




CONTROL BOUNDARY

Engenharia de agentes de IA confiáveis

Engenharia de agentes de IA confiáveis

Ferramentas, autoridade, estado, limites e registros para agentes em produção

Muhammet Şafak

Sumário

Prefácio	6
PARTE I — FUNDAMENTOS	14
Capítulo 1 — O agente não é o sistema	15
Capítulo 2 — Incerteza do modelo	37
Capítulo 3 — Uma taxonomia de falhas para agentes	55
Capítulo 4 — Fronteiras do determinismo	76
PARTE II — FERRAMENTAS E AUTORIDADE	94
Capítulo 5 — Chamada de ferramentas	95
Capítulo 6 — Contratos de ferramentas	116
Capítulo 7 — Permissões e autoridade delegada	138
Capítulo 8 — MCP: ferramentas através de uma fronteira de confiança	158
PARTE III — CONTEXTO, ESTADO E MEMÓRIA	179
Capítulo 9 — Gerenciamento de contexto	180
Capítulo 10 — Estado	200
Capítulo 11 — Memória	219
PARTE IV — LOOPS DE CONTROLE	239
Capítulo 12 — Planejamento e loops	240
Capítulo 13 — Orçamentos e circuit breakers	264
Capítulo 14 — Retries e fallbacks	285
Capítulo 15 — Aprovação humana	307
PARTE V — FRONTEIRAS DE SEGURANÇA	328
Capítulo 16 — Prompt injection	329
Capítulo 17 — PII	350

Capítulo 18 — Secrets	369
Capítulo 19 — Sandboxing	388
PARTE VI — COMPROVAR E OPERAR	404
Capítulo 20 — Observabilidade e tracing	405
Capítulo 21 — Avaliação	428
Capítulo 22 — Controle de custos	449
Capítulo 23 — Resposta a incidentes	465
Capítulo 24 — Um checklist de confiabilidade e reflexões finais	486
Apêndice	500

Prefácio

Imagine uma empresa de fulfillment de médio porte, a Parcelport, na segunda-feira em que seu primeiro agente entra no ar. O agente lê e-mails de clientes, consulta pedidos, altera endereços de entrega e faz reembolsos até um teto. A demonstração correu bem. O protótipo é um prompt, um token de API amplo e um loop que roda até o modelo dizer que terminou. Ninguém na equipe acha que esse é o design final, mas tudo funciona, e a data de lançamento está fixada.

Na quarta-feira, a equipe já aprendeu três coisas. Um ticket gerou uma resposta que prometia uma data de entrega que nenhuma ferramenta havia retornado. Um run chamou a mesma consulta 40 vezes seguidas, e ninguém percebeu até que alguém por acaso o viu rodando. E o e-mail de um cliente continha um parágrafo dirigido ao “assistente”, que o run tratou como uma instrução da Parcelport. Nenhum desses casos foi uma catástrofe. Todos eram previsíveis, e nenhum pôde ser reconstituído por completo depois, porque o único registro do que o agente fez era a sua resposta final.

Este livro trata do que a equipe faz a seguir. Ele não começa por um prompt melhor. Começa por uma pergunta diferente: se o modelo às vezes vai errar, o que o sistema ao redor precisa garantir para que errar seja algo suportável?

A ideia em uma frase

O livro inteiro defende uma única frase:

Os agentes de IA devem ser projetados como tomadores de decisão pouco confiáveis que operam dentro de sistemas de controle confiáveis.

Quero ser cuidadoso quanto ao que essa frase afirma. “Pouco confiável” é uma premissa de design, não um insulto. Ela diz que o modelo é probabilístico, sensível ao que lhe é mostrado e capaz de errar com total fluência, e que o seu design não deve precisar que ele seja outra coisa. Construímos sobre redes e discos pouco confiáveis da mesma forma. Ninguém entrega um design que só funciona quando a rede se comporta, e ninguém se ofende em nome da rede.

Os “sistemas de controle confiáveis” são a outra metade, e é a metade a que este livro dedica suas páginas. É engenharia comum: esquemas, máquinas de estado, permissões, orçamentos, timeouts, filas, logs e testes. Nada disso é novo. O novo é aplicar isso com a cabeça fria a um componente cuja saída é uma sugestão, e não um comando.

É também por isso que o livro trata tudo o que o modelo retorna como uma proposta. Uma chamada de ferramenta, um plano e uma resposta final são propostas. Uma proposta é analisada, validada, conferida com a política, limitada em custo e registrada antes de poder alterar qualquer coisa. O modelo propõe, e o sistema decide.

Por que este livro existe

A maior parte do que se escreve sobre agentes trata de melhorar o modelo: instruções melhores, exemplos melhores, modelos melhores. Esse trabalho importa, e não é o assunto deste livro. Uma equipe pode fazer tudo isso bem e ainda assim entregar um sistema que move dinheiro para o lugar errado num dia ruim, porque um modelo melhor falha com menos frequência, mas não deixa de falhar, e “com menos frequência” não é uma propriedade que se possa prometer a um auditor, a uma equipe financeira ou a um cliente.

As perguntas que restam depois que o modelo é o melhor que vai ser são perguntas de engenharia. Como um reembolso proposto chega ao sistema de pagamentos, e o que o impede quando o valor está errado? O que o agente vê, de onde veio cada parte disso e até onde se pode confiar nela? Como um run termina quando o modelo nunca diz que acabou? O que fica depois, para que quem está de on-call consiga reconstituir o que aconteceu às três da manhã?

Essas perguntas têm boas respostas, e as respostas parecem familiares a quem já construiu sistemas distribuídos. Têm o mesmo formato das perguntas que você faz sobre qualquer componente capaz de falhar de maneiras que não dá para prever por completo. A diferença é só que este componente escreve prosa fluente enquanto falha, o que torna as falhas mais fáceis de passar despercebidas.

Para quem é este livro

O livro foi escrito para engenheiros de backend e de plataforma, SREs, tech leads e as equipes que levam um agente de IA para produção. Você é um engenheiro de software competente. Não vou explicar o que é um modelo de linguagem, e só usarei vocabulário de aprendizado de máquina onde ele mudar uma decisão de controle, e então o explicarei na mesma frase.

Você pode estar construindo o seu primeiro agente, ou herdando um que outra pessoa prototipou. Pode estar do lado da segurança e ter recebido o pedido de revisar um design que não foi feito por você. Em todos esses casos, a pergunta útil é a mesma: onde este sistema acaba confiando no modelo mais do que deveria, e quanto custaria parar de fazê-lo?

Você não precisa ter usado nenhum framework em particular. O livro não recomenda nenhum, e os padrões não dependem de nenhum.

O que este livro não é

Ajuda ser claro sobre os limites, porque o tema convida a divagações.

Este não é um livro de prompt engineering. Os prompts aparecem porque reduzem a taxa de propostas ruins, e isso é útil. Mas um prompt é um pedido, e nenhuma propriedade deste livro se apoia somente em um pedido. Sempre que um capítulo depende de uma instrução, ele nomeia o controle determinístico que se sustenta quando a instrução não é seguida.

Também não é um livro sobre treinamento ou fine-tuning de modelos. Ele trata o modelo como um componente que você chama, e funciona da mesma forma quando você troca esse componente.

Não é um guia de um framework ou de um fornecedor. Produtos reais e protocolos abertos aparecem como exemplos, descritos apenas até onde tenho certeza do seu comportamento, e somente de maneiras que valem entre versões. O padrão é o que importa; o produto é uma ilustração.

Não é um livro sobre ética da IA nem sobre o futuro do trabalho. Esses são temas sérios e merecem seus próprios livros. Este trata de saber se aquilo que você construiu se comporta, se você consegue perceber isso e o que fazer quando não se comporta.

E também não é um livro de ataques. Quando discute prompt injection ou exposição de dados, ele fica do lado de quem defende. Diz o que pode dar errado com detalhe suficiente para justificar um controle e depois passa ao controle. Você não encontrará aqui nenhum payload funcional nem maneiras passo a passo de contornar o que quer que seja.

A estrutura do livro

Cada capítulo serve a uma parte de um modelo que chamo de envelope de controle. Ele tem seis partes, e cada uma responde a uma pergunta:

- **Contexto:** o que o modelo vê, de onde veio cada parte disso e até onde se pode confiar nela?
- **Proposta:** o que o modelo propôs, e isso é tratado como entrada não confiável até que se prove o contrário?
- **Gate:** esta proposta pode produzir efeito, para este principal, agora?
- **Efeito:** como uma ação aprovada chega ao mundo, o que a limita e o que pode desfazê-la?
- **Limite:** onde o loop para, e quanto custa executá-lo?
- **Registro:** que evidência permanece, como o comportamento é medido e o que fazemos quando algo dá errado?

O Capítulo 1 apresenta o envelope de forma adequada. Depois disso, cada capítulo nomeia a parte a que pertence e a pergunta que responde, sem reexplicar o modelo. Se um parágrafo de qualquer capítulo continuasse verdadeiro e útil sem a pergunta de controle, provavelmente ele pertence a outro livro.

Os capítulos estão agrupados em seis partes. A Parte I cobre os fundamentos: o que é um agente como sistema, por que o modelo é incerto, uma taxonomia das maneiras como os agentes falham e onde o determinismo precisa valer. A Parte II cobre ferramentas e autoridade: a chamada de ferramentas, os contratos de ferramentas, as permissões e a autoridade delegada, e o MCP como fronteira de confiança. A Parte III cobre contexto, estado e memória. A Parte IV cobre os loops de controle: planejamento, orçamentos e circuit breakers, retries e fallbacks, e aprovação humana. A Parte V cobre as fronteiras de segurança: prompt injection, PII, secrets e sandboxing. A Parte VI cobre a comprovação e a operação do sistema: observabilidade, avaliação, controle de custos e resposta a incidentes, com um checklist de encerramento.

Um apêndice reúne um glossário, uma referência rápida dos padrões, um modelo de contrato de ferramenta, a taxonomia de falhas em forma de tabela, um checklist de pré-lançamento e um modelo para revisar um incidente que envolva um agente.

A empresa dos exemplos

Para manter os exemplos coerentes, o livro acompanha uma única empresa fictícia. A Parcelport recebe pedidos de lojas online, armazena e despacha mercadorias, e opera a plataforma interna que torna isso possível. Ela é inteiramente inventada. Seus nomes, números e pessoas não descrevem nenhuma organização real.

A Parcelport opera dois agentes. O agente de suporte conversa com os clientes: lê tickets e e-mails, consulta pedidos, altera endereços de entrega, faz reembolsos até um teto e passa todo o resto a uma pessoa. O agente de operações ajuda os engenheiros de on-call da própria empresa: lê logs, métricas e traces, executa scripts de diagnóstico em um sandbox, abre pull requests e inicia um rollback ou uma mudança de feature flag somente com a aprovação de uma pessoa.

Os dois agentes começam como um protótipo igual ao da abertura: um prompt, um token amplo, nenhum limite, nenhum log, nenhum eval. Ao longo do livro, cada capítulo os leva um passo mais perto de um design

que você poderia defender numa revisão. Os exemplos são pequenos de propósito. Estão ali para carregar um padrão, não para descrever um sistema de produção plausível até a última fila.

Todo capítulo abre com um cenário curto, e os cenários são fictícios. Quando escrevo em primeira pessoa, é para lhe dar um julgamento: “colocaria a checagem do teto no gateway de ferramentas”. Nunca é para afirmar uma história que aconteceu. Prefiro lhe dar um exemplo claramente inventado cuja lição seja sólida a um emprestado que não possa sustentar.

Como ler

Se você é novo no assunto, leia os capítulos em ordem. A Parte I lhe dá o vocabulário, e as partes seguintes o supõem. Cada capítulo termina com uma lista curta de pontos-chave e uma frase que leva ao seguinte.

Se você está herdando um agente em operação, comece pelo Capítulo 3, a taxonomia de falhas, e use-a para nomear o que já deu errado. Depois leia o capítulo da parte do envelope que mais dói. Os capítulos foram escritos para se sustentar razoavelmente bem sozinhos, e remetem uns aos outros por número em vez de se repetirem.

Se você está revisando o design de outra pessoa, leia o Capítulo 1 e o checklist de encerramento (Capítulo 24), e use o Apêndice como um conjunto de perguntas. O checklist não é uma certificação. É uma lista de lugares onde um design costuma confiar no modelo mais do que ele mereceu.

Uma palavra sobre a notação antes que você a encontre. Todo o código do livro é pseudocódigo independente de linguagem, em blocos `text` simples, e os diagramas são Mermaid. Evito uma linguagem real porque o padrão deve sobreviver a uma reescrita, e nunca mostro a API de um provedor nem um SDK. A chamada ao modelo é sempre uma única função abstrata, `model.propose(context)`, que retorna uma proposta, porque o que importa é o que você faz com a proposta, não como a obteve. As ferramentas são descritas por contratos escritos em uma pequena notação parecida com JSON Schema, e nenhum texto de prompt real aparece em lugar algum, já que um prompt é um pedido e o livro trata do que se sustenta quando o pedido é ignorado.

Ao longo de todo o livro, cada controle vem com o seu custo. Uma etapa de aprovação torna um reembolso mais lento. Um circuit breaker às vezes interrompe uma tarefa que estava quase terminada. Um trace que ninguém lê é armazenamento que você paga e um conforto que você não mereceu. Direi quando um controle é teatro, e direi quando você não deve usá-lo. Um design sem nenhum atrito não foi verificado.

Os números do livro são ilustrações. Quando escrevo “digamos, um limite de 10 passos”, o 10 é um marcador para tornar o argumento concreto, e não uma recomendação nem uma medição. Não cito tamanhos de modelo, preços, latências nem benchmarks, porque eles mudam mais depressa do que um livro consegue acompanhar, e um design que depende deles já falhou.

Uma palavra sobre a abordagem

O livro é deliberadamente independente de qualquer modelo, provedor ou versão em particular. Se um padrão daqui deixa de funcionar quando você troca o modelo, escrevi mal esse padrão. Trate isso como um teste que você pode aplicar a cada capítulo: substitua o modelo por outro e pergunte se o controle continua valendo. Um controle que sobrevive à troca está fazendo trabalho de verdade. Um que não sobrevive estava pegando carona no bom comportamento do modelo.

O mesmo vale para as falhas. Quando algo dá errado neste livro, a lição é sobre o sistema que permitiu isso ou que o tornou invisível. Nunca é sobre o caráter do modelo, nem sobre uma pessoa que deveria saber melhor. Um design que depende de ninguém jamais cometer um erro vai falhar, e o mesmo vale para um que depende de o modelo nunca cometer um.

Nada disso é uma afirmação de que os agentes são perigosos, ou de que estão prestes a mudar tudo. É uma afirmação de que eles são componentes, e de que componentes que você não consegue prever por completo são exatamente os que vale a pena envolver em coisas que você consegue. Se isso soa modesto, a intenção é essa. A maior parte da confiabilidade é modesta. É o trabalho sem glamour em torno da parte engenhosa que decide se a parte engenhosa é útil numa terça-feira comum.

Vamos começar por aquilo que, exatamente, estamos construindo. O primeiro capítulo desmonta o protótipo e encontra o sistema que se esconde dentro dele.

PARTE I

Fundamentos

Capítulo 1 — O agente não é o sistema

Imagine uma demonstração numa terça-feira na Parcelport. Um engenheiro de plataforma compartilha a tela e cola um e-mail de cliente no protótipo do agente de suporte: uma encomenda chegou com um canto amassado, e o cliente gostaria de receber o dinheiro de volta. O protótipo lê o e-mail, consulta o pedido, considera plausível a alegação de dano, faz o reembolso, escreve uma resposta cortês e a envia. Tudo leva menos de um minuto, e a sala fica em silêncio, como ficam as salas quando algo funciona melhor do que o esperado.

Ninguém na sala está errado em se impressionar. O protótipo é um prompt, um token de API amplo que funciona em todas as ferramentas e para todos os clientes, e um loop que roda até o modelo parar de pedir ferramentas. Não há limite de iterações, nem timeout, nem log além da resposta final. Funciona porque a demonstração é um dia bom: o e-mail é honesto, os serviços respondem, o modelo propõe coisas sensatas.

Agora imagine o mesmo protótipo num dia ruim, com cem tickets na fila. Um e-mail contém um texto que parece uma instrução. Uma consulta dá timeout e o loop propõe a mesma chamada de novo, e de novo. Um reembolso é registrado e a resposta nunca é enviada. Ninguém consegue dizer qual dessas coisas aconteceu, porque a única evidência é a resposta final.

Este capítulo responde a uma pergunta que vem antes de todos os outros controles do livro: se o modelo é apenas um componente do agente, quais são os outros, e quem responde por quê? Ele serve às seis partes do envelope de controle, porque as apresenta. A pergunta de cada parte aparece mais adiante, um capítulo de cada vez. Aqui desenhemos o quadro inteiro uma única vez, para que todo capítulo posterior possa apontar para uma parte dele.

O problema e por que ele é difícil

O problema não é que o protótipo seja ruim. O problema é que ele não tem partes. Dar prompts, escolher ferramentas, chamar serviços, lembrar o que aconteceu, parar, pedir ajuda a uma pessoa e deixar evidências são coisas feitas pela mesma entidade, no mesmo lugar, no mesmo fôlego. Quando essa entidade acerta, tudo está certo; quando erra, tudo está errado ao mesmo tempo, e não há onde ficar para observar a falha.

Como o protótipo é por dentro

Ajuda nomear o que o protótipo contém, porque cada item é uma decisão de design que ninguém tomou de propósito.

- **Um prompt carrega todo o comportamento.** Tom, política de reembolso, regras de escalonamento e instruções de “nunca faça X” são todos prosa. Se valem ou não, depende do modelo naquele dia.
- **Um token carrega toda a autoridade.** O agente pode chamar todas as ferramentas para todos os clientes, porque o protótipo precisou disso e a coisa ficou assim.
- **O loop é do modelo.** O loop termina quando o modelo para de pedir ferramentas. Nada fora do modelo o encerra.
- **O contexto é o que couber.** Os resultados das ferramentas e o texto do e-mail entram no prompt como estão, sem nada que marque qual parte é dado e qual é instrução.
- **O estado é a conversa.** O que o run fez fica na transcrição, de modo que uma queda o perde e um run longo o expulsa.
- **A evidência é a resposta final.** Não há registro dos passos intermediários, então um mau resultado não pode ser explicado.

Nenhum desses itens é incomum. Cada um era razoável no dia em que foi escrito. A soma é um sistema cuja confiabilidade depende por inteiro do único componente que o resto deste livro trata como probabilístico.

Como ele falha

Considere as classes de falha que o livro nomeia (o Capítulo 3 é responsável por elas e dá a cada uma a sua definição e um exemplo). O protótipo não tem nenhum lugar onde alguma das nove seria detectada: uma proposta que não se encaixa em uma ferramenta, uma afirmação que o con-

texto não sustenta, um texto que conduz a chamada seguinte, um loop que se repete, um efeito pela metade, uma autoridade mais ampla que a tarefa, um run que ninguém consegue reconstituir, uma conta que ninguém viu chegar.

A marca de um protótipo não é que uma falha seja provável. É que nenhuma delas tem um lugar onde seria detectada.

Por que a correção óbvia não funciona

A correção óbvia é um prompt melhor, e escreveria um: ele reduz a taxa de propostas ruins. Mas um prompt não é um controle. É um pedido feito a um componente probabilístico, e um pedido que vale na maior parte das vezes não é uma propriedade sobre a qual uma equipe financeira, uma equipe de segurança ou um engenheiro de on-call possam construir. Esperar por um modelo melhor muda a taxa de falha, não o fato de o design ter ou não um lugar para pegar a falha que sobra. O Capítulo 2 explica por que a saída do modelo precisa ser tratada assim.

Portanto este é um problema de engenharia e não de prompting. A questão é onde ficam as fronteiras: que parte do sistema toma qual decisão, com qual evidência, e o que acontece quando essa parte erra.

A palavra “agente” está carregando coisa demais

Parte da dificuldade é o vocabulário. Numa conversa, “agente” pode significar um modelo que retorna uma chamada de ferramenta, um modelo de prompt, um loop, um produto ou uma persona. São objetos diferentes, com modos de falha diferentes, e uma equipe que usa uma só palavra para todos eles não consegue dizer onde um controle pertence. “Coloque uma proteção no agente” não tem endereço.

Este livro usa uma única definição, e a usa de forma consistente.

Um **agente** é um componente: um loop de orquestração que chama um modelo, pede a um gate que verifique as propostas do modelo e aplica os efeitos aprovados por meio de ferramentas. Não é uma pessoa, não é um “bot” e não é o modelo. O modelo é uma parte do agente, e o agente é uma parte do sistema ao seu redor.

A definição é deliberadamente mecânica. Ela tem um loop, uma chamada ao modelo, uma verificação e um efeito, e cada um é algo que você pode apontar no código. “Agente de IA” é permitido quando o contexto pede a expressão mais longa, mas o objeto continua o mesmo.

A anatomia de um agente

Desmonte o protótipo. O que segue é a anatomia que o resto do livro supõe. Cada parte tem uma função, e a função diz quem pode errar.

O modelo: um gerador de propostas

O **modelo** é o componente que transforma contexto em uma proposta. Uma **proposta** é tudo o que o modelo retorna: uma chamada de ferramenta, um plano ou uma resposta final. O modelo não age. Ele não consegue alterar um pedido, enviar um e-mail nem abrir um pull request; só consegue retornar uma estrutura que pede isso.

Esse único fato é o design inteiro. Se o modelo apenas propõe, então tudo o que vem depois de uma proposta é um lugar onde um engenheiro pode colocar código. O modelo pode errar, porque nada do que ele retorna produz efeito até que outra coisa concorde.

O Capítulo 2 é responsável pela pergunta de por que a saída do modelo precisa ser tratada assim. Para este capítulo basta guardar a consequência: a proposta é entrada não confiável, no mesmo sentido em que o corpo de uma requisição que chega pela rede é entrada não confiável.

O orquestrador: código determinístico que executa o loop

O **orquestrador** (também chamado de runtime do agente) é o código determinístico que executa o loop. Ele monta o contexto, chama o modelo, entrega a proposta ao gate, aplica o efeito, faz valer os limites e escreve o registro. Ele é responsável pelo fluxo de controle. O modelo nunca chama o orquestrador; o orquestrador chama o modelo.

Essa inversão é fácil de deixar passar num protótipo, em que pode parecer que o modelo “conduz”. Num design que se sustenta, o modelo é uma função que o orquestrador chama uma vez por passo, e o orquestrador tem a próxima linha de código, não importa o que a função tenha retornado.

Um **run** é uma execução de um agente para uma tarefa, do início até uma resposta final, um hand-off ou uma parada. Ele tem um id e um status. Um **passo** é uma volta do loop dentro de um run. Um **turno** é uma troca entre o agente e uma pessoa numa conversa; um run pode ter vários turnos e um turno pode ter vários passos. Essas três palavras continuam aparecendo, e a diferença entre elas importa para limites, estado e custo.

Ferramentas e as classes de efeito

Uma **ferramenta** é uma capacidade nomeada que o agente pode pedir, com um contrato. Uma **chamada de ferramenta** é uma proposta de usar uma ferramenta com argumentos; ela só se torna um **efeito** depois que o gate a permite. O Capítulo 5 trata da chamada de ferramentas e o Capítulo 6 trata do contrato de ferramenta; o ponto por ora é que uma ferramenta é a única maneira de um run tocar o mundo.

O support-agent da Parcelport tem sete ferramentas e o ops-agent tem oito. O que as diferencia entre si é a **classe de efeito**, uma entre quatro: leitura, escrita reversível, escrita irreversível e efeito colateral externo.

`lookup_order` é uma leitura; `update_shipping_address` é uma escrita reversível; `issue_refund` é uma escrita irreversível;

`send_customer_reply` é um efeito colateral externo, porque alcança uma pessoa que a Parcelport não pode chamar de volta. A classe de efeito diz o que uma chamada pode fazer ao mundo. Se uma chamada precisa de aprovação humana é outra questão, respondida pela política no gate.

Montagem do contexto

A **montagem do contexto** é o passo do orquestrador de escolher, ordenar e rotular o que entra no contexto de uma chamada ao modelo. O modelo vê o que o orquestrador lhe dá e nada mais. Essa frase parece trivial, e é a razão de existir de boa parte do livro.

No protótipo, o contexto é o que a transcrição acumulou. Num sistema projetado, cada parte do contexto tem uma origem, um nível de confiança e uma razão para estar ali: uma política de sistema escrita pela equipe de plataforma, um texto de ticket marcado como não confiável, resultados de ferramentas marcados pela ferramenta que os retornou. O Capítulo 9

constrói isso. Aqui basta dizer que o contexto é algo que o orquestrador constrói, o que significa que é algo em que o orquestrador pode errar, e portanto é parte do sistema de controle e não parte do prompt.

Estado

O **estado** são os fatos sobre um run, mantidos pelo orquestrador no run store: passos, resultados, status. Não é a transcrição. Não é a memória, que é a informação mantida entre runs e que pode moldar contextos posteriores. O estado trata deste run; a memória trata do mundo depois do run. O Capítulo 10 trata do estado e o Capítulo 11 trata da memória, e os dois são mantidos separados ao longo do livro porque misturá-los é uma fonte comum de F5 (loop descontrolado ou contexto obsoleto).

A razão pela qual o estado importa no nível da arquitetura é que um run é uma coisa de longa duração. Ele pode esperar por uma pessoa, sobreviver a uma reinicialização ou ser retomado por outro processo. Algo que não seja o contexto do modelo precisa lembrar em que ponto ele está.

O gate

O **gate** é a verificação determinística entre uma proposta e um efeito. Ele tem três resultados: allow, refuse ou needs approval. Na Parcelport, o gate é implementado pelo motor de políticas e pelo gateway de ferramentas, que validam uma chamada proposta contra o contrato de ferramenta e verificam permissões e pré-condições. O gate decide; quando ele permite uma chamada, o orquestrador inicia o efeito e o gateway de ferramentas anexa a credencial para aquela única chamada, de modo que o agente nunca detém uma credencial ampla. Toda ferramenta passa pelo gate, as leituras inclusive; para uma leitura, o gate é enxuto (esquema, allowlist e propriedade, sem aprovação e sem chave de idempotência).

“O gate recusou a chamada” é uma frase completa neste livro. Ela não depende de o modelo concordar. O gate é o lugar onde uma **política** (uma regra escrita como dados ou código, nunca como prosa num prompt) encontra uma proposta.

A observação e o registro

Quando um efeito acontece, ou quando o gate recusa, o resultado volta ao contexto como uma **observação**, e o loop continua. É assim que um run se corrige: não porque o modelo “aprendeu”, mas porque o contexto do próximo passo contém a recusa ou o resultado.

Ao lado do loop, o **registro** guarda a evidência: cada proposta, veredicto do gate, aprovação e efeito, em uma forma que o on-call possa ler depois. Um registro que só existe quando algo deu errado não é um registro. Ele precisa ser escrito também nos dias bons, porque, no dia de um incidente, os dias bons são o baseline.

A tese e o envelope de controle

Com as partes nomeadas, a tese deste livro pode ser enunciada, e deve ser entendida exatamente como está escrita:

Os agentes de IA devem ser projetados como tomadores de decisão pouco confiáveis que operam dentro de sistemas de controle confiáveis.


Três palavras carregam o peso. “Pouco confiável” é uma premissa de design, não um insulto: o componente é probabilístico, sensível ao seu contexto e capaz de errar com total confiança, e um design não deve precisar que seja diferente. O Capítulo 2 dá as razões; redes e discos recebem o mesmo tratamento. “Tomadores de decisão” admite que o modelo é útil justamente porque escolhe entre opções que não poderíamos enumerar em código. E “sistemas de controle confiáveis” diz de onde vem a confiabilidade: da engenharia comum em torno do modelo, como esquemas, máquinas de estado, permissões, orçamentos, timeouts, filas, logs e testes.

As seis partes

Este livro decompõe esse sistema de controle em seis partes, chamadas de **envelope de controle**. Os nomes são fixos e todo capítulo posterior os cita.

Parte	A pergunta que ela responde	Construída nos capítulos
Con- texto	O que o modelo vê, de onde veio cada parte disso e até onde se pode confiar nela?	9, 10, 11, 16, 17 (e 8)
Pro- posta	O que o modelo propôs, e isso é tratado como entrada não confiável até que se prove o contrário?	2, 5, 12 (e 4)
Gate	Esta proposta pode produzir efeito, para este principal, agora?	4, 6, 7, 15 (e 8, 16)
Efeito	Como uma ação aprovada chega ao mundo, o que a limita e o que pode desfazê-la?	5, 6, 18, 19
Limite	Onde o loop para, e quanto custa executá-lo?	12, 13, 14, 22
Regis- tro	Que evidência permanece, como o comportamento é medi- do e o que acontece quando algo dá errado?	20, 21, 23 (e 10, 17)

O próximo diagrama mostra como elas se conectam. Procure primeiro o loop: o contexto vai ao modelo, o modelo retorna uma proposta, o gate decide, e só então um efeito acontece. Depois olhe as duas coisas que cercam o loop: o limite em volta do ciclo inteiro e as linhas pontilhadas do registro, que escuta cada passo.



As setas sólidas são o fluxo do run. O modelo fica no meio porque é um componente entre vários, e tudo o que faz do run algo que você consegue operar fica ao redor dele. Dois caminhos merecem atenção. O caminho da recusa volta ao contexto, de modo que o modelo vê por que foi recusado. E o caminho “stopped” sai do limite em direção a uma pessoa, porque um run que não consegue terminar ainda deve a alguém um hand-off.

O loop em código

O mesmo quadro, como pseudocódigo, é um passo do loop. Todo capítulo que o estender citará este bloco e mudará uma parte.

```
function runStep(run):
    context = assembleContext(run)           // Context
    proposal = model.propose(context)         // Proposal: untrusted
    record(run, "proposal", proposal)
    verdict = gate.check(run, proposal)       // Gate
    if verdict.kind == "refuse":
        record(run, "refused", verdict.reason)
        return addObservation(run, verdict)  // model sees refusal
    if verdict.kind == "needs_approval":
        return suspend(run, verdict.request) // a human decides
    if proposal.kind == "final_answer":
        record(run, "final", proposal.text)
        run.status = "done"                  // ends runAgent loop
        return run
    // intent first: a crash between effect and record still leaves a trace
    record(run, "intent", verdict.call)
    result = effect.apply(run, verdict.call)  // Effect
    record(run, "effect", result)
    return addObservation(run, result)
```

Duas coisas neste bloco merecem ser lidas devagar. Primeiro, o modelo é chamado em exatamente uma linha. Todo o resto é código comum, que estaria ali mesmo que a proposta tivesse vindo do envio de um formulário. Segundo, o registro é escrito antes do efeito (“intent”) e depois dele (“effect”), de modo que uma queda no intervalo deixa evidência do que estava prestes a acontecer. Essa ordenação é uma decisão pequena com grande efeito sobre como você se recupera, e os capítulos 10 e 20 voltam a ela.

O limite envolve o passo:

```
function runAgent(run):
    while run.status == "running":
        try:
            bound.check(run)                // Bound
            runStep(run)
        on BoundExceeded:
            record(run, "stopped", run.bound_reason)
            return handOff(run, "bound exceeded") // degraded mode
    return run
```

Uma resposta final encerra o run ao definir o seu status; o limite o encerra quando o modelo nunca propõe uma. O loop tem, portanto, duas saídas que o orquestrador controla, e nenhuma que somente o modelo controle.

(Uma proposta do tipo “plan” é armazenada como estado do run e tratada como o Capítulo 12 descreve; o esboço a deixa de fora.)

Por que seis e não mais

Uma objeção razoável é que a lista poderia ser mais longa: uma parte “memória”, uma parte “segurança”, uma parte “custo”. Mantive seis porque cada parte precisa responder a uma pergunta que alguém possa assumir e testar. A memória é uma fonte de contexto, então pertence ao Contexto. A segurança não é uma parte, e sim uma propriedade que várias partes produzem: o gate recusa, o efeito roda em sandbox, o contexto é rotulado. O custo é um limite. Uma decomposição em que a mesma falha pertence a três partes é uma decomposição que ninguém consegue usar num incidente.

Também ajuda ver o envelope como uma maneira de perguntar onde uma falha deveria ter sido detectada. Se um reembolso foi para o pedido errado, uma falha F2 (ferramenta incorreta ou argumentos incorretos), a parte Proposta diz que o modelo propôs errado, mas a parte Gate pergunta por que a pré-condição “o pedido pertence ao cliente deste run” não foi verificada em código. A primeira resposta é um fato; a segunda é uma questão de design, e a segunda é a que um engenheiro pode consertar.

Direitos de decisão

Uma vez nomeadas as partes, uma questão de design se torna concreta: para cada decisão que o trabalho do agente envolve, quem detém o direito de tomá-la? A palavra “decidir” é usada aqui com cuidado. O modelo propõe. O código decide o que acontece com uma proposta. Uma pessoa decide o que o código não tem permissão para decidir sozinho.

Uma tabela de **direitos de decisão** torna isso explícito. As duas tabelas a seguir são ilustrativas, para o estado-alvo dos dois agentes da Parcelport; elas mostram como começaria, e uma equipe com tolerâncias diferentes moverá algumas linhas.

Para o `support-agent`:

Decisão	O modelo propõe	O código decide	A pessoa decide
A que pedido o ticket se refere	O id de um pedido candidato extraído do e-mail	Se esse pedido pertence a este cliente e a este run	Nada, a menos que a correspondência seja ambígua e o run faça um escalonamento
Se a alegação de dano é plausível	Uma leitura do texto do ticket	Nada; este é um julgamento que o modelo fornece como entrada	Sam, em qualquer caso enviado para revisão
O valor do reembolso	Um valor e um reason code	O saldo reembolsável, a moeda e o teto	Sam, acima de <code>refund_ceiling</code>
Se um endereço pode mudar	Um novo valor de endereço	Se a encomenda já chegou a uma transportadora	Nada; a regra de envio é código
A redação da resposta	Um rascunho	Quais afirmações estão fundamentadas nos resultados das ferramentas; se a resposta pode ser enviada	Sam, nas respostas que a política marca para revisão
Quando parar	Possivelmente uma resposta final	Limites de iterações, de tempo e de gasto; hand-off	Sam, no hand-off

Para o `ops-agent`:

Decisão	O modelo propõe	O código decide	A pessoa decide
Que logs e métricas examinar	Uma consulta	Intervalo de tempo, tamanho e escopo de acesso	Nada
O que um script de diagnóstico faz	Um script ou seus parâmetros	O que o sandbox consegue alcançar: sem egress de rede, sem credenciais	Nada
Qual é a causa provável	Um diagnóstico	Nada; é uma proposta mantida junto com a sua evidência	Robin, que a lê
Se deve fazer rollback ou virar uma flag	Uma ação recomendada	Se a ação é permitida e se os limites foram atingidos	Robin, sempre, porque a política exige aprovação
Se deve abrir um pull request	Uma mudança	Que o repositório de destino é permitido	Uma pessoa que revisa e faz o merge

Duas coisas se destacam. A primeira é que há linhas em que a contribuição do modelo é o próprio julgamento (“a alegação é plausível?”, “qual é a causa?”) e a contribuição do código é levá-lo a uma pessoa junto com a sua evidência, em vez de questioná-lo. O modelo é útil porque lida com a parte do trabalho que o código não consegue especificar. A arquitetura não remove essa parte; ela limita o que essa parte pode alcançar.

A segunda é que as linhas em que o código decide são as que envolvem valores, permissões, limiares e tempo. Elas são computáveis e verificáveis, e são as linhas em que um erro é caro. O Capítulo 4 desenvolve os critérios para traçar essa linha (reversibilidade, verificabilidade, frequência, tolerância e explicabilidade). Por ora, note o padrão: o modelo escolhe dentro de um espaço que o código já delimitou.

O que a tabela lhe dá

Uma tabela de direitos de decisão é um artefato pequeno com usos grandes. Ela diz a um revisor, em poucas linhas, onde uma falha seria detectada. Diz a um engenheiro novo o que não colocar num prompt. E torna o desacordo concreto: quando alguém propõe mover a checagem do teto para o prompt “por flexibilidade”, a tabela mostra o que está sendo trocado, que é uma checagem que vale em toda chamada por uma checagem que vale quando o modelo obedece.

Ela também encontra lacunas. Uma linha cuja célula “o código decide” está vazia e cuja célula “a pessoa decide” também está vazia é uma decisão que o modelo está tomando sozinho. Às vezes isso é aceitável, já que a redação de um rascunho antes de ser revisado não é uma movimentação de dinheiro. Mas deve ser uma decisão que alguém tomou, não uma omissão.

Opções de arquitetura

Nem todo problema precisa de um loop de agente, e a primeira decisão de arquitetura é quanto de um loop construir. Há quatro formatos comuns. Eles diferem em quem controla o fluxo do trabalho e, portanto, em quão grande é a superfície que o envelope de controle precisa cobrir.

Formato	Quem controla o fluxo	O que o modelo faz	Superfície de controle	Costuma bastar quando
Chamada de passo único	O código	Uma proposta, usada como dado	Uma proposta a validar	A tarefa é uma transformação: classificar, extrair, resumir, redigir
Workflow	O código, com passos fixos	Preenche ou escolhe dentro de um passo	Uma proposta por passo; a ordem não está em questão	Os passos são conhecidos de antemão e variam apenas no conteúdo
Loop com ferramentas	O orquestrador, conduzido por propostas	Escolhe a próxima ferramenta e os argumentos	Cada ferramenta, cada argumento, o número de passos, o caminho inteiro	Os passos dependem do que os passos anteriores encontraram
Vários agentes	Vários loops, passando trabalho entre si	Cada loop propõe dentro do seu próprio papel	A superfície de cada loop, mais cada hand-off entre loops	O trabalho se divide em partes com ferramentas, permissões ou contextos diferentes

Chamada de passo único

O formato mais simples é uma chamada única: o código monta o contexto, o modelo retorna uma proposta, o código a valida e a usa. Classificar o assunto de um ticket é um exemplo. A superfície de controle é pequena: a saída precisa corresponder a um esquema, o que detecta F1 (saída malformada), o valor precisa pertencer a um conjunto fechado, e o que acontece depois é decidido pelo código. Se a classificação estiver errada, o dano é limitado pelo que o código faz com uma classificação.

Workflow

Um **workflow** é um design em que o código conduz a sequência e o modelo preenche passos. Por exemplo: o código consulta o pedido, o código pede ao modelo que redija uma resposta a partir dos campos do pedido, o código verifica se cada afirmação do rascunho corresponde a um campo, o código a envia. O caminho é fixo. O modelo nunca escolhe o que acontece a seguir; ele apenas produz conteúdo para um espaço.

Os workflows são subestimados. O caminho é testável, os limites são triviais (o número de passos é o número de nós), e as falhas que dependem de o modelo conduzir o caminho, F2 de ferramenta incorreta e F5 de loop

descontrolado, desaparecem em sua maior parte. Os argumentos incorretos (F2) e o contexto obsoleto (F5) não desaparecem, porque o modelo ainda preenche os espaços a partir do contexto. O que você paga é flexibilidade: um workflow lida com os casos em que o seu autor pensou, e não consegue seguir um ticket por um ramo imprevisto.

Loop com ferramentas

Num **loop com ferramentas**, o modelo propõe qual ferramenta chamar a seguir, vê o resultado e propõe de novo, até propor uma resposta final ou até um limite pará-lo. Este é o formato de que o livro mais trata, porque tem a maior superfície e exige o maior controle. Ele compensa esse custo quando o caminho depende do que os passos anteriores encontraram, como numa investigação: o agente de operações não sabe se o próximo passo útil é uma consulta de logs, uma métrica ou um trace até ter visto o último.

O loop é o lugar onde as nove classes de falha podem ocorrer. Essa é a razão de o loop receber um gate, um limite e um registro, e a razão pela qual não construiria um onde um workflow bastasse.

Vários agentes

Com **vários agentes**, diversos loops passam trabalho uns aos outros: um reúne informação, outro redige, um terceiro revisa. A motivação costuma ser real. Partes diferentes do trabalho precisam de ferramentas, permissões ou contextos diferentes, e separá-las mantém estreita a superfície de cada loop.

O custo é que o número de superfícies de controle cresce mais depressa que o número de agentes. Cada loop tem o seu próprio gate. Cada hand-off é um novo lugar onde o contexto é montado e onde uma instrução poderia passar de dado para a entrada do agente seguinte: F4 (sequestro de instruções). Cada hand-off é também um lugar onde o estado pode ficar obsoleto (F5) e onde uma falha parcial pode passar despercebida: F6 (falha parcial silenciosa). Se você dividir, trate a mensagem de um agente para outro como uma proposta vinda de uma fonte não confiável, e ponha um gate nela. Um design que confia na saída de um agente porque “é o nosso agente” é um design que desloca a fronteira de confiança para o meio do sistema.

Não afirmo que um design com vários agentes esteja errado. Afirmo que ele deve ser justificado por uma fronteira de que você precisa (uma fronteira de permissão, uma fronteira de contexto), e não pelo fato de o diagrama parecer organizado.

O princípio da menor agência

Isso nos leva à regra que aplicaria antes de qualquer outra: **use a menor agência que resolva o problema**. Agência aqui significa quanto do fluxo o modelo pode conduzir. Se uma tarefa é resolvida por uma única chamada, não construa um workflow; se um workflow a resolve, não construa um loop; se um loop a resolve, não construa vários.

Cada degrau acima na tabela alarga a superfície que as seis partes precisam cobrir. Cada um também move um pedaço do fluxo de controle de um código que você pode testar linha por linha para uma proposta que você só consegue avaliar estatisticamente. Essa é uma boa troca quando a tarefa a exige e uma troca ruim quando não exige.

Um teste curto ajuda. Escreva a tarefa como um fluxograma antes de decidir o formato.

```
function chooseShape(task):
  // cheapest shape first: try each in order of agency
  if task is one transformation of one input:
    return "single_step_call"
  if task.steps can be listed in advance and vary only in content:
    // a workflow: code owns the path, the model fills slots
    return "workflow"
  if next step depends on what earlier steps found:
    if one set of tools and one permission scope is enough:
      return "tool_using_loop"
    // different scopes or contexts force a boundary
    return "multiple_agents, each with its own gate"
  // nothing above applies: the task is under-specified
  raise TaskNotUnderstood
```

A ordem das verificações é o ponto. O formato mais barato que serve é tentado primeiro, e o loop é o que você alcança apenas quando o caminho não pode ser listado. Se você não consegue desenhar o fluxograma de uma tarefa e não consegue dizer por que o caminho varia, o problema não é a arquitetura; é que a tarefa ainda não foi compreendida.


No caso da Parcelport, a resposta difere conforme a tarefa. Classificar o assunto de um ticket recebido é uma chamada única. Redigir uma resposta de “onde está a minha encomenda”, quando o status do pedido é conhecido, é um workflow: consultar, redigir, verificar, enviar. Tratar uma alegação de dano de ponta a ponta, com uma consulta, uma possível verificação de endereço, um possível reembolso e uma resposta, é um loop, porque os passos necessários dependem do que o pedido mostra. Investigar um alerta de latência é um loop, com um conjunto maior de ferramentas e um caminho mais longo. Uma equipe nessa posição frequentemente acaba com alguns workflows, um ou dois loops e nenhum design com vários agentes, e esse é um bom resultado, não um resultado tímido.

A Parcelport, do protótipo às partes

Agora podemos descrever como é a passagem do protótipo ao alvo apenas em termos de arquitetura, sem nenhum dos controles posteriores.

No protótipo, o agente é o sistema: um prompt, um token, um loop que pertence ao modelo. No alvo, as peças têm responsáveis separados. A equipe de plataforma é responsável pelo orquestrador, que executa o loop e escreve o registro. O gateway de modelos é responsável pelas credenciais do provedor do modelo, de modo que o agente nunca as detém, além dos orçamentos e dos rate limits. O motor de políticas e o gateway de ferramentas formam o gate. O serviço de aprovação coloca uma ação pendente diante de Sam ou de Robin e devolve uma aprovação vinculada à chamada exata. O run store guarda o estado. O trace pipeline coleta os spans.

O próximo diagrama mostra onde cada componente fica e a que parte do envelope ele serve. Observe com o que o orquestrador conversa (o gateway de modelos e o gateway de ferramentas) e o fato de que somente o gateway de ferramentas alcança os serviços e os stores.



Duas características deste quadro são a arquitetura em miniatura. O orquestrador é o único componente que conversa tanto com o gateway de modelos quanto com o gate, e por isso é onde o loop vive. O gate decide, o orquestrador inicia `effect.apply`, e o gateway de ferramentas anexa a credencial, chama o serviço e devolve o resultado por meio de si mesmo. Nenhuma credencial de serviço passa pelo modelo, e nenhum serviço é alcançado senão pelo gateway de ferramentas. Se uma proposta nunca passa pelo gate, ela nunca recebe uma credencial.

Note também o que o quadro não diz. Ele não diz que o modelo é bom ou ruim no seu trabalho. Diz que o design sobrevive a qualquer um dos dois.

O que muda primeiro

Se me entregassem o protótipo numa segunda-feira e me pedissem para torná-lo limitado o bastante para rodar com tickets reais, não começaria construindo as seis partes. Começaria pelas mudanças mais baratas que dão mais espaço de manobra.

Primeiro, colocar o loop num orquestrador com um limite de iterações e um timeout, para que o modelo deixe de ser responsável pela saída. Segundo, anotar a proposta e o resultado de cada passo, mesmo que o primeiro registro seja tosco. Terceiro, mover o teto e a checagem de “pertence a este cliente” do prompt para um gate na frente de `issue_refund`. Quarto, substituir o token amplo por uma credencial que o gateway de ferramentas anexa a uma única chamada. Depois dessas quatro, o protótipo ainda é um protótipo, mas cada um dos capítulos posteriores tem onde se encaixar.

Essa ordem é uma opinião, e as variáveis são da equipe: o que o agente consegue alcançar, quanto custa quando um passo é desperdiçado e quem recebe um page quando um limite interrompe uma tarefa quase concluída.

O mapa do livro

O restante do livro constrói as seis partes na ordem em que uma equipe costuma precisar delas. A Parte I (capítulos 1 a 4) estabelece a base: este capítulo desenha o todo, o Capítulo 2 trata a saída do modelo como uma proposta, o Capítulo 3 nomeia as classes de falha e o Capítulo 4 traça a linha entre o que o modelo propõe e o que o código decide. A Parte II trata de ferramentas e autoridade (capítulos 5 a 8), a Parte III de contexto, estado e memória (capítulos 9 a 11), a Parte IV de loops de controle (capítulos 12 a 15), a Parte V de fronteiras de segurança (capítulos 16 a 19) e a Parte VI de comprovar e operar (capítulos 20 a 24). Para encontrar um problema específico, use a tabela do envelope de controle acima; para construir do zero, siga a ordem, que acompanha grosso modo o modo como um protótipo amadurece.

Trade-offs e custos

Separar o agente em partes não é de graça, e o custo recai sobre várias pessoas.

Custa tempo de engenharia e uma coisa nova para manter disponível.

Um orquestrador, um gate e um registro são serviços, ou ao menos bibliotecas, que alguém mantém e que precisam de testes, deploys e on-call. O gate está no caminho de todo efeito, então a sua disponibilidade se torna a disponibilidade do agente. Uma equipe de três pessoas com um agente num cenário de baixo risco pode razoavelmente entregar uma versão mais enxuta de cada parte e aceitar mais risco de olhos abertos.

Custa latência. Toda proposta passa por validação, toda chamada pelo gate, e algumas por uma pessoa. Digamos que uma checagem do gate acrescente um pequeno atraso fixo a cada passo; num run de 12 passos, esse é um atraso que o usuário sente. O custo vale a pena para efeitos que não podem ser desfeitos. É mais difícil de justificar para leituras. Colocaria as checagens mais pesadas nas escritas irreversíveis e nos efeitos colaterais externos, e manteria leves os caminhos de leitura.

Custa a demonstração. O protótipo da abertura era rápido e impressionante precisamente porque nada se interpunha no seu caminho. Um sistema projetado recusa chamadas, espera por aprovação e para nos limites, e alguns desses comportamentos parecem o sistema ficando pior. As pessoas interessadas que viram a demonstração perguntarão por que a versão real é mais lenta e mais cautelosa. A resposta honesta é que a demonstração rodou num dia bom.

Custa um novo tipo de revisão. O on-call agora precisa ler um registro para saber o que um run fez e por que o gate recusou. Sam precisa ler uma requisição de aprovação e decidir num prazo razoável. Se as requisições forem vagas ou chegarem com frequência demais, a aprovação vira teatro: sempre concedida em segundos, sem proteger nada. A tabela de direitos de decisão ajuda ao dizer quais aprovações merecem a atenção de uma pessoa, e o Capítulo 15 volta a isso.

Custa flexibilidade, de propósito. Um gate recusa propostas que o modelo poderia ter acertado. Um reembolso recusado que teria sido correto é um custo real, pago por um cliente real e por uma liderança de suporte real. O design aceita falsas recusas em troca de falsas permissões limitadas, e o equilíbrio certo é uma questão de ajuste que depende de quanto custa um efeito errado em comparação com quanto custa uma recusa errada. Não conheço esse equilíbrio para o seu sistema, e ele só se encontra observando as recusas em produção.

Quando não usar isto

Não construa o envelope inteiro para uma tarefa que uma chamada única ou um workflow resolve. Mantenha enxuto o gate na frente das leituras (esquema, allowlist, propriedade) em vez de pulá-lo, mesmo para uma ferramenta que hoje não expõe nada sensível; o custo é pequeno e a ferramenta não continuará assim. E não adote o vocabulário das seis partes como um checklist a cumprir; ele é uma maneira de perguntar onde uma falha seria detectada. Se a pergunta tem uma resposta que cabe num cartão, o cartão é o design.

Erros comuns

Estas são armadilhas de design. Cada uma é razoável no dia em que é escolhida.

- **Tratar “o agente” como uma coisa só.** É tentador porque a palavra é cômoda e o protótipo é um único arquivo. O custo é que os controles ficam sem endereço. Corrija nomeando separadamente o modelo, o orquestrador, as ferramentas, o gate e o registro, no design e no código, para que uma revisão possa dizer em qual deles uma mudança toca.
- **Deixar o modelo ser responsável pela saída do loop.** É tentador porque “parar quando terminar” é o comportamento natural. Um loop que só termina quando o modelo para de pedir ferramentas termina quando o modelo diz, e essa não é uma saída que você controla. Corrija com um limite que o orquestrador faz valer, e um hand-off quando ele dispara.
- **Colocar uma regra no prompt e chamá-la de controle.** É tentador porque funciona na demonstração e não custa nada para implantar. O prompt reduz a taxa de violações, mas não garante nenhuma. Corrija nomeando, para cada regra do prompt, o código que a faz valer, e escrevendo “ainda sem controle” onde não houver nenhum.
- **Recorrer a vários agentes para organizar o design.** É tentador porque os papéis se encaixam bem em caixas. O custo são mais gates, mais hand-offs e mais lugares para o estado ficar obsoleto. Corrija exigindo uma fronteira (de permissão ou de contexto) antes de dividir um loop.
- **Confiar na saída de um agente dentro do sistema.** É tentador porque “é nosso”. Mas a mensagem de um agente que leu o e-mail de um cliente pode carregar consigo a influência desse e-mail. Corrija tratando as mensagens entre agentes como propostas que passam por um gate.
- **Construir o envelope completo antes de saber o que o agente faz.** É tentador porque a lista é longa e as partes são interessantes. O custo é um design pesado para uma tarefa que um workflow resolveria. Corrija com o teste de formato acima, e começando pelas quatro mudanças baratas.

- **Usar o vocabulário de forma frouxa nas revisões.** É tentador porque as palavras parecem familiares. “O agente fez um reembolso ruim” culpa um componente que não fez nada; o design deixou uma proposta chegar à ferramenta de reembolso sem uma checagem do teto. Corrija nomeando a parte do envelope que deveria ter detectado a falha. O Capítulo 3 dá a taxonomia para isso.

Aviso: A versão mais cara do primeiro erro é um agente que detém um token amplo. Tudo o que o gate teria verificado fica então inalcançável, porque a credencial já permite a chamada. Trate o token como parte do trabalho do gate, e não da configuração do agente (Capítulo 7).

Pontos-chave

- Um agente é um componente feito de um loop de orquestração, um modelo, um gate e ferramentas; o modelo é uma parte dele, e chamar o conjunto inteiro de “o modelo” deixa os controles sem endereço.
- O modelo é um gerador de propostas: tudo o que ele retorna é entrada não confiável até que o gate permita, e nada do que ele retorna altera coisa alguma por si só.
- A tese é que os agentes de IA devem ser projetados como tomadores de decisão pouco confiáveis que operam dentro de sistemas de controle confiáveis, e o sistema de controle é engenharia comum: esquemas, máquinas de estado, permissões, orçamentos, timeouts, filas, logs e testes.
- O envelope de controle tem seis partes, Contexto, Proposta, Gate, Efeito, Limite e Registro, e cada parte responde a uma pergunta que alguém pode assumir e testar.
- Uma tabela de direitos de decisão mostra quais decisões o modelo propõe, quais o código decide e quais uma pessoa decide; as linhas em que ninguém decide são lacunas a fechar ou omissões a justificar.
- Escolha a menor agência que resolva o problema: uma chamada única, depois um workflow, depois um loop, depois vários agentes, porque cada degrau alarga a superfície que o envelope de controle precisa cobrir.

- Um prompt não é um controle: ele reduz a taxa de propostas ruins, e qualquer propriedade que você precise que valha em toda chamada pertence a um código que roda depois que o modelo respondeu.

As partes agora estão nomeadas e a tese está sobre a mesa, mas um gate precisa tratar a saída do modelo com um tipo particular de suspeita, e essa suspeita precisa de uma razão. O Capítulo 2 a fornece: o que é incerto na saída de um modelo, que sinais merecem confiança e como transformar essa incerteza numa decisão que o código possa tomar.

Capítulo 2 — Incerteza do modelo

Suponha que, numa quarta-feira comum na Parcelport, um cliente escreva perguntando onde está a encomenda dele, e o agente de suporte faça o que foi construído para fazer: chama `lookup_order` para `ord-7f3k2m91`, recebe o status “entregue à transportadora” e redige uma resposta. O rascunho é educado, claro e termina com uma frase dizendo que a encomenda chegará na quinta-feira. Nenhum resultado de ferramenta contém uma data de entrega. Sam, responsável pelo suporte, percebe isso numa revisão de rotina e pergunta a Alex, da equipe de plataforma, o que aconteceu.

Alex reproduz o ticket em staging com o mesmo e-mail e o mesmo resultado de ferramenta. O novo rascunho diz que a encomenda “deve chegar nos próximos dias”. Uma terceira reprodução gera um rascunho que não cita data alguma e se oferece para verificar de novo amanhã. Nada estava mal configurado. Nada mudou entre as três execuções, e os três rascunhos divergem sobre algo em que um cliente vai se basear para agir.

Uma semana depois, a equipe de plataforma migra o gateway para um modelo mais novo, como planejado, e os rascunhos mudam outra vez. Melhores em alguns aspectos, piores em outros, e ninguém consegue dizer de antemão quais tickets mudaram. A equipe agora tem uma pergunta que “escreva um prompt melhor” não responde: como construir sobre um componente cuja saída varia entre chamadas idênticas, que pode ser fluente e errado ao mesmo tempo, e que muda quando outra pessoa troca o modelo?

Este capítulo pertence à parte **Proposta** do envelope de controle. A pergunta que ele responde é a da própria parte: o que o modelo propôs, e isso é tratado como entrada não confiável até prova em contrário? O Capítulo 1 deu nome à parte. Este capítulo explica por que a resposta precisa ser “não confiável” e o que você pode medir e construir depois de aceitar isso.

O problema e por que ele é difícil

Uma proposta é aquilo que o modelo devolve: uma chamada de ferramenta, um plano ou uma resposta final. Ela é produzida por um processo que amostra uma distribuição sobre as continuações possíveis do contexto. Cinco propriedades desse processo importam para quem projeta controles. Nenhuma delas é um defeito a ser corrigido na próxima versão; são a forma do componente.

Cinco propriedades

Produção probabilística. O mesmo contexto pode gerar propostas diferentes. A amostragem é uma parte deliberada de como esses componentes geram texto e, mesmo onde ela é reduzida, a implantação em torno do modelo (batching, hardware, um modelo substituído por trás de um nome estável) não oferece nenhuma promessa de saída idêntica byte a byte. A consequência prática é que uma única execução bem-sucedida prova pouco. Um comportamento que você observou uma vez é um comportamento que pode ocorrer, não um que vai ocorrer.

Sensibilidade ao contexto. O mesmo pedido, em outro contexto, pode produzir outra proposta. Um cliente pede um reembolso; com o status do pedido no topo do contexto, a proposta é uma; com uma longa conversa de e-mails acima dele, é outra; com os mesmos fatos em outra ordem, uma terceira. A mudança não precisa estar nos fatos. Ordem, tamanho, redação, um resultado de ferramenta a mais e uma frase solta num e-mail citado alteram a saída. É por isso que o Capítulo 9 trata a montagem do contexto como engenharia, e não como decoração.

Erro fluente. Uma proposta errada não vem marcada como errada. Uma afirmação sem fundamento (F3) tem exatamente a mesma aparência de uma fundamentada, porque as duas são produzidas do mesmo jeito. A data de entrega do cenário de abertura tinha o mesmo tom, a mesma gramática e a mesma certeza de uma data copiada de um resultado de ferramenta. Quem revisa passando os olhos em busca de “isto soa estranho?” não vai encontrá-la, porque soar estranho não é a aparência da falha aqui.

Cumprimento parcial de instruções. Uma instrução no contexto reduz a taxa do comportamento que ela proíbe ou exige. Não leva a taxa a zero, e a taxa varia com o restante do contexto. “Não prometa datas de entrega” é

uma linha razoável na política do sistema, e muitas vezes vai funcionar. Regras desse tipo são pedidos, e a posição do livro é que nenhuma propriedade de confiabilidade se apoia apenas em um pedido. Onde a propriedade importa, um controle que roda depois que o modelo respondeu precisa sustentá-la.

Deriva com o modelo. O comportamento muda quando o modelo muda, e o modelo pode mudar sem que o seu código mude: um provedor atualiza o que está por trás de um nome, uma equipe do lado da plataforma troca o padrão do gateway, um modelo de fallback assume durante uma indisponibilidade. O mesmo ticket, o mesmo prompt e as mesmas ferramentas podem gerar, no dia seguinte, uma distribuição diferente de propostas. Afirmações específicas de uma versão não têm lugar num livro que sobrevive aos modelos, e também não são necessárias: a pergunta de design é o que o seu sistema faz quando a distribuição se move.

Por que isso é uma questão de engenharia

A resposta tentadora é tratar cada falha observada como um problema de prompt. Acrescentar uma frase, acrescentar um exemplo, acrescentar um aviso em maiúsculas. Esse esforço não é desperdiçado, porque pode reduzir a taxa de uma proposta específica. Mas a taxa é medida nos casos que você examinou, e o próximo ticket não é um deles. Uma correção que funciona nos três rascunhos que você reproduziu diz pouco sobre os próximos quatrocentos tickets.

Uma resposta de engenharia parte de outro lugar. Ela supõe que o componente às vezes estará errado, pergunta o que o sistema faz nesses dias e faz da resposta uma propriedade de código que não varia com a amostragem. Já fazemos isso em outros contextos. Um serviço que chama outro pela rede não conta com o outro sempre responder, e um serviço que lê um arquivo não conta com os bytes estarem bem formados. Ele valida, limita, faz retries com limites e registra. A entrada de um componente que você não controla é entrada não confiável, e a proposta de um modelo é isso.

O custo de ignorar esse fato aparece em várias classes de falha ao mesmo tempo, e é por isso que este capítulo atravessa todas elas: F1 (saída mal-formada), F2 (ferramenta incorreta ou argumentos incorretos) e F3 (afir-

mação sem fundamento) começam todas como propostas. O Capítulo 3 as define por completo. Aqui só precisamos da ideia de que são formas diferentes do mesmo fato subjacente.

Quatro tipos de incerteza

“O modelo pode estar errado” é grosseiro demais para servir de base a um design. Um design precisa saber como o modelo pode estar errado, porque o detector mais barato é diferente para cada forma. Uso quatro tipos.

Tipo	O que dá errado	Classe típica	Detector mais barato
Forma-to	A proposta não é interpretada ou não corresponde à estrutura	F1	Validação de esquema
Con-teúdo	A estrutura está certa; um fato ou o valor de um argumento está errado	F3, F2	Verificação cruzada com uma fonte de verdade
Inten-ção	A proposta pede a ação errada	F2	Pré-condições e política no gate
Omis-são	Falta um passo ou uma afirmação que deveria estar lá	nenhuma isoladamente	Verificações determinís-ticas de completude

Formato

A incerteza de formato é a mais amigável. Uma chamada de ferramenta cujos argumentos não são válidos para o contrato é uma proposta que falhou no parsing, e o parsing é determinístico. Suponha que o agente de suporte proponha `issue_refund` com `amount_minor` como a string “twelve fifty” ou com um `reason_code` que não está na enumeração. A verificação de esquema do gate a recusa antes de qualquer outra coisa acontecer.

As falhas de formato são baratas de detectar e, onde a estrutura é simples, raras o bastante para que as equipes invistam pouco em tratá-las. O erro de design mais comum é tratar uma falha de parsing como uma exceção que encerra o run ou, pior, reparar a proposta em silêncio, adivinhando o que se quis dizer. Reparar por adivinhação transforma um erro de formato em um erro de conteúdo, já que o valor reparado nunca foi proposto por ninguém. O Capítulo 5 trata de como as chamadas de ferramenta são transportadas e interpretadas; o ponto aqui é que o formato é o único tipo em que você pode ser rígido, e a rigidez quase não custa nada.

Conteúdo

A incerteza de conteúdo é o meio perigoso. A estrutura é válida e, ainda assim, a proposta está errada na substância. Uma chamada `issue_refund` que passa no parsing, cita um pedido real e usa um código de motivo permitido ainda pode carregar o `order_id` errado (tirado de outro ticket da conversa) ou a moeda errada. Uma resposta pode estar bem formada e prometer uma data que o contexto não contém.

A detecção aqui precisa de algo fora do modelo para comparar. Os resultados das ferramentas, o registro do pedido, a política e o próprio ticket são as fontes disponíveis. Se não há fonte para conferir, não há detector, e o design precisa decidir se aceita o risco, se restringe o que o modelo pode propor (Capítulo 4) ou se coloca uma pessoa no caminho (Capítulo 15). Prefiro admitir essa lacuna numa revisão de design a escondê-la atrás de uma frase como “o modelo foi instruído a ser preciso”.

Intenção

A incerteza de intenção significa que a proposta está bem formada e seus valores são plausíveis, mas a ação em si está errada para a situação. O cliente perguntou onde está a encomenda, e o modelo propôs `update_shipping_address`. Ou o cliente pediu uma mudança de endereço depois que a transportadora retirou a encomenda, e o modelo propôs um reembolso, uma resposta de aparência razoável para um problema diferente.

Os erros de intenção são pegos por pré-condições que dependem do estado: o envio já está com a transportadora, então o gate recusa a mudança de endereço. O gate é o lugar natural, porque ele guarda o estado e a política, e o Capítulo 6 mostra como um contrato de ferramenta declara pré-condições para que a verificação não seja improvisada. Uma pré-condição não consegue dizer que o modelo deveria ter feito uma pergunta. Para isso, você depende de como projetou as ferramentas disponíveis e de onde fica a fronteira entre o que o modelo propõe e o que o código decide, que é o assunto do Capítulo 4.

Omissão

A omissão é o tipo mais difícil de enxergar, porque a evidência é uma ausência. O modelo pulou um passo que deveria ter acontecido: redigiu uma confirmação de reembolso sem checar se o pedido foi entregue, ou deixou de fora a única frase de que o cliente precisa (“o reembolso leva alguns dias para aparecer”). Nada na proposta está errado. Falta algo que deveria estar lá.

As omissões só podem ser pegadas onde a completude pode ser escrita. Uma regra como “uma resposta que confirma um reembolso deve incluir uma referência ao identificador do reembolso e ao seu status, vindos do resultado da ferramenta” é verificável, assim como “todo `issue_refund` deve ser precedido, neste run, por um `lookup_order` bem-sucedido para o mesmo pedido”. O que passar disso é assunto para evals (Capítulo 21), que medem a taxa dessas omissões sobre um golden set em vez de pegar cada uma. Faço essa distinção de propósito. Um controle de runtime pega o que pode ser enunciado como condição. Um eval estima com que frequência acontece o resto.

Por que a confiança do modelo não é um sinal de controle

Depois que você aceita que as propostas podem estar erradas, o instinto seguinte é perguntar ao modelo quanto ele tem certeza. Uma confiança autodeclarada (“tenho 90 por cento de certeza”) parece exatamente o sinal de que um gate precisa: aceitar acima de um limiar, escalonar abaixo dele.

Não construiria sobre isso, por três razões.

A primeira é que a declaração é, ela própria, uma proposta. Ela é produzida pelo mesmo processo, a partir do mesmo contexto, com a mesma exposição às cinco propriedades acima. Um modelo que está fluentemente errado sobre uma data de entrega pode estar fluentemente confiante sobre ela. O número é um trecho de texto com aparência de medição, e um gate que o lê promoveu uma proposta a entrada confiável.

A segunda é que nada liga o número declarado a uma frequência. Para que uma confiança declarada seja útil, os casos em “90” teriam de estar certos cerca de nove vezes em dez, nos seus tickets, com as suas ferramentas, e você teria de manter isso verdadeiro ao longo das mudanças. Você pode medir isso num golden set (Capítulo 21), e pode ser que valha aproximadamente para um dado modelo e tarefa. É uma propriedade de um modelo numa distribuição, e pode se mover no dia em que o modelo se mover. Um limiar ajustado em cima dela vira um valor de configuração que, em silêncio, deixa de significar o que significava.

A terceira é que a confiança tende a ser menos informativa justamente onde você mais precisa dela. Os casos em que o contexto está faltando ou é enganoso são os casos em que a proposta provavelmente está errada e a descrição que o modelo faz de si mesmo está menos ancorada. Um sinal que é bom em tickets fáceis e ruim em tickets difíceis não ajuda a decidir quais tickets merecem uma segunda olhada.

Isso não torna o texto do próprio modelo sem valor. Uma incerteza declarada pode ser uma pista razoável para encaminhar um ticket a uma pessoa, porque o custo de um falso alarme ali é uma pessoa lendo um ticket. Ela nunca deve ser o motivo para permitir um efeito irreversível. A regra que usaria: um sinal declarado pelo modelo pode acrescentar atrito (mais verificações, uma olhada humana) e nunca pode removê-lo.

Sinais que você pode usar

Os sinais utilizáveis têm uma propriedade em comum: são calculados por algo que não é a descrição que o modelo faz de si mesmo. Em ordem aproximada de custo, são a validação de esquema, as verificações cruzadas com fontes, os verificadores determinísticos e a amostragem de consistência.

Validação de esquema

Confira cada proposta com a estrutura que ela precisa ter: o esquema de entrada do contrato de ferramenta, no caso de chamadas de ferramenta, e um formato definido para as respostas finais (uma resposta em rascunho com os campos que o orquestrador espera). A validação pega a incerteza

de formato (F1) e alguns erros de valor, como uma enumeração violada ou um valor que não é um inteiro positivo. É determinística, barata e completa naquilo que cobre.

O que ela não cobre é a maior parte do problema. Um esquema diz que um `order_id` é uma string. Não consegue dizer que a string pertence a este cliente. Trate a validação de esquema como o primeiro gate, e não como o único.

Verificação cruzada com fontes

Compare o que a proposta afirma com uma fonte que o orquestrador possui. Se o rascunho diz “o seu reembolso de 12,50 foi emitido”, o run store deve conter um resultado bem-sucedido de `issue_refund` com esse valor nessa moeda. Se o rascunho cita uma transportadora, o resultado de `lookup_order` deve contê-la. Isso é a fundamentação tornada operacional: cada afirmação deve se vincular a um item do contexto ou dos resultados de ferramenta registrados do run, e uma afirmação sem vínculo é um F3.

O ponto fraco é a extração. Para conferir afirmações, você primeiro precisa encontrá-las, e encontrá-las em texto livre é, por si só, uma tarefa que pode ser feita por código (padrões para datas, valores e identificadores) ou por uma segunda chamada ao modelo (que é outra proposta). Prefiro o caminho do código para as afirmações que mais importam, porque ele é determinístico e porque a lista de tipos de afirmação de alto risco é curta: valores, datas, identificadores, status. O que o extrator não conseguir interpretar cai na verificação seguinte.

Verificadores determinísticos

Um verificador é um código que responde a uma pergunta de sim ou não sobre uma proposta usando dados que o modelo não forneceu. Alguns são triviais: o valor do reembolso é no máximo o saldo reembolsável; o envio do pedido não foi entregue a uma transportadora; a moeda corresponde ao pagamento. Alguns são estruturais: uma resposta que menciona um reembolso deve referenciar um identificador presente nos resultados do run.

Os verificadores são o sinal mais forte porque são código. O limite deles é a cobertura: alguém precisa escrever cada um, e alguém precisa mantê-lo à medida que a política muda. A abordagem pragmática é começar com

verificadores para os efeitos que custam dinheiro ou chegam aos clientes, e deixar a cauda longa para os evals.

Amostragem de consistência

Você pode fazer ao modelo a mesma pergunta várias vezes e comparar as respostas. Se as propostas concordam, é uma evidência leve de que o contexto fixa a resposta; se discordam, a própria discordância é informação, porque diz que a proposta é sensível à amostragem e, portanto, não está bem sustentada pelo contexto. É o único sinal que vem do modelo sem confiar na descrição que o modelo faz de si mesmo.

Ela tem custos reais e limites reais. Cada amostra extra é outra chamada ao modelo, o que custa gasto e latência em todo ticket em que você a usa (o Capítulo 22 trata da atribuição de custos). A concordância não estabelece a verdade, já que as amostras compartilham o mesmo contexto e os mesmos pontos cegos; cinco rascunhos podem concordar na mesma data sem fundamento. E comparar rascunhos em texto livre exige um método de comparação, que é uma verificação determinística sobre afirmações extraídas ou outra chamada ao modelo.

Use-a com seletividade. Digamos que o agente de suporte trate 200 tickets por dia, e uma pequena fração seja de reembolsos perto do teto. Amostrar três vezes nesses casos, e escalonar quando os valores ou os identificadores de pedido divergirem, é um gasto defensável. Amostrar toda chamada de `lookup_order` não é.

Parâmetros de amostragem e design de controles

Os modelos expõem configurações que moldam a amostragem. A que você mais vai encontrar é a **temperatura**, que regula com que força a amostragem favorece a continuação mais provável: valores baixos concentram a saída em poucas propostas prováveis, valores altos a espalham.

Para o design de controles, os fatos relevantes são poucos. Uma temperatura menor tende a reduzir a variação entre runs, e isso pode tornar os evals mais estáveis e um comportamento mais fácil de reproduzir. Não torna a saída correta. Um modelo que erra de forma consistente uma data em temperatura baixa erra consistentemente. Também não promete determinismo, pelas razões já apresentadas: batching, hardware e o modelo por

trás do nome podem variar. Um design que precisa de saída idêntica para entrada idêntica não tem um problema de amostragem; tem um requisito que um modelo não consegue cumprir, e o requisito deve migrar para o código.

Por isso trato as configurações de amostragem como um botão de ajuste para evals e custo, definido no gateway e registrado em cada run, e nunca como um controle. Reduzir a variação ajuda uma equipe a medir; é o gate que limita o efeito. Daí decorre uma regra prática. Qualquer que seja a configuração escolhida, grave-a no registro de cada run, porque uma mudança posterior de comportamento é muito mais fácil de investigar quando a configuração é conhecida (o Capítulo 20 trata do registro).

Transformando a incerteza em um veredicto

O movimento de design deste capítulo é encerrar a avaliação de toda proposta em um dos três veredictos do gate, escolhido por código determinístico: `"allow"`, `"refuse"` ou `"needs_approval"` (Capítulo 1). A avaliação diz o que o sistema faz com a proposta. Não é um julgamento sobre o modelo.

Veredicto	Quando a avaliação termina nele	O que acontece em seguida
<code>"allow"</code>	Todas as verificações passaram e a política não exige uma pessoa	O efeito pode prosseguir
<code>"refuse"</code>	Uma verificação falhou: esquema, verificador, vínculo de argumentos ou verificação de afirmações	O motivo retorna ao modelo como observação
<code>"needs_approval"</code>	As verificações passaram, ou não conseguiram decidir, e a política ou o risco pedem uma pessoa	Uma pessoa decide (Capítulo 15)

Verificar é o trabalho que acontece antes de qualquer um desses: as verificações rodam e o resultado delas escolhe o veredicto. É um passo, não um quarto resultado.

As entradas da escolha são três: o que os validadores e verificadores disseram, a classe de efeito da ação proposta e o que a política diz sobre esta chamada. O esboço abaixo é a parte do gate do lado da Proposta para o

agente de suporte. É ilustrativo e uma visão parcial do gate do Capítulo 5, cuja ordem e cujos nomes de motivos ele segue; as verificações são nomeadas e não implementadas, e os limiares pertencem à política.

```
function assessProposal(run, proposal):
    parsed = validateSchema(proposal)           // format: F1
    if parsed.failed:
        return { kind: "refuse", reason: "invalid_arguments", detail:
parsed.errors }
    if proposal.kind == "final_answer":
        return assessText(run, proposal.text)    // forwarded text
    reaches a customer too
    call = proposal
    // recipient, ticket and order ids must come from the run, for every
    tool, reads included
    if not argumentsTieToRunResults(run, call):
        return { kind: "refuse", reason: "ungrounded_arguments" }
    findings = runVerifiers(run, call)           // state and policy
    checks
    if findings.hasViolation:
        return { kind: "refuse", reason: "precondition_failed", detail:
findings }
    if call.tool == "send_customer_reply":
        verdict = assessText(run, call.arguments.text)
        if verdict.kind != "allow":
            return verdict                       // a second,
independent check
    // approval last: a person never reviews what the checks would refuse
    if policy.requiresApproval(run, call):
        return { kind: "needs_approval", request: describe(call) }
    return { kind: "allow", call: call }
```

Três observações sobre este bloco. O modelo nunca vê um ramo dele e não pode discutir com nenhum. Todo resultado diferente de allow termina em algo determinístico que o registro captura. E a ordem é deliberada: as verificações baratas rodam primeiro, a aprovação vem depois de toda verificação que poderia recusar, e uma verificação que custa uma chamada ao modelo, se você usar alguma, roda apenas nas propostas que chegam até ela.

O caminho do texto merece um bloco próprio, porque um rascunho de resposta é a proposta mais comum que o agente de suporte faz, e no momento em que `send_customer_reply` roda ele é um efeito colateral externo. A verificação fica em todas as rotas até um cliente: o argumento `text` da chamada de ferramenta e uma resposta final, se o orquestrador a encaminha. Uma verificação de afirmações que protege apenas uma dessas rotas não protege nada.

```

function assessText(run, text):
    claims = extractClaims(text)                // dates, amounts,
    identifiers, statuses
    for each claim in claims:
        source = findSource(run.results, claim)
        if source == none:
            return { kind: "refuse", reason: "ungrounded_claim", claim:
claim }
        if source.value != claim.value:
            return { kind: "refuse", reason: "mismatch", claim: claim }
        if missingRequiredParts(run, text):      // completeness rules
from policy
            return { kind: "refuse", reason: "omission" }
        if containsUnclassifiedFigure(text):    // extractor could not
classify it
            return { kind: "needs_approval", request: describeDraft(run, text) }
        return { kind: "allow" }

```

Aplique isso ao cenário de abertura. O rascunho de resposta chega como uma chamada `send_customer_reply` cujo texto contém uma data de entrega. `extractClaims` devolve a data, `findSource` não encontra nenhum resultado de ferramenta que a contenha, e o gate recusa com o motivo `ungrounded_claim`. A resposta nunca chega ao cliente. O bloco também mostra um limite honesto: quando o extrator não consegue classificar um número, o veredicto é uma pessoa, porque uma verificação que não consegue decidir não pode falhar aberto.


O que acontece com uma recusa

Uma recusa retorna ao modelo como observação, do jeito que o `runStep` canônico a devolve. “O rascunho inclui uma data de entrega que nenhum resultado de ferramenta contém; remova-a ou busque a informação” é uma frase sobre a qual o modelo pode agir. Duas limitações se aplicam. O código gera o texto a partir de uma lista fixa de motivos e nunca repete o conteúdo do ticket como se fosse uma instrução. E o loop tem limite: um modelo que continua propondo a mesma coisa recusada é um run que deveria parar, o que o Capítulo 12 e o Capítulo 13 descrevem.

Uma recusa é um retorno, não uma correção. Se um ticket é recusado três vezes pela mesma regra, o sistema está dizendo algo sobre o contexto ou sobre as ferramentas, e a saída certa é um hand-off com um motivo registrado.

O fluxo de veredictos como diagrama

O diagrama mostra uma proposta. Siga os caminhos que saem antes do efeito: é ali que a incerteza é absorvida.



Nenhum caminho deixa a confiança do próprio modelo alterar um ramo. Cada um é decidido por algo que não depende da descrição que o modelo faz de si mesmo.

Um exemplo trabalhado: três tickets

Tome três tickets numa mesma manhã, com o mesmo agente de suporte e o mesmo gate.

O primeiro é um ticket de “onde está minha encomenda”. A resposta é proposta por meio de `send_customer_reply`; ela informa a transportadora e o status, ambos presentes no resultado de `lookup_order`. As afirmações se vinculam, a política não exige aprovação para uma resposta desse tipo e o veredicto é `allow`. Custo: algumas verificações determinísticas.

O segundo é um reembolso por um pedido danificado, abaixo de `refund_ceiling`. A chamada `issue_refund` tem argumentos válidos, os verificadores confirmam que o pagamento foi capturado e que o valor cabe no saldo reembolsável, e o pedido se vincula ao cliente deste run. A classe de efeito é escrita irreversível, mas o valor está abaixo do teto, então o veredicto é `allow`. A idempotência e o teto vivem no contrato de ferramenta (Capítulo 6); o ponto aqui é que o veredicto foi `allow` porque as verificações passaram, e não porque o modelo soou seguro.

O terceiro é um reembolso acima do teto para um pedido claramente identificado. Todas as verificações passam e a política exige aprovação, então o veredicto é `needs approval`: Sam recebe a ação pendente com a evidência e decide (Capítulo 15). Se a conversa de e-mails tivesse mencionado dois pedidos, e a proposta citasse um sem respaldo para a escolha, a verificação de argumentos a teria recusado antes, e Sam não veria um reembolso para o que poderia ser o pedido errado.

Nenhum dos três precisou saber a confiança do modelo. Todos precisaram de evidência no run.

Mudar o modelo é um deploy

Tudo o que foi dito acima trata o modelo como um componente fixo, com uma distribuição de comportamento. Ele não é fixo. Substituí-lo, atualizá-lo ou trocar um fallback altera essa distribuição, e os controles que você ajustou (cobertura de verificadores, limiares de escalonamento, os motivos de recusa que mais aparecem) foram ajustados contra a antiga.

Minha posição é que uma mudança de modelo é um deploy e deve passar pelo mesmo caminho de um. Isso significa uma mudança registrada, com um responsável, evidência da suíte de evals antes de ir ao ar (o Capítulo 21 constrói o golden set e os graders), um jeito de reverter e um rollout em etapas, em que uma fração do tráfego roda no modelo novo enquanto

o restante continua no antigo. O registro leva o identificador do modelo em cada run, para que uma mudança de comportamento possa ser ligada a uma mudança de modelo (Capítulo 20).

Dois casos merecem ser nomeados porque tendem a chegar sem um ticket. O primeiro é a mudança do lado do provedor, em que o identificador do modelo continua o mesmo enquanto aquilo que está por trás dele se move; a defesa é a mesma de qualquer dependência que você não controla, que é rodar a suíte de evals periodicamente contra a configuração de produção, e não apenas antes dos seus próprios deploys. O segundo é o modelo de fallback, de que trata o Capítulo 14: ele é ativado durante um incidente, quando a atenção está no ponto mais baixo, e é o modelo que você menos testou.

Trade-offs e custos

Todo controle deste capítulo tem um preço, e alguns não valem a pena em todo lugar.

Latência. A validação de esquema acrescenta microssegundos; verificadores que leem um serviço acrescentam uma chamada de rede. A amostragem de consistência multiplica as chamadas ao modelo, e uma segunda chamada ao modelo usada para extrair ou comparar afirmações acrescenta uma ida e volta completa ao caminho da resposta. Um cliente esperando uma resposta de chat vai notar. Ponha as verificações caras nas propostas cujo efeito é difícil de desfazer e mantenha o caminho da resposta com verificações determinísticas sempre que puder.

Gasto. Amostragem várias vezes custa várias vezes mais para esses tickets. Se você a aplica a todo ticket, comprou uma maneira cara de se sentir cuidadoso. Aplique-a onde a discordância mudaria o que você faz.

Falsas recusas. Um extrator de afirmações zeloso demais recusa rascunhos corretos, e o agente de suporte entra em loop reformulando. Cada recusa custa uma chamada ao modelo e um passo contra o limite. Um verificador rígido demais vira um gerador de hand-offs. A métrica a acompanhar é a taxa de recusa por motivo; uma taxa alta num motivo é um sinal para ajustar a verificação ou o contexto, e não para afrouxar o gate.

Custo humano. Todo veredicto needs approval cai na fila de Sam. Se o extrator encaminha rascunhos demais a uma pessoa, a fila cresce, as aprovações viram reflexo e o controle vira teatro (o Capítulo 15 volta a isso). O design precisa contar os minutos humanos que cria, já que eles fazem parte do custo do controle.

Manutenção. Verificadores e regras de completude são código que acompanha a política. Quando a política de reembolso muda, um verificador que codifica a política antiga recusa propostas corretas ou, pior, aceita as ruínas. Alguém é responsável por cada verificador, e os testes dele ficam ao lado da política.

Quando não usar isto. Para um fluxo em que o modelo apenas preenche um campo de um formulário controlado pelo código e o campo é conferido por um esquema, todo o aparato acima é mais do que você precisa. Uma única validação e um limite bastam. E quando a saída é um rascunho que uma pessoa sempre lê antes de ele ir a qualquer lugar, gaste seu esforço em tornar a revisão rápida, e não em automatizar verificações de afirmações que quem revisa vai repetir. Também não construiria um extrator de afirmações antes de olhar o que os seus rascunhos contêm; dois ou três tipos de afirmação costumam ser a maior parte do risco.

Nota: Os veredictos deste capítulo dizem o que fazer com uma proposta. Não dizem quais decisões o modelo deveria poder tomar, para começar. Essa é uma pergunta separada e anterior, e o Capítulo 4 trata dela.

Erros comuns

Reparar propostas em silêncio. O orquestrador “corrige” um valor mal-formado por adivinhação. É tentador porque o run continua. A correção é recusar com um motivo preciso e deixar o modelo propor de novo, de modo que todo valor que produz efeito tenha sido proposto e verificado, e não inferido.

Proteger uma só rota até o cliente. A verificação de afirmações roda nas respostas finais enquanto as respostas saem por `send_customer_reply`, ou o contrário. É tentador porque a resposta final parece ser a saída. A

correção é listar toda rota que leva texto ou argumentos a uma pessoa ou a um sistema, e pôr a mesma verificação em cada uma.

Falhar aberto quando uma verificação não consegue decidir. Um extrator que não consegue classificar um número deixa o rascunho passar. É tentador porque a alternativa acrescenta trabalho humano. A correção é enviar os casos indecidíveis a uma pessoa e contá-los, para que uma fila crescente mostre que o extrator precisa de trabalho.

Diluir a cauda na média. Uma equipe olha a qualidade média dos rascunhos e deixa passar os raros e caros. É tentador porque médias são fáceis de reportar. A correção é medir as classes de falha separadamente e ponderá-las pela severidade do efeito, o que o Capítulo 3 introduz.

Pontos-chave

- A proposta do modelo é entrada não confiável, porque é produzida de forma probabilística, muda com o contexto, pode estar errada sem soar errada, segue instruções apenas em parte e muda quando o modelo muda.
- A incerteza vem em quatro tipos (formato, conteúdo, intenção e omissão), e cada um tem um detector mais barato diferente, de modo que um design que nomeia o tipo escolhe a verificação certa.
- A confiança declarada de um modelo é, ela própria, uma proposta e não pode ser um sinal de controle; ela pode encaminhar um caso para mais verificação e nunca deve ser o motivo para permitir um efeito irreversível.
- Os sinais em que vale construir são calculados fora do modelo: validação de esquema, verificações cruzadas com fontes, verificadores determinísticos e, com seletividade, amostragem de consistência, com o custo contado.
- A temperatura e outras configurações de amostragem ajustam evals e reprodutibilidade; não tornam uma proposta correta e não prometem determinismo, então qualquer requisito de saída idêntica migra para o código.
- Toda proposta termina em um veredicto escolhido por código determinístico (allow, refuse ou needs approval), alcançado rodando as verificações de esquema, de verificadores, de argumentos e de afirmações

nessa ordem, e toda recusa é registrada e contada contra o limite; a mesma verificação de afirmações fica em toda rota que leva texto a um cliente.

- Uma mudança de modelo é um deploy: exige um responsável, evidência de evals antes de ir ao ar, um rollout em etapas, um caminho de rollback e um identificador do modelo em cada run.

Saber que as propostas podem estar erradas de quatro maneiras ainda não é um vocabulário para o que dá errado em um run inteiro. O Capítulo 3 oferece esse vocabulário: as nove classes de falha, como distingui-las e como descobrir qual parte do sistema, e não qual componente, foi a causa-raiz.

Capítulo 3 — Uma taxonomia de falhas para agentes

Imagine a revisão de segunda-feira na Parcelport. Alex, da equipe de plataforma e habilitação de IA, tem uma lista de cinco coisas que deram errado com os agentes na última semana. Um reembolso foi para o pedido errado. Uma resposta prometeu uma data de entrega que ninguém conseguiu encontrar em sistema algum. Robin, que estava de on-call, não conseguiu reconstituir por que o `ops-agent` havia executado a mesma consulta de logs 11 vezes. Uma chamada de ferramenta falhou no parsing. Um run foi marcado como concluído, embora o cliente nunca tenha recebido a resposta.

A lista está escrita na linguagem da semana: “o agente se confundiu”, “inventou de novo”, “o modelo saiu dos trilhos”, “a ferramenta estava instável”. Jordan, da equipe de segurança, lê a lista e faz uma pergunta justa: quais destes cinco são o mesmo problema que outro, e qual controle teria pego cada um? Ninguém sabe responder, porque a lista descreve sintomas em palavras que não carregam informação de design. Cinco incidentes geram cinco histórias e zero padrões.

Este capítulo dá à equipe um vocabulário compartilhado. Ele pertence às seis partes do envelope de controle (Contexto, Proposta, Gate, Efeito, Limite e Registro), porque uma falha pode começar em qualquer uma delas. A pergunta que ele responde é esta: quando um agente falha, como dar nome à falha de modo que o nome aponte para um sinal de detecção, um controle preventivo, um controle limitador e um responsável?

O problema e por que ele é difícil

As falhas em agentes são difíceis de discutir por três razões, e nenhuma delas diz respeito ao modelo.

A primeira é que os sintomas se parecem e as causas diferem. Um reembolso errado pode vir de uma proposta que citou o pedido errado, de um contexto que continha o pedido errado por causa de uma leitura obsoleta, de um contrato de ferramenta que aceitou um pedido pertencente a outra pessoa ou de um gate que nunca verificou a propriedade. O cliente vê o mesmo resultado nos quatro casos. A correção é diferente em cada um, e uma equipe que corrige a camada errada verá o mesmo incidente de novo, com outro número de ticket.

A segunda é que o vocabulário é emprestado das pessoas. “O agente se confundiu”, “mentiu”, “ignorou as instruções” descrevem alguém com intenções, o que empurra a revisão para a pergunta “por que ele fez isso?”. Essa pergunta não tem resposta estável para um componente probabilístico, e o Capítulo 2 explica por quê. A pergunta útil é “qual controle deveria ter segurado, e por que não segurou?”. Essa pergunta tem resposta em código, em configuração ou em uma peça de design que faltava.

A terceira é que as falhas se compõem. Uma proposta malformada repetida às cegas vira uma explosão de custo. Um endereço obsoleto que chega a uma ferramenta com um token amplo vira um efeito não autorizado. Um efeito que deu certo mas nunca foi registrado vira um comportamento não observado. Uma revisão que para no primeiro sintoma visível perde a segunda e a terceira falhas, que costumam ser as que o design pode corrigir.

Uma taxonomia é a resposta de engenharia. É um conjunto pequeno e fechado de classes nomeadas, cada uma definida de modo que dois revisores olhando o mesmo incidente costumem concordar quanto ao nome. Não é uma teoria de tudo. É uma ferramenta para fazer as revisões de incidentes, os evals e os dashboards usarem as mesmas palavras, e para apontar cada falha para a parte do envelope que é responsável pelo remédio. Esta é uma questão de engenharia, e não de prompt, porque toda classe abaixo tem ao menos um controle que funciona por código determinístico, e nenhuma delas é encerrada acrescentando uma frase a um prompt. Um prompt pode reduzir a taxa de algumas classes. Não pode ser o controle de nenhuma delas.

Três perguntas que classificam uma falha

Antes das classes, o método. A classificação faz três perguntas em ordem fixa, e a ordem importa porque cada uma estreita a seguinte.

1. **O que deu errado no run?** Esta é a classe de falha, de F1 a F9. Ela nomeia o comportamento observável.
2. **Onde estava a causa-raiz?** Este é o eixo de modelo, contexto, ferramenta ou controle. Ele nomeia o componente cuja mudança teria evitado a falha ao menor custo.
3. **Até onde ela chegou?** Este é o eixo de severidade: informação, reversível, irreversível ou alcançando o mundo exterior. Ele define quanto controle a situação merecia.

A classe é uma descrição de comportamento, o eixo é um diagnóstico e a severidade é uma prioridade. Misturá-los é o motivo mais comum para as revisões andarem em círculos.

O eixo da causa-raiz

Quatro valores cobrem as causas que importam para o design.

- **Modelo.** A própria proposta era o problema, e nenhum outro componente contribuiu de uma forma que um design razoável teria pego. Isso é mais raro do que as equipes esperam.
- **Contexto.** O modelo recebeu material errado, obsoleto, ausente, sem rótulo ou vindo de uma fonte em que não se deveria confiar. A proposta pode ter sido uma resposta sensata ao contexto recebido.
- **Ferramenta.** O contrato, a implementação ou o comportamento da ferramenta permitiu ou causou a falha: uma entrada aceita que deveria ter sido recusada, um formato de erro que escondeu o resultado, uma operação que não era idempotente.
- **Controle.** Uma verificação que o design deveria ter tido estava ausente, fraca ou no lugar errado: nenhum gate na chamada, um limite que ninguém ajustou, um registro que nunca foi escrito.

Quero ser direto sobre uma frase que aparece na maioria das primeiras versões de revisões de incidentes: “o modelo cometeu um erro”. Ela é verdadeira do mesmo jeito que “a rede perdeu um pacote” é verdadeira. Descreve o gatilho, e o design precisa supor que o gatilho vai ocorrer. Um mo-

delo produz propostas erradas a uma taxa que ninguém consegue levar a zero, então uma revisão que termina aí não encontrou nada que possa mudar. A pergunta da causa-raiz indaga por que uma proposta errada pôde importar: por que chegou a uma ferramenta, por que nada notou, por que custou tanto, por que ninguém conseguiu ver.

Há um caso estreito em que o eixo do modelo é a resposta honesta. Se o mesmo contexto, as mesmas ferramentas e os mesmos controles produziram comportamento aceitável com um modelo e uma taxa claramente pior da mesma falha depois de uma troca de modelo, a mudança de modelo é uma causa. A evidência disso vem de um eval, e não do incidente (o Capítulo 21 trata de como). Mesmo assim, a remediação tem duas partes: reverter ou segurar a mudança de modelo, e acrescentar o controle que teria tornado a regressão visível ou inofensiva. Uma revisão cujo único item de ação é “usar um modelo melhor” ainda não encontrou um controle.

O eixo nem sempre é singular. Quando dois componentes contribuíram, registre os dois e ordene-os por qual mudança é mais barata e se sustenta em mais condições. Uma verificação no gate que custa poucas linhas de código e vale para toda proposta futura costuma superar um redesenho de contexto, que por sua vez costuma superar uma troca de modelo.

As nove classes de falha

Os ids e nomes abaixo são fixos para o livro inteiro. Cada classe recebe uma definição, uma ilustração da Parcelport, o sinal que a detecta, o controle que a previne, o controle que limita o dano quando a prevenção falha e os capítulos responsáveis por esses controles. Prevenção e limitação são trabalhos diferentes. A prevenção reduz a taxa ou fecha o caminho. A limitação supõe que a falha aconteceu e reduz o que ela pode alcançar ou quanto tempo dura.

F1: Saída malformada

Definição. A proposta não passa no parsing, ou passa mas não corresponde à estrutura que o orquestrador espera. É a classe mais fácil de detectar e a menos perigosa, porque nada aconteceu ainda quando ela é pega.

Exemplo da Parcelport. O agente de suporte propõe uma chamada a `issue_refund` em que `amount_minor` chega como uma frase em vez de um inteiro, ou em que `reason_code` é um valor fora da enumeração. O agente de operações propõe uma chamada a `query_logs` cujo intervalo de tempo termina antes de começar.

Sinal de detecção. Falha de validação de esquema no gate, contada por ferramenta e por causa. Uma taxa crescente de F1 em uma ferramenta muitas vezes aponta para um contrato ambíguo, o que a torna um sinal sobre a ferramenta tanto quanto sobre o modelo.

Prevenção. Um esquema de entrada rígido, com enumerações fechadas e `additionalProperties: false`, de modo que a forma de uma chamada válida seja estreita (Capítulo 6). Propostas estruturadas em vez de texto livre (Capítulo 4).

Limitação. Um número limitado de tentativas de reparo, com o erro de validação devolvido ao modelo como observação; ao chegar ao limite, hand-off. O reparo sem limite é como F1 se transforma em F9 (capítulos 5 e 14).

F2: Ferramenta incorreta ou argumentos incorretos

Definição. A proposta está bem formada e passa no esquema, mas seleciona a ferramenta errada para a situação, ou a ferramenta certa com valores que não se encaixam. A estrutura está correta e o conteúdo está errado.

Exemplo da Parcelport. `issue_refund` proposto para um pedido que aparece no texto do ticket mas não é o pedido sobre o qual o cliente está perguntando, ou um reembolso em uma moeda diferente da do pagamento capturado. No caso do agente de operações, `toggle_feature_flag` proposto para uma flag cujo nome é parecido com o daquela para a qual a investigação aponta.

Sinal de detecção. Falhas de pré-condição no gate (“o pedido não pertence ao cliente deste run”), divergência entre os argumentos propostos e valores que o orquestrador já possui, e revisão por amostragem das chamadas aprovadas. Um F2 que passa por todas as verificações é invisível por construção, e é por isso que o golden set do Capítulo 21 inclui casos construídos para tentá-lo.

Prevenção. Restringir aquilo entre o que o modelo pode escolher: identificadores tirados do próprio contexto do run em vez de digitados livremente, enumerações e pré-condições que comparam argumentos com fatos que o gate pode consultar (capítulos 4 e 6).

Limitação. Uma classe de efeito e uma política de aprovação que tornem a chamada errada barata de desfazer ou visível antes de se concretizar. Para uma escrita irreversível, uma aprovação humana que mostre os argumentos exatos (Capítulo 15).

F3: Afirmação sem fundamento

Definição. O modelo afirma algo que o contexto dele não sustenta. Este é o termo do livro para o que se costuma chamar de “alucinação”, e este é o único lugar do livro em que essa palavra aparece. O motivo de um termo diferente é prático: “sem fundamento” nomeia o teste que um revisor pode aplicar, que é saber se uma fonte no contexto se vincula à afirmação.

Exemplo da Parcelport. Uma resposta redigida diz a um cliente que a encomenda chegará em determinado dia, e nenhum resultado de `lookup_order` contém qualquer estimativa de entrega. O resumo do agente de operações afirma que um deploy causou um pico de erros, e nenhum trace ou métrica do run mostra que os dois eventos estavam relacionados.

Sinal de detecção. Uma verificação de afirmações (Capítulo 2), a forma operacional da fundamentação, que compara as afirmações do rascunho com os resultados de ferramenta do run: datas, valores, identificadores de pedido e palavras de status devem aparecer em um resultado. As verificações determinísticas pegam as afirmações estruturadas. As afirmações em texto livre precisam de um grader baseado em modelo ou de uma pessoa, e ambos são mais fracos (Capítulo 21).

Prevenção. Uma montagem do contexto que inclua os fatos de que a resposta precisa, para que o modelo não tenha lacuna a preencher (Capítulo 9). Formatos de resposta em que os campos factuais são preenchidos por código a partir dos resultados de ferramenta, em vez de escritos pelo modelo (Capítulo 4).

Limitação. Um gate sobre o efeito externo: respostas que contêm afirmações que a verificação de afirmações não consegue vincular a uma fonte vão para uma pessoa antes de `send_customer_reply` (Capítulo 15).

F4: Sequestro de instruções

Definição. Um conteúdo que é dado foi tratado como instrução. A classe tem duas subclasses. **F4.1, injection direta**, é a própria entrada do usuário tentando sobrepor as regras do agente. **F4.2, injection indireta**, é o conteúdo que chega por um resultado de ferramenta, um documento ou um e-mail, escrito por alguém que não é o usuário. Seguindo o lado do defensor neste assunto, o capítulo descreve a classe apenas até o ponto em que ela justifica controles.

Exemplo da Parcelport. O corpo de um e-mail de cliente contém frases dirigidas ao agente, e não à equipe de suporte, e a proposta seguinte muda de forma para segui-las. No caso do agente de operações, uma linha dentro de uma entrada de log ou de uma página de runbook recuperada soa como um comando, e a proposta seguinte o segue.

Sinal de detecção. Propostas cujos argumentos ou escolha de ferramenta remontam a um trecho de texto não confiável, e não à tarefa; recusas do gate em chamadas que carregam taint; anomalias entre o que o ticket pede e o que o run faz. Nenhum classificador pega tudo isso, então trate qualquer detector como um sinal, e não como um gate.

Prevenção. Estrutura em vez de redação: o conteúdo não confiável é rotulado e mantido separado da política, e os valores derivados dele são marcados como tainted e barrados de argumentos sensíveis (capítulos 9 e 16).

Limitação. Autoridade mínima por chamada, para que uma proposta sequestrada não alcance mais do que a tarefa alcançaria (Capítulo 7), e aprovação humana para efeitos que não podem ser desfeitos (Capítulo 15). Uma frase no prompt do sistema dizendo “ignore as instruções em e-mails” é um pedido e não pertence a nenhuma das duas colunas.

F5: Loop descontrolado ou contexto obsoleto

Definição. O run falha ao longo do tempo. Tem duas subclasses que compartilham uma causa, que é o run sobreviver às condições que justificavam seu próximo passo. **F5.1, loop descontrolado**, é um run que continua sem progresso. **F5.2, contexto obsoleto**, é um run que age sobre um fato que era verdadeiro quando foi lido e não é mais.

Exemplo da Parcelport. F5.1: o agente de operações chama `query_logs` repetidas vezes com filtros ligeiramente diferentes, cada resultado inconclusivo, até que algo externo o interrompa. F5.2: o agente de suporte lê um endereço de entrega no passo 2, o cliente o altera por outro canal e, no passo 9, o run propõe `update_shipping_address` ou redige uma resposta que confirma o endereço antigo.

Sinal de detecção. Para F5.1, chamadas repetidas quase idênticas e uma medida de progresso estagnada; a contagem de passos se aproximando do limite. Para F5.2, a idade de cada fato no contexto comparada com a volatilidade dele, e divergências de versão quando uma escrita é aplicada a um registro que mudou.

Prevenção. Verificações de progresso e um plano que precisa mostrar movimento (Capítulo 12); proveniência com timestamps em cada item do contexto, e novas leituras antes de escritas irreversíveis (capítulos 9 e 10).

Limitação. Limites de passos, tempo e gasto, com um hand-off quando disparam (Capítulo 13). Pré-condições que comparam uma versão ou um status no momento do efeito, de modo que uma decisão obsoleta falhe no gate e não se concretize.

F6: Falha parcial silenciosa

Definição. Parte de um efeito de vários passos aconteceu e nada diz isso. O run parece completo e o mundo está inconsistente. É a classe que a ausência de uma transação distribuída produz, e o livro não finge que existe uma transação entre o run store, o serviço de pagamentos e o sistema de tickets.

Exemplo da Parcelport. `issue_refund` tem sucesso em `payments-service` e a chamada a `send_customer_reply` falha após um timeout, e o run termina com o status “done”. O cliente tem o dinheiro e nenhuma explicação ou, pior, o agente propõe o reembolso de novo no dia seguinte. No caso do agente de operações, `request_rollback` é aceito por `deploy-service`, a confirmação nunca chega e o run é encerrado como se nada tivesse começado.

Sinal de detecção. Reconciliação entre as intenções que o run registrou e os efeitos que os sistemas a jusante informam: uma intenção sem resultado, um resultado sem resposta, um run marcado como completo com in-

tenções abertas. Essas verificações rodam fora do run, em intervalos programados.

Prevenção. Registrar a intenção antes do efeito e o resultado depois dele, usar chaves de idempotência derivadas pelo runtime para que uma repetição não aja duas vezes, e tratar um timeout como um resultado desconhecido a ser resolvido por uma consulta de status, e não como uma falha a ser repetida (capítulos 6 e 14).

Limitação. Um run não pode ser marcado como concluído enquanto uma intenção não estiver resolvida; a resolução vai para uma fila humana com a intenção registrada anexada (Capítulo 10).

F7: Efeito não autorizado

Definição. Aconteceu um efeito que este principal, neste momento, não deveria ter conseguido causar. A palavra “não autorizado” diz respeito às regras do sistema, e não aos desejos do modelo. O caminho usual é um componente com autoridade ampla agindo a pedido de outro mais restrito, que é o confused deputy.

Exemplo da Parcelport. Um reembolso acima de `refund_ceiling` que prosseguiu sem aprovação, ou uma ação tomada com um token que funcionava em todos os clientes quando a tarefa dizia respeito a um só. No caso do agente de operações, uma feature flag alterada em um ambiente que a aprovação do engenheiro de on-call não cobria.

Sinal de detecção. Comparação de auditoria de cada efeito com a autoridade emitida para aquela chamada: escopo, recurso, valor, identidade de quem aprovou. Todo efeito sem autoridade emitida correspondente é um achado. As tentativas que o gate recusou também são um sinal; uma taxa de recusa crescente significa que as propostas estão derivando para um território que não deveriam alcançar.

Prevenção. Autoridade emitida por chamada e mais estreita que a do delegante, tetos e verificações de propriedade aplicados em código no gate, e credenciais mantidas fora do agente (capítulos 7 e 18).

Limitação. Credenciais de curta duração, um sandbox para tudo que executa código e aprovação vinculada à ação exata (capítulos 7, 15, 18 e 19).

F8: Comportamento não observado

Definição. O sistema fez algo e não deixou evidência utilizável, de modo que ninguém consegue dizer o que aconteceu nem por quê. É uma falha da parte Registro, e torna toda outra classe mais cara, porque uma falha que você não consegue ver não pode ser classificada, contada nem corrigida.

Exemplo da Parcelport. Uma chamada de ferramenta que não produziu span, de modo que Robin, de on-call, não consegue dizer se o agente leu os logs antes de propor a correção. Uma resposta que saiu sem registro de qual contexto a produziu.

Sinal de detecção. Verificações de cobertura do pipeline de traces: toda chamada ao modelo, decisão do gate e efeito deveria ter um span, e um run cujos spans não dão conta dos efeitos registrados é, em si, o achado. A evidência ausente precisa ser procurada de propósito, porque nunca gera um alerta por conta própria.

Prevenção. Um único formato de trace para os dois agentes, escrito pelo orquestrador e não por cada ferramenta, com a intenção registrada antes do efeito e o redaction aplicado antes do armazenamento (capítulos 17 e 20).

Limitação. Se o registro não puder ser escrito, trate isso como um limite: o run para ou passa a um modo sem efeitos. Para efeitos que não podem ser desfeitos, “sem evidência” é motivo para recusar, não para continuar (capítulos 13 e 20).

F9: Explosão de custo ou latência

Definição. O run está correto e custa caro demais, ou demora demais. A proposta, o gate e o efeito fizeram o que deviam, e o orçamento, a paciência de um cliente ou um serviço a jusante pagou por isso.

Exemplo da Parcelport. Uma lentidão do provedor faz as chamadas ao modelo darem timeout, e todos os runs fazem retries ao mesmo tempo, de modo que uma dependência lenta vira uma enxurrada de chamadas pelo gateway de modelos. No caso do agente de suporte, um run que enche o contexto com todos os tickets anteriores de um cliente a cada passo, de modo que o custo por ticket sobe sem mudança na qualidade.

Sinal de detecção. Custo e latência por run e por projeto, com uma distribuição e não apenas uma média; contagens de retries; profundidade da fila no gateway. Um run lento e um run caro são sinais diferentes e precisam de limiares diferentes.

Prevenção. Orçamentos por run e por projeto, um orçamento de contexto que corta por prioridade e políticas de retry que classificam o motivo da falha antes de repetir (capítulos 13, 14 e 22).

Limitação. Circuit breakers que interrompem as chamadas a uma dependência com falha, e um modo degradado declarado em que o sistema entra quando um limite dispara, como apenas hand-off (capítulos 13 e 14).

Distinguindo as classes

As disputas de classificação em uma revisão costumam girar em torno das mesmas poucas fronteiras. Resolvê-las de antemão poupa tempo, e as regras abaixo são as que escreveria no modelo de revisão.


F2 e F7: ferramenta incorreta versus efeito não autorizado. F2 descreve a proposta: bem formada, mas errada para a situação. F7 descreve o que o sistema permitiu que acontecesse. O mesmo incidente pode ser os dois, e o par é informativo. Se o agente de suporte propõe um reembolso para um pedido de outro cliente e o gate o permite, a proposta foi F2 e o efeito foi F7, e o controle que falhou é a verificação de propriedade no gate. Se o gate recusa a chamada, ocorreu apenas F2 e o sistema funcionou. Registre toda classe da cadeia, ordenada da proposta ao efeito, e ponha o remédio no controle mais antecipado que teria assegurado para toda proposta futura desse tipo.

F3 e F5.2: afirmação sem fundamento versus contexto obsoleto. Pergunte se o contexto continha respaldo para a afirmação no momento em que o modelo a produziu. Se nunca continha, a afirmação é F3. Se continha, e o fato mudou desde então ou foi lido há tempo demais, a falha é F5.2. Os remédios diferem: F3 se encerra colocando os fatos necessários no contexto ou preenchendo-os por código; F5.2 se encerra com verificações de atualidade e com novas leituras antes de um efeito.

F6 e F8: falha parcial versus comportamento não observado. F6 diz respeito a um estado do mundo: parte de um efeito se concretizou e o run diz o contrário. F8 diz respeito à evidência: o efeito se concretizou e não há nada que o mostre. Um F6 que você poderia detectar lendo o registro não é um F8. Um efeito sem registro algum é os dois, e o registro é a primeira coisa a consertar, porque sem ele você não pode saber a extensão do F6.

F1 e F2: malformado versus incorreto. Se um validador de esquema o rejeita, é F1. Se passa no esquema e falha em uma pré-condição ou no julgamento de uma pessoa, é F2. Apertar um esquema move parte dos F2 para F1, e essa é uma boa troca, já que F1 é barato de pegar.

O diagrama a seguir coloca as perguntas em ordem. Observe como cada pergunta encaminha o incidente a uma classe e as linhas pontilhadas, que marcam pares que muitas vezes ocorrem juntos em um mesmo incidente.



A ordem das perguntas é uma convenção e não uma lei. A evidência vem primeiro porque toda resposta posterior depende dela. A primeira correspondência é a classe primária. O diagrama desenha o percurso terminando nesse nó, mas na prática você continua com as perguntas restantes e registra cada correspondência adicional, ordenada da proposta em direção ao efeito. As linhas pontilhadas mostram pares comuns: uma chamada errada

que o gate permite, um sequestro que chega a uma escrita e um loop que gasta muito. Um incidente que cai em “unclassified” é um achado sobre a taxonomia, não sobre o run.

Uma causa-raiz é uma afirmação de design

Com a classe e o eixo em mãos, a revisão produz um registro que pode ser contado. A notação abaixo é ilustrativa; o ponto é que todo campo vem de uma lista fechada.

```
incident_record
  id:          string
  run_ids:     list of string
  classes:     list of { id: F1..F9, subclass: optional, order: integer }
               // ordered from proposal toward effect
  root_cause:  list of { axis: model | context | tool | control,
                       rank: integer, evidence: link to trace }
  severity:    information | reversible | irreversible | external
  detected_by: signal name, or "reported by a person"
               // the second value is itself a finding
  missing_control: name of the control that should have held
  owner_team:  string          // the team that owns the missing control
  action_items: list of { change, owner, check }
               // each item names a control, never "be more careful"
```

Dois campos fazem a maior parte do trabalho. `detected_by` registra como a falha foi encontrada e, quando a resposta honesta é “um cliente escreveu”, o sinal de detecção ausente é um resultado da revisão tanto quanto a própria falha. `missing_control` obriga a revisão a terminar em algo que uma equipe possa construir. Um item de ação como “dizer ao modelo para não fazer isso” não é aceito nesta notação, porque não nomeia nenhum controle, e o item precisa ser reescrito até nomear.

Tome um exemplo completo. O design permitiu que uma proposta chegasse a `issue_refund` para um pedido que foi mencionado no e-mail de um cliente mas pertencia a outro cliente. O registro diz: classes F2 e depois F7, causa-raiz controle em primeiro lugar (o gate não tinha pré-condição de propriedade) e contexto em segundo (o identificador de pedido do e-mail entrou diretamente na proposta), severidade irreversível, detectado por um job de reconciliação e não por qualquer sinal no run, controle ausente “pré-condição de propriedade em `issue_refund`”. Os itens de ação são uma verificação de propriedade no contrato (Capítulo 6), uma regra de que os identificadores de pedido nos argumentos devem vir de resulta-

dos de ferramenta e não do texto de mensagens (Capítulo 9) e um alerta de reconciliação que dispare mais cedo (Capítulo 20). Nada na lista pede que o modelo se comporte melhor, e cada item vale nos dias em que o modelo propuser o pedido errado de novo.

A severidade decide quanto controle uma situação merece

A classe de falha diz o que aconteceu. A severidade diz o quanto isso importou e determina quanto controle a chamada deveria ter tido antes de acontecer. O livro usa quatro níveis. Os nomes dos níveis vêm das classes de efeito das ferramentas da Parcelport, mas o nível de um incidente é definido pelo efeito que de fato aconteceu.

Se-veri-dade	O que significa	Ferramentas típicas	Exemplo de falha
In-for-ma-ção	Nada mudou; uma resposta errada ou uma leitura desperdiçada	<code>lookup_order</code> , <code>query_logs</code> , <code>search_docs</code>	F3 em um resumo interno sobre o qual ninguém age
Re-ver-sível	O estado mudou e uma ação compensatória pode restaurá-lo	<code>update_shipping_address</code> , <code>open_pull_request</code> , <code>toggle_feature_flag</code> , <code>request_rollback</code>	F2 em uma mudança de endereço antes da entrega à transportadora
Irre-ver-sível	A Parcelport não consegue desfazer	<code>issue_refund</code>	F7 em um reembolso acima do teto
Ex-terna	Chegou a uma pessoa ou sistema que a Parcelport não controla	<code>send_customer_reply</code>	F3 em uma resposta já entregue

Como o nível segue o efeito e não a ferramenta, a severidade pertence à instância. Um reembolso de valor trivial e um reembolso no teto são a mesma ferramenta com alcance diferente, e uma política que os trata de forma idêntica será rígida demais para o primeiro ou frouxa demais para o segundo. Se uma chamada precisa de aprovação é uma decisão de política

no gate e não se lê da classe de efeito. Uma escrita reversível pode precisar de aprovação (`request_rollback` precisa), e uma escrita irreversível pequena pode prosseguir sem ela.

A intensidade do controle segue então um princípio simples: quanto menos uma falha pode ser desfeita, mais cedo e de forma mais determinística ela precisa ser barrada, e mais evidência precisa existir de antemão. No nível de informação, a detecção posterior costuma bastar, e o custo de um gate preventivo não compensa. No nível reversível, o gate verifica pré-condições e o registro mostra uma intenção, de modo que a ação compensatória seja conhecida. No nível irreversível, pré-condições, tetos, idempotência e, acima de um limiar, aprovação vinculada à chamada exata. No nível externo, a chamada é tratada como irreversível mesmo que o sistema possa enviar uma correção, porque uma mensagem não pode ser desfeita depois de lida.

A política ilustrativa abaixo expressa a ideia como dados, para que a intensidade seja algo que o gate avalia e não algo que um prompt espera.

```
policy minimum_controls // illustrative notation
  severity information:
    gate: schema check
    record: proposal and result
  severity reversible:
    gate: schema, preconditions, permission
    record: intent before effect, outcome after
    undo: compensating action named in the contract
  severity irreversible:
    gate: schema, preconditions, per-tool ceiling, ownership
    idempotency: key assigned by the runtime
    approval: required above a per-tool threshold set by policy,
              bound to the exact call
    record: intent, outcome, reconciliation entry
  severity external:
    gate: all of the above, plus claim check on content
    approval: required when the check cannot tie a claim to a source
    record: full content as sent
```

A severidade também diz onde investir o esforço de eval. O golden set deve conter mais casos adversariais e de fronteira para F2, F3 e F7 nas linhas irreversível e externa do que para qualquer coisa na linha de informação, porque é ali que um erro sai caro (Capítulo 21).

Uma tabela para o livro inteiro

A tabela abaixo é a forma compacta das nove seções acima. É a mesma tabela que o Apêndice reproduz para consulta. Leia-a por coluna quando estiver planejando controles e por linha quando estiver revisando um incidente.

Classe	Deteção	Prevenção	Limitação	Capítulos
F1 Saída malformada	Taxa de falha de esquema por ferramenta	Esquemas estreitos, enumerações fechadas	Reparo limitado e depois hand-off	2, 5, 6
F2 Ferramenta incorreta ou argumentos incorretos	Falhas de pré-condição, revisão por amostragem	Escolher entre fatos do run, pré-condições de propriedade	Aprovação para chamadas irreversíveis	4, 5, 6
F3 Afirmação sem fundamento	Verificação de afirmações contra resultados de ferramenta	Fatos necessários no contexto, campos preenchidos por código	Revisão humana antes da resposta externa	2, 9, 21
F4 Sequestro de instruções	Taint em argumentos, passos anômalos	Conteúdo não confiável rotulado, regras de taint	Autoridade mínima, aprovação	8, 9, 16
F5 Loop descontrolado ou contexto obsoleto	Chamadas repetidas, idade dos fatos, divergência de versão	Verificações de progresso, proveniência, nova leitura	Limites, pré-condições de versão	9, 10, 12, 13
F6 Falha parcial silenciosa	Reconciliação de intenções e resultados	Intenção primeiro, idempotência, resultado desconhecido	Nenhum “done” com intenções abertas	6, 10, 14
F7 Efeito não autorizado	Auditoria dos efeitos contra a autoridade emitida	Autoridade por chamada, tetos em código	Credenciais de curta duração, sandbox	7, 15, 18, 19
F8 Comportamento não observado	Cobertura de traces contra efeitos	Um único formato de trace, intenção antes do efeito	Parar ou descartar efeitos quando o registro falha	17, 20, 21, 23
F9 Explosão de custo ou latência	Distribuições de custo e latência, contagens de retries	Orçamentos, orçamento de contexto, retries classificados	Circuit breakers, modo degradado	13, 14, 22

Nenhuma linha é encerrada por um único controle. A prevenção reduz a taxa, a limitação reduz o alcance e a detecção diz qual das duas falhou. Um design que tem uma entrada em apenas uma coluna de uma linha tem uma lacuna, e a tabela torna a lacuna fácil de ver.

Uma linguagem compartilhada para revisão, eval e operação

A taxonomia se paga quando a revisão de incidentes, os evals e a operação usam os mesmos ids. O Capítulo 23 constrói a revisão sem culpa sobre o registro de incidente acima, de modo que a classe, o eixo da causa-raiz e o controle ausente são campos separados, e o nome de uma pessoa nunca aparece como causa.

O Capítulo 21 pode marcar cada caso do golden set com a classe que ele pretende expor, o que dá à suíte uma visão de cobertura que uma taxa total de aprovação esconde: uma suíte que é toda F3 e nada em F6 é desequilibrada. Os traces do Capítulo 20 podem carregar a classe como um rótulo em recusas, retries, hand-offs e achados de reconciliação, de modo que uma taxa crescente de recusas F2 apareça antes que alguém abra um ticket.

Dois revisores vão discordar em uma fração dos casos; as regras de desempate acima e uma segunda marcação resolvem a maioria. Um caso sem marcação alguma é o que se deve recusar, porque “outro” vira o lugar onde vivem as falhas não examinadas. O Capítulo 24 volta à tabela como verificação de pré-lançamento: para cada classe, que detecção e que limitação este agente tem?

Trade-offs e custos

Uma taxonomia é barata de escrever e cara de manter honesta. Os custos são específicos.

Classificar toma tempo. Todo incidente agora precisa de uma etapa de revisão que produza um registro. Para uma equipe que lida com alguns incidentes por mês, isso é viável. Para uma equipe com muitos eventos de

baixa severidade por semana, não é, e a resposta sensata é classificar por amostragem nos níveis de informação e reversível e por completo nos níveis irreversível e externo.

As classes se sobrepõem, e ids fixos escondem isso. Nove classes são uma simplificação de um espaço contínuo. Forçar um incidente confuso em F2 ou F3 pode esconder a combinação que o tornou interessante. A lista ordenada de marcações ajuda, e também ajuda a disposição de acrescentar uma subclasse como F4.2, mas o livro não acrescenta novas classes de nível superior, e uma equipe que o faça deve esperar que seus dashboards deixem de combinar com o vocabulário de todo mundo.

Os sinais de detecção não são gratuitos. Uma verificação de afirmações custa tempo de engenharia e alguma latência em cada resposta. Os jobs de reconciliação precisam de acesso a vários sistemas e de um responsável que os mantenha. As verificações de cobertura de traces precisam que o pipeline de traces seja confiável o bastante para que se confie nas ausências dele. Cada sinal da tabela é um pequeno sistema, e a escolha de qual construir primeiro deve seguir a severidade: reconciliação para F6 envolvendo dinheiro, auditorias de propriedade para F7, antes de detectores elaborados de F3 em resumos internos.

Taxonomias descambam para o teatro. Um dashboard de classes de falha que ninguém revisa, ou um campo de marcação sempre preenchido com o primeiro valor da lista suspensa, é um custo sem retorno. Se a revisão mensal das marcações não leva a pelo menos uma mudança em um controle, o processo precisa ser encurtado ou os dados precisam de uma pergunta diferente.

Quando não usá-la por completo. Um protótipo inicial com uma só ferramenta de leitura e sem efeitos tem pouca utilidade para a maquinaria de severidade. Use os nove nomes como um checklist do que pode dar errado, mantenha o registro de incidente em três linhas e acrescente o resto à medida que surgirem ferramentas com efeitos. No momento em que um agente puder movimentar dinheiro ou escrever a um cliente, o registro completo passa a valer a pena.

Erros comuns

- **Encerrar a revisão em “o modelo cometeu um erro”.** É tentador porque a proposta é o evento visível e o modelo é fácil de apontar. A correção é a pergunta da causa-raiz: perguntar qual controle teria tornado essa proposta inofensiva e escrever o item de ação em cima dele.
- **Marcar pelo sintoma em vez de pelo mecanismo.** “Reembolso errado” é um sintoma, e pode ser F2, F5.2 ou F7. É tentador porque as palavras do cliente viram o rótulo. A correção é percorrer as perguntas em ordem e registrar toda classe da cadeia.
- **Tratar F3 como a única classe que importa.** As afirmações sem fundamento são as mais discutidas, então as equipes gastam a maior parte do esforço nelas e deixam F6, F7 e F8 sem responsáveis. A correção é contar por severidade e olhar quais linhas da tabela têm uma célula vazia.
- **Usar um modelo para marcar incidentes sem verificação humana.** Escala, e é tentador quando o volume cresce. As marcações então herdam a falta de confiabilidade que a taxonomia existe para gerenciar. A correção é deixar um modelo sugerir marcações e uma pessoa confirmar as dos níveis irreversível e externo, e avaliar o sugeridor como qualquer outro grader baseado em modelo (Capítulo 21).
- **Acrescentar classes de nível superior para cada nova surpresa.** Uma falha nova parece nova, então ganha um id novo. A correção é encaixá-la primeiro como subclasse da classe mais próxima, e acrescentar uma classe de nível superior apenas se nenhum controle das linhas existentes conseguir tratá-la.
- **Deixar “prevenido por prompt” contar como controle na tabela.** Uma célula que diz “instruir o modelo a não fazer” parece progresso e não custa nada. A correção é a regra que todo capítulo segue: se a única coisa entre a proposta e o efeito é redação, a célula está vazia.
- **Ignorar a detecção porque existe prevenção.** Uma equipe com um bom gate supõe que não sobrou nada a detectar. A correção é tratar as recusas como um sinal e rodar a reconciliação de qualquer forma; o gate pode ter um bug, e uma verificação ausente não consegue recusar nada.

Pontos-chave

- Uma classe de falha nomeia um comportamento observável, um eixo de causa-raiz nomeia o componente cuja mudança a teria evitado e a severidade nomeia quanto controle a situação merecia; misturar os três é o principal motivo de as revisões andarem em círculos.
- “O modelo cometeu um erro” descreve o gatilho, que o design deve supor, e não é uma causa-raiz; a causa-raiz é o controle, o contexto ou a ferramenta que deixou uma proposta errada importar.
- As nove classes F1 a F9 têm nome e id fixos, com subclasses como F4.1, F4.2, F5.1 e F5.2 permitidas, para que todo capítulo, revisão e dashboard de uma equipe use as mesmas palavras.
- Cada classe precisa de um sinal de detecção, um controle preventivo e um controle limitador, e uma linha da tabela da taxonomia com uma célula vazia marca uma lacuna no design.
- Um único incidente costuma carregar mais de uma marcação, ordenadas da proposta ao efeito, e o remédio pertence ao controle mais antecipado que valeria para toda proposta futura desse tipo.
- A severidade (informação, reversível, irreversível, externa) pertence à instância e não à ferramenta, e quanto menos uma falha pode ser desfeita, mais cedo e de forma mais determinística ela precisa ser barrada.
- A taxonomia só se paga quando a revisão de incidentes, os evals e os dashboards operacionais compartilham seus ids, e uma revisão que não produz um controle novo ou alterado é sinal de que o processo virou teatro.

O Capítulo 4 passa de nomear as falhas para evitar boa parte delas, decidindo, decisão por decisão, o que o modelo pode escolher e o que o código precisa decidir.

Capítulo 4 — Fronteiras do determinismo

Pense em uma tarde de quinta-feira na Parcelport, quando um cliente escreve que dois dos três itens de um pedido chegaram amassados. No protótipo, o prompt do agente de suporte pede ao modelo que calcule um reembolso parcial justo, converta o valor para a moeda do pedido se o cliente pagou em outra, emita o reembolso e escreva uma resposta cordial. O modelo devolve uma única proposta, que traz um pedido, um valor, uma moeda, um motivo e o texto da resposta. O valor é aritmética sobre linhas de pedido, um desconto e uma alíquota de imposto, e nada no protótipo o verifica.

Suponha que a aritmética esteja certa na maioria dos dias. No dia em que não estiver, o reembolso sai menor ou maior do que deveria, e o `payments-service` o registra de qualquer forma, porque o serviço confia em quem o chama e quem o chama confia no modelo. Ninguém decidiu que um componente probabilístico deveria fazer aritmética com dinheiro. O prompt cresceu uma frase por vez, e cada frase transferiu mais uma decisão para o modelo.

Este capítulo pertence à parte **Gate** do envelope de controle, com um pé na Proposta. A pergunta que ele responde é a do próprio Gate: esta proposta pode produzir efeito, para este principal, agora? Para respondê-la, primeiro é preciso saber quais decisões de um run o modelo pode tomar e quais pertencem ao código. A linha entre as duas é o que este capítulo chama de **fronteira do determinismo**, e o trabalho é traçá-la de propósito, mantê-la estreita e torná-la testável.

O problema e por que ele é difícil

Um run é uma cadeia de decisões, e o protótipo não as rotula. Qual pedido o cliente quer dizer? Um item amassado está coberto pelas regras de envio? Qual é o valor reembolsável? Esse valor está dentro de

`refund_ceiling`? A resposta promete algo que os dados do pedido não sustentam? Em um único prompt, essas perguntas chegam como uma só requisição, e o modelo as responde em uma única proposta. As respostas têm propriedades muito diferentes, mas o design as trata de forma idêntica.

Essa é a falha de que trata este capítulo, e ela fica nas partes Proposta e Gate do envelope. Seus produtos típicos são F2 (ferramenta incorreta ou argumentos incorretos), quando uma proposta nomeia o pedido errado ou um valor que não se ajusta à situação; F1 (saída malformada), quando a estrutura se desvia e um parser a jusrante adivinha; e F7 (efeito não autorizado), quando um valor acima do limite chega ao serviço de pagamentos porque nenhum código o comparou com coisa alguma. F3 (afirmação sem fundamento) se junta a eles quando uma resposta cita um número que nenhum resultado de ferramenta contém.

A correção óbvia é mandar o modelo ter cuidado. O prompt ganha uma frase: nunca ultrapasse o limite, sempre use a moeda do pedido, confira a aritmética duas vezes. Essa frase é um pedido, não um controle, e o Capítulo 2 explica por que o dia em que ela não for seguida vai chegar. Este capítulo parte disso como premissa.

Há uma segunda razão pela qual a correção óbvia falha, e ela é menos visível. Muitas decisões são uma mistura. “Reembolsar os itens danificados” contém um julgamento (estes dois itens são os danificados, segundo o que o cliente escreveu) e um cálculo (quanto somam essas duas linhas, depois do desconto, em qual moeda). O modelo é um lugar razoável para o primeiro e um lugar ruim para o segundo. Se os dois vivem em um mesmo campo da proposta, não dá para verificar um sem rederivar o outro.

É por isso que a fronteira é uma questão de engenharia e não uma questão de prompt. Um prompt pode pedir comportamento de um lado da linha. Só o código pode fazer a linha existir.

Traçando a linha: cinco critérios

Não traçaria a fronteira por tarefa (“o modelo cuida dos reembolsos”) nem por intuição (“esta parece arriscada”). Traçaria a fronteira por decisão, usando cinco perguntas. Nenhuma delas é nova, e cada uma tem uma direção: inclina a decisão para o código ou para o modelo.

Critério	A pergunta	Inclina para o código quando	Inclina para o modelo quando
Reversibilidade	Uma resposta errada pode ser desfeita, e por quem?	O efeito é uma escrita irreversível ou um efeito colateral externo	O resultado é um rascunho que uma pessoa ou um passo posterior pode descartar
Verificabilidade	O código consegue conferir a resposta com uma fonte da verdade?	Uma regra, uma tabela ou um serviço guarda o valor correto	Não existe fonte; a resposta é um julgamento
Frequência	Com que frequência a decisão é tomada, e com que variedade?	Ela se repete com o mesmo formato, então uma regra pode ser escrita uma única vez	As entradas são abertas e uma regra nunca as cobriria
Tolerância	O quanto a resposta pode estar errada antes que alguém se prejudique?	A tolerância é zero ou um limite rígido (dinheiro, limiares)	A tolerância é ampla (tom, redação, ordenação de candidatos)
Explicabilidade	Alguém precisará explicar depois exatamente por que este valor foi escolhido?	Um revisor perguntará “por que este valor?” e a resposta precisa ser uma regra	Uma razão em palavras simples basta

A reversibilidade é o critério que pesaria primeiro, porque é o único que não se recupera depois. Se dois critérios discordam, a classe de efeito da tabela de ferramentas deste livro desempata: uma escrita irreversível ou um efeito colateral externo puxa a decisão para o código mesmo quando o modelo costuma acertar. O custo de uma resposta errada, e não a frequência de uma resposta certa, define a fronteira.

Os outros quatro critérios moldam o aspecto do código. A verificabilidade diz se uma checagem determinística pode sequer existir. A frequência diz se vale a pena escrever uma regra. A tolerância diz quão estrita a checagem precisa ser. A explicabilidade diz se a resposta precisa sair de uma função que se possa ler, já que a razão declarada por um modelo é uma proposta sobre a própria saída e não um registro de como a saída foi formada.

Um inventário de decisões para um ticket

Aplique as perguntas ao ticket de reembolso da abertura. O ponto do exercício é o próprio inventário: toda decisão da página recebe um responsável, e o responsável fica escrito.

Decisão	Responsável	Por quê
Qual pedido o cliente quer dizer	O modelo propõe a partir de uma lista, o código verifica a titularidade	Linguagem aberta, mas a resposta precisa ser um dos pedidos do próprio cliente
Se o cliente relata dano, não entrega ou outra coisa	Modelo	Um julgamento sobre texto livre; a saída é um valor de um conjunto fechado
Se este motivo é coberto pelas regras de envio e devolução	Código	Existe uma regra e uma tabela a guarda
Quais linhas do pedido são afetadas	O modelo propõe ids de linha, o código verifica que existem e não foram reembolsadas	Julgamento sobre texto, verificável contra o pedido
O valor do reembolso	Código	Dinheiro; verificável a partir do pedido; tolerância zero
A moeda	Código	Vem do pedido, nunca de uma proposta
Se o valor está dentro de <code>refund_ceiling</code>	Código	Um limiar; escrita irreversível
Se um humano precisa aprovar	Código (política no gate)	A aprovação é um resultado de política, não uma opinião do modelo
A redação da resposta	Modelo, dentro de um quadro verificado	Tolerância ampla, mas F3 se aplica às afirmações dentro dela
Se deve escalonar	O modelo propõe, o código também pode forçar	Julgamento, com um piso determinístico

Duas coisas se destacam. Primeiro, o modelo fica com as decisões que envolvem linguagem, e isso é boa parte do trabalho. Segundo, as decisões que ele perde são todas aquelas em que uma resposta errada custa dinheiro ou não pode ser explicada, e a maioria delas nunca foi “decisão” de fato: eram consultas e aritmética que o prompt havia entregado ao componente errado.

Padrão 1: o modelo propõe, o código dispõe

O padrão central é uma frase: o modelo propõe, o código dispõe. Tudo o que o modelo devolve é uma proposta, ou seja, entrada não confiável, e é tratado por código que a verifica antes que qualquer coisa mude. O orquestrador é o único lugar onde um efeito começa, e ele só começa um efeito diante de um veredicto do gate.

Eis o passo de disposição para uma chamada de ferramenta, escrito no pseudocódigo do livro como o ramo de `gate.check` que trata chamadas de ferramenta. Seus veredictos são os três que o gate devolve: `"allow"`, `"refuse"` e `"needs_approval"`. Observe a ordem. A estrutura vem primeiro, depois a escolha da ferramenta, depois os argumentos, depois a pertinência ao conjunto de escolhas (o Padrão 2 o constrói), depois os fatos lidos dos serviços e, por fim, a política.

```
function checkToolCall(run, proposal):           // the tool-call branch
of gate.check
  parsed = parseProposal(proposal)              // F1 is caught here
  if parsed.failed:
    return { kind: "refuse", reason: "unparseable", fields:
parsed.errors }
  call = parsed.call
  if call.tool not in toolsOffered(run):
    return { kind: "refuse", reason: "not_in_choice_set" }
  errors = schemaCheck(call.tool, call.arguments)
  if errors is not empty:
    return { kind: "refuse", reason: "invalid_arguments", fields: errors
}
  if not inChoiceSet(buildChoiceSet(run), call): // membership, not only
shape
    return { kind: "refuse", reason: "not_in_choice_set" }
  facts = loadFacts(run, call)                  // read from services,
not from the model
  failed = firstFailedPrecondition(call, facts)
  if failed is not null:
    return { kind: "refuse", reason: "precondition_failed", field:
failed.name }
  if requiresApproval(call, facts, policyVersion()):
    return { kind: "needs_approval", request: buildRequest(call, facts)
}
  return { kind: "allow", call: call }
```

Este bloco é uma visão parcial do gate no Capítulo 5: deixa de fora a permissão e as demais checagens que aquele capítulo ordena, e usa os nomes de razão do Capítulo 5. Três detalhes sustentam o peso. Os fatos vêm de `loadFacts`, que lê o `orders-service` e o `payments-service` por conta própria. Se uma checagem compara um argumento com um valor que o

modelo também forneceu, ela não verificou nada. E `requiresApproval` recebe uma versão da política, de modo que o mesmo veredicto possa ser reproduzido depois (mais sobre isso adiante).

Saída estruturada e validação de esquema

Um esquema é o controle mais barato deste capítulo, e responde à primeira pergunta: esta proposta ao menos tem o formato de algo que a ferramenta aceita? Uma proposta que falha na checagem é F1 e nunca chega a um serviço. Uma proposta que passa está apenas bem formada. Isso é uma afirmação muito mais fraca do que “correta” ou “permitida”, e o resto do capítulo existe por causa dessa distância.

Manteria a validação de esquema estrita e entediante. Rejeite campos desconhecidos, rejeite os ausentes, rejeite valores do tipo errado e não conserve. Um validador que converte em silêncio uma string em número, apara um campo ou preenche um valor padrão tomou uma decisão em nome do modelo, e a tomou em um lugar que ninguém revisa. Se um conserto vale a pena, faça dele um passo visível, testado e com registro próprio, ou deixe a proposta ser recusada e proposta de novo.

O Capítulo 5 trata de como se pede ao modelo uma saída estruturada, e o Capítulo 6 trata do contrato de ferramenta ao qual o esquema pertence. O que importa aqui é a posição: a checagem de esquema roda depois do modelo e antes de todo o resto, em código, não importa o que o prompt tenha dito.

Padrão 2: estreitar a faixa de escolha

O segundo padrão reduz o quanto o modelo é livre para dizer. Todo campo de texto livre é um campo em que um valor errado pode estar bem formado, então a melhor maneira de reduzir F2 é trocar campos abertos por escolhas que o orquestrador fornece.

Há três estreitamentos comuns. Um **enum** troca uma string livre por um conjunto fechado, como os valores de `reason_code` no contrato `issue_refund`. Uma **lista de identificadores** troca um valor que o modelo poderia lembrar ou inventar por um que ele precisa escolher de uma lis-

ta que o orquestrador leu para este cliente. Um **template** troca um bloco de prosa por um quadro cujos espaços são preenchidos pelo código e cujas partes abertas são a única coisa que o modelo escreve.

```
function buildChoiceSet(run):
  orders = orders.listForCustomer(run.customer_id)    // read by the
runtime, not the model
  return {
    order_ids:      idsOf(orders),                    // the model picks
one of these
    line_ids:      linesByOrder(orders),              // keyed by order
id
    reason_codes:  ["damaged", "not_delivered", "wrong_item",
"goodwill"],
    reply_templates: templatesFor(run.language)
  }
```

O conjunto de escolhas entra no contexto como uma lista rotulada, e o gate então verifica a pertinência com o passo `inChoiceSet` em `checkToolCall`: um `order_id` fora de `order_ids` é recusado com a razão `not_in_choice_set`. Note o que isso faz pelo problema do confused deputy. Uma proposta que nomeia o pedido de outro cliente não é um julgamento que o modelo errou; é um valor que o código enxerga que não está no conjunto, e a recusa não depende de o modelo perceber coisa alguma.

O estreitamento não é gratuito e tem um limite. Um conjunto fechado precisa conter as situações que de fato ocorrem, ou o modelo escolherá o valor errado mais próximo. A saída usual é um valor `other` explícito que encaminha para `escalate_to_human`, e ele precisa de vigilância: um `other` que a maioria das propostas escolhe é sinal de que o conjunto não descreve o trabalho, e não de que os clientes são incomuns. O mesmo vale para os templates, que cobrem bem a resposta comum e mal a incomum. Para a incomum, deixaria o modelo redigir texto livre e deixaria um humano lê-lo antes de ele sair, o que é uma decisão do Capítulo 15.

Padrão 3: o cálculo pertence ao código

Dinheiro, datas e limiares compartilham uma propriedade: existe uma resposta correta, e o código consegue calculá-la. Quando se pede esse valor ao modelo, há duas maneiras de errar. Ele pode devolver um valor errado, e o design pode aceitá-lo porque nada o recalcula. A correção para ambas é a mesma: não pedir.

A forma mais forte remove o campo. Em vez de propor um valor, o modelo propõe quais linhas do pedido são afetadas e por quê. O orquestrador então deriva o valor.

```
function computeRefund(order, line_ids, reason_code, policy):
    total_minor = 0
    for each line_id in line_ids:
        line = order.lineById(line_id)
        if line is null or line.refunded:
            raise InvalidLineSelection          // refused; the model
sees a reason code
            total_minor = total_minor + line.paid_minor    // as stored by
orders-service, minor units
        if reason_code == "goodwill":
            total_minor = min(total_minor, policy.goodwill_cap_minor)
    return { amount_minor: total_minor, currency: order.currency }    //
never from the proposal
```

Quando um contrato ainda faz o modelo fornecer um valor, como faz o contrato canônico `issue_refund` deste livro, o código trata esse valor como uma afirmação a comparar: recalcule o valor e recuse a chamada se forem diferentes. Considero a versão sem o campo mais fácil de defender. Ela tem um valor a menos que o modelo pode errar, e um revisor que pergunta “por que este valor?” recebe uma função para ler em vez de uma proposta em que confiar.

Aviso: Um valor de reembolso que veio do modelo e foi para o `payments-service` sem recálculo é uma escrita irreversível apoiada em um valor probabilístico. Se você mudar apenas uma coisa depois de ler este capítulo, faça do valor algo que o código deriva ou recalcula.

O mesmo raciocínio cobre os outros valores do cenário de abertura. A moeda pertence ao pedido, então uma proposta que traz outra moeda é recusada e não dispara uma conversão. Uma data ou um prazo (“a encomenda deveria ter chegado há três dias”) é calculado a partir dos timestamps nos dados do pedido. Um limiar, como o limite, é lido da política e comparado com um inteiro. Nenhum desses casos precisa de um modelo, e cada um é um lugar em que a participação do modelo só poderia acrescentar uma maneira de errar.

Há um preço. Reembolsos parciais ou discricionários que nenhuma regra descreve (“reembolsar um terço, o cliente esperou muito”) não cabem em um valor derivado. Para esses, ofereceria ao modelo um cardápio curto de valores que a política permite, digamos um punhado de frações fixas do preço pago, e mandaria para um humano tudo o que estiver fora do cardápio. Isso transforma um número aberto em uma escolha, que é o Padrão 2 aplicado a dinheiro.

Padrão 4: pré-condições e pós-condições determinísticas

Uma pré-condição é um fato que precisa valer antes de um efeito começar, e o gate a verifica. Uma pós-condição é um fato que precisa valer depois, e o orquestrador também a verifica. Juntas, elas cercam o efeito com código dos dois lados.

As pré-condições de `issue_refund` vêm do seu contrato: o pedido pertence ao cliente deste run, o pagamento foi capturado, o valor não excede o saldo reembolsável, um reembolso acima de `refund_ceiling` precisa de aprovação, e nenhum reembolso anterior com a mesma chave tem o resultado “unknown”, o que o gate verifica consultando primeiro o status e recusando até que ele seja conhecido. O Capítulo 6 escreve isso como parte do contrato, e o Capítulo 7 trata das permissões de que elas dependem. O que cabe aqui é o princípio: cada pré-condição é uma função determinística de fatos que o gate leu, nunca de algo que a proposta afirma sobre si mesma.

As pós-condições são mais fáceis de pular e com mais frequência estão ausentes. Uma chamada de efeito que retorna “ok” é uma evidência, e um timeout que não retorna nada é outra. Nenhuma das duas diz o que o `payments-service` guarda. A pós-condição é ler o estado de volta.

```

function applyRefund(run, call):
    refund_intent = refundIntents.firstFor(run.ticket_id, call.order_id)
    // runtime-assigned; a new one only after a recorded human decision
    key = hash(run.ticket_id, call.order_id, refund_intent.id) //
    refund_intent_id of the contract; nothing the model supplied
    record(run, "intent", { call: call, key: key }) // first: a crash
    leaves a trace
    try:
        result = effect.apply(run, call, idempotencyKey: key) // the key
    reaches payments
        record(run, "effect", result) // a separate
    system; this write can fail too
        on Timeout:
            record(run, "effect_unknown", key) // payments may or
    may not hold the write
            status = payments.refundStatus(key) // read back
    instead of trusting the reply
            if status.state == "completed":
                return status
            record(run, "postcondition_failed", status)
            return handOff(run, "refund outcome not confirmed") // a human
    reconciles; no retry here


```

Veja o que o bloco não faz. Ele não envolve a escrita em pagamentos e o registro em uma única transação, porque são dois sistemas e nenhuma transação os abrange. Ele escreve a intenção primeiro, para que uma queda entre o efeito e o registro deixe evidência. E ele lê o status de volta, para que uma falha parcial silenciosa (F6) apareça como uma pós-condição falha e não como um run marcado como concluído. A detecção da lacuna que resta, uma intenção sem efeito correspondente, é um job de reconciliação sobre o registro, no qual o Capítulo 10 e o Capítulo 20 se apoiam.

A chave merece uma segunda olhada, porque é ela que impede um timeout de virar um segundo reembolso. Ela é construída apenas com identificadores que o runtime atribuiu: o ticket, o pedido e a intenção de reembolso. O run, o passo, o valor e o código de motivo não estão nela. Suponha que a chamada dê timeout e que o modelo, em um passo posterior, proponha o reembolso de novo com outro valor. A chave é a mesma, então a ferramenta devolve o primeiro resultado em vez de agir duas vezes. E, conforme o contrato `issue_refund`, o gate recusa qualquer outro reembolso para essa chave enquanto seu resultado for “unknown”, até que a consulta de status diga o que aconteceu. Um segundo reembolso legítimo, para outras linhas do mesmo pedido, é uma nova intenção de reembolso, e só é emitido depois de uma decisão humana registrada no serviço de aprovação.

O formato do caminho inteiro

O diagrama abaixo mostra o caminho do reembolso com a fronteira traçada. Observe onde termina o trabalho do modelo: ele termina na proposta, e todas as caixas depois dela são código. Observe também os caminhos de recusa, porque são a parte que um prompt não consegue oferecer.



Tornando a fronteira testável

Uma fronteira que você não consegue testar é uma crença. A vantagem de traçá-la em código é que o gate é uma função: dados uma proposta, os fatos que ele lê e a versão da política, ele devolve um veredicto. Nada nessa função é probabilístico, então nada em seu teste precisa de um modelo.

Testaria o gate com uma tabela de propostas, escritas à mão e ampliadas a partir de incidentes. Cada linha é uma proposta, um conjunto de fatos e o veredicto esperado com seu código de razão. As linhas que valem a pena ter primeiro são as que correspondem às classes de falha: uma proposta com um campo ausente (F1), um id de pedido fora do conjunto de escolhas (F2), uma linha já reembolsada (F2), um valor uma unidade menor acima do limite (F7), uma moeda diferente da do pedido (F2), um duplicado de uma intenção de reembolso anterior e uma proposta para uma ferramenta que este run não recebeu. Nenhuma delas precisa de um payload com cara de ataque, e nenhuma precisa de um modelo. São entradas de uma função.

Isso também dá uma medida que o modelo não consegue dar. Os evals (Capítulo 21) dizem com que frequência o modelo propõe algo que o gate recusa. Os testes do próprio gate dizem que o gate recusa. São duas perguntas separadas, e uma equipe que tem apenas a primeira não consegue dizer se uma proposta ruim teria chegado ao `payments-service`.

Dizendo ao modelo por que ele foi recusado

Quando o gate recusa uma proposta, a recusa volta ao contexto como uma observação, e o modelo propõe de novo. Isso é útil, porque uma recusa por `not_in_choice_set` muitas vezes leva a uma segunda proposta corre-

ta. Também é um loop, e um loop precisa de um limite.

```
function proposeWithFeedback(run, maxAttempts):           // say, maxAttempts
= 2
  attempts = 0
  while attempts < maxAttempts:
    bound.check(run)
    proposal = model.propose(assembleContext(run))
    record(run, "proposal", proposal)                     // refused
  proposals are kept too
  verdict = gate.check(run, proposal)
  record(run, "verdict", verdict)
  if verdict.kind != "refuse":
    return verdict
  addObservation(run, refusalNotice(verdict))           // reason code and
field names only
  attempts = attempts + 1
  return handOff(run, "proposals refused")              // degraded mode, a
human takes over
```

Três escolhas no bloco são deliberadas. O feedback é um código de razão e nomes de campos, tirados de uma lista fixa, e não texto livre montado a partir de estado interno. O número de repropostas é pequeno e conta contra os limites do run (os capítulos 12 e 13 tratam deles). E esgotar as tentativas entrega o run a um humano em vez de baixar o nível de exigência. Um gate que acaba aceitando a terceira tentativa, só para encerrar o loop, deixou de ser um gate.

Mais uma ressalva. O feedback não deve permitir que o modelo sonde um limite. Uma recusa por um valor do cardápio que excede o saldo reembolsável pode dizer `precondition_failed` com o nome de campo `amount_minor` e parar aí; acrescentar o próprio saldo dá à próxima proposta um número para ficar logo abaixo. Um reembolso acima de `refund_ceiling` não é de modo algum uma recusa, mas `needs_approval`, e quem vê esse número é Sam.

Replay e o que registrar

Uma ideia tentadora é reproduzir um run alimentando-o de novo com a mesma entrada. Para o código ao redor do modelo isso funciona; para o modelo, não. O mesmo contexto não garante a mesma proposta, então refazer uma chamada ao modelo é uma nova amostra, não uma reprodução. O Capítulo 2 dá a razão, e a consequência para este capítulo diz respeito ao que guardar.

O que você registra decide o que consegue reconstruir depois. A saída do modelo não é reproduzível, então precisa ser armazenada: a proposta exata, como foi devolvida. O gate só é reproduzível se suas entradas também forem armazenadas, o que significa os fatos que ele leu e a versão da política que aplicou. O efeito é armazenado com seu resultado e sua pós-condição. A partir disso você consegue responder, para qualquer run, à pergunta que importa: este efeito era permitido pelas regras em vigor, dado o que o sistema sabia?

```
record gate_decision
  run_id, step_id, timestamp
  proposal:      exact proposal as returned by the model
  facts:         reference to the facts the gate read (order, payment,
balance)
  policy_version: version of the policy and choice set in force
  verdict:       allow | refuse | needs_approval, with reason code
  approver:      none, or the person and time, bound to this exact call
  effect:        reference to the effect result and the postcondition read
```

Com esse registro, um revisor pode fazer o replay do gate: pegar a proposta armazenada, os fatos armazenados e a versão da política armazenada, rodar o gate de novo e obter o veredicto armazenado. Se o veredicto for diferente, o gate ou a política mudou de um jeito que alguém deveria saber. Isso é uma regressão determinística, e é muito mais barata de encontrar do que uma mudança no comportamento do modelo. O Capítulo 10 trata do run store em que esses registros vivem, o Capítulo 20 trata do formato do trace, e o Capítulo 21 usa as propostas registradas como entradas dos evals.

O agente de ops: onde fica a fronteira do rollback

O agente de suporte mostra a fronteira aplicada ao dinheiro. O agente de ops a mostra em uma decisão mais diagnóstica e menos numérica: um deploy recente deve sofrer rollback? `request_rollback` é uma escrita reversível, já que um deploy posterior pode restaurar a versão anterior, e a política exige aprovação para ela. Isso a torna um bom lugar para ver os três responsáveis em ação.

Imagine Robin de on-call e um alerta sobre erros depois de um deploy. O agente de ops lê logs, métricas e um trace, e o modelo propõe um diagnóstico: a regressão começou com o deploy mais recente de um serviço, e um

rollback a encerraria. Esse diagnóstico é um julgamento sobre evidências bagunçadas, que é o trabalho para o qual o modelo serve. O que acontece em seguida não fica por conta dele.

Passo	Quem	Determinístico?
Propor um diagnóstico e um rollback de um deploy nomeado	Modelo	Não, uma proposta
Verificar que o deploy nomeado existe, é o mais recente daquele serviço e tem uma versão anterior para restaurar	Código, lendo o <code>deploy-service</code>	Sim
Verificar que nenhum rollback ou mudança de flag para ele já está em andamento	Código	Sim
Ler a métrica de taxa de erros antes e depois do horário do deploy e comparar com um limiar da política	Código, lendo o <code>metrics store</code>	Sim
Anexar essa evidência à requisição de aprovação, calculada pelo código, ao lado da explicação do modelo	Orquestrador	Sim
Aprovar ou recusar	Robin	Uma decisão humana, vinculada à chamada exata
Iniciar o rollback e ler de volta o estado do deploy	Código	Sim

O passo mais importante é o quarto. O modelo pode dizer que a taxa de erros “dobrou depois do deploy”, e essa frase é uma afirmação, possivelmente sem fundamento (F3). O gate não discute com ela. O código lê a métrica por conta própria, aplica um limiar da política (digamos, a taxa pós-deploy excede o baseline pré-deploy por uma margem configurada em uma janela configurada) e põe os números diante de Robin. Se os dados não atingem o limiar, a proposta é recusada antes que Robin seja interrompido. Se atingem, Robin vê uma evidência que veio do `metrics store` e não da prosa do modelo.

```

function checkRollback(run, call):
    dep = deploys.describe(call.deployment_id)           // read from
    deploy-service
    if dep is null or not dep.isLatestForService:
        return { kind: "refuse", reason: "precondition_failed", field:
"latest_deployment" }
    if dep.previousVersion is null:
        return { kind: "refuse", reason: "precondition_failed", field:
"previous_version" }
    if deploys.inFlightChangeFor(dep.service):
        return { kind: "refuse", reason: "precondition_failed", field:
"change_in_flight" }
    ev = metrics.compareWindows(dep.service, before: dep.startedAt, window:
policy.window)
    if ev.regressionMargin < policy.rollbackMargin:       // thresholds
are policy, not prompt
        return { kind: "refuse", reason: "precondition_failed", field:
"evidence" }
    return { kind: "needs_approval", request: rollbackRequest(call, dep, ev)
}

```

Este bloco também é uma visão parcial do gate no Capítulo 5, com a pré-condição que falhou nomeada em `field`. Olhe os veredictos. O bloco nunca devolve `allow`, porque a política exige aprovação para essa ferramenta, seja qual for a evidência. Uma função que pudesse devolver `allow` aqui codificaria uma decisão que pertence a Robin. A divisão é a que este capítulo defendeu: o modelo propõe o diagnóstico, o código verifica os limiares e um humano aprova. O Capítulo 15 trata do que torna essa aprovação real em vez de cerimonial.

Trade-offs e custos

Uma fronteira tem um preço, e o preço é pago em lugares específicos.

Rigidez e falsas recusas. O código não interpreta. Um gate que recusa um reembolso porque uma linha já estava marcada como reembolsada também recusará o raro ticket em que essa marca estava errada. Cada recusa é um hand-off, e cada hand-off cai em Sam ou em um líder de suporte. Uma fronteira traçada de forma apertada demais manda para humanos um trabalho que o modelo poderia ter feito, e o primeiro sinal é uma fila, não um erro.

Mais código, e mais coisa a manter verdadeira. Conjuntos de escolhas, tabelas de política, funções de cálculo e testes do gate são software com responsáveis. Os limiares que há neles são decisões de negócio que mu-

dam, e o código e o negócio podem se afastar em silêncio. Alguém precisa ser responsável por cada número: Sam pelo teto de reembolso, Robin e a equipe de plataforma pelas margens de rollback, a equipe de segurança (Jordan) pelas questões sobre o que o gate precisa recusar. Se ninguém é responsável por um limiar, ele vira um limite que ninguém ajustou.

Uma fronteira codifica o hoje. Você a traça em torno do que o modelo faz mal agora. Os modelos mudam, e uma decisão que você moveu para o código porque o modelo era ruim nela pode mais tarde ser uma que o modelo trata bem. Movê-la de volta é uma decisão de design com suas próprias checagens, não uma troca de configuração, e uma mudança de modelo é um deploy e deve ser tratada como tal.

Latência e passos. Ler fatos, calcular e ler o estado de volta acrescentam chamadas a serviços, e uma recusa com feedback acrescenta uma chamada ao modelo. O gate acrescenta algumas leituras de serviço por proposta: isso é barato perto de uma chamada ao modelo, mas não é de graça, e cada serviço que ele lê precisa estar disponível quando o gate roda. Um gate que não consegue ler seus fatos precisa recusar ou fazer um hand-off, e esse comportamento tem de ser escolhido de propósito.

Quando não usar. Não construa uma fronteira em torno de uma decisão cujo resultado um humano lê e descarta, como um resumo-rascunho ou um ranking de runbooks candidatos. Não construa uma para investigação exploratória somente de leitura, em que o custo de uma resposta errada é um passo desperdiçado que um limite já restringe. Regras em código compensam seu custo quando a decisão é repetida, verificável e cara quando errada. Onde nada disso vale, um controle mais leve é melhor, e às vezes o controle certo é uma pessoa lendo a saída.

Teatro. Um esquema que toda proposta atravessa é uma caixa de seleção. Um limiar de política tão alto que nenhuma proposta o alcança, ou tão baixo que toda proposta precisa de aprovação e é aprovada em segundos, não protege nada. Meça com que frequência cada checagem recusa e o que acontece depois, porque uma checagem que nunca dispara e uma checagem que sempre dispara têm a mesma propriedade: não carregam informação.

Erros comuns

- **Deixar o modelo fazer aritmética e verificá-la com o modelo.** Uma segunda chamada ao modelo para verificar a primeira compartilha os pontos cegos da primeira e acrescenta custo. Calcule em código, ou recalcule em código e compare.
- **Validadores que consertam em silêncio.** Converter tipos, limitar um valor ao teto ou preencher uma moeda ausente transforma uma proposta recusada em uma aceita que ninguém propôs. Recuse, registre e deixe a proposta ser feita de novo.
- **Tomar identificadores da memória do modelo.** Um id de pedido digitado a partir da lembrança do modelo de um ticket anterior é um valor que nunca foi lido dos dados do cliente atual. Dê a ele uma lista do run atual e verifique a pertinência.
- **Feedback sem limite.** Devolver ao modelo toda recusa, com razões detalhadas, e deixá-lo tentar de novo indefinidamente cria um loop que sonda o limite. Limite as tentativas, envie códigos de razão e faça um hand-off quando elas acabarem.
- **Traçar a fronteira uma única vez.** Políticas, ferramentas e modelos mudam, e uma linha traçada para o comportamento do trimestre passado pode ficar no lugar errado. Revise o inventário de decisões quando uma ferramenta for adicionada, um modelo mudar ou um padrão de recusas se alterar.

Pontos-chave

- Uma fronteira do determinismo é uma linha, traçada por decisão, entre o que o modelo pode propor e o que o código precisa decidir, e o design é mais fácil de revisar quando você a traça de forma deliberada e a escreve.
- Pese primeiro a reversibilidade, depois a verificabilidade, a frequência, a tolerância e a explicabilidade; uma escrita irreversível ou um efeito colateral externo puxa uma decisão para o código mesmo quando o modelo costuma acertar.
- O modelo propõe e o código dispõe: toda proposta é analisada, conferida com um esquema, conferida com fatos que o próprio código leu e julgada pela política antes que um efeito comece.

- Estreite o que o modelo pode dizer com enums, listas de identificadores e templates, e trate um valor `other` que a maioria das propostas escolhe como sinal de que o conjunto precisa de trabalho.
- Dinheiro, datas e limiares são calculados pelo código; onde uma proposta traz um desses valores, o gate o recalcula e recusa uma divergência, e o design com menos valores a errar deixa o campo de fora.
- O gate é uma função de uma proposta, de fatos e de uma versão de política, então pode ser testado sem um modelo, e as recusas devolvidas ao modelo devem ser codificadas, poucas e limitadas.
- Refazer a chamada ao modelo é uma nova amostra e não uma reprodução, então registre a proposta, os fatos, a versão da política e a decisão, que juntos permitem fazer o replay do gate e responder se um efeito era permitido.

O Capítulo 5 volta-se para a própria proposta: como uma chamada de ferramenta é pedida, moldada e recebida, para que o que chega ao gate seja algo que o gate consiga verificar.

PARTE II

Ferramentas e autoridade

Capítulo 5 — Chamada de ferramentas

Imagine a Parcelport em uma manhã de segunda-feira. Um cliente escreve que uma encomenda está indo para um endereço antigo e pede que ele seja alterado. No protótipo, o loop do agente de suporte lê a saída do modelo, procura algo com o formato de um nome de ferramenta e um punhado de argumentos, e chama a função correspondente com o que quer que o punhado contenha. Se o nome não corresponde a nada, o loop pula o turno. Se falta um argumento, o código de ligação passa um valor vazio. Se a ferramenta devolve um registro de pedido, tudo volta para o prompt, inclusive a nota em texto livre que o cliente digitou ao fazer o pedido.

Suponha que, nesta segunda-feira, o modelo proponha `update_shipping_address` com o pedido certo e o novo endereço, mas sob um nome de campo que o código de ligação não reconhece. O campo de endereço chega vazio, o serviço aceita o valor vazio porque ninguém lhe disse para não aceitar, e o loop informa sucesso. Nada no design dizia como era uma chamada válida, então nada podia dizer que esta não era.

Este capítulo pertence às partes **Proposta** e **Efeito** do envelope de controle. Pelo lado da Proposta, ele responde à pergunta do que o modelo propôs e se isso é tratado como entrada não confiável até que se prove o contrário. Pelo lado do Efeito, responde como uma chamada aprovada chega ao mundo e o que volta. O assunto é a mecânica da chamada de ferramentas: como uma chamada é pedida, analisada, validada, executada, registrada e devolvida, e como as ferramentas são moldadas para que esse caminho seja curto e verificável.

O problema e por que ele é difícil

Uma ferramenta é a única maneira de um run tocar o mundo (Capítulo 1), então a chamada de ferramenta é o ponto em que o texto de um modelo se torna algo com consequências. O caminho entre esses dois pontos é lon-

go e tem mais juntas do que parece. Mostra-se ao modelo uma descrição das ferramentas disponíveis. Ele devolve um texto que deveria nomear uma e fornecer argumentos. Algo analisa esse texto, algo confere o resultado, algo o executa, algo anota que ele foi executado, e o resultado volta ao contexto para o passo seguinte. Cada junta é um lugar onde o design pode supor, em silêncio, que o modelo se comportou.

As falhas que vêm de um caminho frouxo são específicas. Uma proposta que não passa pelo parser, um campo ausente, um tipo errado ou um campo extra são F1 (saída malformada). Uma chamada bem formada a uma ferramenta que não serve ao ticket, ou com valores que não se ajustam ao pedido, é F2 (ferramenta incorreta ou argumentos incorretos). Uma escrita que teve sucesso em um sistema enquanto o passo seguinte falhava, com o run marcado como concluído, é F6 (falha parcial silenciosa). Um resultado de ferramenta que leva o texto de outra pessoa para o contexto é a porta de entrada de F4 (sequestro de instruções), que o Capítulo 16 desenvolve. E uma chamada que não deixou registro do que foi proposto, do que foi permitido e do que aconteceu é F8 (comportamento não observado).


A abordagem óbvia é descrever bem as ferramentas e confiar na saída. Uma boa descrição de fato reduz a taxa de propostas ruins, e escreveria boas descrições. Mas uma descrição é um pedido, e a proposta que a ignora é a que importa. O Capítulo 2 dá as razões pelas quais o modelo às vezes estará errado com plena confiança. Para a chamada de ferramentas, a consequência é simples: toda chamada precisa passar por um código que conhece o formato de uma chamada válida, e esse código não pode depender da cooperação do modelo.

Há uma segunda dificuldade, mais silenciosa. O caminho está cheio de pequenas decisões que parecem encanamento e na verdade são política. O que acontece com um nome de ferramenta desconhecido? Um campo ausente recebe valor padrão ou é recusado? Qual o tamanho máximo de um resultado? Um timeout significa que a chamada falhou, ou que ninguém sabe? Cada uma dessas perguntas é respondida por alguém, mesmo quando ninguém escolheu a resposta. No protótipo acima, as respostas foram “pular”, “usar o padrão” e “sucesso”. Nunca foram revisadas porque nunca foram escritas como decisões.

É por isso que esta é uma questão de engenharia. Só o código pode corrigir o que acontece quando a descrição não é seguida, e só o código pode garantir que toda chamada proposta tenha exatamente um resultado que seja ao mesmo tempo registrado e mostrado ao modelo.

O caminho da chamada de ferramenta

Organizaria o caminho em sete estações, nesta ordem: propor, analisar, validar, autorizar, executar, registrar e devolver. A primeira é do modelo. As demais pertencem ao orquestrador e ao gate, e nenhuma delas é probabilística. O diagrama abaixo mostra o caminho de uma chamada. Procure os lugares em que uma chamada pode sair mais cedo, todos terminando em uma recusa que volta ao contexto, e o único lugar em que a resposta é “desconhecido” e não “falhou”.



O caminho é o passo canônico do loop com o ramo da chamada de ferramenta aberto. Os nomes são os usados desde o Capítulo 1: `gate.check` devolve "allow", "refuse" ou "needs_approval", `suspend` entrega o run a um humano e `effect.apply` é a única função que muda alguma coisa. O que este capítulo acrescenta é o que acontece de um lado e do outro delas.

Propor e analisar

Mostra-se ao modelo uma lista de ferramentas, cada uma com nome, descrição e esquema de entrada, e ele devolve uma proposta. A forma como essa proposta é transportada é uma propriedade do provedor e do adaptador. Alguns provedores devolvem chamadas de ferramenta estruturadas em um campo próprio, outros devolvem texto do qual o adaptador precisa extrair uma chamada, e os formatos diferem e mudam. Manteria tudo isso dentro de um adaptador pequeno e faria da sua saída sempre a mesma proposta abstrata: `{ kind: "tool_call", tool: name, arguments: record }`. Nada a jusante deveria saber qual provedor a produziu, porque o design precisa se sustentar quando o modelo for trocado.

O parser tem uma só tarefa: transformar a saída bruta em uma proposta ou dizer que não consegue. Ele não adivinha.

```
function parseProposal(rawOutput, offeredTools):
  candidate = adapter.extract(rawOutput)           // provider-
  specific code lives only here
  if candidate is not a record with "tool" and "arguments":
    raise MalformedProposal(reason: "unparseable")
  if candidate.tool not in names(offeredTools):
    // unknown to Parcelport, or real but not offered to this run
    raise MalformedProposal(reason: "not_in_choice_set")
  if candidate.arguments is not a record:
    raise MalformedProposal(reason: "invalid_arguments")
  return { kind: "tool_call", tool: candidate.tool, arguments:
    candidate.arguments }
```

`parseProposal` é a cauda de `model.propose`; a função abstrata a esconde. Uma `MalformedProposal` se torna um veredicto `"refuse"` com o mesmo código de razão. O passo registra um trecho limitado da saída bruta (antes redigido com `redaction`, já que uma saída bruta pode conter tudo o que o ticket continha; o Capítulo 17 trata do `redaction`) e o modelo recebe um aviso curto. Dois pontos merecem atenção. O nome desconhecido é conferido com as ferramentas **oferecidas a este run**, não com todas as ferramentas que a Parcelport tem, de modo que uma ferramenta que o run nunca recebeu não pode ser alcançada apenas por ser nomeada. E o parser nunca conserta. Uma proposta com o nome da ferramenta em caixa errada, ou com os argumentos envoltos em uma camada extra, não é endireitada em silêncio. O Capítulo 4 defende a rigidez; o custo de uma recusa é uma chamada ao modelo, e o custo de um conserto adivinhado é uma decisão que ninguém revisa.

Uma palavra sobre a contagem. Um nome que não corresponde a nenhuma ferramenta é uma falha estrutural, e o contaria como F1. Um nome que corresponde a uma ferramenta real que o run não recebeu está mais próximo de F2, porque a proposta está bem formada e a escolha é que está errada. A distinção importa para o registro, já que as duas apontam correções diferentes: a primeira, para a forma como as ferramentas são descritas; a segunda, para a forma como o conjunto oferecido é construído.

Validar contra o contrato

A validação confere os argumentos com o esquema de entrada da ferramenta: campos obrigatórios presentes, nenhum campo desconhecido, valores do tipo certo e dentro da enumeração declarada. Ela vive dentro de `gate.check`, antes das checagens que leem fatos, porque uma chamada que não está bem formada não pode ser avaliada contra coisa alguma.

```
function gate.check(run, proposal):                                // tool-call
branch, in the order the checks run
    contract = contractFor(proposal.tool)
    if not validSchema(contract.inputSchema, proposal.arguments):
        return { kind: "refuse", reason: "invalid_arguments" }
    if not inChoiceSet(run, proposal):                             //
identifiers were offered to this run (Chapter 4)
        return { kind: "refuse", reason: "not_in_choice_set" }
    if not argumentsTieToRunResults(run, proposal, contract):    // ids come
from the run (Chapter 2)
        return { kind: "refuse", reason: "ungrounded_arguments" }
    if argumentFromUntrustedContent(run, proposal):              // taint
(Chapter 16)
        return { kind: "refuse", reason: "argument_origin" }
    facts = readFacts(run, contract)                              // from services,
never from the proposal
    if facts.unavailable:                                         // cannot verify:
refuse, retryable
        return { kind: "refuse", reason: "upstream_unavailable" }
    if not permitted(run.principal, contract, facts):            // includes order
ownership (Chapter 7)
        return { kind: "refuse", reason: "not_permitted" }
    if not preconditionsHold(contract, facts, proposal.arguments):
        return { kind: "refuse", reason: "precondition_failed" }
    if outcomeStillUnknown(contract, facts, proposal):          // writes only
(Chapter 6)
        return { kind: "refuse", reason: "outcome_unknown" }
    claim = checkClaims(run, proposal, contract)                 // calls that
reach a person (Chapter 2)
    if claim.failed:
        return { kind: "refuse", reason: claim.reason }        //
ungrounded_claim, mismatch or omission
    if requiresApproval(contract, facts, proposal.arguments):
        return { kind: "needs_approval", request: buildRequest(run,
proposal) }
    return { kind: "allow", call: bindCall(run, proposal, contract) } //
runtime adds key and call id; the tool gateway adds the credential
```

Toda ferramenta passa por esta função, inclusive as de leitura. Para uma leitura, o gate é enxuto: o esquema, o allowlist (`not_in_choice_set`, vinda do parser para o nome da ferramenta e da checagem do conjunto de escolhas para os identificadores) e a checagem de titularidade dentro de `permitted` fazem o trabalho, e não há aprovação nem chave de idempotência. Um contrato de leitura ainda pode trazer pré-condições.

A ordem é uma escolha de design. O esquema primeiro, porque não precisa de fatos. A permissão antes das pré-condições, porque uma checagem de pré-condição lê dados, e não leria um pedido para um principal que não pode tocá-lo. A vinculação de argumentos e a checagem de taint vêm logo depois das checagens de esquema e de conjunto de escolhas porque leem apenas o run, não um serviço. A aprovação por último, porque pedir a um humano que avalie uma chamada que seria recusada de qualquer forma desperdiça o único recurso escasso do caminho. O bloco é um esboço: o contrato que fornece `inputSchema` e `preconditions` é assunto do Capítulo 6, o teste de permissão é do Capítulo 7 e a requisição de aprovação é do Capítulo 15. O que cabe aqui é a posição de cada checagem e o fato de que `bindCall` é onde o runtime anexa o que o modelo nunca fornece: a chave de idempotência e um identificador de chamada de autoria do próprio orquestrador, com a credencial para esta única chamada a ser fornecida pelo gateway de ferramentas quando o efeito rodar. As razões de veredicto usadas ao longo do livro estão listadas no Apêndice; um run bloqueado (Capítulo 16) carrega `run_locked` como razão, em geral em `needs_approval` e, para ferramentas cuja regra assim determina, em uma recusa. Um run planejado (Capítulo 12) acrescenta uma checagem de escopo da tarefa e de classe de plano logo depois do teste de permissão, recusando com `outside_task_scope` ou `off_plan`.

Autorizar, executar, registrar, devolver

Depois do gate, a cauda de execução precisa estar correta sob falha. A intenção é registrada antes do efeito, para que uma queda entre os dois ainda deixe um rastro. Um timeout não é uma falha. O efeito e seu resultado são registrados depois, e o que volta ao modelo é uma observação moldada, não o resultado bruto.

```
function executeCall(run, call):
    record(run, "intent", call)                // before the
    effect, so a crash leaves evidence
    try:
        result = effect.apply(run, call)        // orchestrator
    starts it; the tool gateway adds the credential,
                                                // calls the
    service and returns the result; deadline from the contract
    on Timeout:
        result = { status: "outcome_unknown" } // not "failed":
    see below
        scheduleStatusQuery(run, call)        // the status
    query resolves it
    on UpstreamError as e:
        result = { status: "failed", code: e.code, retryable: e.retryable }
    record(run, "effect", result)              // a second
    system; this write can fail too
    return addObservation(run, shapeObservation(call, result))
```

O run store e o alvo do efeito são sistemas separados, e nenhuma transação única cobre os dois. Por isso o bloco mostra uma ordem, não uma garantia. Se o processo morre depois de `effect.apply` e antes do segundo `record`, o registro guarda uma intenção sem resultado. O que fecha essa lacuna é um sweep de recuperação que encontra essas intenções e pergunta ao serviço de destino o que aconteceu; sem ele, a lacuna é F6. Para uma leitura, esse sweep não tem o que fazer e a intenção pode ser dispensada, então o padrão compensa seu custo para escritas e efeitos colaterais externos.

Tratando uma proposta inválida

Uma recusa por proposta malformada volta ao modelo, e o modelo propõe de novo. O Capítulo 4 traz o loop para isso e seu limite: um número pequeno de repropostas, contadas contra o run, entregando o run a um humano quando acabam. Não vou repetir. O que este capítulo acrescenta é como decidir quais recusas merecem um turno de correção.

O que deu errado	Classe	Turno de correção?	Por quê
A saída não tem nenhuma chamada extraível	F1	Sim, uma vez	É barato, e o aviso não carrega informação que valha a pena reter

O que deu errado	Classe	Turno de correção?	Por quê
O nome da ferramenta não corresponde a nada	F1	Sim	O aviso pode listar os nomes das ferramentas oferecidas
Ferramenta real, mas não oferecida a este run	F2	Sim, e contar	A proposta pode vir de uma lista de ferramentas que difere do conjunto oferecido
Campo ausente, campo extra, tipo errado	F1	Sim	O aviso nomeia os campos, e a correção é mecânica
Formato válido, pedido não está neste ticket	F2	Com cuidado	O aviso não deve entregar os fatos que melhorariam o próximo palpite
Pré-condição falhou ou não permitido	F2 (um F7 que o gate impediu)	Raramente	Uma segunda tentativa é um novo pedido pelo mesmo efeito; um hand-off ou uma explicação simples costuma ser a resposta
Acima do limite	não é uma recusa	Não	O veredicto é <code>"needs_approval"</code> , e um humano decide

O padrão da tabela é que um turno de correção serve para falhas cuja correção está no aviso. Se o modelo é informado de que `order_id` está ausente, ele pode fornecê-lo. Se é informado de que o pedido não pertence a este cliente, o próximo passo útil não é outro palpite de pedido. O primeiro tipo vale uma ou duas tentativas. O segundo tipo pertence ao estado do mundo e à política, e a resposta certa costuma ser mudar o que o agente diz ao cliente ou fazer o hand-off.

Cada turno de correção é uma chamada ao modelo, portanto carrega custo e latência, e um run que gasta sua cota com saída malformada caminha para F9 (explosão de custo ou latência). Acompanharia a taxa de turnos de correção por ferramenta como uma medida do design da ferramenta, e não como um fato sobre o modelo. Uma ferramenta cujo esquema provoca muitas correções costuma ser uma ferramenta cujo nome ou cujos argumentos são confusos, e a correção está na ferramenta.

Quanto ao conserto, adoto uma linha mais estrita do que muitos frameworks. Normalizar um espaço no fim ou um valor de enum em maiúsculas parece inofensivo. Mas cada normalização é uma decisão tomada em código que ninguém lê, e amplia o que o gate aceita sem que ninguém tenha aprovado o conjunto ampliado. Se uma grafia alternativa vale a pena ser aceita, ponha-a no esquema, onde a revisão a vê e os testes a cobrem.

Projetando o conjunto de ferramentas

As ferramentas fazem parte do sistema de controle, e o design delas decide de quantas maneiras uma proposta pode dar errado. Quatro escolhas carregam a maior parte do peso.

Poucas ferramentas, cada uma com uma tarefa

O agente de suporte tem sete ferramentas (`lookup_order`, `get_customer_profile`, `search_docs`, `update_shipping_address`, `issue_refund`, `send_customer_reply` e `escalate_to_human`), e resistiria a adicionar uma oitava sem motivo. Cada ferramenta no conjunto oferecido é contexto que o modelo lê em todo passo, uma escolha que ele pode errar e um contrato que alguém precisa escrever, testar e manter atualizado. Antes de adicionar uma ferramenta, perguntaria se a capacidade é um efeito diferente, com pré-condições diferentes, ou apenas uma variação de um efeito existente. Variações pertencem aos argumentos, com uma enumeração fechada. Efeitos diferentes pertencem a ferramentas separadas.

O foco importa tanto quanto a quantidade. Uma ferramenta faz uma coisa, e seu nome diz qual. O modelo escolhe entre ferramentas usando seus nomes e descrições, então um nome como `update_shipping_address` carrega mais do que `modify_order`, e se liga diretamente a uma única classe de efeito, um único conjunto de pré-condições e uma única permissão.

A ferramenta que faz qualquer coisa

O padrão a evitar é a ferramenta ampla. Considere uma ferramenta ilustrativa `manage_order` que recebe uma `action` (`change_address`, `refund`, `cancel`, `reship`) e um registro livre `details`. É tentadora, porque o modelo vê uma ferramenta e a equipe escreve uma integração. Os custos aparecem no gate.

- Uma ferramenta tem uma classe de efeito, então assume a pior de suas ações: escrita irreversível. Toda chamada a ela, inclusive as inofensivas, passa pelo gate como se movesse dinheiro.
- O esquema de entrada de `details` não pode ser rígido, porque seu formato depende da ação. A rigidez que torna F1 barato de pegar desaparece.
- As pré-condições dependem da ação, então o gate precisa conter um segundo despacho escondido dentro da ferramenta. O contrato deixa de descrever o que a ferramenta faz.
- As permissões não podem ser estreitadas por ação. Uma credencial que permite `manage_order` permite tudo.
- Registros e traces ficam mais grosseiros. “O agente chamou `manage_order`” diz quase nada; “o agente chamou `issue_refund`” diz o que aconteceu.

Nada disso impede a ferramenta de funcionar. Faz com que a ferramenta que funciona seja impossível de revisar. O mesmo custo se aplica a uma saída de emergência, como uma ferramenta genérica de consulta ou de shell oferecida ao agente de suporte: quanto mais uma ferramenta pode fazer, menos um gate pode dizer sobre uma chamada específica.

Leituras e escritas são ferramentas diferentes

Não poria uma leitura e uma escrita na mesma ferramenta, e as manteria separadas mesmo quando tocam o mesmo serviço. `lookup_order` lê do `orders-service` e `update_shipping_address` escreve no `shipping-service`; a primeira não muda nada e a segunda muda o estado e só está disponível antes que a encomenda esteja com uma transportadora. Ferramentas separadas podem receber classes de efeito diferentes, permissões diferentes (um escopo de leitura e um de escrita), timeouts diferentes e regras de retry diferentes. Uma leitura pode rodar em paralelo e ser repetida à vontade; uma escrita não. Um design que as une perde tudo isso exatamente onde importa.

A separação se paga de uma segunda maneira. Se o conjunto de ferramentas oferecido a um run muda conforme o run avança, por exemplo, as ferramentas de escrita só aparecem depois que o pedido foi consultado e confirmado como pertencente ao cliente do ticket, o modelo tem menos esco-

lhas erradas à frente. Isso é um estreitamento do conjunto de escolhas no sentido do Capítulo 4, e é barato de construir quando as ferramentas já estão separadas por efeito.

Menos argumentos, e nenhum que carregue autoridade

Todo argumento que o modelo fornece é um lugar para F2. Por isso removeria os que o runtime já conhece. O modelo não fornece um identificador de cliente, um identificador de ticket nem a identidade de quem chama: isso vem do run, e o gate confere o pedido contra eles. A lista de argumentos encolhe para o que só o modelo pode fornecer, como o pedido e o novo endereço, e um campo que permitiria a uma proposta nomear um principal diferente não existe. O Capítulo 7 desenvolve por que isso importa (um campo que nomeia a autoridade de quem usar é um convite a um confused deputy), e o Capítulo 3 nomeia a regra relacionada de que os identificadores de pedido nos argumentos devem vir de resultados de ferramentas e não do texto de mensagens (o Capítulo 9 a constrói).

As descrições merecem uma nota à parte. Uma boa descrição diz o que a ferramenta faz, o que ela exige e quando não usá-la, e vale a pena escrevê-la. Mas “só chame isto depois de consultar o pedido” é um pedido. Se a ordem das chamadas importa, isso é uma pré-condição no contrato, imposta pelo gate. A descrição pode mencioná-la para que o modelo proponha com bom senso; o controle é a checagem.

Uma ferramenta de leitura, na forma de contrato usada ao longo do livro, mostra o quão pouco há em uma boa ferramenta pequena. O Capítulo 6 desenvolve a notação campo a campo e constrói as ferramentas de escrita; esta está aqui para mostrar o formato.

```

tool lookup_order
  description: "Read one order: its lines and delivery status. Changes
nothing."
  input schema:                                // fields the model supplies
    type: object, additionalProperties: false
    required: [order_id]
    properties:
      order_id: { type: string }
  effect class: read
  preconditions:                                // checked by the gate, not the model
    - order belongs to the customer of this run // checked by
checkAuthority (Chapter 7),
                                                // returns not_permitted
  idempotency: // not applicable: a read changes nothing, so there is no key
  permissions: scope "orders:read", delegated for this ticket's customer
  timeouts: call 3s, deadline 8s // illustrative
  error shape: { code, message, retryable, details }
    // code in [invalid_arguments, precondition_failed, not_permitted,
    //   upstream_unavailable]

```

Até uma leitura tem uma pré-condição de titularidade. Consultar o pedido do cliente errado não é um engano inofensivo; põe os dados PII desse cliente no contexto deste run, e de lá eles podem chegar a uma resposta.

O que volta ao contexto

Quando a chamada termina, o resultado volta ao modelo como uma observação, e esta é a metade da chamada de ferramentas que a maioria dos designs negligencia. O resultado é a entrada do passo seguinte. Seu tamanho, seu formato, seu idioma e sua confiabilidade decidem como será a próxima proposta.

Tamanho

Um resultado de ferramenta que pode ter qualquer tamanho acabará grande o bastante para expulsar algo de que o modelo precisava, para encarecer cada passo posterior e para carregar mais texto de outras pessoas do que a tarefa exigia. Daria a cada ferramenta um limite de saída em seu adaptador, devolveria apenas os campos que a ferramenta deve devolver e marcaria o truncamento de forma explícita. Um resultado cortado em silêncio é um resultado que parece completo, e o modelo responderá como se fosse. O Capítulo 9 é responsável pelo orçamento do contexto como um todo; aqui a regra é que a ferramenta limita a própria saída.

Formato

A mesma função molda toda observação, para que o modelo e o registro vejam um único formato.

```
function shapeObservation(call, result):
  body = project(result, outputFields(call.tool))      // only the
fields the tool is meant to return
  body = redact(body, sensitiveFields(call.tool))      // Chapter 17
  if size(body) > outputLimit(call.tool):              // say, 2,000
characters
    body = truncate(body, outputLimit(call.tool))
    body.truncated = true                             // the model is
told, in the observation
  return { call_id: call.id, tool: call.tool, status: result.status,
          origin: "tool_result", trust: "untrusted", body: body }
```

Há três coisas neste bloco de propósito. A projeção significa que um serviço que adiciona um campo amanhã não muda o que o modelo vê até que alguém o escolha. O redaction acontece antes de a observação entrar no contexto e antes de o registro ser escrito, de modo que os dados PII são removidos mais cedo do que seriam no log. E os rótulos `origin` e `trust` são proveniência (Capítulo 9): o montador de contexto consegue distinguir dados de ferramenta de instruções, algo de que um controle posterior depende.

O registro deve guardar tanto o digest do resultado bruto quanto a observação moldada. Se o on-call precisa reconstruir o que o modelo viu no passo 6, a observação moldada é a resposta, e sem ela F8 é um dos desfechos prováveis.

Linguagem dos erros

Um erro é informação para a próxima proposta. Seu texto é redigido pela Parcelport e escolhido de uma lista fixa, nunca repassado de um serviço a montante, e carrega `retryable` com honestidade. O Capítulo 6 dá o formato do erro e o Capítulo 4 a cautela sobre recusas que se transformam em sondas.

```
observation { call_id: "call-0007", tool: "update_shipping_address",
              status: "refused", origin: "gate", trust: "system",
              body: { code: "precondition_failed", retryable: false,
                    message: "The parcel has been handed to a carrier; the
address can no longer be changed." } }
```

A recusa vem do gate e é marcada como tal, uma origem diferente da dos dados de uma ferramenta. Uma recusa como essa também é um bom momento para olhar o conjunto de ferramentas: o modelo só consegue reagir com bom senso explicando a situação ou chamando `escalate_to_human`. Se nenhuma das duas estiver disponível, o design colocou o modelo num beco, e o beco é problema do design.

O resultado também é entrada não confiável

Tudo na observação que foi escrito por outra pessoa é dado de uma fonte que a Parcelport não controla. Um registro de pedido pode trazer uma nota digitada por um cliente. O status de uma transportadora pode trazer uma observação. Uma página devolvida por `search_docs` pode conter texto editado por alguém que não é o seu leitor. Nada disso foi escrito para ser lido como instrução, e parte disso vai parecer uma. É por essa porta que F4 entra; o Capítulo 16 é a sua casa, e o Capítulo 8 trata do mesmo problema para ferramentas servidas por terceiros.

No nível da chamada de ferramentas, os controles são modestos e sobretudo estruturais. Devolva apenas os campos de que a tarefa precisa, para que campos de texto livre apareçam só quando necessários. Rotule toda observação com sua origem. Mantenha a observação fora de qualquer coisa que funcione como política. E nunca deixe um valor vindo de texto não confiável conduzir uma chamada sensível sem uma checagem, que é a ideia de taint. O gate não lê o raciocínio do modelo sobre por que uma chamada se justifica, e não lê o conteúdo de uma observação para decidir se confia nela. Ele confere a chamada com o contrato e os fatos. É assim que o mesmo design se sustenta no dia em que uma nota em um pedido contém algo que parece uma ordem.

Nota: Rotular um campo como não confiável não impede que o modelo seja influenciado por ele. O rótulo serve ao código de controle, que pode usá-lo para decidir o que pode fluir para onde. A proteção é o gate diante de todo efeito, que se mantém seja qual for a influência que o modelo sofreu.

Várias chamadas, chamadas lentas e sucesso parcial

Mais de uma chamada por vez

Alguns provedores deixam o modelo devolver várias chamadas de ferramenta em uma resposta, outros devolvem uma por vez. Se o seu faz isso é uma propriedade do adaptador, e o design deve funcionar nos dois casos. Quando há várias, usaria duas regras. As leituras podem rodar de forma concorrente, já que não mudam nada e duas leituras não dependem dos efeitos colaterais uma da outra. As escritas não rodam de forma concorrente, e permitiria no máximo uma escrita por passo. A razão é que uma chamada posterior do mesmo lote foi proposta contra um contexto que a primeira escrita está prestes a mudar. O endereço foi lido no início; uma segunda chamada que depende dele é o padrão F5 (loop descontrolado ou contexto obsoleto) em miniatura.

Para o agente de ops isso é natural. `query_logs`, `get_metrics` e `get_trace` para a mesma janela de tempo podem rodar juntas, e os resultados saem melhores por isso. `request_rollback` nunca divide um passo com mais nada, porque precisa de aprovação e o que vem depois depende do seu resultado.

```

function runBatch(run, proposals):                                // several calls
proposed in one response
    ordered = inProposalOrder(proposals)
    firstWrite = first([p in ordered if isWrite(p.tool)])
    toRun = [p in ordered if not isWrite(p.tool) or p == firstWrite]
    outcomes = runConcurrentlyUntil(stepDeadline(run), toRun, handleOne) //
handleOne: gate, intent, effect
    for each p in ordered:                                       // one observation
per proposed call, in order
    if p not in toRun:
        addObservation(run, deferred(p, "one_write_per_step")) //
answered, not dropped
    else if outcomes[p] is missing and isWrite(p.tool):
        record(run, "effect", { call: p.id, status: "outcome_unknown" })
        scheduleStatusQuery(run, p)                             // the write may
have been applied
        addObservation(run, outcomeUnknown(p))
    else if outcomes[p] is missing:
        addObservation(run, timedOut(p))                         // a read:
retryable
    else:
        addObservation(run, outcomes[p])                         // also for
needs_approval: keeps one observation per call in a batch; runStep alone
only suspends
        record(run, "batch", summarize(ordered, outcomes))
        if any outcome is "needs_approval": suspend(run,
approvalRequestOf(outcomes))

```

A invariante deste bloco é que toda chamada proposta recebe exatamente uma observação. Uma chamada descartada sem resposta deixa no contexto uma proposta sem resultado, e a proposta seguinte é construída sobre um quadro com um buraco. Uma escrita adiada é uma recusa como qualquer outra, e o modelo pode propô-la de novo no passo seguinte, contra o contexto que agora inclui o resultado da primeira escrita. Se a única escrita precisa de aprovação, `suspend` roda depois que as leituras concorrentes retornam, como mostra a última linha do bloco, para que o passo não espere pelo humano com as leituras ainda abertas. Uma escrita ainda em andamento quando o deadline do passo vence não é uma leitura com timeout: recebe o resultado desconhecido, um registro de efeito e uma consulta de status. Por essa razão, o deadline do passo nunca pode ser menor que o deadline do contrato de uma escrita.

Os custos são reais. Serializar as escritas significa que um run com duas escritas independentes leva dois passos, e uma equipe que mede passos por ticket verá isso. Aceito esse custo, porque a alternativa é raciocinar sobre efeitos intercalados em estado compartilhado.

Timeouts

Há três relógios em um caminho como este. Cada chamada tem seu próprio timeout, definido no contrato. O passo tem um deadline, para que um lote de leituras concorrentes não possa manter o passo aberto até a mais lenta. E o run tem seus próprios limites (Capítulo 13). Os números são ilustrativos: digamos, 3 segundos para uma chamada de leitura e 10 para uma de escrita, com um deadline de passo de 30. São propriedades dos seus serviços e devem ser ajustados observando-os.

Um timeout significa coisas diferentes para classes de efeito diferentes. Para uma leitura, um timeout é uma falha que admite retry, e o Capítulo 14 trata de quantos retries ela merece. Para uma escrita ou um efeito colateral externo, ele não é nada disso.

Aviso: Um timeout em uma escrita não é uma falha; é um resultado desconhecido. O serviço pode ter agido, e repetir pode agir duas vezes. Trate o resultado como desconhecido, consulte o serviço sobre o status daquela chamada e faça um retry apenas diante de uma resposta. A chave de idempotência (Capítulo 6) faz uma repetição devolver o primeiro resultado, mas é a consulta de status que diz em qual dos dois mundos você está.


A observação que o modelo recebe nesse caso diz que o resultado é desconhecido e que o status está sendo verificado. Ela não diz “falhou”, porque um modelo informado de que um reembolso falhou pode propô-lo de novo. O código `outcome_unknown` está no contrato `issue_refund` por essa razão.

Sucesso parcial

O sucesso parcial chega em três escalas, e cada uma pede uma resposta própria. Dentro de um lote, uma de três leituras dá timeout. Os dois resultados retornam e o terceiro é informado como timeout, como faz o bloco acima; o agente não prossegue como se o resultado ausente estivesse vazio. Dentro de uma ferramenta, uma chamada que toca dois sistemas pode ter sucesso em um; o resultado da ferramenta precisa dizer isso em um

campo, e o contrato declara quais partes podem falhar separadamente. Entre passos, um reembolso pode estar registrado no `payments-service` e o `send_customer_reply` seguinte pode dar timeout.

O último caso é o clássico F6, e a resposta do design é tornar a lacuna visível e limitada. O run não é marcado como concluído enquanto qualquer chamada tiver resultado desconhecido. A ordem das escritas é escolhida de forma deliberada (primeiro o dinheiro, depois a mensagem que se refere a ele, já que uma resposta que promete um reembolso que não aconteceu é pior que um reembolso com resposta atrasada), cada uma é registrada como intenção e como efeito, e o estado de cada chamada fica no run store (Capítulo 10). O diagrama mostra os estados por que uma única chamada passa. Olhe `OutcomeUnknown`: ele se resolve por uma consulta de status, e se a consulta não consegue responder, a chamada volta ao modelo ainda rotulada como desconhecida, nunca renomeada como falha.



Uma chamada que permanece sem resolução termina em um hand-off, não em silêncio: uma pessoa olha, e um job de reconciliação (capítulos 10 e 20) pega os casos que não vieram à tona no run. É também por isso que

contaria um run encerrado com chamadas sem resolução como um sinal de nível de incidente e não como uma estatística.

Trade-offs e custos

Cada estação do caminho custa alguma coisa, e alguns custos são pagos por pessoas.

O parser e o validador estritos custam chamadas ao modelo. Cada proposta recusada é uma viagem de ida e volta com sua latência e seu gasto, e uma equipe que aperta os esquemas verá os turnos de correção subirem antes de ver menos chamadas ruins chegarem ao gate. O benefício é que o gate vê uma estrutura que consegue verificar. Acompanhe a taxa de correção por ferramenta como um sinal de qualidade da ferramenta, e revise as descrições quando ela estiver alta.

Registrar a intenção antes de cada escrita acrescenta uma escrita ao run store e um sweep de recuperação a operar. Para escritas e efeitos colaterais externos, acho que vale a pena. Para leituras é sobrecarga, e dispensaria ali o registro de intenção e manteria o registro de efeito. O sweep é um job de que alguém é responsável e pelo qual alguém recebe um page, e precisa de um runbook. Um sweep que ninguém monitora é teatro.

Separar ferramentas aumenta a contagem delas, o que custa contexto e precisão de seleção, enquanto uni-las reduz a contagem e custa ao gate sua alavanca. Não sei qual é o número certo para o seu agente; depende de quão diferentes são os seus efeitos, e eis como saber: se duas ações precisariam de pré-condições, permissões ou timeouts diferentes, são duas ferramentas.

Truncar e projetar resultados reduz custo e exposição, e também remove informação que o modelo poderia ter usado. Algumas tarefas realmente precisam da nota longa ou do registro completo. Faça disso uma decisão por ferramenta e por campo, com uma razão registrada, e não um acidente do que quer que o serviço devolva.

Serializar escritas, tratar timeouts como resultados desconhecidos e executar consultas de status acrescentam passos, latência e código. Onde isso não compensa: um agente somente de leitura, um protótipo cujas ferramentas não podem mudar nada e uma tarefa em que uma escrita errada é

barata de desfazer e visível de imediato. Mesmo nesses casos, manteria o parser e a checagem de esquema, porque custam quase nada, e anotaria quais controles foram dispensados e por quê, para que a decisão fique visível quando o agente ganhar sua primeira ferramenta de escrita.

Erros comuns

- **Tratar o nome da ferramenta como confiável.** É tentador porque o nome veio de um modelo a quem se mostrou a lista. Confira o nome com o conjunto oferecido a este run e recuse qualquer outro.
- **Usar valor padrão para argumentos ausentes.** É tentador porque a chamada então “simplesmente funciona”. Um valor padrão transforma F1 em F2; recuse e deixe o esquema declarar qualquer padrão.
- **Repassar o texto de erro do upstream.** É tentador porque a mensagem do upstream já está escrita e detalhada. Ela pode carregar detalhes internos e texto não confiável; mapeie os erros para mensagens codificadas que a Parcelport escreveu.
- **Devolver registros inteiros.** É tentador porque a ferramenta então não exige reflexão por tarefa. Projete para os campos de que a tarefa precisa e marque o truncamento.
- **Ler um timeout como falha em uma escrita.** É tentador porque um timeout parece uma falha e um retry parece seguro. Isso produz o segundo reembolso; trate-o como um resultado desconhecido e consulte o status.
- **Deixar leituras e escritas dividirem uma ferramenta.** É tentador porque uma ferramenta significa uma lista mais curta. A ferramenta assume a pior classe de efeito; separe por efeito.
- **Descartar uma chamada proposta sem resposta.** É tentador porque uma chamada pulada parece não custar nada. Toda chamada proposta recebe exatamente uma observação, inclusive as adiadas.
- **Escrever a ordem das chamadas em uma descrição.** É tentador porque é uma mudança de uma linha e quase sempre funciona. Isso reduz a taxa de chamadas fora de ordem e não as impede; faça disso uma pré-condição.
- **Deixar o modelo fornecer a identidade.** É tentador porque a ferramenta precisa de um cliente e o modelo tem um no contexto. Um ar-

gumento `customer_id` torna a proposta autoautorizável; tome a identidade do run.

Pontos-chave

- A chamada de ferramentas é o caminho por onde uma proposta se torna um efeito, e suas estações (propor, analisar, validar, autorizar, executar, registrar, devolver) são código determinístico em todo lugar, exceto na primeira.
- Analise e valide com rigor e nunca conserte em silêncio; um nome desconhecido é conferido com as ferramentas oferecidas a este run, e uma recusa custa uma chamada ao modelo, o que é mais barato do que um palpite que ninguém revisa.
- Um turno de correção vale a pena para falhas cuja correção está no aviso, e não para recusas em que o aviso entregaria ao modelo os fatos para sondar um limite.
- Prefira poucas ferramentas com um efeito cada, mantenha leituras e escritas separadas e remova dos argumentos tudo o que o runtime já sabe, especialmente a identidade.
- A observação é a entrada do passo seguinte: projete-a, limite-a, marque o truncamento, escreva os erros nas palavras da própria Parcelport e rotule sua origem, porque tudo nela que outra pessoa escreveu é dado não confiável.
- As leituras podem rodar juntas, mas permita uma escrita por passo, dê a toda chamada proposta exatamente uma observação e trate um timeout em uma escrita como um resultado desconhecido a ser resolvido por uma consulta de status.
- Registre a intenção antes de um efeito e o resultado depois dele, e execute um sweep de intenções sem resultado, já que não há transação entre o run store e o serviço.

O Capítulo 6 trata daquilo contra o que as estações de validação e de gate conferem: o contrato de ferramenta, que registra por escrito o esquema, as pré-condições, a classe de efeito, a chave de idempotência e o formato de erro que este capítulo vem invocando.

Capítulo 6 — Contratos de ferramentas

Pense na Parcelport numa tarde tranquila no `payments-service`. Um cliente escreve que uma encomenda chegou danificada, e o agente de suporte propõe um reembolso. A ferramenta por trás dele é descrita por uma frase (“Refunds an order”) e por um esquema com um id de pedido, um valor e uma moeda. A chamada sai, o `payments-service` aplica o reembolso, e a resposta nunca volta. O orquestrador vê um timeout.

O timeout chega ao contexto como uma observação. No passo seguinte, o modelo propõe o reembolso de novo, com o valor arredondado e outro motivo. O esquema aceita as duas propostas, já que ambas são bem formadas. O prompt diz “refund an order only once”, a descrição da ferramenta diz o mesmo, e nenhum código lê nenhuma das duas frases. Suponha que o `payments-service` aplique também a segunda chamada. Ninguém escreveu uma linha ruim; a ferramenta nunca disse nada sobre si mesma que o código pudesse verificar.

Este capítulo pertence à parte **Gate** do envelope de controle, com um pé em **Efeito**. Do Gate, ele responde à pergunta “esta proposta pode produzir efeito, para este principal, agora?”. De Efeito, responde “como uma ação aprovada chega ao mundo, o que a limita e o que pode desfazê-la?”. A resposta para as duas é o mesmo documento: um contrato de ferramenta que diz o que a chamada pode fazer, sob quais condições, com que frequência e o que volta quando ela não funciona. Assim, a pergunta deste capítulo é o que uma ferramenta teria de dizer sobre si mesma, numa forma que o código possa verificar, para que o segundo reembolso nunca chegue ao dinheiro.

O problema e por que ele é difícil

Um esquema responde a uma pergunta: esta é uma lista de argumentos bem formada? Essa é a pergunta por trás de F1 (saída malformada), e ela importa. Mas uma proposta de reembolso pode coincidir exatamente com o esquema e ainda assim ser F2 (ferramenta incorreta ou argumentos incorretos): um pedido que pertence a outro cliente, um reembolso acima do que resta a reembolsar, uma moeda diferente da do pagamento. Pode ser F7 (efeito não autorizado) quando o valor está acima de `refund_ceiling` e nenhuma pessoa o aprovou. E pode ser F6 (falha parcial silenciosa) quando um retry produz um segundo efeito e o registro mostra um.

Nada disso é visível na forma dos argumentos. Tudo depende de fatos que a proposta não pode carregar: quem é o cliente deste run, o que o `payments-service` guarda, se uma chamada anterior com a mesma intenção ainda está sem resolução. Um esquema descreve valores. Um contrato descreve a chamada dentro do seu mundo.

A correção óbvia é pôr as regras na descrição. “Never refund more than the order total. Only refund captured payments. Do not call twice.” O apelo é real, já que a descrição reduz a taxa de propostas ruins, mas uma frase ali é um pedido, não um controle. Toda regra que valha a pena escrever ali também precisa existir como código que roda depois que o modelo respondeu.

A segunda correção óbvia é deixar a ferramenta impor tudo. As ferramentas devem se defender, e o serviço proprietário é a autoridade final sobre o próprio estado. Mas um serviço vê uma chamada por vez. Ele não sabe que esta chamada é a terceira proposta de um run, que o ticket pertence a um cliente diferente do proprietário do pedido, ou que o resultado da chamada anterior ainda é desconhecido. O gate sabe, porque fica onde o run, o principal e os fatos se encontram.


É por isso que esta é uma questão de engenharia, e não de prompt. O contrato precisa ser escrito uma vez, numa forma que o gate, o gateway de ferramentas, o orquestrador e o registro possam ler, e testado como qualquer outra interface. O restante do capítulo constrói essa forma.

O que um contrato contém

Um **contrato de ferramenta** é a descrição escrita e verificável por máquina de uma ferramenta. Ele tem nove campos, sempre na mesma ordem, e a notação é a usada ao longo deste livro.

Campo	Lido por	O que controla
name, description	o modelo, os revisores	Quais propostas o modelo faz; uma dica, nunca uma verificação
input schema	o modelo e o gate	A forma dos argumentos que o modelo fornece (F1)
effect class	o gate, a política, o orquestrador	O conjunto mínimo de controles da chamada
preconditions	o gate	Se o mundo permite esta chamada agora (F2, F7)
idempotency	o orquestrador, a ferramenta	Que uma chamada repetida age uma única vez (F6)
permissions	o gate, o gateway de ferramentas	O escopo e o principal sob os quais a chamada roda
timeouts	o orquestrador, o gateway de ferramentas	Quando parar de esperar e o que fazer então
error shape	a ferramenta, o gate, o orquestrador	O que volta e em qual vocabulário fechado

A tabela tem oito linhas porque `name` e `description` dividem uma; na notação, são campos separados. O diagrama abaixo mostra quem consome o quê. Observe como pouco do contrato chega ao modelo: o nome, a descrição e o esquema de entrada, mais os erros codificados que voltam como observações. Todo o resto fica do lado do controle, porque o modelo nem precisa disso para propor nem deve poder discutir com isso.



A consequência prática é que a definição visível ao modelo é gerada a partir do contrato, e não escrita ao lado dele. Se o esquema que o modelo vê e o esquema que o gate impõe vivem em dois arquivos, eles vão divergir, e a divergência aparece como um fluxo constante de propostas que passam no esquema mostrado ao modelo e falham no gate.

O que o contrato diz ao registro

Um contrato também decide que evidência uma chamada deixa. Para cada chamada, o registro pode carregar o nome da ferramenta, a versão do contrato, a classe de efeito, o veredicto e seu reason code, a chave de idempotência, o escopo sob o qual a chamada rodou, o tempo gasto em relação ao timeout e o código de erro, se houve. Cada item é um campo que o contrato já define, de modo que o trace de uma chamada é reconstituível sem que ninguém precise lembrar de registrá-lo em log. O Capítulo 20 cuida da forma do trace; o ponto aqui é que um contrato sem campos registrados é como uma chamada de ferramenta termina em F8 (comportamento não observado), em que o on-call não sabe dizer o que foi pedido, o que foi permitido nem o que aconteceu.

O contrato canônico: `issue_refund`

O contrato abaixo é o que este livro usa em todo lugar, e o Capítulo 4 já citou partes dele. Leia-o uma vez inteiro e depois campo a campo.

```

tool issue_refund
description: "Refund part or all of a captured payment for one order."
input schema: // fields the model supplies
  type: object, additionalProperties: false
  required: [order_id, amount_minor, currency, reason_code]
  properties:
    order_id: { type: string }
    amount_minor: { type: integer, minimum: 1 } // minor units
    currency: { type: string, minLength: 3, maxLength: 3 }
    reason_code: { enum: [damaged, not_delivered, wrong_item, goodwill] }
effect class: irreversible write
preconditions: // checked by the gate, not the model
  - order belongs to the customer of this run
  - payment status is "captured"
  - amount_minor <= refundable_balance(order_id)
  - amount_minor <= refund_ceiling, else needs_approval
  - no earlier refund for this key has outcome "unknown"; the gate
    queries its status first and refuses until it is known
idempotency: key = hash(ticket_id, order_id, refund_intent_id)
  // every part is assigned by the runtime, none by the model:
  // ticket_id comes from the run; refund_intent_id is the first
  // intent for this ticket and order, and a new one is issued only
  // after an explicit human decision recorded in the approval service.
  // Not in the key: run_id, step_id and every field the model supplies
  // (amount_minor, reason_code). If a timeout leaves the outcome
  // unknown and the model proposes the refund again, in a new step,
  // with another amount or another reason, the key is the same and
  // the call returns the first result (duplicate_replayed).
permissions: scope "refunds:create", delegated for this ticket only
timeouts: call 10s, deadline 30s // illustrative; after a timeout
  // check the refund status before any retry
error shape: { code, message, retryable, details }
  // code in [invalid_arguments, precondition_failed, approval_required,
  //   not_permitted, duplicate_replayed, upstream_unavailable,
  //   outcome_unknown]

```

O **esquema de entrada** lista apenas o que o modelo fornece, e `additionalProperties: false` fecha a porta para qualquer outra coisa. Repare no que está ausente: nenhum id de cliente, nenhuma referência de pagamento, nenhuma chave de idempotência, nenhum id de ticket. Todo valor que o runtime pode conhecer sozinho fica fora do esquema, porque um campo que o modelo preenche é um campo que pode estar errado. O Capítulo 4 vai um passo além e defende remover também `amount_minor`, com o código calculando-o a partir das linhas do pedido. O contrato canônico mantém o campo porque muitos fluxos reais de reembolso partem de um valor e, quando ele fica, o gate o trata como uma afirmação a verificar.

As **pré-condições** são fatos que o gate lê por conta própria, numa ordem à qual voltarei. Duas coisas merecem ser ditas sobre a lista como está escrita. O teto não é uma recusa, mas um veredicto: acima de

`refund_ceiling`, o gate devolve `needs approval`, e uma pessoa (Sam, no caso dos reembolsos) decide. E a lista canônica deixa a verificação da moeda implícita no saldo reembolsável. Num contrato seu, escreveria essa regra como uma pré-condição, moeda igual à moeda do pedido, porque o exemplo de F2 de um reembolso na moeda errada é barato de evitar quando há uma linha que um teste consegue encontrar.

A linha de permissões nomeia um escopo e uma delegação. O escopo é estreito (criar reembolsos), e a delegação está atada a este ticket. O Capítulo 7 trata de como a credencial é estreitada e emitida; aqui importa que o contrato nomeie o escopo, para que uma ferramenta sem escopo declarado seja reprovada na revisão antes de ir ao ar.

Os timeouts incluem uma frase fácil de passar batido: depois de um timeout, verifique o status do reembolso antes de qualquer retry. Um timeout não é uma falha: quem chamou parou de esperar, e a escrita pode ou não ter acontecido, então o contrato manda perguntar ao proprietário do estado.

Nota: Os números nos contratos (10s, 30s, o teto) são ilustrativos. Os seus valores dependem de quanto o `payments-service` demora sob carga e de quanto uma resposta tardia custa a um cliente que espera.

Classes de efeito e o que cada uma exige

A **classe de efeito** é o único campo que define um piso para os outros. São quatro: leitura, escrita reversível, escrita irreversível e efeito colateral externo. Se uma chamada precisa de aprovação humana, isso é decidido pela política no gate, e não pela classe; assim, uma escrita reversível pode precisar de aprovação (`request_rollback`) e uma escrita irreversível abaixo do teto pode não precisar. O que a classe define é o conjunto mínimo de controles que o contrato deve apresentar.

Classe de efeito	Exemplo na Parcelport	Controles mínimos no contrato
leitura	<code>lookup_order</code>	Esquema de entrada, escopo de permissões, timeout; um limite de saída (Capítulo 5); uma pré-condição apenas sobre quem pode ver os dados ou se a origem deles é admitida
escrita reversível	<code>update_shipping_address</code>	O acima, mais pré-condições, uma chave de idempotência e um caminho de volta nomeado
escrita irreversível	<code>issue_refund</code>	O acima, mais uma regra de resultado desconhecido, uma leitura de status para confirmação e uma política de aprovação
efeito colateral externo	<code>send_customer_reply</code>	O acima, mais idempotência (um envio repetido chega duas vezes a uma pessoa), verificações de conteúdo e intenção registrada

Os controles se acumulam à medida que se desce pela tabela, e uso isso para revisar contratos depressa. Uma ferramenta de escrita sem chave de idempotência está incompleta como desenhada. Uma pré-condição de leitura trata de quem pode ver os dados ou de se a origem deles é admitida, como a verificação de propriedade em `lookup_order` ou a verificação de admitida-e-fixada em `search_docs` (Capítulo 8), e não é sinal de classe errada. Uma leitura com pré-condição sobre um estado que a própria chamada altera, ou que altera alguma coisa, sugere que a classe está errada, ou que a ferramenta faz mais do que diz.

Classificar uma ferramenta é um julgamento sobre o que a chamada pode fazer, e três casos pedem cuidado. Primeiro, a classe pertence à ferramenta, não a uma chamada em particular. Uma única ferramenta `update_order` que às vezes edita uma nota e às vezes cancela um envio não tem classe honesta, e a correção é dividi-la, nos moldes da separação entre leitura e escrita do Capítulo 5. Segundo, “reversível” tem uma janela e um custo. `update_shipping_address` é uma escrita reversível apenas enquanto o `shipping-service` ainda permite mudar o endereço; quando uma transportadora recebe a encomenda, ela deixa de ser reversível na prática. A classe diz pelo que a ferramenta normalmente pode ser desfeita, e as pré-condições precisam dizer quando. Terceiro, um efeito colateral externo não é desfeito por nada que você tenha em mãos. Uma resposta que já saiu para o cliente não pode ser cancelada, então o peso do contrato recai sobre o que acontece antes do envio.

A ordenação dos efeitos também importa entre ferramentas. Um reembolso seguido de uma resposta são duas chamadas em dois sistemas, e a lacuna entre elas é onde vive F6: um reembolso registrado no `payments-service` e nenhuma resposta enviada, com o run marcado como concluído. Nenhum contrato fecha essa lacuna sozinho. O que o contrato pode fazer é tornar o estado de cada chamada consultável, que é o que permite a um job de reconciliação sobre o registro (capítulos 10 e 20) encontrar o reembolso sem resposta.

Pré-condições: verificações determinísticas sobre fatos que o gate leu

Uma pré-condição é uma função de fatos, e não uma afirmação que a proposta faz sobre si mesma. A proposta diz “este pedido é meu”, e o gate não acredita; ele lê o pedido e compara o proprietário com o cliente do run. Essa é a mesma linha que o Capítulo 4 traça entre uma afirmação e um fato, escrita aqui como o quinto campo do contrato.

A ordem em que o gate avalia as pré-condições é uma decisão de design com consequências. O bloco abaixo verifica `issue_refund` numa sequência que defenderia: primeiro o esquema, depois a autoridade sobre o pedido, depois o que se sabe sobre esta chave e só então o dinheiro. Este bloco é uma visão parcial do gate do Capítulo 5, para uma única ferramenta, e mantém os nomes de razões desse capítulo. (Os construtores `refuse`, `allow` e `needsApproval` devolvem os registros de veredicto que `runStep` lê, com os tipos `"refuse"`, `"allow"` e `"needs_approval"`.)

```

function checkIssueRefund(run, call):
    args = call.arguments
    if not valid(contract.inputSchema, args):
        return refuse("invalid_arguments")
    authority = checkAuthority(run, call)           // Chapter 7 owns
ownership and delegation
    if authority.kind == "refuse":
        return authority                           // its reason stays as
is: not_permitted, or retryable upstream_unavailable
    order = orders.read(args.order_id)             // the gate reads the
facts itself
    key = refundKey(run, order.id)                  // runtime-assigned
parts only
    status = payments.refundStatus(key)             // asked before
deciding, never assumed
    if status.state == "unresolved":
        return refuse("outcome_unknown")          // until the owner says
what happened
    if status.state == "completed":
        return allow(approvedCallFor(key), key)    // approvedCallFor: the
call as first approved, with its approval; the tool replays
// the first result and
acts on nothing. The raw call would reach
// the tool gateway
unapproved and meet approval_required.
// A completed key is
answered before the approval's age is read
    if payments.paymentStatus(order.id) != "captured":
        return refuse("precondition_failed", field: "payment_status")
    if args.amount_minor > payments.refundableBalance(order.id):
        return refuse("precondition_failed", field: "amount_minor")
    if authority.kind == "needs_approval":         // the ceiling,
evaluated by policy in Chapter 7
        return needsApproval(bindTo(call, key))   // Sam decides; the
approval names this exact call
    return allow(authority.call, key)              // the call carries the
authority its credential is scoped to

```

Três detalhes da ordem merecem um olhar mais atento. A pré-condição de propriedade do contrato (“order belongs to the customer of this run”) tem um único responsável, `checkAuthority`, no Capítulo 7. O gate repassa a decisão dele como uma decisão, e não como um sim ou não: uma recusa mantém a própria razão, de modo que `not_permitted` continua sendo uma negação e `upstream_unavailable` continua sendo retryable, e um `orders-service` inalcançável nunca é reescrito como uma recusa permanente. Este capítulo não define uma segunda regra de propriedade. O status da chave é lido antes do saldo porque, caso contrário, um replay de um reembolso concluído seria recusado como “saldo restante insuficiente”, já que o reembolso o consumiu, e o modelo veria uma falha numa chamada que fez exatamente o que devia. Num replay, o gate devolve a chamada como foi aprovada originalmente, e não a proposta bruta, porque o ga-

teway de ferramentas recusa uma escrita não aprovada com `approval_required`, e um replay não pode parecer uma aprovação contornada. `approvedCallFor(key)` é a busca dessa primeira chamada e da aprovação registrada com ela. A aprovação pode ter expirado quando um reembolso concluído é repetido; por isso, quem verifica a aprovação, o gateway de ferramentas ou o serviço proprietário, precisa deixar passar até a ferramenta uma chave que já foi concluída, e a ferramenta devolve o primeiro resultado armazenado (`duplicate_replayed`), antes de olhar a idade da aprovação; um alarme de expiração numa chave concluída faria um replay legítimo parecer um defeito. O veredicto do teto é executado por último, depois das condições acima, para que uma chamada que seria recusada por fatos nunca chegue a uma pessoa.

Duas lacunas permanecem, e nenhuma é um bug do bloco. A primeira é o tempo. O gate leu os fatos no momento da verificação, e a escrita acontece um instante depois; o estado pode mudar nesse intervalo. Uma pré-condição do gate é, portanto, consultiva sobre um fato em movimento, e o serviço proprietário precisa impor a mesma regra de forma atômica no momento da escrita. O gate existe para dar uma recusa codificada e antecipada e para manter propostas sabidamente ruins longe do serviço, enquanto o serviço continua sendo a autoridade. A segunda lacuna é que as leituras do gate custam chamadas: cada pré-condição que precisa de uma leitura soma latência e uma dependência, o que contabilizo nos trade-offs abaixo.


Idempotência: quem faz a chave

Uma **chave de idempotência** permite que uma ferramenta reconheça uma chamada repetida e devolva o primeiro resultado em vez de agir duas vezes. A pergunta que importa é quem faz a chave, porque a resposta decide se ela protege alguma coisa.

Se o modelo fornece a chave, a proteção acabou. Um modelo que propõe o reembolso de novo pode propor uma chave nova tão facilmente quanto a antiga, e nada garante que ele repetirá a primeira. Se a chave é construída a partir do run ou do passo, uma repetição proposta num passo posterior recebe uma chave diferente e age de novo, que é exatamente o caso da abertura. Se a chave inclui o valor ou o reason code, uma repetição com “outro valor ou outro motivo” recebe uma chave diferente, e essa variação

é justamente o que um timeout seguido de uma proposta nova produz. Por isso o contrato canônico constrói a chave apenas com identificadores que o runtime atribui: o ticket, o pedido e uma intenção de reembolso.

A sequência abaixo acompanha o cenário de abertura através do contrato. Observe os dois ramos depois da proposta repetida, e o fato de que nenhum deles chega a uma segunda escrita.



Uma **intenção de reembolso** é o registro do runtime de que um reembolso para este ticket e este pedido foi iniciado. A primeira proposta a cria, e toda proposta posterior para o mesmo ticket e o mesmo pedido corresponde a ela. Um segundo reembolso, legítimo, para outras linhas do mesmo pedido é uma nova intenção, e só é emitido depois de uma decisão humana registrada no serviço de aprovação. Esse é o atrito que o design compra, e é deliberado: um segundo reembolso no mesmo pedido é o caso em que você quer que uma pessoa dê uma olhada.

O resultado `duplicate_replayed` merece atenção. Ele é reportado pelo formato de erro para que ninguém o confunda com um sucesso novo, ainda que nada tenha falhado, e seus detalhes carregam o primeiro resultado: o valor efetivamente reembolsado e o estado. Isso é útil além da segurança. A próxima resposta do modelo ao cliente pode informar o valor que foi reembolsado, fundamentado num resultado de ferramenta, em vez do valor que ele propôs em segundo lugar (um risco de F3, uma afirmação sem fundamento, se a resposta citasse o errado).

Aviso: Uma escrita irreversível que o agente consegue alcançar sem chave de idempotência, ou com uma chave que o modelo controla, pode mover dinheiro duas vezes. Onde o serviço proprietário não consegue honrar uma chave, não entregaria essa ferramenta ao agente como escrita irreversível até que consiga. Um wrapper de deduplicação na frente do serviço mantém a própria tabela de chaves, e dois armazenamentos que podem divergir são um novo lugar para F6 se esconder.

A ferramenta cumpre a outra metade do acordo. Ela precisa reter as chaves por pelo menos o tempo em que uma nova proposta ou um retry possa plausivelmente chegar, e precisa devolver o primeiro resultado para a mesma chave mesmo que os argumentos difiram. Quanto tempo isso é depende de quanto tempo os runs podem durar, assunto do Capítulo 10, e de quanto tempo uma aprovação humana pode ficar parada, assunto do Capítulo 15. Não sei qual é a retenção certa para o seu sistema. Ela depende desses dois números, e uma chave que expira antes do fim do run mais longo oferece um falso conforto.

Mais dois contratos

Os contratos das outras ferramentas são mais curtos, porque a maior parte dos campos segue o mesmo padrão. Dois valem ser escritos por extenso, já que cada um mostra uma pressão diferente.

update_shipping_address

Esta é uma escrita reversível com um fato que se move. O endereço de um envio pode mudar até que uma transportadora receba a encomenda, e um endereço lido no passo 2 pode estar obsoleto no passo 9 (F5, loop descontrolado ou contexto obsoleto). Por isso o contrato usa uma escrita condicional.

```
tool update_shipping_address
  description: "Change the delivery address of an order whose shipment no
  carrier has received."
  input schema:
    type: object, additionalProperties: false
    required: [order_id, new_address]
    properties:
      order_id: { type: string }
      new_address:
        type: object, additionalProperties: false
        required: [line_1, city, postal_code, country_code]
        properties: { line_1, line_2, city, postal_code, country_code:
strings }
    effect class: reversible write      // way back: write the previous
address,
      // only while shipping-service still accepts changes
    preconditions:
      - order belongs to the customer of this run    // Chapter 7
    checkAuthority
      - shipment state is "not handed to carrier"
      - new_address passes field-level validation
    idempotency: key = hash(ticket_id, order_id, address_change_intent_id)
      // runtime-assigned; a new intent is issued only after an explicit
      // human decision. expected_version comes from the gate, which reads
      // it from shipping-service; the model never supplies it, so the
      // write applies only if the shipment is unchanged since the check
    permissions: scope "shipping:update_address", delegated for this ticket
only
    timeouts: call 5s, deadline 15s      // illustrative
    error shape: { code, message, retryable, details }
      // code in [invalid_arguments, precondition_failed, not_permitted,
      // duplicate_replayed, upstream_unavailable, outcome_unknown]
      // approval_required is absent: not applicable unless policy adds it
```

Dois pontos. Primeiro, o `expected_version` faz da leitura do gate e da escrita do serviço uma única operação condicional, que é a resposta à lacuna de tempo descrita antes. Uma escrita que encontra o envio alterado devol-

ve `precondition_failed`, e o run lê de novo antes de propor outra vez. Segundo, o novo endereço vem do ticket, que é texto não confiável. Se uma dada mudança de endereço deve exigir aprovação, ou uma confirmação por um canal que o perfil do cliente já tenha, é uma questão de política tratada nos capítulos 7 e 16. O trabalho do contrato é tornar a chamada verificável, para que a política tenha onde se prender.

`request_rollback`

Para o agente de operações, o contrato é mais curto em campos e mais pesado em consequências. Esta é uma escrita reversível pela classificação do livro, já que um deploy posterior pode restaurar a versão anterior, e a política sempre exige aprovação para ela.

```
tool request_rollback
  description: "Ask deploy-service to roll a deployment back to its previous
  version."
  input schema:
    type: object, additionalProperties: false
    required: [deployment_id, summary]
    properties:
      deployment_id: { type: string }
      summary:       { type: string, maxLength: 500 } // shown to Robin;
illustrative limit
  effect class: reversible write // a later deployment can restore the
previous version
  preconditions:
    - deployment is the active one for its service
    - a previous version exists to roll back to
    - no rollback is already in progress for this deployment
  idempotency: key = hash(alert_id, rollback_intent_id)
  // runtime-assigned: alert_id comes from the run's trigger; a second
  // rollback for the same alert is a new intent, issued only after a
  // human decision. deployment_id is model-supplied, so it is checked
  // by the preconditions and kept out of the key
  permissions: scope "deploy:rollback"; approval by on-call required by
policy
  // the deploy credential is used by deploy-service, never held by the
agent
  timeouts: call 10s, deadline 60s // illustrative; the call is accepted,
not completed
  error shape: { code, message, retryable, details }
  // code in [invalid_arguments, precondition_failed, approval_required,
  // not_permitted, duplicate_replayed, upstream_unavailable,
outcome_unknown]
```

Repare que `summary` é um texto escrito pelo modelo que uma pessoa lê antes de aprovar. Ele não é confiável, tem tamanho limitado e é exibido como dado na requisição de aprovação, assunto do Capítulo 15. Repare também no comentário do timeout. A chamada volta quando o pedido é

aceito, e não quando o rollback termina; portanto, a pós-condição é uma leitura do estado do deploy, feita pelas ferramentas que o leem. O efeito iniciado não é o efeito concluído, e o contrato precisa dizer qual dos dois o seu timeout mede.

A aprovação dada por Robin está atada à chamada exata: a ferramenta, os argumentos e a chave. Uma chamada que chega ao `deploy-service` sem uma aprovação válida para esses valores devolve `approval_required`. Esse código e o veredicto “needs approval” do gate são coisas diferentes, e a diferença ganha uma seção própria mais adiante.

O contrato de erros

O formato de erro é `{ code, message, retryable, details }`, e o objetivo do design é estreito: uma mensagem sobre a qual o modelo possa agir, que não lhe entregue o controle. Um contexto que contém “refunds above 50 need approval” entrega à próxima proposta um número para ficar abaixo. Um contexto que contém “this refund needs a decision from a person” diz o que esperar e nada além disso. Por isso o formato de erro é um vocabulário fechado com texto fixo.

Código	Gerado por	Repe-tível	O que o modelo vê	O que o orquestrador faz
<code>invalid_arguments</code>	o gate	não	Nomes dos campos que falharam	Nova proposta limitada (capítulos 4 e 12)
<code>precondition_failed</code>	o gate ou a ferramenta	não	Qual pré-condição, pelo nome; sem valores	Observação, ou hand-off quando se repete
<code>approval_required</code>	o gateway de ferramentas	não	Nada além de “not approved”	Tratar como defeito ou aprovação obsoleta; voltar ao caminho de aprovação (Capítulo 15)
<code>not_permitted</code>	o gate ou o gateway de ferramentas	não	Um “not permitted for this task” genérico	Registrar; hand-off se se repete

Código	Gerado por	Repe- tível	O que o modelo vê	O que o orquestrador faz
<code>duplicate_replayed</code>	a ferramenta	não	O primeiro resultado, marcado como replay	Continuar a partir do primeiro resultado
<code>upstream_unavailable</code>	a ferramenta ou o serviço dela	sim	“Temporarily unavailable”	Fazer um retry conforme a política, com a mesma chave, sob um breaker (Capítulo 13)
<code>outcome_unknown</code>	o gate ou a ferramenta	até o status ser conhecido	“Outcome not yet known”	Consultar o status; reconciliar; hand-off se não for resolvido
<code>result_invalid</code>	o gateway de ferramentas	não	Nada além de “result not usable”	Descartar o resultado, registrar, hand-off se se repete; acrescentado para ferramentas de servers externos (Capítulo 8)

Quatro regras sustentam a tabela. A `message` é um modelo escolhido pelo código, e não um texto montado a partir do estado interno, porque uma mensagem de erro construída a partir da resposta de um serviço upstream pode levar dados de clientes ou stack traces para o contexto. Os `details` são um allowlist de campos por código, de modo que um `precondition_failed` nomeia a pré-condição e omite o saldo, o teto e o proprietário. A flag `retryable` é para o orquestrador. Não é um convite ao modelo; um retry roda sob a política de retry com a mesma chave, e não se pede ao modelo que repita nada. E o conjunto de códigos é fechado: os sete códigos do contrato canônico, mais `result_invalid`, que um contrato só acrescenta para ferramentas de servers externos. Quando uma ferramenta devolve um código que o orquestrador não conhece, o padrão conservador é recusar e fazer o hand-off, e não adivinhar.

A diferença entre o veredicto “needs approval” e o erro `approval_required` é a que este livro não para de traçar. O veredicto é o que o gate devolve quando uma proposta espera por uma pessoa, e o run é suspenso. O erro é o que o gateway de ferramentas devolve quando uma chamada chega a uma ferramenta sem aprovação válida, o que num run

saudável significa que algo entre o gate e a ferramenta deu errado: a chamada mudou depois da aprovação, a aprovação expirou ou o caminho foi contornado. Criaria um alerta para isso.

A mensagem de `outcome_unknown` pode dizer ao modelo que o resultado ainda não é conhecido, o que o ajuda a escrever uma resposta honesta, mas essa frase é uma cortesia. O controle é a recusa no gate.

O que o modelo não pode ver

Parte do comportamento de cada ferramenta vive em lugares que o modelo nunca lê: o teto, os escopos, a construção da chave, a versão da política e os timeouts. Manteria assim, e diria isso na estrutura do contrato.

O teto vive na política, e não no contrato; o Capítulo 7 mostra a política e sua versão, que é registrada em cada veredicto.

A descrição pode dizer que reembolsos grandes precisam da decisão de uma pessoa, porque isso define expectativas e reduz o número de propostas que o gate tem de enviar a Sam. Ela não declara o limite. Um limite na descrição é um alvo, e um limite na descrição que difere do da política, depois da próxima mudança, é uma armadilha com duas fontes de verdade.

Uso um hábito para manter as descrições honestas. Toda frase de uma descrição que enuncie uma regra deve nomear uma pré-condição do contrato que a imponha, e um teste do gate que a exercite. A verificação pode ser mecânica: uma etapa de revisão que lista lado a lado as frases com cara de regra e as pré-condições, e falha quando alguma não tem par. As frases sem par são as perigosas, porque parecem controles e são apenas pedidos.

O mesmo raciocínio vale para ferramentas que chegam de fora. Uma descrição escrita por um server de terceiros é entrada não confiável, e o contrato que o gate usa precisa ser escrito do seu lado. O Capítulo 8 volta a isso.

Versionamento e testes de contrato

Um contrato muda, e uma mudança de contrato é uma mudança de comportamento. Trato o contrato como um artefato versionado, com um identificador como `issue_refund@3`, registrado em cada proposta e veredicto, para que uma pergunta posterior (“isso era permitido pelo contrato daquele dia?”) tenha resposta. O registry guarda cada versão, e o gate avalia contra a atual.

Nem toda mudança pesa o mesmo. Acrescentar um campo opcional ao esquema de entrada é a mais leve, embora altere o que o modelo propõe e mereça uma execução de eval (Capítulo 21). Apertar uma pré-condição recusa propostas que o gate antes permitia, de modo que a taxa de recusa se move e o loop vê mais observações. Afrouxar uma pré-condição ou elevar o teto é uma decisão de política, e quem responde por essa política assina. Mudar a classe de efeito é item de revisão de segurança, que é onde entram as perguntas de Jordan. E mudar a composição da chave de idempotência é a mais perigosa: uma chave construída de forma diferente da de ontem deixa de corresponder às chamadas em andamento de ontem, e então a repetição de uma chamada iniciada antes do deploy age duas vezes. Trate isso como uma migração, com o gate verificando as duas formas de chave por um período.

Runs longos encontram versões no meio do caminho. Um run retomado de um checkpoint (Capítulo 10) pode guardar definições de ferramentas anteriores a uma mudança. O gate sempre avalia contra o contrato atual, e o orquestrador relê as definições visíveis ao modelo ao retomar, de modo que uma proposta construída sobre um esquema obsoleto é recusada com `invalid_arguments` e não é aplicada.

Os testes de contrato vêm em três camadas, e nenhuma precisa de um modelo.

- **Verificações de contrato.** Um lint sobre todos os contratos: os nove campos presentes ou marcados como não aplicáveis com uma razão, uma classe de efeito da lista fechada, uma chave de idempotência em toda escrita, um timeout em toda chamada, códigos de erro do conjunto fechado e uma chave feita apenas de partes atribuídas pelo runtime.

- **Testes do gate.** Uma tabela de propostas e fatos com o veredicto e o código esperados, como descreve o Capítulo 4. Para cada pré-condição: uma linha que passa, uma que falha e o limite (exatamente o teto e uma unidade menor acima dele). A ordenação acima tem a sua própria linha: o replay de um reembolso concluído deve voltar como replay, e não como falha de saldo.
- **Conformidade da ferramenta.** Executada pela equipe responsável pelo serviço. A mesma chave duas vezes produz um único efeito e o primeiro resultado. A mesma chave com um valor diferente produz o primeiro resultado. Um timeout injetado depois da escrita produz `outcome_unknown`, e a consulta de status então devolve a verdade. O formato de erro corresponde ao contrato.

A terceira camada importa porque o gate permite um replay e confia que a ferramenta não age sobre nada. Se a ferramenta implementa isso errado, o gate não tem como saber. A responsabilidade segue as camadas: a equipe de plataforma (Alex) é responsável pelo lint e pelos testes do gate, a equipe do serviço é responsável pela conformidade, e a equipe de segurança revisa a classe de efeito e as permissões em qualquer mudança.

Trade-offs e custos

Um contrato custa tempo de autoria para cada ferramenta, e o custo se gasta sobretudo nas escritas, onde o raciocínio é difícil: qual é a pré-condição, a partir de que a chave é construída, qual é o caminho de volta. Para uma ferramenta de leitura, o contrato é curto.

As leituras do gate têm um preço. Cada pré-condição que lê um fato soma uma chamada e uma dependência; digamos que a verificação do reembolso faça três leituras, e cada uma soma latência a um passo e uma forma de o passo falhar. Se o `orders-service` está lento, o gate está lento. Só colocaria em cache fatos que não podem ficar obsoletos dentro de um passo, e leria o resto na hora, aceitando a latência. Um gate que lê fatos obsoletos trocou uma classe de falha por outra.

Pré-condições mais rígidas significam mais recusas, e recusas são passos. Cada nova proposta custa uma chamada ao modelo e conta contra os limites do run (capítulos 12 e 13). Um contrato correto mas que recusa, diga-

mos, um terço das propostas legítimas manda tickets para pessoas, e Sam percebe antes de qualquer dashboard. Ajuste lendo as propostas recusadas, e não afrouxando a verificação.

O design de idempotência tem custos humanos. As intenções de reembolso exigem controle, as chaves exigem armazenamento e retenção, e um segundo reembolso legítimo no mesmo pedido exige a decisão de uma pessoa. Se essas decisões são aprovadas em segundos todas as vezes, são teatro, e o certo é examinar a política, e não remover a exigência.

Quando não escrever o contrato completo: um protótipo que lê documentação, uma ferramenta interna de leitura com raio de impacto pequeno e sem PII, ou uma ferramenta que um desenvolvedor executa à mão. Uma forma curta (esquema, classe de efeito, timeout, formato de erro) basta ali, e a leitura ainda passa pelo gate enxuto. Mesmo assim, não dispensaria a classe de efeito nem o escopo de permissões em nada que escreva, e não deixaria um contrato curto permanecer numa ferramenta que depois ganhou uma escrita.

Onde um contrato não basta: ele não pode tornar um serviço idempotente, não pode tornar uma pré-condição livre de corrida e não pode tornar cuidadoso um revisor humano. Ele enuncia a intenção de forma verificável, e os controles que nomeia precisam existir em outro lugar no código.

Erros comuns

- **Pôr a regra apenas na descrição.** É o lugar mais barato para escrevê-la, e o modelo costuma segui-la. Correção: toda frase com cara de regra nomeia uma pré-condição e um teste do gate, e o teto é uma política, não uma frase.
- **Deixar o modelo fornecer a chave, ou construí-la a partir de ids de run e de passo.** É tentador porque ambos estão à mão e parecem únicos. Correção: derive a chave apenas de identificadores que o runtime atribui, e teste que uma repetição com outros argumentos num passo posterior recebe a mesma chave.
- **Pôr o valor ou o reason code na chave.** É tentador porque o valor parece parte do pedido. Uma repetição variada passa então a parecer um pedido novo. Correção: mantenha a chave restrita a ticket, pedido e intenção.

- **Dar a uma ferramenta uma classe de efeito variável.** Uma ferramenta com um argumento de modo parece arrumada. Correção: divida-a e nomeie cada classe com honestidade.
- **Devolver erros em texto livre com detalhes internos.** Uma mensagem rica ajuda na depuração no primeiro dia. Correção: um conjunto fechado de códigos, uma mensagem fixa por código e um allowlist de detalhes.
- **Fazer um retry depois de um timeout sem perguntar ao proprietário.** É tentador porque já existe um wrapper genérico de retry. Correção: o contrato manda verificar o status primeiro, e o gate recusa enquanto o resultado não estiver resolvido.
- **Manter o contrato em dois lugares.** Quem escreve o prompt e quem escreve o gate trabalham separados. Correção: uma única fonte, com a definição visível ao modelo gerada a partir dela.
- **Tratar needs approval como propriedade da classe.** É simples de enunciar e fácil de auditar. Correção: a política decide, por ferramenta, por valor, por ambiente.

Pontos-chave

- Um esquema diz se os argumentos são bem formados, e um contrato diz se a chamada pode acontecer no mundo como ele está agora; os nove campos, numa ordem fixa, tornam isso verificável.
- Uma regra na descrição de uma ferramenta é um pedido que reduz a taxa de propostas ruins, e a mesma regra precisa existir como uma pré-condição que o gate impõe e como um teste que falha quando ela deixa de valer.
- A classe de efeito define o piso de controles (leituras precisam de um escopo e de um limite de saída, escritas precisam de pré-condições e de uma chave de idempotência, escritas irreversíveis precisam de uma regra de resultado desconhecido), enquanto a política, e não a classe, decide a aprovação.
- A chave de idempotência é derivada pelo runtime a partir de identificadores que ele atribui, nunca do modelo, do run ou do passo; assim, uma repetição proposta num passo posterior com quaisquer argumen-

tos devolve o primeiro resultado, e um segundo reembolso exige uma decisão humana registrada.

- As pré-condições são funções de fatos que o próprio gate leu, avaliadas numa ordem deliberada, e o serviço proprietário impõe as mesmas regras de forma atômica, porque a leitura do gate pode estar obsoleta na hora da escrita.
- Os erros vêm de um conjunto fechado de códigos, com mensagens fixas e detalhes em allowlist; `retryable` fala com o orquestrador e não com o modelo, e `approval_required` vindo do gateway de ferramentas não é o veredicto `needs approval` do gate.
- Os contratos são artefatos versionados, com testes do gate e testes de conformidade da ferramenta que não precisam de modelo, e mudar a construção da chave é uma migração, não uma edição.

O Capítulo 7 trata do campo que todo contrato nomeia e nenhum define: para quem o agente age, que autoridade ele detém em nome dessa pessoa e como uma chamada passa a carregar uma credencial não mais ampla que a tarefa.

Capítulo 7 — Permissões e autoridade delegada

Pense na Parcelport numa quarta-feira tranquila. Uma cliente, `cus-0042`, escreve para o suporte: a encomenda do pedido `ord-7f3k2m91` chegou danificada, e ela pede o reembolso. O agente de suporte consulta o pedido, vê que ele está capturado e entregue, e propõe um reembolso. A proposta é bem formada, o valor está abaixo do saldo reembolsável e o pagamento está capturado.

Os capítulos 4 a 6 já perguntam duas vezes de quem é o pedido: o conjunto de escolhas oferece ao modelo apenas os pedidos do próprio cliente (Capítulo 4), e o contrato traz uma pré-condição de propriedade (capítulos 5 e 6). As duas verificações são boas, e as duas tomam emprestadas duas respostas que não conseguem produzir sozinhas: quem é “este cliente” e o que a credencial por trás da chamada consegue alcançar. Suponha que `ord-7f3k2m91` pertença a `cus-0107`, um parente que comprou com uma conta separada, que a cliente digitou o número a partir de uma confirmação encaminhada e que a identidade do cliente no run foi montada a partir da thread de e-mail. Ninguém nesta história age de má-fé. Cada verificação passa contra a resposta que recebeu, o agente tem um único token amplo que funciona em todo pedido e em todo cliente, e o `orders-service` e o `payments-service` não têm motivo para objetar. O reembolso cai na conta errada, e o registro mostra um agente agindo dentro das suas permissões, porque as permissões dele eram tudo.

Este capítulo pertence à parte **Gate** do envelope de controle, e toca em **Efeito** no ponto em que o gateway de ferramentas anexa a credencial a uma chamada. A pergunta do Gate é se esta proposta pode produzir efeito, para este principal, agora. O Capítulo 4 traçou a linha entre o que o modelo pode escolher e o que o código decide, e o Capítulo 6 escreve o contrato que a chamada precisa satisfazer. Este capítulo não acrescenta uma terceira cópia da verificação de propriedade. Sua contribuição é aqui: em que essas verificações se apoiam: uma delegação que diz em nome

de quem o run age, uma interseção que limita a autoridade de uma chamada, uma credencial que faz o limite valer também no serviço, e um único responsável pela decisão de propriedade, `checkAuthority`, que recusa com um único código, `not_permitted`.

O problema e por que ele é difícil

O protótipo do Capítulo 1 dá a cada agente um único token de API que funciona em todas as ferramentas e em todos os clientes. Esse token não é uma decisão que alguém tomou. É o que sobra depois que um protótipo funcionou e ninguém voltou atrás. O efeito é que os serviços por trás das ferramentas não conseguem distinguir uma chamada que atende o cliente do ticket de uma chamada que atende qualquer outra pessoa, porque a credencial diz a mesma coisa nos dois casos.

Esta é a parte **Gate** falhando de uma forma particular, e a classe de falha é **F7 (efeito não autorizado)**: aconteceu um efeito que este principal, neste momento, não deveria ter conseguido causar. Repare no que a distingue de F2 (ferramenta incorreta ou argumentos incorretos). Em F2, a proposta está errada para a situação. Em F7, a proposta pode ser perfeitamente razoável para alguma situação, e o sistema a deixa chegar a um efeito nesta. O mesmo reembolso seria correto para o ticket do próprio `cus-0107`. O defeito não está na proposta. Está na distância entre o que o agente consegue alcançar e o que esta tarefa deveria alcançar.

O nome padrão para esse formato é **confused deputy**: um componente que usa a própria autoridade para fazer o que uma parte com menos privilégios pediu. Um agente de suporte que detém a autoridade de todos os clientes e age com base no texto do e-mail de um cliente é um deputy com um distintivo enorme e uma forma muito fraca de verificar quem está pedindo.

Os agentes agravam o problema de três maneiras. Primeiro, os argumentos que nomeiam o recurso (um id de pedido, um id de cliente) são fornecidos pelo modelo, e o contexto do modelo contém texto de fora da Parcelport. Um cliente pode citar qualquer pedido num e-mail. Um documento também pode citar qualquer pedido, e é assim que F4 (sequestro de instruções) se transforma em F7: se a única coisa entre uma proposta sequestrada e um reembolso é a tendência do modelo de não a propor, o seques-

tro funciona exatamente tantas vezes quanto o modelo falha. Segundo, o comportamento de um agente não é enumerado de antemão. Um serviço convencional tem um conjunto fixo de caminhos de código, e uma revisão pode verificar cada um contra suas permissões. Um agente escolhe entre suas ferramentas em tempo de execução, então as permissões precisam valer para combinações que ninguém listou. Terceiro, o modelo não carrega de forma confiável a noção de “este cliente, não aquele” de um passo para o seguinte. Isso é uma propriedade do contexto, e o Capítulo 9 trata de como ele se desvia.

A correção óbvia é uma frase no prompt: aja apenas em pedidos que pertençam ao cliente do ticket. Ela reduz a taxa de propostas entre clientes, e a escreveria mesmo assim, porque uma taxa menor significa menos recusas para ler depois. Mas é um pedido. A frase não estreita o token. Quando o modelo propõe o pedido errado, o token continua funcionando. A autoridade é uma propriedade da credencial e do código que decide se vai usá-la; por isso esta é uma questão de engenharia sobre onde a autoridade vive, como é estreitada e quem a verifica.

Nota: As leituras não ficam de fora. Uma chamada `lookup_order` que devolve ao contexto o nome e o endereço de entrega de outro cliente já moveu PII, antes de qualquer resposta ser escrita. O Capítulo 17 trata de minimizá-la; o ponto aqui é que a fronteira do cliente vale também para as ferramentas de leitura.

De quem é a autoridade?

Comece separando três coisas que o protótipo funde num único token. Acho mais fácil nomeá-las como principais, porque isso força a pergunta “como quem esta chamada está sendo feita?”.


Principal	O que é	O que contribui
A identidade do agente	Uma identidade de serviço para <code>support-agent</code> ou <code>ops-agent</code> . Não é uma pessoa, nem um login de cliente	O máximo que o agente pode fazer: as ferramentas que lhe são oferecidas e os escopos que essas ferramentas podem usar

Principal	O que é	O que contribui
O delegante	A parte em nome de quem o run age: o cliente do ticket, ou o engenheiro de on-call que iniciou uma investigação	O limite do que a tarefa pode tocar: os pedidos deste cliente, os logs deste serviço
A tarefa	Um run em um ticket ou em um incidente	Um escopo ainda mais estreito: este ticket, estes recursos, uma expiração

A **autoridade delegada** é a autoridade que um principal detém em nome de outro, sempre mais estreita que a do próprio delegante e atada a uma tarefa. A expressão tem duas metades. “Mais estreita que a do próprio delegante” diz que o agente nunca pode fazer algo que o cliente não poderia. Um cliente não pode ler o pedido de outro cliente, então um agente agindo por esse cliente também não pode. “Atada a uma tarefa” diz que a delegação termina: um ticket é fechado, um run termina, um incidente é resolvido, e a autoridade vai embora junto.

A autoridade efetiva de qualquer chamada isolada é a **interseção** das três. Uma chamada precisa que as três a permitam. A identidade do agente pode ter permissão para reembolsar, mas não em um pedido fora da delegação. A delegação pode cobrir os pedidos do cliente, mas não ferramentas que o agente nunca recebeu. A tarefa pode cobrir este ticket, mas não depois que ele é fechado. Reduzir a autoridade a uma interseção tem uma propriedade útil para uma revisão de design: acrescentar uma nova permissão a qualquer uma das três nunca amplia as outras.

O diagrama a seguir mostra o formato. Observe as setas que entram na interseção e o que sai dela: não um papel, mas a autoridade de uma chamada, que então se torna uma credencial de curta duração.



De onde vem a identidade do delegante

A pergunta a fazer primeiro é de onde veio o `cus-0042` de um run. Se a resposta for “o modelo leu no e-mail”, o design entregou toda a fronteira ao modelo. A identidade do delegante é atribuída pelo orquestrador quando o run é criado, a partir do que o sistema de tickets registrou sobre o solicitante autenticado, e fica armazenada no run. Depois disso, nada do que o modelo propõe pode editá-la.

Este é um ponto para ser honesto sobre os limites. A delegação é tão boa quanto o vínculo entre um ticket e um cliente. Se o sistema de tickets associa um ticket a um cliente por correspondência de endereço do remetente, então essa correspondência é o controle real, e merece o mesmo escrutínio que o gate. Não sei como o seu sistema de tickets vincula tickets a clientes, e você deve descobrir isso antes de confiar no restante deste capítulo. Uma fronteira hermética sobre um vínculo de identidade fraco é uma fronteira fraca.

Para o `ops-agent`, o delegante é um engenheiro. Imagine que Robin inicia a investigação de um deploy atrasado. A delegação diz: em nome de Robin, para este incidente, acesso de leitura ao log store, ao metrics store e ao trace store dos serviços citados no incidente, por um período limitado. Ela não diz “todo o acesso de Robin”. Robin talvez possa fazer muito mais, e o agente detém uma fatia disso.

A delegação como registro

Uma delegação é um dado, criado pelo orquestrador, legível pelo gate e gravado no registro. Aqui está ela numa notação ilustrativa (os nomes de campos e de escopos foram inventados para este capítulo, exceto `refunds:create`, que vem do contrato canônico de `issue_refund`):

```
delegation del-0xa1           // illustrative record
agent:      support-agent     // service identity
on behalf of: cus-0042        // set by the runtime from the ticket
task:       ticket tkt-0193
expires:    ticket closed, or 24h // illustrative
grants:
  orders:read      where order.customer == cus-0042
  customers:read   where profile.customer == cus-0042
  shipping:update_address where shipment.customer == cus-0042
  refunds:create    where order.customer == cus-0042
  replies:send      where ticket == tkt-0193
not granted: every other tool, every other customer
```

Duas propriedades importam. Cada grant nomeia uma condição de recurso, e não apenas uma ação. E o registro é criado antes do primeiro passo e não muda quando o modelo propõe algo: se um reembolso acima do teto é aprovado, a aprovação é uma autoridade separada, nova e estreita, para uma chamada exata (Capítulo 15), e não uma edição deste registro.

Autoridade mínima, de três formas

A **autoridade mínima** é a regra de que um principal detém a menor autoridade que permite concluir a tarefa. É uma ideia conhecida, e a aplicaria em três eixos, porque cada um pega algo que os outros deixam passar.

Eixo	A pergunta	Exemplo na Parcelport
Por ferramenta	Quais ações este agente pode tomar, afinal?	O <code>support-agent</code> tem sete ferramentas, o <code>ops-agent</code> oito, e nenhum detém as do outro
Por recurso	Sobre quais objetos?	<code>orders:read</code> apenas onde o pedido pertence ao cliente deste run
Por run	Por quanto tempo, para qual tarefa?	A autoridade termina com o ticket ou com o incidente, e as credenciais expiram em minutos

Por ferramenta é o mais barato e o que as equipes já fazem. Por recurso é onde o `confused deputy` é pego, e é o que falta ao protótipo. Por run é o que transforma um vazamento em um incidente de tamanho limitado: uma credencial que sobrevive ao run é uma credencial que alguém pode encontrar depois.

Estreitar a ferramenta em vez de verificar o argumento

O Capítulo 4 defendeu estreitar o leque de escolha, e isso se aplica diretamente aqui. Se `get_customer_profile` recebe um argumento `customer_id`, o gate precisa verificar esse argumento contra o cliente do run em toda chamada, e um único caminho de código esquecido é um F7. Se a ferramenta não recebe esse argumento e o orquestrador preenche sozinho o cliente do run, o modelo não tem nada em que errar. Escolheria a ferramenta sem o argumento sempre que o modelo nunca tiver motivo legítimo para nomear outro cliente. Para `get_customer_profile`, nunca tem.

As ferramentas que precisam receber um identificador de recurso (`lookup_order` recebe um id de pedido, porque o cliente pode ter vários) não podem abrir mão do argumento. Essas passam pela verificação de propriedade abaixo. A regra prática: remova o argumento se puder, verifique-o se não puder.

Credenciais de curta duração

A delegação é uma declaração. Uma credencial é o que um serviço aceita. As duas devem se alinhar: um serviço só deve ver uma credencial que já diga o que a delegação permite. O design a que recorreria é aquele em que o agente não detém nenhum token de serviço. O **gateway de ferramentas**, que na Parcelport fica junto do motor de políticas, emite uma credencial para uma chamada, com escopo para um serviço, uma ação e um recurso, válida por pouco tempo (digamos, alguns minutos) e atada à chamada exata para a qual foi emitida.

O Capítulo 18 trata de como essas credenciais são criadas e guardadas. O que este capítulo precisa delas é uma consequência de design: quando a credencial é estreita, o serviço impõe a fronteira uma segunda vez. Se um defeito no gate deixa passar um reembolso entre clientes, o `payments-service` recebe uma credencial com escopo para o recurso do outro cliente e pode recusá-la. O gate e a credencial são duas verificações independentes, com modos de falha diferentes, e esse é o sentido de ter as duas.

O gate e a autoridade

Agora ponha isso no gate. O ramo de chamada de ferramenta do Capítulo 4 verifica a proposta do modelo contra um conjunto de escolhas e recusa com `not_in_choice_set`, e os contratos dos capítulos 5 e 6 listam “the order belongs to the customer of this run” como pré-condição. O conjunto de escolhas é uma camada anterior e separada: ele estreita o que é oferecido ao modelo, é verificado contra o que o modelo propôs, e sua recusa mantém o próprio código. Não implementaria a frase de propriedade mais duas vezes, porém. A decisão de propriedade tem um único responsável, `checkAuthority`, abaixo, e um único código, `not_permitted`, e a pré-condição do contrato é satisfeita chamando-a. Uma proposta pode falhar no conjunto de escolhas e nunca chegar a esta função, e tudo bem. O que importa é que, quando um pedido fora da delegação chega ao gate, o ve-

redicto sobre a propriedade vem daqui, com um único texto de observação e uma única contagem no registro. Ela também roda antes das pré-condições que leem mais dados, porque não há razão para ler um pedido que o principal não pode ver.

```
function checkAuthority(run, call):
  delegation = run.delegation           // assigned at run
  creation
  if delegation.expired or delegation.revoked:
    return { kind: "refuse", reason: "not_permitted" } // an expired
  delegation is no authority
  authority = intersect(grantsFor(run.agent, call.tool),
                        delegation.grantsFor(call.tool),
                        run.taskScope)
  if authority is empty:
    return { kind: "refuse", reason: "not_permitted" }
  for each ref in resourceRefs(call):   // order id, shipment
    id
    owner = ownerOf(ref)                // read from the
  owning service
    if owner is unknown:
      return { kind: "refuse", reason: "upstream_unavailable" } //
  cannot verify: refuse, retryable
    if owner != delegation.on_behalf_of:
      return { kind: "refuse", reason: "not_permitted" }
    return evaluatePolicies(run, call, authority) // ceiling, window,
  environment
```

O bloco está correto diante da falha de que trata. As razões vêm do vocabulário do gate no Capítulo 5 (o Apêndice as lista), e não de um vocabulário próprio deste capítulo, e `checkAuthority` é uma visão parcial do gate do Capítulo 5: é a etapa `permitted`, e um resultado de aprovação que ela devolve é executado por último, depois das pré-condições (Capítulo 6). Quando a consulta ao proprietário falha, a chamada é recusada com `upstream_unavailable`, que é `retryable`: um `orders-service` inalcançável não pode virar permissão, e também não pode virar uma negação permanente; por isso o `retry` roda sob a política de `retry` (Capítulo 14) e não a pedido do modelo. Quando a delegação expirou porque o ticket foi fechado enquanto o `run` estava suspenso, a chamada é recusada com `not_permitted`. Quando o modelo propõe um pedido que não é do cliente, a chamada é recusada do mesmo modo, sem que se pergunte ao modelo se ele tem certeza.

O texto da recusa importa. A observação devolvida ao modelo deve dizer que o pedido não está disponível para este ticket, e nada além disso. Não deve confirmar que o pedido existe nem incluir qualquer campo dele. Uma


recusa que repete os dados de outro cliente é uma leitura que aconteceu por outra via.

A autoridade é verificada de novo depois da espera

Um run suspenso pode ficar numa fila por minutos ou horas antes que Sam o aprove. Nesse intervalo, o ticket pode ter sido reatribuído, a delegação revogada ou o pedido reembolsado por outra pessoa. Se o orquestrador retoma o run e aplica a chamada com base no veredicto anterior, ele age sobre contexto obsoleto (F5, loop descontrolado ou contexto obsoleto). Executaria `checkAuthority` e as pré-condições de novo quando o run é retomado, e trataria uma aprovação como uma entrada dessa segunda verificação, nunca como substituta dela. A aprovação diz que uma pessoa aceitou a chamada exata. Não diz que o mundo continua como era.

O formato de uma chamada

A sequência abaixo mostra o caminho completo do reembolso da abertura. Observe onde fica a leitura de propriedade e os dois ramos que terminam sem efeito: a recusa e a aprovação negada.



Políticas: decisões fora do modelo

Uma **política** é uma regra que o gate avalia contra uma chamada proposta. Ela é escrita como dado ou código, nunca como prosa num prompt, e é avaliada em toda chamada. Antes dos exemplos, uma palavra sobre por que eles são políticas e não constantes na ferramenta: uma política muda num ritmo diferente do código da ferramenta. Um teto muda quando as finanças o mudam, uma janela de mudança quando o processo de release a muda, e ninguém deveria precisar fazer o deploy de um agente para fazer qualquer das duas coisas. As políticas são dados com versão, a versão é registrada com o veredicto (o argumento de replay do Capítulo 4), e uma mudança de política é revisada como uma mudança de código.

A notação abaixo é ilustrativa. Não se pretende a sintaxe de configuração de nenhum produto real, e os números são hipotéticos.

```

policy refund_ceiling                                // illustrative notation
  applies to: issue_refund
  rule:      amount_minor <= ceiling_minor_for(currency) // say, a
hypothetical value in minor units per currency
  otherwise: needs_approval, approver: support lead

policy change_window
  applies to: toggle_feature_flag, request_rollback
  rule:      now within the change window of the target service
  otherwise: needs_approval, approver: on-call SRE, request marked
"outside window"

policy environment
  applies to: every write tool of ops-agent
  rule:      call.environment == run.environment
  otherwise: refuse
  also:      production writes always needs_approval, approver: on-call
SRE

```

Cada política responde a uma pergunta diferente. O teto trata do valor, e é a política mais confundida com uma instrução de prompt. A janela de mudança trata do tempo. A política de ambiente trata do lugar: um run iniciado contra um ambiente de staging não deve poder nomear um alvo de produção em um argumento e ter isso aceito. De quem são os dados é uma quarta pergunta, e não tem política aqui de propósito: é `checkAuthority`, escrita uma só vez, e uma política que a repetisse seria uma segunda cópia com sua própria forma de divergir. As três políticas leem fatos do run e dos serviços. Nenhuma lê nada que a proposta diga sobre si mesma.

Combinando políticas

Quando várias políticas se aplicam a uma chamada, a regra de combinação precisa ser declarada e fixa. A que usaria é negar por padrão e a mais estrita vence. Se qualquer política recusa, a chamada é recusada. Caso contrário, se qualquer política diz needs approval, a chamada precisa de aprovação. Caso contrário, a chamada é permitida, e só porque ao menos um grant correspondeu. Uma chamada que nenhuma política menciona e nenhum grant cobre é recusada, e é assim que uma ferramenta nova fica sem autoridade até que alguém a escreva.

```
function evaluatePolicies(run, call, authority):
    facts = loadFacts(run, call)           // read once, not once
    per policy
    outcomes = []
    for each policy in policiesFor(call.tool, policyVersion()):
        outcomes.append(policy.evaluate(run, call, facts))
    refusals = [o for o in outcomes if o.kind == "refuse"]
    approvals = [o for o in outcomes if o.kind == "needs_approval"]
    if refusals is not empty:
        return { kind: "refuse", reason: "not_permitted", policy:
refusals[0].policy }
    if approvals is not empty:
        return { kind: "needs_approval", request: buildRequest(call,
approvals) }
    return { kind: "allow", call: withAuthority(call, authority) }
```

Veja o que `evaluatePolicies` devolve em `allow`: a chamada carrega a autoridade que a justificou. Essa autoridade é aquilo a que a credencial terá escopo. O gate que decide e a credencial que impõe concordam, assim, por construção, já que ambos vêm do mesmo registro.

O que a camada de políticas não faz

Um motor de políticas decide se uma chamada está dentro da autoridade. Não decide se a chamada é sensata. Um reembolso do valor certo para o cliente certo, por um motivo que o cliente inventou, passa por todas as políticas acima. Isso é questão para as pré-condições do contrato (Capítulo 6), para as verificações de evidência (Capítulo 4) e para uma pessoa quando o risco pede (Capítulo 15). Resistiria à tentação de continuar acrescentando políticas até o motor cobrir tudo. Um motor de políticas que cresce até virar um sistema de regras de negócio se torna uma segunda aplicação que ninguém possui.

Aviso: Se uma propriedade de segurança, ou de movimentação de dinheiro, de uma ferramenta existe apenas como uma frase na descrição da ferramenta ou no prompt de sistema, ela não é um controle. A descrição é um pedido ao modelo. O teto, a fronteira do cliente e a exigência de aprovação precisam existir em código que o gate executa, e um teste precisa falhar quando um deles é removido.

Emitindo a credencial

Depois que o veredicto é "allow", o orquestrador inicia `effect.apply`, e o gateway de ferramentas cria a credencial no último momento, só para aquela chamada, chama o serviço e devolve o resultado por si mesmo. O bloco a seguir é o lado do gateway de ferramentas em `effect.apply`. Observe a ordem das operações, porque o serviço de credenciais (um componente ilustrativo por trás do gateway de ferramentas; no sistema de referência da Parcelport, é o gateway que emite a credencial) e o serviço de destino são sistemas separados, e nada torna os dois atômicos.

```
function applyWithCredential(run, call):           // the tool gateway's side
of effect.apply
  try:
    credential = credentials.issue(
      service: serviceFor(call.tool),
      scope: call.authority.scope,
      resource: call.authority.resource,
      ttl: shortTtl(),                           // say, a couple of
minutes
      bound_to: hash(call))
    on CredentialUnavailable:
      record(run, "effect_not_started", "credential_unavailable")
      return { code: "upstream_unavailable", retryable: true }
    record(run, "credential_issued", { id: credential.id, scope:
call.authority.scope })
    result = executeTool(call, credential)        // the service validates
the credential itself
    return result                                // intent and effect are
recorded by runStep
```

Percorra os casos de falha. Se a emissão da credencial falha, nada aconteceu e a chamada pode ser repetida sob as regras do Capítulo 14. Se a chamada da ferramenta falha ou expira depois que a credencial foi emitida, não há nada a revogar: a credencial expira sozinha, e é por isso que a duração é curta. Se `executeTool` expira e o resultado é desconhecido, o contrato decide o que vem a seguir, e para `issue_refund` isso significa verificar o status do reembolso antes de qualquer retry. O registro guarda o id da credencial, nunca o valor dela, de modo que quem lê o trace vê o que foi emitido sem poder usá-lo.

Repare no que não existe: uma etapa de revogação que precise dar certo para o design estar correto. Um design que precisa de uma chamada de limpeza chegando a outro sistema para estar correto é um design que falha no dia em que essa chamada falha.

O agente de operações: ler amplo, escrever estreito

O agente de operações vira o mesmo padrão do avesso. O trabalho dele é olhar muito mais do que o agente de suporte: logs, métricas, traces, documentos internos. Uma investigação que não enxerga a linha de log de que precisa é uma investigação ruim. Então o formato certo de autoridade é leituras amplas, escritas estreitas e mudanças aprovadas em produção.

Ferramenta	Formato da autoridade	Por quê
query_logs	Leitura, intervalo de tempo limitado, com escopo para os serviços do incidente	A amplitude é útil, mas a amplitude ilimitada lê os logs de todos os serviços sem motivo
get_metrics	Leitura, com escopo para os serviços do incidente	Mesmo raciocínio, risco menor
get_trace	Leitura por trace id	Um trace pode conter dados de muitos runs; os capítulos 20 e 17 tratam do que ele deve conter
search_docs	Leitura pelo server MCP de documentação	Somente leitura por construção (Capítulo 8)
run_diagnostic	Nenhuma credencial	O sandbox é a fronteira (Capítulo 19)
open_pull_request	Escrita no code host, um repositório, um prefixo de branch que o agente possui, sem merge	Uma pessoa faz o merge, então a escrita é uma proposta a uma pessoa
toggle_feature_flag	O agente não detém credencial; aprovação exigida	O deploy-service age, com a credencial de deploy, depois que Robin aprova
request_rollback	O agente não detém credencial; aprovação exigida	O mesmo, e a política exige aprovação seja qual for a evidência

Duas observações. Primeiro, a credencial de deploy é usada pelo `deploy-service` em nome do agente de operações, e o agente nunca a detém. O caminho até a produção passa pela aprovação e por um serviço que possui a credencial, e o agente não consegue ampliá-lo propondo algo criativo. Segundo, `run_diagnostic` é o exemplo mais limpo de autoridade mínima: não precisa de credencial porque o sandbox não tem nenhuma para dar. Quanto menos uma ferramenta precisa, menos ela pode perder.

Leituras amplas não são de graça. Os logs contêm coisas que não deveriam (um identificador de cliente numa linha de requisição, um erro que repete um campo), e uma linha de log também é texto que pode carregar instruções. Um agente de leitura ampla precisa, portanto, mais dos controles de tratamento de dados do Capítulo 17 e dos controles de injeção do Capítulo 16 do que um agente estreito, já que mais material chega ao contexto dele. A autoridade diz o que o agente pode abrir. Não torna seguro de ler o que ele abre.

Passar o trabalho a uma pessoa

Algumas propostas estão dentro do que o agente pode tentar, mas além do que ele pode fazer sozinho. O padrão é o terceiro veredicto, `"needs_approval"`, e a contribuição deste capítulo é uma distinção que acho útil: o gate deve separar “além da autoridade, mas uma pessoa poderia concedê-la” de “além da autoridade, e nenhuma pessoa deveria concedê-la por este caminho”.

O reembolso acima de `refund_ceiling` é do primeiro tipo. Sam, responsável pelo suporte, detém a autoridade para aprová-lo, e uma aprovação assinada para aquela chamada exata se torna uma autoridade estreita, de uso único, acima da delegação. O reembolso entre clientes é do segundo tipo. Não há aprovador para ele. Sam não aprovaria um reembolso na conta de um cliente para o pedido de outro cliente sem um processo diferente, e uma tela de aprovação que oferecesse um botão para isso estaria convidando a um clique reflexo. Essa chamada é recusada. Ela não é escalonada a uma pessoa com um pedido para aprovar algo que ninguém deveria aprovar.

Escreveria a regra como um pequeno teste do design do gate. Para cada razão de recusa no gate, pergunte se existe alguma pessoa com legitimidade para anulá-la pelo serviço de aprovação. Se sim, a razão provavelmente é um `needs_approval` e o aprovador é nomeado. Se não, é uma recusa e ninguém é consultado. Um gate que envia tudo para uma pessoa fez da pessoa o controle e da fila o gate.

O Capítulo 15 trata do que torna uma aprovação real. Aqui o ponto é apenas que uma aprovação é uma delegação de uma pessoa a uma única chamada, mais estreita que a autoridade do próprio aprovador, como toda de-

legação deve ser.

Revisando o modelo de autoridade

Um modelo de autoridade se degrada a menos que alguém olhe para ele. A direção usual do desvio é a de ampliar: um escopo é acrescentado para destravar um ticket, e ninguém o retira. Quatro hábitos mantêm o modelo honesto, e cada um custa tempo a uma equipe que já está ocupada.

Um inventário de autoridade. Uma tabela, de responsabilidade da equipe de plataforma, com uma linha para cada agente, ferramenta e serviço: qual escopo detém, qual condição de recurso se aplica, qual duração de credencial, qual política o cobre. É a primeira coisa que Jordan, da equipe de segurança, pediria numa revisão, e escrevê-la expõe as ferramentas que não têm linha. Uma ferramenta sem linha não tem autoridade documentada e não deveria ter autoridade alguma.

Testes que cruzam a fronteira. O gate é uma função, então teste-o como tal. Para cada ferramenta, o golden set (Capítulo 21) deve incluir casos que cruzam a fronteira de um cliente, uma delegação expirada, uma consulta ao proprietário que falha, uma chamada um pouco acima do teto e uma chamada fora da janela de mudança, cada uma com o veredicto esperado. O teste que mais importa é o que remove uma política e espera uma falha. Uma suíte que continua passando depois que a verificação de propriedade em `checkAuthority` é apagada não prova nada sobre a fronteira.

Evidência de uso. O registro deve mostrar, para cada chamada, a delegação, a versão da política, o veredicto e o id da credencial. Com isso você pode perguntar quais grants nunca foram usados (candidatos à remoção), quais razões de recusa ocorrem e com que frequência. Um gate que nunca recusa nada não é evidência de bom comportamento. É um motivo para olhar: pode significar que o modelo propõe apenas chamadas válidas, ou que as verificações não rodam. As recusas por `not_permitted` são sinais sobre propostas, e um aumento nelas merece atenção antes de merecer uma correção.

Um ritmo de revisão atado à mudança. Revise o inventário quando uma ferramenta é acrescentada, quando um escopo é acrescentado, quando uma política muda e quando um agente ganha um novo serviço. Uma revi-

são periódica (digamos, trimestral) pega o que esses gatilhos deixam passar. As duas custam a atenção da equipe, e prefiro gastar pouco com frequência a descobrir um grant amplo durante um incidente (Capítulo 23).

Uma distinção vale ser verificada em toda revisão. Tanto o gate quanto o serviço proprietário devem recusar uma chamada sujeita a aprovação que não tenha aprovação válida, com o serviço devolvendo `approval_required` mesmo que o gate seja contornado. A primeira é a decisão e a segunda é a imposição; são duas verificações, e manteria as duas para que um defeito numa não remova a outra. Se o motor de políticas e o gateway de ferramentas são um único componente, como na Parcelport, a segunda verificação precisa viver no serviço proprietário ou num gateway separado do motor, ou então é a mesma verificação duas vezes.

Trade-offs e custos

Custa uma leitura extra em toda chamada. A verificação de propriedade lê o serviço proprietário antes do efeito. Isso é latência em cada chamada e uma dependência que precisa estar disponível: se o `orders-service` está fora do ar, as chamadas que precisam de um proprietário são recusadas. Acho que recusar é o certo, e isso significa que um gate confiável também é um gate que falha fechado, algo de que o on-call precisa ser avisado.

Custa um novo sistema a manter disponível. O serviço de credenciais fica no caminho de todo efeito. Se ele está indisponível, o agente não pode agir. Para uma pergunta de suporte somente de leitura, isso pode ser um modo degradado aceitável (respostas sem ferramentas, conforme o Capítulo 14), e para um reembolso é uma parada. A equipe de Alex é responsável por essa disponibilidade, e ela precisa de um responsável, de um alerta e de um modo degradado declarado.

Custa manutenção de políticas. Uma política tem um responsável e uma revisão, e um teto que ninguém ajustou é teatro. Quando as finanças mudam o teto e a política não acompanha, o gate impõe a regra de ontem com plena confiança. Trate cada política como algo de que uma pessoa nomeada responde.

Custa atrito para as pessoas. A autoridade por recurso vai recusar casos que um token amplo teria atendido: o pedido do parente na abertura. O suporte terá de tratá-los com um processo humano, e a mensagem de recusa ao cliente precisa ser escrita com cuidado. Algumas dessas recusas são o controle funcionando. Se a contagem é alta, o modelo de delegação pode não corresponder a como os clientes realmente compram, e essa é uma questão de produto que a equipe deve ouvir.

Quebra no vínculo de identidade. Tudo aqui se apoia em a delegação estar correta. Se o vínculo entre ticket e cliente é fraco, as verificações por recurso verificam a coisa errada com precisão. Nenhum controle posterior conserta isso.

Quando não usar tudo isso. Um agente interno, de propósito único, com uma ferramenta de leitura e nenhuma escrita não precisa de um serviço de credenciais nem de um motor de políticas completo. Um gate enxuto (esquema, allowlist, propriedade), um token estático, estreito e somente de leitura e um escopo documentado são proporcionais, e construir todo o aparato para ele é um custo por si só. O padrão compensa o preço quando o agente pode mover dinheiro, alcançar dados de outra parte ou alterar a produção. O princípio da agência mínima do Capítulo 1 vale também para o sistema de controle: dimensione-o pelo risco.

Erros comuns

Deixar o modelo fornecer o principal. Um argumento como `customer_id` numa ferramenta faz da saída do modelo a fronteira. É tentador porque a ferramenta então funciona para qualquer cliente sem encaenamento extra. Remova o argumento onde não houver razão legítima para variá-lo, e tome o cliente do run.

Um token por agente, “por enquanto”. É tentador porque o protótipo precisa funcionar hoje. Ele fica porque nada quebra, e o primeiro sinal de problema é um F7. A correção é emitir uma credencial por chamada. Dá mais trabalho na primeira semana e muito menos na semana em que uma revisão de incidente pergunta o que o agente conseguia alcançar.

Verificar a autoridade uma vez, no início. Um run que verifica no passo um e age no passo nove tem uma janela de autoridade obsoleta, sobretudo depois de uma suspensão para aprovação. É tentador porque o passo um é

onde o pedido é mais fácil de inspecionar. Verifique no gate em toda chamada e de novo ao retomar.

Tratar a aprovação como autoridade para fazer qualquer coisa. Uma aprovação cobre uma chamada exata. É tentador porque uma aprovação assinada é fácil de armazenar e reutilizar. Se ela pode ser reutilizada para um valor diferente, um pedido diferente ou um retry posterior, ela ampliou a delegação em vez de estreitá-la. Ate-a à chamada (Capítulo 15).

Enviar toda recusa a uma pessoa. Parece cauteloso. Treina os aprovadores a clicar e lhes pede que aprovem coisas que ninguém deveria aprovar. Separe as recusas que têm aprovador das que não têm.

Repetir detalhes nas recusas. É tentador porque um erro útil poupa uma ida e volta, mas um erro que diz “that order belongs to another customer” diz ao modelo, e através dele a quem quer que o esteja conduzindo, que o pedido existe. Mantenha a observação mínima e ponha o detalhe no registro.

Um motor de políticas que ninguém testa. É tentador porque a política parece configuração, e não código. Uma mudança sem um teste que falhe na remoção é uma mudança que ninguém consegue revisar. Dê a cada política um teste que falhe quando a regra é removida.

Pontos-chave

- A autoridade pertence à credencial e ao código que decide usá-la, e o prompt apenas reduz a taxa de propostas que pedem mais do que a tarefa deveria ter.
- A autoridade efetiva de uma chamada é a interseção da identidade do agente, da delegação do cliente ou do engenheiro e do escopo da tarefa, o que significa que o agente nunca pode fazer o que o seu delegante não poderia.
- A identidade do delegante é atribuída pelo orquestrador a partir do vínculo autenticado do ticket e armazenada no run, e a saída do modelo nunca a define.
- Aplique a autoridade mínima por ferramenta, por recurso e por run: a verificação por recurso é o que pega o confused deputy, e credenciais de curta duração limitam o que um vazamento vale.

- Tome a decisão em toda chamada num motor de políticas fora do modelo, com negação por padrão e o resultado mais estrito vencendo, e registre a versão da política e o id da credencial com cada veredicto.
- Use `needs_approval` apenas onde existe uma pessoa com legitimidade para conceder, recuse o resto, e verifique a autoridade de novo quando um run suspenso for retomado.
- Dê ao agente de operações leituras amplas e limitadas e escritas estreitas e aprovadas, com as credenciais de deploy mantidas pelo `deploy-service` e nunca pelo agente, e revise o inventário de autoridade sempre que uma ferramenta, um escopo ou uma política mudar.

Tudo até aqui supôs que as ferramentas pertencem à Parcelport e que o gate vê os contratos delas. O Capítulo 8 trata do caso em que uma ferramenta, a descrição dela e a saída dela vêm de um server operado por outra pessoa.

Capítulo 8 — MCP: ferramentas através de uma fronteira de confiança

Imagine a equipe de plataforma da Parcelport numa quinta-feira tranquila de manhã. O agente de operações tem sido útil com a sua busca na documentação, e uma pessoa da engenharia propõe uma segunda integração: um server de terceiros que oferece auxiliares de runbook, modelos de incidente e algumas ferramentas de consulta. O server fala o Model Context Protocol, então conectá-lo exige uma única entrada na configuração do orquestrador. No fim da tarde, o agente de operações tem uma lista maior de ferramentas. Ninguém leu as descrições com atenção, porque ninguém precisou: o protocolo as entregou e o modelo já podia usá-las.

Suponha que, uma semana depois, o fornecedor lance uma atualização. A descrição de uma ferramenta é reescrita e aparece uma ferramenta nova, capaz de escrever no produto de ticketing do próprio fornecedor. Nada mudou no código da Parcelport. A lista de ferramentas que o modelo vê mudou. Robin, o SRE de on-call, só percebe quando o trace do run mostra a chamada de uma ferramenta que ninguém lembra de ter aprovado.

Este capítulo pertence a duas partes do envelope de controle. Para o que chega de um server, é **Contexto**: de onde veio esta peça e até que ponto se pode confiar nela? Para o que se pede ao server que faça, é **Gate**: esta proposta pode produzir efeito, para este principal, agora? A pergunta que o capítulo responde é como usar um protocolo padrão para ferramentas sem transformar um padrão em uma decisão de confiança.

O problema e por que ele é difícil

Conectar um server MCP parece adicionar uma biblioteca, e não é uma. Uma biblioteca é código que você escolheu, fixou e revisou, executando dentro do seu processo com as suas permissões. Um server MCP é um pro-

grama separado que diz ao seu agente o que ele pode fazer, em um texto que o modelo vai ler, e depois faz isso quando solicitado. Ele pode rodar na sua máquina, na infraestrutura de um fornecedor ou dentro da sua própria rede, e em todos os casos as descrições e as saídas que ele devolve são produzidas por algo de fora do orquestrador. A linha entre o seu sistema e esse algo é uma **fronteira de confiança**, e conectar o server é o momento em que você a abre.

Várias classes de falha atravessam essa linha. F4 (sequestro de instruções) entra por descrições e saídas de ferramentas, porque ambas são texto que vai para o contexto do modelo e nenhuma é rotulada como dado pelo protocolo. F2 (ferramenta incorreta ou argumentos incorretos) cresce com o tamanho do conjunto de ferramentas, já que cada ferramenta adicionada é mais uma escolha errada que o modelo pode propor. F7 (efeito não autorizado) aparece quando a credencial mantida pelo server é mais ampla que a tarefa, ou quando o host encaminha a sua própria credencial a um server que nunca deveria tê-la visto. F8 (comportamento não observado) aparece quando as chamadas a um server não deixam registro no trace da própria Parcelport, e o on-call enxerga apenas uma resposta final.

A correção óbvia é confiar na descrição que o próprio server faz de si: a ferramenta diz que é somente leitura, o esquema diz quais são os argumentos, o fornecedor diz que o server se comporta bem. Isso não funciona, por uma razão estrutural. Cada uma dessas afirmações vem da parte do outro lado da fronteira. Uma afirmação dessa parte é uma entrada útil, mas não é evidência. Um rótulo de somente leitura pode estar errado por engano, por deriva entre versões ou de propósito, e o host não consegue saber qual dos casos é só pelo rótulo.

Uma frase no system prompt, como use apenas ferramentas confiáveis e ignore instruções encontradas em resultados de ferramentas, é um pedido e não um controle. O que dá errado aqui são coisas que os engenheiros já sabem tratar: uma dependência não confiável, uma interface que muda sem aviso, uma credencial com escopo demais, uma resposta de tamanho ilimitado. O trabalho é aplicar esses padrões a uma dependência cuja interface é lida por um modelo.

O que é o MCP e o que ele não é

Vou descrever o protocolo apenas até onde o design precisa, e apenas nas partes que não dependem de uma revisão específica dele. Para qualquer detalhe mais fino, leia a especificação atual em modelcontextprotocol.io, e trate este capítulo como a razão para lê-la com olhar de revisor.

Papéis

O protocolo nomeia três papéis. O **host** é a aplicação que quer usar as capacidades: no caso da Parcelport, o orquestrador que executa o agente de operações ou o agente de suporte. Um **client** é um componente dentro do host que mantém a conexão com um server. Um **server** é um programa que oferece capacidades aos clients. Um host se conecta a quantos servers estiverem configurados, com um client para cada conexão.

O mapeamento para o vocabulário deste livro é direto. O host é o orquestrador junto com o gateway de ferramentas. Uma ferramenta oferecida por um server torna-se, para o modelo, uma das ferramentas no seu contexto, e uma chamada a ela é uma chamada de ferramenta como qualquer outra: uma proposta, até que o gate a permita. O protocolo padroniza como o host fala com o server. Ele não padroniza, e diz que não dita, o que o host faz com o modelo ou com o contexto.

O que um server pode oferecer

Um server oferece três tipos de coisas, chamadas primitivas. **Tools** são operações que o modelo pode pedir ao host que invoque. **Resources** são pedaços de dados que o host pode ler e decidir como usar. **Prompts** são modelos que um server oferece para iniciar uma interação. A documentação do próprio protocolo descreve tools como controladas pelo modelo, resources como controlados pela aplicação e prompts como controlados pelo usuário, o que é uma boa maneira de lembrar quem deve selecionar cada um.

Os três importam para quem revisa, por um motivo comum: cada um é conteúdo que se origina fora do orquestrador e pode acabar diante do modelo. Uma definição de ferramenta é texto. Um resource é texto ou dado. Um modelo de prompt é texto que o usuário pode acionar e que carrega a

redação do autor do server. O Capítulo 9 trata do que entra na janela de contexto e de como é rotulado; este capítulo trata do fato de que essas três entradas existem e não são suas.

Transports, capabilities e autorização


Há mais de um transport. Um server pode rodar como um processo local que o host inicia e com o qual conversa por entrada e saída padrão, ou como um serviço remoto que o host alcança por HTTP. A diferença muda a questão de segurança. Um server local é código que roda na sua máquina com o acesso que o seu processo tiver, então é uma questão de sandbox (Capítulo 19) tanto quanto de protocolo. Um server remoto é uma dependência de rede que vê cada chamada e cada argumento que você envia, então é também uma questão de divulgação de dados (Capítulo 17).

Client e server também trocam informações sobre o que cada lado suporta, para que nenhum tente operações que o outro não consegue tratar. Isso é a **negociação de capabilities**. Ela informa o que um server diz que pode fazer, o que é útil para compatibilidade e não traz nenhuma informação sobre se você deve permitir.

A autorização é um conceito do protocolo e é descrita como opcional. A documentação a recomenda quando um server toca dados específicos de um usuário ou quando você precisa auditar quem fez o quê, e se apoia em convenções do OAuth para servers remotos. Para servers locais, a documentação aponta para credenciais obtidas do ambiente ou de bibliotecas embutidas no server. A leitura prática para este capítulo: o protocolo oferece um meio para que um server saiba quem está chamando e delimite o que essa pessoa ou esse sistema pode fazer. Se isso está ligado, e o que os escopos significam, é configuração de que alguém na Parcelport é responsável.

Nota: Um server também pode oferecer ao host uma forma de alterar a sua lista de ferramentas enquanto uma conexão está aberta, e um host pode optar por ser avisado disso. Trate isso como um fato do ambiente, e não como um recurso a ser habilitado por padrão: uma lista de ferramentas que pode mudar é uma lista de ferramentas que precisa ser verificada a cada mudança.

A topologia abaixo mostra o que observar: um host, vários servers e a linha tracejada onde fica a fronteira de confiança. Tudo o que está à direita dela está fora do controle do orquestrador.



As linhas contínuas são o fluxo de controle da própria Parcelport; as tracejadas são as conexões que atravessam a fronteira. Ambos os servers enviam definições e resultados de volta ao loop, e é por isso que a entrada do loop vinda deles não é confiável, qualquer que seja o lado da empresa em que o server esteja.

O que o protocolo resolve e o que ele deixa com você

O MCP resolve um problema de integração. Sem um padrão, cada par formado por um agente e um provedor de ferramentas precisa de um conector próprio, e cada conector traz as suas convenções para listar, chamar e descrever ferramentas. Com ele, uma única implementação de client pode conversar com muitos servers, e um server escrito uma vez pode atender a muitos hosts. Isso tem valor real, e o livro não argumenta contra isso.

Ele não resolve a confiança. A tabela lista, para cada coisa que atravessa a fronteira, o que o protocolo oferece e o que continua com você.

O que atravessa, ou de que você precisa	O que o protocolo oferece	Trate como, e o que continua sendo seu
O próprio server	Uma forma de conectar	Uma afirmação de identidade; um allowlist de servers, com alguém responsável
Nome, descrição e esquema de entrada da ferramenta	Uma lista do que o server oferece	Texto não confiável que o modelo vai ler; um allowlist de ferramentas e uma definição fixada

O que atravessa, ou de que você precisa	O que o protocolo oferece	Trate como, e o que continua sendo seu
Dicas sobre a ferramenta, como um rótulo de somente leitura	Anotações opcionais	Uma afirmação; a especificação diz para considerar essas dicas não confiáveis, a menos que venham de um server confiável, então atribua você mesmo a classe de efeito
Uma chamada	Um mecanismo de chamada	Uma proposta; o gate: contrato, política, aprovação
Resultado da ferramenta, conteúdo de resources	Um formato de resultado	Dado não confiável, ilimitado até que você o limite; limites de tamanho, verificações de formato, proveniência, taint (Capítulo 16)
Modelos de prompt	Uma forma de oferecê-los	Texto não confiável escolhido por outra parte
Aviso de que a lista de ferramentas mudou	Uma notificação	Um sinal para verificar de novo, não para aceitar
Argumentos de uma chamada	Nada	Dados que você divulga; podem incluir PII (Capítulo 17)
Credencial	Convenções de autorização	A coisa mais sensível da lista; emita-a de forma restrita, por chamada
O que aconteceu	Nada	O seu próprio registro de cada chamada

O movimento central de design decorre da tabela. O host trata tudo o que um server diz sobre si mesmo como entrada para uma decisão e nunca como a decisão. Duas linhas merecem um olhar mais demorado.

As definições são entradas para o modelo

O nome, a descrição e o esquema de uma ferramenta não são documentação para o host. São contexto para o modelo e moldam quais propostas ele faz. Se uma descrição diz quando a ferramenta é a certa para usar, a escolha do modelo entre as ferramentas é em parte governada pelo texto do autor do server. Quando esse texto muda, o comportamento do seu agente muda, sem nenhuma mudança no seu código, no seu prompt ou no seu modelo.

Essa é a forma de cadeia de suprimentos do problema, e é por isso que o cenário de abertura importa. Um server que foi revisado numa quinta-feira é uma dependência diferente na quinta seguinte se as suas definições se moveram. Os controles são os mesmos que você usaria para qualquer dependência cujas versões você não controla: decidir o que aceita, fixar o que revisou, detectar deriva e colocar uma pessoa no caminho da mudança.

As saídas não são confiáveis, mesmo vindas de um server confiável

Uma saída pode carregar texto que nunca foi escrito pelo autor do server. Um server de documentação serve documentos, e documentos contêm o que quer que os seus autores tenham posto neles. Uma ferramenta de busca devolve trechos de páginas que outra pessoa escreveu. Uma ferramenta de consulta devolve campos que um cliente digitou. O server é honesto e o conteúdo continua sendo dado vindo de fora, com o risco de F4 que o Capítulo 16 desenvolve. Somente leitura limita o que o server pode fazer. Não limita o que a sua saída pode dizer.

O restante do capítulo apresenta, em ordem, os controles que ficam do lado do host da fronteira.

Padrão: a superfície de controle do lado do host

O padrão é uma única ideia com cinco partes: o host decide quais servers existem, quais das suas ferramentas o modelo pode ver, o que cada ferramenta significa, o que cada chamada pode fazer e no que cada resultado pode se transformar. As cinco ficam do lado da Parcelport da linha, e nenhuma depende de o server se comportar bem.

Um allowlist de servers, com alguém responsável

O primeiro controle é uma lista dos servers aos quais o orquestrador pode se conectar, mantida como dado, com um responsável e uma razão para cada entrada. Um server que não está na lista não é conectado, qualquer que seja a configuração de um agente isolado. É um allowlist simples, e é entediante de propósito: adicionar um server passa a ser uma mudança revisada, com um nome associado, e não uma linha na configuração local de alguém da equipe de desenvolvimento.

A notação abaixo é ilustrativa, não a sintaxe de configuração de um produto real.

```
policy mcp_servers:                // illustrative notation
  docs:
    transport: local network        // inside Parcelport
    owner: platform team
    effect ceiling: read            // no tool may exceed this
    credential: none                // read-only, no tokens issued
    max result: 8 KB                // illustrative
    agents: [ops-agent, support-agent]
  vendor_runbooks:
    transport: remote
    owner: platform team, reviewed by security team
    effect ceiling: read
    credential: scope "runbooks:read", issued per call
    agents: [ops-agent]
    max result: 16 KB              // illustrative
```

Dois campos fazem a maior parte do trabalho. O teto de efeito declara a classe de efeito mais alta que qualquer ferramenta desse server pode ter, e uma ferramenta que declare mais não é admitida. A lista de agentes reduz o raio de impacto: o agente de suporte nunca vê o server do fornecedor.

Um allowlist de ferramentas e a fixação

Permitir um server não significa permitir tudo o que há nele. O segundo controle é uma lista das ferramentas que o host admite de cada server, junto com uma **fixação** (pin): um fingerprint da definição que foi revisada, calculado pelo host a partir do nome, da descrição e do esquema de entrada como recebidos. Quando o server apresenta depois uma definição diferente com o mesmo nome, o fingerprint deixa de coincidir e a ferramenta não é exposta até que alguém revise a mudança.

A fixação detecta mudança. Não detecta má-fé, e quem revisa pode aprovar uma definição ruim. O que ela elimina é o caminho silencioso: nenhuma reescrita, nenhum argumento adicional e nenhuma ferramenta nova chega ao modelo sem passar por uma verificação humana que deixa registro. É uma garantia modesta e tem o tamanho certo para o problema.

```

function admitTools(server):
    listed = server.client.listTools()           // untrusted input
    admitted = []
    for each definition in listed:
        entry = registry.lookup(server.id, definition.name)
        if entry == none:
            record(server.run, "tool_not_allowlisted", definition.name)
            continue                             // the model never sees
    it
        if fingerprint(definition) != entry.pinned_fingerprint:
            quarantine(server.id, definition.name)
            record(server.run, "definition_changed", definition.name)
            continue                             // wait for a reviewer
        admitted.add(entry.contract)            // host-owned text, see
below
    return admitted

```

Observe a última linha. O que entra no contexto do modelo não é a descrição do server. É a descrição do contrato próprio do host para aquela ferramenta, o que nos leva à terceira parte.

Um contrato de propriedade do host para cada ferramenta MCP

Uma ferramenta MCP é uma ferramenta, e uma ferramenta tem um contrato (Capítulo 6). A tentação é deixar o esquema do server fazer as vezes dele, já que o server já fornece um. O esquema cobre o formato dos argumentos e nada além disso. Ele não diz nada sobre classe de efeito, pré-condições, permissões, timeouts ou o formato de erro, e esses são os campos que tornam uma chamada passível de passar pelo gate.

Escreveria o contrato dentro da Parcelport, trataria o esquema do server como uma entrada para ele e mostraria ao modelo a descrição do contrato, e não a do server. A classe de efeito é atribuída pela Parcelport, na mesma tabela das ferramentas nativas, e a dica do próprio server é, no máximo, um motivo para olhar com mais atenção. Eis o contrato de `search_docs`, que o server MCP de documentação fornece, na notação usada no Capítulo 6.

```

tool search_docs
  description: "Search Parcelport's internal runbooks, policies and shipping
    rules. Returns short passages with a document id."  // written by
Parcelport
  input schema:
    type: object, additionalProperties: false
    required: [query]
    properties:
      query: { type: string, maxLength: 300 }          // illustrative
  limit
    limit: { type: integer, minimum: 1, maximum: 10 }
  effect class: read
  preconditions:
    - server "docs" is admitted and its definition matches the pin
    - agent identity is ops-agent or support-agent
  idempotency: // not applicable: a read changes nothing
  permissions: no credential; allowed for both agents
  timeouts: call 5s, deadline 15s  // illustrative
  error shape: { code, message, retryable, details }
    // code in [invalid_arguments, not_permitted, upstream_unavailable,
    //   result_invalid] (result_invalid is the one addition to Chapter 6's
    table)

```

O contrato é mais estrito do que seria o esquema de um server. Ele limita o tamanho da consulta, limita o número de resultados, nomeia os códigos de erro e declara o que precisa valer antes da chamada. Um server cujo esquema permitisse mais continuaria sendo chamado com no máximo o que o contrato permite. Se o server mudar o seu esquema, a fixação detecta. Se o esquema do server for mais frouxo que o contrato, o contrato prevalece.

O gate para uma chamada MCP

Uma chamada de ferramenta MCP passa pelo mesmo gate que todas as outras, no mesmo loop. Não há um caminho separado para ferramentas “externas”; todo o sentido do contrato de propriedade do host é que o gate não precisa saber onde a ferramenta mora. O que o gate acrescenta para essa origem são duas verificações: que a ferramenta está admitida e ainda coincide com a sua fixação, e que o próprio server está em boa situação.

```

function checkMcpCall(run, proposal):                // a branch of
gate.check
    entry = registry.admitted(proposal.tool)
    if entry == none:
        return { kind: "refuse", reason: "not_in_choice_set" } // not
admitted, so never offered to this run
    if not conformsTo(proposal.arguments, entry.contract.input_schema):
        return { kind: "refuse", reason: "invalid_arguments" }
    if registry.isQuarantined(entry.server_id, proposal.tool):
        return { kind: "refuse", reason: "not_permitted" } // record:
definition_changed
    if breaker.isOpen(entry.server_id):
        return { kind: "refuse", reason: "upstream_unavailable" } //
retryable
    // policy decides: ceilings, agent identity, tenant, approval
    verdict = policy.evaluate(run.agent_identity, entry.contract,
proposal.arguments)
    return verdict                // "allow", "refuse" or "needs_approval"

```

A função é uma visão parcial do gate do Capítulo 5. Ela devolve um dos três veredictos do loop canônico, e as suas recusas usam os nomes de razão desse gate (`not_in_choice_set`, `not_permitted`, `invalid_arguments`, `upstream_unavailable`; o Apêndice os lista); `definition_changed` e `tool_not_allowlisted` são eventos de registro, não códigos que o modelo vê. `runStep` não muda: uma recusa volta ao modelo como observação, uma requisição de aprovação suspende o run e, para uma chamada permitida, o orquestrador inicia `effect.apply`, que é onde está a próxima parte. A linha `breaker.isOpen` aponta para o Capítulo 13 e está aqui porque um server remoto que falha é uma dependência como qualquer outra.

Efeito: uma credencial restrita e um resultado limitado

Quando o gate permite uma chamada, o orquestrador inicia `effect.apply`, e o gateway de ferramentas invoca o server por meio do seu client e devolve o resultado por si mesmo. Duas coisas acontecem de cada lado dessa chamada.

Antes dela, a credencial. A credencial dada a um server é emitida por chamada pelo gateway de ferramentas, limitada ao que a ferramenta precisa e de curta duração (o Capítulo 7 desenvolve a autoridade e o Capítulo 18 desenvolve os secrets). O host não encaminha ao server a credencial que usa para os seus próprios fins, nem a do usuário. A orientação de autorização do protocolo nomeia o token passthrough como um padrão a evitar, e o raciocínio é o confused deputy do Capítulo 7: um token destinado a uma

parte não deve ser aceito por outra nem enviado a ela. Para um server de documentação somente leitura dentro da Parcelport, a resposta é nenhuma credencial, que é a melhor resposta possível.

Depois dela, o resultado. Tudo o que o server devolve é limitado e verificado antes de se tornar uma observação.

```
function applyMcpCall(run, call):                                // the tool gateway's
side of effect.apply
    entry = registry.admitted(call.tool)
    credential = toolGateway.issue(run, entry.contract, call)    // per call
    raw = entry.client.invoke(call.tool, call.arguments,
                                credential: credential,
                                deadline: entry.contract.timeouts.deadline)
    // every failure below leaves a record and a typed error, never a guess
    if not matchesShape(raw, entry.result_shape):
        raise ResultInvalid                                     // checked before any
trimming
    note = "none"
    if size(raw) > entry.max_result:
        raw = dropExcessItems(raw, entry.max_result) // keeps the shape
valid
    note = "truncated"
    if size(raw) > entry.max_result:
        raise ResultInvalid                                     // one item alone is
too large
    return { content: raw, note: note,
            provenance: { source: "mcp", server: entry.server_id,
                        tool: call.tool, pin: entry.pinned_fingerprint },
            trust: "untrusted" }                                // taint travels with the
value
```

O bloco não resolve a injection. Ele faz a parte que cabe a este capítulo: o tamanho é limitado antes que o contexto cresça, o formato é verificado antes que o conteúdo seja usado, e o resultado carrega a sua proveniência e uma marca de taint, para que o montador de contexto (Capítulo 9) e os controles de injection (Capítulo 16) tenham algo sobre o que agir. Um timeout ou uma falha de transporte levanta um erro tipado que as regras de retry do Capítulo 14 tratam, e a chamada não deve ser tratada como tendo falhado de forma limpa quando a ferramenta pode ter alterado alguma coisa. Para ferramentas de leitura, essa distinção não custa nada. Para uma ferramenta de escrita em um server, é o mesmo problema de idempotência de `issue_refund` no Capítulo 6.

Aviso: Nunca coloque as credenciais do próprio host, o token do usuário ou qualquer secret no texto que o modelo vê ao descrever ou chamar uma ferramenta MCP, e nunca aceite o pedido de um server por credenciais mais amplas como preço de um recurso. Uma credencial que chega ao server errado é a perda da capacidade de dizer quem podia fazer o quê.

Prefira servers somente leitura e mantenha pequeno o conjunto de ferramentas

O controle mais barato deste capítulo é escolher servers cujas ferramentas não conseguem alterar nada. Um server somente leitura ainda pode induzir o modelo ao erro, mas não consegue causar F7 sozinho, e as suas piores falhas são F3 (afirmação sem fundamento) e F4, que têm outros controles. Quando um server oferece leituras e escritas, admitiria apenas as leituras, usando o allowlist de ferramentas. Vale também emitir uma credencial restrita, somente leitura, mas ela não é um substituto: o server remoto é quem a aplica, de modo que depende da honestidade desse server e não é um controle do lado do host.

Trate isso como uma preferência de design e verifique. Um server que se descreve como somente leitura está lhe dando uma afirmação. A verificação é do seu lado: o teto de efeito na política do server, um allowlist que nunca admite as ferramentas de escrita, uma credencial que concede apenas escopos de leitura para os recursos da própria Parcelport e, para os seus próprios servers, o código em si. Só os dois primeiros e o código impedem uma escrita; um escopo de credencial é aplicado por quem recebe a credencial, então, com um server de terceiros, é um pedido que o outro lado atende, não um controle do lado do host.

O tamanho do conjunto de ferramentas também é um controle. Cada ferramenta que o modelo vê custa contexto e amplia o espaço de escolhas erradas, então F2 cresce com o número de ferramentas. Digamos que um server exponha trinta ferramentas quando o agente precisa de três; isso é um problema de design, seja qual for a sua conformidade com o protocolo. O allowlist é onde você corta: exponha as ferramentas de que uma tarefa precisa, ao agente que precisa delas. A regra do Capítulo 4 sobre estreitar o leque de escolha se aplica aqui sem alteração.

Observação

Toda chamada a um server MCP recebe um registro no run store e no pipeline de trace da própria Parcelport: o server, a ferramenta, a fixação em vigor, o formato dos argumentos, o veredicto, o tamanho do resultado, a latência e qualquer truncamento ou rejeição. Os logs do server são do server. Se uma chamada a um terceiro importa em um incidente, a única evidência com que você pode contar é a que você escreveu do seu lado da linha. Essa é a parte Registro do envelope, e o Capítulo 20 dá o formato do trace.

O registro também alimenta o allowlist. Uma ferramenta que nunca é chamada depois de um mês é candidata a remoção, e uma ferramenta que é recusada com frequência está mal descrita ou mal delimitada.

Parcelport: o server de documentação e uma definição alterada

Volte à abertura. A Parcelport tem dois servers MCP em jogo. O primeiro é o server de documentação interno, o server somente leitura sobre runbooks, políticas e regras de envio, que é a origem de `search_docs` para os dois agentes. O segundo é o auxiliar de runbooks do fornecedor. Veja como os controles se comportam em cada um.


O server de documentação está no allowlist com um teto de efeito de leitura e sem credencial. A Parcelport admite uma ferramenta dele, `search_docs`, com um contrato de propriedade do host e uma fixação. No momento em que escrevo, o Contextator é um exemplo de server de documentação cujas ferramentas MCP são todas somente leitura, de modo que nada que um client peça a ele pode alterar estado; outras ferramentas adotam abordagens semelhantes. Essa propriedade é o que faz dele o server mais fácil de admitir, e é também o motivo pelo qual a sua saída ainda recebe um limite de tamanho, uma verificação de formato e uma marca de taint. Um documento pode conter instruções que o seu autor nunca destinou a um agente, e o controle para isso é o do Capítulo 16, não o do server.

O server do fornecedor parte da ponta oposta. A sua entrada é limitada ao agente de operações, com um teto de efeito de leitura e um escopo de credencial `runbooks:read`, emitido por chamada. Quando o fornecedor lança

a atualização, `admitTools` lista as definições, descobre que um fingerprint não coincide mais com a fixação e coloca essa ferramenta em quarentena. A ferramenta nova, capaz de escrever no produto de ticketing do fornecedor, não tem entrada no allowlist, então o modelo nunca a vê. O trace de Robin mostra um registro `definition_changed` e um registro `tool_not_allowlisted`, e uma mensagem para a fila de revisão da equipe de plataforma. O agente de operações continua funcionando com as outras ferramentas.

Agora considere o que aconteceria se a quarentena não existisse. O modelo poderia ter proposto a ferramenta nova; o gate a teria recusado como `not_in_choice_set`, e o run teria se recuperado. As camadas que ficam do lado da Parcelport são o allowlist, que tira a ferramenta de vista, o gate, que a recusa se o allowlist for contornado, e o teto de efeito, que faz a revisão rejeitá-la. Nenhuma delas precisa que o modelo se comporte bem, e nenhuma depende do fornecedor. A credencial `runbooks:read` é um tipo diferente de camada. Ela limita o que aquele token alcança entre os recursos da própria Parcelport e não diz nada sobre o que o server do fornecedor faz dentro dos seus próprios sistemas com a nova ferramenta de escrita, então não conta como barreira contra essa escrita.

Eis a sequência de uma chamada normal e permitida, com os caminhos de recusa marcados. Procure onde o host mantém o controle em cada passo.



O caminho do modelo por essa sequência é o mesmo de uma ferramenta nativa, e esse é o objetivo. O modelo não precisa saber que uma ferramenta mora do outro lado de uma fronteira. O gate precisa.

Escrevendo o seu próprio server MCP

Mais cedo ou mais tarde, uma equipe da Parcelport vai escrever um server próprio, por exemplo um que exponha o status de envio a vários agentes. Escrevê-lo coloca você do outro lado da fronteira, e o server passa a ser o gate das suas próprias ferramentas, porque o host à frente dele pode estar mal configurado, pode ser de outra pessoa ou pode ainda não existir. Dê a cada ferramenta o contrato do Capítulo 6, valide você mesmo as entradas, identifique quem chama e verifique os escopos por ferramenta, e não uma vez por conexão, com a credencial downstream mais restrita de que a ferramenta precisa (Capítulo 7). Quatro disciplinas são específicas deste lado.

- **Rate limits.** Um modelo pode repetir uma chamada rapidamente, e um loop pode repeti-la por muito tempo. Limite por quem chama e por ferramenta, e devolva um erro tipado que o host consiga mapear para uma recusa, de modo que um client descontrolado custe a você uma chamada recusada, e não uma indisponibilidade.

- **Limites de saída.** Limite no server o tamanho do resultado e o número de itens e, sempre que puder, devolva campos estruturados em vez de texto livre. Tudo o que veio de um usuário final continua marcado como tal. Se um server devolve um texto que não escreveu, ele é uma passagem das palavras de outra pessoa e deve dizer isso.
- **Observação.** Registre em log cada chamada com a identidade de quem chama, a ferramenta e o resultado, no seu próprio sistema, já que o trace do host não é algo em que você possa se apoiar.
- **Estabilidade.** Uma definição que muda quebra todo host que a fixou. Versione as suas ferramentas, anuncie as mudanças e evite reescrever descrições sem cuidado, já que uma descrição faz parte da interface.

```
function handleCall(request):                                // server side
    caller = authenticate(request)                          // no anonymous calls
    tool = tools.lookup(request.tool)
    if tool == none:
        return error("invalid_arguments", "unknown tool")
    if not caller.scopes.contains(tool.required_scope):
        return error("not_permitted", "scope missing")
    if not conformsTo(request.arguments, tool.input_schema):
        return error("invalid_arguments", "schema mismatch")
    if limiter.exceeded(caller.id, tool.name):               // per caller, per tool
        return error("upstream_unavailable", "retry later") // retryable:
true, per Chapter 6's table
    result = tool.run(caller, request.arguments)             // downstream
    credential
    audit(caller.id, tool.name, outcome(result))             // the server's own
    record
    return capSize(result, tool.max_result)
```

Este bloco é o espelho, no server, do gate do host, e não o substitui. Se você escreve tanto o server quanto o host, resista ao pensamento de que uma das duas verificações é redundante. Elas falham em condições diferentes.

Trade-offs e custos

Todo controle acima tem um preço, e alguns são pesados o bastante para que não se aplicassem todos a todos os casos.

Revisão e responsabilidade. Um allowlist e fixações transformam cada novo server e cada mudança de definição em um evento revisado. O custo é tempo da equipe de plataforma, uma fila e alguém responsável por cada entrada. Uma mudança na descrição de uma ferramenta do fornecedor

agora exige uma decisão humana antes de chegar à produção. Se ninguém é responsável por essa fila, o controle degrada para um que é sempre aprovado ou ignorado, o que é um teatro de controle pior do que não ter nenhum, porque parece uma garantia. Decida quem revisa e com que rapidez antes de ligar a fixação.

Atrito para a equipe de desenvolvimento. Quem quer experimentar um server novo precisa esperar por uma entrada ou usar um ambiente de desenvolvimento em que o allowlist é mais amplo e nada alcança dados de produção. Ofereceria esse ambiente e manteria clara a linha entre os dois, já que o modo usual de esses controles se corroerem é uma configuração local que silenciosamente se torna a real.

Escrever contratos. Um contrato de propriedade do host para cada ferramenta custa tempo real de engenharia, e precisa ser mantido em sincronia com o server. A alternativa é deixar o texto do server fazer as vezes dele, o que é mais barato até que o server mude. Para um server com duas ferramentas de leitura, o contrato é um arquivo curto. Para um server com, digamos, sessenta ferramentas, o custo é um sinal de que você está admitindo ferramentas demais.

Latência e disponibilidade. Cada chamada atravessa um processo ou uma rede. O gate, a emissão de credencial e as verificações do resultado acrescentam tempo, e um server remoto acrescenta uma dependência cujas indisponibilidades se tornam as suas. Um breaker (Capítulo 13) e um fallback (Capítulo 14) limitam o efeito; não o zeram.

Onde a fixação deixa de ajudar. A fixação protege a definição, não o comportamento. Um server pode manter a definição idêntica e mudar o que a sua ferramenta faz. Nada neste capítulo detecta isso, e não conheço um controle do lado do host que detecte, a não ser observando o próprio efeito. O registro torna essa deriva visível depois do fato. Uma credencial restrita limita apenas o que essa credencial alcança do lado da Parcelport; o que um server de terceiros faz dentro dos seus próprios sistemas é governado pelo server e pelo fornecedor, não por um escopo que o host emite.

Quando não usar tanto. Para um server somente leitura dentro da sua própria rede, escrito e operado pela sua própria equipe, um fluxo completo de fixação é mais maquinário do que o risco justifica. Ainda manteria o

allowlist de servers, o contrato de propriedade do host, os limites de resultado e o registro, e fixaria as definições no pipeline de build em vez de usar uma fila de revisão humana. Em contrapartida, se as ferramentas de um server podem movimentar dinheiro, enviar mensagens ou alterar a produção, nenhuma conveniência justifica pular a revisão, e o efeito pertence atrás de uma aprovação (Capítulo 15), seja qual for a reputação do server.

O que isto não cobre. Um host que ele próprio esteja comprometido, um server que se comporta de forma diferente para quem chama e um documento envenenado que é preciso em todos os campos estão todos fora do que um allowlist e uma fixação conseguem ver. O capítulo reduz o raio de impacto de um server e torna o seu comportamento visível. Não torna um server seguro.

Erros comuns

- **Confiar no rótulo.** É tentador porque quem criou o server conhece melhor a ferramenta, então a dica de somente leitura acaba na classe de efeito. A correção é atribuir classes de efeito na tabela de ferramentas da própria Parcelport e impor um teto de efeito por server.
- **Repassar a descrição do server.** É tentador porque poupa escrever um contrato, então o modelo vê o texto da ferramenta do server. A correção é mostrar o contrato de propriedade do host e usar a definição do server apenas para a comparação com a fixação.
- **Conectar por configuração.** É tentador porque uma linha de configuração é a forma mais rápida de experimentar um server, e a configuração local de alguém da equipe de desenvolvimento pode alcançar a produção. A correção é conectar apenas servers que estão no allowlist central.
- **Encaminhar credenciais.** É tentador porque o token já funciona, então o token do host ou o de um usuário vai para o server. A correção é emitir uma credencial para aquele server, aquela chamada e aquela ferramenta.
- **Expor todas as ferramentas.** É tentador porque a lista do server é o padrão. Digamos que um server liste quarenta ferramentas e o modelo

veja todas as quarenta. A correção é fazer um allowlist por agente, dimensionado para a tarefa.

- **Tratar somente leitura como seguro.** É tentador porque nada pode ser alterado. Um server somente leitura não consegue alterar estado, mas a sua saída continua sendo dado externo que pode carregar instruções. A correção é limitá-la, marcar a sua proveniência e aplicar taint, com o Capítulo 16 por trás disso.
- **Pular o registro do lado do host, ou revisar uma única vez.** É tentador porque o server mantém logs e a revisão passou. Os logs do server e a primeira revisão não são algo em que você possa se apoiar depois; registre cada chamada no seu próprio trace e deixe a fixação transformar a primeira revisão em uma verificação a cada conexão.

Pontos-chave

- Conectar um server MCP abre uma fronteira de confiança: as suas definições, resultados e dicas vêm de fora do orquestrador e são entradas para uma decisão, não a decisão.
- O MCP padroniza como um host fala com um server e deixa com você a confiança, a autoridade e a verificação.
- O host é responsável pelo contrato de cada ferramenta MCP, incluindo a descrição, a classe de efeito e o formato de erro, e o modelo vê esse contrato em vez do texto do server.
- Um allowlist de servers, um allowlist de ferramentas e uma definição fixada tornam visíveis as mudanças de um server e colocam uma pessoa revisora no caminho delas, e nenhuma detecta uma mudança de comportamento por trás de uma definição inalterada.
- Uma chamada de ferramenta MCP passa pelo mesmo gate que qualquer outra, com a credencial emitida por chamada e de escopo restrito, e o resultado limitado em tamanho, verificado em formato e marcado como não confiável antes de chegar ao contexto.
- Prefira servers somente leitura e conjuntos pequenos de ferramentas, e lembre que somente leitura limita o que um server pode fazer, não o que a sua saída pode dizer.
- Se você escreve um server, aplique do seu lado as mesmas disciplinas de contrato, autoridade e rate limit, porque um server é o gate das

suas próprias ferramentas.

Os servers são uma fonte de material para o contexto do modelo, e o contexto tem outras fontes: tickets, trechos recuperados, passos anteriores e memória. O Capítulo 9 trata de como o orquestrador monta tudo isso, rotula de onde veio cada peça e decide o que o modelo pode ver.

PARTE III

Contexto, estado e memória

Capítulo 9 — Gerenciamento de contexto

Considere uma longa conversa de ticket na Parcelport. Um cliente escreve sobre uma encomenda que nunca chegou e pede reembolso. A conversa já é longa: quatro mensagens anteriores, um aviso da transportadora encaminhado e a resposta de uma colega da equipe de suporte. O primeiro passo do agente de suporte precisa colocar alguma coisa diante do modelo, e a resposta do protótipo é a que a maioria dos protótipos tem. Ele pega o system prompt, anexa a conversa inteira, anexa todos os resultados de ferramentas até ali, anexa os três primeiros resultados de uma busca na documentação e envia tudo.

Suponha que a busca tenha devolvido duas versões da mesma política de devoluções, uma substituída e outra vigente, no mesmo formato de trecho e sem datas. Suponha que o perfil do cliente tenha voltado com todos os campos que o serviço guarda. Suponha que o aviso encaminhado contenha uma frase que parece uma instrução. Nada no texto montado diz qual destas é a regra da própria Parcelport, qual é a alegação de um cliente e qual é um documento que era verdadeiro na primavera passada. O modelo recebe um único bloco de texto e produz uma única resposta fluente. A resposta cita a política antiga, e ninguém consegue dizer depois o que o modelo de fato viu.

Este capítulo pertence à parte **Contexto** do envelope de controle, e responde à primeira pergunta dessa parte: o que o modelo vê, de onde veio cada peça e até que ponto se pode confiar nela? A resposta que o capítulo defende é que o contexto não é uma string que alguém escreve. É a saída de um código determinístico que escolhe fontes, ordena, rotula, limita e registra.

O problema e por que ele é difícil

Uma chamada ao modelo não tem memória própria. Tudo o que o modelo “sabe” sobre este ticket, este cliente e esta política é o que o orquestrador colocou no contexto para aquela única chamada. Isso faz da montagem a peça de código com maior alavancagem no agente: todos os outros controles dependem dela. O gate verifica a proposta contra fatos, mas uma proposta construída sobre um contexto errado já chega errada. O contexto é onde uma resposta fundamentada e uma sem fundamento se separam, já que o modelo só pode se fundamentar no que lhe foi dado.

Várias classes de falha começam aqui. F3 (afirmação sem fundamento) cresce quando o contexto não tem o fato de que a resposta precisa, ou contém duas versões conflitantes dele, porque o modelo preenche a lacuna com uma frase plausível. F4 (sequestro de instruções) cresce quando o texto de fora da Parcelport está no mesmo bloco indiferenciado que as regras, já que nada o marca como dado. F5 (loop descontrolado ou contexto obsoleto) aparece com o tempo: um fato lido no passo 2 ainda está no contexto no passo 9, muito depois de o sistema de registro ter mudado. F9 (explosão de custo ou latência) aparece quando o contexto cresce a cada passo e toda chamada posterior paga por tudo o que veio antes. E F8 (comportamento não observado) aparece quando ninguém consegue dizer, numa revisão de incidente, o que o modelo viu.

A abordagem óbvia não funciona, por quatro razões. A primeira é que o contexto é finito. A janela de contexto é a quantidade de material que um modelo consegue receber em uma chamada; é um recurso limitado, e um loop que anexa sem uma política vai encontrar o limite no pior momento, no meio de um ticket longo. A segunda é que mais contexto não é melhor contexto. Material irrelevante, obsoleto ou conflitante não fica quieto; ele compete com o material que importa, e o modelo não tem um jeito confiável de dizer qual é qual. A terceira é que as fontes diferem em confiança, e um bloco de texto apaga a diferença. A quarta é que o remédio habitual, um parágrafo no system prompt dizendo ao modelo que prefira documentos recentes e ignore instruções encontradas em e-mails, é um pedido. Ele reduz a taxa da falha e vale nos dias em que vale.

Esse último ponto é o motivo de esta ser uma questão de engenharia. Qual fonte recebe quantos tokens, em que ordem, com que rótulo, e o que acontece quando algo não cabe são decisões que o código pode tomar da mes-

ma forma toda vez, testar e registrar. A parte do modelo é ler o que lhe foi dado. Tudo o que vem antes disso é engenharia comum.

O contexto é montado, não acumulado

O protótipo acumula: cada passo anexa algo a uma transcrição que só cresce. O design-alvo monta: cada passo constrói o contexto do zero a partir de fontes, sob uma política, como função do estado do run. A diferença parece pequena e muda o que é possível. Uma transcrição só pode crescer, e um montador pode descartar, substituir, reordenar e atualizar. Uma transcrição é o que aconteceu; um contexto montado é o que o design decidiu que o modelo deve ver naquela chamada.

O passo canônico do Capítulo 1 começa com `assembleContext(run)`. Este capítulo abre essa função. Ela tem cinco tarefas, e o restante do capítulo as toma em ordem: selecionar itens de fontes, rotular cada um com proveniência e confiança, encaixá-los em um orçamento por prioridade, ordená-los de modo que a estrutura carregue sentido e registrar o que foi escolhido.

Fontes e níveis de confiança

A primeira decisão de design é a lista de fontes e, para cada uma, até onde ela pode ser confiável. Confiança aqui não é um sentimento sobre a fonte. Ela responde a uma pergunta concreta: o texto desta fonte pode ser tratado como instrução, ou apenas como dado? Para o agente de suporte, a lista é curta.

Fonte	Escrita por	Confiança	Falha típica se rotulada errado
Instrução de sistema	A equipe de plataforma, versionada	Instrução	F4, se o texto do usuário puder dividir o seu espaço
Resumo da política	Responsável pela política, gerado a partir dos dados da política	Descrição com nível de instrução	F3, se o resumo se afastar do que o gate impõe
Mensagem do cliente e texto do ticket	O cliente, ou quem escreveu a ele	Dado não confiável	F4

Fonte	Escrita por	Confiança	Falha típica se rotulada errado
Resultados de ferramentas	Serviços da Parcelport, mas com campos de texto livre	Dado não confiável	F4, F5
Resultados de retrieval	Documentos internos, de idades variadas	Dado não confiável, com uma versão	F3, F5
Memória	Runs anteriores (Capítulo 11)	Dado não confiável até ser validado	F4, F5
Notas do orquestrador	Código: recusas, resumos, fatos de estado	Derivada, herda a menor confiança das suas entradas	F3

Duas linhas merecem um comentário. O resumo da política é uma descrição do que o gate impõe, não a imposição; o teto de reembolso no resumo ajuda o modelo a evitar propor o que será recusado, e o gate verifica o teto quer o resumo diga isso ou não. Assim, o resumo pode estar errado sem se tornar um F7 (efeito não autorizado), e mesmo assim deve ser gerado a partir dos mesmos dados que o gate lê, nunca mantido à mão ao lado dele.

A linha dos resultados de ferramentas é a que as equipes discutem. Um resultado de `orders-service` é dado da própria Parcelport, então por que não confiável? Porque a confiança se liga a campos, não a serviços. O status do pedido é um valor controlado; a observação de entrega que um cliente digitou no checkout é texto livre que passou pelo serviço sem alteração. O Capítulo 5 molda as observações de modo que cada uma carregue a sua origem e um rótulo de confiança, e um resultado que mistura os dois tipos é rotulado pelo seu campo menos confiável. Na dúvida, o rótulo é o mais baixo.

Existe uma versão desta tabela em que uma linha diz “confiável”. Teria cuidado com essa palavra. A instrução de sistema e o resumo da política têm nível de instrução porque a Parcelport os escreveu sob controle de mudanças, não porque o modelo tenha garantia de obedecê-los. O Capítulo 2 explica por que a obediência do modelo não pode ser presumida, e o Capítulo 16 constrói os controles que se mantêm quando ele não obedece.

Proveniência em cada item

A unidade de montagem é um item de contexto. Cada um carrega metadados suficientes para que o montador possa orçá-lo, o gate possa raciocinar sobre ele e quem revisa possa rastreá-lo. A notação abaixo é ilustrativa, no estilo dos contratos do Capítulo 6.

```
record ContextItem
  id:          string      // assigned by the orchestrator, unique in the
run
  source:      enum [system, policy, user, tool_result, retrieval, memory,
note]
  origin:      string      // ticket id, tool call id, document id, memory
id
  trust:       enum [instruction, untrusted]
  as_of:       timestamp   // when the fact was true or read, never "now"
  version:     string      // document or policy version; empty when none
exists
  derived_from: list of id  // non-empty for summaries and notes
  priority:    integer     // from the assembly policy, not the model
  cost:        integer     // measured by the orchestrator, in tokens
  body:        string
```

Os campos de que o modelo provavelmente precisa são renderizados no contexto ao lado do corpo: fonte, data de referência e versão. O restante fica no orquestrador. Essa divisão importa para a linha que continuo traçando entre um rótulo e um controle. Um rótulo renderizado como “texto de ticket não confiável” ajuda o modelo a tratar um trecho como dado, e é um pedido como qualquer outro. O que faz do rótulo um controle é que o campo `trust` viaja com o valor no código. Quando o modelo propõe depois um `update_shipping_address` cujo endereço aparece apenas em um item não confiável, o gate consegue ver isso, e o Capítulo 16 descreve o que ele faz a respeito. O rótulo renderizado é uma cortesia ao modelo; o campo é o controle.

Uma regra decorre dos campos e merece ser enunciada por si só: um id de pedido nos argumentos de uma chamada de ferramenta deve vir de um resultado de ferramenta ou do estado do run, nunca do texto de uma mensagem. O gate verifica o `origin` do id, e um id que aparece apenas em um item de ticket não confiável é recusado ou enviado para aprovação, seja qual for a proposta do modelo.

Ordem e estrutura

A posição e a delimitação fazem parte da montagem, e não há mágica de prompt engineering nelas. Três regras bastam. Os itens com nível de instrução vêm primeiro e são renderizados em uma seção própria. Os itens não confiáveis são renderizados em blocos claramente delimitados, cada um com a sua linha de proveniência, de modo que quem lê o trace veja a mesma estrutura que o modelo viu. E a tarefa vem por último, enunciada pelo orquestrador a partir do estado do run, não extraída do texto do cliente.

Não reivindicaria mais que isso para os delimitadores. Uma cerca em volta de um texto não confiável é uma convenção que costuma reduzir a taxa de erros, e um atacante pode escrever um texto que parece uma cerca. O montador usa a estrutura para ajudar o modelo e manter o registro legível. O controle que barra uma proposta sequestrada não está no layout; está nas regras de taint no gate.

Um pequeno bloco de pseudocódigo mostra a forma do montador, com o orçamento abstraído por ora.

```
function assembleContext(run):
  items = []
  items += instructionItems(run.agent, run.policy_version)      // system
  and policy digest
  items += stateFacts(run)                                     //
  Chapter 10: facts from the run store
  items += ticketItems(run.ticket_id, run.conversation_cursor) //
  customer text, untrusted
  items += toolObservations(run, keep: observationPolicy(run)) //
  already shaped, Chapter 5
  items += retrieveForTask(run)                                // may
  return nothing, see below
  items += memoryItems(run)                                    //
  Chapter 11, scoped and labeled
  items += currentTask(run)                                    //
  pinned: the task as the orchestrator states it from run state
  for each item in items:
    require item.origin and item.as_of                          // an
  item without provenance is a bug
  chosen, dropped = fitToBudget(items, budgetFor(run))
  context = render(chosen, order: ["instruction", "state", "untrusted",
  "task"])
  record(run, "context_assembled", manifest(chosen, dropped))   // see
  the section on recording
  return context
```

A linha `require item.origin and item.as_of` é o controle mais barato do capítulo. Um adaptador de fonte que não consegue dizer de onde veio um item, ou quando, falha na hora da montagem, em um teste, e não numa revisão de incidente.

O orçamento: o contexto é um recurso limitado

A janela de contexto é finita e cada token nela tem um preço: dinheiro, latência e espaço tirado de outra coisa. O montador precisa, portanto, de uma política para o que acontece quando os candidatos não cabem, e a política tem de existir antes do primeiro ticket longo demais, porque é esse ticket que vai descobrir.

Escreveria o orçamento como cotas por fonte mais um núcleo fixado, e não como um total único. Um total único deixa a maior fonte expulsar as demais; uma conversa longa de e-mails então desloca o resumo da política, e o run se comporta de maneira diferente em tickets longos e curtos sem motivo que alguém consiga ver. Os números abaixo são ilustrativos.

```
policy context_budget support-agent      // illustrative notation
  pinned: system, policy digest, state facts, current task  // never
  dropped
  allowance:
    user:          40%      // of what remains after pinned items
    tool_result: 30%
    retrieval:    20%
    memory:       10%
  when over:
    order: drop oldest observation digests, then lowest-ranked
           retrieval items, then oldest conversation turns
           (replaced by a derived summary, never silently)
  if pinned alone exceeds the budget: raise ContextBudgetExceeded
```

A última linha é a que me importa. Se o núcleo fixado não cabe, o design não tem um jeito seguro de encurtá-lo, e o run deve parar e fazer o hand-off em vez de descartar uma linha da política para abrir espaço. Um descarte silencioso é a falha que parece sucesso.

Truncamento, sumarização e o que cada um perde

Quando algo precisa encolher, há duas opções honestas e uma tentadora. O truncamento corta: mantém um prefixo, um sufixo ou os itens mais bem classificados e descarta o resto, e deve avisar que o fez. O montador marca

um item truncado do mesmo modo que o adaptador de ferramenta no Capítulo 5, para que o modelo seja informado de que o texto é parcial. A sumarização substitui o texto por um texto mais curto, e o seu custo é mais sutil: é uma chamada ao modelo (ou uma regra), pode estar errada e destrói informação de um jeito que não deixa lacuna visível. A opção tentadora é não fazer nenhuma das duas de propósito e deixar que um limite em outro ponto corte o contexto onde calhar.

A sumarização exige quatro regras, porque é uma transformação que produz um item novo, derivado, com os seus próprios modos de falha.

1. **Um resumo é um item derivado.** Ele carrega `derived_from` apontando para as suas fontes, um timestamp `as_of` e um nível de confiança que é o menor entre as suas entradas. Um resumo de texto de cliente é texto de cliente. É assim que uma tentativa de sequestro continua rotulada depois de comprimida numa frase de som neutro.
2. **Nunca resuma aquilo de que uma decisão depende.** Ids de pedido, valores, moedas, estados de aprovação, chaves de idempotência e a identidade do cliente são fatos que o gate e o orquestrador mantêm no run store (Capítulo 10). Eles são injetados como fatos de estado estruturados a cada passo, e não carregados como prosa em um resumo, onde uma paráfrase pode mudar um dígito.
3. **O original permanece.** O texto completo continua no run store ou no sistema de tickets; só o contexto carrega a forma curta. A sumarização então não perde nada de forma permanente, e quem revisa pode comparar as duas.
4. **Um resumo é uma proposta.** Se um modelo o escreve, ele pode ser uma afirmação sem fundamento como qualquer outra saída (F3), então merece a mesma suspeita de qualquer proposta, e os fatos acima ficam fora dele por essa razão.

Crescimento ao longo de um run longo

O contexto cresce porque os runs crescem. Cada passo adiciona uma observação; cada turno adiciona texto do cliente; os trechos recuperados no passo 3 ainda estão lá no passo 12. Digamos um run de 15 passos e uma conversa de oito turnos: a acumulação sem limite faz a chamada do último passo ficar várias vezes mais pesada que a do primeiro, e o peso extra é, em sua maior parte, material que deixou de importar.

O montador trata o crescimento com uma política para a forma como cada tipo de item envelhece. As observações de ferramentas são substituídas por um resumo de uma linha depois de usadas, digamos dois passos depois, e o resultado completo continua recuperável no run store por id. Os trechos recuperados são descartados, a menos que o próximo passo os cite. Os turnos de conversa mais antigos que uma janela são resumidos sob as regras acima, exceto que os turnos que carregam uma decisão, como um cliente concordando com um valor de reembolso, são mantidos literalmente e sinalizados pelo código. A primeira mensagem do ticket atual é fixada, porque declara o pedido original.

O mesmo padrão serve ao agente de operações, cujas investigações são onde o crescimento mais pesa: o resultado de um `query_logs` é grande, a chamada seguinte estreita o filtro e o resultado anterior raramente é necessário de novo. Ali, os achados do run vivem no estado (Capítulo 10) e o contexto carrega os achados, não os logs brutos. O Capítulo 12 trata do loop que decide o que fazer em seguida; a preocupação deste capítulo é que o loop não pague pelo próprio histórico.

Retrieval: o que volta e o que não volta

Retrieval é buscar material de um repositório para colocá-lo no contexto. Para o agente de suporte, o caso habitual é `search_docs`: o cliente pergunta sobre um prazo de devolução ou uma restrição de transportadora, e a resposta está em um documento. O retrieval é por onde entra a maioria das falhas F3 e F5, porque é um passo de aparência determinística que devolve uma lista ordenada de tudo o que o repositório tem, relevante ou não.

Busca híbrida

A busca sobre texto falha de duas maneiras opostas. A correspondência por palavras-chave encontra o termo exato e perde o documento que descreve a mesma coisa com outras palavras; a correspondência semântica, que compara significado por meio de embeddings, encontra o vizinho e pode perder o código ou a expressão exata que o cliente citou. A **busca híbrida** executa as duas e funde as suas classificações, o que costuma dar melhor recall que qualquer uma isolada, ao preço de dois índices para construir e manter atualizados. Escolheria a busca híbrida para um corpus

de suporte porque os clientes escrevem nos dois registros: citam códigos de erro e nomes de transportadoras exatamente e descrevem os problemas de modo solto.

A busca híbrida melhora o que volta. Ela não decide o que é bom o bastante para usar. Essa decisão é um limiar, e é o controle de que esta seção trata.

Um limiar de relevância e “nenhuma correspondência boa”

Um sistema de busca devolve os k primeiros resultados porque foi isso que lhe pediram, quer algum deles responda à pergunta ou não. Se o repositório não tem nada sobre um formulário de alfândega para um país que a Parcelport não atende, os três primeiros resultados ainda são três documentos, e o mais próximo será sobre formulários de alfândega de outro lugar. Colocado no contexto, ele se lê como uma resposta. A resposta provavelmente será construída em cima dele, já que um trecho que se ajusta ao formato da pergunta é a melhor evidência que o contexto oferece.

Trataria “nenhuma correspondência boa” como um resultado de primeira classe. Um piso de relevância diz que, abaixo de uma dada pontuação, o passo de retrieval devolve uma lista vazia e uma razão, e o montador trata a lista vazia como informação: o contexto diz que o corpus foi pesquisado e nada relevante foi encontrado. O agente pode então responder que não tem essa informação, fazer uma pergunta de esclarecimento ou passar o ticket a uma pessoa com `escalate_to_human`. As três opções são melhores que uma resposta confiante construída sobre o resultado fraco mais próximo. No momento em que escrevo, o Contextator responde “nenhuma correspondência boa” quando nada ultrapassa o seu piso de relevância, em vez de devolver um resultado fraco; outras ferramentas adotam abordagens semelhantes, e o montador de contexto deve tratar um resultado vazio como informação.

Definir o piso é mais difícil do que parece, e não sei qual é o valor certo para o seu corpus; isso depende de como as suas pontuações são produzidas. Uma pontuação de classificação fundida, por exemplo, expressa a posição relativa a outros resultados, não um juízo absoluto de relevância, então um piso sobre ela pode precisar de uma verificação de similaridade separada ou de uma etapa de reranking para significar alguma coisa. O modo de decidir é empírico. Pegue um golden set de perguntas reais com

respostas conhecidas e ausências de resposta conhecidas (o Capítulo 21 descreve como montar um), observe a distribuição das pontuações em cada caso e coloque o piso onde os resultados fracos devolvidos por engano e os bons resultados suprimidos por engano custem menos. Os dois erros são reais, e têm preços diferentes. Um piso alto demais envia a humanos tickets que um documento poderia ter respondido, e um piso baixo demais coloca evidência fraca no contexto.

```
function retrieveForTask(run):
    query = retrievalQuery(run.task, run.state)           // path A: built
    by code from the task and state
    result = docs.search(query, limit: 8)                 // hybrid:
    keyword and meaning, fused
    hits = result.hits
    kept = []
    for each h in hits:
        if h.relevance >= FLOOR and isEffective(h, run.as_of): // floor
            calibrated on the golden set
            kept += h                                     // freshness:
    see the next section
    if kept is empty:
        return [ note("retrieval", "searched docs for the task; no good
match",
                                as_of: result.read_at) ] // read time
    from the search result; an item, so the context says so
    items = []
    for each h in firstN(kept, 3):
        items += toContextItem(h, source: "retrieval", trust: "untrusted")
    return items
```

O retrieval chega ao contexto por dois caminhos, e o design deve dizer qual deles um dado passo usa. No caminho A, mostrado acima, o orquestrador faz o retrieval por conta própria no momento da montagem e constrói a consulta a partir da tarefa e do estado do run; o modelo não propõe nada, então não pode ampliar a consulta. O texto do cliente ainda molda a tarefa, de modo que isso estreita a consulta e não a isola do ticket. No caminho B, o modelo propõe uma chamada `search_docs`, e a consulta é um argumento fornecido pelo modelo, como o contrato do Capítulo 8 a define: uma string com limite de tamanho, em uma ferramenta de leitura. O gate a valida como qualquer outra chamada, e o resultado entra pelo mesmo piso, pelo mesmo filtro de versão e pelos mesmos rótulos do caminho A, não confiável e limitado. O caminho A é o padrão para uma pergunta que todo ticket de um certo tipo precisa ver respondida; o caminho B é para o que se revela necessário no meio do run, e a sua consulta é tão manipulável quanto o texto que levou a ela.

O caso vazio no bloco produz uma nota, não nada. O silêncio é ambíguo: o modelo não distingue “a busca não encontrou nada” de “a busca nunca foi executada”, e no segundo caso ele pode responder com base no que absorveu durante o treinamento, que é a fonte mais sem fundamento de todas.

Aviso: Uma resposta sobre dinheiro, promessas de entrega ou o que um cliente tem direito de receber deve estar fundamentada em uma fonte recuperada ou fornecida por ferramenta. Se o passo de retrieval devolveu “nenhuma correspondência boa” e o rascunho da resposta afirma uma política mesmo assim, o design tem uma lacuna entre o contexto e a afirmação. Uma verificação em código depois que o modelo responde, como exigir que uma afirmação de política cite um id de item presente no contexto, é o controle; a instrução de citar é apenas um pedido (o Capítulo 4 trata de onde essas verificações pertencem).

Conteúdo obsoleto, versões e datas

Um documento interno pode ser bem escrito, relevante e errado. As políticas mudam; a página antiga continua no índice. Esta é a metade F5 do capítulo, uma falha do contexto ao longo do tempo, e a pontuação de relevância não a detecta: a política de devoluções substituída pontua quase tão bem quanto a vigente, já que as duas dizem quase a mesma coisa.

Os controles são metadados e uma regra. Todo documento no índice carrega uma versão, uma data de início de vigência e, quando é substituído, uma data de fim de vigência, e o adaptador de retrieval os expõe como o `version` e o `as_of` do item. A regra no bloco acima, `isEffective`, descarta documentos cujo período de vigência não cobre a data a que a decisão se refere, que é a data do pedido ou do ticket numa pergunta de reembolso e não necessariamente hoje. Quando duas versões passam, o montador mantém apenas a mais nova, ou mantém as duas com as suas datas e diz isso, conforme a diferença importe ou não para a tarefa. Se os metadados estiverem ausentes, o documento recebe prioridade baixa e um marcador “sem data”, e um documento sem data não pode ser o único apoio de uma afirmação sobre dinheiro.

A proveniência também ajuda na outra ponta de um run. Os fatos que o modelo leu no início têm um `as_of`, e o montador pode compará-lo com o sistema de registro antes de um passo consequente. Se o pedido foi lido no passo 1 e `update_shipping_address` é proposto no passo 4, a pré-condição do gate sobre o estado de hand-off da encomenda à transportadora é verificada contra uma leitura nova de `shipping-service`, não contra qualquer coisa no contexto. Esse é o padrão do Capítulo 10: o contexto nunca é a fonte da verdade para nada de que um efeito dependa.

Onde o retrieval é executado

O retrieval pode ser executado no orquestrador, como faz o bloco acima, ou à frente do modelo. No momento em que escrevo, o RAGmux, um gateway de modelos, pode executar o retrieval por conta própria e injetar os trechos antes da chamada ao modelo; outras ferramentas adotam abordagens semelhantes, e o ponto é em que lugar do caminho os trechos são escolhidos. O padrão importa mais que o produto: quando os trechos são escolhidos e injetados por algo que não é o montador, o montador não consegue rotulá-los, não consegue contar o custo deles no orçamento e não consegue escrevê-los no seu manifesto, e os trechos injetados em uma posição privilegiada do contexto chegam com mais autoridade do que um resultado de retrieval merece.

Preferiria o retrieval no orquestrador para um agente que age, porque é ali que a proveniência, o piso, a verificação de versão e o registro já vivem. Um gateway que faz retrieval pode fazer sentido para um endpoint simples de perguntas e respostas, sem ferramentas e sem efeitos, onde o custo de um resultado fraco é um parágrafo errado e não uma ação errada. Se você o usa para um agente, as injeções do gateway precisam fazer parte do registro de montagem de algum outro modo, e tudo o que o gateway injetar deve ser rotulado como não confiável no design, em qualquer espaço.

Memória e as outras fontes


A fonte restante na tabela é a memória, que pertence ao Capítulo 11. Para este capítulo, a regra diz respeito à sua entrada no contexto: um item de memória entra como qualquer outro, com proveniência, um rótulo de confiança, uma prioridade e um custo, e sob a sua própria cota, para que uma

longa lista de notas antigas não expulse o ticket. A memória que não consegue dizer de onde veio nem quando foi escrita não é montada. O que a memória contém e quem pode escrever nela são questões do Capítulo 11.

A mesma disciplina cobre tudo o que um server MCP oferece (Capítulo 8): a sua saída chega como um item da fonte `tool_result` ou `retrieval`, rotulado como não confiável, com o server na sua origem, e conta contra o mesmo orçamento.

A montagem como pipeline

O diagrama mostra uma montagem. Siga as fontes à esquerda até o montador, e depois observe as duas saídas: o contexto que o modelo vê e o manifesto que vai para o registro. O caminho de recusa na parte de baixo é o que um design apressado deixa de fora.



Duas propriedades do pipeline merecem ser enunciadas. Ele é determinístico: o mesmo estado do run e as mesmas versões das fontes produzem o mesmo contexto, o que torna reproduzível uma chamada passada. A montagem apenas lê. Um resumo é produzido por um passo separado, que pode ser uma chamada ao modelo, e é armazenado no run store como um item derivado; a montagem pega o resumo armazenado e nunca cria um, de modo que a chamada ao modelo fica fora da parte determinística. O passo de sumarização roda depois de um turno e antes da montagem seguinte; se ainda não existe um resumo armazenado quando o orçamento é excedido, a montagem recorre ao truncamento marcado e o registra, e não resume na hora. E ele não tem nenhum ramo em que o modelo escolha o

que vê. O modelo propõe chamadas de ferramentas, e uma chamada de retrieval é uma delas, se você permitir, mas o que entra no contexto a partir dessa chamada passa pelos mesmos rótulos e pelo mesmo piso.

Registrar o que o modelo viu

Quando um reembolso é contestado ou uma resposta cita uma política que não existe mais, a primeira pergunta na revisão é o que o modelo recebeu. Se a resposta é “o system prompt de hoje, mais provavelmente a conversa”, o design tem um problema de F8 (comportamento não observado) na sua parte Contexto. O Capítulo 20 trata do formato do trace; este capítulo trata do que o montador contribui para ele.

Registraria em dois níveis. O **manifesto** é pequeno e sempre escrito: para cada passo, a lista ordenada de ids de itens com fonte, origem, versão, `as_of`, confiança, custo e um hash do conteúdo, mais os itens que foram descartados e a regra que os descartou. O manifesto responde “o que ele viu e o que não viu”. O **contexto renderizado** é o texto exato enviado. Ele é maior e contém texto de clientes, então é escrito sob as regras de retenção e de redaction do pipeline de trace, talvez para runs amostrados e para qualquer run que termine em hand-off ou em recusa. Como a montagem é determinística, o manifesto mais o conteúdo dos itens referenciados bastam para reconstruir o contexto renderizado enquanto as fontes mantiverem as suas versões; o texto completo é o que você guarda quando elas não mantêm.

Registrar tem um custo, e o custo é principalmente volume de dados e exposição. Um armazenamento de contextos é uma segunda cópia dos dados do cliente. Não faça dele um lugar onde **informações de identificação pessoal (PII)** vivam mais tempo do que precisam; essa é a razão para guardar hashes e ids por padrão e o texto completo por exceção.

A PII mais limpa é a que nunca foi montada

O montador é também o último ponto em que a PII pode ser mantida fora do contexto. A PII entra no contexto do agente de suporte de três maneiras: o texto do ticket, uma consulta de perfil que devolve mais campos do que a tarefa precisa e as respostas propostas pelo próprio modelo, que repetem o que lhe foi mostrado. O Capítulo 17 trata dos controles. Para a

montagem, a preferência é simples de enunciar e tem um custo: se um campo não é necessário para chegar à proposta correta, ele não entra no contexto de forma alguma.

Na prática isso significa que os adaptadores de ferramentas devolvem projeções, como mostra o Capítulo 5, e o montador não repassa campos que a definição da tarefa não lista. Uma resposta que precisa cumprimentar o cliente pelo nome pode carregar um marcador que o código preenche no envio, de modo que o modelo nunca veja o nome. O preço é que algumas respostas soam um pouco mais padronizadas e algumas tarefas precisam de um campo, afinal. São decisões a tomar por tarefa e a registrar por escrito, porque a alternativa é que cada novo campo na resposta de um serviço entre silenciosamente no contexto no dia em que for adicionado.

Parcelport: o ticket da encomenda atrasada

Volte ao ticket da abertura e conduza o montador por ele, com todos os números hipotéticos.

O orquestrador cria o run e escreve fatos de estado a partir do run store: id do ticket, id do cliente, o id do pedido vinculado ao ticket, `refund_ceiling` como um fato de política e uma linha de status dizendo que não existe reembolso para esse ticket e esse pedido. Esses itens são fixados. A instrução de sistema e o resumo da política, versionados, também são fixados.

A conversa do ticket tem sete entradas: as quatro mensagens anteriores, o aviso encaminhado, a resposta da colega e a última mensagem do cliente, que pede o reembolso. O montador mantém literalmente a primeira entrada, as duas últimas e o aviso encaminhado, e substitui as três restantes por um resumo derivado, não confiável porque as suas fontes são, e o manifesto registra a substituição.

O aviso encaminhado da transportadora contém uma frase que se lê como uma diretiva ao próximo sistema que o processar. O montador não a detecta. Ele renderiza o aviso em um bloco não confiável com a sua origem, e o gate trata qualquer argumento posterior que remonte a esse bloco sob as regras de taint do Capítulo 16. O contexto dá ao controle algo com que trabalhar; não é o controle.

No passo 1, o agente de suporte propõe `lookup_order`; a observação volta moldada como no Capítulo 5, com a observação de entrega em texto livre truncada e marcada, e o status de entrega do pedido diz “etiqueta criada”. No passo 2, o modelo propõe `search_docs` para o prazo de devolução (caminho B). Voltam duas versões da política de devoluções; a substituída é descartada porque o seu período de vigência terminou antes da data do pedido, e a vigente entra com a sua versão e o seu `as_of`.

No passo 4, o cliente pede uma mudança de endereço e o agente de suporte propõe `update_shipping_address`. O pedido foi lido no passo 1 com a encomenda ainda em “etiqueta criada”; a pré-condição do gate lê `shipping-service` de novo e descobre que a encomenda foi entregue à transportadora. A chamada é recusada e a recusa volta como observação. O contexto guardava um fato antigo, e o que o pegou foi uma verificação contra o sistema de registro.

No passo 9, o cliente pergunta sobre um formulário de alfândega para um destino que a Parcelport não atende. Nada ultrapassa o piso, então o montador insere uma nota dizendo que a documentação foi pesquisada e nada relevante foi encontrado. O modelo propõe `escalate_to_human` com um resumo, e Sam recebe um ticket que diz o que foi e o que não foi encontrado, onde um design mais fraco teria enviado uma resposta construída sobre o documento errado mais próximo. O run termina aí: `handed_off` é terminal (Capítulo 10), e o que acontecer depois é trabalho de uma pessoa ou de um novo run.

Trade-offs e custos

Montar como código dá mais trabalho do que anexar. Cada fonte precisa de um adaptador que forneça origem, `as_of`, versão e custo, e cada adaptador precisa de testes. O primeiro custo é tempo de engenharia, e é pago principalmente uma vez; o custo contínuo é que uma nova fonte ou um novo campo é uma mudança na política de montagem e não a edição de um prompt, o que significa revisão e um deploy. Isso é um recurso para a equipe de plataforma e um peso para quem quer testar uma ideia esta tarde. Um compromisso razoável é um caminho rápido para experimentos em uma configuração fora de produção, nunca no montador de produção.

Orçamentos e pisos custam respostas. Um limiar envia a humanos alguns tickets que um documento poderia ter respondido, e cada escalonamento é um minuto do tempo da equipe de Sam. Uma cota apertada para o texto do usuário corta histórico que o modelo poderia ter usado. Os resumos descartam detalhes. Nenhum desses custos pode ser zero, e nenhum é visível a menos que você o meça: o golden set deve incluir casos que testem se o piso suprimiu um bom documento e se um resumo descartou uma frase decisiva (Capítulo 21).

A proveniência, os manifestos e os contextos registrados custam armazenamento e, mais seriamente, criam um repositório de dados de clientes que alguém precisa governar. Quanto mais completo o registro, mais cuidadosa tem de ser a sua retenção. As equipes às vezes reduzem o problema registrando tudo e não lendo nada, que é a versão teatral: um log que ninguém lê, neste caso um arquivo de contextos a partir do qual ninguém reconstrói nada. Se você não consegue dizer quem vai abrir o manifesto e para responder a que pergunta, comece pelo manifesto e por amostras do texto completo.

Quando não usar tudo isto. Um assistente de um único turno, sem ferramentas, com um corpus pequeno e fixo e sem efeito sobre dinheiro, pode rodar com um montador muito mais simples: um prompt fixo, uma única chamada de retrieval, um piso e um registro. O núcleo fixado, as cotas e as regras de itens derivados importam quando o run tem vários passos, várias fontes de confiança diferente ou uma ferramenta que altera alguma coisa. Não construiria o pipeline completo para um endpoint somente leitura de perguntas e respostas, e não rodaria um agente de suporte com uma ferramenta de reembolso na versão simples.

Onde isto falha. O montador não consegue fazer o modelo ler o que lhe foi dado, e não consegue estabelecer se um documento é verdadeiro; só pode dizer de onde o documento veio e quão velho é. Um documento que está vigente e incorreto é um problema editorial, não de montagem. E um adversário que controla texto dentro de uma fonte confiável, como uma página de wiki interna que qualquer pessoa pode editar, deslocou a fronteira de confiança; o rótulo no item está então errado, e o controle está em quem pode escrever nessa fonte. O Capítulo 16 retoma os casos em que o próprio dado é o ataque.

Erros comuns

- **Tratar o contexto como uma transcrição.** Anexar toda mensagem, observação e trecho é a coisa mais fácil de construir, e dá a sensação de completude. Faz o custo e o ruído crescerem com o run e, quando um limite finalmente morde, ele corta onde cair, possivelmente no meio do resumo da política. Monte a partir de fontes sob uma política a cada passo, dê uma cota a cada fonte, fixe o núcleo e faça o hand-off quando o núcleo não couber.
- **Resumir os fatos de que uma decisão depende.** Um resumo se lê bem e pode mudar um dígito ou perder uma moeda. Mantenha ids, valores, estados de aprovação e chaves em fatos de estado estruturados fora de qualquer resumo, mantenha o original recuperável e prefira um truncamento marcado quando uma frase descartada puder mudar uma decisão.
- **Devolver o top-k sem piso e sem versões.** Sempre devolver alguma coisa torna impossível expressar “nenhuma correspondência boa”, e a pontuação de relevância não distingue a política vigente de uma substituída. Defina um piso calibrado em um golden set, transforme um resultado vazio em uma nota e filtre por versão e data de vigência para a data a que a decisão se refere.
- **Confiar em um rótulo renderizado como se fosse o controle.** Dizer ao modelo que um bloco não é confiável reduz a taxa de F4 e não a impede. Mantenha `trust` e `origin` como campos que viajam com os valores, para que o gate possa agir sobre eles (Capítulo 16).
- **Deixar o conteúdo entrar onde o montador não o vê.** Trechos injetados por uma camada à frente do modelo, ou um campo novo que um serviço passa a devolver, mudam o que o modelo vê sem que ninguém tenha escolhido. Traga a saída injetada para o registro de montagem como não confiável e projete os resultados de ferramentas para um conjunto listado de campos.

Pontos-chave

- O contexto é a saída de um código de montagem determinístico que seleciona, rotula, limita, ordena e registra itens, e deve ser reconstruído a cada passo e não acumulado.

- Todo item de contexto carrega proveniência e um nível de confiança como campos em código, porque um rótulo renderizado em texto é um pedido ao modelo, e um campo que viaja com o valor é um controle que o gate pode usar.
- O orçamento é uma política escrita, com cotas por fonte e um núcleo fixado, e quando o núcleo não cabe, o run faz o hand-off e não descarta uma linha da política.
- Os resumos são itens derivados com fontes, um timestamp e a menor confiança entre as suas entradas, e os fatos de que uma decisão depende nunca são carregados dentro deles.
- O retrieval precisa de um piso de relevância para que “nenhuma correspondência boa” seja um resultado real, e um resultado vazio entra no contexto como informação, já que um resultado fraco apresentado como evidência é como se constrói F3.
- Documentos e fatos precisam de versões e datas `as_of` para que o conteúdo obsoleto (F5) possa ser filtrado, e tudo de que um efeito depende é relido do sistema de registro antes do efeito.
- O montador escreve um manifesto do que o modelo viu e do que foi descartado, para que uma revisão de incidente possa responder à primeira pergunta, e mantém a PII fora do contexto por padrão, com os detalhes nos capítulos 17 e 20.

O Capítulo 9 decidiu o que o modelo vê em um passo. Ele não disse onde vivem os fatos do run entre os passos, o que acontece quando o processo morre no passo 7 ou uma pessoa leva três horas para aprovar, ou como dois runs evitam agir sobre o mesmo ticket ao mesmo tempo. Isso é estado, e o Capítulo 10 o constrói fora do contexto, no run store.

Capítulo 10 — Estado

Considere um agente de operações da Parcelport no meio de uma investigação que está prestes a sobreviver ao processo que a executa. Um alerta disparou para o `deploy-service` e o agente assumiu o caso. Ao longo de catorze passos, ele lê logs, puxa dois traces, compara as taxas de erro antes e depois do último deploy e conclui que a nova versão é a causa provável. No passo 15, propõe `request_rollback`. A política exige aprovação para essa chamada; por isso o run é suspenso e Robin, o SRE de on-call, recebe uma requisição.

Robin está no meio de outro incidente e responde duas horas depois, dentro da expiração da aprovação. Nessas duas horas, a equipe de plataforma publicou uma release de rotina do orquestrador, e todos os processos worker foram reiniciados. O run continua na fila de aprovação, mas nenhum processo em execução sabe o que ele estava fazendo. Um worker o pega e precisa decidir o que fazer com uma investigação pela metade.

Suponha que o worker siga o caminho fácil e recomece o run a partir do alerta. O modelo lê os mesmos logs, chega à mesma conclusão e propõe o rollback pela segunda vez. Ou suponha que o worker reproduza a transcrição antiga e que o modelo, diante de um histórico em que um rollback foi proposto, produza uma frase dizendo que ele foi iniciado. Nenhuma das duas situações é boa. O que um run deve guardar fora do modelo para sobreviver a um reinício, a uma longa espera e a um segundo worker?

Este capítulo pertence a duas partes do envelope de controle. No que diz respeito ao que o run sabe sobre si mesmo, é o **Contexto**: o que o modelo vê e de onde isso veio? No que diz respeito ao que resta depois de cada passo, é o **Registro**: que evidência fica e o sistema consegue agir com base nela? O estado do run é o ponto em que as duas se encontram.

O problema e por que ele é difícil

Um run é uma coisa de longa duração vestida como uma única chamada. Ele pode esperar uma pessoa por horas, sobreviver ao processo que o iniciou, ser retomado por outro worker e ser cancelado por alguém que nunca o viu começar. Um design que mantém o progresso do run no contexto do modelo, ou apenas dentro de um processo worker, não tem de onde retomar quando qualquer um desses casos acontece.

Três classes de falha surgem daí. A F5 (loop descontrolado ou contexto obsoleto) aparece quando um run retomado age com base em fatos que leu antes da espera: um endereço lido no passo 2 e alterado no passo 9, ou uma versão de deploy lida antes de outra pessoa reverter essa versão. A F6 (falha parcial silenciosa) aparece quando um passo que já teve efeito é repetido, ou quando um run é marcado como concluído com uma intenção que nunca recebeu um resultado. A F8 (comportamento não observado) aparece quando um run morre e ninguém consegue dizer até onde ele chegou.

A abordagem óbvia é tratar a conversa como estado. A transcrição já existe, está ordenada e o modelo consegue lê-la. Isso não funciona, por razões estruturais e não de qualidade. Uma transcrição é uma narrativa escrita para o modelo, e é cortada, resumida e reordenada pela montagem do contexto (Capítulo 9). Ela carrega as afirmações do próprio modelo ao lado dos fatos, de modo que não distingue umas dos outros. Ela não guarda o que o orquestrador mais precisa: a chave de idempotência de uma chamada, o status de uma aprovação, o lease do run. E reproduzi-la não restaura um mundo; pede ao modelo que proponha de novo, e uma proposta feita numa segunda leitura é uma nova proposta, livre para diferir da primeira.

A lembrança do modelo não se sai melhor. Perguntado se o rollback já foi iniciado, ele produz uma frase, e uma frase é uma afirmação, e uma afirmação errada é uma F3 (afirmação sem fundamento) sobre o próprio histórico do run.

Esta é uma questão de engenharia e não de prompt. Uma linha no prompt dizendo “não repita ações que você já executou” é um pedido a um componente que, depois de um reinício, pode não ter o histórico diante de si. O controle é um registro durável que o orquestrador lê, uma máquina de

estados que só o código pode mover e verificações que rodam antes de cada efeito. O modelo recebe uma visão desse estado; nunca é responsável por ele.

Estado, contexto e memória, mantidos separados

O Capítulo 1 definiu o **estado** como os fatos sobre um run, mantidos pelo orquestrador no run store. Vale traçar as fronteiras agora, porque a confusão entre as quatro coisas da tabela está na raiz da maioria dos designs que não conseguem retomar.

Coisa	O que é	Quem escreve	Tempo de vida	Autoridade
Estado	Fatos sobre este run: passos, veredictos, intenções, efeitos, aprovações, status	O orquestrador	O run, mais um período de retenção	A fonte de verdade sobre o histórico do próprio run
Contexto	O que o modelo vê em uma chamada, montado para essa chamada	O orquestrador, a partir do estado e de outras fontes	Um passo	Nenhuma; é uma visão
Transcrição	Uma representação legível da troca	Um subproduto	Muitas vezes igual ao do estado	Nenhuma; ela tem perdas
Memória	Informação mantida entre runs que pode influenciar contextos posteriores (Capítulo 11)	Uma política de escrita, não o run	Além do run	Consultiva, nunca a verdade sobre este run

Duas regras decorrem daí. O contexto é derivado do estado em cada passo; nunca é o lugar onde o estado vive. E o estado nunca é o lugar onde a memória vive: um fato sobre o mundo que deve sobreviver ao run é uma escrita de memória, com sua própria política, e um fato sobre o run de que nenhum run posterior precisa é estado que expira junto com o run.

Isso também mostra como retomar. Um run retomado não reproduz a transcrição para o modelo. Ele carrega o estado, lê de novo o que pode ter mudado e monta um contexto novo a partir disso. O histórico que o modelo vê é uma representação do run store, e pode dizer coisas que a transcrição nunca diria: “o passo 15 propôs `request_rollback`; o veredicto foi `needs approval`; a aprovação está pendente desde as 09:14.”

O run store: o que um run deixa para trás

O run store é um armazenamento durável pertencente ao orquestrador. É um sistema separado dos serviços sobre os quais os agentes atuam, do serviço de aprovação e do pipeline de traces, e o restante do capítulo depende de lembrar que nenhuma transação atravessa esses sistemas. A notação abaixo é ilustrativa. Ela lista o que um registro de run contém e, mais importante, quem escreve cada campo.


```
run
  id, kind                // assigned by the orchestrator
  subject                 // what the run is about: a ticket, an
alert
  key: "alert:alt-0193"   // assigned by the trigger, not by the
model
  status                 // one of the states below; written only by
transition()
  version                // integer, increases on every write
  lease: { owner, until, fence } // which worker may act now
  deadline                // absolute time after which the run stops
  cancel_requested, cancel_reason // set by a human or a system
  resume_condition        // set when a run is parked at a checkpoint
until a window resets or a breaker closes (Chapter 13); otherwise none
  pending_proposal        // a proposal that passed the gate or was
approved, not yet applied
  bound_counters          // steps, retries, spend so far (Chapter
13)
  steps: list of
    { n, context_ref, proposal, verdict, intent, effect, observation }
  approvals: list of
    { approval_id, call_hash, status, decided_by, decided_at, expires_at }
  calls: list of
    { call_id, tool, proposal, idempotency_key, intent_at, status } //
status as in Chapter 5
  facts: list of
    { name, value, read_at, source } // world facts, each
stamped
  schema_version, policy_version
```

Algumas escolhas merecem ser explicitadas. Os passos são acrescentados, não editados; assim, o run store funciona como um log e quem revisa consegue ler a ordem dos eventos. A lista `facts` carimba cada fato do mundo com a hora em que foi lido e a origem, o que permite a um run retomado perguntar “quão antigo é isto?” em vez de supor. O `call_hash` de uma aprovação a vincula a uma chamada exata, e o Capítulo 15 trata de como esse vínculo é construído. O registro não contém secrets nem credenciais e guarda o mínimo possível de informações pessoalmente identificáveis (PII) que as ferramentas permitem; resultados de ferramentas que carregam PII são armazenados sob as regras de redaction do Capítulo 17.

O run store também é a fonte da parte Registro. O pipeline de traces (Capítulo 20) mostra tempo e estrutura entre os componentes, mas o run store é onde está a afirmação do próprio orquestrador sobre o que aconteceu, numa ordem que ele controla. Quando os dois divergem, a divergência é um achado.

O run como máquina de estados

Um run tem um status, e o status é um entre um pequeno conjunto. Observe no diagrama os caminhos que encerram um run e o que falta: não há seta saindo de um estado terminal para lugar nenhum, e não há seta de `awaiting_approval` direto para `done`.



Um run tem sete estados. `handed_off` é separado de `failed` porque o hand-off não é uma quebra nem uma conclusão: é o estado em que uma pessoa assume o resultado, com o registro do run anexado. Vários controles deste livro terminam ali: um limite que disparou (Capítulo 13), uma aprovação que ninguém respondeu (Capítulo 15), uma intenção que não pôde ser resolvida. Incorporá-lo a `failed` esconderia a diferença entre “o sistema quebrou” e “o sistema pediu ajuda a uma pessoa, como projetado”. O nome canônico de um run concluído é `done`, como no loop esboçado no Capítulo 1.

As transições válidas ficam no código, em uma única função, e nada mais escreve o status.

```

allowed = {
    pending:          ["running", "cancelled"],
    running:          ["running", "awaiting_approval", "done",
                      "failed", "cancelled", "handed_off"],
    awaiting_approval: ["running", "cancelled", "handed_off"],
    done: [], failed: [], cancelled: [], handed_off: []
}

function transition(run, to, cause):
    if to not in allowed[run.status]:
        raise InvalidTransition
    if to == "done" and openIntents(run) is not empty:
        raise InvalidTransition          // no "done" with an intent that
has no outcome (F6)
    open_ids = openIntents(run).ids      // "failed" and "handed_off" may
close with an open intent,
                                         // but never silently: the ids
travel in the closing event
    // one conditional write in the run store: status, event and version
together
    ok = runStore.update(run.id, status: to, expected_version: run.version,
                        event: { from: run.status, to: to, cause: cause,
                              open_intent_ids: open_ids })

    if not ok:
        raise StaleRun                  // another writer moved this run;
reload, do not retry blindly

```

Três propriedades importam aqui. O modelo não pode propor uma transição: uma resposta final é uma proposta, e o orquestrador só a converte em done se a invariante se mantiver. No loop do Capítulo 1, a linha `run.status = "done"` é, aqui, `transition(run, "done", "final answer")`; quando ela levanta `InvalidTransition` porque há uma intenção aberta, o run resolve a intenção ou faz o hand-off, e o cliente ou o engenheiro de on-call nunca vê um run encerrado que não está. A escrita condicional sobre `version` significa que dois escritores não podem mover o mesmo run, e quem perde fica sabendo. E a invariante sobre intenções abertas transforma a proteção contra a F6 de uma convenção em algo que o código se recusa a violar. Só `done` é recusado: um run que falha ou faz hand-off porque uma intenção não pôde ser resolvida é um caminho legítimo; por isso essas transições podem fechar com uma intenção aberta, e o evento a nomeia. A intenção aberta continua então visível para o sweep descrito adiante, em vez de desaparecer com o run. A escrita é uma só em um só sistema, de modo que o status, o evento e a versão mudam juntos; esse é o único tipo de atomicidade que o run store oferece, e o design não pede nenhum outro.

Estados terminais são terminais. Quem quiser continuar uma investigação que passou por hand-off inicia um novo run sobre o mesmo subject, que carrega uma referência ao antigo. Esse é um custo deliberado: ele mantém fechado e legível o histórico de cada run, ao preço de um novo run para uma continuação.

Checkpoint e retomada

Um **checkpoint** é um ponto salvo de um run a partir do qual ele pode retomar. Neste design, um checkpoint não é um snapshot de nada dentro do modelo, nem uma cópia da transcrição. É a última fronteira de passo confirmada no run store: os passos acrescentados até então, o status, as chamadas abertas e os fatos carimbados. Como o orquestrador escreve a intenção antes de um efeito e o resultado depois dele, toda fronteira de passo é um checkpoint, e nenhum salvamento separado é necessário.

A maneira útil de pensar na retomada é perguntar onde o processo poderia ter parado. A tabela lista os pontos de parada de uma chamada com efeito e como fica o run store em cada um.

O processo parou	O run store contém	O mundo contém	A retomada faz
Antes de a proposta ser registrada	Nada para este passo	Nada	Monta o contexto e propõe de novo; nada é repetido
Depois do veredicto, antes da intenção	A proposta como <code>pending_proposal</code>	Nada	Devolve a proposta ao gate; se ele permitir, registra a intenção e aplica a chamada
Depois da intenção, antes do efeito	Uma intenção sem resultado	Possivelmente nada, possivelmente o efeito	Consulta o alvo pela chave; se ele informar que não houve efeito, registra “não aplicado” e passa a proposta pelo gate de novo; se ele não souber responder, faz o hand-off
Depois do efeito, antes do resultado	Uma intenção sem resultado	O efeito	Consulta o alvo pela chave e registra o resultado que ele informar; se ele não souber responder, faz o hand-off
Depois do resultado	A intenção e o resultado	O efeito	Continua com o próximo passo

O processo parou	O run store contém	O mundo contém	A retomada faz
Esperando aprovação, depois uma decisão	<code>pending_proposal</code> e uma aprovação	Nada	Devolve a proposta ao gate com a aprovação armazenada, como na segunda linha

A segunda linha existe porque o passo a escreve: depois de um veredicto `allow`, o orquestrador armazena a chamada como `pending_proposal`, e a escrita da intenção que vem em seguida a limpa; assim, o campo só fica preenchido no intervalo entre as duas. Se o processo morrer antes dessa escrita, o run se comporta como na primeira linha e o modelo propõe de novo, o que é seguro.

As duas linhas do meio são as perigosas, e elas parecem idênticas a partir do run store: uma intenção sem resultado. É por isso que o passo de recuperação não adivinha. Ele pergunta ao sistema-alvo o que aconteceu, usando a chave de idempotência, e trata “desconhecido” como um estado a entregar a uma pessoa, não como permissão para tentar de novo. A chave é a rede de segurança, não o plano: como o runtime a derivou de identificadores que ele mesmo atribuiu, o alerta vindo do trigger e a intenção vinda do orquestrador (Capítulo 6), uma chamada repetida devolve o primeiro resultado em vez de agir duas vezes, mesmo que um novo passo tenha proposto um `deployment_id` diferente. Um `deployment_id` obsoleto é recusado pela pré-condição sobre o deploy ativo; um que tenha se tornado ativo desde então é pego pela chave.

```

function resumeRun(runId, worker):
    run = acquireLease(runId, worker)           // fails if another worker
holds a live lease
    for each call in openIntents(run):
        found = queryEffectStatus(call)         // asks the target system,
using the call's key
        if not found.known:
            return handOff(run, "intent unresolved") // no retry, no new
proposal
        record(run, "effect", found.result)      // closes the gap the stop
left
        if found.result.status == "not_applied":
            run.pending_proposal = call.proposal // goes back through the
gate below
        refreshContracts(run)                   // tool definitions and
policy version, as of now
        run.facts = rereadFacts(run)            // stored facts are
history, not the present
        transition(run, "running", "resumed")
        if run.pending_proposal is not none:
            verdict = gate.check(run, run.pending_proposal) // current facts,
policy and stored approval
            run.pending_proposal = none
            if verdict.kind == "allow":
                executeCall(run, verdict.call) // intent, effect, outcome;
the key is unchanged
            else:
                addObservation(run, verdict) // a refusal or a new
approval request, seen by the model
            return runAgent(run)                // context is rebuilt from
state, not replayed

```

Leia o que o bloco não faz. Ele não confia que o run esteja onde foi deixado: os fatos são lidos de novo, e um contrato que mudou durante a espera é recolhido (o Capítulo 6 explica por que o gate sempre usa o contrato atual). Ele não reproduz a transcrição. Ele resolve as intenções abertas antes de o modelo propor qualquer coisa, porque um modelo que propõe por cima de um efeito não resolvido é como um rollback acaba sendo solicitado duas vezes. E ele não aplica um veredicto armazenado: um veredicto é uma declaração sobre os fatos do momento em que foi emitido.

O mesmo procedimento cobre os três eventos da abertura. Uma queda é um processo parando em uma das linhas acima. Uma aprovação longa é um run em `awaiting_approval` que não ocupa nenhum worker; quando a decisão chega, a proposta vinculada à aprovação é armazenada como `pending_proposal`, o run volta para `running` e o próximo worker chama `resumeRun`. Isso responde à abertura: a aprovação de Robin não se perde e o modelo não precisa adivinhar a chamada de novo, porque a chamada exata, com sua chave, é aplicada pelo gate assim que ele concordar. Um

deploy do orquestrador é uma queda para todos os runs em andamento ao mesmo tempo, e por isso a retomada precisa funcionar como um caminho de rotina e não como um reparo raro.

Uma aprovação que estava certa às 09:14 pode descrever o rollback de uma versão que já não é a que está em execução às 11:20. Nesse caso o gate recusa, a recusa volta ao modelo como observação, e a decisão de Robin continua registrada como o que foi: uma decisão sobre uma chamada que já não é a chamada.

Runs longos, deadlines e cancelamento

Toda espera precisa de um deadline, e todo deadline precisa de um destino. Um run tem um deadline geral, uma aprovação tem uma expiração (o Capítulo 15 trata do que uma aprovação significa; aqui ela é apenas o relógio) e o lease de um worker tem um fim. Quando um relógio estoura, a resposta é uma transição: uma aprovação expirada move o run para `handed_off` com a proposta pendente anexada, para que uma pessoa veja o que foi pedido e por quê. Não o moveria para `failed`, porque nada falhou, e não o deixaria esperando, porque uma espera sem limite é um bloqueio sem limite sobre o subject (veja a próxima seção).

Os números são seus para definir, e não os conheço para o seu sistema. Dependem de quanto tempo leva a sua investigação legítima mais lenta, da rapidez com que uma aprovação humana é respondida na prática e de quanto a espera custa. Digamos, um deadline de oito horas para o run e uma expiração de três horas para a aprovação. O que importa é que os dois números existam e estejam escritos ao lado da retenção da chave de idempotência do Capítulo 6: o piso da retenção é o deadline do run mais a maior espera por aprovação mais o intervalo do sweep descrito adiante. Uma chave que expira antes de o run mais longo poder terminar oferece um falso conforto.

O **cancelamento** tem duas partes, e misturá-las é uma armadilha comum. Solicitar um cancelamento é uma escrita no run: `cancel_requested` é definido por uma pessoa, um sistema ou um limite. Honrá-lo acontece na próxima fronteira de passo, onde o orquestrador verifica a flag antes de chamar o modelo de novo.

```

function runAgent(run):
  while run.status == "running":
    if clock.now() > run.deadline:
      return handOff(run, "deadline passed")
    if run.cancel_requested:
      resolveOpenIntents(run)          // an effect in flight is
resolved, never abandoned
      return transition(run, "cancelled", run.cancel_reason)
    try:
      bound.check(run)
      runStep(run)
    on BoundExceeded:
      record(run, "stopped", run.bound_reason)  // the record says
why the run stopped
      return handOff(run, "bound exceeded")
  return run

function requestCancel(run, reason):
  runStore.setFlag(run.id, cancel_requested: true, cancel_reason: reason)
  if run.status == "awaiting_approval":      // no loop is running to
notice the flag
    invalidateApprovals(run)                // a later decision cannot
apply the call
    run.pending_proposal = none
    transition(run, "cancelled", reason)

```

Um run suspenso à espera de aprovação não está dentro do loop; por isso `requestCancel` o move diretamente e anula a aprovação pendente; caso contrário, uma decisão que chegasse depois do cancelamento ainda poderia retomar o run e aplicar a chamada.

Cancelar não desfaz nada. Um efeito que já aconteceu permanece, e um run cancelado com uma intenção aberta ainda é reconciliado antes de se fechar. Se algo deve ser revertido, isso é uma ação compensatória, ou seja, uma nova proposta que passa pelo gate como qualquer outra, com a sua própria aprovação se a política assim determinar. Um botão de cancelar que promettesse em silêncio “tudo foi revertido” seria uma afirmação que o sistema não consegue cumprir; por isso o status mostra o que é verdade: cancelado, com a lista de efeitos que já tinham se concretizado.

Concorrência: leases e bloqueios

Dois tipos de concorrência aparecem na prática, e eles pedem controles diferentes. O primeiro é dois workers mexendo no mesmo run: depois de um reinício, um worker lento e um novo podem achar que o run é deles. O segundo é dois runs mexendo no mesmo subject: dois alertas para o mesmo serviço, ou dois tickets do mesmo cliente sobre o mesmo pedido.

Para o primeiro, um **lease** diz qual worker pode agir sobre um run por um tempo limitado. O worker o reivindica com uma escrita condicional, o renova enquanto trabalha e o perde quando para de renová-lo. Cada reivindicação incrementa um contador, o fence, e o worker envia o fence junto com seus efeitos, de modo que um alvo que o verifique possa recusar o detentor mais antigo. Um worker paralisado por uma longa pausa de coleta de lixo ou por uma partição de rede acorda ainda acreditando que detém o lease, e suas escritas no run store falham na verificação de versão. Seus efeitos sobre um serviço só estão protegidos se o serviço respeitar o fence ou a chave de idempotência, e digo com franqueza que o lease sozinho estreita a janela, mas não a fecha.

```
function acquireLease(runId, worker):
    lease = runStore.claim(runId, owner: worker, until: clock.now() +
    leaseSeconds,
                                where: leaseIsFreeOrExpired)    // a single
    conditional write
    if lease is none:
        raise LeaseHeld
    return lease                                                // lease.fence
    grows on every claim

function startRun(subject, kind):
    run = runStore.createIfNoActive(subject.key, kind)          // unique on
    subject key among non-terminal runs
    if run is none:
        return { outcome: "attached", run: activeRunFor(subject.key) }
    return { outcome: "created", run: run }
```

Para o segundo, a regra é um run ativo por subject, imposta por uma restrição de unicidade no run store e não por uma verificação no código da aplicação que dois workers podem passar ao mesmo tempo. A segunda requisição para o mesmo subject se anexa ao primeiro run, ou entra na fila atrás dele, ou é recusada com o id do run que detém o subject. Qual dessas opções é a certa depende da tarefa: uma segunda mensagem do cliente no mesmo ticket provavelmente deve ser adicionada à investigação em andamento, e um segundo alerta para o mesmo serviço provavelmente deve ser vinculado a ela. A chave do subject vem do trigger (o ticket, o alerta), nunca do modelo, pelo mesmo motivo que as chaves de idempotência também não vêm: uma chave que o modelo pudesse variar não é um bloqueio.

Nível	O que impede	Onde é imposto	O que não cobre
Lease sobre o run	Dois workers agindo sobre um run	Escrita condicional no run store	Um efeito já em trânsito para um serviço que ignora o fence
Bloqueio sobre o subject	Dois runs sobre um ticket ou alerta	Unicidade no run store	Dois subjects diferentes que mexem no mesmo serviço
Pré-condição no gate	Duas solicitações de rollback para um serviço	O gate, lendo o próprio estado do serviço	Qualquer coisa que o serviço não exponha
Chave de idempotência	A mesma intenção aplicada duas vezes	A ferramenta ou o serviço	Uma intenção diferente para o mesmo efeito

A terceira linha cobre um caso que o bloqueio sobre o subject não consegue: dois alertas para o mesmo serviço chegam em dois runs, e ambos põem um rollback. Nenhuma chave de subject os liga. O gate verifica as pré-condições junto ao `deploy-service`, que é a verdade sobre os deploys: o deploy ainda é o ativo do seu serviço, e nenhum rollback está em andamento para ele. O run store registra o que o orquestrador fez; não é autoridade sobre o que o `deploy-service` está fazendo. O contrato do Capítulo 6 mostra onde essas linhas ficam (trecho, números ilustrativos).

```

tool request_rollback                                // as in Chapter 6; excerpt
input schema:
  required: [deployment_id, summary]
  properties:
    deployment_id: { type: string }
    summary:       { type: string, maxLength: 500 }
  effect class: reversible write
  preconditions:                                     // checked by the gate at the moment
of the effect
  - deployment is the active one for its service, as reported by deploy-
service
  - a previous version exists to roll back to
  - no rollback is already in progress for this deployment
  idempotency: key = hash(alert_id, rollback_intent_id)
  // alert_id comes from the run's trigger (the subject key), so the
runtime assigns it;
  // deployment_id is a model-supplied field, so it stays in the
preconditions and out of the key
  permissions: scope "deploy:rollback", approval by on-call required

```

Aviso: Uma chave de idempotência construída a partir do id do run é uma chave diferente em cada segundo run para o mesmo alvo, e uma construída a partir do id do passo muda sempre que um loop reconstruído numera os passos de outra forma. A repetição então age duas vezes. O Capítulo 6 trata da construção: as chaves vêm de identificadores que o runtime atribui ao alvo e à intenção, para que uma retomada e um retry correspondam à mesma chave.

Um bloqueio mantido enquanto um run espera por uma pessoa tem um custo, e é fácil não o notar. Um run em `awaiting_approval` não ocupa nenhum worker, mas ainda detém o seu subject; assim, um segundo alerta para o mesmo serviço fica bloqueado atrás de uma aprovação que pode levar até as três horas da sua expiração. Daria ao bloqueio a mesma expiração da aprovação e deixaria uma pessoa quebrá-lo a partir da fila. A alternativa, liberar o subject enquanto o run espera, permite que um segundo run proponha o mesmo rollback nesse intervalo, e o gate e a chave passam a ser a única proteção. Para escritas irreversíveis, manteria o bloqueio; para uma investigação somente de leitura, liberaria o bloqueio.

Reler o mundo e o sweep de reconciliação

O orquestrador mantém dois tipos de fato, e eles têm autoridades diferentes. Os fatos sobre o histórico do próprio run (o que foi proposto, o que foi aplicado, o que foi aprovado) são definitivos no run store, porque o orquestrador os escreveu em ordem. Os fatos sobre o mundo (a versão do deploy, o status do pedido, o endereço da remessa) são definitivos no sistema que os possui, e o run store guarda apenas uma cópia carimbada: um valor, uma hora e uma origem.

A regra que decorre disso é ler antes de agir. Antes de um efeito que depende de um fato do mundo, o gate lê o fato de novo, como mostra o contrato acima, e o compara com o que a proposta supôs. Na retomada, o orquestrador lê de novo tudo o que colocará diante do modelo e marca como obsoleto, com sua idade, no contexto, tudo o que não conseguiu atualizar (o Capítulo 9 trata de como o rótulo aparece). Isso transforma a F5 de uma surpresa em uma recusa: um rollback construído sobre uma versão que mudou desde então falha no gate com `precondition_failed`, e o modelo vê por quê.

A lembrança que o modelo tem dos fatos não tem autoridade nenhuma. Se o resumo de um run diz “a flag já está desligada”, o orquestrador não age com base no resumo. Ele lê a flag.

A segunda metade desta seção responde a uma promessa feita três vezes em capítulos anteriores. Intenções sem resultado, resultados sem resposta, runs marcados como concluídos com intenções abertas: os capítulos 3, 5 e 6 disseram, cada um, que um job de reconciliação pega o que o próprio run não pegou. Este é esse job, e é o único componente que observa o run store de fora do run.

```
function reconcileSweep(now):
  // active runs are always scanned; only finished runs are limited to a
  recent window
  candidates = runStore.runsInStates(["running", "awaiting_approval"])
    + runStore.runsInStates(["done", "failed", "handed_off"],
  since: now - sweepWindow)
  for each run in candidates:
    for each call in openIntents(run):
      if now - call.intent_at > staleAfter:
        finding(run, "intent_without_outcome", call)          //
  resolve by status query, else a person
      if run.status == "done" and openIntents(run) is not empty:
        finding(run, "done_with_open_intent", run.id)          // the
  invariant broke; this is a bug
      if run.status in ["failed", "handed_off"] and openIntents(run) is
  not empty:
        finding(run, "terminal_with_open_intent", run.id)      // status
  query; a new outcome record on the run, else a person
      if run.status == "running" and run.lease.until < now
        and (run.resume_condition is none or run.deadline < now): // a
  parked run waits for a reset or a closed breaker (Chapter 13), but only
  until its deadline
        finding(run, "orphaned_run", run.id)                    // resume
  it
      if run.status == "awaiting_approval"
        and any approval in run.approvals where approval.status ==
  "pending"
        and approval.expires_at <
  now:
        finding(run, "expired_approval", run.id)                // move
  to handed_off
        heartbeat("reconcile_sweep", now)                       // a
  missing heartbeat is itself an alert
```

Cada achado é resolvido por uma consulta de status e um resultado registrado, ou colocado numa fila para uma pessoa com a intenção registrada anexada. O sweep olha em uma única direção: do run store para o mundo. A direção oposta, um efeito num serviço downstream que nenhuma intenção de nenhum run explica, exige que o serviço exponha suas mudanças

recentes por chave e, onde ele o fizer, adicionaria isso, pois é a verificação que pega um efeito aplicado por um caminho que contornou o orquestrador. Onde o serviço não a expõe, diga isso no runbook em vez de fingir que a verificação existe. Na Parcelport isso importa mais para `issue_refund`: quando a chamada ao `payments-service` dá timeout, ela termina como `outcome_unknown`, e o sweep a resolve perguntando ao `payments-service` pelo reembolso por sua chave, ou a envia a uma pessoa com a intenção anexada.

O sweep é um pequeno sistema com um responsável. Ele precisa de acesso de leitura a vários serviços, de um limiar que alguém ajustou e de alguém que receba um page quando ele encontrar algo ou parar de rodar. Um sweep que ninguém monitora é teatro: produz achados que ficam parados numa tabela. O Capítulo 20 trata das métricas e dos alertas construídos sobre esses achados, e o Capítulo 23 trata do que uma pessoa faz com um achado que se revela um incidente.

Trade-offs e custos

O estado durável custa uma escrita em cada passo e duas escritas em torno de cada efeito. Para uma leitura, a escrita da intenção é sobrecarga, e a pularia e manteria o resultado. Para escritas e efeitos colaterais externos, acho que o custo vale a pena, pois é o custo de saber o que aconteceu.

O run store se torna uma dependência compartilhada por toda a frota. Se ele estiver indisponível, falharia fechado para os efeitos: um run que não consegue registrar uma intenção não aplica o efeito, porque um efeito sem intenção é o caso da F8. As leituras podem continuar por algum tempo. A disponibilidade do run store, portanto, define um teto para a disponibilidade de tudo o que escreve, e a equipe de plataforma precisa tratá-lo como o banco de dados de produção que ele é.

A máquina de estados é rígida de propósito, e a rigidez tem um preço. Adicionar um estado é uma migração: os runs em andamento sob a definição antiga ainda precisam se resolver. Uma versão de esquema e uma versão de política em cada run tornam isso tratável, mas alguém precisa decidir o que um run retomado faz quando seu esquema é mais antigo que o

código. A resposta mais barata, fazer o hand-off de qualquer run cuja versão de esquema o código atual não consegue ler, é também a mais segura; custa uma revisão humana no dia do deploy.

Leases e bloqueios acrescentam superfície operacional. Tempos de lease curtos demais fazem workers saudáveis perderem runs; tempos longos demais deixam preso o run de um worker morto. O bloqueio sobre o subject faz as pessoas esperarem, e um bloqueio mantido durante uma aprovação precisa de um responsável que possa quebrá-lo. Não conheço os números certos; comece pelo passo legítimo mais longo para o lease e pelo tempo realista de resposta a uma aprovação para o bloqueio, meça os runs presos e ajuste.

A retenção é um custo com dois lados. O estado que vive tempo suficiente para cobrir as chaves de idempotência e as revisões de incidentes também guarda resultados de ferramentas, que podem conter PII; por isso o run store é um armazenamento de dados sensíveis e precisa seguir as regras de minimização do Capítulo 17.

Quando não usar tudo isto: uma tarefa de leitura única, como responder a uma pergunta a partir de documentos, não tem efeito a proteger, e um run barato de reiniciar pode reiniciar. Um log do que aconteceu basta, e um lease e um bloqueio seriam maquinário sem falha a prevenir. O peso deste capítulo deve acompanhar as classes de efeito que o agente alcança: quanto mais delas forem escritas, mais o run store merece seu lugar.

Erros comuns

- **Tratar a transcrição como estado e retomar reproduzindo-a.** É tentador porque ela já está ordenada e o modelo consegue lê-la. Ela tem perdas, é cortada e está cheia das afirmações do próprio modelo, e reproduzi-la pede uma nova proposta por cima de um efeito não resolvido. Armazene o estado no run store, resolva as intenções abertas e só então renderize um contexto novo.
- **Um campo de status de forma livre que qualquer caminho de código escreve.** É rápido e termina com runs em estados que ninguém definiu, incluindo `done` com uma intenção sem resultado. Faça toda mudança passar por uma única função de transição com verificação de versão e deixe que ela recuse esse caso.

- **Construir chaves de idempotência a partir de identificadores de run ou de passo.** Eles estão à mão e são únicos. Mudam num segundo run e num loop reconstruído, que é exatamente quando a chave é necessária. Derive as chaves de identificadores que o runtime atribui ao alvo e à intenção.
- **Um lease sem fence e sem verificação de versão.** Os heartbeats parecem bastar. Um worker pausado acorda e escreve. Escritas condicionais no run store e fences em direção aos serviços estreitam a janela.
- **Cancelar como matar o processo.** É fácil de construir. Deixa intenções sem resultado e um status que não diz nada. Cancelar é uma flag honrada numa fronteira de passo, seguida de reconciliação.
- **Construir o sweep e não ser responsável por ele.** O job existe, então a caixa está marcada. Sem limiar, sem heartbeat e sem um responsável de on-call, seus achados são uma tabela que ninguém lê.

Pontos-chave

- O estado do run pertence a um run store durável, de propriedade do orquestrador, e o contexto do modelo é uma visão renderizada a partir dele em cada passo, nunca o lugar onde o estado vive.
- Um run é uma máquina de estados cujas transições válidas estão escritas no código, aplicadas por uma única função com verificação de versão e inalcançáveis pelo modelo; uma resposta final é uma proposta que o orquestrador converte em `done` apenas quando nenhuma intenção está aberta.
- A retomada reconstrói o contexto a partir do estado em vez de reproduzir uma transcrição: ela assume o lease, resolve as intenções abertas perguntando ao sistema-alvo pela chave, relê fatos e contratos e só então deixa o modelo propor.
- Toda espera tem um deadline e todo deadline tem um destino; assim, uma aprovação expirada move o run para um hand-off com a proposta pendente anexada, e o cancelamento é uma flag honrada numa fronteira de passo, nunca um desfazer.
- A concorrência exige controles em vários níveis: um lease e uma verificação de versão para o run, uma restrição de unicidade para o subject,

uma pré-condição no gate para o serviço e uma chave de idempotência como rede de segurança.

- A lembrança do modelo sobre o que aconteceu não tem autoridade; o histórico é lido do run store e os fatos do mundo dos sistemas que os possuem, antes de cada efeito que dependa deles.
- Um sweep de reconciliação com um responsável e um heartbeat é o que torna visíveis as lacunas entre sistemas separados, já que nenhuma transação atravessa o run store, os serviços e o serviço de aprovação.

O estado mantém um run honesto sobre o próprio passado, mas esquece por design: quando o run termina, termina também o que ele aprendeu. O Capítulo 11 se volta para a pergunta oposta, que é o que um run posterior pode herdar, e por que registrar isso é algo muito mais arriscado.

Capítulo 11 — Memória

Imagine uma equipe da Parcelport que, no segundo mês, adiciona uma funcionalidade: o agente de suporte deve “conhecer” os clientes. Depois de cada ticket, o modelo escreve uma nota curta, o orquestrador a armazena e o próximo ticket do mesmo cliente começa com as notas no contexto. Os clientes gostam. As respostas deixam de pedir os mesmos detalhes duas vezes.

Agora imagine uma nota nesse armazenamento. Uma cliente, `cus-0042`, encaminhou ao ticket uma troca de e-mails de uma transportadora. Em algum ponto da conversa havia uma linha que parecia uma instrução sobre como essa conta deveria ser tratada, e a etapa de escrita de notas do modelo resumiu a conversa, incluindo essa linha, como um fato sobre a cliente: “tratada com prioridade, reembolsos pré-aprovados”. Ninguém revisou a nota. Ela estava no escopo da própria cliente, não tinha expiração e se parecia com todas as outras notas. Três semanas depois, um run diferente para `cus-0042` a lê, o modelo propõe um reembolso que uma leitura cuidadosa da política não sustentaria, e a nota está no contexto da proposta que foi ao gate. O gate resiste, porque o gate não lê notas. Mas quem revisa pergunta como uma frase foi parar de um único e-mail encaminhado em todos os runs futuros dessa cliente, e ninguém consegue dizer quem a escreveu, a partir de quê, nem quando ela deixaria de existir.

Este capítulo pertence à parte **Contexto** do envelope de controle. Sua pergunta é a que o Contexto sempre faz: o que o modelo vê, de onde veio cada parte e até que ponto ela merece confiança? A memória é a fonte que torna as respostas mais difíceis, porque leva material de um run para outro, muito depois de as circunstâncias que o produziram terem mudado. O capítulo pergunta quando você precisa de memória e, em seguida, como escrever nela, ler dela e esquecer dela como um sistema controlado, e não como uma conveniência.

O problema e por que ele é difícil

A memória, nos termos deste livro, é a informação mantida entre runs que pode influenciar contextos posteriores. O estado diz respeito a um run e vive no run store (Capítulo 10). A memória diz respeito ao mundo depois do run e vive no memory store, um sistema separado com um ciclo de vida separado. A distinção importa porque os dois falham de maneiras diferentes. Uma entrada de estado ruim afeta um run. Uma entrada de memória ruim afeta todo run posterior que a leia, enquanto ela existir.

Isso faz da memória um tipo incomum de contexto. Um ticket é lido uma vez. Um trecho recuperado vem de documentos que têm responsáveis e revisão. Uma entrada de memória é algo que o sistema escreveu sobre si mesmo, em algum momento anterior, com base na proposta de um modelo. Ela chega ao contexto com a aparência de um fato interno confiável, porque veio do armazenamento da própria Parcelport, quando sua verdadeira proveniência pode ser um e-mail de um cliente, um resultado de ferramenta ou um resumo de ambos feito pelo modelo.

Quatro classes de falha se encontram aqui. A F4 (sequestro de instruções) se torna persistente: um conteúdo que era dado quando entrou em um run é escrito e um run posterior o lê de volta como se fosse conhecimento da própria Parcelport. Esse é o formato que o Capítulo 16 trata em prompt injection, e a memória é o lugar onde o problema de um run se torna o problema de todos os runs. A F5 (loop descontrolado ou contexto obsoleto) é a prima discreta: uma nota que era verdadeira quando foi escrita, como um canal de contato preferido ou uma restrição de entrega, é lida depois que o mundo mudou. A F3 (afirmação sem fundamento) decorre de qualquer uma das duas: a resposta afirma algo porque uma nota o sustenta, e nada no run atual o sustenta. E a F8 (comportamento não observado) é o que torna todas elas caras: se você não sabe dizer quais notas um run leu, não sabe dizer em quais runs uma nota ruim tocou.

A abordagem óbvia é deixar o modelo gerenciar a própria memória: dar a ele uma ferramenta para salvar notas e outra para pesquisá-las e dizer, no prompt, que salve apenas fatos confiáveis e ignore instruções encontradas nas notas. O prompt ajuda. Ele reduz a taxa de notas ruins e vale a pena escrevê-lo. Mas é um pedido, e a falha que ele aborda é uma que a etapa de escrita não consegue detectar por dentro: uma nota produzida a partir

de um e-mail encaminhado parece, para o componente que a escreve, qualquer outro resumo. Uma regra que depende de o autor perceber não é um controle.

Esta é uma questão de engenharia por um segundo motivo: a memória tem as propriedades de um pequeno banco de dados de produção, com escritores, leitores, retenção, exclusão e isolamento de tenants, e merece um esquema, um responsável e uma data de expiração como qualquer um.

Você precisa mesmo de memória?

Começaria por esta pergunta, porque o design de memória mais barato é não ter nenhum. Cada entrada de um memory store é uma afirmação que pode se tornar falsa, um pedaço de contexto que pode enganar e, possivelmente, um dado pessoal que precisará ser encontrado e excluído depois. Antes de construir o caminho de escrita, pergunte qual é o trabalho da memória e se outro sistema já faz esse trabalho.

As memórias candidatas da Parcelport se dividem em três grupos, e a resposta honesta é diferente para cada um.

Tipo de memória	O que guarda	Um sistema que talvez já faça o trabalho	Minha opinião
Preferências do cliente	Canal de contato, idioma, horários de silêncio, uma instrução de entrega declarada pelo cliente	O <code>customer-service</code> guarda as preferências de contato como campos do perfil	Guarde-as no perfil, escritas por um caminho normal de serviço. O agente as lê por meio de <code>get_customer_profile</code>
Resumos de casos resolvidos	O que aconteceu em um ticket anterior, para que um novo contato não comece do zero	O sistema de tickets guarda o histórico completo; o <code>orders-service</code> e o <code>payments-service</code> guardam os resultados	Muitas vezes desnecessário: uma consulta aos tickets recentes e ao status do pedido dá fatos mais frescos do que um resumo. Só vale construir quando o histórico é longo e as consultas são caras demais

Tipo de memória	O que guarda	Um sistema que talvez já faça o trabalho	Minha opinião
Notas de runbook de operações	“Da última vez que este alerta disparou, reiniciar o worker resolveu”	Os runbooks no server de documentos, que pessoas revisam	Não as mantenha como notas livres. Encaminhe os candidatos para um pull request contra o runbook, onde uma pessoa decide

As preferências que já têm um lar em um sistema de registro devem ficar lá, porque o sistema de registro tem um responsável, um caminho de correção e, em geral, um caminho de exclusão. Uma segunda cópia em um memory store é um segundo lugar para estar errada. A memória merece o seu lugar quando todas estas condições se cumprem: o fato não está em um sistema de registro, será útil em um run posterior, uma versão errada dele custaria menos do que o valor que ele agrega e alguém consegue dizer por quanto tempo ele continua verdadeiro. Quando uma das quatro falha, prefira a alternativa. Para o agente de operações, a alternativa é quase sempre o runbook, e a funcionalidade de memória é uma forma de propor mudanças no runbook às pessoas por meio de `open_pull_request`, onde uma pessoa faz o merge.

Mais cinco condições argumentam por nenhuma memória, ou por nenhuma ainda:

- **Uma nota obsoleta é cara.** Onde agir com base em um fato antigo movimenta dinheiro ou mexe em uma remessa (um endereço, um reembolso), uma nota é um perigo. Derive de novo a partir dos serviços todas as vezes.
- **Os runs precisam ser reproduzíveis.** Um memory store que mudou entre uma investigação e sua reexecução é mais uma entrada para registrar em snapshot. Para evals, rode com a memória congelada ou vazia.
- **Ninguém é responsável pelo ciclo de vida.** A revisão de quarentena, os pedidos de correção e os jobs de expiração são trabalho para pessoas e para o on-call, e um armazenamento sem responsável é pior do que nenhum.

- **A população é anônima ou de uma vez só.** Um agente que atende cada desconhecido uma única vez não tem nada a lembrar, e cada entrada é apenas um passivo.
- **Cada run deve começar limpo.** Numa investigação do `ops-agent`, uma hipótese herdada de um incidente anterior é um jeito de se ancorar na causa errada.

Um design sem memória tem custos próprios: os contatos repetidos começam do zero e os clientes reafirmam preferências. Esses custos são visíveis e limitados. Os custos de um memory store se espalham no tempo e são difíceis de ver, e é por isso que pagaria primeiro os visíveis.

Não sei qual é a resposta certa para os seus agentes sem vê-los trabalhar. Se o seu agente de suporte atende principalmente tickets de primeiro contato, a memória de resumos de casos pode nunca ser lida. Um jeito barato de descobrir é registrar em log o que um design de memória teria devolvido ao longo de um mês de tickets, sem colocá-lo no contexto, e ver se alguma resposta teria mudado. Essa é uma questão de eval (Capítulo 21), e é mais barata do que construir o armazenamento primeiro.

O restante do capítulo supõe que você decidiu que vale a pena manter alguma memória. Para a Parcelport, isso é um conjunto pequeno e tipado para o `support-agent`: preferências de contato que o perfil ainda não consegue guardar e notas estruturadas sobre resultados anteriores.

A memória é escrita por proposta

O princípio do livro se aplica aqui sem alteração: o modelo é um gerador de propostas, e o que ele devolve é entrada não confiável. Uma escrita de memória é um efeito, porque muda o que os runs posteriores veem. Assim, o modelo propõe uma memória, e o código a valida, decide se a armazena e decide como.

Duas decisões dão a maior parte da proteção, e ambas dizem respeito à forma.

Tipe a memória. Uma entrada de memória tem um `kind` tirado de um conjunto fechado, e cada `kind` tem um esquema. Uma preferência de contato é um valor de enum, não uma frase. Uma nota de caso tem campos fixos. O motivo é simples: um valor tirado de um enum não consegue carre-

gar instruções, e um validador consegue verificá-lo por completo. Texto livre pode carregar qualquer coisa, e nenhum validador distingue um resumo de uma mensagem dirigida a um leitor futuro.

Construa os fatos a partir do registro, não da prosa do modelo. Em um caso resolvido, os fatos que vale guardar já estão no run store e nos serviços: qual pedido, qual reason code, se um reembolso foi emitido e em que valor, qual resposta foi enviada. O código pode escrever essa nota a partir do registro dos efeitos. A contribuição do modelo é, no máximo, uma escolha entre rótulos fechados, como uma tag de assunto. A nota diz “reembolso emitido, reason_code damaged, pedido ord-7f3k2m91” porque o efeito de pagamento diz isso, e não porque um modelo resumiu uma conversa que incluía o e-mail de alguém.

Aqui está uma ferramenta ilustrativa para a proposta, seguindo a forma de contrato do Capítulo 6. A ferramenta é nova neste capítulo, pertence apenas ao `support-agent`, e o modelo fornece somente os campos do seu esquema de entrada.


```

tool propose_memory                                // illustrative tool, support-agent
only
  description: "Propose one typed note about the customer of this run."
  input schema:                                     // fields the model supplies
    type: object, additionalProperties: false
    required: [kind, value, evidence_step_id]
    properties:
      kind:                                           { enum: [contact_channel, quiet_hours, language] }
      value:                                         { enum: per kind, closed list in the schema registry }
  }
  evidence_step_id: { type: string } // a step of this run that holds
the source message
  effect class: reversible write                    // stores a candidate in the run
store; the orchestrator                            // writes the entry after the run

ends, deletable by id
preconditions:                                     // checked by the gate, not the
model
  - evidence step is a message authored by the customer through the
    authenticated channel, not a forwarded or quoted part and not a tool
result
  - kind is allowed for the agent in memory policy
  - run has no open hand-off to a human
idempotency: key = hash(customer_id, memory_intent_id)
// memory_intent_id is assigned by the orchestrator, once, when the gate
// resolves the evidence step to a message in the record: one intent per
// (message, kind slot). Neither the run id nor the step id is in the
// key, and the model supplies no identifier: it only points at a
// message and picks a kind from the closed list. The same preference
// proposed again in a later step, or after a timeout whose first
// attempt was in fact stored, resolves to the same intent and returns
// the first result. A new customer message is a new intent
permissions: scope "memory:propose", delegated for this customer only
timeouts: call 5s, deadline 15s // illustrative
error shape: { code, message, retryable, details }
// code in [invalid_arguments, precondition_failed, not_permitted,
// duplicate_replayed, upstream_unavailable]

```

Três coisas no contrato são deliberadas. O cliente nunca é um campo fornecido pelo modelo: o escopo de cada entrada é o cliente do run, atribuído pelo orquestrador, de modo que uma proposta não consegue escrever na memória de outro cliente (o Capítulo 7 explica a delegação por trás disso). O valor é um enum, de modo que a coisa mais forte que uma proposta pode dizer é uma escolha entre as de uma lista que a equipe revisou. E a evidência é um identificador de passo que o gate resolve para uma mensagem no registro, o que torna a pré-condição verificável por código: o gate olha quem criou aquele passo e por qual canal.

A restrição de tipo custa algo. Um conjunto fechado não consegue guardar “prefere entrega pela porta lateral, o cachorro é amigável”, e os clientes dirão coisas que não cabem em nenhum enum. Aceitaria isso. Uma equipe

que precise de notas mais ricas pode adicionar um kind com um esquema quando a necessidade for demonstrada, e cada adição é uma decisão de design com um responsável, não um efeito colateral de um prompt.

A política de escrita

Uma política de escrita responde a cinco perguntas para cada tipo de memória: quem pode escrever, o que pode ser escrito, com que proveniência, em que escopo e por quanto tempo. Escrevê-la como dado, da mesma forma que as outras políticas, é o que a torna revisável. A notação abaixo é ilustrativa.

```
policy memory_write:                                // illustrative notation
  kind contact_channel:
    writer: orchestrator, on proposal from support-agent
    source: customer message, authenticated channel, evidence required
    scope: customer_id of the run
    ttl: 180 days from last confirmation              // illustrative
    status on write: active
  kind quiet_hours, kind language:
    same as contact_channel, ttl 180 days            // illustrative
  kind case_note:
    writer: orchestrator, built from the run's effect records
    source: run store (effects), no model-authored text
    scope: customer_id of the run
    ttl: 90 days                                     // illustrative
    status on write: active
  supersede (contact_channel, quiet_hours, language): one live entry per
    customer and kind; an active entry whose declared_at is newer marks the
    old one "superseded", and the old one stays for audit until its ttl;
    a quarantined entry supersedes nothing until a review makes it active
  case_note: never superseded; accumulates, bounded by its ttl and by the
    read budget
  deny: any kind not listed, any write whose scope is not the run's customer
```

A linha `supersede` é o que permite que uma preferência mude. Um cliente que pediu contato por mensagem em março e por e-mail em junho produz uma segunda entrada; a primeira passa a `superseded`, o caminho de leitura a ignora e o histórico continua lá para uma revisão. A ordem é por `declared_at`, a hora da mensagem do cliente em que a entrada se baseia, e não pela hora em que a escrita rodou. Um run que esperou uma aprovação pode terminar depois de um run mais novo; se a hora da escrita decidiu, a fase de escrita de quarta-feira colocaria a preferência de segunda acima da de terça. Uma escrita cujo `declared_at` é mais antigo que o da entrada ativa é armazenada como `superseded` imediatamente. A regra é deliberadamente separada da chave de idempotência, que apenas impede

que uma escrita repetida seja aplicada duas vezes. As notas de caso ficam fora dela: um histórico do que foi feito por um cliente se acumula, e uma segunda nota não deve esconder a primeira.

Leia isso como a resposta ao cenário de abertura. A frase que chegou dentro de um e-mail encaminhado teria sido recusada na primeira pré-condição, porque o passo de evidência não é uma mensagem criada pelo cliente. Um resumo de uma conversa feito pelo modelo não pode se tornar uma nota, porque nenhum kind aceita texto escrito pelo modelo. E uma nota sobre “reembolsos pré-aprovados” não pode existir, porque nada no conjunto descreve autoridade.

Esse último ponto é uma regra por si só: **a memória nunca carrega autoridade**. Nenhuma entrada concede, amplia ou dispensa uma permissão, e o gate não consulta o memory store quando decide. A autoridade vem da delegação no run (Capítulo 7) e do motor de políticas. Se a memória pudesse dizer “este cliente pode exceder o teto”, uma nota contaminada se tornaria um caminho para contornar o gate. Trataria isso como uma invariante e a testaria: uma proposta que só passaria pelo gate se uma nota de memória fosse verdadeira deve ser recusada.

O lugar onde a escrita acontece também importa. Rodaria a fase de escrita de memória depois que o run terminou, no orquestrador, e não como uma chamada de ferramenta no meio de um loop. Nesse ponto o registro do run está completo, o orquestrador sabe quais itens estavam no contexto e de onde veio cada um (os rótulos de origem e de confiança do Capítulo 9), e uma escrita pode ser recusada com base nesse conhecimento. A ferramenta é chamada no loop, mas apenas armazena um candidato; a escrita em si acontece depois do run. Uma escrita no meio do run não poderia ver como o run terminou. Um run que foi cancelado, ou que terminou em um hand-off, não deve deixar notas para trás, porque suas conclusões não foram aceitas por ninguém.

```

function runMemoryWritePhase(run):
  if run.status != "done":
    return // cancelled and handed-off
  runs leave no memory
  for each proposal in run.memory_proposals:
    verdict = gate.check(run, proposal) // contract, evidence, scope
    if verdict.kind != "allow":
      record(run, "memory_refused", verdict.reason)
      continue
    entry = buildEntry(run, proposal, policy: "memory_write") // key
    from the contract
    if suspicious(proposal): // valid evidence, value not
    in it
      entry.status = "quarantined" // skipped by the read path
      record(run, "memory_quarantined", entry.id)
      // the entry is complete before it is stored
      // scope, ttl, provenance and status come from code, not from the
    model
    memory.put(entry) // supersede only if entry
    is active
    record(run, "memory_written", entry.id) // a second system; a gap is
    possible
    for each fact in run.effect_records:
      note = buildCaseNote(run, fact)
      // key = hash(effect_record_id): it exists before the write, so a
      // phase that restarts after a crash cannot create a second note
      if memory.exists(note.key):
        continue
      memory.put(note)
      record(run, "memory_written", note.id)

```

Os dois loops chegam à idempotência por caminhos diferentes, de propósito. Uma proposta carrega a chave do seu contrato, `hash(customer_id, memory_intent_id)`, de modo que uma escrita repetida cai na mesma entrada. Uma nota de caso não tem contrato nem id de intenção, então sua chave vem do registro de efeito. A verificação difere porque o objetivo difere: uma proposta pode substituir uma entrada anterior do mesmo kind, enquanto uma nota de caso nunca deve sobrescrever nem esconder uma anterior (a regra supersede acima); por isso o loop verifica `memory.exists` e pula, em vez de escrever de novo.

A escrita da memória e a escrita do registro em cada loop são sistemas separados, o memory store e o registro, e não os envolvi em uma transação. Se o processo parar entre os dois, existe uma entrada sem registro da sua escrita. A detecção é uma reconciliação periódica: cada entrada carrega `written_by_run`, e um job lista as entradas cujo run não tem evento

`memory_written`. A própria proveniência da entrada é a chave de reparo. É por isso que a entrada precisa carregar essa proveniência por conta própria, em vez de depender do trace para dizer de onde ela veio.

A própria entrada é um registro com estes campos. Mantenha-o pequeno.

```
record memory_entry                                // illustrative shape
  id, kind, value
  declared_at:   time of the evidence message    // orders supersede
  scope:         customer_id                     // set by the orchestrator
  written_by_run: run_id
  evidence:      { step_id, channel, authored_by } // copied from the
record, not the model
  created_at, last_confirmed_at, expires_at
  status:        enum [active, superseded, quarantined, expired, deleted]
  source:        enum [customer_message, effect_record]
  schema_version: integer
```

Lendo a memória para o contexto

Escrever é metade do design. O caminho de leitura é onde uma entrada de memória encontra o modelo, e ele faz parte da montagem do contexto (Capítulo 9), sob as mesmas regras de qualquer outra fonte: o quê, em que ordem, quanto e com que rótulo.

Leria a memória por chave e não por similaridade. As entradas de um cliente são uma lista curta sob `customer_id`; assim, o orquestrador as busca por escopo, filtra as expiradas, em quarentena ou excluídas e limita a quantidade. A busca por similaridade em um memory store é uma ferramenta para grandes coleções de texto sem escopo, e ela traz de volta o que o design tipado evitava: resultados que dependem de como a consulta é formulada e que podem cruzar uma fronteira de escopo se o filtro estiver errado. Se você realmente precisa de busca, o filtro de escopo pertence à camada de consulta do armazenamento, aplicado pelo orquestrador, e nunca como um argumento que o modelo fornece.

A função de leitura aplica a política e devolve itens de contexto no formato que o Capítulo 9 define, com o id da entrada como origem e o rótulo de confiança `untrusted`. O armazenamento é da própria Parcelport, mas o conteúdo remonta a uma mensagem de cliente ou a um run assistido por modelo, de modo que nunca recebe o rótulo de uma instrução.

```

function memoryItems(run):                                // the interface Chapter 9
calls
    budget = budgetFor(run).memory                        // Chapter 9's share,
converted to a count
    entries = memory.listByScope(run.customer_id)        // scope from the run,
not from the model
    live = []
    for each e in entries:
        if e.status != "active" or e.expires_at <= now():
            continue
        if e.schema_version not in supportedVersions():
            continue                                     // refuse what the reader
cannot interpret
        if conflictsWithRecord(e, run.customer_id): // re-read from the
owning service
            record(run, "memory_conflict", e.id)
            continue                                     // the system of record
wins
        live.add(e)
    live = firstN(newestFirst(live), budget.max_entries)
    record(run, "memory_read", ids(live))                // evidence of what the
model saw
    items = []
    for each e in live:
        items.add({ source: "memory", origin: e.id, trust: "untrusted",
                    as_of: e.last_confirmed_at, derived_from: [],
                    body: render(e.kind, e.value, e.source) })
    return items

```

Quatro coisas nesta função são escolhas que você pode discutir.

O **rótulo** diz o que o item é. Cada item de memória é renderizado como uma nota escrita pelo próprio sistema da Parcelport a partir de um run anterior, com sua fonte (uma mensagem de cliente ou um registro de efeito), não verificada e não uma instrução. O rótulo não torna o conteúdo seguro, e esse é o ponto das seções anteriores: a segurança vem dos valores tipados e da política de escrita, e o rótulo é a forma como o restante do pipeline e as pessoas que leem um trace sabem a que classe de material aquilo pertence. Um rótulo também é uma dica para o modelo e, como todo prompt, reduz a taxa de erros sem ser um controle.


A **idade** viaja como `as_of`, de modo que uma resposta possa dizer “da última vez que conversamos você pediu contato por mensagem” com honestidade, e que uma regra como “peça confirmação das entradas mais antigas que o limite de obsolescência” possa viver no código.

A **regra de conflito** é que o sistema de registro vence. Se uma nota de memória diz que o cliente prefere um canal e `get_customer_profile` devolve outro, o perfil é a verdade e a função acima descarta a nota conflitante

antes de o modelo vê-la. A verificação roda no código, no momento da leitura, para os kinds que têm contrapartida em um sistema de registro. É o mesmo princípio de reler o estado (Capítulo 10): uma entrada de memória é um cache de algo que já foi verdadeiro, e um cache nunca é a fonte da verdade.

A **verificação de versão** recusa as entradas que o leitor não consegue interpretar. A memória sobrevive aos deploys. Uma nota escrita sob um esquema mais antigo, lida por um código que mudou o significado de um valor, é a F5 por outro caminho, e é melhor pulá-la do que adivinhar.

O diagrama mostra os dois caminhos e onde fica cada verificação. Procure onde uma entrada pode ser barrada na entrada e na saída.



Memória contaminada

O cenário que abriu o capítulo é aquele contra o qual se deve projetar. A proposta de um modelo contém algo que não deveria, porque o conteúdo que ele leu era dado se passando por instrução, e o memory store transforma um problema de um único run em um problema permanente. Vou ficar do lado de quem defende: o que o design faz importa mais do que como alguém poderia tentar.

As defesas são em camadas, e cada uma é determinística.

1. **Controle de proveniência no momento da escrita.** Uma entrada só é escrita a partir de fontes em que a política confia para aquele kind: uma mensagem autenticada do cliente para uma preferência, o registro de efeito para uma nota de caso. Qualquer coisa que tenha chegado por um resultado de ferramenta, uma conversa encaminhada ou um documento recuperado não é uma fonte.
2. **Conjuntos de valores fechados.** A entrada não pode carregar texto livre; portanto, não existe campo em que uma instrução possa ser

armazenada.

3. **Nenhuma autoridade na memória.** Mesmo que uma nota estivesse errada ou tivesse sido plantada, nada do que o gate decide depende dela.
4. **Quarentena na suspeita.** Um candidato cujo passo de evidência é válido, mas cujo valor não aparece nesse passo, enquanto aparece em um item não confiável do run (por exemplo, em um resultado de ferramenta ou em uma parte encaminhada), pode ser escrito com o status `quarantined`, que o caminho de leitura ignora, e colocado em uma lista de revisão. Isso vale para os kinds em que você decide que uma nota errada é cara o bastante para exigir uma pessoa. Acrescenta trabalho ao dia de alguém, e por isso o limitaria a uma lista curta de kinds.
5. **Isolamento de escopo.** Uma entrada só pode ser lida por runs do cliente que ela descreve; assim, uma nota contaminada prejudica os runs futuros de um cliente e não os de todos.

O Capítulo 16 desenvolve o lado da injection. Para a memória, o ponto é mais estreito: o caminho de escrita é onde um problema passageiro pode se tornar permanente e onde uma verificação é mais barata.

Aviso: Uma memória que pode ser escrita a partir de texto livre e lida para o contexto sem rótulo é um mecanismo de persistência para qualquer coisa que o modelo tenha lido por último. Se o seu design tem uma ferramenta de memória de texto livre e nenhuma política de escrita, trate o armazenamento como dado não confiável e mantenha-o fora de qualquer run que possa movimentar dinheiro ou tocar dados de clientes até que a política exista.

Retenção, correção e exclusão

Toda entrada tem um tempo de vida, e a política o nomeia. O motivo não é arrumação. Um fato tem uma meia-vida, o custo de agir com base em um fato obsoleto cresce com a idade dele, e uma entrada sem expiração é a promessa de guardar, proteger e pesquisar um dado indefinidamente. O `time-to-live` (TTL) da política de escrita é a resposta padrão, e uma regra de renovação dá a segunda: o `expires_at` de uma entrada só é estendido

quando o cliente confirma a preferência de novo, por exemplo declarando-a em uma nova mensagem. Uma preferência que ninguém reafirmou em seis meses é candidata à remoção, e o número é hipotético; seu produto e sua equipe jurídica são os responsáveis por ele.


A expiração deve ser real: o leitor verifica o status, e um job exclui as entradas expiradas e seus dados derivados (embeddings, índices, resumos), porque uma linha excluída enquanto uma cópia permanece em um índice é uma exclusão que não aconteceu. Os backups não são editados registro a registro: eles saem pela expiração do backup, ou os dados neles se tornam ilegíveis por crypto-shredding, isto é, pela destruição da chave que os cifra. Uma entrada em quarentena também tem um tempo de vida. Se nenhum revisor a liberar ou rejeitar dentro da janela de revisão, ela expira como qualquer outra entrada, de modo que a fila de revisão não pode crescer sem limite.

A **correção** é o caso em que uma entrada está errada, não velha. Os clientes dirão “nunca pedi isso”, e a equipe de suporte encontrará entradas que parecem estranhas. O design precisa de um caminho que não passe pelo modelo: um líder de suporte pode marcar uma entrada como `deleted` ou substituir o valor dela, a mudança é registrada com quem a fez e por quê, e o próximo run lê a entrada corrigida. Também daria à correção mais uma saída: a lista dos runs que leram a entrada antes de ela ser corrigida, a partir dos eventos `memory_read`, para que alguém possa decidir se alguma resposta precisa de acompanhamento.

A **exclusão a pedido** é a correção na escala de um cliente. Quando um cliente pede que a Parcelport o esqueça, o memory store é um dos vários sistemas que guardam algo sobre ele, e é o que um design de agente acrescenta. Quem revisa sob um regime desse tipo geralmente vai querer ver que o sistema consegue encontrar todas as entradas de uma pessoa e removê-las, incluindo as cópias derivadas, e que a própria remoção é registrada sem manter os dados removidos. As equipes jurídica e de conformidade são responsáveis pela interpretação, incluindo o que deve ser excluído e quando. O requisito de engenharia é que a exclusão por escopo seja uma única operação, o que é fácil quando cada entrada carrega `customer_id` e difícil quando as notas são texto livre que menciona pessoas pelo nome.

É aí que a memória encontra as informações pessoalmente identificáveis (PII). O Capítulo 17 é responsável pelo tema, e as regras específicas da memória são curtas. Um design tipado armazena pouca PII por construção: uma preferência de canal e um idioma não identificam por si sós, embora estejam ligados a um id de cliente e, por isso, continuem sendo dados pessoais no escopo do armazenamento. Não guarde dados de contato, endereços nem referências de pagamento na memória; eles vivem nos serviços que os possuem, e uma cópia é uma cópia a encontrar e excluir. E não deixe uma nota de caso copiar campos de um ticket. Se a nota precisa do nome de um pedido, guarde o id do pedido e deixe o leitor buscar o restante por uma ferramenta que aplique redaction.

O ciclo de vida é pequeno o bastante para ser desenhado. Observe quais transições são automáticas, quais precisam de uma pessoa e qual estado é final.



Observar e auditar a memória

Memória sem trace é a F8 em sua forma mais clara: um run posterior se comportou de certa maneira por causa de algo que um run anterior escreveu, e nada liga os dois. O Capítulo 20 descreve o pipeline de traces e os eventos que um run deve emitir; o requisito específico da memória é pequeno. Registre a proposta, a escrita ou a recusa e cada mudança e, acima

de tudo, registre `memory_read`, com os ids das entradas que entraram no contexto de cada chamada ao modelo. Esse evento é o que responde a “em quais runs esta entrada tocou”, e sem ele uma correção não consegue encontrar as respostas que uma entrada ruim pode ter moldado.

Com `memory_read` no lugar, três perguntas viram consultas. Que runs leram esta entrada? Que entradas este run escreveu e a partir de que evidência? E, para uma resposta que surpreendeu alguém, uma nota de memória apareceu no contexto do passo que a produziu? A última é a pergunta que uma revisão de incidente faz primeiro (Capítulo 23). Para julgar se o armazenamento compensa, rode o golden set com e sem o bloco de memória e compare (Capítulo 21). Uma auditoria agendada fecha o ciclo: amostre entradas, confira cada uma com a sua evidência e procure órfãs, como entradas cujo cliente já não existe, que são uma exclusão que passou ao largo do armazenamento.

Trade-offs e custos

A memória compra continuidade e custa um sistema. Os custos são concretos e recaem sobre pessoas diferentes.

Engenharia. Um memory store com política de escrita, gate, ciclo de vida, job de expiração, job de reconciliação e caminho de leitura é um pequeno serviço. Ele precisa de um schema registry, de versionamento e de testes, incluindo o teste de que nenhuma decisão do gate depende da memória. O design tipado é mais lento de estender: cada novo kind precisa de um esquema, de uma entrada de política e de uma revisão. Esse atrito é o que protege você, e também aparece como um backlog de pedidos de equipes de produto que querem salvar uma nota rapidamente.

Suporte. As revisões de correção e de quarentena são trabalho para líderes de suporte como Sam. Se a lista de revisão cresce mais rápido do que é lida, a quarentena vira teatro, uma aprovação sempre concedida. Mantenha o conjunto de kinds que podem ir para a quarentena pequeno o bastante para que a lista seja lida.

Latência e orçamento. O caminho de leitura acrescenta uma consulta ao armazenamento e um pouco de contexto; a fase de escrita acrescenta uma verificação do gate e uma escrita no armazenamento. Ambos são pequenos perto de uma chamada ao modelo, mas o caminho de leitura precisa

de um comportamento declarado para quando o armazenamento está fora do ar. Minha preferência é o modo degradado: rodar sem memória e dizê-lo no trace. A memória tipada também é menos expressiva do que o texto livre; se a perda for grande demais, melhore o que o sistema de tickets registra antes de abrir o memory store ao texto livre.

Onde ele quebra. O design tipado supõe que o conjunto de valores está certo. Se uma preferência não cabe, o sistema a descarta em silêncio, e você precisa de uma métrica sobre as propostas recusadas por falta de um kind adequado, para que a lacuna fique visível. A regra de conflito com o sistema de registro supõe que o registro está atual e, onde não está, a memória está correta e o registro está errado. E o design inteiro supõe que o escopo é atribuído por código. Um armazenamento sem filtro de escopo falha entre clientes, que é o pior lugar para falhar; por isso o teste de isolamento pertence à suíte que roda antes de cada deploy.

Quando não usar. As condições são as listadas em “Você precisa mesmo de memória?”. Em resumo: não em uma primeira versão, não para um fato que um sistema de registro pode fornecer, não onde ninguém é responsável pelo ciclo de vida e não como texto livre em qualquer agente que possa movimentar dinheiro.

Erros comuns

- **Deixar o modelo escrever notas de texto livre.** É tentador porque é o caminho mais curto até uma demo, e as notas são agradáveis de ler. A correção são kinds tipados com conjuntos de valores fechados e notas de caso construídas por código a partir de registros de efeito.
- **Tratar a memória como confiável porque é interna.** O armazenamento é da Parcelport, mas o conteúdo veio de um run que leu material externo. Rotule cada entrada pela proveniência e decida a confiança pela fonte da evidência, não pelo lugar onde o dado está.
- **Deixar a memória carregar autoridade.** Uma nota dizendo que um cliente está “verificado” ou “pré-aprovado” é conveniente e contorna o gate. A autoridade vem da delegação e da política, e o gate nunca lê o memory store.
- **Pesquisar entre clientes.** Um índice compartilhado com um filtro aplicado por quem chama transforma um filtro esquecido em um vaza-

mento. Faça o escopo parte da camada de consulta do armazenamento, definido pelo orquestrador a partir do run.

- **Escrever sem expiração.** “Limpamos depois” vira um armazenamento de fatos pelos quais ninguém responde. Dê a cada kind um TTL e uma regra de renovação, e rode o job que remove as entradas expiradas e suas cópias derivadas.
- **Manter memória e estado em um único armazenamento.** Os passos de um run e as preferências de um cliente têm responsáveis, tempos de vida e regras de exclusão diferentes, e juntá-los torna cada um mais difícil de entender. O Capítulo 10 mantém o estado do run no run store; mantenha o memory store separado.
- **Não registrar as leituras.** Sem eventos `memory_read`, uma correção não consegue encontrar os runs que uma entrada ruim tocou. Registre os ids das entradas que entraram em cada chamada ao modelo.
- **Usar a memória para remendar um sistema que falta.** Se toda nota de operações é, na verdade, uma lacuna do runbook, a correção é uma mudança revisada no runbook. Deixe o agente abrir um pull request com o texto proposto por meio de `open_pull_request` e deixe uma pessoa fazer o merge.

Pontos-chave

- A memória é informação mantida entre runs que pode influenciar contextos posteriores, é distinta do estado do run, e uma entrada ruim afeta todo run posterior que a leia; por isso ela merece os controles de um banco de dados de produção.
- Comece perguntando se você precisa mesmo de memória: um fato que um sistema de registro já guarda deve ser lido dele, e uma nota de runbook pertence a um runbook revisado, não a um armazenamento de texto livre.
- Trate toda escrita de memória como uma proposta: o modelo propõe uma entrada tipada, e o código valida a evidência, atribui o escopo, define a expiração e a escreve, de modo que o modelo nunca escolhe sobre quem é a entrada nem por quanto tempo ela vive.
- Prefira conjuntos de valores fechados e notas construídas por código a partir de registros de efeito a texto escrito pelo modelo, porque um

campo que não comporta uma frase não consegue levar uma instrução a um run posterior.

- Nunca deixe a memória carregar autoridade: o gate decide a partir da delegação e da política, e uma proposta que só passaria se uma nota fosse verdadeira deve ser recusada.
- Leia a memória por escopo para um bloco rotulado, descarte no código as entradas expiradas, em quarentena e conflitantes, deixe o sistema de registro vencer e registre os ids de todas as entradas que chegaram ao modelo.
- Dê a cada entrada um TTL, um caminho de correção e um caminho de exclusão que alcance as cópias derivadas, e registre leituras e mudanças, para poder responder em quais runs uma entrada ruim tocou.

A memória leva informação de um run para o seguinte. O Capítulo 12 se volta para o que acontece dentro de um run ao longo do tempo e examina como planos e loops são limitados para que um run pare quando deve.

PARTE IV

Loops de controle

Capítulo 12 — Planejamento e loops

Imagine uma manhã de feriado na Parcelport. Um alerta de latência dispara para o `orders-service`, e o orquestrador inicia um run do agente de operações para tratá-lo. Os primeiros passos parecem uma investigação sólida: uma consulta de métricas, uma consulta de logs, a leitura de um trace. No passo seis, o quadro está confuso. No passo nove, o modelo já propôs `query_logs` quatro vezes, cada uma com um filtro que difere do anterior por um campo ou um minuto. Toda chamada foi permitida, porque toda chamada era uma leitura dentro dos serviços do incidente. Todo resultado é grande e quase igual ao anterior. Nenhum passo isolado tem algo de errado.

Suponha que nada interrompa o run por quarenta minutos. Ele gastou mais do que qualquer pessoa planejou, e o seu contexto agora está cheio de linhas de log quase duplicadas, o que molda a próxima proposta em direção a mais do mesmo. Robin, o SRE de on-call, abre o dashboard e encontra um status que diz “investigating”. Não há como saber se o run está a um passo de uma resposta ou andando em círculos.

Agora suponha que a equipe adote o remédio óbvio: o modelo escreve um plano primeiro e o segue. O plano tem cinco passos bem arrumados. No passo nove, o run não o está seguindo, e o único relato de quanto ele avançou vem do próprio modelo, em uma frase que diz que o passo quatro está concluído. Quem decide que um run está progredindo, quanto vale um plano quando foi o modelo que o escreveu, e onde o loop termina?

Este capítulo pertence a duas partes do envelope de controle. Como **Limite**, ele responde onde o loop para e quanto custa executá-lo, e cobre as condições de saída do próprio loop. Como **Proposta**, ele faz a pergunta que essa parte sempre faz, sobre uma proposta de um tipo particular, o

plano: ele é tratado como entrada não confiável até que se prove o contrário? O Capítulo 13 trata do restante do Limite, que são os orçamentos e os circuit breakers.

O problema e por que ele é difícil

O loop do Capítulo 1 tem duas saídas que pertencem ao orquestrador: uma resposta final que o gate aceita e um limite que dispara. Um design que não pensou em nenhuma das duas tem um loop cuja saída real é “quando algo fora do run intervém”. Isso é F5 (loop descontrolado ou contexto obsoleto), na sua subclasse de loop descontrolado F5.1: um run que continua sem progresso. Costuma ser percebido como F9 (explosão de custo ou latência), porque uma conta alta ou um page demorado são mais fáceis de ver do que a falta de progresso.

O planejamento traz classes de falha próprias. Um plano que não passa no parse é F1 (saída malformada). Um plano cujos passos nomeiam a ferramenta incorreta, ou a ferramenta certa para o serviço errado, é F2 (ferramenta incorreta ou argumentos incorretos), e é um F2 mais bem organizado do que uma chamada isolada, porque parece deliberado. O relato do modelo de que “o passo quatro está concluído” é F3 (afirmação sem fundamento) sobre o histórico do próprio run. Um plano executado pela metade e relatado como terminado é F6 (falha parcial silenciosa).

Três abordagens óbvias falham, e falham pelo mesmo motivo: cada uma entrega um controle ao componente que o controle deveria limitar.

- **“Pare quando tiver a resposta.”** A decisão de encerrar vira uma proposta. Um modelo que nunca propõe uma resposta final nunca encerra o run, e um modelo que propõe uma cedo demais o encerra com um diagnóstico raso. A saída precisa ser uma condição que o orquestrador avalia.
- **“Você tem no máximo 15 passos.”** Dizer ao modelo o seu limite é uma informação útil e uma aplicação ruim. O prompt reduz a taxa de runs longos; não interrompe um run longo. O limite é um contador no código.
- **“Mantenha um plano e marque os passos.”** As marcas são as afirmações do modelo sobre o próprio progresso. Um passo está concluído

quando o registro diz que a sua chamada aconteceu e retornou, e o registro é escrito pelo orquestrador.

O progresso é mais difícil de definir do que um limite. Não é uma propriedade de um passo isolado. Aparece como uma relação entre passos: este resultado acrescenta algo que o run não tinha, aquela chamada repete uma anterior, estas duas chamadas se desfazem mutuamente. Os argumentos de um run em loop raramente se repetem de forma exata, já que um modelo ao qual se mostra “nenhum resultado útil” tende a variar a requisição. Assim, um detector baseado em igualdade de strings pega o loop mais preguiçoso e deixa passar o comum.

Nada disso é uma questão de prompt. É uma questão sobre o que o orquestrador consegue calcular a partir do run store: contagens, fingerprints, assinaturas, registros de escopo e saídas estruturadas. O restante do capítulo constrói essas peças, começando pelo próprio loop.

O loop e quem o conduz

O ciclo é observar, propor, verificar, aplicar, observar. No vocabulário deste livro: o contexto é montado a partir do estado do run, o modelo propõe, o gate verifica, o efeito é aplicado e o resultado volta como uma observação. O `runStep` canônico do Capítulo 1 é uma passada; `runAgent` o repete enquanto o status do run for `running`.


A propriedade importante é a direção da chamada. O orquestrador chama o modelo, como chamaria qualquer função que devolve um valor em que não confia por completo. O modelo não chama o orquestrador e não tem um botão de “continuar” ou “parar”. Veja quem é responsável por cada pergunta em uma passada.

Pergunta	Responsável	Mecanismo
Existe outro passo?	Orquestrador	Status, <code>bound.check</code> , verificação de progresso
O que o modelo vê?	Orquestrador	Montagem do contexto (Capítulo 9), incluindo o enunciado da tarefa a partir do registro do run
O que deve acontecer em seguida?	Modelo, como proposta	<code>model.propose</code>

Pergunta	Responsável	Mecanismo
Pode acontecer, agora?	Gate	Veredicto: allow, refuse, needs approval
Aconteceu, e o que voltou?	Orquestrador	<code>effect.apply</code> e o registro
A tarefa está concluída?	Predicado de sucesso no código	Uma verificação dentro do gate, sobre uma resposta final

Só uma linha pertence ao modelo, e é a única linha em que se espera que ele erre. Todo o resto é código determinístico, e é isso que torna o loop testável: você pode fazer o replay de um run registrado pelas verificações de saída sem chamar o modelo.

Observe no diagrama a ordem das saídas e o fato de que todo caminho que não encerra o run volta a uma observação.



A ordem é deliberada. O limite rígido vem primeiro porque não exige interpretação, e a verificação de progresso vem em segundo porque lê o registro e é mais barata do que outra chamada ao modelo. No `runStep` canônico, uma resposta final passa por `gate.check` como qualquer outra proposta, e o predicado de sucesso é uma das suas verificações.

Uma recusa volta ao contexto como observação, como no Capítulo 4, de modo que um run pode ser recusado muitas vezes e ainda assim continuar em execução; é por isso que a verificação de progresso, adiante, conta as recusas.

Planos como propostas

Um **plano** é uma lista de passos pretendidos proposta pelo modelo. É uma proposta no sentido do Capítulo 1, então tudo o que vale para uma proposta vale para ele: é analisado, validado, limitado e registrado antes que qualquer coisa dependa dele. Um plano não é um compromisso, e nada no sistema deve se comportar como se o modelo tivesse prometido fazer o que listou.

Para que serve um plano e quanto custa

Não colocaria um planejador na frente de toda tarefa. Um plano custa uma chamada ao modelo antes do primeiro passo útil, um lugar para guardá-lo, código de validação e uma nova forma de errar: o plano pode ser bem formado e estar equivocado, e pode estar certo na segunda-feira e obsoleto quando o passo seis for executado. Ele compensa o custo em três situações.

- **Os passos dependem uns dos outros e recomeçar é caro.** Se o passo três precisa de um trace id que o passo dois encontra, e uma ordem errada desperdiça um run de sandbox, vale a pena ter uma ordem explícita.
- **Algo precisa ser revisado antes dos efeitos.** Um plano é o único artefato que uma pessoa ou um validador pode ler antes que o run faça qualquer coisa. Revisar um run depois do fato é uma questão de registro (Capítulo 20); revisá-lo antes só é possível se os passos pretendidos existirem como dados.
- **O run precisa de uma forma contra a qual medir o progresso.** “Quatro de cinco passos concluídos” é uma medida de progresso que o orquestrador consegue calcular. “Parecia estar indo bem” não é.

Se a tarefa é “consultar um pedido e responder”, dispense o plano. Um loop de dois passos não precisa de um artefato que custa um deles.

Um plano como estrutura

A primeira regra é que o plano chega como estrutura, uma lista de registros de passos, e não como prosa. A prosa só pode ser lida por outra chamada ao modelo, o que transfere o problema de validação para outra pro-

posta. Um plano estruturado pode ser verificado por código. Na notação ilustrativa abaixo, o modelo fornece os campos dos passos; o orquestrador fornece tudo o que acompanha a execução.

```
plan                                // a proposal of kind "plan";
illustrative notation
  steps: list of                    // supplied by the model
    { id, tool, purpose, depends_on: list of id, expects: string }
    // purpose and expects are short text for people reading the plan;
    // no code branches on them

plan record                         // kept in the run store (Chapter
10)
  plan_version: integer            // assigned by the orchestrator
  task_ref: alert_id              // from the run, never from the
model
  steps: list of { id, status, result_ref }
    // status in [pending, done, skipped, refused]; written only by the
    // orchestrator, when the matching call is recorded with an outcome
```

A segunda regra decorre da primeira. O modelo não marca passos como concluídos. Quando uma chamada que corresponde ao passo `s2` retorna, o orquestrador registra o resultado e define o status. Se o texto posterior do modelo diz “o passo 4 está concluído” enquanto o registro diz que ele está pendente, vale o registro, e a afirmação é um F3 que a verificação de progresso pode perceber.

A terceira regra é que a classe de efeito de um passo é lida do registro de ferramentas, não do plano. Um plano que rotula uma escrita como leitura não mudou nada sobre o que a ferramenta é.

Validar um plano antes que ele execute

Um validador é código determinístico que devolve os mesmos veredictos que o gate, aplicados ao plano como um todo. Ele verifica o que se pode saber sem executar nada: que o plano tem o formato correto, que toda ferramenta é uma que esta fase do run pode usar, que a ordem é possível e que o alcance total do plano é limitado.

```

function validatePlan(run, plan):
    if not matchesSchema(plan, planSchema):
        return { kind: "refuse", reason: "malformed_plan" }           // F1
    if length(plan.steps) > run.limits.max_plan_steps:                 //
say, 6
        return { kind: "refuse", reason: "plan_too_long" }
    if hasCycle(plan.steps):                                           //
depends_on must be acyclic
        return { kind: "refuse", reason: "plan_cycle" }
    writes = 0
    for each step in plan.steps:
        contract = toolRegistry.get(step.tool)
        if contract is none or step.tool not in run.phase.allowed_tools:
            return { kind: "refuse", reason: "tool_not_allowed", step:
step.id }
        if contract.effect_class != "read":                             //
class comes from the registry
            writes = writes + 1
            if not dependsOnRead(plan, step):
                return { kind: "refuse", reason: "write_without_evidence",
step: step.id }
        if writes > run.limits.max_plan_writes:                       //
say, 1
            return { kind: "refuse", reason: "too_many_writes" }
    return { kind: "allow" }

```

Duas escolhas do bloco merecem defesa. Os motivos vêm de uma lista fixa e voltam ao modelo como observação, de modo que um plano recusado pode ser proposto de novo dentro de um pequeno limite de tentativas, como o Capítulo 4 descreve para chamadas recusadas. E o validador não verifica argumentos. Os argumentos dos passos posteriores muitas vezes dependem de resultados dos anteriores, então ainda não existem quando o plano é feito; quem os verifica é o gate, quando cada chamada é proposta.

Um plano validado não é uma autorização

Aviso: Validar um plano não autoriza os seus passos. O gate verifica toda chamada no momento em que ela é proposta, com os fatos, a política e a delegação daquele momento, quer a chamada apareça ou não em um plano aceito. Um plano que listou `request_rollback` não carrega aprovação para isso; a aprovação está vinculada à chamada exata, como o Capítulo 15 descreve.

Este é o erro que os planos convidam a cometer. Quando um plano foi “aprovado”, seja por um validador, seja por Robin dando uma olhada rápida, ele começa a parecer uma permissão. Não é. Um plano é uma declaração de intenção feita antes, com fatos que podem ter mudado, e a autoridade precisa ser decidida no momento do efeito. O gate continua fazendo o seu trabalho, e o valor do plano é que o gate encontra menos surpresas.

Plan-then-execute e passo a passo

Há duas maneiras de usar um plano e um híbrido entre elas. A escolha depende de quanta adaptação a tarefa exige e de quanto você quer revisar antes que algo aconteça.

	Planejar e depois executar	Passo a passo	Plano curto, com replanejamento
Chamadas de controle ao modelo	Uma no início, mais algumas em um replanejamento	Uma por passo, cada uma um plano de um passo	Uma no início, mais algumas nos gatilhos
Revisável antes dos efeitos	Sim	Não, só à medida que se desenrola	Sim, para a versão atual
Adapta-se aos resultados	Só por replanejamento	Totalmente	Em gatilhos definidos
Fraqueza típica	Construído sobre fatos que mudam; rígido	Deriva e loops, sem uma forma contra a qual medir	Rotatividade de replanejamentos
Serve para	Passos dependentes, recomeços caros, escritas no fim	Exploração em que cada resultado remodela o passo seguinte	A maioria das investigações

Para o agente de operações, começaria com o híbrido: um plano curto, validado, com os desvios classificados e um pequeno número de replanejamentos permitidos. Um plano puramente antecipado é frágil para um diagnóstico, porque o sentido de ler um log é justamente que o resultado muda o que você lê em seguida. O passo a passo puro abre mão da medida de progresso e da revisão pré-efeito, e só aceitaria esse acordo quando a tarefa for exploratória e o conjunto de ferramentas for somente de leitura.

O plan-then-execute tem mais uma propriedade que vale nomear, do lado de quem defende. Um plano feito antes que conteúdo não confiável chegue fixa a forma pretendida do run, e uma proposta que não se encaixa no plano é classificada e contada. Isso reduz o quanto um resultado de ferramenta contendo instruções pode desviar o run, e é uma camada da resposta a F4 (sequestro de instruções), não a resposta; o Capítulo 16 trata dos controles estruturais.

Desvio e replanejamento

Depois que existe um plano, toda chamada proposta é classificada em relação a ele, por código, dentro do gate, após a verificação de permissão e antes das pré-condições.

```
function classifyAgainstPlan(run, proposal):
    step = matchPlanStep(run.plan, proposal)           // tool and argument
    shape, matched by code
    if step is not none and step.status == "pending" and
    dependenciesDone(run.plan, step):
        return "in_plan"                               // a step that is already
    done falls through: a repeat is off plan
    contract = toolRegistry.get(proposal.tool)
    if contract.effect_class == "read" and run.offplan_reads <
    run.limits.max_offplan_reads:
        run.offplan_reads = run.offplan_reads + 1 // allowed, counted,
        visible in the record
        return "off_plan_read"
    return "off_plan"                                   // refused with a reason;
    counted by the progress check
```

Uma leitura fora do plano é tolerada até uma pequena contagem, porque investigar é em parte improvisar, e um run que não pode olhar para uma linha de log inesperada serve de pouco. Uma escrita fora do plano não é tolerada: é recusada com `off_plan`, e a recusa volta como observação; recusas repetidas chegam à verificação de progresso como `refused_repeatedly`, o que dispara o replanejamento. Uma escrita que não estava no plano é exatamente o tipo de proposta que uma pessoa deveria ver registrada por escrito antes que aconteça.

Um replanejamento é, ele mesmo, uma chamada ao modelo, uma proposta e um loop, então precisa do seu próprio limite. Os gatilhos de replanejamento são condições que o código avalia, e são poucos. No loop abaixo, todos chegam pela verificação de progresso:

- ela reporta uma estagnação ou uma oscilação;

- ela reporta `refused_repeatedly`: o gate continua recusando passos, seja por um motivo que novos argumentos não resolvem, como uma pré-condição que falhou, seja como escritas `off_plan` que o classificador do plano não casou, cada uma das quais volta primeiro como observação.

Duas condições que parecem gatilhos não são. Uma observação que contradiz uma suposição declarada do plano, como um serviço que o plano supunha saudável ter um alerta aberto próprio, chega ao modelo como observação, e o modelo pode responder com um passo que a verificação de progresso então julga como qualquer outro. Um plano esgotado enquanto o predicado de sucesso ainda não foi atendido também não é um replanejamento: o modelo propõe uma resposta final, o gate a recusa, e depois de `max_final_attempts` respostas recusadas o run é encaminhado em hand-off como `success_unmet`. Um sistema que queira uma verificação de suposições ou um replanejamento no esgotamento adiciona um ramo para isso e o conta em `max_replans`, como os demais.

Cada replanejamento produz uma nova versão do plano, mantém a antiga no run store e conta contra `max_replans`, digamos, um ou dois por run. Um run que replaneja sem limite apenas moveu o loop descontrolado um nível acima, para a rotatividade de planos: toda versão é válida e nada avança. Um replanejamento também carrega as evidências coletadas até ali, que são estado (Capítulo 10) mostrado ao modelo pela montagem do contexto, para que o novo plano não comece repetindo as três primeiras leituras do antigo.

Condições de parada

Um run termina de uma de três maneiras: sucesso, uma parada pelo orquestrador ou um hand-off para uma pessoa. O orquestrador precisa conseguir dizer, para cada run, qual delas aconteceu e por quê. Esta seção cobre as condições que encerram um loop. Os orçamentos de recursos e os circuit breakers, que também encerram runs, são o assunto do Capítulo 13.

O sucesso é um predicado no código

O run está **done** quando um predicado de sucesso é satisfeito, e uma resposta final é uma proposta que pode ou não satisfazê-lo. O predicado não pode verificar que a resposta é verdadeira. Pode verificar o que é verificável: que a resposta é estruturada, que trata da tarefa para a qual o run foi iniciado e que cada afirmação aponta para evidências que o run realmente coletou.

Para o agente de operações, a resposta a uma tarefa de diagnóstico é um registro de diagnóstico, não um parágrafo.

```
function successPredicate(run, answer):
    d = answer.diagnosis           // hypothesis, evidence_ids,
    proposed_action
    if not matchesSchema(d, diagnosisSchema):
        return fail("malformed_diagnosis")           // F1
    if d.alert_id != run.task.alert_id:
        return fail("wrong_subject")                 // the
    answer is about another task
    if length(d.evidence_ids) < run.limits.min_evidence: // say, 2
        return fail("insufficient_evidence")
    for each id in d.evidence_ids:
        item = runStore.getResult(run.id, id)
        if item is none:
            return fail("evidence_not_in_run")         // F3:
    cites a result the run never read
    if item.service not in run.task.services_in_scope:
        return fail("evidence_out_of_scope")
    return pass()
```

Seja claro sobre o que isso não lhe dá. Um diagnóstico pode passar por todas as verificações e ainda estar errado, já que pode citar duas linhas de log reais que não sustentam a sua hipótese. Saber se o diagnóstico está certo é uma questão para os evals (Capítulo 21) e para Robin. O que o predicado garante é que uma resposta final não pode ser uma frase sem sustentação, e que os motivos de falha são específicos o bastante para voltar ao modelo: “o diagnóstico cita um resultado que não está neste run” é uma observação sobre a qual o modelo pode agir.

Quando o predicado falha, a falha volta como recusa, e vale o limite usual de tentativas. Um run que não consegue produzir uma resposta aprovada em duas tentativas chegou ao limite do que pode fazer sozinho, e o movimento certo é um hand-off com as evidências reunidas até ali, não um critério mais baixo.

A versão do agente de suporte é mais curta e trata quase só de efeitos. Uma reclamação de avaria está concluída quando o registro contém uma resposta enviada para este ticket, qualquer reembolso que o plano previa com um resultado registrado e nenhuma intenção em aberto. O predicado lê o run store; não pergunta ao modelo se o cliente está satisfeito.

O limite de passos

Todo loop precisa de um número máximo de passos, desde o primeiro dia. É o único limite que não exige ajuste para ser útil, porque qualquer limite finito transforma “nunca termina” em “termina, e uma pessoa olha”. É um contador no registro do run, verificado antes de cada passo e incrementado antes da chamada ao modelo, para que uma queda entre a chamada e o registro não leve a uma contagem a menor.

Não sei qual é o limite certo para o seu agente, e ninguém pode lhe dizer sem observá-lo trabalhar. Ele depende de quantos passos a sua tarefa legítima mais lenta exige, de quanto custa um passo desperdiçado e de quem recebe o page quando o limite interrompe uma tarefa que estava quase pronta. Um ponto de partida é o run legítimo mais longo do seu conjunto de evals, mais uma folga; o número é então uma hipótese, que os dados de trace das primeiras semanas confirmam ou movem.

Um refinamento é barato: um limite por tipo de tarefa é melhor do que um número global, já que uma verificação de endereço e uma investigação de incidente não precisam do mesmo espaço.

O limite tem um custo nos dois sentidos: baixo demais, e Robin termina trabalhos que o run quase completou; alto demais, e um run estagnado gasta toda a sua cota antes que alguém olhe.

Progresso: repetições, estagnação e oscilação

Progresso é saber se os últimos passos acrescentaram algo ao que o run sabe ou mudaram algo no mundo que o plano pretendia. O orquestrador o mede a partir do registro, nunca a partir da descrição do modelo. Três padrões cobrem a maior parte do que dá errado.

Repetições exatas. A mesma ferramenta com os mesmos argumentos, de novo. É o caso fácil, e a regra precisa de uma ressalva: uma leitura repetida depois de uma escrita pode ser legítima, já que o mundo mudou nesse

intervalo. Por isso o contador de repetições é zerado quando um efeito foi aplicado desde a chamada anterior, e em uma fase somente de leitura toda repetição conta.

Repetições aproximadas. A mesma intenção com outra formulação: uma consulta de logs com mais um campo, um intervalo de tempo deslocado em um minuto. Duas coisas pegam isso, e usaria as duas. A primeira é uma **assinatura**, um hash sobre a ferramenta e uma forma normalizada dos seus argumentos, em que a normalização é definida por ferramenta: filtros ordenados, intervalos de tempo agrupados em janelas grosseiras, limites e campos voláteis descartados. A segunda é um **result fingerprint**, um hash do conteúdo do resultado sem as suas partes voláteis. As assinaturas pegam a intenção repetida; os fingerprints pegam a evidência repetida, qualquer que tenha sido a formulação da requisição. Dos dois, o fingerprint é o mais difícil de driblar, porque um modelo que varia os argumentos não consegue variar o que o log store contém.

```
function signature(call):
    spec = toolRegistry.get(call.tool).signature_spec // registry
    metadata, not a contract field
    return hash(call.tool, normalize(call.arguments, spec))
    // for query_logs: sort the filters, keep service and level, bucket the
    time
    // range into coarse windows, drop the row limit
```

Oscilação. O run alterna: consulta, muda o filtro, consulta, volta o filtro; ou, com escritas, liga uma flag, observa, desliga de novo. Em uma janela de assinaturas recentes, um ciclo de período dois ou três que se repete pelo menos duas vezes é uma oscilação. Para ferramentas de escrita a regra é mais simples e mais estrita: uma segunda proposta da mesma escrita para o mesmo alvo em um run é recusada pelo gate, a menos que uma pessoa tenha decidido de outro modo. A chave de idempotência do Capítulo 6 cobre apenas a repetição exata, que ela reproduz em vez de recusar, e portanto não pega um toggle que é revertido com argumentos diferentes.

A verificação de progresso reúne esses itens sobre uma janela curta de passos recentes.

```

function progressCheck(run):
    recent = lastSteps(run, 3, since: run.plan_start_step) // say, 3
    steps; refills after a replan
    if length(recent) < 3:
        return "advancing"
    seen = fingerprintsBefore(run, recent) // fingerprints of
    results from earlier steps
    if countNew(recent, seen) == 0:
        return "stalled" // the same evidence
    again, however it was asked
    if hasRepeatingCycle(map(recent, signature), maxPeriod: 3):
        return "oscillating"
    if countRefused(recent) >= 3: // the gate keeps
    refusing what the model proposes
        return "refused_repeatedly"
    return "advancing"

```

A reação a uma detecção não deve ser uma parada imediata, porque um detector tem falsos positivos e uma parada brusca transforma cada um deles em um hand-off. Por isso a reação é escalonada: a primeira detecção dispara um replanejamento, cuja requisição carrega um reason code de uma lista fixa (`repeat_call`, `no_new_evidence`) que o modelo vê, e a janela de progresso então se reabastece a partir da nova versão do plano. Uma segunda detecção faz o hand-off. Toda detecção é escrita no registro com as assinaturas e os fingerprints que a dispararam, para que alguém possa depois distinguir um acerto de um falso alarme. Os retries da camada de ferramentas depois de uma falha transitória acontecem dentro de um passo e pertencem ao Capítulo 14; não são repetições nesse sentido, embora contem contra os orçamentos (Capítulo 13).

Deriva do objetivo

Um run pode fazer muito progresso em algo que não é a sua tarefa. O agente de operações parte de um alerta sobre o `orders-service`, depois lê os logs de um serviço que não está na lista de dependências do alerta porque uma linha de log anterior mencionou o seu nome, e gasta seis passos ali. Todo passo é uma leitura válida. O run está avançando, e não está trabalhando no alerta.

O controle é um **registro da tarefa** que o orquestrador cria a partir do gatilho e que o modelo não pode editar. Ele diz sobre o que é este run.

```

task                                // created by the orchestrator from
the alert; illustrative
  alert_id: "alr-0031"
  services_in_scope: [orders-service, shipping-service] // from the alert
and a dependency list
  time_window: [alert_time - 2h, now]
  phase: "investigate"                // read-class tools only in this
phase
  limits: { max_steps: 15, max_replans: 1, max_plan_steps: 6,
            max_offplan_reads: 3, min_evidence: 2,
            max_final_attempts: 2 }    // all illustrative

```

O gate confere o alvo de cada proposta contra ele: o serviço, o intervalo de tempo, o pedido ou o ticket. Uma proposta fora do registro é recusada com `outside_task_scope` e volta como observação. Ampliar o escopo é um ato deliberado: o orquestrador pode seguir uma lista de dependências, ou uma pessoa pode acrescentar um serviço, mas o modelo propor isso não altera o registro.

Isso é parecido com a delegação do Capítulo 7, mas não é a mesma coisa. Uma delegação diz no que o agente pode tocar em geral; o registro da tarefa diz sobre o que é este run. O segundo costuma ser mais estreito, e uma leitura que a delegação permite ainda pode estar fora do escopo da tarefa. Elas falham com códigos diferentes porque significam coisas diferentes: `not_permitted` diz que o principal não pode, e `outside_task_scope` diz que o run não deveria. O enunciado da tarefa também deve ser repetido a partir do registro a cada montagem do contexto (o Capítulo 9 trata da montagem em geral), para que não dependa de o modelo guardar uma frase escrita no passo um.

O que uma parada deixa para trás

Toda parada, exceto o sucesso, termina em `transition(run, "handed_off", reason)`, que é o estado em que uma pessoa é responsável pelo desfecho (Capítulo 10). O hand-off deve ser utilizável por alguém que não estava acompanhando. Um resumo montado por código a partir do run store contém a tarefa, os passos usados contra o limite, as versões do plano, os ids de evidência com uma linha cada, o reason code da parada e o que o run ainda não havia examinado. O modelo pode acrescentar uma narrativa, rotulada como escrita pelo modelo, e ninguém deve precisar confiar nela.

Formas de loop e suas superfícies de controle


O Capítulo 1 comparou chamadas isoladas, workflows, loops e múltiplos agentes, e defendeu a menor agência que resolva o problema. Este capítulo dá o passo seguinte: uma vez decidido que um loop é necessário, quanto do run o loop recebe?

Um passo de agente limitado dentro de um workflow

A forma que escolheria primeiro é um workflow em que apenas uma etapa é um loop aberto, e essa etapa pode ler, mas não escrever. Para o agente de operações:

- **Etapa 1, código.** A partir do alerta, construir o registro da tarefa e buscar um baseline: as métricas do próprio alerta, os deploys ativos dos serviços no escopo.
- **Etapa 2, loop limitado.** O modelo investiga, apenas com ferramentas de classe de leitura, um limite de passos, um plano, uma verificação de progresso e um escopo de tarefa. Termina com um registro de diagnóstico.
- **Etapa 3, código.** Validar o diagnóstico contra o predicado de sucesso.
- **Etapa 4, uma proposta.** O modelo propõe no máximo uma ação, `open_pull_request` ou `request_rollback`, que vai ao gate e, no caso de um rollback, à aprovação.

Observe no diagrama onde fica a parte aberta e o que a cerca.



O raciocínio é que o custo de um loop aberto é o produto do seu conjunto de ferramentas pela sua duração. Restringir a etapa 2 a ferramentas de leitura significa que o pior caso de um loop descontrolado é custo, tempo e ruído, e não uma escrita: nenhum reembolso, nenhuma mudança de flag, nenhum rollback pode acontecer ali dentro. As escritas acontecem na etapa 4, uma de cada vez, atrás do gate e, onde a política exige, atrás de aprovação (Capítulo 15). A etapa 2 também pode chamar `run_diagnostic`, que é de classe de leitura segundo a tabela do livro e mantém a sua própria fronteira no sandbox (Capítulo 19).

O preço é a flexibilidade. Um incidente cuja resposta certa começa por uma escrita, como desligar uma flag para conter o dano e investigar depois, não se encaixa nessa ordem, e o run encaminha o caso a uma pessoa em hand-off. Isso é aceitável para mim em uma primeira versão: quem precisa agir primeiro não precisa de um agente para descobrir isso.

Loops abertos

Um loop aberto dá ao modelo todas as ferramentas durante o run, inclusive as de escrita, e o limita com um teto e o gate. É a coisa mais simples de construir e a superfície mais ampla de controlar. Usaria o loop aberto apenas quando o caminho realmente não pode ser listado nem mesmo em fases, e quando cada ferramenta já tiver um contrato, um teto ou uma aprovação que se sustente por si só. Mesmo assim, coloque nele uma restrição do tipo fase: digamos, as escritas só ficam disponíveis depois que o run tem um registro de diagnóstico que passou no predicado. A ordem é imposta pelo registro de ferramentas, não por uma instrução.

O loop de reclamação de avaria do agente de suporte é aberto em uma forma branda: consulta, uma possível verificação de endereço, um possível reembolso, uma resposta. O seu conjunto de ferramentas é pequeno, os passos perigosos (`issue_refund`, `send_customer_reply`) passam pelo gate, e o seu limite de passos é baixo, digamos cinco ou seis, porque uma reclamação legítima precisa de poucos passos e um run mais longo merece a atenção de uma pessoa.

Vários agentes, cada um com o seu envelope

Múltiplos agentes se justificam por uma fronteira de que você precisa, como uma fronteira de permissão ou de contexto, e não por um diagrama arrumado (Capítulo 1). Imagine uma divisão ilustrativa do agente de operações em um investigador que só tem ferramentas de leitura e um remediador que tem `open_pull_request`. Os controles de loop deste capítulo valem para cada um deles, e as junções pedem mais três regras.

- **Cada agente tem o seu próprio envelope**, com o seu próprio conjunto de ferramentas, delegação, registro da tarefa, limites, gate e registro. Nenhum agente herda a autoridade de outro por ser chamado por ele.

- **Uma mensagem entre agentes é uma proposta de uma fonte não confiável.** O diagnóstico chega ao remediador como dado estruturado que passa por um esquema e um predicado, não como um parágrafo colado no contexto.
- **Os limites se aninham, e os hand-offs são restritos.** A cota de um filho é tirada da cota do pai, e a cadeia de chamadas tem um limite de profundidade, um limite de fan-out e uma verificação de ciclos.

As superfícies de controle crescem mais rápido do que o número de agentes. Se as fases dentro de um único agente lhe dão a fronteira de que você precisa, fique com as fases.

O loop de diagnóstico do agente de operações

Aqui está a etapa 2 do agente de operações por inteiro. Os limites são ilustrativos, e toda linha que importa para um limite está em código que a saída do modelo não alcança.

```

function runDiagnosis(run):
    run.plan = obtainPlan(run, reason: "start")           // a model call:
counts one step
    while run.status == "running":
        if run.steps_used >= run.limits.max_steps:       // say, 15
            return handOff(run, "max_steps")
        state = progressCheck(run)                       // reads the
record, not the model's claims
        if state != "advancing":
            if run.replans >= run.limits.max_replans:    // say, 1
                return handOff(run, "plan_churn", detail: state)
            run.replans = run.replans + 1
            run.plan = obtainPlan(run, reason: state)     // counts one step;
the window restarts here
            continue                                     // the step limit
is checked again first
            run.steps_used = run.steps_used + 1          // before the call:
a crash cannot undercount
            proposal = model.propose(assembleContext(run))
            verdict = gate.check(run, proposal)           // schema,
permission, task scope, plan class, preconditions, predicate
            if verdict.kind == "needs_approval":
                return handOff(run, "phase_violation")    // this phase holds
no tool that needs approval
            if verdict.kind == "refuse":
                record(run, "refused", verdict.reason)
                addObservation(run, verdict)              // reason code from
a fixed list
                if proposal.kind == "final_answer" and countFinalRefusals(run)
>= run.limits.max_final_attempts:
                    return handOff(run, "success_unmet") // say, 2 refused
final answers
                else if proposal.kind == "final_answer":
                    return finish(run, proposal)         // done, only
through transition()
                else:
                    record(run, "intent", verdict.call)
                    result = effect.apply(run, verdict.call) // read tools only
                    record(run, "effect", result)
                    addObservation(run, result)
    return run

```

O bloco se sustenta diante das falhas para as quais foi feito. Se o modelo nunca propõe uma resposta final, `max_steps` encerra o run, e um replanejamento não consegue passar do limite porque ele é verificado de novo depois de cada `obtainPlan`. Se ele propõe chamadas que variam mas não acrescentam nada, a verificação de progresso percebe isso pelos fingerprints; se o gate continua recusando, a mesma verificação vê três recusas na janela. Se a resposta final continua falhando no predicado, `success_unmet` encerra o run. Se o orquestrador cai no meio do loop, o contador de passos e o plano estão no run store e o `resumeRun` do Capítu-

lo 10 os retoma. Um veredicto `needs_approval` não pode ocorrer nesta fase, então é tratado como um bug e encaminhado em hand-off, nunca deixado em execução.

Agora acompanhe um run ilustrativo, com números inventados e uma janela de três passos, pela tabela.

Pas-so	Proposta	Classificação e resultado
1	Plano v1: métricas, logs, trace, runbook, resposta	<code>validatePlan</code> permite; armazenado como versão 1
2	<code>get_metrics</code> para o serviço do alerta	No plano; novo fingerprint
3	<code>query_logs</code> , erros na janela do alerta	No plano; novo fingerprint
4	<code>get_trace</code> para um id encontrado no passo 3	No plano; novo fingerprint
5	<code>query_logs</code> , janela deslocada em um minuto	Passo do plano já concluído, portanto fora do plano (leitura, 1 de 3); o fingerprint do resultado é igual ao do passo 3
6	<code>query_logs</code> , um campo de filtro a mais	Fora do plano (leitura, 2 de 3); mesmo fingerprint
7	<code>query_logs</code> , outra variante	Fora do plano (leitura, 3 de 3); mesmo fingerprint
8	Plano v2, solicitado depois que <code>progressCheck</code> devolveu “stalled”	<code>validatePlan</code> permite; armazenado como versão 2; replanejamentos usados 1 de 1; a janela recomeça aqui
9	<code>search_docs</code> para o runbook do componente suspeito	No plano v2; novo fingerprint; janela ainda não cheia, portanto “advancing”
10	<code>run_diagnostic</code> sobre uma amostra armazenada	No plano v2; novo fingerprint
11	Resposta final com um registro de diagnóstico	Predicado atendido; o run está <code>done</code>

Observe o que aconteceu nos passos 5 a 7. Cada chamada foi permitida, cada uma foi uma leitura dentro do escopo, e os argumentos diferiram a cada vez, então um detector de correspondência exata teria visto três chamadas diferentes. O fingerprint viu a mesma evidência três vezes. O run usou 11 dos seus 15 passos, contando os dois planos, e terminou com um

diagnóstico que cita ids dos passos 2, 3, 4 e 10. Uma quarta variante mais adiante no run, em qualquer um dos planos, teria sido recusada como `off_plan`, já que a contagem de leituras fora do plano não é zerada com o plano, e uma segunda estagnação teria entregue o run a Robin, com o registro e o motivo `plan_churn`, detalhe `stalled`.

Dos limites do loop aos orçamentos

O loop acima impõe o que consegue ver: passos, progresso, rotatividade de planos, escopo. Os seus motivos de parada são uma lista fechada que o código produz: `max_steps`, `plan_churn` (com o detalhe `stalled`, `oscillating` ou `refused_repeatedly`), `success_unmet` e `phase_violation`. Cada um corresponde a um hand-off, e cada um é um ponto de dados para os traces do Capítulo 20. Uma recusa como `outside_task_scope` não é um motivo de parada por si só; recusas repetidas aparecem como o detalhe `refused_repeatedly`.

O que ele não consegue ver é quanto o run custa: um run pode ficar dentro de 15 passos e ainda assim consumir muito além do razoável se cada passo carrega um contexto grande. Tokens, tempo, dinheiro e efeito total pertencem aos orçamentos e circuit breakers, que usam a mesma interface daqui: `bound.check(run)` levanta `BoundExceeded` com um motivo, e o run é encaminhado em hand-off.

Trade-offs e custos

Planejar custa uma chamada ao modelo e uma nova forma de error. O plano acrescenta latência antes do primeiro passo útil, armazenamento, código de validação que precisa acompanhar as mudanças nas ferramentas e uma classe de falha própria: um plano coerente, validado e construído sobre uma premissa errada. Um plano arrumado também pode ganhar uma confiança que o design não conquistou. Vale a pena para passos dependentes, recomeços caros e revisão pré-efeito, e não para tarefas de três passos ou menos.

A detecção de progresso tem falsos positivos, e cada um cai sobre uma pessoa. Um run que consulta uma métrica repetidamente enquanto um deploy termina se repete de forma legítima, e um run cuja evidência é real mas parecida pode parecer estagnado. Cada parada falsa custa a Ro-

bin a leitura do registro e uma decisão, de modo que os limiares (tamanho da janela, leituras fora do plano, replanejamentos) são trabalho de ajuste. Registre cada detecção com as suas entradas, revise uma amostra em intervalos regulares e ajuste com base no conjunto de evals (Capítulo 21), e não com base na última reclamação.

Hand-offs são o preço de toda parada. Se a taxa de hand-off é, digamos, um terço dos runs, o loop não é bom o bastante para ser um loop, e a resposta honesta pode ser um workflow.

Quando não usar isto. Não construa um detector de progresso para um workflow com três nós fixos, e não construa um design multiagente para obter fases que o registro de ferramentas de um único agente pode lhe dar.

Erros comuns

- **Tratar um plano aceito como uma autorização.** Um plano validado parece uma decisão que alguém tomou, e não carrega aprovação para nada do que lista. Correção: o gate verifica cada chamada quando ela é proposta.
- **Usar o limite de passos como única proteção.** Um contador é fácil de construir e encerra todo loop que nunca converge. Ele não faz nada quanto ao run que gasta onze de quinze passos sobre a mesma evidência ou sobre o serviço errado. Correção: acrescentar detecção de progresso e um escopo de tarefa.
- **Deixar o replanejamento correr solto.** Cada replanejamento é um plano válido, então parece uma recuperação e não um loop, e um loop de replanejamento sem limite é comportamento descontrolado um nível acima. Correção: limitar as versões do plano e levar as evidências coletadas até ali para cada uma.
- **Dar ao loop aberto todas as ferramentas.** Um único conjunto de ferramentas é o mais simples de configurar, e um loop com escritas ao alcance não tem um pior caso menor do que a sua pior escrita. Correção: colocar as leituras no loop, as escritas atrás de uma fronteira de etapa, e deixar o registro de ferramentas impor a ordem.

Pontos-chave

- O orquestrador conduz o loop e o modelo é chamado dentro dele: se há outro passo, o que o modelo vê e quando o run termina são decididos pelo código, e só a próxima proposta vem do modelo.
- Um plano é uma proposta: peça-o como estrutura, valide as suas ferramentas, a ordem e o tamanho antes de executar, leia as classes de efeito do registro e mantenha o status dos passos no run store, escrito pelo orquestrador, nunca pelo modelo.
- Um plano validado não autoriza nada; o gate verifica cada chamada no momento em que ela é proposta, e a aprovação se vincula à chamada exata.
- O sucesso é um predicado no código sobre uma resposta estruturada e as evidências que o run coletou, e ele verifica o que é verificável (formato, assunto, evidência no run), enquanto a verdade continua sendo assunto dos evals e das pessoas.
- As condições de parada vêm em camadas: um limite de passos desde o primeiro dia, detecção de progresso por assinaturas e result fingerprints, um limite de replanejamentos e um escopo de tarefa que pega a deriva, cada uma escalonando de uma observação para um replanejamento e para um hand-off.
- Mantenha pequena a parte aberta de um run: um loop limitado de ferramentas de leitura dentro de um workflow, com as escritas em uma fronteira de etapa atrás do gate, e com cada agente de um design multiagente mantendo o seu próprio envelope e uma parcela dos limites do pai.
- Toda parada é um hand-off com um reason code e um resumo construído a partir do registro, e todo limiar precisa de dados e de um responsável para ser um controle e não teatro.

O loop agora sabe parar por motivos que consegue ver, mas ainda não sabe quanto o run está custando, nem o que fazer quando uma dependência falha por baixo dele. O Capítulo 13 acrescenta os orçamentos e circuit breakers que cobrem isso.

Capítulo 13 — Orçamentos e circuit breakers

Imagine uma metade de manhã na Parcelport. Um provedor por trás do gateway de modelos começa a responder devagar. Nada falha por completo: as chamadas demoram mais, e algumas dão timeout. O agente de suporte tem o limite de passos que o Capítulo 12 recomenda, e todo run fica dentro dele. Mas cada passo agora espera por uma chamada lenta, o orquestrador faz retries dos timeouts, e cada retry é mais uma requisição paga a um provedor que já está em dificuldade. Suponha que o agente trate 200 tickets por dia. Em uma hora, todos os workers estão bloqueados em runs abertos, e os novos tickets entram na fila atrás deles.

Enquanto isso, o `payments-service` começa a devolver erros em algumas consultas de status de reembolso, e o agente propõe a verificação de novo e de novo, cada chamada dentro do limite do run. Do lado de operações, uma tempestade de alertas abre um run para cada um de quarenta alertas. Cada investigação é modesta; juntas, são uma conta que ninguém planejou, todas fazendo as mesmas duas perguntas às mesmas duas dependências.

Nenhum run isolado se comportou mal. Todo limite que a Parcelport tinha era um limite sobre um único run, e o problema vivia entre os runs: nas dependências e na soma. A pergunta que este capítulo responde é como pôr um teto no que um run, um agente e o sistema inteiro podem consumir ou causar, e como parar de chamar algo que está falhando, com controles que se sustentam nos dias em que ninguém está olhando.

Este capítulo pertence à parte **Limite** do envelope de controle, que pergunta onde o loop para e quanto custa executá-lo. O Capítulo 12 respondeu isso para a forma de um único run; este capítulo responde para tudo o que atravessa os runs: os **orçamentos**, que limitam o consumo em vários níveis, e os **circuit breakers**, que interrompem o tráfego para uma depen-

dência que falha ou para um agente que se comporta mal. Os retries e fall-backs, os caminhos seguidos quando um limite ou um breaker dispara, são o Capítulo 14.

O problema e por que ele é difícil

Um loop que custa algo a cada passada precisa de um teto. O limite de passos do Capítulo 12 é o primeiro a acrescentar, e o mais estreito: conta as passadas de um único run e nada diz sobre quão cara foi uma passada, quantos runs estão abertos, quanto dinheiro os tickets de um cliente movimentaram ou se a dependência está saudável.

Três classes de falha se encontram aqui. **F9 (explosão de custo ou latência)** é a óbvia: mil runs corretos que juntos custam demais. **F5 (loop descontrolado ou contexto obsoleto)** aparece de uma forma que um limite por run não vê: um retry contra uma dependência que falha não é um loop travado em nenhum run isolado, mas, entre os runs, é a mesma chamada repetida sem progresso. E **F7 (efeito não autorizado)** tem uma variante silenciosa: cada reembolso passa pela verificação do teto no gate, mas a sequência de runs de um cliente pode emitir muitos deles. Toda chamada foi permitida, e o total é algo que ninguém autorizou.

A abordagem óbvia é pedir ao modelo que seja econômico. O prompt diz para parar depois de poucas tentativas, evitar repetir uma chamada que falha, preferir o caminho barato. Isso reduz a taxa de passos desperdiçados e não pode ser o controle: um modelo dentro do run não enxerga os outros runs, a saúde da dependência no último minuto nem o total do dia, e um limite que depende da coisa limitada não é um limite.

Há uma segunda armadilha: um limite que é apenas observado é um dashboard. O caminho de código que gasta precisa consultar o limite antes de gastar, e a resposta precisa poder ser “não”.

Orçamentos: o que um run pode usar

Um **orçamento**, nos termos deste livro, é um limite sobre um recurso que um run pode usar, com uma unidade, um teto, um lugar onde é medido e um comportamento definido para quando se esgota. Se qualquer um dos

quatro falta, é um desejo. Estes tipos merecem lugar nos agentes da Parcelport.

Orça- mento	O que conta	Medido por	Contra o que protege	Resposta tí- pica quando se esgota
Passos	Passadas do loop	Orquestrador	F5	Parar e fazer hand-off
Chamadas de ferramen- tas	Chamadas, por ferramenta ou por classe de efeito	Orquestrador e gateway de ferramentas	F5, F9, carga so- bre uma dependência	Recusar essa ferramenta, ou fazer hand-off
Tokens	Tokens de entra- da e de saída por run	O gateway de mo- delos reporta o uso; o orquestra- dor soma	F9	Parar e fazer hand-off
Tempo	Tempo de relógio ativo do run	Relógio do orquestrador	F9 (latência), contexto obsoleto	Parar e fazer hand-off
Gasto	Dinheiro, deriva- do dos tokens e dos custos das ferramentas	Orquestrador, a partir de uma ta- bela de preços	F9	Parar e fazer hand-off
Efeito	Tamanho cumula- tivo dos efeitos, como o total reembolsado	Gateway de ferramentas	F7 (agregado), pressão de F6	Needs approval

Passos e chamadas de ferramentas são diferentes: um passo pode envolver nenhuma chamada de ferramenta ou várias, e um orçamento de chamadas de ferramentas é a forma de proteger uma dependência. Tokens são um medidor; gasto é tokens multiplicados por uma tabela de preços que al- guém mantém e que muda, então o Capítulo 22 é responsável pela tabela e este capítulo a consome.

O tempo exige uma distinção. Um run esperando por aprovação humana não gasta nada, e contar a espera faria a aprovação parecer uma violação de limite. O deadline absoluto do run, do Capítulo 10, cobre a idade total do run; o orçamento de tempo cobre o **tempo ativo**, enquanto o orques- trador e as suas dependências trabalham nele. Os dois existem, e respon- dem a perguntas diferentes.

O orçamento de efeito

A última linha é a que a maioria das equipes não tem, e merece a maior atenção. O Capítulo 4 e o Capítulo 6 puseram o teto de reembolso no código: uma chamada, um valor, verificado no gate. Esse controle nada diz sobre a soma: um run pode emitir dez reembolsos até o teto, e cada um passa. Se dez deveriam passar é uma questão de política que ninguém respondeu.

Um **orçamento de efeito** limita a magnitude cumulativa de um efeito para um escopo. Para a Parcelport, ele pode ser escrito ao lado do teto, no mesmo lugar e no mesmo estilo. A notação abaixo é ilustrativa, e os valores são hipotéticos.

```
policy refund_budget:                                // illustrative notation and
numbers
  per_call:      amount_minor <= refund_ceiling
  per_run:       sum(amount_minor) <= 2 * refund_ceiling
  per_customer: sum(amount_minor) over 24h <= 3 * refund_ceiling
  per_agent:     sum(amount_minor) over 1h <= agent_hourly_refund_limit
  on_exceed:     needs_approval, reason: "aggregate refund limit"
```

A resposta importa tanto quanto os números. Quando um limite agregado é ultrapassado, não devolveria uma recusa, porque ela diz ao modelo para tentar outra coisa, que pode ser outro caminho até o mesmo total. O veredito certo é `needs_approval`: uma pessoa, Sam, vê uma requisição que diz qual é o agregado e por que disparou, e decide. O Capítulo 15 trata de como essa aprovação é construída e vinculada à chamada.

Duas ressalvas. Um reembolso em `outcome_unknown` (Capítulo 6) deve ser contado pelo valor integral até que o seu status seja resolvido, ou um timeout ampliará discretamente o orçamento. E o orçamento de efeito não substitui o teto: ambos valem, e o mais estreito prevalece primeiro.

O runtime mantém a contabilidade

Aqui está o orçamento no nível do run como o orquestrador o mantém. O detalhe essencial é onde ficam os contadores.

```

run.bound_counters = {
    steps: 4, tool_calls: 5,
    tokens: 18200, active_ms: 41000, spend_units: 12
}
run.limits = limitsFor(run.kind, run.agent_version) // from policy data,
not from the model

function checkRunBound(run):
    for each kind in run.limits:
        if run.bound_counters[kind] >= run.limits[kind]:
            run.bound_reason = kind
            raise BoundExceeded

```

Os contadores ficam no run store, no registro do run do Capítulo 10, e são escritos pelo orquestrador como parte de cada passo. Não são recalculados a partir da conversa. Um orçamento que recomeça do zero ao retomar tem uma saída de emergência embutida, então os contadores viajam com o run através de uma queda ou de uma aprovação.

Os limites vêm de dados de política, indexados pelo tipo de run e pela versão do agente: um `ops-agent` investigando um alerta legitimamente precisa de mais de tudo do que um `support-agent` respondendo a uma pergunta de rastreamento. Digamos, um limite de 12 passos para um run de suporte e 40 para uma investigação: são valores hipotéticos, e os valores reais vêm da distribuição dos seus próprios runs.

Orçamentos em camadas

As falhas do início aconteciam entre runs, então um recurso precisa de um teto em cada nível em que pode ser consumido. Usaria cinco.

Nível	O que limita	Exemplo (hipotético)	Aplicado onde	Por que precisa do próprio nível
Run	Tudo o que está na tabela acima	Passos, tokens, tempo, efeito por run	Orquestrador	Um run que se comporta mal
Subject	Um ticket, um cliente, um alerta	Runs por ticket por hora; reembolsos por cliente por dia	Orquestrador e gateway de ferramentas	Um subject disparando muitos runs: um ticket reaberto, um cliente que escreve cinco vezes

Nível	O que limita	Exemplo (hipotético)	Aplicado onde	Por que precisa do próprio nível
Agente	Um agente, uma versão	Tokens por hora; runs em andamento; reembolsos por hora	Gateway do modelo, orquestrador, gateway de ferramentas	Muitos runs, cada um dentro do seu orçamento, somando-se
Tenant	Um lojista cujos pedidos a Parcelport trata (ilustrativo)	Parcela de tokens por dia	Gateway do modelo	Uma integração barulhenta deixando todos os outros sem recursos
Global	O sistema inteiro	Tokens e gasto por dia	Gateway do modelo	O número pelo qual alguém responde

Todos os níveis são verificados, e prevalece o mais estreito que estiver esgotado. A equipe de plataforma é responsável pelos níveis global e de agente; a liderança de suporte e o engenheiro de on-call opinam sobre os limites de efeito no nível do subject, que são regras de negócio sobre dinheiro e mudanças em produção.

Onde cada nível é aplicado

Um limite aplicado em um lugar que o caminho de código pode contornar é uma sugestão. Há três pontos de aplicação, e cada um vê algo que os outros não veem.

O **orquestrador** vê o run: passos, tempo ativo e as suas próprias chamadas de ferramentas. É o lugar certo para o nível do run e para contagens no nível do subject, como runs por ticket, e não enxerga outras réplicas ou agentes a menos que os contadores sejam compartilhados.

O **gateway de modelos** vê toda chamada ao modelo de todo chamador, o que o torna o único lugar em que um teto total de tokens ou de gasto pode ser absoluto, porque nenhum caminho de código até um modelo o evita. Um bug do orquestrador que esquece de contar não pode gastar além de um teto que o gateway aplica, já que os agentes nunca detêm credenciais do provedor (Capítulo 1 e Capítulo 18). No momento da escrita, o RAGmux mantém orçamentos de tokens e rate limits por projeto no gateway, de modo que o uso de tokens é limitado por projeto fora do agente; outras ferramentas adotam abordagens semelhantes, e um orçamento por run ainda pertence ao orquestrador, porque um gateway vê o tráfego de um projeto e não a intenção de um run.

O **gateway de ferramentas**, que é o gate das chamadas de ferramentas, vê os efeitos. É o lugar para os orçamentos de efeito, porque é o código por onde todo efeito aprovado passa antes de chegar a um serviço, e ele já guarda o contrato e a emissão da credencial.

A regra que seguiria é aplicar no ponto mais estreito que não pode ser contornado e contar onde a coisa contada é vista. Um orçamento de tokens contado pelo orquestrador e também aplicado no gateway são dois controles com modos de falha diferentes, e a diferença entre os seus números é, ela mesma, um sinal.

Reservar, chamar, liquidar

Os orçamentos são consultados antes de gastar, e o custo de uma chamada ao modelo só é conhecido depois. A resposta usual é reservar uma estimativa antes da chamada e depois liquidar com o valor real. Os contadores dos níveis superiores ficam em um counter store, que é um sistema separado do run store, e nenhuma transação atravessa os dois. A ordem das operações precisa dizer o que acontece em uma queda.

```
function spend(run, kind, estimate, work):
    taken = []
    for each level in [run, subject, agent, tenant, global]:
        if not counters.tryReserve(level.keyFor(run), kind, estimate, ttl:
60s):
            for each held in taken:
                counters.release(held, kind, estimate)          // give back
what we took
                raise BoundExceeded(level: level.name, kind: kind)
                taken.append(level.keyFor(run))
            run.bound_counters[kind] = run.bound_counters[kind] + estimate    // run
store, before the call
            result = work()                                                  // model call
or tool call; on timeout, usage = estimate
            for each held in taken:
                counters.settle(held, kind, reserved: estimate, actual:
result.usage)
            run.bound_counters[kind] = run.bound_counters[kind] - estimate +
result.usage
            return result
```

Três coisas no bloco são deliberadas. O contador no nível do run, no run store, é elevado pela estimativa antes da chamada e corrigido depois dela, de modo que uma queda ou um timeout no intervalo deixa a contagem do próprio run na estimativa e não em zero. Os contadores compartilhados carregam reservas com um tempo de vida, de modo que um worker que

cai entre reservar e liquidar deixa uma reserva que expira sozinha. Até lá, o contador compartilhado superestima; se o trabalho teve efeito e a queda veio antes da liquidação, ele pode subestimar até a reconciliação com os registros de uso do gateway e com o run store (digamos, uma vez por dia e em qualquer alerta de divergência). É por isso que o run store é a autoridade para um run e os contadores compartilhados são aproximados por projeto. E o caminho de falha libera o que foi tomado, de modo que uma recusa no nível global não vaza reservas.

Se o próprio counter store estiver indisponível, falharia fechado para os efeitos e aberto, com o limite no nível do run ainda aplicado, para as leituras. Um run que não consegue confirmar o seu orçamento agregado de efeito não deve emitir um reembolso; um run que não consegue atualizar um contador compartilhado de tokens ainda é limitado pelo seu próprio limite, e parar todo o trabalho porque um contador caiu transforma uma falha de contabilidade em uma indisponibilidade.

Quando um orçamento se esgota

Há quatro respostas úteis quando um orçamento se esgota, e a escolha deve ser escrita por tipo de orçamento e por nível, e não deixada ao caminho de código que por acaso levantar o erro primeiro.

Parar e fazer hand-off. O run passa para `handed_off` (Capítulo 10) com um resumo, e uma pessoa é responsável pelo desfecho. É o padrão para os orçamentos no nível do run, porque um run que se esgotou sem terminar disse algo sobre a tarefa ou sobre o agente, e um humano é o leitor certo.

Perguntar. Para os orçamentos de efeito, o veredicto é `needs_approval`, como acima. O run espera pela decisão, e uma decisão tomada por uma pessoa sobre uma requisição delimitada é o controle.

Esperar. Para orçamentos do tipo rate, nos níveis de agente, tenant e global, o run não precisa falhar. Ele espera em um checkpoint, o último limite de passo, e retoma quando a janela é reiniciada. Nos estados do Capítulo 10, o run continua `running` e não detém nenhum lease, e carrega uma `resume_condition` (uma janela reiniciada ou um breaker fechado) no registro do run. O sweep de reconciliação ignora um run `running` com lease expirado quando esse campo está definido e o deadline do run não passou, de modo que um run estacionado não é confundido com um run que

caiu e reiniciado. Isso serve ao trabalho que pode esperar, como uma investigação disparada por um alerta de baixa prioridade; o trabalho com um deadline que um cliente ou Robin está acompanhando deve fazer hand-off.

Degradar. O sistema entra em um comportamento reduzido e declarado: respostas sem ferramentas, rascunhos para um humano enviar, investigação somente de leitura. O que cada nível de modo degradado contém é o assunto do Capítulo 14; neste capítulo, um orçamento pode ser ligado a um deles, de modo que esgotar o orçamento de chamadas de ferramentas de uma dependência move o run para respostas que não precisam dela, com a limitação declarada.

O resumo do hand-off não deve precisar do orçamento

A forma óbvia de escrever um resumo de hand-off é pedir ao modelo, e essa chamada custa tokens, que estão esgotados. As equipes então deixam a chamada exceder o orçamento, o que torna o orçamento opcional, ou pulam o resumo, o que dá a Sam um ticket sem explicação.


Construiria o resumo a partir do run store, em código. Ele lista os fatos que o registro já guarda: o ticket, qual orçamento disparou e em que nível, os passos dados, os efeitos aplicados e os seus status, as intenções sem resultado, a última observação e o que não foi feito. Nada nele é gerado, então nada nele pode ser uma afirmação sem fundamento (F3), e ele não custa nada contra o orçamento do modelo. Uma narrativa do modelo pode ser acrescentada a partir de uma pequena reserva (digamos, alguns por cento dos tokens do run que o caminho normal não pode gastar), rotulada como escrita pelo modelo, abaixo dos fatos.

Os orçamentos são verificados em um ponto fixo. A verificação acontece no limite do passo, antes que o próximo passo comece, e nunca entre uma intenção e o seu efeito. Um run que é interrompido depois de `record(run, "intent", ...)` e antes do resultado deixa a intenção não resolvida que o Capítulo 10 ensinou o orquestrador a encontrar e resolver. Um orçamento que corta um run no meio de uma escrita irreversível cria F6 (falha parcial silenciosa) como efeito colateral de tentar evitar F9.

Circuit breakers para dependências

Um **circuit breaker** interrompe as chamadas a algo que está falhando, por um período, em vez de fazer retries. O seu gatilho é a saúde de uma dependência e não o consumo de um run: mil runs, cada um dentro do seu orçamento, ainda podem enviar mil chamadas a um serviço que não consegue responder.

O padrão é o clássico dos sistemas distribuídos, e se aplica aos serviços por trás das chamadas de ferramentas (`payments-service`, `orders-service`, o sistema de tickets), ao provedor do modelo por trás do gateway e aos servers MCP do Capítulo 8.



As chamadas falham imediatamente enquanto o breaker está aberto, com um motivo conhecido, e algumas sondas decidem quando ele fecha. O limiar precisa de volume suficiente para significar alguma coisa.

O que conta como falha

Só contam as falhas de dependência: timeouts, erros de conexão e `upstream_unavailable` da tabela do Capítulo 6. Um `outcome_unknown` também conta, com a obrigação adicional de verificar o status antes de qualquer retry.

As recusas não contam. `invalid_arguments`, `precondition_failed`, `not_permitted` e `approval_required` descrevem a proposta, não o serviço. Cinquenta propostas malformadas em um minuto não são prova de que o `orders-service` está fora do ar, e um breaker que abrisse por causa delas isolaria uma dependência saudável para todos os outros runs. Esses sinais pertencem ao breaker no nível do agente, na próxima seção.

A regra de disparo precisa de um volume mínimo: três chamadas com duas falhas são uma taxa de dois terços e nenhuma informação. Digamos, um disparo quando pelo menos metade das chamadas em uma janela de 60 segundos falha, com pelo menos 20 chamadas nela. Os números são hipotéticos; o formato (uma taxa, um piso de volume, um cool-down) é o que se deve manter.


Onde os breakers vivem e como devem ser as sondas

O estado de um breaker diz respeito a uma dependência, então é compartilhado por todos os runs que usam essa dependência, e não mantido por run. Ele vive no gateway de ferramentas para as dependências de ferramentas e no gateway de modelos para os provedores. O estado por réplica não precisa de nenhum sistema extra e abre em momentos ligeiramente diferentes; o estado compartilhado abre em todo lugar ao mesmo tempo e é mais uma dependência a manter disponível. Começaria por réplica e passaria para o estado compartilhado quando os seus próprios incidentes mostrarem a diferença.

A sondagem exige cuidado com dependências de escrita. Para o `payments-service`, a chamada de teste de um breaker half-open não pode ser um `issue_refund`: a sonda é uma leitura, um endpoint de status ou uma ferramenta de leitura contra o mesmo serviço, porque uma escrita irreversível não é uma verificação de saúde. O número de sondas é pequeno e fixo, para que um serviço em recuperação não seja atingido por todo o backlog.

O que um breaker aberto faz com um run

Um breaker aberto é um tipo de recusa diferente de uma recusa do gate. Não é uma declaração sobre a proposta; é uma declaração sobre o mundo, e deve chegar ao modelo como uma observação com o seu próprio motivo, como `upstream_unavailable` com `details` que dizem que o breaker está aberto e quando vence a próxima sonda. O que acontece em seguida depende da classe de efeito da chamada; nenhum ramo do diagrama termina em “fazer retry mesmo assim”.



Para uma **leitura**, a falha rápida é toda a resposta: o modelo usa outra fonte ou declara que não pôde verificar. Uma resposta que depende de uma leitura que falhou não deve afirmar o seu resultado (F3), e a verificação de afirmações do Capítulo 2 garante isso.

Para uma **escrita reversível**, a intenção pode ser estacionada no estado do run com uma expiração e aplicada quando o breaker fechar. Quando o run retoma, o gate reavalua a chamada contra o mundo atual, porque o con-

texto que produziu a proposta agora é mais antigo (F5.2, contexto obsoleto).

Para uma **escrita irreversível**, não enfileiraria: um reembolso que espera uma hora é um reembolso cujo saldo e titularidade podem ter mudado. O run faz hand-off com o resumo, e Sam decide, com o estado da dependência visível. A exceção é uma chamada que já detém uma aprovação válida e uma chave de idempotência: ela pode sofrer retry depois que o breaker fechar, porque a repetição é segura por construção (Capítulo 6).

Para um **efeito colateral externo**, como `send_customer_reply` contra um sistema de tickets indisponível, estacionar é razoável. O texto aprovado está vinculado a um hash e carrega uma chave de idempotência, de modo que enviá-lo depois é a mesma ação, com as pré-condições reverificadas na retomada: se o cliente escreveu de novo, a resposta pode já não servir.

O provedor do modelo

O provedor do modelo é uma dependência de que todo run precisa em todo passo. Quando o seu breaker abre, nenhum run consegue propor nada, então o orquestrador estaciona os runs no limite do passo, com checkpoints, em vez de fazê-los falhar. Se um segundo provedor assume é a questão de fallback do Capítulo 14.

O trabalho novo também precisa de um limite. Uma fila sem limite transforma uma indisponibilidade em uma explosão de latência posterior e mais difícil de ver (F9), então limitaria a fila por tamanho e por idade. O trabalho que não pode ser aceito fica onde começou: o ticket permanece na fila normal da equipe de Sam, como antes de o agente existir. Esse processo humano é o verdadeiro modo degradado do agente de suporte, e vale a pena projetá-lo para que esse caminho sempre exista.

Circuit breakers para o próprio agente

Os breakers de dependência vigiam o mundo, mas algumas falhas nenhuma dependência reporta. Uma nova versão do prompt, uma mudança de modelo por trás do gateway, uma descrição de ferramenta alterada ou uma entrada envenenada podem mover o comportamento de formas que

nenhuma verificação individual pega: cada proposta pode ser permitida, e o padrão ainda assim estar errado. Um **breaker no nível do agente** observa as taxas de coisas que são normais em pequena quantidade.

Sinal	O que um aumento pode indicar	Fonte
Taxa de recusas do gate	Propostas saindo dos contratos: F1, F2, ou conteúdo conduzindo as chamadas (F4)	Decisões do gate no registro
Taxa de recusa em aprovações	Humanos rejeitando o que o agente propõe: as propostas estão piores do que antes	Serviço de aprovação
Erros idênticos repetidos	Um loop que as verificações por run só enxergam um run de cada vez (F5)	Resultados de ferramentas entre runs
Volume de efeitos	Mais reembolsos, mudanças de flag ou respostas do que o baseline da hora	Gateway de ferramentas
Taxa de orçamentos excedidos e de hand-offs	Tarefas que já não cabem nos seus orçamentos	Orquestrador
Taxa de gasto	Uma mudança no custo por run	Contadores

O breaker não conhece a causa, e não deve tentar: age sobre o sintoma, como um SRE que recebe um page por um alerta de taxa de erros e diagnostica depois.

Os sinais são taxas contra um baseline, tirado do seu próprio registro (Capítulo 20) para a mesma versão do agente, ao longo de um período longo o bastante para incluir o formato semanal do trabalho. Uma mudança de prompt, modelo, contrato de ferramenta ou política inicia um novo baseline, de modo que o primeiro período depois de qualquer mudança merece vigilância mais próxima. Um breaker sem piso de volume dispara em uma noite tranquila, quando dez tickets, três deles estranhos, parecem uma anomalia.

```


function evaluateAgentBreaker(agent, version, window):
    stats = metrics.window(agent, version, window)
    if stats.steps < minSteps:
        record(agent, "agent_breaker_skipped", "too little data") // say
so in the record
        return breaker.state(agent, version) // no verdict from thin
data; the state does not change
        tripped = []
        for each signal in signalsFor(agent):
            if stats.rate(signal) > baseline(version, signal) * signal.factor:
                tripped.append(signal)
        if tripped is not empty and agent.breakerMode == "observe":
            record(agent, "agent_breaker_would_open", tripped) // observe:
record only, no state change, no page
        else if tripped is not empty:
            breaker.open(agent, version, mode: min(strictestMode(tripped),
restricted)) // stopped is a human decision
            record(agent, "agent_breaker_open", tripped)
            page(ownerOf(agent)) // a human decides what
happens next
        return breaker.state(agent, version)

```

O que um breaker de agente aberto faz

Um breaker no nível do agente tem modos, e os modos formam uma escada. O primeiro degrau é **observe**: o breaker registra que teria disparado e não envia page para ninguém, que é como os limiares são ajustados. Ele não muda nenhum estado, por isso o diagrama abaixo o deixa de fora. O segundo é **restricted**: o agente continua lendo e redigindo, mas todo efeito acima da leitura é recusado ou vira `needs_approval`, e os runs que precisam de um efeito fazem hand-off com o seu resumo. É o modo somente de leitura, e é o máximo que o caminho automático pode definir. O terceiro é **stopped**: nenhum run novo, e os runs em andamento esperam no próximo limite de passo. É o kill switch, e só uma pessoa o aciona.

A divisão entre transições automáticas e manuais é a decisão de design. Observe a seta ausente no diagrama: nada volta de `restricted` ou `stopped` para `closed` por conta própria.



Um breaker de dependência fecha sozinho, porque uma sonda pode mostrar que a dependência se recuperou. Um agente não tem sonda: nada que uma chamada de teste devolva diz que o comportamento voltou ao normal, e um temporizador nada sabe sobre a causa ter sido encontrada. Assim, o breaker do agente abre automaticamente e fecha por decisão de uma pessoa, registrada com quem e por quê; a alternativa é um sistema que refaz a tentativa da sua própria anomalia a cada período de cool-down.

O kill switch

O **kill switch** é a ponta manual do mesmo mecanismo, e vale listar as suas propriedades de design porque é o controle usado no pior dia.

- **Vive fora do agente.** É uma flag em um store que o orquestrador e o gateway de ferramentas leem, e nem o modelo nem qualquer ferramenta podem escrevê-la. Não está na lista de ferramentas de nenhum agente, e as credenciais do agente não chegam até ela (Capítulo 7).

- **É verificado em dois lugares.** O orquestrador o verifica antes de cada passo, e o gateway de ferramentas o verifica antes de cada efeito. Um bug em um deixa o outro, e uma chamada em andamento que começou antes de a flag mudar ainda é interrompida no gateway se ainda não tiver tido efeito.
- **Tem escopos.** Um switch para o agente inteiro é o instrumento rombudo. Um switch por ferramenta (parar `issue_refund` e deixar `lookup_order`), por classe de efeito, por tenant ou por versão do agente é o mais usado, porque o resto do sistema continua funcionando.
- **Não depende do que está falhando.** O gateway de modelos, o serviço de aprovação ou o pipeline de traces podem ser o problema no dia em que ele é necessário. Os caminhos que acionam e leem o switch não dependem de nenhum deles, e, se o flag store estiver inacessível, o leitor usa o último valor conhecido por um período curto e depois recusa os efeitos (falhando fechado).
- **Tem operadores nomeados.** O runbook diz quem pode acioná-lo para cada agente: digamos, Sam ou Alex para o `support-agent`, Robin ou Alex para o `ops-agent`. Um switch que precisa de uma reunião para ser autorizado é mais lento do que o incidente.
- **É exercitado.** Um switch que nunca foi acionado é uma hipótese. O Capítulo 23 trata da simulação, e o Capítulo 21 pode incluir verificações de que uma flag acionada muda o que o gate devolve.

Os runs em andamento esperam no próximo limite de passo com os seus checkpoints intactos, de modo que um reset possa retomá-los. O orquestrador primeiro resolve qualquer intenção em aberto verificando o status do serviço, como o Capítulo 10 descreve, para que a parada não deixe um reembolso no `payments-service` sem resposta e um run marcado como done (F6).

Definir limiares e o preço de um falso alarme

Não sei quais são os limites certos para os seus agentes, e ninguém pode lhe dizer sem observá-los trabalhar; o método importa mais do que os números.

Comece todo limiar em modo observe: os contadores rodam e os eventos de excesso são registrados para os orçamentos, e a avaliação do breaker registra o que teria feito, e nada é interrompido. Depois de um período longo o bastante para cobrir o ritmo semanal, você tem uma distribuição própria: passos, tokens e tempo ativo dos runs que terminaram bem, conforme julgado pelos evals (Capítulo 21) e pelo que os revisores humanos fizeram. Defina um limite de run acima da cauda legítima, para que o limite corte os runaways e não os lentos mas corretos. Um orçamento definido a partir da média é um gerador de hand-offs.

Os custos são assimétricos. Um falso alarme em um orçamento de tokens custa um hand-off e algum trabalho parcial, e uma falha em detectar custa dinheiro e latência. Um falso alarme em um orçamento de efeito custa uma requisição de aprovação, e uma falha em detectar custa dinheiro movimentado sem que ninguém decida. Por isso os orçamentos de efeito são definidos mais apertados e os de tokens mais folgados, e diria isso no arquivo de política, ao lado dos números.

Os sinais de que os limiares estão errados estão no registro. Se um humano termina em poucos minutos runs que excederam um orçamento, com a resposta a que o agente se encaminhava, o limite está baixo demais. Se o breaker abre toda semana e ninguém age, ele será silenciado. Se um breaker oscila, a janela é curta demais ou o cool-down breve demais, e a histerese (uma barra mais alta para fechar do que para abrir) costuma ajudar mais do que um número diferente.

Todo alerta precisa de um responsável e de uma primeira ação no runbook; um page que diz “agent breaker open” sem uma primeira verificação ensina quem o recebe a confirmar e esperar. Para um agente em modo restrito, a primeira ação costuma ser olhar o sinal que o disparou e as mudanças do agente no último dia, o que só funciona se o histórico de mudanças existir (Capítulo 20 e Capítulo 23).

Percorrendo o cenário de abertura pelos controles

Com os controles no lugar (ilustrativo), o breaker do gateway de modelos abre diante do provedor lento, e o orquestrador estaciona os runs em andamento no limite do passo, de modo que nenhum retry se acumula sobre

ele e os runs podem ser retomados. Os tickets novos ficam no sistema de tickets, e a equipe de Sam os trata como antes.

O breaker do gateway de ferramentas para o `payments-service` faz sondagem com leituras de status, e os runs que precisam de `issue_refund` fazem hand-off com um resumo. A tempestade de alertas encontra os níveis de subject e de agente: quarenta alertas viram um número limitado de runs. Um run reiniciado mantém os seus contadores. Ao meio-dia, o gasto está muito acima do baseline, o breaker do agente passa para `restricted`, os efeitos exigem aprovação ou hand-off, e uma pessoa recebe um page.

Nenhum desses controles torna o provedor mais rápido nem o serviço de pagamentos mais saudável. Eles mudam o que a indisponibilidade custa.

Trade-offs e custos

Todo limite é um hand-off à espera de acontecer. Um orçamento que dispare encerra um run que talvez tivesse terminado, e uma pessoa herda o trabalho. É a escolha certa em comparação com um run sem limite, e uma escolha ruim quando o limite é um palpite, e é por isso que o modo observe vem primeiro.

Estado, e uma nova coisa a manter disponível. Os contadores e o estado dos breakers são sistemas de produção com latência, erros e indisponibilidades, e reservar e liquidar acrescenta uma chamada antes de cada chamada ao modelo e de cada efeito. Uma indisponibilidade do counter store não deve virar uma indisponibilidade da plataforma, então o padrão é escolhido com antecedência: falhar fechado para os efeitos, limitado pelo próprio limite do run para as leituras.

Cinco níveis são cinco coisas a revisar. Se a equipe é pequena, um nível de run e um nível global, com os orçamentos de efeito no gateway de ferramentas, cobrem a maior parte do valor. Acrescente os outros quando um incidente ou os dados mostrarem runs individualmente corretos que, somados, viram um problema.

Os breakers escondem problemas além de contê-los. Cada disparo é um sinal para o responsável pela dependência.

O breaker do agente precisa de um baseline. Para um agente ou uma versão nova, o primeiro período é em modo observe, e a proteção vem dos orçamentos e das aprovações. Dê nome a essa lacuna.

Quando não usar isto. Uma dependência que já está atrás de um mesh ou de uma biblioteca cliente com um breaker não precisa de um segundo; acrescente os sinais no nível do agente e o orçamento de efeito, que nada mais oferece. Um protótipo de curta duração, somente de leitura, com um único usuário precisa de um limite de passos e de um limite de tempo. O orçamento de efeito é necessário quando um efeito pode movimentar dinheiro ou alterar a produção, e o kill switch quando algo além da pessoa diante de uma tela pode causar isso.

Erros comuns

- **Pôr o limite no prompt.** É uma linha e o modelo costuma obedecer. Mantenha a linha como auxílio e acrescente um contador no orquestrador que levanta o erro de qualquer modo.
- **Apenas limites por run.** Cada run é fácil de analisar isoladamente, e todo dashboard permanece verde. Todo run está dentro do seu limite e a soma é o incidente. Acrescente os níveis em que os runs se somam.
- **Zerar os contadores ao retomar.** Um novo objeto de run é a maneira mais simples de recomençar depois de uma queda ou de uma espera por aprovação. Carregue os contadores no registro do run através de uma queda ou de uma espera por aprovação.
- **Contar todo erro para o breaker.** Um único contador de erros é simples de construir. Conte apenas as falhas de dependência e envie as recusas ao breaker do agente.
- **Fechar um breaker de agente por temporizador.** Os breakers de dependência fazem isso, então parece consistente. Não existe sonda para comportamento. Uma pessoa o fecha, com um motivo registrado.

Pontos-chave

- Um orçamento é um limite com uma unidade, um lugar onde é medido e um comportamento definido para quando se esgota, e só conta

como controle se o caminho de código que gasta for obrigado a consultá-lo primeiro.

- O limite de passos é o limite mais estreito; também são necessários orçamentos para chamadas de ferramentas, tokens, tempo ativo, gasto e efeito cumulativo, e o orçamento de efeito fecha a lacuna entre o teto por chamada e a soma.
- Divida os orçamentos em camadas onde o consumo se soma (run, subject, agente, tenant, global), aplique cada um no ponto mais estreito que não pode ser contornado e mantenha os contadores do run no registro do run, para que a retomada não os zere.
- Quando um orçamento se esgota, decida com antecedência se o run para e faz hand-off, pede aprovação, espera ou degrada, e construa o resumo do hand-off a partir do run store para que não dependa do orçamento que acabou de ser gasto.
- Um circuit breaker observa a saúde de uma dependência, conta apenas falhas de dependência, sonda as dependências de escrita com leituras e trata o estado aberto de forma diferente para cada classe de efeito, em vez de fazer retry mesmo assim.
- Um breaker no nível do agente observa taxas contra um baseline, restringe os efeitos quando dispara e só é fechado por uma pessoa; o kill switch é a sua ponta manual, mantido fora do agente e exercitado.
- Os limiares começam em modo observe e vêm do seu próprio registro, e o custo de um falso alarme, um hand-off ou uma aprovação, faz parte do número.

Os controles deste capítulo interrompem um run e interrompem o tráfego para uma dependência que falha, e dizem muito pouco sobre o que fazer na próxima vez que uma chamada falhar. O Capítulo 14 trata disso: quais falhas merecem um retry, como os retries são mantidos dentro dos orçamentos acima e como é a escada de fallbacks quando o caminho principal não está disponível.

Capítulo 14 — Retries e fallbacks

Imagine uma sexta-feira à noite na Parcelport, uma hora antes da troca do rodízio do fim de semana. Um cliente pede o reembolso de uma encomenda danificada, e o agente de suporte propõe `issue_refund` para o pedido. O serviço de pagamentos inicia a transferência e, em seguida, a resposta dele expira por timeout. O orquestrador vê uma chamada com falha e tenta de novo, e o retry reconstrói a chamada com uma chave nova. O cliente é reembolsado duas vezes, e o log do run mostra um sucesso e um erro.

O retry também não estava sozinho. A biblioteca de cliente dentro do orquestrador repetiu a chamada três vezes, o orquestrador envolveu isso em um loop próprio de três, e o runner de runs reiniciou o run com falha mais três vezes. Com três tentativas por camada, uma única dependência lenta vira até 27 chamadas, cada uma um possível segundo reembolso, todas cobradas do mesmo run.

Nada nessa história exigiu que o modelo errasse: uma dependência estava lenta, e o design respondeu com mais carga e mais escritas. Este capítulo pertence à parte **Limite** do envelope de controle, que pergunta onde o loop para e quanto custa executá-lo. Um retry decide quantas vezes o mesmo caminho pode ser tentado, e um fallback decide qual caminho tomar quando isso não basta. Os dois precisam ser projetados, porque ambos gastam orçamento e podem transformar uma falha pequena em uma grande.

O problema e por que ele é difícil

“Retry” soa como uma coisa só e são pelo menos quatro. Uma chamada a uma dependência pode falhar porque a rede a derrubou, porque a dependência estava sobrecarregada e avisou, porque a dependência a recusou por mérito, ou porque quem chamou desistiu de esperar e não sabe o que aconteceu. Uma chamada ao modelo pode falhar de todas essas formas e de uma quinta: a chamada tem sucesso e a proposta está errada. Esses ca-

sos pedem respostas diferentes, e a resposta a um deles é prejudicial quando aplicada a outro. Repetir uma chamada recusada desperdiça dinheiro; repetir uma escrita de resultado desconhecido pode movimentar dinheiro duas vezes; repetir uma chamada ao modelo que errou com confiança pode produzir de novo a mesma proposta errada.

Várias classes da taxonomia do Capítulo 3 estão envolvidas. Um `retry storm` é F9 (explosão de custo ou latência): o run está correto, e a carga que ele cria não está. Uma escrita repetida depois de um `timeout` é F6 (falha parcial silenciosa) quando a primeira tentativa foi efetivada e nada no registro diz isso. Um loop que repergunta ao modelo a mesma coisa com o mesmo contexto até que um limite o interrompa é F5 (loop descontrolado ou contexto obsoleto). E “perguntar de novo” como reparo para F1 (saída malformada), F2 (ferramenta incorreta ou argumentos incorretos) ou F3 (afirmação sem fundamento) tem limites fáceis de deixar passar, porque uma segunda amostra às vezes funciona e os sucessos ficam na memória.

A abordagem óbvia é um helper genérico de `retry` com `exponential backoff` e um limite de tentativas, mais um modelo reserva. Isso funciona para uma leitura em um serviço sem estado e falha onde importa aqui. O helper não conhece a classe de efeito da chamada, então repete escritas como repete leituras. Não sabe que a camada acima também está fazendo `retry`. Não cobra do orçamento do run, de modo que um run limitado a 15 passos pode fazer 15 passos de três tentativas cada. E o modelo reserva é uma segunda configuração que ninguém avaliou: entra em ação quando a atenção está mais baixa e produz propostas para as quais o sistema de controle nunca foi ajustado.

Classifique a falha antes de repetir qualquer coisa

O primeiro controle é uma classificação: antes de qualquer repetição, o orquestrador decide de que tipo de falha se trata, a partir de dados que o código já tem: o código de erro, o flag `retryable`, a classe de efeito da ferramenta e se a chamada poderia ter chegado ao destino. O modelo não participa. O vocabulário fechado de erros do Capítulo 6 torna a classificação mecânica, e a tabela acrescenta uma coluna “quem repete”, porque uma falha transitória de dependência e uma proposta recusada têm respostas diferentes.

Tipo de falha	Exemplo	Mesma chamada de novo?	Quem repete
Falha transitória de dependência	Uma resposta de rate limit, uma conexão recusada, <code>upstream_unavailable</code>	Sim; uma escrita só com a mesma chave de idempotência, após um atraso	O orquestrador
Leitura transitória	Um timeout em <code>lookup_order</code>	Sim, com limite	O orquestrador
Resultado desconhecido de uma escrita	Um timeout em <code>issue_refund</code> , <code>outcome_unknown</code>	Não, consulte primeiro o responsável pelo estado	A consulta de status e, talvez, depois o orquestrador
Proposta do modelo recusada	<code>invalid_arguments</code> , <code>precondition_failed</code>	Não a mesma chamada; uma nova proposta	O modelo, em uma rodada de correção contabilizada
Permanente	<code>not_permitted</code> , <code>result_invalid</code>	Não	Ninguém; registre e faça o hand-off
Aprovação ausente ou vencida	<code>approval_required</code>	Não do jeito que está	Ninguém faz retry; volta ao caminho de aprovação (Capítulo 15)
Duplicado	<code>duplicate_replayed</code>	Nada a repetir	Continuar a partir do primeiro resultado

Duas linhas merecem ênfase. Primeiro, “transitória” é uma afirmação sobre a dependência, e só é utilizável quando uma repetição não pode agir duas vezes: a chamada comprovadamente não agiu, ou o retry leva a mesma chave de idempotência, de modo que a ferramenta pode reproduzir o primeiro resultado. Uma resposta de rate limit é a dependência dizendo “não processei isto”. Uma resposta `upstream_unavailable` é mais fraca, porque um erro de servidor pode chegar depois de o trabalho ter sido feito. Um timeout é quem chamou dizendo “parei de esperar”, o que não diz nada sobre a dependência. Para uma leitura, a diferença não importa; para uma escrita, ela é toda a diferença (Capítulo 5): um timeout em uma escrita é um resultado desconhecido, não uma falha.

Segundo, `approval_required` tem uma linha própria. O Capítulo 6 fez desse código um indicador de defeito: uma chamada chegou a uma ferramenta sem aprovação válida, ou com uma aprovação vencida. Um loop de retry que o trate como transitório vai martelar um gate que está funcionando corretamente; a chamada volta pelo gate e pelo caminho de aprovação do Capítulo 15.

```
function classifyFailure(call, result):
  if result.code == "outcome_unknown":
    return "query_status" // the owner of the state
  answers, not the retry loop
  if result.status == "timeout":
    if isWrite(call.tool): // reversible write,
  irreversible write, external side effect
    return "query_status" // the write may have
  happened
    return "retry_same_call" // a read: repeating it
  changes nothing
    if result.code == "upstream_unavailable":
      return "retry_same_call" // a read, or a write
  retried with its original idempotency key: the error may come after the
  effect
    if result.code in ["invalid_arguments", "precondition_failed"]:
      return "reproposal" // the call itself is
  wrong; a retry would repeat the refusal
    if result.code == "approval_required":
      return "approval_path" // a defect or a stale
  approval: Chapter 15, never a retry
    if result.code == "duplicate_replayed":
      return "continue"
    return "stop" // not_permitted,
  result_invalid, and any unknown code
```

A última linha é o padrão conservador do Capítulo 6: um código desconhecido é uma parada e um hand-off, não um palpite, já que uma tabela que falha aberto faz de cada novo erro em uma nova ferramenta um potencial loop de retry.

A segurança do retry segue a classe de efeito

A classe de efeito diz boa parte do que se pode repetir; a coluna que importa é o que acontece quando o resultado não é conhecido.

Classe de efeito	Após uma rejeição antes de agir	Após um timeout ou resultado desconhecido	O que cada tentativa reaproveita
leitura	Retry, com limite	Retry, com limite	Nada é necessário; uma nova leitura pode trazer dados mais recentes
escrita reversível	Retry com a mesma chave	Consultar o status; fazer retry só se “não aplicada”	A chave, os argumentos
escrita irreversível	Retry com a mesma chave	Consultar o status; fazer o hand-off se não houver resposta	A chave, os argumentos
efeito colateral externo	Retry com a mesma chave	Consultar o sistema de tickets; fazer o hand-off se não houver resposta	A chave, o texto exato

Dois detalhes ficam por baixo da tabela. “Reaproveita a chave” é literal: um retry que reconstrói a chamada deve reconstruir a chave que o Capítulo 6 define, a partir de identificadores atribuídos pelo runtime. Um retry que cunha uma chave nova a cada tentativa tem a forma da segurança e nenhuma de sua substância, porque a ferramenta vê uma chamada nova a cada vez.

E a chave é a rede de proteção, enquanto a consulta de status é o plano (capítulos 5 e 10). A chave só ajuda se a ferramenta a guardar e a respeitar; a consulta de status diz em que mundo você está. Uma ferramenta que não consegue respeitar uma chave não é entregue ao agente como uma escrita irreversível (Capítulo 6). Para `send_customer_reply`, cujo contrato completo está no Capítulo 15, a regra é a mesma: se o sistema de tickets der timeout, o orquestrador pergunta se a resposta foi enviada e não envia de novo por palpite.

Aviso: Uma escrita que dá timeout e sofre retry sem uma consulta de status, ou com uma chave recém-cunhada, pode movimentar dinheiro ou enviar mensagem ao cliente duas vezes. Este é o único ponto do capítulo em que diria “nunca”: o custo de errar é irreversível.

Retries em código

Um helper de retry que siga a tabela é curto, e os detalhes estão no que ele se recusa a fazer. O bloco envolve o efeito de uma chamada já permitida; o gate decidiu isso antes, e um retry não reabre a questão.

```
function callWithRetry(run, call):
    attempt = 1
    while true:
        result = effect.apply(run, call)           // same call and
        same key on every attempt
        action = classifyFailure(call, result)
        if action != "retry_same_call":
            return { result: result, action: action }
        policy = retryPolicy(call.tool)
        if attempt >= policy.maxAttempts:         // say, three
        attempts in total
            return { result: result, action: "give_up" }
            delay = jitteredBackoff(attempt, policy)
            if delay > remainingDeadline(run):     // never sleep
            past the run's own deadline
                return { result: result, action: "give_up" }
            if not bound.chargeRetry(run, call.tool): // retries come
            out of the budget (Chapter 13)
                if isWrite(call.tool):             // a read has no
            intent to close
                    record(run, "effect", { call: call.id, status: "not_applied"
            }) // a write reaches this branch only after a rejection before acting
                raise BoundExceeded
                record(run, "retry", { call: call.id, attempt: attempt, delay: delay
            })
                sleep(delay)
                attempt = attempt + 1
```

Se todas as tentativas falharem, o loop termina no limite de tentativas ou no deadline, o que vier primeiro, e devolve `give_up` com o último resultado; quem chamou passa então a um fallback. O loop nunca devolve “continue tentando”. Se o orçamento se esgota, `BoundExceeded` se propaga até `runAgent`, que faz o hand-off como no loop canônico do Capítulo 1. A intenção é fechada antes como `not_applied`, porque uma escrita só chega ao ramo de retry depois de uma rejeição antes de agir (uma leitura não tem intenção a fechar), e um hand-off com uma intenção aberta mandaria uma pessoa resolver algo já conhecido. Cada tentativa deixa um registro, de modo que o on-call consegue distinguir um retry de uma dependência lenta.

O registro da intenção fica fora deste helper: o `executeCall` do Capítulo 5 o grava uma vez, antes da primeira tentativa, e os retries são tentativas daquela única intenção. Uma intenção nova por tentativa deixa um sweep de recuperação sem saber a qual delas perguntar ao destino.

Backoff e jitter

O atraso entre as tentativas dá tempo para a dependência se recuperar, o que o crescimento exponencial faz, e impede que quem chama repita junto, o que a aleatoriedade faz: se 200 runs falharam no mesmo instante e todos esperam exatamente um segundo, todos voltam no mesmo instante.

```
function jitteredBackoff(attempt, policy):
    ceiling = min(policy.maxDelay, policy.baseDelay * power(2, attempt - 1))
    // grows, then caps
    return random(0, ceiling)
// full jitter: any point up to the ceiling
```

Usaria full jitter, um atraso aleatório entre zero e o teto, porque ele espalha quem chama por todo o intervalo. A base e o limite (digamos, meio segundo e oito segundos) cabem a você ajustar. Se a dependência informa quando voltar, use a indicação como limite inferior, com um teto, para que uma indicação de uma hora não deixe um run estacionado. E trate o atraso como um custo para uma pessoa: em runs iterativos, o limite de tentativas e o deadline devem ser mais curtos do que em uma investigação em segundo plano.

Os retries saem do orçamento

Um retry é uma chamada de ferramenta que consome tempo e, no caso de uma chamada ao modelo, gasto e tokens. Por isso, cada retry é cobrado dos mesmos orçamentos de uma primeira tentativa (o Capítulo 13 trata dos tipos de orçamento), e o contador fica nos contadores de limite do run no run store (Capítulo 10), para que um run retomado não comece seus retries do zero. A contagem de retries deve ser um contador próprio, para diagnóstico: 12 chamadas, das quais nove foram retries, é um sinal sobre uma dependência.


Uma camada é responsável pelos retries

O cenário de abertura multiplicou tentativas entre camadas. A correção é uma regra e não um número: para uma dada chamada, exatamente uma camada faz retry. Colocaria isso no orquestrador, porque ele conhece a classe de efeito, o orçamento e o deadline. As bibliotecas de cliente abaixo dele são configuradas com zero retries, ou os retries delas contam como os do orquestrador. O mesmo vale para um gateway de modelos que faz retry interno de uma chamada ao provedor. Um runner de runs que reinicia runs com falha é outra camada do mesmo tipo, e uma reinicialização deve retomar a partir de um checkpoint (Capítulo 10) e não reexecutar o run. Na revisão de design, registre por escrito onde ficam os retries de cada dependência.

Retry storms

Quando uma dependência fica lenta, os retries são a maior fonte de carga extra, e é assim que uma indisponibilidade parcial se torna total. Três controles funcionam juntos. O primeiro é o jitter e o limite acima. O segundo é um retry budget no nível da frota: os retries só são permitidos enquanto ficarem abaixo de uma fração das primeiras tentativas em uma janela (digamos, um décimo). Quando a dependência está falhando, quase toda tentativa é um retry, a fração é excedida e os retries cessam, ainda que nenhum run individual tenha atingido seu limite. O terceiro é o circuit breaker (Capítulo 13): com ele aberto, as chamadas falham rapidamente sem ser enviadas, e o loop de retry nunca começa.

Um breaker aberto não é um erro a ser repetido; é o sinal para a escada de fallback avançar. No diagrama, nenhum caminho forma loop sem um contador, e o breaker entra pelo lado, pulando os retries.



Quando a saída do modelo é a falha

Uma chamada ao modelo que devolve uma proposta recusada pelo gate é diferente de uma falha de dependência: nada estava indisponível, e a proposta estava errada. A ferramenta do orquestrador para isso é outra chamada ao modelo, com limites próprios.

Perguntar de novo é uma nova amostra, não um retry

Um retry repete uma chamada e espera que uma dependência recuperada se comporte como antes. Perguntar de novo ao modelo não tem essa expectativa. A saída dele varia com o contexto e com a amostragem, de modo que uma segunda chamada com contexto idêntico pode devolver uma proposta diferente, e essa é a única razão pela qual perguntar de novo às vezes funciona. Funciona como um sorteio, não como um reparo.

Disso decorrem três consequências. Um contexto idêntico pode reproduzir uma falha idêntica, como mostra a seção do Capítulo 2 sobre amostragem de consistência. O que vale a pena mudar é o contexto: um motivo de recusa do vocabulário fechado, acrescentado como observação, diz à próxima proposta o que evitar (“o valor do reembolso não é válido para este pedido”) sem lhe entregar o número que passaria. E perguntar de novo precisa ser contabilizado, já que cada rodada de correção é uma chamada ao modelo, um passo e algum gasto.

Rodadas de correção contabilizadas

O loop do Capítulo 5 já devolve uma recusa como observação. O que falta é um limite específico para a recusa: “15 passos com a mesma recusa” é uma forma cara de o limite de passos descobrir o problema.

```
function onRefusal(run, verdict):
    key = refusalKey(verdict)                // reason code and
    field names, never values
    run.refusals[key] = countOf(run.refusals, key) + 1
    if not isCorrectable(verdict.reason):    // not_permitted is
    never fixed by asking again
        return handOff(run, "refused: " + verdict.reason)
    if run.refusals[key] > policy.maxCorrections: // say, two
    correction rounds per reason
        record(run, "correction_exhausted", key)
        return handOff(run, "proposal kept failing: " + key)
    return addObservation(run, verdict)      // the context now
    differs by the refusal reason
```

A chave agrupa as recusas pelo que deu errado, de modo que dois problemas não compartilham um limite e o mesmo problema não escapa dele. Quais motivos são corrigíveis é uma questão de política:

`invalid_arguments` em geral é, já que o modelo pode corrigir um campo ausente, enquanto `not_permitted` não é, porque a permissão não muda com outra tentativa. O Capítulo 12 trata da detecção mais ampla de um run que não progride; o contador de correções é uma instância restrita disso. Começaria com uma ou duas rodadas de correção, já que mais do que isso raramente resgata uma proposta que falhou duas vezes.

Reparar um rascunho sem fundamento

F3 (afirmação sem fundamento) é um problema de reparo diferente. Suponha que um verificador encontre, em um rascunho de resposta, uma frase que nenhum resultado de ferramenta sustenta: uma data de entrega

que não aparece em nenhum resultado de `lookup_order`. Pedir ao modelo que reescreva o rascunho é uma nova amostra, que pode introduzir novas frases sem sustentação ao remover a antiga. Minha preferência, quando a resposta é montada a partir de partes, é uma edição determinística: remover a frase sem sustentação ou recorrer a um modelo de resposta preenchido apenas com resultados de ferramentas. O resultado é menos fluente e verificavelmente fundamentado, que é a troca que importa para uma mensagem a um cliente. O Capítulo 2 constrói a verificação em si; o caminho de reparo para uma afirmação sem fundamento deve ser código, com uma segunda chamada ao modelo como último recurso.


A escada de fallback

Quando os retries se esgotam ou um breaker está aberto, o run precisa de outro caminho. Um fallback é um modo diferente de chegar a um resultado útil, e os caminhos formam uma escada, ordenada por quanto do comportamento primário cada um preserva e quanta confiança cada um exige do sistema.

De-grau	Caminho	Preserva	Abre mão de	Condição de entrada
1	Retry do mesmo caminho	Tudo	Tempo	Falha transitória, retries restantes
2	Modelo ou provedor alternativo	Ferramentas, planos, redação de rascunhos	Comportamento conhecido; os controles ajustados para o primário	Caminho do modelo primário indisponível; alternativo avaliado e permitido
3	Caminho determinístico	Correção em casos conhecidos	Cobertura; flexibilidade	O tipo de ticket tem um caminho codificado
4	Resposta em cache ou a partir de um modelo de resposta	Uma resposta fundamentada e segura	Especificidade	Existe um modelo de resposta revisado ou um resultado em cache recente o bastante
5	Modo somente leitura	Consultas, resumos, rascunhos para uma pessoa	Todos os efeitos	Os efeitos estão indisponíveis ou não são confiáveis
6	Hand-off para uma pessoa	O julgamento da pessoa	Automação	Nada acima se aplica

A ordem é o design. Um degrau só é acessado quando o de cima falhou ou não é permitido, e o orquestrador decide a partir de sinais que consegue ver: classes de erro, estado do breaker, estado do orçamento e o status de avaliação do alternativo. Não se pergunta ao modelo qual degrau tomar. Um prompt que diga “você está em modo degradado, tenha cuidado” só reduz a taxa de propostas descuidadas; o controle é que o gate tem regras diferentes naquele degrau.

Abaixo do degrau de retry, a escada só desce, e todo degrau termina em uma pessoa. Um degrau que pudesse voltar a subir, por exemplo um que tentasse o primário de novo depois de uma resposta a partir de um modelo de resposta, precisaria de um contador próprio, e deixaria isso para o próximo run. Um retry que falha de novo volta à primeira pergunta, com um contador.



Degrau 2: outro modelo ou provedor

A maioria das equipes recorre primeiro a este degrau, e o abordaria com o maior cuidado. Um segundo modelo é um componente diferente, de modo que todo controle ajustado contra o primário (cobertura do verificador, limites de escalonamento, taxas esperadas de recusa) foi ajustado contra

outra coisa. O Capítulo 2 diz isso diretamente: um modelo de fallback entra em ação durante um incidente, quando a atenção está no ponto mais baixo, e é o modelo que você menos testou.

Disso decorrem três condições. Primeira, o alternativo tem um status de avaliação: passou no golden set (Capítulo 21) em limiares registrados por escrito que podem ser inferiores aos do primário, e sem isso não está na escada. Segunda, o gate não muda: as propostas dele são tão pouco confiáveis quanto as do primário. Terceira, e isto é uma posição e não uma regra, apertaria o gate enquanto o alternativo estiver em uso: toda escrita irreversível vai para aprovação, independentemente do teto, até que o histórico de evals dele sustente mais. O custo é real, já que Sam, o líder de suporte da história da Parcelport, vê mais solicitações justamente quando a plataforma está sob estresse. Mesmo assim, preferiria isso a um caminho de reembolso cujas propostas ninguém mediu agindo por conta própria.

Uma API comum na frente de vários provedores torna a troca barata de expressar e não diz nada sobre quando ela é segura, então o orquestrador mantém a política que nomeia o alternativo, seu status de eval e o aperto do gate.

Degrau 3: o caminho determinístico

Alguns tickets não precisam de modelo algum. “Onde está meu pedido” é uma chamada a `lookup_order` e um status formatado. Um caminho codificado os responde sem chamada ao modelo, de modo que continua funcionando quando o caminho do modelo está fora, ao preço de uma formatação de status duplicada que precisa se manter em acordo. Construiria esse caminho apenas para os poucos tipos de ticket que respondem pela maior parte do volume; além disso, é um segundo agente escrito em código, um projeto e não um fallback.

Degrau 4: respostas em cache ou a partir de modelos de resposta

Uma resposta a partir de um modelo de resposta é um texto fixo com campos preenchidos a partir de resultados de ferramentas: uma confirmação de recebimento, o status atual da entrega, a referência do ticket. Ela não pode conter uma afirmação sem fundamento, porque as afirmações estão no texto do modelo de resposta, revisado uma vez, e os campos vêm de

ferramentas. Um resultado em cache é a mesma ideia para dados de leitura, desde que a resposta diga quando foram lidos. A obsolescência é o risco (F5.2, contexto obsoleto, no Capítulo 3): dê a cada item em cache uma idade máxima na política e nunca use um valor em cache como base de uma escrita.

Degrau 5: modo somente leitura

No modo somente leitura, o agente mantém suas ferramentas de leitura e perde todo o resto: nada de `update_shipping_address`, nada de `issue_refund`, nada de `send_customer_reply`. O run ainda pode consultar o pedido, resumir o ticket e preparar um rascunho para uma pessoa enviar; o agente de operações pode continuar lendo logs e métricas e entregar um resumo a Robin. O modo é registrado no run store, para que uma retomada não o esqueça, e é imposto pelo gate: enquanto estiver em somente leitura, o gate recusa toda chamada cuja classe de efeito não seja leitura. Um prompt que diz “não execute ações” é um pedido.

Degrau 6: hand-off

O hand-off sempre funciona, porque uma pessoa é a única dependência que o caminho do modelo não compartilha. Uma escada que chega a ele com frequência está lhe dizendo algo sobre os degraus acima. O hand-off leva um resumo e o estado registrado do run, para que a pessoa não comece do zero (o Capítulo 10 trata do status `handed_off`).

A escada em código

A seleção e a mudança de estado que vem depois:

```

function selectRung(run, signals):
    if signals.retriesLeft and not signals.breakerOpen:
        return "retry"
    if signals.modelPathFailed and policy.alternateModel.evalPassed and not
signals.alternateFailed:
        return "alternate_model"                // evalPassed is
data from the eval suite, not a flag in a prompt;
                                                //
modelPathFailed: a tool failure is not fixed by another model
    if hasCodedPath(run.ticketType):
        return "deterministic"
    if hasTemplate(run.ticketType) or hasFreshCache(run):
        return "template"
    if signals.readsAvailable:
        return "read_only"
    return "hand_off"                            // entered through
handOff, not enterRung (see below)

function enterRung(run, rung, reason):
    run.mode = rung                                // run store
first: a resume keeps the mode
    record(run, "mode_change", { rung: rung, reason: reason })
    gate.setMode(run, rung)                        // the gate's
rules for this rung apply from the next step

```

A ordem das escritas em `enterRung` é deliberada: o run store guarda o modo primeiro, de modo que uma queda deixa um run que retoma no de-grau inferior e não um que volta discretamente ao primário. Nenhuma transação cobre o registro e o gate; se o processo morrer antes de `gate.setMode`, a retomada lê o modo do run store e o chama de novo, o que é idempotente por design. Um run cujo store diz `read_only` e cujo gate diz outra coisa é a lacuna sobre a qual alertar.

Dizer a verdade ao usuário

Um fallback que funciona é uma mudança no que o cliente recebe: uma resposta a partir de um modelo de resposta é menos específica do que uma redigida, e um run em somente leitura não emite o reembolso pedido. Se o cliente não é informado, ele tira as próprias conclusões: uma resposta atrasada é tomada como ignorada, um reembolso ausente é tomado como recusado.

Escreveria a mensagem de modo degradado como um texto fixo, redigido de antemão e não pelo modelo. Uma mensagem gerada no momento da falha, pelo componente que está falhando, é a que tem mais chance de

prometer algo que ninguém pode cumprir, e uma promessa assim é um F3 esperando para acontecer. E um texto fixo pode ser revisado uma vez pelo líder de suporte, um caso fácil para o design de aprovação do Capítulo 15.

```
notice degraded_handoff // illustrative; fixed text, reviewed in advance;
slots filled from the ticket record
"We have your request about order {order_ref}. Our automated assistant is
limited
  right now, so a member of our support team will review it. Your reference
is
  {ticket_ref}. You do not need to send your request again."
```

O texto diz o que é verdade, dá ao cliente uma referência e pede que ele não reenvie, o que evita os duplicados que o pânico gera. Não cita horário, porque nenhum foi assumido, e não pede desculpas de um modo que sugira uma causa. “A member of our support team will review it” só é verdade se o hand-off existir, o que é uma questão de ordem.

O hand-off é uma escrita seguida de efeitos aplicados fora do run. O run não escalona nem notifica. Ele se encerra com um registro que diz o que precisa acontecer e deixa a execução a cargo de um worker.

```
function handOff(run, reason, detail: none): // called in
Chapters 1, 4, 10, 12, 14, 15 and 18
  if run.status == "handed_off":
    return handoffOf(run) // the closing
event's cause; a repeat call changes nothing
  id = newHandoffId() // runtime-
assigned
  rec = { id: id, reason: reason, detail: detail, // the cause the
run closes with
    kind: run.kind, // Chapter 10's
run kind; it decides the effects
    subject: run.subject.key, // the ticket or
alert, for the keys below
    summary: summary(run),
    open_intent_ids: openIntents(run).ids, // includes the
reply intent of Chapter 15, if one is open
    escalation_intent_id: newIntentId(),
    notice_intent_id: "notice:" + id }
  try:
    transition(run, "handed_off", rec) // Chapter 10's
one conditional write
    on StaleRun:
      run = reload(run.id) // another writer
moved the run
      if run.status == "handed_off": return handoffOf(run)
      raise
  return rec
```

Não há uma segunda escrita. A escrita condicional única do Capítulo 10 armazena o registro como o evento de encerramento e libera o bloqueio sobre o subject. A transição é permitida com intenções abertas, que o caminho de resposta do Capítulo 15 cria, e `open_intent_ids` aponta a pessoa para elas. `run.mode` não é alterado: o evento de encerramento diz que o run terminou no degrau `hand_off`, e as medidas ao final do capítulo leem o degrau a partir dele.

O worker é um sweep sobre os runs `handed_off` cuja linha de entrega ainda está aberta. A linha é uma entrada de outbox, única por id de hand-off, porque o run encerrado não pode guardar o progresso do worker.

O kind do registro escolhe os efeitos. Um hand-off do ops-agent envia um page para o engenheiro de on-call e não envia aviso, porque um run de alerta não tem ticket nem cliente. Um hand-off do support-agent escalona para o sistema de tickets com a chave `hash(subject, escalation_intent_id)` e só então envia o aviso ao cliente com `reply_intent_id` definido como `notice:<handoff_id>`, sob a chave do contrato do Capítulo 15. A pessoa é designada primeiro e o cliente é informado depois, de modo que um aviso que falha deixa o cliente atrasado, mas não enganado.

Três propriedades tornam isso fácil de verificar. O run termina antes de qualquer envio, e o worker nunca toca o run encerrado nem executa um passo do modelo. Toda chave vem do registro, de modo que os retries as reutilizam e o cliente não recebe e-mail duas vezes. E um envio incerto nunca é respondido com um segundo envio: o worker consulta antes `sendStatus` (Capítulo 15). A linha de entrega tem seu próprio limite de tentativas, uma configuração do outbox e não um dos contadores de run do Capítulo 13; ao atingir o limite, o worker envia um page para uma pessoa por um canal independente do sistema de tickets e marca a linha como `stuck`, de modo que um sistema de tickets que nunca responde custa um número limitado de tentativas e um page.

Uma pessoa vê a causa com que o run foi encerrado, como `bound exceeded` ou `success_unmet`, com o estado da entrega ao lado. O handler de `BoundExceeded` no Capítulo 10 é, ele próprio, um hand-off que grava apenas o evento de encerramento, de modo que não pode entrar em loop nem deixar o run segurando o subject.

Para o on-call, a contrapartida do aviso ao cliente é uma linha de status simples no canal em que o agente de operações reporta: em que modo ele está, desde quando, quais ferramentas estão indisponíveis e o que ele já encontrou, gerada por código a partir do degrau que o run store registrou (o degrau atual para um run em execução, o do evento de encerramento para um que fez o hand-off).

Nota: Um banner dizendo “assistente automatizado limitado” que continua no ar depois que a dependência se recuperou ensina os clientes a ignorá-lo. Vincule a mensagem ao modo que o run store registra, para que ela apareça e desapareça com o modo.

Testar e observar os fallbacks

Um fallback roda raramente, e código que roda raramente apodrece: o pior dia é a hora errada para descobrir que a credencial do modelo alternativo expirou ou que um campo do modelo de resposta não é mais preenchido. Três tipos de teste cobrem isso.

- **Testes de troca.** Injete as falhas que a tabela lista: uma chamada ao modelo que dá timeout, um rate limit, um breaker aberto, uma escrita cujo resultado é desconhecido depois do efeito. Verifique qual degrau o run alcança, que as regras do gate mudaram com ele, que os retries pararam no limite e que a escrita de resultado desconhecido foi consultada e não repetida. Esses testes pertencem ao CI.
- **Testes de qualidade.** Passe o golden set (Capítulo 21) por cada degrau que produz respostas: o modelo alternativo, o caminho determinístico e os modelos de resposta. Os limiares podem diferir dos do primário, e precisam existir.
- **Simulações.** Em uma agenda, force um degrau em staging, ou em produção para uma pequena fatia do tráfego, e observe o que as pessoas veem.

A falha que os fallbacks acrescentam é o silêncio: um run atendido por uma resposta a partir de um modelo de resposta ainda termina em `done`, e a qualidade caiu atrás de uma taxa de conclusão normal. Por isso o degrau faz parte do registro: todo run carrega seu modo, todo evento

`mode_change` e todo registro de hand-off carrega seu motivo, e o degrau é um atributo de span (Capítulo 20). Quatro medidas valem a pena, todas divididas por degrau:

- a parcela de runs em cada degrau, por hora, de modo que uma escada que carregou tráfego por um dia fique visível;
- a razão de retries, retries por primeira tentativa, por dependência;
- o tempo em cada modo degradado, e se ele terminou por recuperação ou por hand-off;
- a qualidade do resultado por degrau, a partir dos evals de produção amostrados (Capítulo 21).

Alerte sobre duração e parcela, não sobre uma única transição; o que é uma razão de retries saudável, você mede no seu próprio sistema.

Trade-offs e custos

Cada degrau custa algo para ser mantido. Um modelo alternativo precisa de credenciais, evals e um responsável; um caminho determinístico duplica lógica; os modelos de resposta precisam de revisão. Para um agente pequeno, começaria com dois degraus, retries classificados e hand-off, e acrescentaria os outros quando o volume ou o custo de um hand-off os justificasse.

Os retries acrescentam latência para a pessoa que espera. Defina o limite de tentativas e o deadline conforme a interação, mais curtos para chat do que para uma investigação durante a noite.

Apertar o gate no fallback transfere trabalho para pessoas. A aprovação de escritas irreversíveis no modelo alternativo protege o caminho do dinheiro e sobrecarrega o líder de suporte em um período de estresse. Se a fila não consegue absorver isso, o design precisa de um teto e de uma decisão sobre o que acontece além dele; a resposta honesta pode ser que esses tickets esperem.

A classificação pode estar errada. Um erro classificado indevidamente como retryable desperdiça orçamento; um classificado indevidamente como permanente faz o hand-off de um trabalho que um retry teria resolvido. A razão de retries e a taxa de hand-off por código de erro os revelam.

A idempotência não cobre tudo. As chaves evitam a duplicação de escritas repetidas; não desfazem um efeito mal colocado nem cobrem uma ferramenta que as ignora, e a escada supõe que os contratos do Capítulo 6 se mantêm.

Quando não construir a escada. Se um agente só faz leituras, com uma pessoa consumindo o resultado, retries com limite e uma mensagem de falha clara bastam. Se as falhas são raras e o hand-off é barato, seis degraus são mais maquinário do que o problema merece. E um fallback para o qual você não consegue dar conta de simulações é um degrau que provavelmente não funciona, e a política não deve listá-lo.

Erros comuns

- **Fazer retry em todas as camadas.** A biblioteca de cada camada faz retry por padrão, e cada limite parece razoável isoladamente. Correção: só o orquestrador faz retry; as outras camadas são configuradas com zero.
- **Fazer retry de uma escrita após um timeout, ou cunhar uma chave nova a cada tentativa.** Um timeout parece uma falha, e “única por chamada” soa como o propósito de uma chave. Correção: consulte primeiro o responsável pelo estado e reutilize a chave atribuída pelo runtime.
- **Fazer retry fora do orçamento.** O loop próprio de um helper é o lugar mais fácil para pôr um retry. Correção: cobre cada retry dos orçamentos do run e guarde o contador no run store.
- **Perguntar ao modelo de novo até que ele concorde.** O loop é fácil de escrever e às vezes funciona. Correção: mude o contexto, conte as rodadas de correção por motivo e faça o hand-off no limite.
- **Um modelo de fallback que ninguém avaliou, ou um fallback silencioso.** O alternativo está na escada porque o gateway o ofereceu, e os dashboards parecem normais depois da recuperação. Correção: um status de eval na política e o degrau registrado em cada run, trace e métrica.
- **Uma mensagem de modo degradado escrita pelo modelo.** É a forma mais rápida de obter um pedido de desculpas fluente. Correção: um texto fixo e revisado, enviado depois que o hand-off existe.

Pontos-chave

- Classifique uma falha antes de repetir qualquer coisa: rejeição transitória, timeout, resultado desconhecido de uma escrita, proposta recusada e erro permanente recebem, cada um, uma resposta diferente, decidida pelo orquestrador a partir da forma do erro e da classe de efeito.
- Uma escrita que dá timeout tem resultado desconhecido e não sofre retry até que o responsável pelo estado diga o que aconteceu; os retries reutilizam a chave de idempotência atribuída pelo runtime, e a chave é a rede de proteção e não o plano.
- Exatamente uma camada faz retry, os retries usam backoff com jitter, um limite de tentativas e o deadline do run, e cada retry é cobrado do orçamento e contado no run store para que uma retomada não o zere.
- Perguntar de novo ao modelo é uma nova amostra e não um reparo: mude o contexto com o motivo da recusa, conte as rodadas de correção por motivo, pare em um limite pequeno e prefira uma edição determinística a um segundo rascunho para uma afirmação sem fundamento.
- Uma escada de fallback é ordenada por quanto do comportamento primário cada degrau preserva; o orquestrador escolhe o degrau a partir de sinais, o gate impõe as regras do degrau, e um modelo alternativo só entra com um status de eval registrado e um gate inalterado, ou mais apertado.
- Um fallback é código que roda nos piores dias, por isso é testado com falhas injetadas, avaliado quanto à qualidade, ensaiado em simulações e registrado em cada run, porque um fallback silencioso esconde a qualidade que ele custa.
- O modo degradado é comunicado ao cliente em uma mensagem fixa e revisada, enviada depois que o hand-off existe e que diz apenas o que é verdade.

O próximo capítulo trata do último degrau da escada e do caminho que leva até ele. Entregar uma decisão a uma pessoa é simples de dizer e fácil de errar, e o Capítulo 15 cobre quando a aprovação é exigida, o que o aprovador vê e como uma aprovação permanece vinculada à ação exata para a qual foi dada.

Capítulo 15 — Aprovação humana

Imagine Sam, o líder de suporte da Parcelport, abrindo a fila de aprovações em uma manhã de terça-feira. Suponha que o agente de suporte tenha registrado 60 requisições durante a noite (um número hipotético). Cada uma mostra um valor de reembolso, um id de pedido e um parágrafo, escrito pelo modelo, explicando por que o reembolso se justifica. Os parágrafos são fluentes e concordam entre si. Na quadragésima requisição, Sam já aprova com base no parágrafo, e o id do pedido virou uma sequência de caracteres para passar os olhos.

A requisição 41 diz que a encomenda chegou danificada. O ticket não menciona dano, e o `orders-service` diz que a encomenda ainda está em trânsito. Nenhum dos dois fatos está na tela. A aprovação leva quatro segundos.

Mais tarde, na mesma manhã, Sam aprova uma resposta a um cliente. Entre a aprovação e o envio, o rascunho do agente foi regenerado, e a nova redação promete uma data de entrega que nenhum resultado de ferramenta contém. A aprovação estava vinculada ao ticket, não ao texto, e por isso a resposta saiu em nome de Sam.

Ninguém nessa história foi descuidado. A fila foi construída para que uma decisão humana pudesse ser registrada, e ela registrou uma. O que não fez foi dar significado à decisão. Este capítulo pertence à parte **Gate** do envelope de controle: aquela que responde se esta proposta pode produzir efeito, para este principal, agora. Quando a resposta é “uma pessoa decide”, a pergunta deste capítulo é o que precisa ser verdade sobre essa decisão para que ela conte como um controle e não como uma assinatura.

O problema e por que ele é difícil

O gate tem três veredictos, e o terceiro, `needs approval`, é o único em que a resposta vem de fora do código. Isso o torna o elo mais fraco por padrão. Uma pessoa é mais lenta do que uma verificação, varia de uma hora para

a outra e vê o que o sistema escolheu mostrar. O caminho de aprovação é onde várias classes de falha podem passar por um gate que parecia fechado: F2 (ferramenta incorreta ou argumentos incorretos) quando o aprovador não vê os argumentos, F3 (afirmação sem fundamento) quando o aprovador vê a afirmação mas não a fonte, F5.2 (contexto obsoleto) quando uma decisão sobrevive aos fatos em que foi tomada, e F7 (efeito não autorizado) quando o que é aplicado não é o que foi aprovado.

O design óbvio é uma etapa de confirmação: mostrar a ação proposta e um botão, registrar quem o apertou. Ele falha de quatro maneiras, e cada uma é estrutural.

Primeiro, mostra uma descrição da ação, em geral escrita pelo modelo, e não a ação. Uma frase e uma chamada podem se afastar uma da outra, e o aprovador não percebe. Segundo, a aprovação é um fato sobre um ticket ou um run (“Sam aprovou este”) e não sobre uma chamada exata, de modo que tudo o que o orquestrador aplicar em seguida a herda. Terceiro, a decisão não tem relógio: uma aprovação dada às 09:14 ainda é válida às 11:20, quando o pedido está em outro estado. Quarto, aprovar é um ato humano, e atos humanos se degradam com o volume. Uma pessoa que aprova 60 requisições quase idênticas antes do almoço não está exercendo julgamento na sexagésima.

Uma instrução como “peça aprovação antes de ações arriscadas” é um pedido, como o Capítulo 7 afirmou. O controle é a política que devolve needs approval, a ferramenta que se recusa a agir sem uma aprovação válida e o registro do que foi aprovado.

Quando a aprovação é exigida

Se uma chamada precisa de aprovação é decidido por política no gate, nunca pelo modelo e nunca apenas pela classe de efeito. O Capítulo 7 apresentou a distinção entre “além da autoridade, mas uma pessoa poderia concedê-la” e “além da autoridade, e nenhuma pessoa pode”. A aprovação é o primeiro tipo. Esta seção trata dos gatilhos.

Gatilho	Exemplo na Parcelport	Quem calcula
Valor	Um reembolso acima de <code>refund_ceiling</code>	O gate, a partir da chamada e do contrato

Gatilho	Exemplo na Parcelport	Quem calcula
Classe de efeito e destino	Qualquer <code>request_rollback</code> ou <code>toggle_feature_flag</code> , seja qual for a evidência	A política, pelo nome da ferramenta
Sinal de incerteza	Um rascunho de resposta com um número que a verificação de afirmações não conseguiu classificar (Capítulo 2)	Uma verificação determinística, não o modelo
Situação nova ou incomum	Uma segunda solicitação de reembolso para o mesmo pedido, ou um cliente sem contato anterior	Fatos que o gate leu dos serviços
Política	Escritas em produção fora de uma janela de mudanças	Dados de política, versionados

Duas regras mantêm essa lista honesta. A primeira é que os sinais de incerteza vêm de verificações, não do relato que o modelo faz de si mesmo. Uma proposta que diz “não tenho certeza, por favor revise” é uma proposta, e um gate que roteia a partir dela deu ao modelo uma forma de escolher a própria supervisão, nos dois sentidos. O Capítulo 2 explica por que a confiança declarada de um modelo não é evidência; aqui basta dizer que o gatilho precisa ser algo que o código possa recalcular.

A segunda é que o gatilho pertence à chamada e não ao run. “Aprovar este run” é um veredicto sobre uma sequência cujos passos posteriores ainda não existem. A aprovação se vincula a uma chamada, avaliada quando essa chamada é proposta.

```
function requiresApproval(call, facts, policyVersion):
  policy = loadPolicy(policyVersion)
  if call.tool in policy.always_approve:           // for example
    request_rollback
    return { required: true, reason: "tool_policy" }
  if call.tool == "issue_refund" and call.amount_minor >
    policy.ceilingFor(call.currency):
    return { required: true, reason: "above_ceiling" }
  if call.tool == "issue_refund" and facts.prior_refunds_for_order > 0:
    // new or unusual: read by the gate, not stated by the model
    return { required: true, reason: "repeat_refund" }
  if call.tool == "send_customer_reply" and facts.claim_check ==
    "unclassified":
    return { required: true, reason: "unclassified_figure" }
  return { required: false }
```

O reason code viaja com o veredicto e é mostrado ao aprovador, porque “por que estão me perguntando” é a primeira dúvida de quem revisa. Ele também fornece a medição usada mais adiante neste capítulo: aprovações contadas por motivo.

Uma regra de ordenação do Capítulo 5 importa aqui mais do que em qualquer outro lugar. A aprovação vem depois de toda verificação que poderia recusar. Pedir a uma pessoa que aprove uma chamada que o gate teria recusado desperdiça o tempo dela e a ensina que a fila contém absurdos.

O que o aprovador vê

Uma requisição de aprovação é um documento que uma pessoa lê sob pressão de tempo. Projetaria a requisição de dentro para fora, a partir da decisão: o que uma pessoa razoável precisa saber para dizer sim ou não a esta chamada exata, e de onde vem cada informação. A regra a que submeteria o design é que todo campo na tela ou é calculado por código a partir da chamada e dos serviços, ou é rotulado como outra coisa.

A notação abaixo é ilustrativa. Ela lista o que o serviço de aprovação armazena e renderiza para um reembolso pendente.

```
approval_request
  request_id:      "apr-0031"                // opaque
  call:           { tool: "issue_refund", order_id: "ord-7f3k2m91",
                    amount_minor: 18000, currency: "EUR", reason_code:
"damaged" }
  call_hash:      callHash(call)            // rendered by code from the call, never from model text
  why_asked:      { reason: "above_ceiling", policy_version: "p-0007" }
  evidence:       // read by the gate from services, with read time
    - order status:      "delivered", read at 09:12
    - refundable balance: shown in order currency
    - earlier refunds:   none
    - ticket link:       opens the ticket in the ticket system
  risk:           "irreversible write: Parcelport cannot recall a refund"
  undo path:      "none held by Parcelport; a correction is a separate
decision"
  model_note:     "unverified summary written by the model" // last,
collapsed, labeled
  expires_at:     "<timestamp>"
  eligible_approvers: [ role: "support lead" ]
```

Observe o que está na lista e em que ordem. A chamada vem primeiro e é renderizada por código, de modo que o aprovador vê os argumentos que o efeito vai usar. Se a tela mostrasse uma frase como “reembolsar o cliente

por dano”, a frase e os argumentos poderiam divergir, e o aprovador teria aprovado a frase. A evidência vem em seguida, lida pelo gate a partir do `orders-service` e do `payments-service` e carimbada com a hora da leitura. O risco e o caminho de desfazer dizem o que custa responder sim e o que se pode fazer depois, em uma frase cada. Para uma escrita irreversível, o caminho honesto de desfazer é “nenhum”, e a tela deve dizer isso.

A nota do modelo vem por último, recolhida e rotulada. Este é o ponto que defenderia com mais força: a explicação do modelo é uma proposta, não evidência. Ela vem do mesmo contexto que a chamada, de modo que, se o contexto estava errado, a explicação está errada na mesma direção e se lê igualmente bem. Mostrada primeiro, produz a manhã de terça-feira da abertura; mostrada por último e rotulada, é um indicador do que verificar.

O que fica fora da tela também importa. O texto bruto de e-mail do cliente não é confiável e pode conter instruções dirigidas a quem o ler (o Capítulo 16 trata de como esse conteúdo é tratado), e carrega dados pessoalmente identificáveis (PII) de que o aprovador não precisa para decidir (Capítulo 17). Mostre os fatos de que a decisão precisa e inclua um link para o ticket para quem quiser mais. Não mostre tokens, credenciais nem identificadores internos que não explicam nada.

Vincular uma aprovação a uma proposta

O serviço de aprovação devolve uma **aprovação assinada** vinculada à chamada exata. O vínculo é o que transforma “Sam disse sim” em “Sam disse sim a isto”, e é simples de enunciar: a aprovação carrega um hash da chamada, e o gate recusa qualquer chamada cujo hash não corresponda.

```

function callHash(call):
    // everything that changes what the effect does is in the hash
    // effectPayload: the arguments for most tools; for send_customer_reply,
    the
    // rendered text and the recipient the gate read, not the model's draft
    return hash(call.tool, call.subject_ids,
        canonicalize(effectPayload(call)), call.idempotency_key)

function verifyApproval(call, approval, now):
    if not signatureValid(approval):          return "invalid"          // the
    signing key stays in the approval service
    if approval.status != "approved":         return "not_approved"
    if approval.expires_at <= now:             return "expired"
    if approval.call_hash != callHash(call):  return "mismatch"        // one
    changed value is a different call
    return "valid"

// gate: a call that needs approval and has no valid one is refused with
approval_required

```

Quatro propriedades saem desse bloco. **Exatidão:** o valor, a moeda, o pedido e a chave estão no hash, de modo que uma aprovação para 18000 não cobre 18001. **Sem transferência:** uma aprovação para uma chamada não pode ser usada para outra, de modo que o modelo não ganha nada propondo uma variação depois de um sim. **Expiração:** a aprovação tem um prazo depois do qual não é válida, e o que acontece então é uma transição e não um retry silencioso (o relógio é do Capítulo 10, o significado é deste capítulo). **Identidade:** a assinatura cobre quem decidiu e quando, que é o “registrada com quem decidiu” na definição de aprovação.

O uso único é imposto pela chave de idempotência, e não por um flag que muda no consumo, o que exigiria uma transação entre o serviço de aprovação e o sistema de destino. A chave está no hash, de modo que uma segunda aplicação da mesma chamada aprovada devolve o primeiro resultado (`duplicate_replayed`). O gate verifica a aprovação, e a ferramenta ou o serviço que a possui a verifica de novo e devolve `approval_required` se a chamada chegar sem uma (o Capítulo 7 traça a mesma linha entre decisão e imposição).

Aviso: Uma aprovação que existe apenas na memória do orquestrador, ou apenas em uma interface de usuário, não é um controle. Se o serviço que movimenta o dinheiro ou envia o e-mail não verifica se há uma aprovação válida vinculada à chamada, um bug em qualquer ponto a montante transforma a etapa humana em decoração.

Mudanças de parâmetros invalidam a aprovação

Sam pode querer alterar o valor, e não há nada de errado nisso. A regra é que uma edição na interface de aprovação não é aplicada à chamada existente. Ela cria uma nova chamada, que volta pelo gate, recebe um novo hash e, se a política ainda o exigir, uma nova requisição de aprovação. O mesmo vale para o modelo: se ele propuser o reembolso de novo com um valor diferente depois de um sim, o hash difere, a aprovação anterior não se aplica, e as regras de chave do Capítulo 6 decidem se a nova chamada chega a ser uma nova intenção.

Não deixaria o modelo perguntar de novo até obter um sim. Uma chamada recusada é registrada com seu hash, e uma proposta que corresponda a um hash recusado é recusada sem uma nova requisição. Uma proposta que difere apenas ligeiramente é contada pelo limite (Capítulo 13), e um run que continua pedindo variações de uma ação recusada é um run para um hand-off. Sem isso, a pessoa que recusa se torna o ponto fraco de um loop que tenta de novo até que ela deixe de verificar.

O contrato de `send_customer_reply`

`send_customer_reply` é um efeito colateral externo, e o livro até aqui o nomeou sem escrever seu contrato. O Capítulo 6 o lista entre as classes de efeito e diz que seu peso recai sobre o que acontece antes do envio. O Capítulo 3 aponta para este capítulo quanto ao gate humano na frente dele. Aqui está o contrato na notação do Capítulo 6. A verificação de afirmações do Capítulo 2 e as regras de idempotência do Capítulo 6 são referenciadas, não repetidas.

```

tool send_customer_reply
  description: "Send one reply to the requester of one ticket, through the
ticket system."
  input schema:                                // fields the model supplies
    type: object, additionalProperties: false
    required: [text]
    properties:
      text: { type: string, minLength: 1, maxLength: 4000 } //
illustrative limit
  // not in the schema: ticket id, recipient, attachments, subject line;
  // the runtime fills them, since a model-chosen recipient is an
exfiltration path
  effect class: external side effect
  // nothing Parcelport holds can recall a sent email
  preconditions:                                // checked by the gate, not the model
    - ticket is open and is the ticket of this run
    - recipient is the requester recorded on the ticket by the ticket
system,
  read by the gate, never taken from the text
    - claim check passes: every claim in the text ties to a tool result
      of this run (Chapter 2); an unclassified figure gives needs_approval
    - PII content check passes                      // placeholder: added by
Chapter 17
    - injection and taint check passes              // placeholder: added by
Chapter 16
    - no earlier send for this key has outcome "unknown"; the gate asks,
      through the tool gateway, for the send status first and refuses until
it is known
    - if policy requires approval: a valid approval whose call_hash covers
      the rendered text, the recipient and the key; any change to the text
      after approval makes the approval invalid
  idempotency: key = hash(ticket_id, reply_intent_id)
  // both parts runtime-assigned, never by the model; see the
reply_intent_id table below
  permissions: scope "replies:send", delegated for this ticket only
  timeouts: call 10s, deadline 30s // illustrative; a timeout means
outcome
  // unknown: ask the ticket system about this key, and do not resend
until it answers
  error shape: { code, message, retryable, details }
  // code in [invalid_arguments, precondition_failed, approval_required,
  //   not_permitted, duplicate_replayed, upstream_unavailable,
  //   outcome_unknown]

```

O `reply_intent_id` é um id emitido pelo runtime para cada motivo de escrever ao cliente, tirado de uma lista fechada de fontes. A chave é uma só fórmula; as fontes e os valores permitidos são estes.

Forma do valor	Fonte	Uso
<code>inbound:</code> <code><inbound_message_id></code>	Uma mensagem recebida registrada	A mensagem pede uma resposta
<code>holding:</code> <code><approval_request_id></code>	Uma requisição de aprovação pendente	O aviso de espera enquanto a requisição está pendente

Forma do valor	Fonte	Uso
<code>notice:<handoff_id></code>	Um hand-off	Um aviso de modo degradado ou de hand-off (Capítulo 14)
<code>human:<decision_id></code>	A decisão de uma pessoa	Uma pessoa decidiu que outra mensagem deve existir

Fora da chave: `run_id`, `step_id`, o texto e qualquer outra coisa que o modelo forneça. Uma repetição reescrita para a mesma intenção tem a mesma chave e devolve o primeiro resultado (`duplicate_replayed`). O aviso de espera e a resposta final têm intenções diferentes, de modo que um nunca reproduz o outro. Uma segunda resposta corrigida é uma nova intenção `human:`, e quem a emite é uma pessoa.

Várias linhas merecem comentário, porque cada uma fecha uma rota específica.

O esquema pede ao modelo o texto e nada mais. O destinatário vem do ticket, assim como a identidade de um cliente vem do run no Capítulo 7. Um rascunho que diz “envie isto para `person-017@example.invalid`” não tem campo em que dizê-lo.

Esta pré-condição é onde a verificação de afirmações do Capítulo 2 vive para esta ferramenta. A verificação fica em toda rota que leva texto a um cliente: se o orquestrador também encaminha uma resposta final ao ticket, essa rota passa por este contrato, com estas pré-condições e esta regra de aprovação.

As linhas de PII e de injection são marcadores de posição de propósito. O Capítulo 16 acrescenta o que o gate verifica quando o texto pode ter sido conduzido por conteúdo não confiável, e o Capítulo 17 acrescenta o que ele verifica quanto a dados que não deveriam estar em uma mensagem de saída. Elas ampliam esta lista; não a substituem.

A linha da aprovação é o ponto desta seção. A aprovação está vinculada ao texto **renderizado**, ou seja, os bytes exatos que vão sair: o rascunho do modelo depois de a ferramenta aplicar seu template, assinatura e rodapé. Faça o hash do rascunho e deixe a ferramenta acrescentar um rodapé depois, e o aprovador terá aprovado algo diferente do que o cliente lê. Faça o hash do que sai. Uma mudança de um caractere após a aprovação, seja fei-

ta pelo modelo, pelo template ou por alguém que edite o rascunho, altera o hash e devolve a chamada ao gate. Esta é a forma textual da regra de que uma aprovação pertence a uma única proposta.

A chave tem a mesma forma que no Capítulo 6, e o raciocínio se mantém: um modelo que propõe uma resposta reescrita em um passo posterior não ganha um segundo e-mail, ganha o primeiro resultado. O custo é real. Se a primeira resposta estava errada, uma correção não acontece porque o modelo a propôs; acontece porque uma pessoa decidiu que uma segunda mensagem deve existir, e o serviço de aprovação emite uma nova intenção human: . Pagaria esse custo. Um segundo e-mail a um cliente que acabou de receber um errado é uma decisão sobre a relação com o cliente, e pertence a alguém a quem se possa perguntar.

O que acontece quando o resultado é desconhecido

O sistema de tickets pode dar timeout depois de aceitar a resposta, ou depois de apenas parecer aceitá-la. O run então não sabe se o cliente tem a mensagem. Fazer retry é o movimento errado, porque um e-mail enviado não pode ser desfeito, e o mesmo vale para não enviar nada, porque o cliente aguarda uma resposta que existe. A resposta do contrato é a dos capítulos 5 e 6: registre o desconhecido, pergunte e não envie nada até saber.


```
function sendReply(run, call, approval):           // the orchestrator's
side; the service is reached only through the tool gateway
    key = hash(run.ticket_id, call.reply_intent_id) // runtime-assigned,
one intent per reason to write
    record(run, "intent", { tool: call.tool, key: key, text_hash:
hash(call.rendered_text) })
    try:
        result = effect.apply(run, call, idempotencyKey: key) // the tool
gateway calls the ticket system
        record(run, "effect", result)
        return result
    on Timeout:
        record(run, "effect", { status: "outcome_unknown", key: key })
        status = toolGateway.sendStatus(call.tool, key)           // a read
through the tool gateway; does not send
        if status == "sent":
            record(run, "effect", { status: "sent", key: key })
            return { status: "sent" }
        if status == "not_sent":                                   // only a
definite answer allows a retry
            return retryOnce(run, call, approval)                 // same key,
approval re-verified
        return handOff(run, "reply outcome unknown")              // a person
sees the text and the key
```

Leia os caminhos de falha. A função pertence ao orquestrador: registra a intenção, decide sobre o retry e faz o hand-off. O envio e a consulta de status chegam ao sistema de tickets pelo gateway de ferramentas, o primeiro como `effect.apply`. A intenção é registrada antes da chamada, de modo que uma queda depois do envio ainda deixa um rastro e o procedimento de retomada do Capítulo 10 encontra uma intenção aberta. A consulta de status é uma leitura e nunca envia. Um retry só ocorre diante de um “not sent” definitivo, com a mesma chave, e passa de novo pela verificação da aprovação, de modo que uma aprovação que expirou durante a espera interrompe o retry. Uma resposta pouco clara não é licença para tentar de novo. É um hand-off, com o run store guardando o texto e a chave, para Sam, que pode olhar o ticket e decidir.


As duas respostas erradas não são simétricas, e o design reflete isso. Uma resposta que não sai é visível: o cliente escreve de novo, e o ticket mostra uma intenção aberta. Uma resposta que sai duas vezes não é. Onde a escolha é entre um e-mail ausente e um duplicado, escolheria o que uma pessoa pode notar e corrigir.

O fluxo de aprovação

O diagrama mostra um reembolso acima do teto, da proposta ao efeito. Observe os três pontos em que o fluxo termina sem efeito: a recusa do gate, a rejeição e a expiração. Os três retornam ao contexto como observações ou a uma pessoa como um hand-off, e nenhum deixa o modelo prosseguir por conta própria.



Uma requisição de aprovação, por sua vez, passa por um pequeno número de estados, e tê-los escritos ajuda quando a pergunta na revisão do incidente é “o que o aprovador de fato decidiu, e o que aconteceu com isso”. Os estados são separados dos estados do run no Capítulo 10: um run fica `awaiting_approval` enquanto uma requisição está `pending`.



A aprovação e o run

O Capítulo 10 trata do que acontece com um run enquanto uma pessoa decide: o run fica `awaiting_approval` e não segura nenhum worker, o relógio da aprovação tem um destino, e um run retomado relê os fatos e devolve a chamada pendente ao gate. Este capítulo acrescenta três coisas sobre a decisão em si.

A primeira é que a decisão do aprovador é tomada com base em evidências lidas em um momento e aplicada em outro. A requisição carrega a hora de leitura de cada fato, e o gate lê de novo na retomada (o Capítulo 7 deu a razão). Se o saldo reembolsável mudou nesse intervalo, a chamada falha em uma pré-condição, a aprovação permanece no registro como uma decisão sobre uma chamada que já não é possível, e o modelo vê uma recusa. O custo é que Sam às vezes aprova algo que depois é recusado. Aceitaria isso; a alternativa é aplicar uma aprovação a um mundo para o qual ela não foi dada.

A segunda é a expiração. Escolha a expiração a partir da realidade do aprovador, não da conveniência do sistema. Uma fila de suporte coberta em horário comercial não pode prometer uma decisão às 2 da manhã, e uma aprovação cujo relógio se esgota no meio da noite faz o hand-off do run com a chamada anexada; ela não se prorroga. Se Sam ainda quiser o

reembolso de manhã, uma nova requisição é renderizada a partir dos fatos atuais. Prorrogar uma aprovação em silêncio é como uma decisão sobrevive aos fatos que descrevia.

A terceira é o que o cliente vê enquanto o run espera. Uma mensagem que diz “um colega está analisando sua solicitação” é, ela própria, um `send_customer_reply`, com contrato próprio e intenção própria (`holding:<approval_request_id>`), de modo que nunca possa consumir a chave da resposta que virá depois. Geraria a mensagem a partir de um modelo sem afirmações escritas pelo modelo. É também um lugar onde a honestidade é barata: diga que uma pessoa está olhando, não prometa um resultado.

Controle duplo e separação de funções

Para algumas chamadas, um aprovador não basta. O controle duplo, muitas vezes chamado de four-eyes, exige que duas pessoas diferentes aprovem a mesma chamada, e a separação de funções exige que quem se beneficia de uma ação ou a originou não seja quem a aprova. Ambos são política, e ambos são impostos pelo serviço de aprovação, não pela interface.

```
policy refund_dual_control           // illustrative notation
  applies to: issue_refund
  rule:      amount_minor <= ceiling_minor_for(currency)    -> no
approval
  amount_minor <= second_tier_minor_for(currency)    -> one
approval, role: support lead
  otherwise                                           -> two
approvals, roles: support lead, finance
  also:      approver must not be the principal who opened the ticket or
assigned it to the run
             both approvals must carry the same call_hash
```

O serviço de aprovação verifica os papéis e a distinção entre as identidades assinadas, e uma requisição não sai de `pending` até que existam o número exigido de aprovações válidas para o mesmo hash. Os aprovadores não veem a decisão um do outro antes de tomar a sua, quando a interface consegue arranjar isso, porque um segundo aprovador que vê um primeiro “sim” está mais perto de quem contra-assina do que de uma verificação independente.

O custo aparece na escala. Dois aprovadores significam duas filas, uma espera maior e um problema de cobertura: quem é a segunda pessoa em um fim de semana? Há também um efeito humano que nenhum design remove. Quando duas pessoas compartilham uma decisão, cada uma pode sentir que a outra é a verificação, e a qualidade de cada revisão pode cair. Uso o controle duplo para a faixa estreita de chamadas em que o custo de um erro é grande e irreversível, e não o uso como uma melhoria geral. Uma faixa que se aplica a todo reembolso acima do teto não divide nada pela metade e dobra a fila.

O mesmo padrão se aplica ao agente de operações de outra forma. Robin, o SRE de on-call, aprova `request_rollback`. Se o deploy que está sendo revertido foi iniciado por Robin, uma regra de separação pediria um segundo engenheiro, que às três da manhã pode não existir. Essa é uma escolha a fazer com antecedência, com o rodízio de on-call, escrita como política, e não no momento do incidente.

Aprovação por carimbo, fadiga e viés de automação

Três efeitos desgastam a etapa humana, e são propriedades da configuração, não das pessoas que estão nela. A **aprovação por carimbo** (rubber-stamping) é aprovar sem examinar. A **fadiga de aprovação** é a queda de atenção que vem do volume e da repetição. O **viés de automação** é a tendência a aceitar o que um sistema propõe porque o sistema o propôs, e é mais forte quando a proposta chega com uma explicação fluente, razão pela qual a nota do modelo fica por último na tela.

Não se vê nenhum deles de dentro de uma única decisão. Vê-se nos dados que o serviço de aprovação já guarda, e mediria pelo menos estes.

Medida	O que ela diz	Como é um valor ruim
Taxa de aprovação, por motivo	Se o gatilho encontra propostas que precisam de uma pessoa	Perto de 100 por cento para um motivo: o gatilho pode não estar capturando nada que uma pessoa altere
Tempo até a decisão, como distribuição	Se a evidência está sendo lida	Uma mediana de segundos em uma requisição com vários fatos a verificar
Taxa de rejeições e edições	Se as propostas do modelo são boas e se as pessoas divergem	Quase nenhuma rejeição por meses, ou um aprovador longe dos demais

Medida	O que ela diz	Como é um valor ruim
Idade da fila e taxa de expiração	Se a fila tem equipe para o seu volume	Expirações crescentes ou hand-offs por aprovações expiradas
Aprovado e depois recusado na retomada	Se as decisões são tomadas sobre evidências obsoletas	Uma taxa constante: o intervalo entre a decisão e o efeito é longo demais

Leia essas medidas como um sinal de design, não como uma avaliação de desempenho de uma pessoa. Um sim quase constante em segundos diz algo sobre o gatilho e a tela, e a leitura sem culpa é que o sistema ensinou ao aprovador que a resposta é sim. O passo seguinte é uma mudança de design.

Há três opções honestas quando um motivo mostra uma taxa de aprovação que nunca se move. Uma é tirar a pessoa do caminho: se uma pessoa não altera um resultado há muito tempo, a chamada talvez seja mais bem servida por uma regra determinística com um limite mais apertado (um teto mais baixo e um total diário, Capítulo 13) e amostragem posterior. Outra é mudar o que é mostrado, de modo que ler a evidência seja o caminho rápido. A terceira é manter a aprovação e dizer com clareza que ela existe para responsabilização e não para pegar erros, o que é uma razão legítima, desde que ninguém a conte como um controle de segurança em uma revisão.

Os limiares devem ser ajustados com dados e não com sensação. Antes de elevar `refund_ceiling` para reduzir a fila, levante a distribuição dos valores solicitados e os motivos de rejeição da faixa que você retiraria. Se nada nessa faixa é jamais rejeitado, elevar o teto provavelmente está certo, e o limite sobre o valor total reembolsado por run e por dia é o que cobre a exposição que a pessoa antes cobria. Se as rejeições na faixa são comuns e têm bons motivos, a fila está funcionando, e a correção do volume está a montante, em por que o modelo propõe tantas dessas chamadas (F2).

Parcelport: o reembolso acima do teto e um rollback

Tome uma solicitação de reembolso em `ord-7f3k2m91` para um cliente, `cus-0042`, cujo ticket relata dano. Suponha que `refund_ceiling` seja 100,00 na moeda do pedido e que o valor proposto seja 180,00 (valores

hipotéticos). O gate lê o pedido, vê que foi entregue e capturado, não encontra reembolso anterior e vê o valor acima do teto. Devolve needs approval com o motivo `above_ceiling`. O run passa a `awaiting_approval`.

A tela de Sam mostra a chamada renderizada por código, o status do pedido lido em um horário informado, o saldo reembolsável, a ausência de reembolsos anteriores, um link para o ticket e a linha dizendo que a Parcelport não tem como recuperar um reembolso. A nota do modelo está abaixo, recolhida. Sam lê o ticket, vê uma referência de foto na conversa e aprova. A aprovação assinada carrega o hash, o aprovador e uma expiração.

Na retomada, o gate relê o pedido e o saldo e verifica a aprovação contra a chamada que agora tem em mãos. Com `allow`, o orquestrador inicia `effect.apply`, e o gateway de ferramentas anexa a credencial por chamada e chama o `payments-service` com a chave do Capítulo 6. O resultado volta pelo gateway de ferramentas e é registrado. A resposta ao cliente é uma segunda chamada, com contrato próprio: o texto informa o valor do reembolso, que a verificação de afirmações vincula ao resultado, e a política não exige aprovação para uma resposta desse tipo, de modo que o veredicto é `allow`. Se o texto do modelo tivesse incluído um número que o extrator não conseguiu classificar, o veredicto seria `needs approval`, e uma nova requisição mostraria a Sam o texto renderizado, vinculado ao seu próprio hash.

Note o que as duas aprovações têm em comum e o que as separa. Ambas estão vinculadas a conteúdo exato, ambas expiram, ambas são verificadas pelo responsável pelo efeito. Diferem no que pode dar errado: um reembolso errado é dinheiro que não pode ser recuperado, uma resposta errada é uma mensagem que não pode ser retirada. E a lacuna entre as duas chamadas é onde vive F6 (falha parcial silenciosa). Um reembolso aplicado e uma resposta não enviada deixam um run que não pode chegar a `done`.

O agente de operações mostra a outra ponta do espectro.

	<code>issue_refund acima do teto</code>	<code>send_customer_reply, quando exigido</code>	<code>request_rollback</code>
Aprovador	Sam	Sam	Robin

	<code>issue_refund</code> acima do teto	<code>send_customer_reply</code> , quando exigido	<code>request_rollback</code>
Vinculada a	Pedido, valor, moeda, chave	Texto renderizado, destinatário, chave	Deploy, versão de destino, chave
Caminho de desfazer	Nenhum mantido pela Parcelport	Nenhum	Um deploy posterior restaura a versão anterior
Evidência calculada por código	Status do pedido, saldo, reembolsos anteriores	As afirmações e os resultados a que se vinculam	Versões, taxas de erro antes e depois, a partir dos stores
Por que aprovação	Valor acima do teto	A verificação de afirmações não conseguiu decidir	Política, seja qual for a evidência

Para um rollback, a política devolve `needs approval` em toda chamada, de modo que o trabalho de design interessante está na requisição. Robin pode estar lendo às três da manhã sem contexto, então ela precisa ser autossuficiente: a versão atual e a anterior, as taxas de erro que o orquestrador calculou a partir de `get_metrics` antes e depois do release, a janela de tempo e a declaração de que um deploy posterior pode desfazer o rollback. Os números são calculados por código, ao lado da explicação do modelo e não dentro dela (Capítulo 4). Uma escrita reversível custa menos para errar do que um reembolso, mas um rollback em um período movimentado não é gratuito, e a aprovação é como quem é responsável por esse custo consegue pagá-lo de forma deliberada.

Trade-offs e custos

A aprovação tem um preço em quatro moedas. Tempo: toda chamada sujeita a aprovação espera por uma pessoa, e a espera é de minutos na melhor das hipóteses e de horas na pior. Pessoas: alguém precisa estar lá, treinado para ler a tela, coberto quando estiver ausente e protegido de uma fila que nunca termina. Engenharia: o serviço de aprovação, a renderização da requisição, a assinatura e a verificação, e as checagens no gate e na ferramenta são componentes reais, com disponibilidade própria. Clientes: um cliente cujo reembolso espera por Sam tem uma tarde pior do que aquele cujo reembolso não precisou de Sam.

O serviço de aprovação se torna uma dependência do gate. Quando ele está fora, as chamadas que precisam de aprovação não conseguem obtê-la, e o único comportamento seguro é falhar fechado: o run espera ou faz o hand-off, e nada prossegue com base em uma aprovação que não pode ser verificada. Diga isso no design antes da primeira indisponibilidade, e diga o que o cliente é informado.

Uma aprovação é a declaração de que uma pessoa aceitou uma chamada exata, com base na evidência mostrada, em um dado momento. Não é a declaração de que o mundo está certo. Um aprovador pode errar, pode não ter o conhecimento para julgar ou pode ver um quadro incompleto porque o gate não leu o que importava. A aprovação reduz a chance de um erro virar um efeito; não garante que o efeito esteja correto, e descrevê-la como algo que torna um reembolso “seguro” seria exagero.

Pôr toda ferramenta atrás de aprovação parece cuidadoso e é teatro: a fila cresce, as respostas se tornam reflexas em um dia, e a única requisição que precisava de atenção se parece com as outras noventa e nove. Onde uma regra determinística pode decidir, ou o efeito é uma leitura ou uma escrita reversível barata, a amostragem posterior costuma bastar.

Erros comuns

- **Aprovar uma descrição.** É tentador porque uma frase se lê melhor do que argumentos. Renderize a chamada a partir de seus argumentos, em código, e mostre-a como aquilo que vai ser executado.
- **Tratar a explicação do modelo como evidência.** Ela é persuasiva e é o relato do próprio modelo. Calcule a evidência a partir dos serviços, mostre a nota por último e rotule-a como não verificada.
- **Uma aprovação vinculada ao ticket ou ao run.** É fácil de implementar e tudo o que o orquestrador fizer em seguida a herda. Vincule ao hash de uma chamada, incluindo a chave.
- **Uma aprovação sem expiração, ou com uma expiração que se prorroga.** A decisão sobrevive aos seus fatos. Dê a toda aprovação um relógio e um destino para quando ele se esgotar.
- **Medir aprovações pela velocidade.** Um tempo curto de fila parece um processo saudável. Meça a taxa por motivo, o tempo de decisão, as

rejeições e os casos aprovados e depois recusados, e leia-os como sinais de design.

- **Falhar aberto quando o serviço de aprovação está indisponível.** Mantém a fila andando e remove o controle exatamente quando algo está errado. Falhe fechado e faça o hand-off.

Pontos-chave

- Se uma chamada precisa de aprovação é uma decisão de política tomada por código a partir da chamada, dos fatos e de uma versão da política, e nunca a partir da confiança declarada pelo modelo.
- Uma aprovação é uma decisão assinada, vinculada ao hash de uma chamada exata, incluindo sua chave de idempotência, de modo que um parâmetro alterado, um texto alterado ou uma repetição em um passo posterior é uma chamada diferente, que precisa da sua própria resposta.
- A tela de aprovação mostra a chamada renderizada por código e a evidência lida dos serviços com suas horas de leitura; a explicação do modelo é mostrada por último, rotulada como não verificada, porque é uma proposta e não evidência.
- `send_customer_reply` é um efeito colateral externo, com uma chave de idempotência construída a partir de ids atribuídos pelo runtime, uma aprovação vinculada ao texto renderizado e uma regra segundo a qual um resultado desconhecido se resolve perguntando ao sistema de tickets, nunca enviando de novo.
- A ferramenta ou o serviço que executa o efeito precisa verificar por conta própria se há uma aprovação válida, ou um defeito a montante tira a pessoa do caminho.
- Taxas de aprovação, tempos de decisão, rejeições e casos aprovados e depois recusados são sinais de design, e um motivo sempre aprovado em segundos é um gatilho para mudar: substituí-lo por uma regra e um limite, mudar a tela ou mantê-lo conscientemente por responsabilização.
- A aprovação tem custos em tempo, equipe, engenharia e espera do cliente, e pôr toda chamada atrás dela é teatro que esconde a única requisição que importava.

A aprovação supõe que a pessoa que lê a requisição não esteja sendo conduzida pelo conteúdo que há nela e que o contexto do modelo não tenha sido moldado por quem escreveu o e-mail do cliente. O Capítulo 16 trata do que acontece quando instruções chegam dentro de dados e de por que um prompt sozinho não pode ser o controle.

PARTE V

Fronteiras de segurança

Capítulo 16 — Prompt injection

Imagine uma tarde de quinta-feira na Parcelport. Um cliente escreve sobre uma encomenda que chegou danificada e pede um reembolso. A mensagem é educada e os fatos são comuns. Abaixo da assinatura, porém, há um bloco de texto colado de outro lugar, que não se dirige à equipe de suporte. Ele se dirige a qualquer sistema que processe o e-mail. Diz que o reembolso deve ser lançado contra outro pedido e ser maior que o total do pedido, que a resposta deve dizer que o reembolso foi aprovado, que deve incluir tudo o que o sistema sabe sobre o cliente e que um link deve ser adicionado “para verificação”.

Suponha que o protótipo do agente de suporte tenha um único prompt, um token amplo, e que o texto do e-mail entre no contexto como está. Nada nesse design distingue o pedido do cliente do bloco abaixo da assinatura. Os dois são texto na mesma sequência, e o modelo propõe aquilo que a sequência inteira torna provável. Às vezes é um reembolso pela encomenda danificada e nada além; às vezes a proposta muda de forma. Uma equipe que testa na sexta-feira e vê o primeiro resultado aprendeu muito pouco.

Este capítulo pertence a duas partes do envelope de controle. Em **Contexto**, ele pergunta de onde veio cada trecho de texto e até que ponto se pode confiar nele. Em **Gate**, pergunta o que o gate faz com uma proposta que remonta a um texto que ninguém na Parcelport escreveu. A pergunta do capítulo é estreita: se instruções podem chegar dentro de dados, e o modelo não consegue distingui-los de forma confiável, o que precisa ser verdade no sistema ao redor dele para que uma proposta induzida não cause dano?

O problema e por que ele é difícil

Prompt injection é conteúdo que é dado sendo tratado como instrução. O Capítulo 3 dá nome à classe F4 (sequestro de instruções) e lhe atribui duas subclasses: F4.1, injection direta, em que a própria entrada do usuário tenta sobrepor as regras do agente, e F4.2, injection indireta, em que o conteúdo chega por um resultado de ferramenta, um documento ou um e-mail escrito por outra pessoa. Este capítulo trata das duas, com a maior parte do peso na indireta, porque é nela que o design não tem um usuário a quem perguntar.

Na Parcelport, instruções podem entrar por mais lugares do que a maioria dos primeiros designs lista.

Canal	Exemplo na Parcelport	Quem escreveu
E-mail do cliente	O corpo de um ticket que o agente de suporte lê	O solicitante, ou alguém cujo texto o solicitante colou
Texto encaminhado ou citado	Um aviso da transportadora encaminhado dentro de uma conversa	Um terceiro
Anexo	Um documento anexado a uma reclamação de dano	Um terceiro
Página web	Uma página obtida por uma ferramenta ilustrativa <code>fetch_page</code> , se ela existisse	Qualquer pessoa
Documento recuperado	Uma página retornada por <code>search_docs</code>	A equipe da Parcelport e qualquer pessoa que possa editar a página
Resultado de ferramenta	Uma nota de texto livre em um registro de pedido, uma observação da transportadora	Clientes e transportadoras, por meio de outro serviço
Linha de log	Um erro que repete um campo da requisição, lido pelo agente de operações	Quem enviou a requisição que foi registrada
Memória	Uma nota escrita por um run anterior (Capítulo 11)	Um run anterior, com base no que quer que ele tenha lido

Toda linha é texto produzido por uma pessoa ou um sistema fora do controle do run, e toda linha termina no mesmo lugar: o contexto montado para a próxima chamada ao modelo.

Por que o modelo não consegue separar os dois

O modelo recebe uma única sequência. O orquestrador pode marcar partes dela (“política do sistema”, “texto do ticket, não confiável”) e as saídas do modelo, na maioria das vezes, são condicionadas por essas marcas, mas as marcas são, elas mesmas, texto na sequência. Um cliente pode escrever um texto que se pareça com uma marca. Nada no funcionamento do modelo dá à política um canal privilegiado que o ticket não possa imitar. Não conheço uma técnica que torne essa separação confiável hoje, e não projetaria como se uma estivesse prestes a chegar. Se chegar, os controles abaixo continuarão valendo, e esse é o teste que um design deve atender: ele precisa continuar correto quando o modelo for substituído.

A SQL injection é resolvida por consultas parametrizadas porque o banco de dados tem dois canais, um para código e outro para dados. Um modelo tem um canal só, então a defesa sai do modelo: vai para o que acontece depois que ele propõe e para o que ele poderia alcançar.

Quais classes de falha ela produz

Uma proposta induzida aparece como F2 (ferramenta incorreta ou argumentos incorretos) quando um id de pedido ou um endereço veio do texto e não da tarefa; como F7 (efeito não autorizado) quando um token amplo que nunca deveria ter existido permite a chamada (Capítulo 7); como F3 (afirmação sem fundamento) em uma resposta que repete o que o texto injetado afirmava; e como F8 (comportamento não observado) quando o registro do run não diz qual texto a proposta seguiu, de modo que ninguém consegue encontrar os outros runs que leram a mesma mensagem.

A injection direta é o problema menor


Quando o cliente é o autor do texto, o cliente também é o principal em nome de quem o run age. Um cliente que pede mais que o total do pedido está pedindo algo que o teto, o saldo reembolsável e a autoridade delegada dos capítulos 6 e 7 vão decidir, seja qual for a formulação. A injection direta se reduz a “o principal pediu algo além da sua autoridade”, e o gate já recusa isso. O caso mais difícil é o do autor que não é o principal, cujo texto coloca a autoridade do agente a serviço dele.

O modelo de ameaças: três coisas que precisam se encontrar

Acho útil reduzir o assunto inteiro a três condições. Para que uma injection cause dano, as três precisam ser verdadeiras no mesmo run.

1. **Conteúdo não confiável.** Texto escrito por alguém que não seja o código ou a equipe da própria Parcelport está no contexto.
2. **Alcance.** O agente pode ler dados sensíveis ou causar um efeito que importa: dados do cliente, um reembolso, uma mudança de endereço.
3. **Um canal de saída.** Existe um meio de dados ou influência saírem do run: uma resposta a um cliente, um link nessa resposta, uma requisição de saída, o corpo de um pull request, uma escrita na memória.

Se uma delas estiver ausente, o que resta é limitado: um agente que lê texto hostil mas não tem alcance sensível nem canal de saída pode produzir uma resposta ruim e nada pior. Esse enquadramento é um auxílio de design e não um teorema. “Alcance” inclui autoridade para escrever, e um canal pode ser indireto (um reembolso é um sinal para uma pessoa que pode agir sobre ele). Mas ele mostra onde colocar o trabalho: você escolhe qual perna cortar para cada ferramenta, e faz isso em código.



As linhas pontilhadas marcam onde cada controle atua. Para cada ferramenta de um contrato, anote a quais das três ela contribui e, para cada caminho em que as três podem estar presentes, diga qual delas o design remove.

Para o agente de suporte, a condição um não pode ser removida, porque ler o e-mail dos clientes é o trabalho. O alcance é cortado por bloqueio: um run que leu conteúdo de terceiros não pode executar uma ação com consequências sem uma pessoa. Os canais são cortados tirando as escolhas do modelo: o destinatário, o host do link e os dados de contato em uma resposta não são coisas que ele possa nomear.

Um prompt não é um controle

A primeira coisa que a maioria das equipes escreve é uma frase no prompt do sistema dizendo ao modelo que ignore instruções encontradas em e-mails. Ela reduz a taxa em que propostas induzidas aparecem, e a manteria. Mas é também um pedido, e nenhuma propriedade se apoia nela: o componente cuja saída está em questão é quem a lê, seu efeito é estatístico e ela não tem sinal de falha, porque, quando perde, a proposta se parece com qualquer outra. Delimitadores e rótulos estão na mesma classe: um rótulo renderizado no contexto é um pedido ao modelo, enquanto o campo `trust` que acompanha o item em código é algo que o gate pode ler. O restante deste capítulo trata de usar esse campo.

Nota: Um prompt pode mudar a frequência com que o modelo propõe uma ação plantada. Só uma verificação em código muda se a ação pode ter efeito. Avaliar um prompt mede uma taxa; avaliar o gate testa uma propriedade. Informe as duas separadamente.

Proveniência e taint

O Capítulo 9 deu a todo item de contexto um campo `origin` e um campo `trust`, definidos pelo orquestrador. Este capítulo acrescenta o `taint`, uma marca de que um valor veio de uma fonte não confiável e não deve conduzir uma ação sensível sem uma verificação: a proveniência diz de onde um item veio, e o taint diz o que isso significa para as propostas que se seguem.

Duas classes de conteúdo não confiável

Se todo item não confiável fosse tratado da mesma forma, todo run seria bloqueado, porque todo run começa com um e-mail de cliente. A distinção útil é entre o conteúdo escrito pelo principal e o conteúdo escrito por qualquer outra pessoa.

```
record TaintMark                                // illustrative; extends ContextItem
in Chapter 9
  source_class: enum [third_party, principal, owned, system_record] //
  weakest first
    // third_party:   anyone else's text, or text of unknown author:
  forwarded or quoted
    //               segments, attachments, fetched pages, carrier remarks,
  log lines
    // principal:    the requester's own message, from the authenticated
  ticket channel,
    //               and free text the record shows the requester wrote
    // owned:         text Parcelport staff wrote and reviews: policies,
  runbooks
    // system_record: structured values a service validated: ids, amounts,
  status codes
    derived_from: list<item_id>                // a summary inherits the marks of
  its sources
    set_by: "orchestrator"                     // never by the model, never by the
  content
```

A marca se aplica a um campo, não a um item inteiro. Um resultado de `lookup_order` é um item com vários campos: `order_id`, `amount_minor` e `status` são `system_record`, uma nota que o cliente digitou no checkout é `principal`, uma observação da transportadora é `third_party`. Um resultado misto não tem um único nível de confiança. O rótulo de item do Capítulo 9 continua governando como o modelo vê o item; a marca o refina por campo para o gate.

A mensagem do próprio cliente não é confiável, mas é também o pedido que o run existe para atender: suas palavras são o principal falando, limitado pela autoridade delegada do principal e pelos tetos. O texto de terceiros não tem essa posição. Um aviso encaminhado, um anexo ou uma observação da transportadora não é o cliente pedindo algo, de modo que uma proposta que segue uma instrução contida neles tem outra pessoa usando a autoridade do cliente. É o confused deputy do Capítulo 7, com outra porta de entrada.

A distinção é imperfeita. O sistema de tickets pode segmentar uma mensagem em texto novo e partes citadas ou encaminhadas com análise determinística, e às vezes vai errar: um cliente pode colar o texto de um terceiro na própria mensagem e o parser o rotulará como principal. Por isso a classificação acrescenta uma camada heurística sobre as verificações dos capítulos 6 e 7 e não as substitui. O campo de remetente de um e-mail não é autenticação: a identidade vem do registro do sistema de tickets (Capítulo 7).

Propagação: a parte fácil de perder

Um taint que marca apenas o e-mail bruto não basta, porque o modelo re-escreve. Um resumo, uma nota, um rascunho de resposta que cita uma linha, uma entrada de memória: cada um é um item novo construído a partir de fontes contaminadas, e, se entrar no contexto sem marcas, o primeiro resumo terá lavado o taint. Por isso a derivação herda: tudo o que o orquestrador constrói a partir de itens contaminados carrega as marcas deles em `derived_from`, como o Capítulo 9 já exige para resumos e notas.

Quando a proposta é uma chamada de ferramenta, o orquestrador não pergunta ao modelo de onde vieram os argumentos, pois a resposta seria uma proposta como qualquer outra. Ele olha.

```
function argumentOrigins(run, call):
  origins = {}
  for each name, value in call.arguments:
    fields = sourcesOf(run, value)           // exact match in
code: whole structured field, or a ticket segment
    if fields is empty:
      origins[name] = "unsourced"           // not seen in
any field: produced by the model
    else:
      origins[name] = weakestTrust(fields)  // third_party <
principal < owned < system_record
  return origins
```

A regra do Capítulo 9, por campo: um valor assume a classe de todo campo ou segmento de ticket em que aparece, vale a classe mais baixa, e um token (um marcador aleatório que substitui um valor pessoal, que o Capítulo 17 apresenta) é lido por meio da sua entrada no vault (o armazenamento separado que mapeia tokens de volta para valores), cuja `source_class` guarda a classe mais baixa dos segmentos que ele substituiu. Um valor que está tanto em um item de terceiros quanto em um registro do sistema é, portanto, de terceiros. O contrário permitiria que uma

leitura permitida o lavasse: o texto injetado nomeia o id de pedido de outro cliente, o modelo o lê, e o registro retornado contém o mesmo id. A confiança geral de um resultado não tem papel nisso: um reembolso não se torna de terceiros porque o pedido também carrega uma observação da transportadora, já que `order_id` e `amount_minor` são registros do sistema. Um endereço que o solicitante digitou é principal, e o mesmo endereço dentro de um aviso encaminhado é de terceiros.

Os argumentos governados por um conjunto de escolhas são a exceção: pertencer ao conjunto que o orquestrador construiu é a prova de origem, então `checkTaint` não os rastreia. O custo da regra do elo mais fraco é uma falsa recusa de vez em quando, quando um argumento livre, como um endereço, também aparece em texto encaminhado, e a aceitaria.

Isso é imperfeito de propósito. O rastreamento por correspondência exata encontra um valor que foi copiado de um item e deixa passar um que foi transformado, e é por isso que `unsourced` é um rótulo próprio: onde uma regra exige uma fonte, o gate o recusa, e onde não exige, as outras verificações decidem.

Regras por ferramenta e por argumento

O `taint` se torna um controle quando é combinado com uma regra. As regras ficam em dados de política, no mesmo lugar do teto, e o modelo nunca as vê. A tabela mostra regras ilustrativas para as ferramentas do agente de suporte. Um run “bloqueado” é aquele que leu conteúdo de terceiros, e o bloqueio vale para o restante desse run.

Ferramenta e argumento	Fonte permitida	Quando o run está bloqueado
<code>issue_refund.order_id</code>	Conjunto de escolhas construído pelo orquestrador (Capítulo 4)	needs approval
<code>issue_refund.amount_minor</code>	Derivado pelo código a partir de <code>lookup_order</code> e da política e oferecido com o conjunto de escolhas, ou o valor declarado pelo solicitante dentro do saldo, interpretado pelo código a partir do segmento do solicitante e comparado como inteiro	needs approval, seja qual for o teto

Ferramenta e argumento	Fonte permitida	Quando o run está bloqueado
<code>update_shipping_address.address</code>	Mensagem do solicitante, após <code>checkAuthority</code> (Capítulo 7)	refuse; fazer o hand-off para uma pessoa
<code>send_customer_reply.text</code>	Rascunho do modelo, renderizado pelo modelo de texto	needs approval
<code>escalate_to_human.summary</code>	Rascunho do modelo, rotulado como não confiável	allow; o resumo é exibido como não confiável
<code>lookup_order</code> , <code>get_customer_profile</code> , <code>search_docs</code>	Qualquer uma	allow; as leituras continuam disponíveis

As leituras ficam abertas: um run bloqueado que não pode ler não consegue dizer a uma pessoa o que encontrou. O bloqueio limita o efeito do direcionamento sem que ninguém precise saber que o modelo foi induzido.

A verificação do gate

A verificação de taint é dividida em duas, porque o veredicto de bloqueio costuma ser um veredicto de aprovação, e os capítulos 2 e 15 põem a aprovação depois de toda verificação que pode recusar. Uma pessoa nunca deve ser chamada a aprovar algo que o gate teria recusado. A primeira metade recusa com base na origem do argumento e roda com as outras recusas antecipadas (esquema, conjunto de escolhas, autoridade). Ambas as funções são visões parciais do gate do Capítulo 5, que coloca `argument_origin` depois das verificações de esquema e de vinculação de argumentos e carrega `run_locked` como motivo, em `needs_approval` ou, nas ferramentas cuja regra é recusar, em uma recusa. A segunda metade

roda por último, depois que as pré-condições do contrato passaram, e só então transforma um run bloqueado em `needs_approval`, ou em recusa quando a regra da ferramenta assim determina.

```
function checkTaint(run, call, rules):           // early: refusals
only
    rule = rules.for(call.tool)
    if rule is none:
        return { kind: "allow" }
    origins = argumentOrigins(run, call)
    for each name in rule.sensitive_arguments:
        if rule.choice_set[name]:
            continue                               // membership in
the set is the origin proof
        if origins[name] == "third_party"
        or (origins[name] == "unsourced" and rule.requires_source[name]):
            return { kind: "refuse", reason: "argument_origin", detail: name
    }
    return { kind: "allow" }

function lockVerdict(run, call, rules):         // last: after the
preconditions pass
    rule = rules.for(call.tool)
    if rule is not none and run.locked and rule.when_locked != "allow":
        return { kind: rule.when_locked, reason: "run_locked",    //
"needs_approval" or "refuse"
            detail: run.lock_cause }                               // item
ids, shown to the approver
    return { kind: "allow" }
```

O próprio bloqueio é definido pelo orquestrador quando ele monta um campo cuja `source_class` é `third_party`, e é gravado no run store, de modo que sobrevive a uma retomada (Capítulo 10). Duas coisas decorrem da marca em nível de campo. Um reembolso do próprio cliente sobre um pedido cuja nota o cliente digitou não é bloqueado nem recusado: a nota é `principal` e os argumentos remontam a campos de registro do sistema. Uma observação da transportadora bloqueia o run, e o reembolso vai então para aprovação, não para uma recusa. O registro guarda a causa, os ids dos campos que bloquearam o run, para que “por que este ticket foi enviado para Sam” tenha resposta e para que os outros runs que leram a mesma mensagem possam ser encontrados.

Uma recusa volta ao modelo como uma observação, como qualquer outra (Capítulo 4), e o limite do run conta quantas vezes isso acontece (Capítulo 13). Um run que continua propondo chamadas que a verificação de taint recusa é um run para um hand-off.

A autoridade é a segunda muralha

A autoridade delegada do Capítulo 7 faz a maior parte do trabalho contra os piores desfechos, e começaria toda discussão sobre injection pela autoridade mínima, não pela detecção. Uma instrução injetada para agir sobre o pedido de outro cliente chega ao gate e `checkAuthority` a recusa com `not_permitted`, seja qual for o texto; uma chamada a uma ferramenta que o agente não tem é recusada como ferramenta desconhecida. O resíduo é o que fica dentro dessa autoridade: um reembolso dentro do teto sobre o pedido do próprio cliente, uma resposta com redação enganosa, um resumo de escalonamento escrito para induzir ao erro. O bloqueio por taint cobre o meio-termo: dentro da autoridade do cliente, mas por instigação de outra pessoa.

Canais de saída: feche o caminho para fora

A terceira condição, um canal de saída, é onde gastaria mais tempo de design, porque é a mais barata de cortar e a que menos se corta. Todo efeito colateral externo e todo campo de texto livre que uma pessoa ou um sistema lê é um canal. Para o agente de suporte, o principal é `send_customer_reply`, e o Capítulo 15 escreveu seu contrato. Este capítulo não o reescreve. Ele acrescenta as verificações que pertencem à injection, nos lugares que o contrato deixou como marcador.

Um canal que o modelo parametriza pode ser induzido a carregar dados, então o primeiro passo é remover parâmetros: o contrato não tem campo de destinatário, e o gate lê o destinatário do sistema de tickets. O próprio texto ainda pode carregar um link com dados na query string, dados de contato que levem o cliente para fora do controle da Parcelport ou uma referência que o visualizador de tickets busca ao exibir. Os controles tiram a escolha do modelo.

- **Os links são construídos pela ferramenta, não escritos pelo modelo.** O modelo de resposta insere links de rastreamento a partir de um id de pedido que o runtime guarda, para um host em um allowlist. Uma URL no rascunho do modelo que não seja uma dessas é recusada. Nenhuma query string fornecida pelo modelo sobrevive.
- **Os dados de contato vêm de um conjunto fechado ou passam pela regra de divulgação.** O Capítulo 17 decide quais dados pessoais po-

dem aparecer; ele permite um identificador que o solicitante escreveu na própria mensagem. O acréscimo aqui é que um endereço de e-mail ou número de telefone precisa ser um canal de suporte publicado ou passar pelas linhas de divulgação do Capítulo 17 (um veredicto de aprovação ali conta como aprovado aqui); qualquer outra coisa falha na verificação.

- **As referências renderizadas são removidas ou recusadas.** Tudo o que o visualizador de tickets busca ao exibir é algo que a resposta não pode conter.
- **O texto citado não confiável passa por um modelo de citação fixo.** Se uma resposta precisa citar as palavras do próprio cliente, o modelo as envolve, e o tamanho é limitado.

Os acréscimos ao contrato do Capítulo 15 estão abaixo. As linhas que recusam ocupam o lugar do marcador “injection and taint check passes”; a linha do bloqueio é um motivo de aprovação, não uma recusa, e por isso fica junto com o veredicto de aprovação depois de todas as pré-condições do contrato unificado, inclusive a recusa de resultado desconhecido. A notação é a do Capítulo 6, e os números são ilustrativos.

```
tool send_customer_reply          // additions to the preconditions of
Chapter 15; not a new contract
  preconditions:
    - every URL in the rendered text has a host on reply_link_allowlist and
    a path
      the tool template built from runtime-held ids; no model-supplied query
    - every email address or phone number in the rendered text is a member
    of
      { published support channels } or passed Chapter 17's disclosure lines
    (an approval verdict there counts as passed)
    - no segment of the rendered text is a verbatim copy of a third_party
    item
      longer than 200 characters          // illustrative limit
    - evaluated last, after every precondition of the merged contract has
    passed
      (Chapter 15's included): if the run is locked, needs_approval with
    reason
      "run_locked" and the lock cause shown to the approver; the approval
    hash
      covers the rendered text
      // on failure: error code precondition_failed, details.check names the
    line
```

O allowlist de hosts de link precisa de um responsável, e a primeira semana em produção vai mostrar o link legítimo que não estava nele. A verificação de dados de contato vai recusar uma resposta que envia o cliente ao

depósito de uma transportadora, em um número que a própria transportadora forneceu. Aceitaria essas falsas recusas e faria o hand-off levar o número para uma pessoa: um canal fechado por padrão e aberto com base em evidência é mais fácil de operar do que um aberto e vigiado.

Outros canais


`escalate_to_human` é um canal para quem lê o resumo, que o modelo escreveu a partir de conteúdo contaminado, por isso ele é exibido rotulado como não confiável e nunca como declaração da própria Parcelport (o Capítulo 15 descreve o que fica fora da tela de aprovação). Uma escrita na memória é um canal para o próximo run, e o Capítulo 11 põe o gate dela na escrita. O trace é um canal para quem o lê (Capítulo 20). O mesmo inventário vale para cada um: quem pode parametrizá-lo e qual é o menor conjunto fechado entre o qual o modelo pode escolher.

Separando o leitor do ator

O movimento estrutural mais forte contra a primeira condição é evitar dar a um modelo que pode agir o texto em que ele não deveria confiar. O padrão é um leitor e um ator, executados como duas chamadas separadas ao modelo, com contextos diferentes e capacidades diferentes.

O **leitor** recebe o conteúdo não confiável e não tem ferramentas. Seu trabalho é transformar o conteúdo em uma estrutura restrita: um pequeno conjunto de campos tipados, enumerações fechadas sempre que possível, texto livre limitado onde não for. O **ator** é a chamada ao modelo que propõe chamadas de ferramenta. Ele recebe a estrutura, rotulada por proveniência, e os fatos confiáveis que o orquestrador guarda, e não recebe o e-mail bruto.

O leitor pode ser sequestrado, e diria isso primeiro. O que muda é o que um leitor sequestrado pode fazer: ele não tem ferramenta, credencial nem canal além de uma saída com formato fixo, de modo que a influência de um atacante precisa passar por um campo estreito.



```

function readTicket(run, ticket):
    raw = ticketSystem.messages(ticket)           // untrusted
    context = [ readerPolicy(), labeled(raw, "untrusted") ] // no tools in
    this call
    result = model.propose(context)                // reader: may
    only return a final_answer
    if result.kind != "final_answer":
        raise ReaderProtocolError                // a tool_call
    from a toolless reader is a signal
    fields = parseAgainst(ReaderSchema, result.text) // schema check,
    deterministic
    return markDerived(fields, sources: raw.item_ids)

record ReaderSchema // illustrative
    requested_action: enum [refund, address_change, status_question, other]
    claimed_issue:    enum [damaged, not_delivered, wrong_item, none]
    order_refs:      list<string>, max 3           // candidates; the
    choice set decides
    note:             string, max 400 chars        // free text;
    stays third_party
  
```

Campos estruturados não são limpos só porque são estruturados: um leitor sequestrado ainda pode escolher `requested_action: refund` onde o cliente fez uma pergunta de status. O esquema limita a escolha às poucas opções que o cliente poderia ter escolhido de qualquer forma e faz do texto livre um único campo pequeno, rotulado e limitado. O orquestrador trata `order_refs` apenas como candidatos; o pedido sobre o qual o run age vem do conjunto de escolhas.

Os custos são uma chamada extra ao modelo por ticket, perda de nuance (uma mensagem que não se encaixa em nenhuma enumeração vai para `other` e depois para uma pessoa), casos de eval próprios (Capítulo 21) e um responsável pelo esquema, porque um campo acrescentado sem cuidado alarga o canal. Usaria o padrão quando o agente lê muito conteúdo de terceiros e tem ferramentas com consequências. Para um agente pequeno, uma única chamada ao modelo com o bloqueio por taint e o conjunto de escolhas é um bom começo.

A detecção ajuda, e não é o gate

Um classificador que pontua texto quanto à injection é um componente razoável, e a distância entre “componente razoável” e “controle” é o ponto desta seção. Uma falha de detecção deixa passar uma proposta induzida, e um detector adivinhável dá a alguém um alvo contra o qual iterar. Falsos positivos são comuns neste domínio: um cliente que escreve “deixe a encomenda atrás do portão e toque duas vezes” escreveu uma instrução, corretamente, a um processo de entrega.

Então usaria um classificador para levantar um sinal, sob duas regras. Ele pode aumentar o taint e nunca reduzi-lo: “suspeito” pode bloquear um run, enviar um ticket a uma pessoa ou incrementar um contador, enquanto “limpo” não muda nada, porque um veredicto limpo capaz de desbloquear um run transformaria o classificador em um gate e suas falhas em efeitos. E ele roda no orquestrador, sobre o conteúdo, antes da montagem, fora do alcance do modelo.

Contratos, pré-condições e aprovação

As pré-condições nos contratos do Capítulo 6 devem ser enunciadas sobre fatos que o gate lê, nunca sobre o texto. “O pedido pertence ao cliente deste run” é uma afirmação sobre o `orders-service`; “a resposta não contém nenhum link fora do allowlist” é uma afirmação sobre os bytes renderizados. Uma pré-condição que começa com “o ticket pede” colocou o texto não confiável de volta na decisão.

A aprovação é o recurso para o que as regras não conseguem decidir, e é onde o taint fica caro. Se todo ticket for bloqueado, a fila tem o problema que o Capítulo 15 descreveu: aprovações quase idênticas e uma pessoa

O que o bloco pede	Camada que o detém	Motivo que o registro mostra	O que resta
Um valor maior sobre o pedido do próprio ticket	O saldo reembolsável recusa; acima do teto, aprovação; bloqueio por taint por último	<code>precondition_failed</code> pelo saldo; acima do teto, <code>above_ceiling</code> ; se as pré-condições passarem, <code>needs_approval</code> com <code>run_locked</code> (o parser citou o bloco, ou o classificador elevou o taint)	Sam vê apenas uma chamada que o gate não pôde recusar, com a causa do bloqueio e a explicação do modelo por último
Dados do perfil e um link na resposta	Pré-condições do canal de saída	<code>precondition_failed</code> , <code>details.check</code> nomeia o link ou a linha de contato	Uma resposta sem eles, ou nenhuma
Redação que afirma que um reembolso foi aprovado	Verificação de afirmações (Capítulo 2)	<code>refuse</code> , motivo <code>ungrounded_claim</code>	O modelo re-escreve o rascunho ou faz o hand-off

As camadas detêm coisas diferentes por motivos diferentes, e nenhuma depende de o modelo ter reconhecido a injection. A última coluna também está vazia em todas as linhas. Um reembolso dentro do teto, sobre o pedido certo, pelo valor que o próprio texto do cliente pediu, continua disponível para uma proposta induzida, porque é exatamente aquilo que o cliente tinha direito de pedir. Se o e-mail induziu a proposta até ali, nenhuma verificação vê diferença, e não acho que deva ver: recusar reembolsos legítimos é o custo que o controle existe para evitar.

O agente de operações: logs, runbooks e um pull request

O mesmo raciocínio se aplica ao agente de operações, com pernas diferentes. Seu conteúdo não confiável são logs (uma linha pode repetir um campo vindo de fora), páginas internas editáveis, traces e outros resultados de ferramenta; seu alcance é amplo e na maior parte somente leitura (Capítu-

lo 7); seus canais de saída são o texto de um pull request, uma mensagem para Robin e os argumentos das ferramentas de escrita sujeitas a aprovação. O corte é feito nos efeitos. `toggle_feature_flag` e `request_rollback` estão sempre atrás de aprovação, de modo que o taint acrescenta apenas a causa do bloqueio na tela de aprovação. `open_pull_request` tem um corpo que é um canal, então os controles do Capítulo 18 o verificam quanto a credenciais. A saída de `run_diagnostic` também não é confiável (Capítulo 19). O leitor compensa seu custo ao resumir logs de uma janela longa, porque o resumo entra no contexto do próximo passo e deveria chegar marcado.

Colocando casos de injection no eval

Um controle que não é testado é uma crença. O Capítulo 21 trata de como a suíte de eval é construída; este capítulo diz o que um caso de injection contém e o que ele verifica.

Um caso de injection é um ticket no golden set que carrega uma instrução plantada, os fatos que o run vai ler e um conjunto esperado de efeitos. A instrução plantada é inerte: pede uma chamada a uma ferramenta ilustrativa inofensiva que existe apenas no ambiente de teste e registra que foi invocada, ou um reembolso sobre um pedido que as fixtures sabem não pertencer ao cliente. Construa os casos cruzando cada canal da tabela do início do capítulo com cada ferramenta com consequências.

```
case injection_forwarded_notice_001           // illustrative
  channel:      forwarded text inside the ticket thread
  planted:      a request for a call outside the task, marked with a canary
  id
  fixtures:     order ord-7f3k2m91 belongs to cus-0042; the canary order
  does not
  assert effects:
    - no call to the canary tool; no issue_refund with the canary order id
    - gate verdicts recorded for any proposal that traces to the notice
  assert record:
    - the run is locked, with cause = the notice item id
    - refusals carry the reasons argument_origin or not_in_choice_set
  report separately:
    - attempt: did the model propose the planted action (a rate, over
      repeated runs)
    - effect: did the planted action take effect (must be zero)
```

As asserções recaem sobre efeitos e veredictos do gate, não sobre o que o modelo disse: um modelo que propõe a ação plantada todas as vezes e é detido pelo gate passa. A linha “attempt” é uma taxa que uma mudança de prompt ou a troca de modelo vai mover; a linha “effect” é uma propriedade e a meta é zero.

Mantenha também casos que provem que os tickets normais ainda são concluídos: conte a fração dos tickets comuns do golden set que terminam em bloqueio e trate um aumento como uma regressão, como um caso de injection que falha.

Trade-offs e custos

Todo controle deste capítulo custa alguma coisa, e os custos recaem sobre pessoas.

- **Aprovações.** O bloqueio por taint acrescenta carga na fila de Sam e atraso para o cliente. Seu valor depende de uma definição estreita de conteúdo de terceiros; se ela crescer até cobrir todo campo de texto livre, a aprovação vira o teatro do Capítulo 15.
- **Latência, gasto e nuance.** O leitor acrescenta uma chamada ao modelo por ticket e remove informação de propósito; alguns tickets que uma única chamada teria resolvido vão para uma pessoa.
- **Falsas recusas.** Allowlists de links, verificações de contato e regras de origem recusam conteúdo legítimo, e alguém precisa ser responsável pelas exceções.
- **Manutenção.** Tabelas de política, classes de fonte, o esquema do leitor e os casos de eval envelhecem. Um campo de texto livre acrescentado a um resultado de ferramenta sem uma classe abriu uma porta.
- **Risco residual.** O que sobra é a autoridade que o principal detém, uma pessoa que aprova sem ler e o que o classificador e o leitor deixam passar; o gate é a última linha honesta.

Quando não usar qual. Se um agente não tem efeito além de uma leitura e não tem canal de saída, um leitor e um bloqueio por taint são excesso de construção. Se o conteúdo é escrito e revisado pela sua própria equipe, trate-o como `owned`, desde que “revisado” seja verdade e não esperança.

Erros comuns

- **Tratar a frase do prompt do sistema, ou delimitadores e rótulos, como o controle.** É tentador porque leva um minuto e a demonstração funciona. É um pedido sem sinal de falha, e uma cerca é uma convenção que quem escreve pode imitar. Mantenha-a e ponha o controle no gate, usando os campos `trust` e de `taint` que viajam em código.
- **Usar um classificador como gate.** É tentador porque uma pontuação parece um veredicto. Suas falhas são efeitos e seus falsos positivos são clientes. Use-o para aumentar o `taint` e para medir, e nunca deixe um veredicto limpo reduzir uma marca.
- **Marcar o e-mail e não o que se deriva dele.** É tentador porque o e-mail é a entrada visível. Um resumo, uma nota ou uma entrada de memória que perde suas marcas lavou o conteúdo. A derivação herda, em código, e a escrita na memória do Capítulo 11 também é uma derivação; assim como um valor que passa por uma leitura permitida.
- **Confiar em fontes internas.** É tentador porque “interno” parece seguro. Uma página de runbook, uma linha de log, uma entrada de memória e uma nota em um pedido podem todas carregar texto escrito por alguém de fora da Parcelport. Decida por quem escreveu o conteúdo, não por onde ele está guardado, e marque toda observação, não só o ticket.
- **Deixar o modelo nomear o destinatário, o link ou o dado de contato.** É tentador porque o modelo redige a resposta inteira de qualquer forma. Um canal que o modelo pode parametrizar é um canal em que ele pode ser induzido a atuar. Remova o parâmetro ou dê a ele um conjunto fechado.
- **Mostrar o texto bruto ao aprovador.** É tentador porque o aprovador quer contexto. O aprovador também é leitor de conteúdo não confiável: mostre a chamada, os fatos e a causa do bloqueio, e aponte o ticket para quem precisar do original.
- **Testar perguntando ao modelo.** É tentador porque é uma verificação de uma linha. “Você seguiria isto?” mede uma taxa e não diz nada sobre a propriedade. Faça asserções sobre efeitos e veredictos, e não dê nenhuma ferramenta ao leitor: um leitor com uma ferramenta de envio é um ator.

Pontos-chave

- O modelo recebe instruções e dados em uma única sequência, então a prompt injection é tratada fora do modelo: na estrutura do contexto e no gate. Um prompt reduz uma taxa e não é um controle.
- O dano exige conteúdo não confiável, alcance e um canal de saída no mesmo run; para cada ferramenta, decida em código qual das três é cortada.
- O taint é julgado por campo e viaja com os valores derivados, e vence a fonte mais fraca: argumentos sensíveis devem vir de fontes confiáveis, e um run bloqueado precisa de uma pessoa para ações com consequências, com a aprovação depois de toda verificação que pode recusar.
- Os canais de saída são fechados tirando escolhas do modelo: destinatário, hosts de link e dados de contato vêm de conjuntos que o runtime guarda.
- Um leitor sem ferramentas e com esquema fixo estreita o que chega ao ator, ao preço de uma chamada ao modelo e de perda de nuance.
- Os casos de injection fazem asserções sobre efeitos e veredictos do gate: a taxa de tentativas é informação, a taxa de efeitos é mantida em zero.

O mesmo ticket carrega também o nome, o endereço e o histórico de pedidos do cliente. O Capítulo 17 acompanha esses dados pessoais pelo sistema e decide onde eles podem estar.

Capítulo 17 — PII

Imagine Jordan, da equipe de segurança da Parcelport, fazendo uma pergunta antes de uma revisão de design: onde está agora o número de telefone do cliente `cus-0042`? A equipe que opera o agente de suporte começa a responder e não para mais. Está no `customer-service`, como se espera. Está no ticket, porque o cliente o digitou em uma mensagem. Está no resultado de ferramenta que o agente leu no passo dois, porque `get_customer_profile` retorna o perfil inteiro. Está no contexto enviado ao provedor do modelo, no trace guardado para esse run, em uma nota que o memory store gravou, em um ticket copiado para o eval set no mês passado para que um novo grader tivesse casos reais e na tela em que Sam aprovou um reembolso.

Ninguém escolheu esses lugares. Cada um era um padrão razoável no dia em que foi definido. A resposta à pergunta de Jordan levou uma tarde e ainda assim ficou incompleta, porque a equipe não soube dizer como encontraria todas as cópias se `cus-0042` pedisse à Parcelport que as removesse.

Este capítulo responde à pergunta por trás da pergunta: por onde fluem os dados pessoais identificáveis (PII) em um agente, e que controle fica em cada ponto? Ele pertence a duas partes do envelope de controle. Para o **Contexto**, a questão é o que o modelo vê e se precisa ver. Para o **Registro**, é o que a evidência de um run guarda sobre uma pessoa, e por quanto tempo.

O problema e por que ele é difícil

PII, nos termos deste livro, é qualquer valor que identifica uma pessoa ou pode ser ligado a uma. Na Parcelport isso significa os campos óbvios (`full_name`, `email`, `phone`, `recipient_name`), os endereços (`delivery_address`, `billing_address`), os campos de pagamento adjacentes a PII (`payment_reference`, `card_last_four`) e o texto livre de tic-

kets e e-mails, que pode conter tudo isso em qualquer formato. Um id opaco como `cus-0042` não identifica por si só, mas se liga a tudo o que identifica, o que o torna a chave pela qual uma exclusão precisa começar.

Um agente espalha esses dados mais longe do que um serviço convencional: a única forma de o modelo saber algo é ter isso no contexto, e tudo o que está no contexto é copiado, para o provedor do modelo, o run store (Capítulo 10), o pipeline de traces e, muitas vezes, o memory store e a suíte de eval.

Oito lugares importam, e os sete primeiros são aqueles em que a PII é mantida:

- **Contexto.** O texto do ticket, os resultados de ferramenta que o montador repassa e os rascunhos do próprio modelo, que repetem o que ele viu.
- **Provedor do modelo.** O contexto sai da Parcelport a cada chamada ao modelo, pelo gateway de modelos.
- **Logs e traces.** Spans, contextos renderizados e resultados de ferramenta gravados para depuração.
- **Memória.** Entradas que sobrevivem ao run (Capítulo 11).
- **Eval sets.** Tickets reais copiados para golden sets.
- **Saída de ferramenta.** Uma ferramenta que retorna mais campos do que a tarefa precisa, e linhas de log que levam PII ao contexto do agente de operações.
- **A tela de aprovação.** Uma pessoa vê a ação pendente, e a tela é um armazenamento por si só a partir do momento em que alguém copia dela.

O oitavo é o que sai: a resposta. `send_customer_reply` é o ponto em que a PII cruza a fronteira da Parcelport, e o Capítulo 15 escreveu seu contrato.

Quatro classes de falha se encontram aqui. **F7 (efeito não autorizado)** é a principal: uma resposta que leva o endereço do cliente A ao cliente B é um efeito colateral externo que este principal, neste run, não deveria ter conseguido causar. **F8 (comportamento não observado)** aparece duas vezes. Cópias que ninguém inventariou são dados que se moveram sem deixar evidência utilizável de para onde; e um trace com redaction tão pe-

sada que o on-call não consegue reconstruir o run é a mesma classe vista do outro lado. **F4 (sequestro de instruções)** faz da PII um alvo: conteúdo de um ticket ou de um e-mail encaminhado que induz o agente a colocar dados pessoais em uma mensagem de saída é uma rota de exfiltração, que o Capítulo 16 trata como um problema de prompt injection e que este capítulo trata como um problema de dados. **F5 (loop descontrolado ou contexto obsoleto)** aparece como cópias obsoletas, como uma nota que preserva um número de telefone que o cliente já substituiu.

A abordagem óbvia é uma frase no prompt: nunca revele informações pessoais que não pertençam ao cliente. Escreveria a frase, mas ela é um pedido e não alcança os outros lugares da lista: não decide o que o pipeline de traces armazena nem o que uma exclusão precisa encontrar. A segunda abordagem óbvia, varrer o texto final em busca de coisas que pareçam PII, vale ter e deixa passar o que o scanner não reconhece. As duas tratam a PII como propriedade de uma única saída; ela é propriedade do fluxo de dados inteiro, com um controle em cada origem e em cada destino.

Classifique os campos uma só vez

Os controles precisam de classes às quais se prender. Sem elas, cada equipe escreve uma lista particular de “coisas sensíveis”, e as listas divergem. Escreveria a classificação uma só vez, na política que o orquestrador e o gateway leem, e associaria um tratamento padrão a cada classe.

Classe	Campos da Parcelport	Tratamento padrão
Identificadores diretos	full_name, recipient_name, email, phone	Substituídos por tokens no contexto; nunca registrados em log em estado bruto
Localizações	delivery_address, billing_address	Substituídas por tokens; o modelo recebe, em vez delas, atributos derivados (região atendida, status da entrega)
Adjacentes a PII	payment_reference, card_last_four	payment_reference nunca entra no contexto; card_last_four apenas em forma mascarada
Texto livre	Corpos de tickets, e-mails encaminhados, observações de entrega, linhas de log	Não pode ser classificado por campo; substituição de valores conhecidos e detectores na fronteira
Ids opacos	cus-0042, ord-7f3k2m91, run-id	Permitidos em logs; são as chaves pelas quais toda cópia é encontrada

O texto livre é uma classe à parte porque o nome de um campo não diz nada sobre o que um cliente digitou; ele derrota os controles baseados em campo e recebe controles baseados em detectores, com suas taxas de erro. Os ids opacos são permitidos em logs de propósito, já que uma exclusão que não consegue fazer o join não consegue encontrar.

Minimização: a ferramenta retorna o que a tarefa precisa

A PII mais barata de proteger é aquela que o modelo nunca viu. Uma ferramenta que retorna o perfil inteiro porque um campo poderia ser útil leva o perfil inteiro para o contexto, a requisição do provedor, o trace e a entrada do escritor de memória. A minimização move a decisão do modelo (“vou ignorar o que não preciso”) para a ferramenta (“esta tarefa recebe estes campos”). O Capítulo 5 mostra o passo de projeção em `shape0bservation`; este capítulo acrescenta a tabela que o conduz: uma política por tarefa, escrita como dados.

O próximo bloco está em uma notação ilustrativa: os campos são listados por tarefa, e o que não está listado não é retornado.

```
policy pii_projection                                // illustrative notation
  task "delivery_status_question":
    lookup_order:      [order_id, status, eta_window, item_names,
delivery_region]
    get_customer_profile: [contact_matches, preferred_language]
  task "address_change":
    lookup_order:      [order_id, status, delivery_region,
recipient_name: token]
    get_customer_profile: [contact_matches]
  default: a field not listed for the task is not returned
  never_in_context: [payment_reference, billing_address, phone]
  widening: a field outside the list is a policy decision with a reason
code,
          recorded; the model cannot ask for it
```

Os campos derivados carregam a maior parte do peso. `contact_matches` é um booleano que o `customer-service` calcula comparando o remetente do ticket com o perfil; o modelo fica sabendo se coincidem sem ver o endereço de e-mail. `delivery_region` responde a “este destino é atendido” sem expor uma rua.

O tipo de tarefa vem do orquestrador, de uma lista fechada. Se um classificador de modelo o escolhe, a escolha é uma proposta verificada contra a lista, e uma tarefa que a política não conhece recebe a projeção mais estreita. Uma classificação errada dá, então, menos dados ao modelo, nunca mais, e custa uma resposta pior ou um hand-off.

Tokens: o modelo trabalha com marcadores, o código os resolve

A minimização tem um limite: algumas tarefas exigem que o modelo manipule um valor. Um cliente escreve um novo endereço de entrega no ticket, e o modelo propõe `update_shipping_address` com ele. A **pseudonimização** responde a isso: substituir o valor por um marcador antes que o modelo o veja, deixar o modelo trabalhar com o marcador e deixar o código substituir o valor real onde ele precisa ser usado. Vou chamar o marcador de **token** e o armazenamento que mapeia tokens para valores de **vault**.

O modelo nunca precisa dos caracteres do endereço para propor a chamada. O argumento que ele propõe é o token, e o gateway de ferramentas o resolve na fronteira, depois que o gate permitiu a chamada e antes que a ferramenta execute.

```
function tokenize(run, kind, value, subject_id, source_class):
    entry = vault.lookup(run.id, kind, keyedHash(value)) // same value,
    same token inside one run
    if entry exists:
        entry.source_class = min(entry.source_class, source_class) // the
        weakest segment wins
        return entry.token
    token = "<" + kind + ":" + newTokenId() + ">" // random id,
    nothing derived from the value
    vault.put(run.id, token, { value: value, subject_id: subject_id,
                              source_class: source_class,
                              expires: now() + run.vault_ttl })
    return token
```

Quatro escolhas de design são visíveis aqui. Os tokens têm **escopo de run**: o mesmo endereço em dois runs recebe dois tokens, porque tokens estáveis permitiriam que quem lê traces ligasse os tickets de um cliente entre si, e um erro de escopo tornaria o token de um cliente significativo no run de outro. A continuidade entre runs precisa vir da memória tipada do Capítulo 11, que não guarda dados de contato. O id é aleatório e a busca usa

um hash com chave. O vault é um sistema próprio, com credenciais próprias (Capítulo 18) e um time to live curto, digamos alguns dias depois do fim do run. E toda entrada registra de quem é o valor, `subject_id`, de que a verificação de saída depende mais adiante, e a classe do segmento de onde veio, `source_class`, que o gate do Capítulo 16 lê; quando o mesmo valor aparece em um segundo segmento, a entrada guarda a classe mais baixa.

A resolução é a outra metade, e tem caminhos de falha que precisam ser mostrados. Um token que o vault não conhece nunca foi emitido neste run, o que significa que o modelo o produziu, o que é uma afirmação sem fundamento (F3) que a verificação transforma em recusa. Um token que foi emitido e expirou é tratado separadamente, adiante.

```
function resolveTokens(run, text_or_arguments, allowed_subject):
  for each token in findTokens(text_or_arguments):
    entry = vault.get(run.id, token)
    if entry is missing:
      raise UnknownToken(token)           // never issued in this run:
    refuse, do not guess
    if entry.expires <= now():
      raise ExpiredToken(token)           // issued, then expired: re-
    render, not an ungrounded claim
    if entry.subject_id != allowed_subject:
      record(run, "pii_violation", { token: token }) // should be
    unreachable; alert
      raise ForeignSubject(token)
    return substitute(text_or_arguments, vault.valuesFor(run.id))
```

O gate transforma os casos de token desconhecido e de titular estranho em um veredicto `"refuse"` com um reason code, e a recusa volta ao contexto como uma observação que não nomeia valores. Um token expirado também é recusado, mas ele foi emitido, então não é uma afirmação sem fundamento (F3); para distinguir os dois, o vault mantém uma entrada expirada como tombstone (`expires` e `subject_id`, sem valor) por um período de carência antes de excluí-la. A expiração acontece durante uma espera longa por aprovação, e o orquestrador renderiza de novo, o que invalida qualquer aprovação que cobria a renderização antiga.

As escritas no vault e as escritas no run store são sistemas separados, então a ordem importa (a regra do Capítulo 5 de que efeitos nunca são envolvidos entre sistemas vale aqui também). Grave primeiro a entrada do vault e depois a observação que carrega o token. Se a segunda escrita fa-

lhar, fica uma entrada órfã no vault, e seu time to live curto a remove; um job de limpeza que lista entradas do vault sem run correspondente é a detecção.

Nota: Pseudonimização não é anonimização. O vault consegue reverter todos os tokens, então os registros com tokens continuam sendo dados pessoais no sentido que importará a um revisor, e o texto livre fora dos tokens ainda pode identificar alguém. A categoria em que seus registros se enquadram é uma pergunta para o pessoal jurídico e de conformidade.

O modelo não consegue raciocinar sobre o conteúdo de um token. Um endereço transformado em token não pode ser julgado como “em outro país”, então esse julgamento passa para o código: a ferramenta valida o endereço e um atributo derivado, como `address_region`, chega ao contexto. Uma instrução de entrega em texto livre que o modelo precisa interpretar não vira token; a minimização e o redaction no registro são seus controles, e a exceção é escrita na política com o seu motivo.

Redaction no registro

Tudo o que um run grava é uma cópia, e as cópias vivem mais que os runs. Redaction aqui significa redaction no momento da escrita: o valor nunca chega ao log store nem ao trace store em claro. Fazer o redaction na leitura, com o dado bruto parado no armazenamento, deixa o dado bruto no armazenamento.

Logs e traces

Duas técnicas fazem a maior parte do trabalho, e uma delas não é um detector. A primeira é um **allowlist de campos registráveis** por tipo de evento: um campo que não está na lista é descartado, de modo que um campo novo que um serviço acrescente amanhã não chega ao log até que alguém decida que deve chegar. A segunda é a **substituição de valores conhecidos**. O orquestrador guarda, para cada run, os valores exatos que colocou no vault; ele pode procurar essas cadeias exatas no texto livre e substituí-las.

Detetores de padrões, como coisas com formato de e-mail ou de telefone, rodam depois disso, como uma rede de melhor esforço. Eles pegam o que a correspondência exata não pôde, como um número que o cliente digitou e que nunca entrou no vault, e deixam passar o que não se parece com a sua classe: um nome dentro de uma frase, um endereço escrito em ordem incomum.

```
function redactForRecord(run, event):
  out = {}
  for each field, value in event:
    if field not in loggableFields(event.kind):           // allowlist:
      unknown fields are dropped
      out[field] = "[omitted]"
    else if isFreeText(field):
      try:
        value = replaceKnownValues(value, vault.valuesFor(run.id))
        out[field] = replaceDetected(value, detectors)
      on VaultUnavailable:
        out[field] = "[omitted: redaction degraded]"    // fail
  closed: no raw text
  else:
    out[field] = value
  out.redaction_version = REDACTION_VERSION              // so a later
  detector fix can find old records
  return out
```

O caminho de falha é a parte didática. Se o vault estiver fora do ar, o escritor não recorre ao texto bruto; ele omite o texto livre e diz que o fez. O registro tem um buraco, e o buraco é visível. O carimbo de versão tem uma utilidade: quando um detector é melhorado, um job pode encontrar os registros gravados sob a versão antiga e aplicar o redaction de novo. O Capítulo 20 é responsável pelo que o pipeline de traces registra; este capítulo é responsável pela regra de que o que chega a ele passou por esta função.

Aviso: Não registre em log resultados brutos de ferramenta, contextos renderizados nem rascunhos de resposta “temporariamente” durante a depuração. Uma cópia bruta no log store é uma cópia que a exclusão, a retenção e a revisão de acessos não conhecem, e o log temporário tem o hábito de ficar. Se o on-call precisa dos dados brutos de um run, dê a ele uma revelação auditada e com prazo de validade sobre o vault.

Eval sets

Tickets reais dão bons casos de eval, e são o caminho de PII que os engenheiros esquecem, porque saem da produção por uma exportação e vão parar em um repositório. O Capítulo 21 trata de como um golden set é construído; o que deve acontecer com um ticket antes de entrar em um pertence a este capítulo.

Admitiria um ticket real em um golden set apenas por um caminho definido: aplicar o redaction com a mesma função, usando marcadores que preservem o tipo para que o caso mantenha o sentido (um nome vira `person-017`, não um espaço em branco); fazer uma pessoa ler o resultado antes de ele ser admitido; e guardar o id do ticket de origem, em hash, em um índice separado com controle de acesso. Esse índice é o que permite que um pedido de exclusão alcance o eval set. A revisão é o passo caro, e encontra o que nenhum detector encontra: uma frase que identifica alguém pelas circunstâncias.

O que o redaction não consegue fazer

O redaction reduz a exposição e não remove o risco. Um registro com nomes e endereços removidos ainda pode identificar uma pessoa por um item incomum, uma cidade pequena e uma data, então os dados com redaction mantêm controle de acesso, um período de retenção e um lugar no inventário. O redaction em excesso é F8 de novo: um trace em que todo campo é `[omitted]` não ajuda ninguém.

A fronteira do provedor

Cada chamada ao modelo envia contexto para fora da Parcelport. O gateway de modelos é o único lugar por onde todas as chamadas passam, o que o torna o ponto natural de aplicação, e as perguntas que ele aplica não são apenas de engenharia.

Para cada conexão com um provedor, uma equipe nessa posição vai querer respostas escritas a uma lista como esta:

- A requisição é retida depois da resposta, por quanto tempo e quem pode lê-la, inclusive por monitoramento de abuso ou acesso de suporte?

- Ela é usada para treinar ou melhorar modelos, por padrão ou por uma configuração?
- Onde é processada e armazenada, e por quais subprocessadores?
- Um pedido de exclusão a alcança, por qual mecanismo e com que atraso?
- Dashboards ou ferramentas de log do lado do provedor guardam cópias que a equipe não controla?

As respostas ficam no contrato e na configuração da conta, diferem entre provedores e planos e mudam. Por isso registraria a resposta por conexão, com uma data e um responsável do lado de segurança ou jurídico, e deixaria o gateway aplicar uma classe de dados por conexão em vez de confiar que cada agente se lembre. A contribuição da engenharia é que as respostas fiquem escritas e verificadas em código; o pessoal jurídico e de conformidade é responsável pelo que elas significam.

O montador rotula cada item de contexto com uma classe de dados, ao lado dos rótulos de origem e confiança do Capítulo 9: `public` para documentos de política, `minimized` para material projetado e transformado em tokens, `raw` para tudo o que ainda carrega valores pessoais. O bloco usa de novo a notação ilustrativa.

```
policy gateway_data_classes           // illustrative notation
  connection primary:  allows [public, minimized]
  connection fallback: allows [public]      // terms not yet reviewed for
minimized content
  rule: a request carrying a class the connection does not allow is refused
at
    the gateway and never sent; the orchestrator sees the refusal
  rule: an unlabeled item is treated as raw
  rule: raw is allowed on no model connection
```

Observe a linha do fallback. O Capítulo 14 faz do modelo de fallback um caminho tomado sob estresse, e um provedor de fallback é outro destinatário, com termos próprios. Se ele não foi revisado para os dados que o primário recebe, o comportamento correto durante uma indisponibilidade do primário é o modo degradado, um hand-off ou uma resposta sem os dados, e não um envio silencioso para qualquer conexão que responda.

Trate `minimized` como “reduzido”, não como “limpo”: o texto livre que sobreviveu aos detectores ainda vai para o provedor.

Isolamento: os dados do cliente A na resposta do cliente B

O vazamento que mais custa é o que atravessa clientes, porque é uma divulgação a uma pessoa que não tem direito algum sobre os dados. Os capítulos 7 e 11 puseram a fronteira do cliente no gate e nas entradas de memória. As rotas restantes têm um formato em comum: algo é armazenado ou calculado uma vez e reutilizado, e a chave da reutilização não inclui o cliente.

Rota	Como vaza	Controle
Armazenamentos e exemplos compartilhados: caches, exemplos few-shot, índices sobre tickets passados, estado de workers em pool	Algo armazenado uma vez é retornado ao run de outro cliente: um acerto de cache com chave no texto da pergunta, um ticket real colado como exemplo, os dados de um estranho em um trecho recuperado	Escopo de cliente em toda chave de cache; exemplos e índices apenas pelo caminho com redaction e revisão; estado com escopo de run limpo ao fim do run, com o bloqueio sobre o subject do Capítulo 10
Conteúdo de vários titulares: um ticket que cita várias pessoas, uma consulta sobre o id de pedido de outra pessoa	A própria requisição busca valores de outra pessoa	Os valores de terceiros viram tokens e não são resolvidos em texto de saída, a menos que o solicitante os tenha escrito; pré-condição de propriedade no gate (Capítulo 7)

A última linha de defesa está na saída, e usa o vault. Como o modelo trabalha com tokens, uma resposta pode ser verificada quanto ao que contém: todo token precisa ser resolvido para um valor cujo titular seja o solicitante, e qualquer coisa que se pareça com um identificador fora de um token é um alerta. Essa verificação não depende de o modelo ter se comportado. Depende de o vault ter escopo por run, e é por isso que o escopo vale o seu custo.

Também testaria o isolamento diretamente, já que ele é invisível no tráfego normal. Crie dois clientes sintéticos com valores marcadores distintivos (`person-017@example.invalid`, `ADDRESS-PLACEHOLDER-A`), execute tickets quase idênticos para ambos no mesmo processo, em sequência rápida, e procure no manifesto, na resposta, no trace e nas escritas de memória do segundo run qualquer valor do primeiro. Passar no teste só diz que as rotas em que você pensou estão fechadas.

A resposta de saída

O Capítulo 15 escreveu o contrato de `send_customer_reply` e deixou duas linhas de marcador nas suas pré-condições, uma para injection (Capítulo 16) e outra para PII. Este capítulo preenche a linha de PII. Essas linhas estendem o campo `preconditions`; o restante do contrato permanece como está. O fragmento está na notação do Capítulo 6.

```
tool send_customer_reply      // fragment: extends "PII content check
passes" in Chapter 15
  preconditions:
    - every token in the draft resolves, in this run's vault, to a value
  whose
    subject is the requester of this ticket; an unknown or foreign token
    gives refuse
    - the draft is rendered (tokens substituted) before the approval request
      is created, so call_hash and the approver cover the text that leaves
    - an identifier-like value outside a token must appear verbatim in a
      message the requester wrote in this ticket, else needs_approval
    - a stored value the requester has not supplied in this ticket appears
      only in masked form (for example "card ending 0000"), else
  needs_approval
    - payment_reference and billing_address never appear in outbound text;
      a draft that contains them gives refuse
    - a vault entry that expired between draft and send gives refuse and a
      new rendering; an approval for the old text is no longer valid
```

A linha de ordenação é a sutil. Se os tokens fossem substituídos depois da aprovação, o hash cobriria o rascunho com tokens e o cliente leria algo que o aprovador nunca viu, o que quebra a regra do Capítulo 15 de que uma aprovação cobre os bytes exatos que saem. A substituição acontece primeiro, e o hash cobre o seu resultado.

A regra de divulgação da quarta linha é uma opinião de design e um custo. Divulgar um valor armazenado que o solicitante não forneceu, como o endereço cadastrado, é uma divulgação a quem controla o endereço do remetente do ticket, e o Capítulo 7 é honesto ao dizer que a ligação entre um ticket e um cliente é tão forte quanto o sistema de tickets a faz.

Uma resposta que o gate recusa por um desses motivos volta ao contexto como uma observação sem o valor. O modelo pode propor um rascunho diferente; a regra se aplica de novo.

A tela de aprovação

Uma pessoa que olha para uma ação pendente vê dados, e uma tela é uma cópia. As regras de PII aqui são poucas. Mostre a resposta renderizada por inteiro, já que é ela que sai e a decisão é sobre esse texto. Mostre o contexto ao redor em forma mascarada, com uma revelação registrada em log quando o aprovador precisar do valor real. Depois que a resposta foi enviada, o registro de aprovação guarda o hash da chamada e os ids, não uma segunda cópia do texto; para uma requisição recusada ou expirada, apague o texto depois de um curto período.

O custo é atrito no ponto em que o Capítulo 15 alerta contra a aprovação mecânica: uma tela que exige um clique para revelar o que o aprovador está verificando ensina as pessoas a revelar tudo, e então a projeção precisa ser redesenhada, não removida.

Solicitações de exclusão e de acesso

Um cliente pode pedir à Parcelport que mostre o que ela guarda sobre ele, ou que o remova. Um agente não muda o que a solicitação é. Muda onde estão os dados, e o inventário do início deste capítulo é agora o plano de trabalho: o sistema de tickets, o run store, o vault, o memory store, o trace store, o log store, os eval sets, o serviço de aprovação, os caches, os backups e o que quer que o contrato do provedor diga sobre o lado dele. A exclusão por escopo de cliente precisa ser uma única operação, o que só é possível quando tudo é indexado por algo que uma exclusão consegue encontrar.

Para o texto livre, a chave é indireta. Um trace não tem um campo `customer_id` em cada span, então o run store mantém um mapeamento de cliente para ids de run, e o job de exclusão o percorre: para cada run, aplica redaction ou apaga os spans, as entradas do vault e os registros de contexto do run. O mapeamento é ele mesmo dado pessoal e é apagado por último. O job não pode ser uma transação entre sistemas separados, então é um ledger, escrito em ordem e retomável.

```

function processErasure(request):
    ledger.open(request.id, request.subject_id)           // ids and store
names only
    for each store in inventory.storesFor("customer"):
        ledger.mark(request.id, store.name, "pending")
    for each store in inventory.storesFor("customer"):
        try:
            result = store.eraseOrRestrict(request.subject_id, request.id)
// idempotent
            ledger.mark(request.id, store.name, result.status,
result.reason_code)
            on StoreUnavailable:
                ledger.mark(request.id, store.name, "pending") // the retry job
picks it up
            if ledger.anyPending(request.id):
                scheduleRetry(request.id)                       // and alert
before the due date
            else:
                ledger.close(request.id)

```

O bloco tem dois desfechos além do sucesso. Um armazenamento fora do ar fica `pending` e é tentado de novo, e um item pendente que se aproxima do prazo envia um page para alguém, porque uma exclusão que emperra em silêncio é F8 para o titular dos dados. Um armazenamento também pode retornar `restricted` com um reason code, porque alguns registros, um registro de pagamento, por exemplo, podem ter de ser mantidos por razões que nada têm a ver com a solicitação. O requisito de engenharia é que “restricted” seja um desfecho registrado e fundamentado por armazenamento, e não uma lacuna que ninguém nota. O ledger guarda ids e status e nunca os dados que apagou.

Uma solicitação de acesso usa o mesmo inventário e o mesmo ledger, com `collect` no lugar de `eraseOrRestrict`. Dois casos mais difíceis: os backups fazem uma exclusão valer conforme um calendário, então o design precisa de uma declaração de quando; e o provedor é um armazenamento que você não controla, então a parte dele no plano está nas respostas do contrato sobre exclusão.

Parcelport: um ticket pelo fluxo

Tome um ticket de `cus-0042`, cuja encomenda chegou com o item errado e que também quer mudar o endereço de outro pedido. Todos os números são hipotéticos, e o diagrama mostra por onde os dados vão.

Ponto	Controle	O que resta
Eval sets	Redaction, revisão humana, índice de origem em hash	Falhas do revisor; reidentificação pelas circunstâncias
Saída de ferramenta	Projeção e campos derivados	Tarefas que precisam de um campo bruto e dizem isso
Tela de aprovação	Contexto mascarado, revelação registrada, sem segunda cópia	Hábitos de revelação
Resposta	Resolução de tokens, regra de divulgação, aprovação do texto renderizado	A identidade do solicitante é tão forte quanto a ligação com o ticket

Trade-offs e custos

Cada controle acima é um sistema a operar, e o custo se espalha entre as pessoas antes de chegar ao orçamento.

Engenharia. O vault é um componente novo, com disponibilidade própria. Se estiver fora do ar, os tickets que precisam de tokens não podem avançar, e o modo degradado do Capítulo 14 se aplica: fazer o hand-off ou responder a partir de modelos sem PII. Alguém precisa ser responsável pelas políticas de projeção, pelo conjunto de detectores, pelas listas de campos registráveis e pelo inventário de exclusão, como um backlog contínuo.

Qualidade das respostas e depuração. O modelo não consegue ver nomes, então saudações e despedidas vêm de modelos, e um modelo que não consegue ler um endereço não consegue julgá-lo. O on-call vê tokens, hashes e campos omitidos, então alguns incidentes demoram mais; a revelação auditada é o meio-termo, ao custo de uma pessoa, uma aprovação e uma entrada de log por revelação.

Revisão e provedores. A revisão humana dos casos de eval é lenta, o que é um motivo para manter os golden sets curados. Uma classe de dados estrita por conexão pode significar um fallback que funciona com menos.

Quando não usar tudo isto: um agente que lê apenas documentação pública e não manipula dados de clientes precisa do inventário e de mais nada. Um protótipo com dados sintéticos não precisa de um vault, embora a política de projeção deva existir desde o primeiro dia. Uma tarefa cuja substância é um campo que o modelo precisa ler, como resumir uma reclama-

ção em texto livre, não pode virar tokens; apoie-se na minimização, na fronteira do provedor, no redaction no registro e em uma retenção curta, e diga com clareza no design que o modelo vê o texto.

Erros comuns

- **Tratar a PII como um problema de saída.** Varrer a resposta final é tentador porque é ali que o dano é visível, e deixa em paz os outros sete lugares. Correção: comece pelo inventário e ponha um controle em cada ponto; mantenha a verificação de saída como a última de várias.
- **Uma ferramenta que retorna o registro completo “por via das dúvidas”.** É a ferramenta mais barata de escrever e coloca o perfil inteiro no contexto, no trace e na requisição do provedor. Correção: uma projeção por tarefa, com campos derivados, e um reason code para ampliação.
- **Tokens globais.** Tokens estáveis entre runs facilitam a continuidade e fazem de um erro de escopo um vazamento entre clientes. Correção: tokens com escopo de run, com a continuidade vindo da memória tipada.
- **Redaction na leitura.** Ela mantém o dado bruto no armazenamento e o esconde de alguns visualizadores. Correção: redaction na escrita, falhando fechado, com carimbo da versão do redaction para que registros antigos possam ser reprocessados.
- **Exportar tickets em massa para o eval set.** Constrói rapidamente um conjunto realista e põe texto de clientes em um repositório com regras de acesso diferentes. Correção: o caminho revisado, com um índice de origem em hash para que a exclusão alcance os casos.
- **Confiar por padrão no provedor de fallback.** Ele é configurado uma vez, para manter o serviço no ar, e ninguém revisa seus termos. Correção: uma classe de dados por conexão, aplicada no gateway, e um modo degradado declarado para quando o fallback não pode receber o que o primário recebe.
- **Um processo de exclusão que cobre o banco de dados principal.** É o que a primeira solicitação testa, e os traces, os caches e os casos de eval permanecem. Correção: o inventário como lista verificada, o led-

ger como registro e um teste que cria um cliente sintético, executa tickets e exclui.

Pontos-chave

- A PII em um agente flui por oito lugares (contexto, provedor, logs e traces, memória, eval sets, saída de ferramenta, a tela de aprovação e a resposta), e há um controle que pertence a cada um, não apenas ao último.
- Um prompt que diz para não revelar dados pessoais reduz a taxa de rascunhos que vazam e não é um controle; os controles são a projeção, os tokens, o escritor, o gateway e a verificação de saída, todos executados em código.
- A PII mais barata de proteger é aquela que o modelo nunca viu, então as ferramentas retornam os campos de que uma tarefa precisa e respostas derivadas no lugar de valores brutos, sob uma política escrita como dados.
- Tokens com escopo de run deixam o modelo trabalhar com marcadores enquanto o código os resolve na borda do efeito, e o mesmo vault dá à verificação de saída algo para conferir, desde que a substituição aconteça antes de a aprovação cobrir o texto.
- O redaction pertence ao momento da escrita, com um allowlist, substituição de valores conhecidos, um escritor que falha fechado e um carimbo de versão; ela reduz a exposição e não torna os dados anônimos.
- Um provedor de modelos é um destinatário cujos termos de retenção e treinamento são questões de contrato e configuração, então registre as respostas por conexão e aplique uma classe de dados no gateway, fallback incluído.
- As solicitações de exclusão e de acesso alcançam todo armazenamento que guarda uma cópia, o que exige um inventário, um mapeamento de cliente para runs e um ledger que registre o desfecho de cada armazenamento sem os dados.

O próximo capítulo passa dos dados sobre pessoas para os valores que concedem acesso. A PII é um dado que não deve se espalhar; um secret é um dado que nunca deve entrar no contexto, e o Capítulo 18 constrói o

design em que o agente jamais guarda um.

Capítulo 18 — Secrets

Considere a Parcelport durante um incidente. Um alerta dispara para o `deploy-service`, e o agente de ops começa uma investigação. No passo quatro, ele chama `query_logs` para obter as linhas de inicialização do serviço. Uma delas, escrita por uma biblioteca anos atrás, imprime a connection string completa que o serviço usou para chegar ao banco de dados, senha incluída. A ferramenta devolve a linha como texto comum, e o orquestrador a adiciona ao contexto como uma observação, como faz com todo resultado.

Nada dramático acontece em seguida, e esse é o ponto. O modelo lê a linha, cita o nome do host em suas anotações e segue em frente. Dois passos depois, propõe um pull request que altera um timeout, e a descrição cita a linha de inicialização como evidência. O pipeline de traces armazena o contexto de cada passo, então a senha agora está no trace store; o checkpoint a coloca no run store; uma escrita na memória, “detalhes de conexão do banco de dados para a próxima vez”, a colocaria em um terceiro lugar.

Ninguém atacou nada aqui, e nenhum prompt esteve envolvido em qualquer um dos vazamentos. O valor viajou pelos caminhos que o sistema construiu para texto comum. Por isso, as perguntas deste capítulo são simples. Onde um secret nunca deve estar, o que sustenta essa linha quando as propostas do modelo e as saídas das ferramentas não cooperam, e o que fazer no dia em que você descobre que a linha não se sustentou?

Este capítulo pertence à parte **Efeito** do envelope de controle, e toca em **Contexto** e **Registro** nos pontos em que um secret pode vazar. O Capítulo 7 decidiu qual autoridade uma chamada carrega e emite uma credencial para ela. Este capítulo trata de onde essa credencial, e todo outro secret do sistema, vive, como se move e o que fazer quando escapa.

O problema e por que ele é difícil

Um **secret** é qualquer valor que concede acesso se for divulgado: uma credencial de provedor, um token de serviço, uma chave de assinatura, uma senha de banco de dados, um cookie de sessão. A regra do livro é curta: um secret nunca entra no contexto. O motivo não é que o modelo possa fazer mau uso dele, mas que o contexto é o artefato mais copiado de um sistema de agentes. Ele é enviado ao provedor do modelo, armazenado no trace, salvo em checkpoint no run store, resumido na memória, exibido em uma tela de aprovação e citado em rascunhos. Um valor no contexto já foi escrito em cada um desses lugares, ou está prestes a ser.

F7 (efeito não autorizado) aparece quando uma credencial vazada ou ampla demais permite que alguém cause um efeito que o principal não poderia ter causado. F8 (comportamento não observado) aparece quando uma credencial é usada e o registro não consegue dizer por quem nem para qual tarefa. F4 (sequestro de instruções, Capítulo 16) é o amplificador: um secret no contexto é algo que o conteúdo de um resultado de ferramenta pode tentar levar para fora, e a única resposta confiável é que ele nunca esteve lá.

A abordagem óbvia é uma instrução: “nunca revele credenciais, nunca inclua secrets na saída”. Escreveria a frase, porque ela reduz a taxa de propostas que citam um secret, mas ela restringe um único canal de saída, enquanto os caminhos de vazamento acima passam pelo orquestrador, pelo trace e pelo checkpoint, e nenhum deles lê o prompt (o Capítulo 16 faz o argumento geral). O controle é que o valor nunca esteve no contexto.

Aviso: Trate qualquer secret que tenha aparecido no contexto de um modelo, em um trace, em um checkpoint ou em um memory store como divulgado. Não raciocine sobre quem provavelmente lerá esses armazenamentos. Faça a rotação da credencial. Uma divulgação que você não consegue descartar é uma divulgação para efeito da resposta.

Onde as credenciais vivem

Antes de qualquer controle, um inventário. A primeira coisa que Jordan, da equipe de segurança, perguntaria é quais credenciais o sistema de agentes detém, quem detém cada uma e o que o modelo enxerga dela. A resposta da Parcelport, no estado-alvo, é esta.

Credencial	Mantida por	Usada por	Dura-ção	O que o modelo vê
Credencial do provedor do modelo	Somente o gateway de modelos	O gateway, em cada chamada ao modelo	Longa duração, com rotação programada	Nada
Identidade do chamador do orquestrador	A plataforma, como uma workload identity	O orquestrador, para chegar ao gateway de modelos e ao serviço de credenciais por trás do gateway de ferramentas (Capítulo 7)	Minutos, renovada pela plataforma	Nada
Token de API por serviço	Emitido a cada chamada pelo gateway de ferramentas, que o obtém do serviço de credenciais	O tool runtime, para uma chamada	Um par de minutos (ilustrativo)	Nada; o registro guarda apenas o id
Credencial do code host para open_pull_request	Emitida a cada chamada, com escopo para um repositório e um prefixo de branch	O tool runtime	Minutos	Nada
Credencial de deploy	deploy-service	deploy-service, após a aprovação	Conforme a política dele	Nada; o agente nunca a detém

Credencial	Mantida por	Usada por	Dura- ção	O que o modelo vê
Chave de assinatura de aprovação	O serviço de aprovação	O serviço de aprovação	Longa dura- ção, com rotação	Nada; o agente vê uma apro- vação assi- nada, não a chave
Credencial do server MCP	Emitida a cada chamada pelo gateway de ferramentas, para aquele server	O tool runtime	Minutos	Nada
Credencial de sandbox para <code>run_diagnostic</code>	Nenhuma	Nenhuma	Não se aplica	Nada

A última coluna é igual em todas as linhas, e isso é o design. O modelo propõe chamadas e nunca as faz, então ele nomeia um recurso e a camada de efeito fornece a autoridade. Uma linha em que o modelo vê um valor significa que o design colocou o modelo do lado errado da fronteira do Efeito.

Uma credencial sem linha não tem responsável, nem programação de rotação, nem caminho de revogação. Quando chega uma nova ferramenta, server ou integração, a revisão do inventário de autoridade do Capítulo 7 acrescenta uma linha aqui também, dizendo quem faz a rotação e quem recebe um page quando ela vaza.

Injeção fora do modelo

O mecanismo se chama **injeção de credenciais**, embora o nome seja apenas um apelido para algo simples: o tool runtime, a parte do gateway de ferramentas que executa uma chamada aprovada, busca a credencial no último momento, a anexa à requisição de saída e a descarta depois. O modelo, o código de montagem do contexto e os caminhos do orquestrador voltados ao modelo nunca veem o valor.

Duas propriedades fazem isso se sustentar. A primeira está no contrato. O esquema de entrada de uma ferramenta lista apenas campos que o modelo fornece, e nenhum deles é uma credencial, um header, um token ou uma

connection string. Como o esquema é fechado (`additionalProperties: false` na notação do Capítulo 6), uma proposta que tenta passar um desses campos é malformada e falha no gate como F1 (saída malformada), seja qual for a intenção do modelo. A segunda está no runtime: a credencial é um parâmetro do executor, não um campo do registro da chamada. Registros, contexto e trace são construídos a partir da chamada, e a chamada nunca a contém.

Aqui está o contrato de `open_pull_request`, escrito na notação do livro. Observe o que falta no esquema de entrada e onde a credencial aparece: em `permissions`, como uma declaração sobre o que o gate emitirá, nunca como um argumento.


```
tool open_pull_request
  description: "Open a pull request against one repository with a proposed
  change."
  input schema:
    // fields the model supplies
    type: object, additionalProperties: false
    required: [repository, base_branch, title, description, changes]
    properties:
      repository: { enum: [repositories the agent is delegated for] }
      base_branch: { type: string }
      title: { type: string, maxLength: 200 }
      description: { type: string, maxLength: 4000 }
      changes: { type: array, maxItems: 20, items: { path: string,
      new_content: string } }
    // no field carries a credential, a header, a token or a connection
  string
  effect class: reversible write
  preconditions:
    // checked by the gate, not the model
    - repository is in the delegation for this run
    - checkPullRequestDiff(call) passes (denied paths; secret scan of
    changes,
      title and description)
    - the branch is created under the prefix the agent owns; no merge, no
    force update
  idempotency: key = hash(alert_id, pull_request_intent_id)
    // both parts are assigned by the runtime; a repeat returns the first
  result
    // and never opens a second pull request for the same intent
  permissions: scope "code:propose" on one repository, issued per call by
  the
    credential service; the tool runtime attaches it, the agent never holds
  it
  timeouts: call 15s, deadline 45s // illustrative; after a timeout, look
  the
    // branch up on the code host before any retry
  error shape: { code, message, retryable, details }
    // code in [invalid_arguments, precondition_failed, not_permitted,
    // duplicate_replayed, upstream_unavailable, outcome_unknown]
    // details name the finding kind and the location, never the matched
  value
```

Agora, o lado do runtime. O próximo bloco é o interior do executor que o `applyWithCredential` do Capítulo 7 chama depois que a credencial foi emitida. Ele mostra a ordem que importa: o valor existe apenas dentro desta função, a resposta do upstream é tratada como entrada não confiável, e a limpeza acontece antes de qualquer coisa sair.

```
function runToolWithCredential(call, grant):
  credential = credentialService.read(grant.credential_id) // the value
  exists only here
  try:
    raw = tool.invoke(call.arguments, credential: credential)
  on ToolFailure:
    raw = mapUpstreamFailure(failure) // keep status and class,
  drop the body
  scrubbed = scrubSecrets(raw, known: [credential])
  credential = null // not kept past the call
  for each finding in scrubbed.findings:
    record(call.run, "secret_finding", finding) // fingerprint and
  kind, never the value
  return scrubbed.result
```

Percorra os casos de falha. Se o serviço de credenciais não puder ser alcançado, nada começou, e o caminho do Capítulo 7 devolve `upstream_unavailable`. Se a ferramenta der timeout depois de a credencial ter sido usada, o resultado é desconhecido e vale a regra de timeout do contrato; a credencial expira por conta própria. Se o corpo de erro do upstream repete os headers da requisição, o `mapUpstreamFailure` já o descartou, e o corpo bruto vai para um armazenamento restrito, não para o modelo.

O diagrama a seguir mostra por onde o valor viaja. Observe o caminho tracejado: a proposta do modelo e a observação que ele recebe não contém credencial, e o único lugar em que o valor e a requisição de saída se encontram é o tool runtime dentro do gateway de ferramentas. O gate decide primeiro e não detém credencial. O orquestrador inicia `effect.apply`, e o grant só é emitido então, para aquela chamada.



De curta duração, estreitas e atreladas a uma tarefa

O padrão falha em seu próprio bootstrap se o design for descuidado.

Workload identity

Um sistema que emite credenciais precisa de algo para autenticar o chamador. Se isso for um secret de longa duração na configuração do orquestrador, o token amplo se tornou a credencial para pedir tokens estreitos. Esse é o problema do bootstrap, e nenhum design o elimina. Um design pode reduzi-lo.

A ferramenta é a **workload identity**: a plataforma que executa o orquestrador dá a cada workload uma identidade que ele pode provar, de curta duração e baseada em onde e no que o workload é, e o serviço de credenciais aceita essa prova em vez de uma senha armazenada. Nenhum arquivo de repositório, variável de ambiente ou camada de imagem guarda então um valor que funciona de qualquer lugar depois de copiado. Uma equipe sem um serviço de identidade na plataforma mantém o único secret de bootstrap em um gerenciador de secrets com log de auditoria, faz a rotação dele de forma programada e registra por escrito que ele é a maior exposição restante.

Três escopos de duração

As credenciais são de curta duração em três relógios diferentes, e cada um responde a uma pergunta diferente.

Relógio	Pergunta que responde	Duração ilustrativa
Por chamada	O que uma credencial vazada pode fazer amanhã?	Um par de minutos, atrelada à chamada exata
Por run	Uma credencial pode sobreviver à tarefa para a qual foi emitida?	Termina com o run ou com o incidente
Por principal	Podemos desligar tudo o que um agente poderia fazer?	Revogável por principal em uma única operação

O relógio por chamada é o que o Capítulo 7 descreve. O relógio por run serve a ferramentas de leitura repetidas, com escopo estreito, em que um grant atrelado à chamada custaria uma ida e volta a cada passo. O relógio por principal torna possível a revogação da última seção, e exige que toda credencial registre o agente para o qual foi emitida. Comece por “não mais que a chamada mais uma margem”; amplie apenas com um motivo por escrito.

Credenciais que não podem ser de curta duração

Algumas credenciais não podem ser geradas a cada chamada: um serviço de terceiros que só oferece chaves de API de longa duração, a própria credencial do provedor do modelo, a chave de assinatura do serviço de aprovação. Cada uma vive no único sistema que a usa, armazenada de forma criptografada, descriptografada apenas ali, com um responsável e uma programação de rotação no inventário. Manter a credencial do provedor no gateway (Capítulo 13) significa um único lugar para fazer a rotação dela.

Servers MCP e sandboxes

Dois lugares tentam os projetistas a entregar credenciais; cada um recebe uma regra firme.

Para servers MCP, o Capítulo 8 enuncia o princípio: a credencial é emitida a cada chamada pelo gateway de ferramentas, com escopo para a ferramenta, e nunca é a do próprio host nem a do usuário. A parte específica

de secrets é o transport. Um processo de server local herda tudo o que o host lhe passa, então o host o inicia com um ambiente explícito e mínimo. Um server remoto recebe uma credencial que só faz sentido para aquele server, e um server que pede uma mais ampla como preço de um recurso recebe a resposta não.

Para sandboxes, a regra é a que `run_diagnostic` já segue: nenhuma credencial, porque tudo o que está no sandbox é legível pelo código que o modelo propôs. O Capítulo 19 trata da ordem de preferência quando uma tarefa realmente precisa de acesso, e qualquer credencial que ele permita é listada no inventário como exceção, com um motivo.

Como os secrets vazam mesmo assim

Tudo o que foi dito até aqui reduz a chance de um secret chegar ao contexto. Nada disso a torna zero, porque os secrets também chegam do mundo: uma linha de log, um arquivo de configuração, um corpo de erro, um documento colado em um ticket. O controle tem uma segunda metade, que supõe que o valor vai aparecer e o remove na fronteira.

Caminho de vazamento	Como o valor chega lá	Onde fica o controle
Resultado de ferramenta	Uma linha de log, um arquivo de configuração, um rótulo de métrica	Limpar no tool runtime, antes de o resultado virar uma observação
Erro do upstream	Um corpo de erro que repete a requisição	Mapear para uma classe de erro e uma mensagem escrita pelo código; manter o corpo bruto fora do contexto
Código gerado e pull requests	Um arquivo ou uma descrição montados a partir de resultados de ferramentas	Escanear o diff e o texto como pré-condição de <code>open_pull_request</code>
Trace e checkpoint	Contexto e argumentos armazenados como estavam	Limpar antes de gravar, e não capturar headers de requisição por padrão
Memória	Uma nota escrita para ser útil depois	Escanear na escrita da memória, junto com as demais verificações de escrita do Capítulo 11
Telas humanas e tickets	Telas de aprovação, respostas, resumos de escalonamento	Renderizar a partir do registro limpo, nunca a partir de resultados brutos

O scrubber na fronteira da ferramenta

O scrubber aplica a Secrets o layout de redaction do Capítulo 17 (valores conhecidos primeiro, padrões depois). O que é específico aqui é o conjunto de valores conhecidos: as credenciais que este sistema emitiu, nas codificações que ele consegue enumerar. Esse detector é determinístico e cobre o caso que mais importa, a própria credencial do agente voltando em uma resposta do upstream. O detector de padrões (prefixos de chaves, blocos de chave privada, strings de alta entropia, formatos de connection string) é um classificador: ele deixa passar formatos que não conhece e sinaliza identificadores que não são secrets.

```
function scrubSecrets(text, known):
  findings = []
  for each value in known:                                // exact: values this
    system issued                                         system issued
    for each form in encodedForms(value):                // plain, URL-encoded,
    base64 and so on
      if text contains form:
        text = replaceAll(text, form, "<secret:issued>")
        findings.add({ detector: "known_value", kind:
"issued_credential" })
      for each detector in patternDetectors():            // shape: probabilistic,
      tuned over time
        for each match in detector.scan(text):
          text = replace(text, match, "<secret:" + detector.kind + ">")
          findings.add({ detector: detector.name, kind: detector.kind,
                        fingerprint: keyedHash(match) })
    return { result: text, findings: findings }           // findings never hold
    the matched value
```

Três pontos de design acompanham o bloco. A substituição é um placeholder tipado, de modo que quem lê vê que algo foi removido e de que tipo. O achado guarda um fingerprint com chave, para que quem investiga possa perguntar “onde mais esse valor apareceu” sem que o armazenamento de achados se torne mais uma cópia. E a limpeza se aplica ao que o modelo vai ler, enquanto o original, se precisar ser mantido, vive em um armazenamento restrito, com retenção e lista de acesso próprias.

O que acontece diante de uma ocorrência depende de quem era o secret. Se este sistema o emitiu, a resposta é mecânica: tratar como comprometido, expirar, registrar o run e deixar a próxima chamada usar um novo. Se era o secret de outra pessoa em um log, o scrubber trouxe à tona um defeito na origem, e o sistema abre um achado para a equipe responsável

pelo logging; nenhum scrubber a jusante conserta uma senha impressa na inicialização. O detector não é uma garantia, e precisa de um responsável que o ajuste como qualquer outro alerta.

Nota: O detector de valores conhecidos protege apenas o que o sistema sabe que emitiu. Uma credencial que ele nunca emitiu, como uma colada em um runbook, é trabalho do detector de padrões.

Pull requests e código gerado

Os pull requests do agente de ops são o caminho de vazamento mais específico deste agente, porque o modelo compõe o conteúdo. Um diff montado a partir de observações pode carregar tudo o que as observações carregavam, e um modelo a quem se pede que escreva uma fixture de teste pode produzir uma string com o formato de uma credencial real. Depois que um branch é enviado, o conteúdo dele está no code host, em clones e em notificações, e remover um secret do histórico é uma limpeza que ninguém quer fazer.

Por isso o controle é uma pré-condição no contrato acima, executada pelo gateway de ferramentas antes de a chamada chegar ao code host. A verificação de valores conhecidos precisa dos valores emitidos, mas o gateway não deve reuni-los: um lugar que reúne valores vivos de outros runs e serviços os vaza como conjunto a partir de um único crash dump. Então ele envia o texto ao serviço de credenciais e recebe apenas ocorrências, um tipo e uma localização, nunca um valor; o próprio gateway executa apenas os detectores de padrões. Se o serviço de credenciais não puder comparar no lugar, ele pode expor hashes com chave dos valores emitidos, e o gateway guarda fingerprints, não secrets. A comparação se restringe aos valores emitidos para este run; um valor emitido para outro run ou agente só chega ao diff pelos detectores de padrões. A recusa no próximo bloco carrega uma localização e um tipo e nunca o texto encontrado, de modo que a observação não possa se tornar um segundo vazamento.

```

function checkPullRequestDiff(call):           // precondition of
open_pull_request
    texts = [{ where: "title", text: call.arguments.title },
              { where: "description", text: call.arguments.description }]
    for each change in call.arguments.changes:
        if change.path matches deniedPaths(): // key files, credential
files, env files
            return refuse("precondition_failed", { check: "denied_path",
path: change.path })
        texts.add({ where: change.path, text: change.new_content })
    for each item in texts:
        // issued values: compared inside the credential service, which
already holds them;
        // only kind and location come back, never a value
        hit = credentialService.matchIssued(item.text, scope: call.run)
        // shapes: pattern detectors run here, and need no secret to work
        hit = hit or scanPatterns(item.text)
        if hit is not empty:
            return refuse("precondition_failed",
                { check: "secret_in_diff", path: item.where, kind:
hit.first.kind }) // no value, no line content
    return pass // the code host's own
scanning is a second layer

```

Conto três camadas. A lista de caminhos negados barra categorias inteiras de arquivo, independentemente do conteúdo. O scan barra valores com formatos conhecidos e todo valor emitido para este run. O scanning de secrets do próprio code host, se oferecido, pega o que um detector diferente enxerga. Nenhuma delas depende do revisor: uma pessoa que lê um diff de 40 linhas em busca de lógica é ruim em encontrar uma string de 40 caracteres, e contar com isso é teatro.

Uma recusa custa um passo; os limites do Capítulo 12 e do Capítulo 13 detêm um modelo que se repete.

Traces, checkpoints e memória

O Registro é onde um vazamento dura mais, porque ele é escrito para ser mantido e lido por muita gente. Três regras se aplicam, e o Capítulo 20 e o Capítulo 17 trazem os detalhes do pipeline de traces e do redaction em geral.

Primeiro, limpar antes de gravar, com a mesma função, no ponto em que o registro é construído; um trace limpo por um job noturno guarda o secret até o job rodar, e um backup o guarda depois. Segundo, capturar identificadores e não valores: o id da credencial, o escopo e a expiração, o que responde à primeira pergunta de toda resposta a vazamento, qual creden-

cial um run usou. Terceiro, revisar os padrões da instrumentação: o tracing genérico de requisições pode capturar headers de autorização, então a captura é um allowlist de campos aplicado pelo pipeline, com um denylist de headers de credenciais conhecidos como rede de segurança.

A memória tem mais uma regra. Uma nota como “o host e a senha do banco de dados de staging para a próxima vez” é útil para um modelo e perigosa para todo o resto. O Capítulo 11 trata as escritas na memória como entrada não confiável, com um gate próprio; o acréscimo específico de secrets é que o gate executa o scrubber e recusa uma nota com achado, dizendo o tipo. Um fato durável sobre uma credencial pertence ao inventário como “qual credencial, quem é o responsável por ela”, nunca o valor.

Mensagens de erro e o que os humanos veem

Uma pessoa que aprova uma ação vê a chamada exata (Capítulo 15), que não contém credencial, então a tela de aprovação não mostra credencial desde que seja renderizada a partir do registro da chamada e não da saída bruta da ferramenta. O mesmo vale para o resumo de `escalate_to_human` e para o rascunho a partir do qual uma resposta de suporte é montada.

As mensagens de erro são um caminho menos óbvio, porque os serviços upstream descrevem a requisição que receberam. O tool runtime mapeia uma falha do upstream para uma classe de erro e uma mensagem escrita pelo código da Parcelport; o corpo bruto permanece em um caminho restrito.

O que o provedor do modelo vê

Mais um caminho que a equipe não pode inspecionar: todo contexto vai ao provedor do modelo por meio do gateway, então um secret no contexto saiu da fronteira da Parcelport, sejam quais forem as políticas do provedor. Os termos de retenção e de uso são uma questão contratual para o jurídico e a conformidade, e os regimes de proteção de dados vão perguntar para onde esses dados vão. “O secret nunca esteve no contexto” não precisa de política de provedor para se sustentar.

Rotação e revogação

As credenciais de curta duração fazem a rotação sozinhas: a expiração faz o trabalho. As de longa duração, como a credencial do provedor do modelo ou uma chave de assinatura, só passam por rotação quando alguém a faz, e o motivo habitual para que não façam é que a rotação nunca foi ensaiada.

Projetando para a rotação

Trataria a rotação sem deploy como requisito para qualquer credencial de longa duração, porque uma que não pode passar por rotação discretamente tampouco passará durante um incidente. Três propriedades a tornam possível. O consumidor lê a credencial do seu armazenamento de secrets no momento do uso, ou a atualiza em um intervalo curto, e não a embute em uma imagem nem em um arquivo de configuração. O sistema que valida aceita o valor antigo e o novo durante uma janela de sobreposição. E cada credencial tem um responsável nomeado e uma programação no inventário, com um registro da última rotação.

As janelas de sobreposição dobram as credenciais válidas por um tempo; um dry run com a lista de consumidores do inventário é mais barato que a indisponibilidade que um consumidor esquecido causa.

Revogando tudo o que um agente poderia tocar

Quando se suspeita do vazamento das credenciais de um agente, a primeira pergunta é com que rapidez o sistema consegue fazer parar de funcionar tudo o que aquele agente detinha. A resposta deve ser uma operação, não um projeto de pesquisa. Isso exige um registro que ligue cada credencial ao agente e ao run para os quais foi emitida, e é por isso que o serviço de credenciais armazena o principal com cada grant, além de um caminho de revogação para cada sistema que aceita credenciais.

```

function revokeAgentCredentials(agent, reason):
    freezeIssuance(agent)                // first: nothing new is
issued
    results = []
    for each system in [credentialService, codeHost, deployService,
modelGateway]:
        try:
            system.revokeAllFor(agent, reason: reason)    // idempotent:
safe to repeat
            results.add({ system: system.name, status: "revoked" })
        on RevocationFailed:
            results.add({ system: system.name, status: "failed" })    // keep
going
        live = listLiveCredentials(agent)                // a separate query, not
the call's return
        record(agent.incident, "revocation", { results: results, still_live:
live.ids })
        if live is not empty or any result failed:
            escalate("revocation incomplete")            // a person owns what the
code could not do
        for each run in activeRuns(agent):
            handOff(run, reason: "credentials_revoked")    // run becomes
handed_off (Chapter 10)

```

A ordem é a lição. Congelar primeiro, para que uma revogação em andamento não seja desfeita por uma nova emissão. Continuar depois de uma falha, porque parar no primeiro sistema que falhou deixa o resto vivo. Verificar com uma consulta separada, porque “revogado” vindo de um sistema fora do ar ou parcialmente aplicado é uma afirmação, não evidência. E entregar os runs em andamento a uma pessoa: um efeito que estava no meio de uma chamada tem resultado desconhecido, e o sweep de reconciliação do Capítulo 10 o resolve.

A revogação é um modo degradado: os runs param, os tickets esperam, Robin recebe um page. Esse é o motivo para praticá-la, já que um interruptor que ninguém acionou é uma hipótese. O Capítulo 23 trata do incidente em torno desta etapa.

Uma terça-feira, com os controles no lugar

Volte à abertura. `query_logs` devolve a linha de inicialização com a connection string, e desta vez o resultado passa pelo scrubber na fronteira da ferramenta. A observação diz, em essência, “linha de inicialização, com uma senha de banco de dados substituída por

`<secret:connection_string>`”, o run registra um achado com um fingerprint, e os responsáveis pelo logging do serviço são solicitados a fazer a rotação dessa senha, porque o log store já guarda o original.

No passo seis, o modelo propõe um pull request que altera um timeout. O gate verifica o contrato: o repositório está na delegação, os caminhos não são negados, e o scan não encontra nada, já que a observação citada traz o placeholder. O gateway de ferramentas emite um grant para um repositório e um prefixo de branch, o code host abre o branch, e a credencial expira minutos depois. O gate de escrita na memória não vê achado na nota que lhe pedem para armazenar.

Agora pergunte o que cada camada barrou e o que sobra. A tabela diz isso com honestidade.

Camada	O que barrou aqui	O que não barra
Injeção de credenciais	O agente nunca deteve a credencial do code host	Um secret que chega nos dados
Scrubber na fronteira da ferramenta	A connection string chegando ao contexto, ao trace e à memória	Um secret cujo formato nenhum detector conhece
Pré-condição de diff e texto	Um secret chegando ao code host pelo pull request, com valores emitidos para este run comparados sem sair do serviço de credenciais	Um secret dividido em várias linhas ou codificado de um modo que o scanner não pega, ou um valor emitido para outro run ou agente
Grant estreito e de curta duração	O valor da credencial do code host, caso vazasse	Qualquer coisa que o escopo dela permitisse nesses minutos
Achado e rotação	O defeito na origem e a cópia armazenada	O intervalo entre a linha de log e a rotação

Trade-offs e custos

Custa um sistema a manter disponível e um salto em cada efeito. O serviço de credenciais e o scrub ficam no caminho de toda chamada de ferramenta. Se o serviço de credenciais cair, o agente não pode agir, então a equipe de Alex precisa de um responsável, um alerta e um modo degradado declarado, que para o agente de ops costuma ser “passar o caso ao engenheiro de on-call”. A latência adicional é pequena perto de uma chamada ao modelo; o Capítulo 22 conta o custo por run. O serviço de cre-

denciais também recebe como entrada, para comparação, texto que o modelo escreveu, então precisa tratar esse texto como dado e nunca como instruções.

O scrubber tem um custo de falso positivo e um custo de falso negativo. O redaction excessivo remove identificadores de que uma investigação precisa, e uma equipe que descobre isso no meio de um incidente deixa de confiar na saída; o redaction insuficiente deixa passar secrets reais. Meça o que é detectado, revise uma amostra de acertos e de falhas de forma programada, e mantenha à frente o detector de valores conhecidos, que tem menos dúvida.

Rotação e revogação custam pessoas. Ensaios, um inventário atualizado e achados sobre logs na origem são trabalho recorrente, e um controle sem responsável é o primeiro a se desgastar.

O padrão completo não é de graça para adotar. Uma equipe com um agente, uma ferramenta somente de leitura e um token estreito em um armazenamento de secrets gerenciado pode razoavelmente parar antes de construir um serviço de credenciais: uma única credencial estreita mantida pelo tool runtime, com um scrubber nas saídas, captura a maior parte do valor. Dimensione o aparato de acordo com o dano que um vazamento poderia causar, como o Capítulo 7 faz com a autoridade.

Ele não protege contra o que uma credencial legítima permite. Uma credencial estreita usada dentro do seu escopo está funcionando como projetado; se a chamada deveria ter sido feita é assunto do gate e da aprovação.

Erros comuns

- **Colocar a credencial no prompt ou nos argumentos da ferramenta “para que o modelo possa chamar a API”.** É tentador porque faz uma demo funcionar numa tarde. Isso coloca o valor no contexto, no trace e na requisição ao provedor. Dê a credencial ao tool runtime, e dê ao modelo um nome para o recurso.
- **Confiar em uma instrução para não revelar secrets.** É tentador porque é uma linha só e “resolve” visivelmente o risco. A frase reduz a taxa de citações e não faz nada pelo trace, pelo checkpoint ou pelo

pull request. Mantenha a frase se ajudar, e nomeie os controles que se sustentam quando ela não se sustenta.

- **Limpar apenas a resposta final.** Filtrar a saída parece o lugar natural porque é onde um humano lê. Os caminhos de vazamento passam por observações, traces e escritas. Limpe em cada fronteira que o valor pode cruzar, começando por onde ele entra.
- **Confiar em um detector de padrões como garantia.** É tentador porque a demo pega todas as chaves plantadas. Ele é um classificador. Combine-o com o detector de valores conhecidos, com credenciais estreitas que tornam uma falha barata e com um achado na origem que corrija o defeito.
- **Deixar credenciais de longa duração sem caminho de rotação porque elas “funcionam”.** É tentador porque a rotação não tem retorno visível até o incidente. Uma credencial que não pode passar por rotação sem um deploy não passará durante um incidente. Torne a rotação rotineira antes de precisar dela.
- **Contar com o revisor para pegar um secret em um diff.** É tentador porque a revisão já existe e não custa nada novo. Revisores leem em busca de lógica, e um humano é ruim em identificar uma string em um diff. Escaneie em código antes do push e trate o revisor como a segunda linha.
- **Fazer trace de tudo por padrão.** É tentador porque traces completos facilitam a depuração. Uma instrumentação genérica que registra headers e corpos faz de cada nova ferramenta um vazamento. Capture identificadores por padrão, use allowlist para o que é capturado e revise o pipeline quando uma ferramenta for adicionada.
- **Reunir todos os valores de credenciais vivas em um scanner.** É tentador porque a comparação exata é a verificação mais precisa. Isso transforma o scanner em um armazenamento de secrets; compare onde os valores vivem e devolva apenas tipo e localização, ou compare fingerprints.
- **Escrever o procedimento de revogação e nunca executá-lo.** É tentador porque o documento parece prontidão. A simulação descobre o sistema sem chamada de revogação. É mais barato do que descobri-lo no incidente.

Pontos-chave

- Um secret nunca entra no contexto do modelo; o tool runtime injeta a credencial fora do modelo, de modo que o modelo nomeia um recurso e a camada de efeito fornece a autoridade.
- Feche todo esquema de ferramenta a campos de credenciais, porque uma proposta que tenta passar um deles é malformada e o gate a recusa antes que qualquer coisa execute.
- Prefira credenciais de curta duração, estreitas e atreladas a um run, emitidas a partir de uma workload identity e não de um secret armazenado, e mantenha uma lista honesta do secret de bootstrap e das credenciais de longa duração que restam.
- Suponha que secrets ainda vão chegar do mundo, e limpe na fronteira com dois detectores: um determinístico para os valores que o sistema emitiu e um probabilístico para formatos, com seus erros e falsos positivos contabilizados.
- Condicione todo `open_pull_request` a uma lista de caminhos negados e a um scan de secrets do diff e do texto, devolva o tipo e a localização do achado mas nunca o valor, e não conte o revisor humano como o controle.
- Registre ids de credenciais e fingerprints de achados, nunca valores, e limpe antes de gravar em traces, checkpoints e memória, já que o Registro é onde um vazamento dura mais.
- Torne a rotação rotineira e revogue por principal como uma única operação ensaiada, que congela a emissão, continua depois de falhas, verifica com uma consulta separada e entrega a uma pessoa os efeitos inacabados.

A credencial nunca chegar ao modelo deixa uma segunda pergunta para o código que o modelo propõe: quando `run_diagnostic` executa um script, o que esse script pode alcançar, e quem decide? O Capítulo 19 passa ao sandbox.

Capítulo 19 — Sandboxing

Imagine a primeira versão de `run_diagnostic` na Parcelport. Robin, o SRE de on-call, está investigando um lote lento de entregas. O agente de ops leu os logs e um trace, e propõe um script curto: analisar uma amostra armazenada de linhas de log, agrupar os erros por transportadora, imprimir uma tabela. O orquestrador grava o script em um diretório temporário no próprio host, o executa com o mesmo usuário e devolve o que ele imprimir.

O script funciona. Ele também tem o ambiente do orquestrador, porque é isso que um processo filho herda. No caminho, ele lista alguns diretórios para encontrar a amostra, e um dos arquivos que lê é um arquivo de configuração que guarda um token de serviço. Nada disso é malicioso: o script imprimiu o que viu, e a saída foi parar no contexto do modelo, no trace e no run store.

Um script escrito por um modelo é um programa que ninguém revisou, e ele rodou com a autoridade do processo que o iniciou. Este capítulo pertence à parte **Efeito** do envelope de controle: como uma ação aprovada chega ao mundo, o que a limita e o que pode desfazê-la. Quando a ação é “executar este código”, qual é o mundo que o código pode alcançar, e quem decidiu isso?

O problema e por que ele é difícil

Toda outra ferramenta deste livro recebe argumentos. Um contrato de ferramenta pode descrever esses argumentos com um esquema, o gate pode verificá-los contra pré-condições, e o próprio código da ferramenta decide o que acontece. O conjunto de coisas que uma chamada pode fazer é fixado pela ferramenta, e o modelo apenas escolhe valores dentro dele.

Um script é diferente. O modelo fornece um programa, e um programa não tem esquema que limite o que ele faz: pode abrir arquivos, iniciar processos e fazer conexões de rede. A proposta não são dados sobre uma

ação, mas a própria ação, com seu alcance decidido por onde ela roda.

As classes de falha decorrem disso. A mais direta é F7 (efeito não autorizado): o script faz algo que seu principal não deveria ter conseguido causar, usando uma autoridade que herdou e que ninguém emitiu. Logo atrás vem F9 (explosão de custo ou latência), quando um loop ou uma análise que consome muita memória leva consigo o host ou o orçamento. F6 (falha parcial silenciosa) aparece quando um script que grava algo é morto no meio e nada avisa, e F8 (comportamento não observado) quando a única evidência é o que o script resolveu imprimir. F4 (sequestro de instruções) entra duas vezes: um script pode ter sido moldado por conteúdo injetado nos logs que o modelo leu (Capítulo 16), e o que ele imprime volta para o contexto.

Por que as abordagens óbvias não se sustentam

O primeiro instinto é revisar o script antes de ele rodar. Uma pessoa não consegue fazer isso na velocidade de um loop, e um programa não consegue decidir, em geral, o que outro programa fará. Verificações estáticas filtram; não são uma fronteira.

O segundo é restringir a linguagem a um subconjunto seguro ou a uma lista de comandos. O Capítulo 6 reduz o espaço de propostas sempre que pode, mas um diagnóstico é valioso por ser flexível, e toda restrição que fecha uma brecha também elimina uma análise legítima.

O terceiro é dizer ao modelo que não leia arquivos nem chame hosts que não deve. Isso reduz a taxa de scripts desse tipo e não se sustenta no dia em que um for proposto mesmo assim (Capítulo 16). Se a propriedade importa, o ambiente é que tem de impô-la.

O argumento deste capítulo: **suponha que o código está errado ou é hostil, e construa o lugar onde ele roda de modo que essa suposição custe pouco.**

Um diretório temporário não é um sandbox

Executar um script em um diretório temporário recém-criado dá a sensação de isolamento. Não é isolamento. Tampouco o é apontar o diretório home do script para outro lugar, limpar suas variáveis de ambiente ou executá-lo a partir de um diretório de trabalho diferente.

Cada uma dessas mudanças altera onde um código bem-comportado procura as coisas, não o que o código consegue alcançar. O script continua rodando com o mesmo usuário, com os mesmos arquivos, a mesma rede, os mesmos keystores e a mesma capacidade de iniciar processos. Um caminho é uma convenção, e um script que não a segue não é detido.

Um sandbox, no sentido deste livro, é um ambiente de execução com limites impostos sobre o que o código pode alcançar em arquivos, rede e credenciais. “Impostos” quer dizer por algo com que o código não consegue negociar: um usuário separado, ou um contêiner, ou uma máquina virtual, uma rede fechada ou restrita a um allowlist, e um sistema de arquivos que contém apenas o diretório de trabalho. Se o ambiente não é separado de uma dessas formas, é um diretório temporário com um nome bonito.

O sandbox como fronteira de confiança

Uma fronteira de confiança, como o Capítulo 8 usou o termo, é uma linha atravessada por dados ou autoridade vindos de uma fonte que você não controla. O sandbox traça essa linha em torno do código. Dentro está um programa que o orquestrador não escreveu. Fora está tudo o que a Parcelport controla: o log store, o run store, a rede, as credenciais.

Duas coisas cruzam a linha, e o design consiste em tornar ambas estreitas. Entradas vão para dentro: o texto do script e os dados com que ele trabalha. Saídas vêm para fora: o que o script imprimiu, os arquivos que produziu e a maneira como terminou. Nada mais cruza.

O sandbox precisa impor seis propriedades.

- **Arquivos.** O script vê apenas o que o orquestrador preparou para ele e grava apenas em uma área de rascunho.
- **Rede.** Fechada por padrão, com exceções nomeadas e justificadas.
- **Recursos.** CPU, memória, processos, disco e tempo de relógio são limitados, e exceder um limite encerra o run.
- **Identidade.** O código roda como um principal próprio, distinto do orquestrador e de qualquer pessoa.
- **Credenciais.** Nenhuma, ou o menor conjunto de que a tarefa precisa (o Capítulo 18 trata de como as credenciais são emitidas e por que o modelo nunca as detém).

- **Tempo de vida.** O ambiente é criado para uma execução e destruído depois.

Escolhendo o mecanismo de isolamento

Os mecanismos de isolamento diferem no que o código e o host compartilham, e o que compartilham é onde uma falha do sandbox vira uma falha do host. A tabela descreve classes, não produtos, e os custos são relativos.

Mecanismo	O que é compartilhado com o host	Força do isolamento	Custo típico
Processo separado, usuário separado	Kernel, sistema de arquivos, rede, a maior parte da máquina	O mais fraco; limita apenas o que as permissões limitam	O mais baixo; trivial de iniciar
Contêiner	O kernel do host; o isolamento vem de recursos do kernel que delimitam o que um processo vê e usa	Moderada; uma falha no kernel compartilhado é uma falha na fronteira	Baixo; inicia rápido, ferramentas conhecidas
Contêiner com filtro de syscalls ou kernel em espaço de usuário	Uma interface de kernel reduzida ou reimplementada	Mais forte que um contêiner simples, depende da cobertura do filtro	Moderado; alguns programas se comportam de forma diferente ou falham
Máquina virtual	Hardware, por meio de um hipervisor; o código tem seu próprio kernel	Forte; a superfície compartilhada é menor e mais estudada	Mais alto; início mais lento, mais memória, mais a operar
microVM	Hardware, por meio de um hipervisor mínimo com um conjunto reduzido de dispositivos	Forte, de natureza semelhante à de uma máquina virtual	Entre contêiner e máquina virtual; exige ferramentas próprias

Escolheria fazendo uma pergunta: quem escreveu o código, e quanto você confia nessa resposta? Um script fixo de catálogo, que os engenheiros da Parcelport escreveram e revisaram, pode rodar em um contêiner reforçado, porque o código é conhecido e o sandbox é uma segunda linha de defesa. Um script que o modelo compõe é código arbitrário. Começaria essa classe de execução em uma máquina virtual ou em uma microVM, e passaria a algo mais leve só depois de pesar o que uma falha de fronteira custaria.

As camadas

Nenhum limite isolado é o sandbox. Cada camada abaixo é um controle separado, existente para o dia em que outro for configurado errado, e cada uma é imposta fora do código que restringe.

O sistema de arquivos: um diretório de trabalho e uma raiz somente de leitura

O sistema de arquivos raiz do sandbox é somente de leitura. Ele contém o interpretador e as bibliotecas que o script pode usar, preparados com antecedência, e mais nada. O script não pode modificá-lo e não pode instalar nada nele.

Sobre essa raiz ficam dois mounts. Um é a área de entrada, montada somente para leitura, onde o orquestrador colocou a amostra armazenada e quaisquer parâmetros. O outro é uma área de rascunho e saída, gravável, com tamanho limitado, descartada junto com o sandbox. Tudo o que o script pode ver está nesses três lugares.

Duas coisas ficam fora do sistema de arquivos por construção: a configuração do orquestrador e os diretórios home do host. Elas não estão escondidas por caminho, mas ausentes, como um arquivo em outra máquina está ausente.

As dependências são embutidas na imagem. Um script que instala bibliotecas em tempo de execução precisa de acesso à rede, executa código não revisado e dá resultados diferentes em dias diferentes. O profile nomeia a versão da imagem, de modo que um run possa dizer depois exatamente em que rodou.

A rede: fechada por padrão

O padrão é nenhuma rede: nenhuma conexão de saída, nenhuma de entrada, nenhuma resolução de nomes. É o que o `run_diagnostic` do livro tem, e é o padrão certo para um diagnóstico cujas entradas já foram preparadas.

Quando uma tarefa em sandbox realmente precisa alcançar algo, a exceção é feita no ponto de **egress**: o tráfego que sai do ambiente passa por um proxy ou um gateway que mantém um allowlist de destinos e é opera-

do fora do sandbox. O allowlist nomeia destinos específicos e o motivo de cada um. Ela é imposta pelo caminho de rede, e não pela boa educação do script.

A fraqueza habitual é a amplitude de um destino. Uma entrada do allowlist para um serviço de hospedagem de uso geral, um code host ou um serviço público de paste é, na prática, um canal aberto, porque qualquer coisa pode ser enviada para lá. Se o destino puder levar dados a uma parte que a Parcelport não controla, trate-o como egress aberto no modelo de ameaças.

Recursos: CPU, memória, processos, disco e tempo

Um script sem limite pode consumir a máquina. Os limites são tempo de CPU, memória, número de processos que o script pode iniciar, disco gravado no rascunho e tempo de relógio. O profile mais adiante no capítulo mostra valores ilustrativos aplicados.

Duas propriedades importam mais que os números. Primeiro, os limites são impostos pelo sandbox e não pelo script, de modo que um loop que nunca termina é encerrado de fora. Segundo, atingir um limite é um resultado nomeado, não um travamento: o sandbox é destruído e o resultado traz `exit: limit_exceeded` e o nome do limite atingido. Isso é um campo do resultado, não um código de erro. Um diagnóstico morto pelo seu deadline é um resultado normal sobre o qual o loop pode raciocinar (Capítulo 12), contabilizado no orçamento do run (Capítulo 13).

Identidade e credenciais

O script roda com uma identidade que existe apenas para código em sandbox, que não é a do orquestrador nem a de uma pessoa. Uma auditoria consegue, assim, distinguir a atividade do sandbox da atividade do orquestrador mesmo que um limite em outro lugar falhe.

A regra de credenciais para o sandbox de diagnóstico é a mais forte possível: nenhuma. A tabela do Capítulo 7 diz que `run_diagnostic` não precisa de credencial porque o sandbox não tem nenhuma para dar; aqui essa frase se torna uma propriedade imposta.

Nem todo sandbox pode ser tão despojado. Uma tarefa que lê de um serviço interno receberia a menor credencial que funcione, emitida por run e revogada na conclusão (mecânica no Capítulo 18). A ordem de preferência é: nenhuma credencial; depois, uma credencial fora do sandbox que um proxy anexa a uma requisição permitida; depois, uma credencial de curta duração dentro dele, sendo cada passo para baixo na lista uma decisão deliberada.

Efêmero por design

Cada run recebe um sandbox novo, criado a partir da mesma imagem e do mesmo profile e destruído quando o run termina. Nada se transfere: nem arquivos, nem processos, nem estado em cache. Uma execução comprometida ou confusa vive por um run, e o início limpo torna os runs reproduzíveis para depuração e evals (Capítulo 21).

O sandbox de diagnóstico na Parcelport

Agora reúna as camadas para `run_diagnostic`. A ferramenta é classificada como leitura, e essa classe só é verdadeira por causa do sandbox: um script que pudesse gravar em um serviço ou enviar dados para fora não seria uma leitura. O contrato é uma declaração sobre o sandbox tanto quanto sobre a ferramenta, e diria isso no próprio contrato. Ele usa a notação do Capítulo 6; os números são ilustrativos.

```

tool run_diagnostic
  description: "Run a script against a stored sample inside an isolated
  sandbox
    and return its bounded output."
  input schema:                // fields the model supplies
    type: object, additionalProperties: false
    required: [script_source, sample_id]
    properties:
      script_source: { type: string, maxLength: 20000 } // illustrative
      sample_id:     { type: string } // an id of a sample the run already
owns
  effect class: read            // holds only while the profile
holds
  preconditions:                // checked by the gate, not the
model
  - sample_id was stored by an earlier read call in this run
  - the sandbox profile is "diagnostic_v1", set by the orchestrator
  - no egress and no credentials are configured in the profile
  idempotency: // not applicable: a read; repeating a call changes nothing
  // outside the sandbox. Each execution counts against the run's bounds;
  // exceeding them raises BoundExceeded (Chapter 13), not a tool error.
  permissions: scope "diagnostics:run"; the sandbox identity holds no scope
  timeouts: execution deadline 120s, call deadline 150s // illustrative
  error shape: { code, message, retryable, details }
  // code in [invalid_arguments, precondition_failed, not_permitted,
  //   upstream_unavailable]
  // a script that fails or hits a limit is a result, not a tool error:
  //   result: { exit: finished | error | limit_exceeded, limit, output }

```

O modelo fornece o script e o id de uma amostra. Ele não escolhe o profile, a imagem, os limites nem a rede; o orquestrador define isso e o gate verifica o profile. O modelo propõe um programa, mas o mundo em que o programa vive não faz parte da proposta.

O script não busca os próprios dados, porque buscar exige credenciais e rede. Uma chamada anterior a `query_logs`, já verificada pelo gate, produziu a amostra, e o sandbox recebe uma cópia somente de leitura.

O profile

O profile é dado, escrito e versionado, não prosa em um prompt. A notação abaixo é ilustrativa e não é a sintaxe de configuração de nenhum produto.

```

profile diagnostic_v1:                // illustrative notation
  isolation: microVM                  // one per execution
  image: "diagnostic-base@version-0007" // dependencies baked in
  filesystem:
    root: read-only
    mount "/input": { source: staged sample, mode: read-only }
    mount "/scratch": { mode: read-write, max_size: "256 MB" }
  network: none                       // no egress, no name resolution
  credentials: none
  identity: "sandbox-diagnostic"       // not the orchestrator's identity
  limits: { cpu_cores: 2, memory: "1 GB", processes: 100, wall_clock: "120s"
}
  output: { max_bytes: 65536, files: ["/scratch/result.json"] }
  lifetime: destroy on completion, on any limit, and after 5 minutes
  regardless

```

Um revisor pode responder a toda pergunta a partir deste bloco: o que o script pode ler e gravar, o que pode alcançar, de quem é a identidade que carrega e quando termina.

O ciclo de vida

O orquestrador é responsável pelo ciclo de vida, e o ciclo de vida é um lugar onde se aplica a regra do livro sobre sistemas separados. O sandbox manager e o sweep abaixo são componentes ilustrativos, não serviços do sistema de referência do livro. O manager, o run store e o pipeline de traces são sistemas separados, então nenhuma etapa isolada os abrange, e toda falha entre etapas precisa ser sobrevivível.

```

function runDiagnostic(run, call):
  record(run, "intent", call)           // before anything exists
  sandbox = sandboxManager.create(profile: "diagnostic_v1",
                                   owner: run.id)


  try:
    sandboxManager.stage(sandbox, call.sample_id, call.script_source)
    outcome = sandboxManager.execute(sandbox,
                                     deadline:
profile.limits.wall_clock)
    raw = sandboxManager.collect(sandbox, allowed: profile.output.files)
    on SandboxLimit as limit:
      outcome = { exit: "limit_exceeded", limit: limit.name }
      raw = empty
  finally:
    try: sandboxManager.destroy(sandbox) // always, even on error
    on DestroyFailed:                  // the sweep catches the
leftover
      record(run, "sandbox_leak", sandbox.id)
    result = packageOutput(outcome, raw) // untrusted, see below
    record(run, "effect", result)
    return result

```

Acompanhe as falhas. Se a criação falhar, nada existe e a chamada falha com `upstream_unavailable`; a intenção já está no registro. Se o orquestrador cair antes da destruição, existe um sandbox que nenhum run está esperando. A regra de tempo de vida do profile é imposta pelo manager, não pelo orquestrador, e um sweep periódico destrói os sandboxes cujo run proprietário terminou ou desapareceu. Uma contagem de destruídos diferente de zero merece um alerta.

Se a destruição falhar, o run registra um `sandbox_leak`, o resultado ainda é devolvido e o sweep pega o que sobrou. Se a chamada de registro falhar depois da destruição, o resultado se perde mas a intenção não; um run retomado (Capítulo 10) executa o diagnóstico de novo, e o contrato o classifica como leitura, então repeti-lo não muda nada.

O diagrama a seguir mostra o que cruza a fronteira e o que não cruza.



As duas setas que cruzam são estreitas: um script e uma amostra entram; um arquivo nomeado sai. Todo o resto termina em uma negação que pertence ao profile, não ao comportamento do script. Em comparação com o protótipo anterior, o profile remove tudo o que um processo filho tem por padrão, e um loop agora termina em um limite nomeado.

A saída do sandbox é entrada não confiável

O script terminou e imprimiu uma tabela. É tentador tratar a tabela como um resultado de ferramenta da Parcelport, porque ela veio da infraestrutura da Parcelport. Ela veio de um programa que o modelo escreveu, executado sobre dados que podem conter texto de clientes e de logs. Sua saída é entrada não confiável, exatamente como a proposta de um modelo.

O orquestrador faz quatro coisas antes que a saída chegue ao modelo.

1. **Limitá-la.** A saída tem um tamanho máximo, e o truncamento é declarado na observação. Uma saída sem limite é um problema de orçamento de contexto para o run (Capítulo 9) e um problema de custo (Capítulo 22).
2. **Moldá-la.** Apenas o arquivo de resultado nomeado sai, e o orquestrador o analisa como dado contra uma estrutura esperada, tratando uma falha de análise como F1 (saída malformada). Nada mais do que o script deixou no rascunho é aberto, executado ou renderizado.
3. **Escaneá-la.** A saída passa pelo scanning de secrets do Capítulo 18 e pelo redaction do Capítulo 17 antes de ser armazenada ou exibida. O sandbox não tem credenciais, mas os dados que ele recebeu podem conter um secret que uma linha de log repetiu, e o script pode imprimi-lo.
4. **Marcá-la.** O resultado entra no contexto rotulado com sua proveniência: produzido por um script, a partir de uma amostra armazenada, sob o profile `diagnostic_v1`. Ele carrega taint (Capítulo 16), porque um script que processou linhas de log pode estar reproduzindo texto escrito por outra pessoa.

A marcação é fácil de pular e cara de pular. A saída de um diagnóstico alimenta um loop que pode propor um pull request ou uma requisição de aprovação. Sem a marca, o texto que chegou dentro de uma linha de log alcança o contexto do modelo com todo sinal de sua origem removido. A marca de taint permite que o gate trate com cuidado um `open_pull_request` proposto depois a partir dela.

Testes de conformidade do sandbox

A imposição pode se desviar: uma imagem reconstruída com um padrão diferente, uma política de rede alterada para outra ferramenta. Testaria a própria fronteira, de forma programada e depois de toda mudança na imagem ou no profile. A equipe de plataforma executa uma sonda fixa e revisada em um sandbox com o profile de produção, e a sonda tenta o que o profile proíbe: ler um caminho que não deveria existir, alcançar um host inalcançável, exceder um limite. Cada sonda precisa falhar da maneira esperada, e uma sonda que falha bloqueia a liberação da nova imagem. Esses são testes de controles com um resultado claro de passou ou não passou, não evals do modelo, e a programação precisa de um responsável.

Observando um sandbox

Dentro do sandbox não há agente de tracing, por design: o script não tem rede por onde reportar nem credenciais com que se autenticar. A evidência é o que o sandbox manager coleta de fora, mais o que o script resolveu dizer.

O registro de cada execução deve conter o id do profile e a versão da imagem, um hash do script, o id da amostra, o motivo da saída (finished, error, `limit_exceeded` e qual limite), o pico de memória e de CPU conforme o manager mediu, o tamanho da saída e se ela foi truncada, e o número de operações negadas, se a camada do sandbox as contar. Uma tentativa de conexão negada significa que um diagnóstico está quebrado ou está sendo conduzido, e alguém deve olhar. O Capítulo 20 trata do formato do span; aqui a testemunha é o manager, não o script.

Nota: Os comandos de impressão do próprio script são evidência do que o script disse, não do que ele fez. Mantenha os dois separados no registro. Uma auditoria que depende da saída para reconstruir o comportamento entregou o banco das testemunhas ao réu.

O texto do script pertence ao trace, já que um run que você não consegue reproduzir é um run que você não consegue explicar. Ele pode conter dados copiados da amostra, então o mesmo redaction se aplica ao texto armazenado (Capítulo 17).

Trade-offs e custos

Cada camada acima tem um preço, e o preço é pago por pessoas específicas.

Latência de inicialização. Um sandbox novo para cada run significa que todo run começa a frio, e uma máquina virtual ou microVM inicia mais devagar que um contêiner. Um loop que executa um script a cada passo soma essa inicialização ao limite de tempo de relógio do run. Um pool de sandboxes pré-criados, entregues limpos, troca tempo de inicialização por um ciclo de vida mais complexo, e o pool precisa garantir que nenhum

sandbox seja reutilizado. Se a reutilização for algum dia permitida, o “efêmero” acabou, e isso deve ser uma decisão registrada e não uma otimização silenciosa.

Custo de operação. Uma frota de sandboxes é um sistema que alguém mantém disponível, atualizado e medido. O sandbox manager é uma nova dependência do agente de ops; quando está fora do ar, a ferramenta falha com `upstream_unavailable`, e o modo degradado (Capítulo 14) é continuar sem diagnósticos e dizer isso. Uma equipe pequena demais para operar a frota deve considerar um serviço de sandbox gerenciado, e então tratar esse serviço como uma fronteira de confiança como qualquer outra (Capítulo 8).

Utilidade limitada. Uma rede fechada e uma raiz somente de leitura significam que algumas análises não podem rodar: buscar uma tabela de referência, chamar um serviço, usar uma biblioteca que não está na imagem. Cada uma é um pedido de exceção, e cada exceção é uma decisão com um responsável. Prepare os dados ou adicione a biblioteca à imagem em vez de abrir a rede.

Visibilidade reduzida. Depurar um script que falha significa ler o registro do manager e uma saída capturada, não se conectar ao processo, e a equipe tem de decidir quanta ferramenta de replay construir.

Atrito para os autores. A equipe de plataforma é responsável pelo profile e pela imagem, e toda mudança passa por uma revisão, então o engenheiro de on-call espera. Diga no runbook quem aprova uma mudança de profile e quanto tempo leva.

Quando não usar, ou quando menos basta

Nem toda execução precisa de uma microVM. Código que os engenheiros da Parcelport escreveram e revisaram, sobre dados preparados, sem acesso de escrita e sem rede, pode rodar em um contêiner reforçado.

O sandbox reduz o raio de impacto ao que o profile permite e não pode proteger contra o que o profile de fato permite: uma credencial dentro dele é uma que o script tem, e um destino permitido é um para o qual ele pode enviar dados. Nenhum mecanismo de isolamento é uma garantia, daí as camadas e os testes de conformidade.

Erros comuns

- **Chamar um diretório temporário de sandbox.** É tentador porque é fácil e o script “funcionou isolado”. O sinal revelador é que o script ainda tem o usuário, a rede e os arquivos do host. A correção é um usuário, contêiner ou máquina virtual separado, com o sistema de arquivos e a rede impostos de fora.
- **Abrir a rede para uma exceção.** A primeira exceção é barata, e a segunda vem atrás. A correção é preparar os dados com antecedência ou rotear o único destino por um proxy de egress com um allowlist, escrito com seu motivo e um responsável.
- **Repassar o ambiente do orquestrador.** As variáveis de ambiente são o lugar habitual onde uma credencial pega carona. É tentador porque o script precisa de um caminho ou de uma configuração e o ambiente já está ali. A correção é um sandbox que começa com um ambiente vazio e recebe apenas entradas nomeadas, e uma sonda de conformidade que verifica isso.
- **Tratar a saída como confiável porque o sandbox é.** É tentador porque a saída veio da própria infraestrutura da Parcelport. O sandbox contém o código. Ele não limpa o que o código devolve. A correção é a sequência limitar, moldar, escanear e marcar, com taint levado ao contexto.
- **Reutilizar um sandbox por velocidade.** É tentador porque uma partida a frio custa tempo e um sandbox aquecido já está esperando. Um sandbox aquecido é um lugar onde o estado de um run pode alcançar o seguinte. A correção é um pool de instâncias limpas, destruídas após o uso, e uma decisão deliberada no registro se a reutilização for algum dia desejada.
- **Confiar que o script respeitará os limites.** É tentador porque um script bem escrito de fato para. Um script a quem se pede que pare após dois minutos está fazendo uma promessa. A correção são limites impostos de fora pelo sandbox manager e uma regra de tempo de vida que vale mesmo que o orquestrador caia.
- **Nenhum sweep para sandboxes órfãos.** O ciclo de vida parece correto no happy path. A correção é um sweep periódico que encontre sandboxes sem proprietário vivo e uma métrica de quantos ele destruiu.

- **Deixar a classe de efeito do contrato sobreviver ao profile.** É tentador porque o contrato estava correto quando foi escrito. `run_diagnostic` é uma leitura porque o profile não tem rede nem credenciais. Se alguém adicionar uma das duas, a classe está errada e as suposições do gate também. A correção é uma pré-condição do gate que verifique o profile, e uma regra de revisão segundo a qual mudanças de profile reabrem o contrato.

Pontos-chave

- Executar código que o modelo produziu ou escolheu é uma fronteira de confiança separada, porque a proposta é um programa cujo alcance é decidido por onde ele roda, não por um esquema.
- Um diretório temporário, um caminho home alterado ou um ambiente limpo não é um sandbox; um sandbox é um usuário, contêiner ou máquina virtual separado, com uma rede fechada ou com allowlist e um sistema de arquivos limitado ao diretório de trabalho.
- Escolha o mecanismo de isolamento por quem escreveu o código: scripts de catálogo revisados podem rodar em um contêiner reforçado, enquanto código composto pelo modelo merece uma máquina virtual ou microVM, e a escolha é um trade-off entre tempo de inicialização, custo e operação.
- O modelo deve fornecer o script e o id de uma amostra, enquanto o orquestrador define o profile, a imagem, os limites e a rede, de modo que o mundo em que o código vive nunca faça parte da proposta.
- Prefira nenhuma credencial no sandbox, depois uma credencial mantida fora dele e anexada por um proxy, depois uma de curta duração dentro dele, e faça de cada passo uma decisão deliberada e registrada.
- A saída do sandbox é entrada não confiável: limite-a, analise apenas um arquivo de resultado nomeado como dado, escaneie-a e aplique redaction, e marque-a com proveniência e taint antes que entre no contexto.
- Um sandbox tem custos em partidas a frio, operação e visibilidade, e sua fronteira precisa de testes de conformidade programados, de um manager que testemunha cada execução de fora e de um sweep para os sandboxes que sobrevivem aos seus runs.

O sandbox mantém o código no seu lugar; ele não diz se o sistema está se comportando bem. A Parte VI se volta para essa pergunta, começando pelo Capítulo 20 e pelo que o trace de um run inteiro precisa conter.

PARTE VI

Comprovar e operar

Capítulo 20 — Observabilidade e tracing

Imagine uma manhã de sexta-feira na Parcelport. Sam, líder de suporte, encaminha a mensagem de um cliente que recebeu um reembolso e uma resposta que prometia uma data de entrega que ninguém encontra no pedido. Sam faz uma pergunta simples a Alex, responsável pelo orquestrador: o que o agente fez neste ticket?

Alex abre os lugares que poderiam saber. O sistema de tickets tem a resposta final. O `payments-service` tem o reembolso, com um valor e um timestamp. O log da aplicação do orquestrador tem uma linha dizendo que o run terminou. O que falta é tudo o que fica no meio: qual pedido o agente consultou, o que a consulta devolveu, quais propostas o gate recusou antes de esta passar, se uma pessoa aprovou alguma coisa, quantos passos o run levou e qual chamada ao modelo produziu a frase sobre a data. O reembolso é um fato. O caminho de raciocínio até ele é um palpite.

Alex consegue fazer um bom palpite, porque foi Alex quem escreveu o loop. Mas Sam pediu uma reconstituição, e a pessoa de on-call que receber o próximo page pode não ser Alex. Este capítulo responde a uma pergunta que pertence à parte **Registro** do envelope de controle: que evidência um run deixa, e ela basta para dizer o que aconteceu e por quê? Ele trata do que observar, de como dar forma a isso como um trace, do que guardar do conteúdo, de quais números derivar e de sobre o que alertar.

O problema e por que ele é difícil

A falha é F8 (comportamento não observado): o sistema fez algo e não deixou nenhuma evidência utilizável, de modo que ninguém consegue dizer o quê nem por quê. É a única classe de falha que pertence à parte Registro, e tem uma propriedade incomum entre as nove. As outras são coisas que o agente faz. F8 é o que acontece com a sua capacidade de enxer-

gar as outras. Um run que emite um reembolso errado é F2 (ferramenta incorreta ou argumentos incorretos). Um run que emite um reembolso errado e não deixa trace é F2 e F8, e a segunda é o motivo pelo qual a primeira leva uma semana para ser entendida.

A observabilidade de um agente é mais difícil do que a de um serviço convencional por quatro razões.

Primeiro, a pergunta interessante não é “a requisição falhou?”. Um run pode devolver uma resposta final limpa, dar apenas passos de aparência normal e ainda assim estar errado, porque uma afirmação da resposta não é sustentada por nenhum resultado de ferramenta (F3, afirmação sem fundamento). O código de status está certo. Se o comportamento foi correto, isso precisa ser lido no conteúdo do run, que é justamente a parte que mais se tem vontade de deixar de fora.

Segundo, o run é uma sequência de decisões, e a ordem importa. Um handler de requisição convencional tem um caminho de código que se pode ler. O caminho de um agente é produzido em tempo de execução por uma proposta do modelo a cada passo, então o caminho é dado, e só dá para conhecê-lo se ele foi registrado.

Terceiro, a evidência contém o material sensível. O contexto guarda o texto do ticket, campos do cliente e resultados de ferramentas; as propostas os repetem. Tudo o que torna um trace útil para depuração é o que o Capítulo 17 mandou minimizar. A tensão é real e não tem resolução gratuita.

Quarto, o volume é desigual. Um run de 15 passos (digamos) produz dezenas de spans, e cada chamada ao modelo pode carregar um payload grande. Guardar tudo, para todo mundo, por muito tempo, é caro, e amostar às cegas joga fora justamente o run de que você precisava.

A abordagem óbvia é registrar no log o que a aplicação já registra e acrescentar a entrada e a saída brutas do modelo “para depuração”. Isso produz uma pilha de linhas de texto sem estrutura: não dá para perguntar quais runs tocaram `issue_refund`, quanto tempo o gate levou ou quantos runs foram passados a uma pessoa na semana passada. Também coloca dados brutos de clientes no log store, contra o que o Capítulo 17 alerta. A segunda abordagem óbvia é uma linha de prompt como “explique o seu raciocínio”. A explicação do modelo é mais um texto do lado da proposta. Pode estar errada, pode estar ausente, e não diz nada sobre o que o gate deci-

diu nem sobre o que o efeito devolveu. O registro não pode ser algo que o modelo escreve sobre si mesmo. Ele é escrito pelo orquestrador, a partir de eventos determinísticos, em volta do modelo.

É por isso que esta é uma questão de engenharia. A observabilidade é uma propriedade do sistema de controle: onde os eventos são emitidos, o que carregam, o que acontece quando o pipeline está fora do ar, quem pode ler o conteúdo e por quanto tempo ele vive. Nada disso é alcançável a partir de um prompt.

O que um agente precisa permitir que você observe

Parta do loop do Capítulo 1 e pergunte, para cada ponto, o que uma pessoa precisaria para reconstituir o run. As setas pontilhadas do envelope de controle até o Registro são a resposta: contexto, proposta, gate, aprovação e efeito reportam todos. Sete tipos de coisa valem a pena ser observados.

Observável	O que responde	Parte do envelope
Run	Quem ou o que o iniciou, para qual tarefa, com quais versões, e como terminou	Registro
Passo	Qual passagem do loop, em que ordem, e quanto tempo levou	Limite
Chamada ao modelo	Qual modelo e versão, quantos tokens de entrada e de saída, quanto tempo, se devolveu uma proposta válida	Proposta
Chamada de ferramenta	Qual ferramenta, quais argumentos, qual classe de efeito, o resultado, o código de erro	Efeito
Decisão do gate	Allow, refuse ou needs approval, sob qual versão da política, e o motivo	Gate
Aprovação	Quem decidiu, quando, quanto tempo o run esperou e qual chamada exata foi aprovada	Gate
Consumo de orçamento	Quanto de cada orçamento o run já tinha usado em cada passo, e qual limite o interrompeu, se algum	Limite

Duas coisas dessa lista são fáceis de pular porque não são eventos que o modelo ou uma ferramenta produz. A decisão do gate é tomada pelo seu próprio código, então ninguém pensa nela como algo a registrar; no entanto, uma chamada recusada é exatamente a evidência de que um controle funcionou, e uma versão da política na decisão é o que permite res-

ponder, meses depois, qual regra estava em vigor. O consumo de orçamento é a outra: o Capítulo 13 deu um orçamento ao run, e o trace deveria mostrar o orçamento se esgotando, para que um run interrompido por um limite seja visível como um run que estava prestes a ser interrompido, e não apenas como uma interrupção.

Mais dois tipos de fato ficam ao lado desses e pertencem ao mesmo trace: os identificadores das peças de contexto e a sua proveniência (Capítulo 9), para que se possa dizer de qual fonte veio uma afirmação, e as transições de estado do run (Capítulo 10). Registraria identificadores e rótulos de proveniência em cada chamada ao modelo, junto com o manifesto de cada montagem (Capítulo 9) e um evento `memory_read` para as entradas de memória que entraram nela (Capítulo 11), e deixaria o texto completo para o armazenamento de conteúdo descrito mais adiante neste capítulo.

Nota: O run store do Capítulo 10 e o trace deste capítulo se sobrepõem de propósito. O run store é a fonte da verdade para retomar e para o registro de intenção antes do efeito; é transacional em si mesmo e lido pelo orquestrador. O pipeline de traces é para pessoas, é otimizado para consulta e para volume, e pode perder dados. Não faça o run store depender do pipeline de traces, e não reconstrua o estado do run a partir de traces.

O trace: o run como trace, as chamadas como spans

A definição deste livro é curta. Um **trace** é o registro ordenado de um run através dos componentes. Um **span** é uma operação cronometrada dentro dele. A forma geral vem do tracing distribuído, e o OpenTelemetry é o padrão aberto comum para isso. Os spans se aninham, carregam atributos e eventos e podem apontar para spans de outros traces; um contexto de span viaja com cada requisição para que o lado receptor anexe os seus spans à mesma árvore.

Para um agente o mapeamento é direto, e o manteria direto.

- **O run é o trace.** O id do run é o id do trace, ou corresponde a ele um a um. Quem tem o id do run, vindo de um ticket ou do run store, consegue encontrar o trace.
- **Um passo é um span** sob o span raiz do run.

- Uma chamada ao modelo, uma verificação do gate, uma chamada de ferramenta e uma espera por aprovação são spans sob o seu passo.
- Mudanças de estado, recusas e leituras de orçamento são eventos ou atributos de span, não novos traces.

A árvore em texto abaixo mostra uma forma para os dois agentes. É um esboço, não um esquema; o ponto é o aninhamento.

```
run (root span)
  step 1
    model.propose
    gate.check
    tool.call
  step 2
    model.propose
    gate.check           verdict: needs_approval
    approval.wait        // a span with a duration, owned by the approval
  service
    step 3                // after resume, linked to step 2
      gate.check
      tool.call
    step 4
      model.propose        // proposal.kind = final_answer
```

A forma é a mesma para `support-agent` e `ops-agent`, e esse é o benefício de pôr o loop no orquestrador: a mesma instrumentação serve aos dois. Só os nomes das ferramentas mudam. Essa uniformidade é o que permite que um único dashboard, um único conjunto de alertas e uma única ferramenta de inspeção funcionem para ambos.

Atributos de span

Os atributos são onde está o valor. Um span com um nome e uma duração diz para onde o tempo foi; um span com os atributos certos diz o que aconteceu. A tabela abaixo lista os atributos que poria em cada tipo de span. Os nomes são deste livro e ilustrativos; use os nomes do seu padrão de tracing onde ele os tiver.

Span	Atributos que valem a pena
run	run.id, agent, task.kind, ticket.id ou alert.id, principal, orchestrator.version, policy.version, prompt.version, mode (o degrau da escada de degradação, Capítulo 14), status, stop.reason, failure.class

Span	Atributos que valem a pena
<code>step</code>	<code>step.index</code> , <code>bound.remaining</code> (passos, gasto, tempo)
<code>model.propose</code>	<code>model.name</code> , <code>model.version</code> , <code>tokens.in</code> , <code>tokens.out</code> , <code>latency.ms</code> , <code>proposal.kind</code> , <code>proposal.valid</code> (false marca F1), <code>context.piece_ids</code>
<code>gate.check</code>	<code>tool</code> , <code>effect.class</code> , <code>verdict</code> (allow, refuse, needs_approval), <code>policy.rule</code> , <code>refusal.reason</code> (um motivo de veredicto do gate, listado no Apêndice), <code>policy.version</code>
<code>tool.call</code>	<code>tool</code> , <code>effect.class</code> , <code>idempotency.key</code> , <code>outcome</code> (success, código de erro, unknown), <code>latency.ms</code> , <code>attempt</code> , <code>retry.count</code>
<code>approval.wait</code>	<code>approval.id</code> , <code>approver.role</code> , <code>decision</code> , <code>wait.ms</code> , <code>bound.to</code> (o digest da chamada)

Dois deles merecem um comentário.

`failure.class` é definido no run, e no span em que a falha foi detectada, com um valor de F1 a F9. É como a taxonomia do Capítulo 3 se torna algo que se pode contar. Muitos runs não terão valor, porque nada deu errado; os úteis são aqueles em que o sistema de controle detectou uma classe (uma verificação de esquema que falha é F1, uma chamada recusada por causa do pedido errado é F2 capturada no gate, uma interrupção por limite é F5 ou F9). Uma classe que nenhuma instrumentação consegue definir é uma classe que você não consegue ver, e isso já vale saber.

`model.version` e as versões no span do run são a resposta para a pergunta que todo incidente com agentes acaba fazendo: algo mudou? O modelo, o prompt, os contratos de ferramentas, a política e o orquestrador têm cada um uma versão, e um run que não consegue dizer sob quais versões rodou não pode ser comparado com o da semana passada. Um prompt não é um controle, mas é um artefato implantado que muda o comportamento, e merece uma versão como qualquer outro. Guardados junto com o momento em que cada versão entrou em vigor, esses mesmos campos são o histórico de mudanças de um agente: o que mudou e quando. É uma das primeiras coisas que a pessoa de on-call lê quando um alerta dispara (Capítulo 13), e o Capítulo 23 delimita as suas consultas por ele.

Convenções semânticas

O OpenTelemetry também tem a ideia de **convenções semânticas**: nomes combinados para atributos comuns, de modo que todo serviço que fala com um banco de dados ou com um servidor HTTP rotule os seus spans da mesma forma e um backend consiga reconhecê-los. Existem convenções para chamadas de IA generativa também, mantidas como um esforço à parte e ainda em evolução. Não vou listar aqui nomes de atributos delas, porque nomes numa especificação em movimento são o tipo de detalhe que está errado quando o livro é lido. O padrão é estável: use os nomes do padrão onde ele os tiver, para que as ferramentas entendam os seus spans; mantenha no seu repositório uma tabela curta de mapeamento dos seus atributos para os do padrão; e ponha os seus atributos específicos de agente (decisão de política, classe de efeito, classe de falha) sob um namespace próprio, já que nenhuma convenção geral vai carregá-los. Leia a especificação atual em opentelemetry.io antes de se comprometer com nomes.

Propagação de contexto: manter um run em um trace

Um trace só é uma árvore se as partes concordam sobre o pai. Num sistema de agentes, as partes são muitas: o orquestrador, o gateway de modelos, o gateway de ferramentas, os serviços por trás das ferramentas, o serviço de aprovação. Uma chamada ao modelo atravessa até o gateway; uma chamada de ferramenta atravessa até o gateway de ferramentas e depois até o `orders-service` ou o `payments-service`. Se cada componente inicia o seu próprio trace, você obtém uma dúzia de fragmentos sem id em comum.


O controle é a propagação de contexto: o orquestrador cria o contexto de trace do run uma única vez e o repassa em toda chamada de saída, nos headers ou nos metadados que o seu transport já tem. O gateway, o gateway de ferramentas e os serviços anexam os seus spans a ele. Isso dá uma árvore em que a latência própria do gateway de modelos e a chamada ao `payments-service` ficam ambas sob o passo que as causou.

Três situações pedem cuidado extra.

Um run que é suspenso. Quando o gate devolve needs approval, o orquestrador suspende o run (Capítulo 15), e uma pessoa decide minutos ou horas depois. O run é retomado, possivelmente em outro worker. O trace precisa sobreviver a isso. Guardaria o id de trace do run no run store, para que o passo retomado inicie um span sob a mesma raiz, e acrescentaria um link do passo retomado para o passo que suspendeu. O tempo de espera da aprovação é um span à parte, para que “este run levou, digamos, quatro horas” possa ser visto como “este run esperou uma pessoa por, digamos, três horas e cinquenta minutos”.

Trabalho depois da resposta. Alguns efeitos se completam depois da resposta final do modelo: uma resposta entra numa fila e é enviada depois, um rollback termina no `deploy-service`. Esses spans podem chegar depois que o span raiz já terminou. Um link, ou um span filho que chega tarde, os mantém anexados. Isso importa para F6 (falha parcial silenciosa): o caso em que a resposta nunca saiu só é visível se o envio faz parte da mesma história.

Fronteiras que você não controla. Um provedor de modelo, um server MCP de terceiros (Capítulo 8) ou uma transportadora externa não vão entrar no seu trace. Trate cada um como uma folha: o seu span em volta da chamada registra o que você enviou, o que voltou e quanto tempo levou. Não finja enxergar dentro dele, e não ponha os seus ids de trace em requisições a partes que não têm motivo para recebê-los.



Olhe os dois tipos de seta. As contínuas levam o contexto de trace adiante junto com o trabalho, de modo que cada componente conhece o seu pai. As pontilhadas levam os spans concluídos até o pipeline de traces, que ali-

menta o trace store. O pipeline é um sistema separado de todos eles, o que importa na próxima seção.

Instrumentando o loop

O loop do Capítulo 1 já chama `record(run, event, detail)` nos lugares certos. A camada de observabilidade é o que `record` faz com cada chamada, e o que o código ao redor faz quando o pipeline não está disponível. A pergunta de design é: o run espera pelo trace?

A resposta aqui é não para o pipeline de traces e sim para o run store. O orquestrador escreve o registro de intenção e o registro de efeito no run store, porque a correção do run e a sua retomada dependem deles (Capítulo 10). Ele emite spans para o pipeline de traces de forma assíncrona, com um buffer local, porque bloquear o passo até que um span esteja gravado de forma durável trocaria a disponibilidade do agente pela completude do registro, e um pipeline lento ou indisponível não deveria impedir o reembolso de um cliente; para uma escrita irreversível, o registro de intenção no run store já oferece a parte durável. Esta é uma escolha com um custo, e o custo é F8 pela porta lateral: se spans se perdem, o run aconteceu e a evidência não. Por isso o design acrescenta uma forma de enxergar a perda.

```

function emitSpan(run, span):
    span.run_id = run.id
    span.seq = nextSpanSeq(run)           // assigned by the orchestrator,
per run
    if buffer.isFull():
        buffer.dropOldest(preferring: "low_priority") // if only high-
priority spans remain, the oldest goes too, and is counted
        counters.increment("spans_dropped", reason: "buffer_full")
        buffer.append(span)               // local, bounded; never blocks
the step

function flushBuffer():
    for each batch in buffer.batches():    // a batch stays in the buffer
until send succeeds
        try:
            tracePipeline.send(batch)
            buffer.remove(batch)
        on PipelineUnavailable:
            counters.increment("spans_unsent")
            return                          // retry later; the run is not
affected

function reconcileRun(run):
    for each intent in runStore.intents(run.id):        // Chapter 10's
intent records, written before the effect
        if not traceStore.hasSpan(run.id, "tool.call",
intent.idempotency_key):
            flag(run, "trace_incomplete")
        for each result in runStore.results(run.id):    // Chapter 10's
outcome records, written after it
            outcome = toSpanOutcome(result.status)      // run store terms
-> success | error code | unknown
            if not traceStore.hasSpan(run.id, "tool.call",
result.idempotency_key, outcome):
                flag(run, "trace_incomplete")           // a visible hole,
counted and alertable

```

Três detalhes sustentam o peso. O número de sequência é atribuído pelo orquestrador, por run, para que os spans possam ser ordenados e os descartes contados possam ser comparados com os números que estão faltando. O buffer é limitado e descarta primeiro os spans de baixa prioridade. E `reconcileRun` confere o run store, a lista definitiva de efeitos: toda intenção precisa de um span `tool.call` com a sua chave, e todo resultado precisa de um com a sua chave e o outcome correspondente, de modo que perder o span que carrega o outcome registrado não seja escondido por uma tentativa anterior que falhou, e de modo que um buraco se torne um run sinalizado e uma taxa sobre a qual se pode alertar. Um trace em cuja completude você não pode confiar ainda é útil, mas só se você sabe quando ele não está completo.

O run store, o pipeline de traces e o serviço de pagamentos são sistemas separados, sem transação entre eles, de modo que o trace nunca deve ser a única testemunha de uma escrita irreversível (Capítulo 10).

Emita eventos, não prosa

Uma disciplina faz o resto do capítulo funcionar: emita atributos estruturados, não frases. Um span que diz `refused: "the amount was too high"` pode ser lido por uma pessoa e contado por ninguém. Um span com `verdict: refuse, refusal.reason: precondition_failed` e `field: amount_minor` pode ser contado, plotado em gráfico e alvo de alertas. Os motivos devem vir de uma lista fechada que o gate e o orquestrador compartilham, da mesma forma que os códigos de erro num contrato. Um campo de texto aberto serve para notas humanas; não é com ele que uma métrica se constrói.

O que guardar do conteúdo

Tudo o que foi dito até aqui é metadado: estrutura, identificadores, versões, tamanhos, tempos. É barato e de baixo risco. A pergunta difícil é o conteúdo: o contexto renderizado, o texto da proposta do modelo, os argumentos da ferramenta e os resultados da ferramenta.

O conteúdo é o que você precisa para responder “por que o agente propôs isso”. Dá para ver que um passo propôs `issue_refund` para o pedido errado; só dá para ver por quê se for possível ver o contexto naquele passo, incluindo o resultado de ferramenta que listava dois pedidos. Sem o conteúdo, você sabe o que aconteceu e não consegue dizer por quê. Com ele, você guarda uma cópia dos dados do cliente em mais um lugar.

Não faria disso um sim ou não. Faria disso um conjunto de camadas, decididas por campo, com a decisão por escrito.

Camada	O que guarda	Quem pode ler	Retenção
Metadados	Estrutura de spans, atributos, versões, tamanhos, tempos, veredictos, reason codes	Todas as pessoas das equipes de engenharia e de operações de suporte	A mais longa; é barata e não carrega conteúdo

Camada	O que guarda	Quem pode ler	Retenção
Conteúdo com redaction	Peças de contexto, propostas e resultados de ferramentas com PII e secrets removidos no momento da escrita (Capítulo 17)	Quem trabalha no comportamento do agente	Mais curta
Conteúdo bruto	O conteúdo como era, ou o caminho de revelação até ele	Um grupo pequeno e nomeado, com uma revelação auditada que expira	A mais curta, ou nenhuma

As regras que acompanham as camadas:

1. **Faça o redaction no momento da escrita, não na leitura.** O span que chega ao pipeline de traces já passou pela função de redaction do Capítulo 17. Se o redaction falha, o campo de conteúdo é omitido e o span diz isso; ele não é escrito bruto. Um buraco é visível; um vazamento não.
2. **Guarde o conteúdo num armazenamento separado, com controle de acesso.** O span guarda uma referência ao conteúdo, não o conteúdo. Isso permite que a camada de metadados seja legível por muitos enquanto a camada de conteúdo não é, e permite que retenção e exclusão atuem no armazenamento de conteúdo sem tocar na árvore de spans. O caminho de apagamento do Capítulo 17 precisa alcançá-lo; uma referência por id do run e hash do ticket torna isso possível.
3. **Secrets nunca entram em nenhuma camada.** Um secret é um valor que concede acesso se divulgado. O gateway de ferramentas emite credenciais por chamada (Capítulo 18) e o orquestrador nunca as vê em claro; o trace também não deveria. Um trace store que guarda um token é um armazenamento de credenciais com acesso de consulta para a equipe inteira.
4. **Amostre o conteúdo, não os metadados.** Metadados são baratos; guarde-os de todo run. O conteúdo é caro e arriscado; guarde-o de uma amostra, e de todo run que importa.

Amostragem que preserva os runs de que você precisa

Uma amostra aleatória uniforme do conteúdo é o padrão usual, e ela falha da maneira que importa: o run que você precisa investigar é raro, então uma amostra de um em vinte (digamos) tem dezenove chances em vinte

de não tê-lo guardado. A alternativa é decidir depois que o run termina, quando você sabe como ele foi. Isso costuma ser chamado de tail-based sampling: colete os spans do run e, quando o run se completar, aplique uma regra que decide o que manter.

Um conjunto de regras com o qual começaria:

- guardar o conteúdo completo com redaction de todo run que foi recusado, escalonado, interrompido por um limite, passado a uma pessoa ou aprovado;
- guardá-lo de todo run com `failure.class` definido e de todo run sinalizado com `trace_incomplete`;
- guardá-lo de todo run a que uma reclamação de cliente, uma reversão ou um incidente se refira depois pelo id do run (um job pode promover retroativamente o conteúdo de um run, se o armazenamento de conteúdo ainda o tiver);
- guardar uma pequena amostra uniforme de runs comuns bem-sucedidos, porque sem eles você não tem baseline do que é normal nem fonte de casos para o Capítulo 21.

O preço é memória: para decidir no fim, você mantém o conteúdo do run até o fim. Para um run de 15 passos (digamos) isso é pouco; para uma investigação longa do agente de operações que é retomada ao longo de horas, é mais, e a retenção acontece na área de staging do armazenamento de conteúdo, não na memória do orquestrador. Um limite de tempo no staging a mantém limitada.

Aviso: Se você não consegue dizer o que aconteceu num run que movimentou dinheiro, o design falhou, qualquer que seja o custo de guardar a evidência. Para escritas irreversíveis e para efeitos colaterais externos, guarde sempre os metadados e o conteúdo com redaction da chamada e do seu resultado, independentemente da amostragem. Este é um dos poucos lugares em que o livro diz “sempre”, porque a alternativa é perder a capacidade de dizer o que aconteceu.

Métricas: no que o trace se transforma em agregado

Um trace responde a perguntas sobre um run. As métricas respondem a perguntas sobre todos eles: o agente está melhorando ou piorando, algo está se desviando, e isto é um run ruim ou um dia ruim? As métricas de um agente são derivadas dos atributos do trace, no metrics store, e a derivação é a razão pela qual os atributos devem ser estruturados.

As que construiria primeiro:

Métrica	Como é derivada	O que ela diz
Taxa de sucesso dos runs	Runs com status done e sem hand-off, sobre todos os runs, por tipo de tarefa	Se o agente completa o que começa. Defina sucesso com cuidado: “done” não é “correto”
Taxa de recusa	Veredictos refuse do gate sobre todas as verificações do gate, por ferramenta e por motivo	Com que frequência as propostas estão erradas de maneiras que o gate consegue ver; um aumento é um sinal de F2 ou F4
Taxa de hand-off	Runs encerrados por <code>escalate_to_human</code> ou por um limite, sobre todos os runs	Quanto trabalho ainda cai sobre pessoas; uma queda pode ser boa ou pode ser um buraco
Taxa de aprovação	Aprovadas sobre decididas, por ferramenta e por papel do aprovador	Se está perto de 100% e as decisões levam segundos, a aprovação é teatro (Capítulo 15)
Tempo de espera por aprovação	Durações de <code>approval.wait</code>	O custo humano do controle; onde a fila se forma
Passos por run	Contagem de spans de passo, como distribuição	Os loops aparecem na cauda, não na média (F5)
Tokens e custo por run	Soma de <code>tokens.in</code> e <code>tokens.out</code> , e gasto, por run	A entrada do Capítulo 22
Distribuição das classes de falha	Contagem por <code>failure.class</code>	Se F1 a F9 estão se movendo; o que o sistema de controle está capturando
Taxa de propostas inválidas	<code>proposal.valid</code> falso sobre as chamadas ao modelo	Pressão de F1, e se uma mudança de modelo ou de prompt a piorou
Compleitude dos traces	Runs sinalizados com <code>trace_incomplete</code> sobre todos os runs	Quanto confiar em tudo o que está acima

Algumas cautelas para ler essas métricas.

As taxas precisam de denominadores que signifiquem algo. Uma taxa de recusa calculada sobre todas as verificações do gate cai quando o agente dá mais passos bem-sucedidos e sobe quando dá menos; olhe-a por ferramenta e por motivo, e mantenha a contagem ao lado da taxa, porque uma taxa de 50% em quatro chamadas não é um achado.

Uma recusa não é uma falha. Um gate que recusa com `not_permitted` um reembolso de um pedido que não é do cliente, ou que manda para aprovação um reembolso acima do teto, é o sistema funcionando. Trate as taxas de recusa e de hand-off como sinais de onde as propostas do modelo e a sua política discordam, e leia-as como uma pergunta, não como uma pontuação a minimizar.

A cardinalidade é um custo. Uma métrica rotulada por id do run ou id do ticket é uma nova série temporal por run, e os metrics stores não gostam disso. Os rótulos devem ser os limitados: agente, ferramenta, tipo de tarefa, veredicto, reason code, classe de falha, versão. Os identificadores ilimitados pertencem ao trace, que é o lugar aonde você vai a partir de uma métrica quando algo parece errado.

Por fim, fatie por versão. Toda métrica acima deveria poder ser fatiada por versão do modelo, versão do prompt, versão da política e versão do orquestrador, porque uma mudança em qualquer uma delas é a explicação mais provável para uma variação. O Capítulo 21 usa as mesmas fatias antes de uma mudança ser lançada; aqui elas são a forma de notar uma mudança que foi lançada sem um eval.

Alertas e objetivos de nível de serviço

Um alerta é a decisão de que alguém deve ser acordado, ou interrompido, e o custo disso é real. Os alertas de agentes seguem a regra usual de alertas: envie um page para o que precisa de ação agora; abra um ticket para o que pode esperar. O que muda é o que você observa.

Um serviço convencional alerta sobre erros e latência. Um agente pode não ter nenhum dos dois e mesmo assim estar se comportando mal, então acrescentaria os sinais que o próprio sistema de controle produz.

Sinal	Por que importa	Classe provável
Taxa de recusa de uma ferramenta subindo em relação ao seu próprio baseline	As propostas estão mudando de forma: uma mudança de modelo, de prompt ou de contexto, ou conteúdo conduzindo as chamadas	F2, F4
Recusas do gate com <code>not_permitted</code> em uma ferramenta de que o agente não deveria precisar	Uma questão de autoridade, possivelmente uma injection	F7, F4
Passos por run, percentil 99, perto do limite de passos	Loops se formando	F5
Custo ou tokens por run, cauda subindo; taxa de gasto por hora acima do baseline	Retry storm, crescimento de contexto, descontrole	F9
Outcome <code>unknown</code> de ferramenta ou falhas no envio da resposta depois de um reembolso	Efeitos parciais sem confirmação	F6
Taxa de propostas inválidas subindo depois de um deploy	Uma mudança de versão quebrou a estrutura	F1
Taxa de hand-off ou tempo de espera por aprovação subindo	As pessoas são o gargalo, ou o agente está falhando mais	todas
Taxa de <code>trace_incomplete</code> acima de um limiar pequeno	Você está perdendo evidência	F8
Qualquer escrita irreversível sem registro de intenção correspondente	A divergência mais grave	F6, F8

Alerte sobre mudança em relação a um baseline para os sinais de taxa, e sobre uma condição fixa para os invariantes. “Qualquer escrita irreversível sem registro de intenção” é um invariante e deve disparar com uma única ocorrência; “a taxa de recusa de `issue_refund` é o dobro da da semana anterior” é uma taxa e deve disparar quando a mudança se sustentar.

A última linha merece a sua razão. Ela precisa de um job de reconciliação (ilustrativo) que compare os registros de reembolso do `payments-service`, a autoridade sobre se um reembolso aconteceu, com os registros de intenção do run store. Um reembolso que existe no `payments-service` sem intenção correspondente é um efeito que não passou pelo gate, e esse é o tipo de fato para o qual um alerta existe. O Capítulo 23 continua a partir daí.

Um objetivo de nível de serviço para um agente

Um objetivo de nível de serviço (SLO) é uma meta para um comportamento medido ao longo de um período, junto com uma quantidade tolerada de descumprimento. A ideia vale para agentes, com cuidado sobre o que está sendo prometido.

Não escreveria um SLO para “a resposta está correta”, porque isso não pode ser medido online para todo run, e uma meta que não se pode medir é um desejo. Escreveria SLOs para o que o sistema de controle e o pipeline conseguem medir:

- a parcela de runs que chegam a um status terminal (done, passado a uma pessoa, interrompido) dentro de um deadline, digamos 99% dentro do deadline da tarefa ao longo de um período móvel;
- a parcela de escritas irreversíveis que têm um trace completo e um registro de intenção correspondente, com uma meta próxima de todas elas e nenhuma tolerância para uma sem explicação;
- a parcela de requisições de aprovação decididas dentro de um tempo declarado, que é um SLO para o lado humano do sistema e pertence a quem lidera o suporte e à equipe de on-call, não só à plataforma;
- a parcela de runs com trace completo, como o SLO da própria evidência.

As porcentagens acima são ilustrações. Os valores certos dependem das suas tarefas, da sua equipe para aprovações e do que custa perder uma meta. Se as respostas do agente são boas é uma questão de eval (Capítulo 21), e pode existir um SLO sobre uma pontuação amostrada de grader, mas o rotularia como uma estimativa e poria o tamanho da amostra ao lado dele.

Cada alerta nomeia quem age, o que essa pessoa abre primeiro e o que ela pode fazer; se a resposta a “o que ela pode fazer” é “nada”, é um dashboard, não um alerta (a regra é a do Capítulo 13, e o runbook do Capítulo 23 é onde ela vive).

Replay e inspeção

Um trace é evidência. A ferramenta que o torna utilizável é uma visão de inspeção, e a forma mais útil dela é um replay.

Por **replay** entendo algo estreito: percorrer um run registrado em ordem, vendo em cada passo o contexto como foi montado (com redaction, na camada que quem vê tem permissão de ver), a proposta, o veredicto do gate com a regra e a versão da política, a aprovação, se houve, e o efeito ou a recusa que se seguiu. É uma visão somente de leitura do que aconteceu. É a resposta à pergunta de Sam no começo do capítulo.

O replay nesse sentido não executa o modelo de novo, e não pode chamar nenhuma ferramenta. Reexecutar um run registrado contra ferramentas reais é como um diagnóstico se transforma num segundo incidente: o reembolso é emitido outra vez, ou a resposta é enviada duas vezes. Um visualizador mostra o registro; ele não age sobre ele.

Um segundo tipo de replay é útil e diferente, e manteria os dois separados no nome e nas permissões: a **reavaliação**. Dado o contexto registrado de um passo e uma nova versão de modelo, de prompt ou de política, execute de novo a proposta ou a verificação do gate numa sandbox sem efeitos e compare. Esta é uma técnica de eval, e o Capítulo 21 a usa; aqui o trace é a fonte dos casos. Dois limites se aplicam. A saída do modelo em geral não é reproduzível, então uma proposta diferente na reavaliação não é uma regressão por si só; é uma amostra. E o gate é determinístico, então executar de novo as propostas registradas por uma nova versão da política é exato, e é uma forma barata de ver o que uma mudança de política teria recusado.

```
function inspectRun(runId, viewer):
  trace = traceStore.get(runId)
  for each step in trace.steps:
    show(step.index, step.bound.remaining)
    show(step.proposal.kind, step.proposal.valid)
    show(step.gate.verdict, step.gate.policy_rule,
step.gate.policy_version)
    if step.approval:
      show(step.approval.decision, step.approval.wait_ms)
    if viewer.mayRead("redacted_content"):
      show(contentStore.fetch(step.content_ref, tier: "redacted"))
    else:
      show("[content not available at your access level]")
  audit(viewer, "inspect", runId)      // reading a run is itself
recorded
```

O visualizador é uma porta de entrada para dados de clientes, então a leitura é auditada.

A ferramenta `get_trace` do agente de operações é este mesmo armazenamento, lido por meio de uma ferramenta. É um bom uso, e tem um limite que vale dizer com clareza. A ferramenta lê traces por id com o acesso da autoridade delegada do agente de operações (Capítulo 7); deve ler os metadados e a camada com redaction, como poderia o engenheiro que iniciou a investigação, e não mais que isso. O conteúdo do trace inclui texto que veio de tickets e de resultados de ferramentas, então as regras do Capítulo 16 se aplicam: é dado com proveniência, marcado como não confiável quando entra no contexto.

Um trace pela Parcelport

Considere o ticket do cenário de abertura, com a instrumentação instalada. O ticket `tk-5521` pergunta sobre uma encomenda danificada; o pedido é `ord-7f3k2m91`, e o valor é um número hipotético acima de `refund_ceiling`. A árvore abaixo mostra o run.

```
run run-3b9d agent: support-agent ticket: tk-5521
  versions: orchestrator 41, policy 17, prompt 9, model "model-A" version
  "v-x" // illustrative labels
  status: done stop.reason: final_answer failure.class: none
  step 1 bound.remaining: steps 9, spend 80%
    model.propose tokens.in 1900 tokens.out 60 proposal: tool_call
  lookup_order valid
    gate.check verdict: allow rule: read_tools_default
    tool.call lookup_order outcome: success latency 120ms
  step 2 bound.remaining: steps 8, spend 70%
    model.propose tokens.in 2300 tokens.out 80 proposal: tool_call
  issue_refund valid
    gate.check verdict: needs_approval rule: above_ceiling
    approval.wait approver.role: support_lead decision: approved wait
  540s
  step 3 (linked to step 2) bound.remaining: steps 7, spend 62%
    gate.check verdict: allow approval.bound_to: call-digest-0007
    tool.call issue_refund outcome: success idempotency.key: key-
  0007
  step 4
    model.propose proposal: tool_call send_customer_reply valid
    gate.check verdict: allow
    tool.call send_customer_reply attempt 1 outcome: error
  upstream_unavailable idempotency.key: key-0008
    tool.call send_customer_reply attempt 2 outcome: success
  idempotency.key: key-0008 retry.count 1
  step 5
    model.propose proposal: final_answer
```

Todos os números são inventados para a ilustração. As linhas `gate.check` são uma visão parcial do gate do Capítulo 5: `rule` nomeia a regra de política que disparou, e uma recusa acrescentaria `refusal.reason` do mesmo vocabulário; a leitura do passo 1 passa pelo gate como toda outra chamada. Leia a árvore como Alex a leria. O reembolso passou por aprovação, e a espera foi de nove minutos; a aprovação foi vinculada a um único digest de chamada, e o reembolso carrega a chave de idempotência que pegaria uma repetição. A resposta falhou uma vez com um erro explícito antes de a mensagem ser aceita, o que a classificação do Capítulo 14 trata como passível de retry, e o retry ficou dentro do passo 4 como uma segunda tentativa: reutilizou o veredicto do gate e a mesma chave, e foi cobrado do orçamento do run como uma primeira tentativa, porque um retry não reabre o gate (Capítulo 14). Nada aqui mostra a frase sobre a data de entrega, porque a data não está na estrutura; está no conteúdo. É aí que as camadas compensam. Alex abre o conteúdo com `redaction` do passo 4 e vê as peças de contexto por id e proveniência: o resultado da consulta do pedido lista um status e nenhuma data, e a data na resposta não tem fonte. Isso é F3 (afirmação sem fundamento), visível no trace, com uma `failure.class` que um grader, do Capítulo 21, pode definir depois do fato num run amostrado.

Uma variação mostra o Registro em ação. Suponha que o span `tool.call` de `issue_refund` no passo 3 tivesse sido perdido por causa de um buffer cheio. Todos os spans de passo estão presentes, então uma contagem de passos não veria nada de errado. Mas o run store guarda os registros de intenção e de resultado para `key-0007`, `reconcileRun` não encontra nenhum span `tool.call` para essa chave e sinaliza `trace_incomplete`. O reembolso, uma escrita irreversível, continua visível por esses registros. O buraco é um fato com um número, não um mistério.

Os runs do agente de operações têm a mesma árvore, com spans de `query_logs`, `get_metrics`, `get_trace` e `run_diagnostic` no lugar. Um span `run_diagnostic` registra o outcome do sandbox, a sua duração e se ele atingiu um limite; o que o script imprimiu é conteúdo e segue as regras das camadas, porque a saída de um diagnóstico pode conter dados que o script conseguiu ler no sandbox. Um span `request_rollback` carrega a aprovação com o papel e a decisão de Robin, e o identificador de implan-

tação que o `deploy-service` devolveu, de modo que “o que o agente mudou em produção” seja uma consulta sobre `effect.class` e `tool`, não um exercício de arqueologia.

Trade-offs e custos

Volume e dinheiro. Faça o orçamento do pipeline de traces e do armazenamento de conteúdo como faz o do agente, e deixe o Capítulo 22 contá-los no custo por ticket.

Privacidade contra depurabilidade. O redaction tira do engenheiro parte da informação necessária para explicar um run, e os caminhos de revelação custam uma aprovação e uma auditoria. Esse é um custo para o on-call, que às vezes vai precisar do valor bruto numa hora inconveniente. Uma revelação que leva um dia é um controle que ninguém usa, e uma revelação que qualquer pessoa pode disparar não é controle nenhum. Onde fixá-la depende dos seus dados e do seu regime; regimes desse tipo costumam perguntar onde os dados pessoais são armazenados, quem pode lê-los e por quanto tempo, e as suas pessoas de jurídico e de conformidade são responsáveis por essa interpretação.

Manutenção da instrumentação. Toda nova ferramenta, tipo de span ou classe de falha precisa de atributos, e a lista de atributos se afasta do código a menos que um teste de contrato ou uma verificação de esquema a sustente. Um esquema de trace que ninguém valida degenera em texto livre em um trimestre.

Quando não usar tudo isso. Um protótipo que trata alguns runs por dia para uma equipe não precisa de tail-based sampling, de um armazenamento de conteúdo em camadas nem de um SLO. Precisa, desde o primeiro dia, de três coisas: um id do run em tudo, a decisão do gate e a chamada de ferramenta com o seu resultado registradas como eventos estruturados, e redaction no momento da escrita. Acrescente o resto quando o volume, o risco ou o número de pessoas que precisam ler o registro crescerem. O que você não deve fazer em nenhuma escala é executar um agente que pode movimentar dinheiro ou contatar clientes sem nenhum registro do que ele fez.

O que a observabilidade não faz. Um trace diz o que aconteceu. Ele não impede que aconteça.

Erros comuns

Pedir ao modelo que se explique e armazenar isso como o trace. É tentador porque a explicação parece um registro. Uma string de explicação é mais uma saída do lado da proposta; pode estar errada e pode estar ausente. Pode ser um contexto útil para uma pessoa, guardado como conteúdo. Não é o registro. Correção: o orquestrador escreve o registro a partir de eventos que observou; o texto do modelo é conteúdo dentro do registro.

Prompts e resultados de ferramentas brutos no log store geral. É tentador porque é a forma mais rápida de depurar. Cria uma cópia que a retenção e a exclusão desconhecem (Capítulo 17). Correção: faça o redaction no momento da escrita, guarde o conteúdo no seu próprio armazenamento, dê à revelação uma trilha de auditoria e uma expiração.

Amostragem aleatória uniforme do conteúdo. Mantém o custo baixo e descarta o incidente. É tentadora porque é simples e o volume parece representativo. Correção: decida depois que o run termina, e guarde todo run recusado, escalonado, aprovado, interrompido ou com falha, mais uma pequena amostra uniforme para o baseline.

Deixar traces armazenados voltarem ao contexto como texto confiável. É tentador porque o trace são dados nossos. Um trace guarda texto de tickets e de resultados de ferramentas. Correção: quando um trace entra no contexto de um agente, por exemplo por meio de `get_trace`, ele entra como dado com proveniência, marcado como não confiável (Capítulo 16).

Pontos-chave

- O registro de um run é escrito pelo orquestrador a partir de eventos determinísticos, e o relato do próprio modelo sobre o que fez é conteúdo dentro desse registro, nunca um substituto dele.
- Trate o run como um trace e cada passo, chamada ao modelo, verificação do gate, chamada de ferramenta e espera por aprovação como um span, com atributos para versões, tokens, latência, classe de efeito, veredicto da política e classe de falha.
- Mantenha o pipeline de traces fora do caminho crítico, dê a cada span um número de sequência e reconcilie cada registro de efeito do run

store com um span `tool.call`, de modo que a evidência perdida se torne um buraco medido e não um F8 silencioso.

- Metadados são baratos e legíveis por muitos; o conteúdo é arriscado e em camadas, com redaction no momento da escrita, guardado num armazenamento separado com controle de acesso e mantido pelo resultado e não pelo acaso, de modo que todo run que foi recusado, escalonado, aprovado, interrompido ou com falha esteja disponível para inspeção.
- Derive métricas de atributos estruturados, leia as suas caudas e denominadores e fatie-as por versão, porque a explicação usual para uma mudança de comportamento é uma alteração no modelo, no prompt, na política ou na ferramenta que ninguém ligou a um eval.
- Alerte sobre sinais específicos de agentes, como taxa de recusa, passos na cauda, taxa de custo, outcomes unknown e escritas irreversíveis sem registro de intenção, e dê a cada alerta um responsável e uma primeira ação, ou transforme-o em um dashboard.
- O replay é uma visão somente de leitura do que aconteceu, a reavaliação é uma comparação em sandbox, e nenhum dos dois pode chamar uma ferramenta.

O registro diz o que o agente fez e quanto custou fazê-lo. O Capítulo 21 usa esse registro para decidir, antes de uma mudança ser lançada, se o agente deve poder continuar a fazê-lo.

Capítulo 21 — Avaliação

Imagine que Alex, da equipe de plataforma e habilitação de IA da Parcelport, altere uma frase no texto de política do prompt de sistema do agente de suporte. A frase era desajeitada, e a nova redação é mais clara para quem lê. Os testes unitários do orquestrador passam. Os testes do gate passam. Os testes de contrato de `issue_refund` passam. Nada no pipeline está vermelho, então a mudança vai ao ar naquela tarde.

Na quinta-feira, Sam, líder de suporte, percebe que a fila de escalonamentos cresceu. O agente de suporte começou a passar adiante tickets sobre encomendas danificadas que antes resolvia sozinho, e também começou a oferecer um reembolso por cortesia em alguns casos em que o cliente não havia pedido nenhum. Nada ultrapassou um teto e nada quebrou uma regra, então o gate ficou quieto. O comportamento mudou mesmo assim, e nenhum teste do pipeline foi construído para notar. Alex tem uma frase desajeitada, uma frase mais clara e nenhum modo de dizer qual das duas produz o melhor agente.

Este capítulo pertence à parte Registro do envelope de controle. O Capítulo 20 responde a “o que aconteceu neste run”; este capítulo responde a uma pergunta diferente da mesma parte: como medir o comportamento de um componente probabilístico antes de uma mudança ser lançada e enquanto ele roda, para que uma mudança de prompt, de modelo, de ferramenta ou de política seja uma decisão medida e não uma esperança?

O problema e por que ele é difícil

A maior parte do sistema de controle deste livro é determinística, e é testada como o código determinístico é testado. O gate devolve o mesmo veredicto para a mesma proposta. O validador de contrato aceita ou rejeita os mesmos argumentos todas as vezes. Um teste unitário de qualquer um dos dois é barato, rápido e exato, e deve ser escrito. Nada neste capítulo o substitui.

A parte que não se comporta assim é o modelo. Dado o mesmo contexto duas vezes, ele pode devolver duas propostas diferentes. Dado um contexto ligeiramente diferente, pode devolver uma muito diferente. Um teste que afirma “para este ticket, a proposta é igual a esta chamada de ferramenta exata” vai falhar num dia bom por motivos inofensivos e passar num dia ruim por sorte. O Capítulo 2 explica por que o modelo se comporta assim; para este capítulo, basta a consequência. Um único run diz quase nada sobre uma taxa, e uma taxa é o que você precisa saber.

Isso dá três problemas. O primeiro é que o comportamento precisa ser medido como uma distribuição: em muitos runs sobre muitos casos, que parcela fez a coisa certa? O segundo é que “a coisa certa” muitas vezes não é uma string que se possa comparar. Um rascunho de resposta pode estar correto em cem redações diferentes e errado de uma maneira sutil. O terceiro é que a própria medição pode estar errada, porque quem faz a avaliação pode ser um modelo, ou uma pessoa cansada, ou uma regra rígida demais.

Toda classe de falha da taxonomia aparece aqui, e é por isso que os evals são uma preocupação do Registro e não da Proposta; uma tabela mais adiante no capítulo associa cada classe a um caso e a um grader. F8 (comportamento não observado) é a que torna um eval impossível, porque um run sem registro não pode ser avaliado.

É uma questão de engenharia e não uma questão de prompt porque a alternativa é ler um punhado de saídas, decidir que parecem boas e lançar. Isso é uma revisão, e uma revisão vale alguma coisa, mas ela não escala para o número de mudanças que uma equipe faz, não se lembra das falhas do mês passado e não consegue dar um número para comparar. Um eval consegue.

Eval não substitui testes

Manteria duas ideias separadas desde o início, porque misturá-las produz tanto falsa confiança quanto esforço desperdiçado.

Um **teste** afirma que o código determinístico faz o que a sua especificação diz. A entrada é fixa, a saída é fixa, e uma falha significa um defeito. Os testes cobrem o parser que transforma uma proposta em uma chamada tipada, a recusa do gate a um reembolso acima do teto, a função que deriva

uma chave de idempotência, o filtro de redaction, a máquina de estados que leva uma aprovação de pendente para decidida. Eles rodam a cada commit e precisam ser exatos. Se um teste é instável, a correção está no teste ou no código.

Um **eval** é uma medição repetível do comportamento contra resultados esperados. A entrada é um caso, o que se mede é uma proposta probabilística ou um run feito de várias delas, e o resultado é uma pontuação ou uma taxa. A falha de um caso num eval não é necessariamente um defeito; é um ponto de dado numa distribuição, e o que importa é se a distribuição se moveu.

A fronteira entre os dois é a fronteira do determinismo do Capítulo 4. Tudo o que está do lado determinístico dela recebe testes. Tudo o que está do lado probabilístico recebe evals. Quando uma equipe nota que um eval está verificando algo determinístico, como “o valor do reembolso nunca excede o teto”, isso é um sinal de que a verificação pertence ao gate, onde vale em todo run, e de que o eval deveria apenas confirmar que o gate está ligado. Um eval não deveria ser o que impõe um limite.

Os dois também se complementam. Um teste do gate diz que o gate recusa uma proposta ruim. Um eval diz com que frequência o modelo produz propostas ruins para o gate recusar, e uma taxa de recusa alta aponta para o prompt, para as descrições das ferramentas ou para o retrieval. O gate é o controle; o eval é como você vê quanto trabalho o controle está fazendo.

Níveis de eval

Um eval só é útil quando está claro o que ele mede. Acho que vale separar quatro níveis, porque eles têm custos, graders e responsáveis diferentes.

Passo único

Um eval de passo único recebe um contexto e verifica uma proposta. Dado este ticket e estes resultados de ferramentas, o modelo propõe `lookup_order` com o id de pedido correto? Dados este pedido e esta mensagem do cliente, ele propõe `issue_refund` com um valor e uma moeda que combinam com a situação, ou propõe `escalate_to_human`?

Esses evals são baratos e precisos. O contexto é fixo, então você pode construí-lo à mão ou reproduzindo um passo armazenado do run store. O resultado esperado muitas vezes pode ser enunciado como uma verificação: a ferramenta está num conjunto permitido, os argumentos validam contra o contrato, o id do pedido é igual ao do ticket. São o nível certo para capturar F1 e F2, e para medir como uma mudança na descrição de uma ferramenta move a qualidade dos argumentos. A fraqueza deles é que um único passo não mostra como os erros se acumulam ao longo de um run.

Ponta a ponta

Um eval de ponta a ponta executa o loop inteiro sobre um caso, com ferramentas simuladas ou em sandbox, e avalia o resultado. O run terminou no estado certo? O reembolso foi emitido uma só vez, no valor certo, com a resposta enviada? Ele fez o hand-off quando devia? As ferramentas são substituídas por fakes determinísticos que devolvem resultados registrados, de modo que a única coisa que varia entre as repetições é o modelo.

Esse nível captura F5 e F6: loops que não convergem, um reembolso registrado e uma resposta nunca enviada. É mais lento e mais caro, já que cada caso custa um run completo, e mais difícil de depurar: um caso que falha tem muitos passos. Avaliaria o estado final e uma lista curta de invariantes (no máximo um reembolso por intenção, nenhum efeito depois de uma recusa) em vez de tentar casar a sequência exata de chamadas. A sequência não é o que importa para o cliente.

Segurança e fronteira

Um eval de segurança pergunta se os controles se sustentam quando a entrada é hostil ou a situação está no limite. Um ticket cujo corpo contém instruções dirigidas ao agente muda a próxima chamada de ferramenta? Um pedido que exige mais autoridade do que a delegada produz uma proposta recusada ou um efeito aprovado? A resposta final contém PII que não deveria?

Esses evals importam porque verificam se o gate está no caminho, antes de mais nada. Um caso em que o modelo é levado a propor um reembolso acima do teto, e o resultado esperado é `needs_approval`, está testando a ligação mais do que o modelo.

Seguindo o lado defensivo do livro, os casos aqui descrevem a situação e o comportamento esperado do controle; não precisam carregar texto de ataque funcional. Um caso pode dizer “o corpo do ticket contém uma instrução dirigida ao agente, marcada como não confiável” e o fixture pode usar um placeholder inofensivo. O Capítulo 16 é responsável pelos controles de injection; este nível é como você verifica que eles continuam valendo depois de uma mudança.

Custo e latência

O último nível mede o que um run custa e quanto tempo leva: passos, tokens, chamadas ao modelo, chamadas de ferramentas, tempo de relógio. Essas são propriedades de um run, avaliadas contra um orçamento do Capítulo 13 e contra as metas de custo do Capítulo 22. Uma mudança que mantém a qualidade da resposta e dobra o número de passos é uma regressão para F9 (explosão de custo ou latência), e não vai aparecer em nenhum eval de correção.

Registraria isso em toda execução de eval, qualquer que seja o nível, e não trataria como um projeto à parte. O custo de um caso é um subproduto de executá-lo e guardá-lo é quase de graça.

Nível	O que verifica	Grader típico	Principais classes de falha	Custo de execução
Passo único	Uma proposta para um contexto fixo	Verificação determinística	F1, F2, F3	Baixo
Ponta a ponta	Estado final e invariantes de um run	Determinístico mais grader de modelo	F5, F6, F2	Médio a alto
Segurança e fronteira	Os controles se sustentam sob entrada hostil ou no limite	Verificação determinística	F4, F7	Médio
Custo e latência	Passos, tokens e tempo contra os limites	Verificação determinística	F9, F5	De graça com os outros

Construindo o golden set

Um golden set é a coleção fixa de casos contra a qual um eval mede. A qualidade dele limita tudo o que vem depois, e é onde gastaria o primeiro esforço de qualquer programa de evals.

De onde vêm os casos

Há três fontes, e um conjunto saudável tem todas elas.

Tráfego real amostrado. Os casos mais representativos são tickets reais. Amostre-os do sistema de tickets por categoria e dificuldade, não uniformemente, porque uma amostra uniforme é dominada pela maioria fácil e diz pouco sobre os casos que importam. Tickets reais contêm PII, então passam pelo caminho de redaction do Capítulo 17 antes de entrar no conjunto, e o conjunto vive num armazenamento com os controles de acesso de um armazenamento de dados de produção. Um fixture com um nome real é um vazamento com atraso. O redaction tem um efeito colateral que vale declarar: ela pode mudar o caso. Se o ticket original mencionava um nome de um modo que importava, a versão com redaction deve manter o papel e descartar o valor.

Casos difíceis. Algumas situações são raras no tráfego e caras quando dão errado: um pedido de reembolso para um pedido com dois reembolsos parciais, uma mudança de endereço um minuto depois da entrega à transportadora, um cliente que escreve num idioma que a equipe de suporte atende por outro canal, um ticket que pede duas coisas ao mesmo tempo. Esses são escritos à mão, com Sam ou com quem lidera o suporte e sabe como são os tickets difíceis. São poucos e carregam muito peso.

Casos vindos de incidentes. Todo incidente que envolve um agente deve deixar pelo menos um caso para trás. O Capítulo 23 é responsável pelo procedimento que transforma um incidente em um caso. Esta é a única fonte que melhora com o passar do tempo.

O que um caso contém

Um caso precisa de estrutura suficiente para que um grader possa usá-lo e uma pessoa possa lê-lo um ano depois.

```

case refund-partial-goodwill-017
  agent: support-agent
  level: end_to_end
  failure_class_targeted: F2          // wrong arguments for the situation
  context:
    ticket: "Customer reports one of two items arrived damaged." //
  redacted
    order: ord-EXAMPLE-0001, lines: 2, status: "delivered"
    tool_results: recorded           // fakes replay these
  expected:
    final_state: "resolved"
    effects: [ one issue_refund, one send_customer_reply ]
    invariants:
      - refund amount_minor <= price of the damaged line
      - reason_code == "damaged"
      - no second issue_refund for this intent
  source: sampled_traffic           // or hard_case, or incident:INC-EXAMPLE
  added: "2026-09-14"
  last_reviewed: "2026-09-14"

```

Dois campos aqui são fáceis de deixar de fora e caros de não ter. A classe de falha alvo permite fatiar os resultados pela taxonomia (uma seção mais adiante). A fonte e as datas permitem aposentar casos que já não refletem como a Parcelport funciona.

Tamanho e equilíbrio

Não sei qual é o tamanho certo para o seu golden set, e ninguém pode dizer sem conhecer o seu tráfego. Depende de quantas situações distintas o seu agente encontra, de quanto custa uma resposta errada em cada uma e de quanto custa executar um run. Um conjunto de, digamos, 150 casos que cobrem bem as situações é mais útil do que um conjunto de 2.000 casos que são todas variações de “onde está a minha encomenda”. Comece com o que você consegue revisar à mão, faça-o crescer a partir de incidentes e observe o equilíbrio por nível e por classe de falha.

Mais um aviso sobre equilíbrio. Um conjunto que é na maior parte casos fáceis vai pontuar alto e não dizer nada. Se a taxa de passagem é de 98 por cento no primeiro dia, o conjunto provavelmente não é difícil o bastante para enxergar uma regressão, e uma regressão vai se esconder nos dois por cento.

Graders

Um grader decide se uma saída atende às expectativas. Há quatro tipos, e recorrerá a eles nesta ordem.

Verificações determinísticas

Se uma propriedade pode ser verificada por código, verifique-a por código. O nome da ferramenta está no conjunto permitido. Os argumentos validam contra o contrato. O valor do reembolso não excede o saldo reembolsável. A resposta não contém nenhum valor da lista de redaction. O run terminou num estado do conjunto permitido. O número de passos está abaixo do limite. Os graders determinísticos são baratos, exatos, repetíveis e fáceis de explicar quando um discorda de uma pessoa. São também os únicos graders em que se pode confiar sem calibração.

O limite deles é a expressividade. Não conseguem dizer se uma resposta é educada nem se responde à pergunta que o cliente fez.

Comparação com referência

Onde existe uma resposta boa conhecida, compare com ela: a chamada de ferramenta esperada, o estado final esperado, o escalonamento esperado. Para saídas estruturadas isso funciona bem, com a ressalva de antes: compare o que importa (o id do pedido, o valor, a moeda) e não as partes incidentais (a redação de um campo de texto livre). Uma comparação exata de string num rascunho de resposta é um grader que punirá toda reformulação inofensiva e ensinará a equipe a ignorar falhas.

Graders de modelo

Para as propriedades que o código não consegue verificar, um **grader de modelo** lê a saída e uma rubrica e devolve um julgamento. O rascunho da resposta faz alguma afirmação que os resultados das ferramentas não sustentam? Ele responde à pergunta do cliente? O tom é aceitável segundo as diretrizes de suporte? Isso é útil, e é também um modelo, com a incerteza que o Capítulo 2 descreve. Um grader de modelo é um componente probabilístico dentro do seu sistema de medição, e precisa ser avaliado como tal.

Três hábitos mantêm um grader de modelo honesto. Dê a ele uma rubrica estreita, com um número pequeno de perguntas explícitas, e não um pedido geral para avaliar a qualidade. Peça um julgamento amarrado a evidência na saída, para que uma pessoa que leia o resultado veja por quê. E não use o mesmo modelo e a mesma configuração que produziram a saída como seu único grader, porque os dois compartilham pontos cegos. Não vou nomear qual modelo usar; o design precisa se sustentar quando o modelo for substituído, e uma mudança no grader deve ela mesma passar pela calibração abaixo.

Calibração. Antes que a pontuação de um grader de modelo signifique alguma coisa, meça o quanto ele concorda com pessoas. Tome uma amostra de saídas, digamos 100, e peça a duas ou mais pessoas que as avaliem contra a mesma rubrica. Compare o grader com as pessoas, e compare as pessoas entre si. A concordância bruta favorece um grader quando a maioria das saídas passa, porque dois graders concordam por acaso no rótulo comum; use uma medida corrigida pelo acaso, como o kappa de Cohen, ou pelo menos informe a concordância na classe de falha separadamente. A concordância entre as pessoas é o teto: um grader que concorda com uma pessoa tantas vezes quanto as pessoas concordam entre si é tão bom quanto a rubrica permite, e uma concordância humana baixa diz que a rubrica é vaga. Veja onde o grader discorda. Se ele é leniente com afirmações sem fundamento (F3), a falha que mais importa em respostas redigidas, então a sua taxa de passagem superestima a qualidade exatamente onde você precisa que ela seja precisa.

Recalibre quando qualquer coisa no grader mudar: o modelo, a rubrica, as instruções. Mantenha o conjunto rotulado por pessoas como um pequeno golden set próprio. Ele é a avaliação do avaliador.

Avaliação humana

As pessoas continuam sendo a referência. Elas avaliam o conjunto de calibração, revisam amostras de runs de produção e julgam os casos que nenhum grader trata, como saber se a resposta a um cliente aborrecido foi bem conduzida. A avaliação humana é lenta e cara, e está sujeita a cansaço e a deriva entre revisores. Usaria a avaliação humana com parcimônia e de propósito: para calibração, para novos modos de falha que nenhum grader cobre ainda e para verificações pontuais periódicas que mantêm os

graders automáticos honestos. Diga quem a faz e quanto tempo leva, como nas aprovações do Capítulo 15. Uma revisão humana que está agendada mas sem pessoal é teatro.

Resultados probabilísticos: repetições, taxas e intervalos

O modelo não é determinístico, então um caso não é aprovado ou reprovado; ele tem uma taxa de passagem ao longo de repetições. Isso muda como você executa e lê um eval.

Repetições

Execute cada caso várias vezes, digamos cinco, e registre os resultados. Para um grader determinístico, o custo é o custo dos runs. Um caso que passa cinco de cinco e um caso que passa duas de cinco são diferentes, ainda que uma única execução de qualquer um dos dois pudesse ter ido para qualquer lado. O segundo caso está dizendo que o agente não é confiável naquela situação, que é exatamente o que você precisa ver, e um eval de uma só tentativa o mostraria metade das vezes.

O número certo de repetições depende da variância do agente, do custo de um run e de quão fina é a mudança que você precisa detectar. Começaria baixo, olharia quais casos discordam de si mesmos entre repetições e gastaria repetições onde está a variância.

Taxas e a ideia de um intervalo

Um resultado agregado é uma taxa: a parcela de execuções de casos que passaram. Uma taxa vem de uma amostra finita, então carrega incerteza. Se um conjunto tem 150 casos com cinco repetições cada, a taxa de passagem pode marcar 91 por cento numa execução e 89 por cento em outra sem nenhuma mudança no agente. Uma mudança que leva o número de 91 para 89 não mostrou nada.

A ideia de que você precisa é a de **intervalo de confiança**: uma faixa em torno da taxa medida na qual a taxa verdadeira plausivelmente está, que fica mais estreita com mais casos e mais larga com menos. Você não precisa de um curso de estatística para usá-la. Calcule um intervalo para a diferença entre candidato e baseline: se ele exclui o zero, essa é a evidência,

enquanto comparar dois intervalos separados a olho é um atalho conservador que pode esconder uma diferença real. Peça aos seus colegas de dados ou de plataforma o método certo para o seu conjunto; estou descrevendo o princípio, não prescrevendo uma fórmula.

Os casos não são amostras independentes, já que as repetições de um caso são correlacionadas e casos parecidos se agrupam. Isso torna os intervalos ingênuos estreitos demais. Uma salvaguarda prática é contar o caso, e não a repetição, como a unidade ao comparar, e olhar a lista de casos que mudaram de resultado e lê-los.

Evals flaky

Um eval que dá resultados diferentes para o mesmo agente é flaky. Parte disso é a natureza do modelo e aparece como alta variância em casos específicos; isso é um achado e não um incômodo. Outras fontes estão no harness e são responsabilidade sua: fakes de ferramentas que dependem do tempo, graders com aleatoriedade própria, fixtures que vazam estado entre casos, um gateway que varia sob carga.

Trate a instabilidade como trataria um teste flaky, com um passo extra. Separe os casos cuja variância vem do agente (mantenha-os e informe a taxa de passagem deles) dos casos cuja variância vem do harness (corrija-os). Ponha um caso flaky em quarentena com um responsável e uma data de expiração, não com um skip silencioso. Uma quarentena sem expiração é como um conjunto deixa, em silêncio, de medir aquilo para que foi construído.

O eval como gate de deploy

Um eval que ninguém precisa olhar antes de lançar é um relatório. Um eval que fica entre uma mudança e a produção é um controle.

O que conta como mudança

Num agente, mais do que o código muda o comportamento. Tudo o que segue muda o que o agente faz, e cada item deveria disparar uma execução de eval:

- Uma mudança no texto de política do prompt de sistema ou em qualquer outro texto de prompt.

- Uma mudança de modelo, ou da configuração do gateway de modelos para o projeto.
- Uma mudança na descrição de uma ferramenta, num contrato de ferramenta ou no conjunto de ferramentas que o agente vê.
- Uma mudança numa política do gate que altere quais propostas passam.
- Uma mudança no retrieval, na montagem do contexto ou no comportamento da memória.
- Uma mudança nos limites: limites de passos, orçamentos, regras de re-try e de fallback.

O incidente da abertura deste capítulo pertence ao primeiro item. A mudança foi uma reformulação, e o processo de revisão a tratou como documentação. Nada no pipeline distinguia uma edição de prompt de uma edição de comentário. Trataria o texto de prompt e de política como código que é lançado pelo mesmo pipeline, com o mesmo gate.

Limiares

Um gate de deploy precisa de uma regra. A regra mais simples é um limiar de regressão contra o baseline: o candidato não pode ser pior do que a configuração atual de produção por mais do que uma margem declarada em qualquer métrica do gate. A margem deve refletir o ruído da medição, que é onde os intervalos acima se justificam.

```
function evalGate(candidate, baseline, goldenSet):
  results = runEval(candidate, goldenSet, repeats: 5)
  base = loadResults(baseline, goldenSet)
  // hard gates: a safety or boundary case that fails blocks the change
  for each case in goldenSet.where(level == "safety"):
    if results.passRate(case) < 1.0:
      return { decision: "block", reason: "safety case failed", case:
case.id }
  // soft gates: compare rates by slice with a margin that covers noise
  for each slice in ["F2", "F3", "F6", "overall"]:
    drop = base.caseRate(slice) - results.caseRate(slice) // unit: the
case, not the repeat; a case passes when its pass rate over repeats meets
the threshold in its definition, say 4 of 5
    if drop > margin(slice):
      return { decision: "block", reason: "regression", slice: slice }
  // cost is read at the tail, not the mean
  if results.p95Cost() > base.p95Cost() * costLimit:
    return { decision: "inconclusive", reason: "cost increase" }
  return { decision: "ship" }
```

inconclusive aqui significa que o gate não consegue decidir sozinho. Um aumento de custo vai para uma pessoa e não para um bloqueio automático, porque um agente mais caro pode ser a troca certa por mais qualidade, e essa é uma decisão de produto de quem é responsável pelo orçamento.

Não definiria os limiares a partir de um modelo pronto. Comece com uma margem frouxa, observe os falsos bloqueios e as regressões não detectadas por algumas semanas e aperte. Um gate que bloqueia uma boa mudança duas vezes por semana será contornado na terceira semana.

Quem é responsável pelo gate

A suíte de evals pertence à equipe de Alex, mas os casos pertencem às pessoas que conhecem as situações. A equipe de Sam deveria poder acrescentar um caso sem mudar código. O caminho de override, em que uma pessoa lança apesar de um gate reprovado, deveria existir, porque haverá um dia em que ele será necessário, e deveria deixar um registro de quem o fez e por quê. Um override que não deixa registro é F8 dentro do seu próprio processo.

Avaliação online

Um eval offline mede os casos em que você pensou. A produção traz aqueles em que você não pensou, então o eval offline é um controle necessário e insuficiente. A avaliação online mede o comportamento do agente em tráfego real, de um modo que não prejudica o cliente.

Avaliação por amostragem de runs de produção

O pipeline de traces do Capítulo 20 já registra todo run. Amostre uma parcela dos runs terminados, passe-os pelos graders que funcionam sem referência (os invariantes determinísticos e graders de modelo para fundamentação e tom) e acompanhe as taxas ao longo do tempo. É aqui que a deriva aparece: uma atualização de modelo no provedor, uma mudança no que os clientes escrevem, uma ferramenta cujos resultados mudaram de forma. Isso não vem com um deploy, então nenhum gate de deploy os captura. A avaliação online por amostragem é o controle que os enxerga.

A amostragem toca dados de produção, então valem as mesmas regras de qualquer uso de traces: redaction, controle de acesso e um período de retenção (Capítulo 17 e Capítulo 20). A saída da avaliação online também é uma fonte para o golden set. Um run de produção que um grader sinalizou e uma pessoa confirmou é um candidato a caso.

Shadow runs

Em um shadow run, a configuração candidata recebe uma cópia das entradas reais e produz propostas que são registradas e avaliadas, mas nunca aplicadas. As ferramentas que ela chama são versões somente de leitura ou fakes registrados; um agente em shadow não pode ser capaz de chamar `issue_refund` ou `send_customer_reply` de verdade. Essa restrição é um requisito de design, e a imporia no gate, com o agente em shadow sem nenhuma credencial para ferramentas de escrita, já que um prompt que diz “não aplique efeitos” não é um controle.


Os shadow runs mostram como um candidato se comporta em tráfego que o golden set não cobre, ao custo de executar o agente duas vezes. Eles não conseguem mostrar como os clientes reagem, e não conseguem mostrar comportamento que depende dos efeitos de ações anteriores, porque esses nunca acontecem.

Canary

Um canary encaminha uma pequena parcela do tráfego real para o candidato e aplica os seus efeitos. É o primeiro ponto em que as ações do candidato são reais, então vem depois do eval offline e, para uma mudança arriscada, depois de um shadow run. Use uma atribuição estável por ticket ou por cliente, para que um ticket não seja tratado metade por uma configuração e metade por outra. Compare as taxas do canary, e as suas taxas de escalonamento e de aprovação, com o baseline, e defina uma regra de rollback de antemão: se uma métrica nomeada cruza uma linha nomeada, o tráfego volta para o baseline sem uma reunião.

Aplica-se a cautela habitual com dinheiro. Para um agente de suporte que emite reembolsos, uma coorte de canary está gastando dinheiro de verdade numa configuração não comprovada. Mantenha a parcela do canary pequena, mantenha os limiares do gate e da aprovação em vigor nos valores de produção e prefira começar pelas categorias de ticket em que os

efeitos são reversíveis. Um canary é um lugar em que manteria um passo de aprovação humana no caminho por mais tempo do que o regime estável exige.



Leia o diagrama da esquerda para a direita e encontre as três saídas antes do rollout completo. Cada estágio custa mais do que o anterior e captura um tipo diferente de problema, e o laço na parte de baixo é a parte que as equipes pulam: o que a avaliação online encontra volta para o golden set, para que a próxima mudança enfrente o caso.

Alinhando os evals com a taxonomia de falhas

Uma única taxa de passagem esconde a informação de que você mais precisa. “Noventa por cento” não diz se os dez por cento que faltam são redações um pouco desajeitadas ou reembolsos errados. A taxonomia de falhas do Capítulo 3 é a cura, e custa um campo em cada caso.

Marque cada caso com a classe de falha que ele visa, e marque cada resultado que falha com a classe em que a falha se enquadra. Depois informe os resultados como uma tabela por classe, junto com a taxa geral.

Classe	Caso de eval típico	Grader	O que significa uma regressão
F1 saída malformada	Contexto em que uma chamada de ferramenta é necessária, com um campo incomum	Determinístico: validar contra o contrato	As propostas do modelo falham mais no parser; verifique as descrições das ferramentas
F2 ferramenta incorreta ou argumentos incorretos	Ticket com dois pedidos, só um reembolsável	Determinístico e referência	As propostas escolhem o pedido ou o valor errado; o gate está capturando mais
F3 afirmação sem fundamento	Resposta redigida quando o resultado da ferramenta não tem o fato pedido	Grader de modelo, calibrado, mais uma verificação determinística nos campos citados	As respostas afirmam coisas que o contexto não sustenta

Classe	Caso de eval típico	Grader	O que significa uma regressão
F4 sequestro de instruções	Ticket com texto dirigido ao agente, marcado como não confiável	Determinístico: próxima chamada inalterada, nenhum efeito	Os controles estruturais do Capítulo 16 estão mais fracos ou foram contornados
F5 loop descontrolado ou contexto obsoleto	Caso em que uma ferramenta devolve o mesmo resultado vazio	Determinístico: passos abaixo do limite, motivo de parada registrado	Os loops estão mais longos; verifique as verificações de progresso do Capítulo 12
F6 falha parcial silenciosa	A ferramenta de resposta falha depois que o reembolso tem sucesso	Determinístico: o run não é marcado como completo, a lacuna é detectada	O run store e a ordenação dos efeitos têm um buraco
F7 efeito não autorizado	Pedido acima da autoridade delegada	Determinístico: o veredicto do gate é refuse ou needs approval	O gate não está no caminho; pare o lançamento
F8 comportamento não observado	Qualquer run, verificado quanto a um trace completo	Determinístico: todo efeito tem um span e um registro	O registro tem lacunas e os incidentes futuros não poderão ser revisados
F9 explosão de custo ou latência	Caso que historicamente disparava muitos passos	Determinístico: passos, tokens e tempo contra os limites	A mudança custa mais; compare com as metas de custo

A tabela também diz onde investir. Uma regressão em F7 ou F4 é um evento de parar a linha, qualquer que seja a taxa geral, porque esses casos verificam controles. Uma regressão em F3 pode ser aceitável em troca de um ganho em outro lugar, se a resposta passa por uma pessoa antes de ser enviada, e não é aceitável se é enviada diretamente. A taxonomia converte “a pontuação caiu” em “esta classe de falha ficou mais frequente”, e isso é algo sobre o qual uma equipe pode agir.

Para o `ops-agent`, o mesmo alinhamento vale com casos diferentes. Um eval de `runbook` dá ao agente um alerta registrado e um conjunto de resultados de ferramentas registrados (logs, métricas, um trace), e verifica a investigação: ele consultou o `runbook` certo por meio de `search_docs`, o diagnóstico proposto citou a evidência que recuperou (F3), parou dentro do seu limite (F5), e a proposta de `request_rollback` chegou ao gate

com o veredicto `needs_approval`, sem nenhum efeito aplicado antes de uma aprovação registrada (F7)? O grader do último item é determinístico, e o caso deveria estar no nível de segurança.

Manutenção do conjunto e sobreajuste a ele

Um golden set não é um artefato acabado. É uma peça do sistema que precisa do cuidado que qualquer outra peça precisa.

Obsolescência

As políticas da Parcelport mudam, as ferramentas mudam, os produtos mudam. Um caso que espera que um reembolso seja emitido sob uma política que não existe mais vai reprovar o comportamento novo, que está correto. Cada caso carrega uma data de revisão, e uma revisão periódica aposenta, atualiza ou confirma casos. Quando um caso falha depois de uma mudança deliberada de política, o caso é que está errado; atualize-o no mesmo pull request da política, para que o conjunto e o sistema não se afastem.

Sobreajuste

Esta é a falha mais sutil de um programa de evals. Quando uma equipe melhora um prompt até o golden set passar, ela está otimizando o prompt para esses casos. Quanto mais vezes o conjunto é usado como alvo, menos a taxa de passagem diz sobre casos que o conjunto não contém. O agente não aprendeu a lidar com reembolsos; o prompt foi ajustado a esses 150 tickets.

Há contramedidas práticas, nenhuma delas completa. Mantenha uma parte reservada do conjunto, usada para o gate e não para o ajuste, e renove-a com tráfego novo e incidentes para que ela não fique conhecida. Prefira correções que mudam o contexto, a descrição da ferramenta ou um controle a correções que remendam a redação de um ticket. Uma correção geral move muitos casos e um remendo move um. Um prompt que ganha uma exceção para cada caso que falhou é um mau cheiro de design, já que cada exceção ocupa o lugar de um controle ausente que pertence ao código. Observe a distância entre a taxa de passagem do golden set e a taxa de passagem online. Se o número offline sobe e o online não, o conjunto foi decorado.

Custo da suíte

A suíte de evals tem custos contínuos: chamadas ao modelo para cada repetição de cada caso, chamadas ao grader de modelo, manutenção de fixtures, tempo de avaliação humana. Suponha que uma execução completa do conjunto leve, digamos, 40 minutos. As pessoas envolvidoras vão executá-la com menos frequência e pedir exceções. O remédio é uma suíte em camadas: um conjunto pequeno e rápido a cada mudança de prompt ou de política, o conjunto completo antes de um release e as verificações caras, com avaliação humana, num cronograma. Um controle caro demais para ser executado é executado menos, e um controle executado menos foi removido na prática.

Aviso: Uma suíte de evals que fica vermelha por semanas e é dispensada todas as vezes equivale a não ter nenhuma, e é pior, porque o processo de release continua afirmando incluir uma. Se a suíte não está bloqueando mudanças, ou corrija o que ela reporta ou retire abertamente a sua autoridade, para que ninguém a confunda com um controle.

Trade-offs e custos

Os evals custam esforço real, e seria desonesto se os apresentasse como gratuitos.

Construir o conjunto custa pessoas. Alguém precisa amostrar tickets, aplicar redaction, escrever os resultados esperados e revisar os casos difíceis com a equipe de Sam. Isso é tempo qualificado, e compete com o trabalho de funcionalidades. O retorno chega devagar, nas mudanças que não causam uma fila de quinta-feira, que são invisíveis por natureza.

Um grader de modelo acrescenta um componente que pode errar.

Para equipes pequenas, esse custo adicional pode ser maior do que o problema. Se os graders determinísticos cobrem a maior parte do que importa, não acrescentaria um grader de modelo para o resto só porque é possível.

Os limiares criam atrito. Um gate que bloqueia mudanças desacelera a equipe, que é a função dele, e até que a margem esteja ajustada o preço é pago em falsos bloqueios.

Quando não construir tudo isso. Um agente que apenas redige respostas para uma pessoa revisar, em baixo volume, não precisa de um sistema de canary. Um protótipo sem usuários precisa de um punhado de casos escritos à mão e do hábito de executá-los. O programa completo, com um conjunto que tem responsável, graders calibrados, um gate de deploy e amostragem online, se justifica quando um agente produz efeitos que custam dinheiro ou tocam clientes, quando várias pessoas o alteram e quando ele muda com frequência. A ordem em que construiria é: graders determinísticos sobre um conjunto pequeno feito à mão, depois casos de incidentes, depois o gate de deploy, depois a amostragem online, e só então graders de modelo, shadow runs e canaries, se o tráfego e o que está em jogo justificarem.

Evals não provam segurança. Uma suíte que passa diz que o agente se saiu bem nos casos do conjunto. Não diz nada sobre casos fora dele, e não torna o agente seguro.

Erros comuns

- **Tratar o eval como um teste unitário.** Afirmar uma proposta exata em um único run falha por motivos inofensivos e passa por sorte. É tentador porque é a forma de teste que a equipe já conhece. Meça uma taxa ao longo de repetições, avalie o que importa e reserve as asserções exatas para o lado determinístico.
- **Usar uma única pontuação geral.** Um único número esconde qual classe de falha se moveu. É tentador porque cabe em um dashboard. Informe por classe de falha e por nível, e trate regressões em F4 e F7 como bloqueantes independentemente da média.
- **Confiar em um grader de modelo não calibrado.** A taxa de passagem do grader vira o número de qualidade, e ninguém sabe como ela se relaciona com o que as pessoas pensam. É tentador porque elimina o trabalho de rotulagem humana. Calibre contra rótulos humanos, encontre onde ele é leniente e recalibre quando ele mudar.
- **Ler diferenças dentro do ruído.** Declarar uma mudança melhor porque a pontuação passou de 89 para 91 em um run. É tentador porque um número se moveu. Repita os casos, compare com um intervalo e leia os casos que mudaram de resultado.

- **Ajustar contra o conjunto inteiro.** Iterar no prompt até todo caso passar e depois usar o mesmo conjunto como gate. É tentador porque o conjunto é a única medida disponível. Reserve uma parte para o gate, renove-a com tráfego e incidentes e observe a distância entre as taxas offline e online.
- **Deixar PII real no conjunto.** Copiar tickets como estão. É tentador porque um ticket real é o caso mais fiel. Faça o redaction na entrada, mantenha o papel e descarte o valor, e armazene o conjunto com controle de acesso de nível de produção.

Pontos-chave

- Um eval mede as partes probabilísticas do sistema e um teste verifica as partes determinísticas, então você precisa dos dois, e qualquer limite que precise valer sempre pertence ao gate e não a um eval.
- Separe quatro níveis de eval, passo único, ponta a ponta, segurança e fronteira, e custo e latência, porque eles têm graders, custos e responsáveis diferentes.
- Construa o golden set a partir de tráfego real amostrado e com redaction, de casos difíceis escritos à mão e de casos vindos de incidentes, e trate uma revisão de incidente que não deixa nenhum caso para trás como inacabada.
- Prefira graders determinísticos, use graders de modelo só para o que o código não consegue verificar e calibre todo grader de modelo contra rótulos humanos antes de acreditar na sua pontuação.
- Informe os resultados como taxas ao longo de repetições, com alguma noção de incerteza, fatiadas por classe de falha, de modo que uma regressão seja lida como “esta classe de falha ficou mais frequente” e não como um número que se moveu.
- Faça de uma mudança de prompt, de modelo, de ferramenta, de política ou de limite uma execução de eval com um limiar de regressão, trate os casos de segurança como bloqueantes e complemente o gate de deploy com amostragem online, shadow runs e um canary onde o que está em jogo justificar.
- Mantenha o conjunto como parte do sistema, aposentando casos obsoletos, reservando casos contra o sobreajuste e mantendo a suíte barata

o bastante para ser executada, já que um controle que é pulado é um controle que sumiu.

O eval diz se o agente ainda faz a coisa certa; não diz nada sobre o que a coisa certa custa. O Capítulo 22 retoma o Limite que o eval vinha medindo de lado, o gasto e a latência de cada run, e mostra como atribuí-lo, limitá-lo e reduzi-lo sem deixar que a qualidade pague em silêncio pela economia.

Capítulo 22 — Controle de custos

Imagine que a liderança de operações da Parcelport faça a Alex uma pergunta simples no fim de um trimestre: quanto custa agora um ticket de suporte, já que o agente de suporte cuida da primeira triagem? Alex abre a fatura do provedor de modelos e encontra uma única linha. Ela é grande, cresceu ao longo do trimestre e não diz nada sobre qual agente, qual cliente, qual funcionalidade ou qual tipo de ticket a causou. O agente de operações usa o mesmo gateway, de modo que as investigações dele também estão nessa linha.

Suponha que uma mudança de prompt no segundo mês tenha acrescentado um longo trecho de política a cada chamada ao modelo. Ninguém decidiu dobrar a entrada de um run típico; o trecho era razoável, as respostas melhoraram um pouco e a mudança foi para produção. Suponha também que uma política de retry contra um provedor lento tenha multiplicado as chamadas sem alarde durante uma semana ruim. Cada uma dessas foi uma decisão local sensata, e cada uma é invisível em uma única linha de fatura.

Sam tem uma versão diferente da pergunta. O agente faz o hand-off de alguns tickets, e cada hand-off cai em uma fila humana. O agente está mais barato do que antes, ou o custo saiu da fatura e foi parar na equipe de Sam, onde ninguém o coloca em um dashboard? A pergunta que este capítulo responde é como enxergar o que um run custa, como contê-lo com controles que não degradem o trabalho em silêncio e como perceber quando o custo muda.

Este capítulo pertence à parte **Limite** do envelope de controle. O Limite pergunta onde o loop para e quanto custa executá-lo. O Capítulo 13 deu os tetos rígidos; este capítulo trata do gasto cotidiano que permanece dentro de todos os limites e mesmo assim está errado: como medi-lo, atribuí-lo, reduzi-lo e acompanhá-lo.

O problema e por que ele é difícil

A classe de falha é a **F9 (explosão de custo ou latência)**: o run está correto e custa caro demais. É uma classe incômoda porque nada está quebrado. Toda chamada tem sucesso, toda resposta é aceitável, o gate permitiu todas as propostas. Os sintomas são uma fatura e uma fila, e ambos chegam tarde.

O custo também alimenta outras classes. Um run em loop gasta dinheiro como efeito colateral da **F5 (loop descontrolado ou contexto obsoleto)**. Não se pode dizer que um run que não enxerga o próprio gasto esteja limitado por ele. E um custo que ninguém consegue atribuir é um caso de **F8 (comportamento não observado)**: o sistema fez algo caro e não deixou nenhuma evidência utilizável do que foi nem do porquê. Sem atribuição, um pico de custo é uma investigação do zero.

A abordagem óbvia é cortar o maior número. Usar um modelo menor, encurtar o prompt, fazer cache das respostas. Cada uma dessas medidas pode estar certa, e cada uma pode também eliminar justamente o que tornava as respostas aceitáveis. O custo de uma chamada ao modelo é uma linha em uma soma maior, e otimizar uma linha enquanto as outras se movem é como o controle de custos se transforma em uma regressão de qualidade que aparece semanas depois como uma fila humana mais longa.

A segunda abordagem óbvia é pedir ao modelo que seja econômico. O prompt manda usar o menor número possível de passos e não se repetir. Isso pode reduzir a taxa de passos desperdiçados, mas não é um controle. O modelo não enxerga o total do dia nem a tabela de preços, e um limite que depende daquilo que está sendo limitado não é um limite. O teto vive no código (Capítulo 13); o custo cotidiano vive nas escolhas de design que o código faz: o que entra no contexto, qual nível de modelo é consultado, quais requisições nunca chegam ao agente.

Para onde vai o dinheiro

Antes de medir qualquer coisa, liste os lugares onde um run gasta. A maioria das listas para nos tokens. Para um agente, os tokens são a maior linha visível e raramente a única.

Origem	O que a impulsiona	Onde se esconde
Tokens de entrada	Tamanho do contexto montado, enviado de novo a cada passo	Crescimento do contexto: cada passo carrega o que os passos anteriores acrescentaram
Tokens de saída	Tamanho das propostas e dos rascunhos	Rascunhos prolixos, planos repetidos, explicações que ninguém lê
Passos do loop	Número de iterações antes de uma resposta final ou de uma parada	Passos sem progresso (Capítulo 12)
Retries e fallbacks	Chamadas repetidas ao modelo, um nível de fallback mais caro	Uma semana degradada parece tráfego normal, só que mais caro (Capítulo 14)
Chamadas de ferramentas	Custo externo do serviço por trás da ferramenta	Uma consulta de logs sobre um intervalo amplo, um diagnóstico que demora
Sandbox	Segundos de inicialização e de computação de <code>run_diagnostic</code>	Scripts curtos dominados pela inicialização
Tempo humano	Aprovações, hand-offs, revisão de runs amostrados	Aparece na agenda de uma equipe e nunca em uma fatura
O registro	Armazenar traces, prompts e saídas (Capítulo 20)	Retenção do contexto completo de cada passo
Evals	Execuções de golden set, graders, tráfego em shadow (Capítulo 21)	Cada mudança dispara uma execução paga

O crescimento do contexto merece um número, porque é o custo que surpreende as pessoas. Digamos que um run comece com 2.000 tokens de contexto e que cada passo acrescente 1.000 tokens de resultados de ferramentas e propostas. No passo k , a chamada ao modelo carrega 2.000 mais 1.000 vezes k tokens de entrada. Ao longo de dez passos, isso soma 75.000 tokens de entrada; um contexto que não crescesse teria enviado 20.000. Ao longo de quinze passos, a soma é 150.000. Metade a mais de passos, o dobro de entrada. Os números são hipotéticos, e o que importa é o formato: o custo de entrada cresce mais rápido que o número de passos, e é por isso que o limite de passos e a dieta do contexto são controles de custo, além de controles de confiabilidade. Se o seu provedor cobra prefixos repetidos de forma diferente, isso muda a taxa, não o formato.

O tempo humano é o custo que mais costuma ficar de fora. A equipe de Sam lê um resumo de hand-off e responde, e uma aprovação custa a atenção de uma pessoa a cada vez (Capítulo 15). Quando este capítulo fala em

“custo de um run”, os minutos humanos que o run causa fazem parte dele.

Medir e atribuir o custo

Você não consegue cortar um custo que não consegue situar. A atribuição responde a quatro perguntas sobre cada unidade de gasto: qual run, qual agente e versão, qual funcionalidade e qual cliente ou tenant. O lugar para respondê-las é o trace (Capítulo 20), porque o trace já carrega identificadores de run e de passo, e um evento de custo é mais um fato sobre um span.

Registraria o uso bruto, não o dinheiro. Tokens de entrada, tokens de saída, chamadas, segundos de sandbox. O dinheiro é calculado na hora do relatório, a partir de uma tabela de preços que tem a própria versão. Se o provedor mudar um preço, ou se você mudar o nível de uma rota, não é preciso reescrever o histórico, e você pode perguntar quanto o mês passado teria custado aos preços de hoje.

```
function recordCost(run, step, call, kind, usage):
  event = {
    run_id: run.id, step_id: step.id,
    kind: kind,
    usage: usage,
    seconds
    route: step.route,
    "primary", "fallback"
    retry_of: call.attempt > 1 ? call.id : null,
  from the retry loop (Chapter 14)
    agent: run.agent, agent_version: run.agent_version,
    feature: run.feature,
    tenant: run.tenant_id,
    subject: run.ticket_id,
    price_version: prices.version,
    estimated: usage.is_estimate
  }
  record(run, "cost", event)
```

Três campos fazem um trabalho fácil de subestimar. `route` permite separar o custo do caminho barato do custo do primário e do fallback.

`retry_of` torna o custo das chamadas repetidas separável do custo do trabalho. `estimated` marca as chamadas cujo uso nunca foi informado, que é o que um timeout deixa para trás; o orquestrador guarda uma estimativa, o gateway pode ter cobrado outra coisa, e o evento diz qual dos dois é.

O pipeline de trace é um sistema separado do gateway de modelos, então os dois vão discordar de vez em quando. Trataria o uso informado pelo gateway como a fonte da verdade para os tokens e faria a reconciliação diária contra ele: a soma dos eventos de custo por agente e por dia contra o total do gateway. Uma diferença não é um incômodo contábil, é um sinal. Uma diferença positiva no gateway indica que algumas chamadas não deixam evento de custo, o que é uma F8 dentro do sistema de custos: um caminho de código que chega ao modelo sem passar pelo orquestrador. Uma diferença negativa indica que eventos estão sendo contados em dobro. As duas merecem um responsável.

Os identificadores importam por outro motivo. O custo por cliente é uma pergunta útil, e ela deve ser feita com identificadores opacos de tenant e de subject, nunca com nomes ou e-mails no evento (Capítulo 17). O registro de custos é duradouro e amplamente legível, porque o financeiro e a engenharia o consultam, e os dados PII não têm lugar nele.

A unidade que importa

Um custo por chamada ao modelo é um número útil para a engenharia e ruim para o negócio. A unidade pela qual gerenciaria é o **custo por ticket resolvido** para o agente de suporte e o **custo por investigação** para o agente de operações, em que o custo inclui tudo o que o run causou: modelo, ferramentas, sandbox e os minutos humanos de hand-offs e aprovações.

“Resolvido” importa no denominador. Um run que termina em hand-off não foi resolvido pelo agente, e o custo humano dele pertence ao run. Se você dividir apenas o custo da fatura apenas pelos tickets resolvidos pelo agente, pode fazer o número cair entregando cedo os tickets caros, o que tira os tokens deles da fatura enquanto o custo humano cai em outro lugar; na fatura parece economia e, na prática, é um custo em outro orçamento.

Economia unitária, com números inventados

Números hipotéticos mostram a estrutura, e nada abaixo é uma medição. Use os seus. Digamos que a fila de suporte da Parcelport receba 200 tickets por dia. Suponha que a unidade seja uma unidade de custo abstrata e

que um humano tratando um ticket do zero custe 50 unidades. Digamos que o gasto do agente com modelo, ferramentas e sandbox tenha média de 3 unidades por run, ou seja, 600 unidades por dia.

Suponha que, em um dia típico, 130 dos 200 tickets sejam resolvidos pelo agente sem trabalho humano e 70 sejam entregues com um resumo, cada um custando a um humano 35 unidades, porque o resumo economiza tempo de leitura. Digamos que 20 dos 200 envolvam uma aprovação que custa 5 unidades da atenção de Sam cada. O total diário é:

model, tool, sandbox:	200 runs x 3 units	= 600
hand-offs:	70 tickets x 35 units	= 2,450
approvals:	20 x 5 units	= 100
total		= 3,150
per ticket handled:	3,150 / 200	= 15.75 units
all-human baseline:	200 x 50	= 10,000


Neste exemplo inventado, a linha parecida com a fatura, de 600 unidades, está abaixo de um quinto do total, e o custo humano dos hand-offs é a maior linha. A alavanca que parece maior não é a alavanca que é maior.

Teste isso. Digamos que um nível de modelo mais barato reduza o gasto com modelo em um terço, o que economiza 200 unidades por dia. Suponha que ele também reduza a taxa de resolução, de modo que dez tickets a mais por dia terminem em hand-off. Cada um desses dez passa a custar 35 unidades de tempo humano que antes não custava, ou seja, 350 unidades. A mudança economiza 200 e custa 350, num aumento líquido de 150 unidades por dia, e a fatura mostra um bom resultado enquanto a fila humana cresce. O inverso também vale: uma mudança que custa mais por run e resolve dez tickets a mais pode reduzir o total. É por isso que uma mudança de custo é sempre avaliada contra a qualidade, e o restante do capítulo volta a esse ponto.

Controles que reduzem o custo

Há cinco controles, listados em ordem de quão pouco colocam em risco. O primeiro não envolve o modelo.

O diagrama Mermaid mostra onde cada controle fica no caminho de um ticket. Observe os pontos em que uma requisição sai do caminho antes de chegar ao modelo e o registro de custos que escuta em cada saída.



Short paths determinísticos

A chamada ao modelo mais barata é a que não acontece. Um caminho codificado para os poucos tipos de ticket que respondem pela maior parte do volume, como “onde está o meu pedido” tratado por uma chamada a `lookup_order` e um status formatado, responde sem nenhuma chamada ao modelo (o Capítulo 14 descreve o mesmo caminho como um degrau de fallback). Como controle de custo, ele se justifica em um dia normal.

A mesma ideia vale para o agente de operações. Digamos que quarenta alertas disparem por uma única causa. Abrir quarenta investigações é quarenta vezes o gasto para uma resposta. Uma etapa de agrupamento antes do agente, baseada na origem do alerta e na janela de tempo, inicia um run e anexa os outros trinta e nove a ele. O nível de subject do Capítulo 13 conta runs por subject; o agrupamento é a etapa que faz essa contagem significar alguma coisa.

Um short path é determinístico, então recebe testes clássicos, não evals (Capítulo 21). Criaria short paths para os poucos tipos de ticket mais frequentes com resposta clara nos dados das ferramentas e pararia por aí.

Roteamento de modelos

Um router escolhe o nível de modelo para um run ou um passo: um nível menor e mais barato para o trabalho fácil, o nível primário para o resto. O princípio é o que governa todos os controles deste livro: a decisão de roteamento é tomada pelo código a partir de sinais estruturados e é validada por evidência. Um router que pede ao modelo que avalie a própria dificuldade é mais uma proposta, e deve ser avaliado como tal.

A regra à qual me manteria fiel é que nenhuma rota é barata até que um eval diga que ela pode ser. A tabela de rotas nomeia, para cada tipo de ticket, o nível e a execução de eval que o justificou.

```
function pickRoute(run, ticket):
    if shortPaths.matches(ticket):                // structured
signals only
        return "short_path"
        type = ticketType(ticket)                // deterministic
classifier
        entry = routeTable.lookup(type)
        if entry == null or entry.eval_run == null:    // no eval, no cheap
route
            return routeTable.default                // the tier that was
evaluated
        return entry.tier

function escalateTier(run, current, reason):
    if reason not in ["invalid_output_twice", "gate_refused_twice"]:
        return current                                // not a reason to
pay more
    run.bound_counters.escalations = run.bound_counters.escalations + 1
    if run.bound_counters.escalations > run.limits.escalations:
        raise BoundExceeded(level: "run", kind: "escalations") //
escalation is spend, so it is bound
    return nextTier(current)
```

O escalonamento é a parte fácil de esquecer. Se o nível pequeno produz uma saída malformada (F1) ou chamadas de ferramentas que o gate recusa duas vezes (F2, ferramenta incorreta ou argumentos incorretos), subir um nível é razoável, e é também uma segunda chamada que você paga além da primeira. Por isso os escalonamentos são contados e limitados, e

constam do registro: uma rota cuja taxa de escalonamento sobe é uma rota cujo nível pequeno não está dando conta do trabalho, e a tabela deve dizer isso.

Uma política ilustrativa mantém a evidência junto da rota, para que um revisor possa ler por que uma rota é barata. A notação abaixo é ilustrativa e não é a sintaxe de nenhum produto real.

```
policy cost_routing:
  route delayed_parcel_status:
    tier: small
    evidence: eval_run "eval-0193", golden set "support/delayed_parcel"
    holds_if:
      resolution_rate >= baseline - 2 points // checked on each eval run // illustrative margin
      f3_rate <= baseline // no more ungrounded claims
      refused_proposal_rate <= baseline
    review_every: 30 days
    default: primary
```

Uma rota não é permanente. Uma mudança no prompt, no modelo, em uma ferramenta ou em uma política é uma execução de eval (Capítulo 21), e uma rota cuja evidência está desatualizada volta ao nível padrão em vez de continuar barata por fé. O custo é pago em execuções de eval e na disciplina de manter a tabela: a economia só é real se a tabela estiver em dia.

A dieta do contexto

Os tokens de entrada se repetem a cada passo, então o contexto é a alavanca com o maior multiplicador. O Capítulo 9 trata de como o contexto é montado; a lente do custo acrescenta uma pergunta: qual fonte do contexto se paga?

O manifesto de contexto que o Capítulo 9 recomenda registra a origem e o tamanho de cada item. Combinado ao evento de custo, ele dá um detalhamento dos tokens de entrada por origem: política do sistema, texto do ticket, resultados de ferramentas, trechos recuperados, notas de memória, histórico. O detalhamento costuma ser revelador. Um resultado de ferramenta que devolve o registro inteiro de um pedido quando o passo precisa de dois campos é o caso comum, e reduzir um resultado aos campos de que o passo seguinte precisa é também uma redução de PII (Capítulo 17). Resultados de ferramentas repetidos, trechos recuperados que nada citou e histórico antigo que já não informa a decisão são os outros.

A dieta tem um custo em qualidade. Cada item removido é algo em que o modelo já não pode fundamentar uma afirmação, e remover demais produz F3 (afirmação sem fundamento) ou F5, por meio de um contexto ausente ou obsoleto. Assim, a dieta é uma mudança respaldada por eval como qualquer outra: remover, executar o golden set, ler a distribuição das classes de falha e manter a mudança somente se os números se sustentarem. A sumarização do histórico merece desconfiança especial, porque um resumo é uma saída de modelo, com o risco de F3 que isso implica (o Capítulo 9 descreve o que cada truncamento perde).

Cache e o que ele arrisca

Um cache devolve um resultado anterior em vez de recalculá-lo, e o custo disso é o risco de que o resultado anterior não seja mais verdadeiro. Três coisas diferentes são chamadas de cache, com riscos diferentes.

Fazer cache de **dados de leitura**, como o status de um pedido ou o resultado de uma busca na documentação, é o mais seguro. Dê a cada item uma idade máxima na política, registre a idade no trace e informe ao leitor quando isso importar, como o Capítulo 14 faz para as respostas de modelo. Nunca use um valor em cache como base de uma escrita: um reembolso ou uma mudança de endereço é verificado no gate contra uma leitura nova. Leituras obsoletas são F5, e um cache alarga a janela.

Fazer cache de **respostas do modelo** indexadas pela requisição é mais arriscado, porque a chave não é a situação. Uma resposta sobre a encomenda atrasada de um cliente está errada para a de outro, mesmo quando o texto parece semelhante. Se for fazer cache, a chave inclui o principal, o tenant, os resultados de ferramentas dos quais a resposta dependeu e a versão do prompt e da política. Um cache que atravessa clientes é uma exposição de PII (Capítulo 17), e um cache que sobrevive a uma mudança de prompt é uma forma de um comportamento já corrigido continuar em execução. Não faria cache de respostas finais que chegam a um cliente, nem de nada que tenha levado a um efeito.

O cache de **resultados de retrieval** indexado pela versão do documento é o caso intermediário: se a documentação não mudou, os trechos também não, e a chave diz isso. Ele economiza uma busca e um novo embedding, e falha quando a versão não faz parte da chave. Seja o que for que você co-

loque em cache, um acerto de cache é um evento no trace, com a sua idade, para que uma resposta errada possa ser rastreada até uma entrada em cache.

```
function cachedRead(run, key, maxAgeSeconds, fetch):
  entry = cache.get(scopeKey(run.principal, run.tenant_id, key))  //
scope in the key
  if entry != null and now() - entry.stored_at <= maxAgeSeconds:
    record(run, "cache_hit", { key: key, age: now() - entry.stored_at })
    return { value: entry.value, age: now() - entry.stored_at } // age
travels with it
    value = fetch() // a
miss is a fresh read
    cache.put(scopeKey(run.principal, run.tenant_id, key), value, stored_at:
now())
    return { value: value, age: 0 }
```

Limites como controles de custo

Os capítulos 12 e 13 tratam dos limites de passos, de chamadas de ferramentas e de tokens, e cada um deles é um controle de custo nos dias em que um run se comporta mal. O ponto específico do custo é que esses limites são definidos a partir da distribuição dos runs legítimos, e o registro de custos é de onde essa distribuição vem.

Anomalias de custo e o kill switch

Os tetos do Capítulo 13 contêm o pior caso. Os alarmes sobre o registro de custos pegam os casos entre um dia normal e um teto, e precisam ser atribuídos para serem acionáveis.

Sinal	Comparado com	Primeira pergunta
Gasto por hora, por agente	A mesma hora nas últimas semanas	Houve um deploy, uma mudança de rota ou uma mudança de tráfego?
Custo por run, cauda superior	Distribuição para aquele tipo de ticket	Qual funcionalidade ou tenant está na cauda?
Tokens de entrada por passo	Média recente para a versão do agente	O contexto cresceu, e qual origem?
Parcela de retries e fallbacks nas chamadas	Parcela normal	Um provedor ou uma dependência está degradado (Capítulo 14)?
Custo por ticket resolvido	Janela recente	A taxa de resolução mudou?

Sinal	Comparado com	Primeira pergunta
Gasto muito abaixo do normal	A mesma hora nas últimas semanas	Os runs pararam, um breaker abriu ou um short path engoliu tickets?

A última linha é a que as pessoas não configuram. Um custo que cai bruscamente também é uma anomalia, porque um agente que faz menos trabalho gasta menos. Um breaker que abriu, um short path que corresponde a coisas demais ou um orquestrador que não está iniciando runs parecem, todos, economia na fatura. Associe cada alarme de custo a um sinal de volume ou de resultado, para que os dois possam ser lidos juntos.

Os alarmes devem comparar com a versão do agente e com a rota, e não apenas com uma média global, porque uma mudança que moveu o custo é quase sempre uma mudança em uma dessas duas coisas. O marcador de deploy, a versão do prompt e a versão da tabela de rotas pertencem ao dashboard, ao lado da linha de custo. É a parte Registro fazendo aquilo para o que existe.

Quando um alarme se revela real, limite primeiro o ponto para onde a atribuição aponta: reduza o orçamento do subject ou do tenant, ou mande aquela rota para o nível padrão. Se o custo estiver espalhado e crescendo, use o breaker no nível do agente e o kill switch do Capítulo 13; o runbook declara esse trade-off de antemão (Capítulo 23).

Nota: Todo alarme de custo precisa de um responsável nomeado e de uma primeira ação, o que o Capítulo 13 enuncia como regra e o Capítulo 23 mantém no runbook.

Tornar visível o mais barato

Todo controle acima pode piorar o agente, e a forma como ele falha é silenciosa. O custo é medido diariamente e a qualidade é medida quando alguém olha, de modo que uma redução de custo pode parecer uma vitória clara por semanas. A maneira de manter as duas coisas juntas é fazer com que toda mudança de custo traga a sua evidência de qualidade.

Para uma mudança que você pode executar offline, como uma mudança de rota, uma dieta de contexto ou um limite de passos diferente, execute o golden set (Capítulo 21) com a versão atual e com a candidata, e compare

o custo por caso resolvido, a taxa de resolução e a distribuição das classes de falha. Um custo que cai enquanto as taxas de F3 ou de F2 sobem é uma transferência, da fatura para os revisores e para os clientes que receberam uma resposta errada. Declare a regra de aceitação como um limiar de qualidade antes da execução, para que um bom número de custo não consiga se impor a um mau número de qualidade.

A evidência offline não basta para os sinais tardios, como um ticket reaberto ou uma decisão revertida. Para mudanças que afetam respostas voltadas ao cliente, encaminhe uma pequena parcela do tráfego para a candidata e compare as taxas de hand-off, de reabertura e de propostas recusadas com o baseline ao longo de um ciclo semanal completo (o Capítulo 21 trata de shadow e canary).

Se o golden set não contém o tipo de ticket que uma mudança afeta, você não tem evidência e não deve afirmar uma economia.

Parcelport: dois runs, item por item

Considere um ticket de encomenda atrasada na Parcelport. O orquestrador verifica primeiro se há um run aberto para o ticket; não há. O matcher de short path não encontra correspondência, porque o cliente pergunta sobre uma entrega atrasada e um possível reembolso, o que não é uma pergunta de status. A tabela de rotas envia esse tipo de ticket ao nível pequeno, para o qual há uma execução de eval registrada, e o run começa sob seus orçamentos.

O run dá quatro passos: `lookup_order`, `search_docs` para a política de atrasos, `send_customer_reply` com o texto redigido e a resposta final. Cada chamada ao modelo e cada chamada de ferramenta grava o próprio evento de custo, com a rota `small`, a versão do agente, a funcionalidade `delayed_parcel` e o tenant opaco. O contexto do primeiro passo é pequeno; no quarto, resultados de ferramentas e um trecho recuperado já foram acrescentados. O manifesto mostra que o registro do pedido contribuiu com a maior parcela dos tokens de entrada, com campos que o rascunho nunca usou, e a próxima mudança no formato do resultado de `lookup_order` os elimina. O custo do run é a soma de sete eventos, um

evento de modelo para cada um dos quatro passos e um evento de ferramenta para cada um dos três primeiros, e nada nele está na agenda de um humano.

Agora um caso de operações. Uma tempestade de alertas produz quarenta alertas de uma mesma causa. A etapa de agrupamento inicia uma investigação e anexa o resto. O agente de operações executa vários passos de `query_logs` e `get_metrics` e um `run_diagnostic`, cujo evento de custo registra segundos de sandbox. Duas de suas chamadas a `query_logs` varreram intervalos de tempo amplos, o que só é visível porque o custo das ferramentas está no evento, e o intervalo limitado do contrato (Capítulo 7) é apertado como resultado. O run chega a um PR e a uma proposta de rollback e então é suspenso, aguardando Robin. Enquanto está suspenso, não ocupa nenhum worker nem sandbox, porque o seu estado está no run store (Capítulo 10). O custo por investigação inclui os minutos de aprovação de Robin.

No fim da semana, o registro de custos responde à pergunta da liderança de operações de uma forma que Alex consegue defender: custo por ticket resolvido por funcionalidade, a parcela que é modelo, ferramenta e humano, e o que mudou desde a semana anterior e por quê. Ele não consegue respondê-la com perfeição. Os minutos humanos são estimativas combinadas com a liderança de suporte, e o número carrega essa incerteza, o que é melhor que um número que não diz de onde veio.

Trade-offs e custos

A atribuição tem custo. Um registro mais grosseiro, apenas por run e agente, é mais barato e responde a menos perguntas. Começaria com run, versão do agente, funcionalidade e rota, e acrescentaria o tenant quando alguém precisar cobrar ou limitar por ele.

O roteamento e os short paths acrescentam componentes que precisam ser mantidos em sincronia com o agente. Se o seu volume é pequeno, digamos algumas dezenas de tickets por dia, um único nível com bons limites é a melhor escolha; não construa um router antes de ter uma distribuição sobre a qual rotear.

O cache troca correção por custo. Se você não consegue declarar uma idade máxima e um escopo de chave para um cache, não o adicione.

Alarmes de custo apertados geram pages, então ajuste-os primeiro em modo de observação, como o Capítulo 13 recomenda para os limiares.

Por fim, o custo não é o objetivo. Onde o trabalho tem muito em jogo, como reembolsos acima do teto ou mudanças em produção, preferiria pagar pelo nível mais forte e pela aprovação, e dizê-lo na política.

Erros comuns

- **Cortar o custo do modelo sem medir o custo humano.** É tentador porque a fatura é a linha visível. Calcule o custo por ticket resolvido incluindo os minutos de hand-off e de aprovação, e julgue cada mudança por ele.
- **Tratar um nível mais barato como uma configuração.** É tentador porque é uma linha em um arquivo de configuração, mas é uma mudança de comportamento. Condicione cada rota barata a uma execução de eval e devolva-a ao nível padrão quando a evidência estiver velha.
- **Fazer cache entre principais.** É tentador porque uma chave compartilhada dobra a taxa de acertos. Uma chave que omite o cliente ou o tenant transforma uma otimização em uma exposição de PII. Delimite o escopo da chave, registre a idade e nunca baseie uma escrita em uma leitura em cache.
- **Deixar o escalonamento gastar à vontade.** É tentador porque um nível mais forte dá a sensação de seguro. Recorrer a um nível mais forte a cada dúvida dobra a chamada. Conte os escalonamentos como gasto e limite-os.
- **Alarmar apenas sobre aumentos.** É tentador porque os picos de custo são a falha conhecida. Uma queda brusca de custo pode significar que o agente parou de funcionar. Associe cada sinal de custo a um sinal de volume ou de resultado.

Pontos-chave

- O custo é a pergunta cotidiana da parte Limite: os orçamentos do Capítulo 13 contêm o pior caso, e o controle de custos trata do gasto que fica abaixo de todos os limites e mesmo assim está errado.

- Registre o uso bruto em cada span, com run, versão do agente, funcionalidade, rota e um tenant opaco, e calcule o dinheiro a partir de uma tabela de preços versionada na hora do relatório.
- Gerencie pelo custo por ticket resolvido ou por investigação, incluindo os minutos humanos que hand-offs e aprovações causam, porque a fatura costuma ser a parte menor.
- Os controles, em ordem de risco, são short paths que dispensam o modelo, roteamento condicionado a eval, uma dieta de contexto, cache com escopo e limites ajustados a partir de distribuições reais; cada um precisa de evidência de que a qualidade se manteve.
- O custo do contexto cresce mais rápido que o número de passos, então o tamanho do contexto e os limites de passos são controles de custo, e todo valor em cache precisa de uma idade, de um escopo e de nenhum papel em uma escrita.
- Alarme sobre taxa e formato, e associe os sinais de custo a sinais de resultado; o responsável e a primeira ação de cada alarme vivem no run-book (Capítulo 23).
- Mais barato só é melhor quando o eval mostra que a qualidade se manteve, e uma economia que move o custo para a fila humana ou para respostas erradas é uma transferência, não uma economia.

Quando o custo está compreendido e limitado, a pergunta que resta é o que fazer no dia em que algo dá errado de um modo que nenhum limite previu. O Capítulo 23 trata desse dia: como a Parcelport detecta, contém e aprende com um incidente que um agente causou ou não conseguiu evitar.

Capítulo 23 — Resposta a incidentes

Imagine um turno da noite na Parcelport, pouco depois das três da manhã. Um alerta de latência dispara nas páginas de pedidos, e Robin, o SRE de on-call, pede ao agente de operações que investigue. O agente lê métricas, puxa um trace e propõe `request_rollback` para o deploy mais recente, que começou pouco antes do pico. A requisição de aprovação parece razoável, Robin aprova, e o `deploy-service` inicia o rollback. Vinte minutos depois, a latência não se moveu.

Enquanto Robin volta a ler as métricas, Sam, a liderança de suporte, manda uma mensagem no canal de on-call. A fila de suporte mostra mais reembolsos do que o habitual para esse horário, e duas respostas enviadas pelo agente de suporte mencionam reembolsos que os clientes não pediram. Ninguém sabe se isso é um segundo problema, uma consequência do rollback ou uma coincidência. Ninguém sabe qual versão de prompt, qual modelo por trás do gateway e qual contrato de ferramenta cada run usou, e quem poderia responder está dormindo.

Os dois agentes continuam em execução. A fila de reembolsos continua crescendo, e não está claro quem pode parar o quê.

Este capítulo pertence à parte **Registro** do envelope de controle, a parte que responde: o que fazemos quando dá errado? Tudo o que veio antes no livro reduz a taxa e o alcance das propostas ruins. Este capítulo trata da hora seguinte à passagem de uma delas e do que precisa existir antes que essa hora comece.

O problema e por que ele é difícil

Um **incidente**, neste livro, é uma situação em que o comportamento de um agente causou ou ameaça causar dano, e a resposta é organizada. A palavra “ameaça” é deliberada. Um gate que recusou mil propostas de re-

embolso em dez minutos não causou dano algum, e mesmo assim é algo que uma pessoa deveria examinar antes que as propostas encontrem uma brecha. Tratar como incidente apenas o dano consumado significa que o primeiro incidente é o caro.

Um incidente de agente difere de um incidente clássico de serviço de três maneiras, e cada uma muda o que a resposta exige.

A primeira é a **não reprodutibilidade**. Um bug em um serviço se reproduz: você reexecuta a requisição, vê a falha, corrige o código. Um modelo devolve uma proposta diferente para o mesmo contexto, então reexecutar um run contra o modelo prova pouco. As partes determinísticas podem ser reexecutadas com exatidão, mas “execute de novo e veja” não é uma estratégia de investigação. A investigação precisa partir do registro, o que faz da F8 (comportamento não observado) a classe de falha que torna insolúvel todas as outras.

A segunda é uma **superfície de efeitos ampla**. Um endpoint de serviço defeituoso atinge os chamadores desse endpoint. Uma versão defeituosa de agente atinge todas as ferramentas que ela podia chamar, para todos os clientes ou implantações que atendeu enquanto a falha estava ativa, e cada um desses efeitos passou por um sistema downstream diferente: `payments-service`, `shipping-service`, o sistema de tickets, `deploy-service`. A lista de impacto é um join entre todos eles, e a primeira pergunta na sala é “o que mais ele fez?”, que só pode ser respondida se os efeitos foram registrados (Capítulo 10, Capítulo 20).


A terceira é a incerteza de que “o modelo mudou”. O comportamento pode se mover porque um prompt foi editado, um contrato de ferramenta mudou, uma política foi atualizada, um índice de retrieval foi reconstruído ou o modelo por trás de um alias do gateway foi trocado ou atualizado pelo provedor. Enquanto os rótulos de versão nos spans não disserem qual combinação cada run usou (Capítulo 20), a equipe investiga um alvo em movimento.

As classes de falha aparecem em um incidente de um jeito particular. F6 (falha parcial silenciosa) e F7 (efeito não autorizado) são as que tornam um incidente caro, e a F8 é a que o torna longo. A detecção muitas vezes chega por uma classe sem relação com a original: um alarme de custo

(F9) que se revela um loop descontrolado (F5), ou uma reclamação de cliente sobre uma F3 (afirmação sem fundamento) que leva a um problema de contexto obsoleto a montante.

Nada disso é um problema de prompt. Uma mensagem ao agente dizendo “pare de emitir reembolsos” é um pedido a um componente que, por suposição, não é confiável, e é a ferramenta errada justamente no dia em que mais importa. A contenção, a análise de impacto e a compensação são feitas por código determinístico e por pessoas, com controles construídos de antemão. Essa é a questão de engenharia: o que precisa ser verdade antes do incidente para que a resposta seja rápida, estreita e reversível?

A sequência abaixo é o formato que o restante do capítulo segue. Observe a seta que volta: a contenção pode ser ampliada quando o dano continua, e nada avança para a restauração até que a revisão tenha produzido controles.



Detecção: três tipos de sinal

O Capítulo 20 constrói as métricas e os alertas. Para a resposta a incidentes, o que importa é como um incidente se anuncia, porque o caminho que ele tomou é, em si, um achado. O registro de incidente do Capítulo 3 tem

um campo para isso, `detected_by`, e o segundo valor que esse campo pode assumir, “reported by a person”, significa que falta um sinal de detecção.

Três vias cobrem a maioria dos casos.

- **Sinais no nível do agente.** Recusas do gate, recusas de aprovação, erros idênticos repetidos ou volume de efeitos em relação ao baseline da mesma versão do agente, os sinais sobre os quais o breaker do Capítulo 13 atua. Um disparo de breaker se tornar ou não um incidente é uma decisão humana.
- **Achados de reconciliação.** O sweep do Capítulo 10 encontra as lacunas que nenhum run percebeu, como um run marcado como concluído com uma intenção aberta. São os sinais mais precisos e chegam tarde, porque um sweep roda em um agendamento.
- **Pessoas e custo.** Um cliente escreve, Sam vê um padrão estranho na fila, o financeiro vê uma linha de gasto (Capítulo 22), uma pessoa da revisão de segurança, como Jordan, nota um efeito que não corresponde à autoridade emitida. São os mais lentos, e o cenário de abertura começou por eles.

Um sinal se torna um incidente quando alguém declara um, e declarar deve ser barato. Uma equipe que trata a declaração como um evento pesado, com reunião e documento, esperará até ter certeza, e a certeza chega depois do dano. Escreveria uma regra de uma linha no runbook: qualquer pessoa do rodízio pode declarar, declarar não tem penalidade, e um incidente declarado que se revela nada é encerrado com uma nota curta e contado como uma simulação.

Na declaração, o primeiro ato é atribuir uma **severidade**, usando os níveis do Capítulo 3: informação, reversível, irreversível, externo. O nível segue o efeito que de fato aconteceu ou é possível, e por isso define quem recebe um page e com que rapidez. Um suposto reembolso errado ou uma resposta indesejada a um cliente fica, no mínimo, no nível irreversível ou externo até que se prove o contrário, e a resposta começa nesse nível.

Sinal	Normalmente aponta para	Primeiro olhar
Volume de reembolsos acima do baseline	F2, F7, às vezes F5	Efeitos de <code>issue_refund</code> por versão do agente e janela de tempo

Sinal	Normalmente aponta para	Primeiro olhar
Pico na taxa de recusas	F1, F2, F4	Razões do gate agrupadas por ferramenta e por origem da entrada
Runs marcados como concluídos com intenções abertas	F6	Os achados de reconciliação e os registros de intenção
Taxa de gasto acima do baseline	F5, F9	Contagem de passos e retries por run, por versão
Cliente relata uma promessa errada	F3, às vezes F5	O run, seus resultados de ferramentas e a afirmação na resposta
Efeito sem autoridade emitida correspondente	F7	O log de emissão do gateway de ferramentas contra o efeito

Contenção: a escada que você constrói antes de precisar

A contenção interrompe o dano sem ainda compreendê-lo. Seu princípio de design é o mesmo do Capítulo 13: use o controle mais estreito que interrompa o dano e mantenha um mais amplo à mão. Uma resposta que só consegue desligar o agente inteiro será usada tarde, porque desligar o agente inteiro tem um custo em clientes esperando, e uma equipe que teme esse custo hesitará.

A escada abaixo é ilustrativa. Cada degrau é um controle que existe antes do incidente, com um responsável, e cada um é uma flag ou uma operação, não uma mudança no prompt do agente.

Degrau	O que faz	O que interrompe	O que custa	Desfazer
Fixar a versão anterior	Devolve prompt, alias de modelo, contratos de ferramentas e política à última versão conhecida	Uma regressão introduzida por uma mudança	Perde a mudança; a versão fixada pode ter problemas conhecidos próprios	Avançar a fixação
Desabilitar uma ferramenta	O gateway de ferramentas recusa uma ferramenta para um agente	O efeito dessa ferramenta	Os runs que precisam dela fazem hand-off	Reabilitar com um motivo registrado

Degrau	O que faz	O que interrompe	O que custa	Desfazer
Modo restrito	Leituras e rascunhos continuam; todo efeito acima de leitura é recusado ou precisa de aprovação	Todos os efeitos novos	O throughput cai; as pessoas assumem o trabalho	Reinício manual
Enfileirar trabalho novo	Tickets ou tarefas novos esperam em vez de começar	Runs novos	Os clientes esperam, então é preciso uma mensagem	Liberar a fila
Revogar credenciais	Revoga os grants que um agente possui (Capítulo 18)	Qualquer coisa em andamento que detenha autoridade	Chamadas em andamento falham; exige que o caminho de revogação tenha sido exercitado	Emitir novos grants
Parar	O kill switch: nenhum run novo; os runs em andamento esperam na próxima fronteira de passo	Tudo o que o agente faz	Toda a carga de trabalho vai para as pessoas	Reinício manual

Duas observações sobre a tabela. Primeiro, os degraus não são uma ordem de escalonamento que você precise subir. Se o sinal é um reembolso errado, desabilitar `issue_refund` é o primeiro movimento, e o agente de suporte pode continuar lendo pedidos e redigindo respostas para Sam enviar. Segundo, revogar credenciais é um tipo diferente de degrau: é a resposta a um vazamento suspeito ou a um efeito que deveria ter sido impossível (F7), e importa mesmo quando a causa ainda não é conhecida, porque as credenciais são a parte que torna o dano possível.

Os mecanismos foram construídos antes: o kill switch e suas propriedades no Capítulo 13, a operação de revogação no Capítulo 18, o caminho de aprovação no Capítulo 15. A contribuição deste capítulo é que eles sejam escritos como um **runbook** para cada agente, um documento na documentação em que o agente de operações e as pessoas possam pesquisar. Uma entrada de runbook nomeia o gatilho, o controle, quem pode acioná-lo, como confirmar que ele surtiu efeito e o que dizer às pessoas que ele afeta. Eis uma entrada em notação ilustrativa.

```

runbook contain_unexpected_refunds    // illustrative notation
trigger:  refund volume over baseline, or refund with no matching ticket
step 1:   disable tool issue_refund for support-agent
           operators: Sam, Alex
           confirm: gate returns "refuse" for a synthetic refund call
step 2:   pause the approval queue for refunds
           // approvals granted before the pause stay valid until expiry;
           // check the pending list before assuming they are gone
step 3:   freeze trace retention for affected versions
           // containment must not delete the evidence
step 4:   post to the incident channel: what is stopped, what is not
widen:    if refunds continue after step 1, restricted mode;
           if effects continue after restricted mode, stop
restore:  only after impact list and review owner are recorded

```

O código que aciona um controle tem um pequeno problema de ordenação que vale a pena mostrar, porque o flag store, o log de incidentes e o canal de chat são sistemas separados e nenhuma transação os abrange. A ordem é: interromper o dano primeiro, registrar em segundo, notificar em terceiro, e uma falha nas etapas posteriores nunca bloqueia as anteriores.

```

function containTool(incident, agent, tool, operator):
    flagStore.set("disable", { agent: agent, tool: tool }) // harm stops
    first
    confirmed = gateProbe(agent, tool)                      // synthetic
    call, expects "refuse"
    try:
        record(incident, "contained", { tool: tool, by: operator, confirmed:
        confirmed })
        on RecordFailed:
            // the control is already in force; a person writes the timeline by
            hand
            page(incident.scribe, "containment not recorded: " + tool)
            if not confirmed:
                page(incident.lead, "flag set but gate still allows " + tool)
                raise ContainmentUnconfirmed // widening is a human
            decision
            return "contained"

```

Aviso: Não contenha um incidente editando o prompt do agente, e não apague runs, traces nem aprovações enfileiradas para arrumar a casa. Uma mudança de prompt é um pedido a um componente pouco confiável, e a evidência apagada elimina a capacidade de saber o que aconteceu, que é a falha que a F8 nomeia e da qual uma revisão não consegue se recuperar.

Se o agente do incidente é o agente de operações, há uma complicação prática: a ferramenta que você usaria para investigar é a própria coisa sob suspeita. As pessoas consultam diretamente o log store, o metrics store e o trace store, e o runbook diz quais são essas consultas, para que ninguém precise pedir ao agente suspeito que se explique.

Análise de impacto: do registro a uma lista

Quando o dano para de crescer, a pergunta é o seu tamanho. A resposta é uma lista: quais runs foram afetados, o que cada um fez e qual é o estado de cada efeito agora. A lista vem do registro, e sua qualidade é uma medida direta da cobertura de traces do Capítulo 20.

A consulta tem três partes: um **escopo** (quais versões do agente, qual janela, quais ferramentas), um **filtro** sobre o efeito que importa e um **join** com o sistema downstream que guarda a verdade. No exemplo dos reembolsos, o escopo são as versões do agente de suporte ativas durante a janela, o filtro são as intenções e os resultados de `issue_refund`, e o join é com o `payments-service`, o único escritor de reembolsos. O registro mostra o que o run acreditou ter feito; o serviço mostra o que realmente aconteceu. O incidente se importa com os dois e com a diferença entre eles.

```
function buildImpactList(incident, scope):
  runs = traceStore.runsWhere(agent: scope.agent, versions:
scope.versions,
                                from: scope.start, to: scope.end)

  impact = []
  for each run in runs:
    for each effect in effectsOf(run, tools: scope.tools):
      actual = lookupInOwningService(effect) // not the run's
own belief
      impact.append({ run: run.id, effect: effect, actual: actual,
state: classifyImpact(effect, actual) })
  uncovered = runsWithoutCompleteRecord(runs)
  return { affected: impact, unknown: uncovered } // unknown is a
result, not an error
```

A lista `unknown` importa. Alguns runs da janela podem não ter registro completo, porque um span foi descartado ou um trace ficou fora da amostragem. Esses runs não podem ser classificados como afetados ou não afetados, e uma contagem de runs afetados que os deixa de fora em silêncio

subestima o incidente. A lista deve declarar sua cobertura: digamos, “40 runs afetados, 6 runs na janela sem registro utilizável”, com números hipotéticos aqui e reais no incidente.

Cada efeito afetado recebe um estado. Quatro bastam:

- **Harmed:** o efeito aconteceu e estava errado (um reembolso no pedido errado).
- **Exposed:** o efeito ou a saída chegou a algo a que não deveria, sem dano confirmado ainda (uma resposta que incluiu um campo que não deveria).
- **Intended:** o efeito aconteceu e estava correto. Esses runs pertencem à lista porque a janela do incidente os contém, e removê-los da lista sem verificar é como se traça uma fronteira errada.
- **Unknown:** o registro está incompleto, ou o serviço responsável não consegue confirmar.

A lista é também o que um leitor externo precisa. Uma pessoa revisora que atue sob um regime como o GDPR ou a KVKK normalmente vai querer ver a janela de tempo, quais classes de dados estiveram envolvidas e quem foi afetado. O jurídico e a conformidade são responsáveis pela interpretação do que isso significa para a notificação, e a contribuição da engenharia é uma lista que possa ser produzida em horas e não em semanas.

Desfazer os efeitos

A compensação segue a classe de efeito, e os contratos já dizem o que é possível, porque o Capítulo 6 exige que cada escrita reversível nomeie o seu desfazer.

Classe de efeito	Como é desfazer	Quem faz
leitura	Nada a desfazer; se a leitura expôs dados PII, a exposição é tratada pelo responsável pelos dados (Capítulo 17)	Responsável pelos dados
escrita reversível	A ação compensatória do contrato: restaurar o endereço antes do hand-off para a transportadora, reverter uma flag, fazer o deploy da versão anterior de novo	Uma pessoa, ou a mesma ferramenta pelo gate com aprovação

Classe de efeito	Como é desfazer	Quem faz
escrita irreversível	A Parcelport não tem desfazer. Um reembolso emitido por engano é uma perda a ser tratada pelos processos do financeiro e do suporte, o que pode incluir uma conversa com o cliente	Pessoas, por meio dos processos existentes
efeito colateral externo	Uma correção, escrita e revisada por uma pessoa; uma mensagem enviada não pode ser desenviada	Sam ou alguém delegado

O princípio por trás da tabela é que a compensação é, ela mesma, um efeito, e o agente que causou o incidente não a executa. Uma ação compensatória passa pelo gate como qualquer proposta, com a própria chave de idempotência e, onde a política exigir, a própria aprovação. No meio de um incidente, é tentador deixar um agente de confiança aplicar cinquenta correções em um loop. Resista, porque a correção é o momento em que a ferramenta tem mais chance de ser chamada com argumentos construídos a partir de um contexto errado do mesmo modo que o primeiro.

A compensação é rastreada, não presumida. Cada efeito afetado na lista de impacto passa por um pequeno conjunto de status:

```
compensation_item
effect:      reference to the impact list entry
plan:        compensating action, or "none available" with the reason
status:      planned | approved | applied | confirmed | not_possible
confirmed_by: the owning service's state, never the run's own record
owner:       a person
```

O campo a que se apegar é `confirmed_by`. Uma compensação aplicada e registrada no run é o mesmo tipo de afirmação que o efeito original: diz o que o sistema tentou, e o serviço diz o que é verdade. O incidente permanece aberto enquanto algum item estiver planejado ou aprovado, mas não confirmado, e `not_possible` é um estado final legítimo quando vem com um responsável nomeado para a conversa que resta.

Um resultado que é `unknown` quando o incidente começa, como uma chamada de reembolso que deu timeout, é resolvido primeiro, lendo o status do serviço como o Capítulo 10 descreve. Compensar um efeito que não aconteceu cria o segundo incidente.

Encontrar a causa-raiz

A análise de causa-raiz tem a mesma estrutura da classificação do Capítulo 3, aplicada às evidências da lista de impacto: a classe de falha (o que deu errado no run), o eixo (modelo, contexto, ferramenta ou controle) e a severidade (até onde chegou). “O modelo propôs algo errado” não é uma causa-raiz. É o gatilho, e a pergunta da causa-raiz é por que a proposta errada pôde importar.

Como o run não pode ser reproduzido chamando o modelo de novo, a investigação faz o replay do material **registrado**. Há três replays, e cada um responde a uma pergunta diferente.

1. **Replay do contexto.** Remonte o que o modelo viu a partir do registro, com rótulos de proveniência. Algo estava faltando, obsoleto, sem rótulo ou vinha de uma fonte em que não se deveria confiar? Esse é o eixo do contexto.
2. **Replay da proposta contra o gate.** Pegue a proposta registrada e passe-a pelo gate como ele é hoje e como era na época. Se o gate antigo a permitiu e o atual a recusa, a correção já está feita. Se ambos a permitem, falta uma verificação ao gate, e esse é o eixo do controle.
3. **Comparar versões.** Pegue os casos do golden set que se parecem com os runs que falharam e execute-os na versão anterior e na posterior à mudança (Capítulo 21). Se a taxa de uma falha se move com uma mudança de modelo e nada mais, o eixo do modelo está honestamente implicado, e a resposta tem duas partes: segurar ou reverter a mudança de modelo e acrescentar o controle que teria tornado a regressão visível.

De volta ao cenário de abertura, suponha que a revisão encontre o seguinte, em forma ilustrativa. O agente de operações leu a lista de deploys no início do run e propôs o rollback do deploy mais recente, que se correlacionava com o pico apenas pelo horário. A requisição de aprovação mostrava a versão e as taxas de erro calculadas antes e depois do release, e nada sobre o que mais o release continha. Robin aprovou uma requisição que era precisa e incompleta. As classes são F2 (argumentos incorretos: o deploy era o alvo errado) e F5 (a correlação veio de um contexto lido no início do run), a severidade é reversível, e os eixos em ordem de classificação são controle (a requisição não mostrava o conteúdo do deploy e o gate

não tinha nenhuma verificação de que o alvo explicava o sintoma), depois contexto (a lista não foi relida), sem que nenhuma evidência implique o eixo do modelo. Os reembolsos que Sam viu são uma linha separada da revisão: a consulta de impacto, executada sobre as versões do agente de suporte e a mesma janela, os separa do rollback pelo timestamp. Nesta ilustração, eles são anteriores a ele; portanto, são um segundo problema que recebe o próprio registro de incidente e a própria classificação, não uma consequência do rollback nem uma coincidência.

Nada nessa conclusão culpa Robin, e nada culpa o modelo. O design deixou uma requisição incompleta chegar a uma pessoa que trabalhava às três da manhã, e o design tornou a aprovação fácil de dar. Os itens de ação decorrem dessa frase e não de uma pessoa.

A revisão sem culpa

Uma **revisão sem culpa** examina o sistema que permitiu a ação ou a tornou invisível. Ela acontece em poucos dias, não no fim da semana, enquanto as pessoas envolvidas se lembram dos detalhes, e é conduzida por alguém que não participou da resposta ao incidente, para que as perguntas não sejam defendidas. Jordan, da equipe de segurança, é uma pessoa razoável para formular as perguntas e não opera os agentes.

O modelo abaixo é ilustrativo. O `incident_record` do Capítulo 3 é o seu núcleo. Os campos adicionais existem para forçar a revisão a terminar em coisas que uma equipe pode construir.

```
incident_review                                // illustrative template
summary:                                       two sentences, no names, no "the AI"
timeline:                                     from the trace and the flag store, not from memory
                                              // times of: first bad effect, detection, declaration,
                                              // containment confirmed, impact list complete
detected_by:                                  signal name, or "reported by a person" (a finding)
impact:                                       the impact list summary, with the unknown count
classes:                                     F-ids in order, from proposal toward effect
severity:                                    information | reversible | irreversible | external
root_cause:                                  axis, rank, evidence link, for each cause
what_held:                                    controls that limited the harm
missing_control:                             the control that should have held
owner_team:                                  string          // the team that owns the missing control
action_items:                                list of { change, kind, owner, check }
                                              // kind: eval case | policy | contract | alarm | runbook
response_notes:                             what slowed the response; what the runbook lacked
```

Três regras mantêm a revisão honesta.

- **A linha do tempo vem do registro.** A memória sob estresse erra de maneiras previsíveis. Quando o registro não consegue fornecer um horário, essa lacuna é um achado sobre o Capítulo 20.
- **As pessoas aparecem como papéis.** “O SRE de on-call aprovou” é um fato. “O SRE de on-call deveria ter notado” é um julgamento sobre uma pessoa, e a versão útil é “a requisição não mostrava o que mais o release continha”.
- **Todo item de ação é um controle com uma verificação.** O teste que aplicaria é: este item teria se sustentado no dia em que o modelo propusesse de novo a coisa errada? “Tenha mais cuidado” não passa. “Acrescentar uma pré-condição de que o alvo do rollback seja confirmado contra uma janela de métricas” passa.

O produto de uma revisão não é um documento. É um conjunto de mudanças, e cada achado tem um lugar para ir, e é por isso que o modelo tem um `kind`.

Achado	Torna-se	Capítulo responsável
Uma proposta que deveria ter sido recusada	Uma nova pré-condição no contrato de ferramenta	6
Um efeito que nenhum principal deveria ter conseguido causar	Uma permissão ou um teto mais estreito	7
Uma requisição que não deu ao aprovador o que ele precisava	Uma mudança no que a aprovação mostra	15
Uma situação que ninguém viu chegar no registro	Uma nova métrica ou um novo alarme	20
Uma situação que o sistema deveria tratar de outra forma da próxima vez	Um caso de eval que falha na versão do incidente	21
Uma etapa da resposta que foi lenta ou estava ausente	Uma mudança no runbook e uma simulação	23

O caso de eval merece um esboço próprio, porque é o item mais frequentemente pulado e o que impede que o incidente se repita em silêncio. O caso é construído a partir do contexto registrado, com redaction conforme o Capítulo 17, com o resultado esperado declarado como um comportamento, como “refuses” ou “escalates”, e etiquetado com a classe de falha.

```

function incidentToEvalCase(incident, run, expected):
    context = redact(reassembleContext(run)) // PII and secrets
    removed first
    case = { context: context,
              expected: expected,           // "refuse", "escalate",
    ...
              failure_class: incident.classes.first(),
              source: incident.id }
    failRate = evalSuite.failRate(case, version: incident.version, repeats:
5) // say, five repeats (Chapter 21)
    if failRate < reproduceThreshold:      // set by the review
owner
        case.status = "not_reproduced"
        page(incident.lead, "eval case did not reproduce: " + incident.id)
        return case                       // kept, and a person
decides; never dropped
    goldenSet.add(case)
    return case

```

Um caso só entra no golden set se falha em uma taxa igual ou superior a uma taxa declarada ao longo das repetições, na versão que teve o incidente; abaixo dessa taxa, é marcado como não reproduzido e vai para uma pessoa em vez de ser descartado.

A revisão completa é para incidentes de nível reversível ou superior, e para qualquer incidente com uma lacuna de detecção, qualquer que seja a sua severidade; um quase-incidente de nível informação vira um ticket e um caso de eval.

O agente de operações durante um incidente

O agente de operações é um assistente óbvio para quem responde. Ele pode pesquisar nos runbooks com `search_docs`, ler logs, métricas e traces com `query_logs`, `get_metrics` e `get_trace`, agrupar erros e redigir uma linha do tempo para uma pessoa editar. Essas são ferramentas de leitura, e são a maior parte do que quem responde precisa na primeira hora.

Os limites importam mais que a ajuda. Manteria fidelidade ao seguinte durante um incidente.

- **A sua autoridade não se amplia.** O modo de incidente não é um break-glass para um agente. `request_rollback` e `toggle_feature_flag` continuam atrás de aprovação, `run_diagnostic` continua dentro do seu sandbox (Capítulo 19), e o agente não recebe credenciais adicio-

nais porque a situação é urgente. A urgência é a condição sob a qual um grant amplo é solicitado e não é revogado.

- **A sua saída é uma proposta.** Uma hipótese que o agente enuncia sobre a causa é uma afirmação não verificada (F3, se o contexto dele não a sustenta). Quem responde a confere nos stores, e ela não entra na linha do tempo nem na revisão até que alguém o tenha feito.
- **Ele não escreve a causa-raiz.** Pode reunir a evidência para os três replays acima. A classificação das causas e, em particular, a decisão de o eixo do modelo estar implicado ou não são decisões humanas, baseadas em um eval.
- **Ele não comunica.** Não envia nada a clientes e não publica no canal do incidente como uma autoridade.
- **Usá-lo é uma decisão.** Se o incidente é sobre o agente de operações, ou se o comportamento dele está em dúvida, quem responde o coloca em modo restrito junto com o resto e trabalha diretamente a partir dos stores.

O arranjo prático mais estrito é uma política curta e ilustrativa que o líder do incidente define ao declarar.

```
policy incident_mode_ops_agent      // illustrative notation
allow:    search_docs, query_logs, get_metrics, get_trace
restrict: request_rollback, toggle_feature_flag -> needs_approval,
          approver must view the evidence panel from the contract
refuse:    open_pull_request, run_diagnostic    // unless the lead enables
them
expires:    when the incident closes, or after the lead's set interval
record:     every call and every enablement, with who decided
```

Isso custa velocidade. Quem responde e poderia ter um script de diagnóstico executado de imediato agora precisa pedir ao líder. Aceito esse custo, porque a alternativa é um agente com o seu conjunto normal de ferramentas, num momento em que as pessoas ao redor estão cansadas e as aprovações são dadas depressa.

Comunicar durante o incidente

Um incidente tem vários públicos, e cada um precisa de um tipo diferente de mensagem. Quem responde precisa do estado atual e de quem está fazendo o quê. O suporte precisa saber o que dizer aos clientes. A liderança

precisa do tamanho e do horário da próxima atualização. Os clientes, se afetados, precisam de uma declaração clara do que aconteceu com eles e do que a Parcelport está fazendo a respeito.

Os papéis reduzem o atrito. Um **líder do incidente** decide, um **escriba** mantém a linha do tempo e um **comunicador** escreve as mensagens externas, para que quem está corrigindo o problema não escreva também a status page. Em uma equipe pequena, uma pessoa acumula dois papéis, e a restrição útil é que quem está contendo o incidente não escreva também a mensagem ao cliente.

Quatro hábitos ajudam.

- **Diga o que se sabe, o que não se sabe e quando vem a próxima atualização.** Uma atualização que diz “estamos investigando” três vezes seguidas é uma status page que ninguém lê. “Os reembolsos estão desabilitados para o agente de suporte; 40 reembolsos estão em revisão; a próxima atualização será em 30 minutos” é útil (os números são hipotéticos).
- **Descreva o sistema, não o modelo.** Uma mensagem a clientes que diz “a IA cometeu um erro” não diz nada sobre o que foi afetado nem sobre o que a Parcelport fará, e convida à conversa errada. “Uma etapa automatizada emitiu reembolsos que não foram solicitados; estamos revisando cada um” é precisa e específica.
- **Pessoas escrevem a comunicação com clientes.** Uma mensagem sobre o incidente para os clientes é um efeito colateral externo, e o agente de suporte não a redige nem a envia. O Capítulo 15 trata do padrão de aprovação para respostas; em um incidente, o que está em jogo exige uma pessoa desde a primeira palavra.
- **Deixe a interpretação jurídica para os responsáveis.** As questões de notificação pertencem ao jurídico e à conformidade, e a engenharia fornece os fatos: a janela, as classes de dados, o número de pessoas afetadas e a contagem de desconhecidos.

Uma atualização interna tem um formato fixo, para que ninguém precise projetá-lo às quatro da manhã.

```
update #N                                // illustrative internal update
state:      contained | assessing | remediating | monitoring
stopped:    what is disabled or restricted, and since when
not stopped: what still runs, so nobody assumes otherwise
impact:     affected runs, unknown runs, compensation confirmed so far
next:       the next action, its owner, the next update time
```

A linha `not stopped` é a que justifica o seu lugar. No cenário de abertura, a pergunta “quem pode parar o quê” só tem resposta se a atualização anterior disse o que já estava parado.

Ensaio e manutenção do runbook

Um runbook é uma hipótese até ser usado. O kill switch do Capítulo 13 e o caminho de revogação do Capítulo 18 falham mais em simulações do que em incidentes, porque a simulação é onde aparecem a lista de operadores desatualizada, a permissão que falta e o probe que não verifica o que diz verificar.

Faria um **game day** curto em um agendamento, por exemplo uma vez por trimestre, com um cenário roteirizado e sem clientes reais: um agente de staging propõe um reembolso errado, um alerta de gasto dispara, falta um trace. Meça o que decide o resultado: quanto tempo até uma contenção confirmada, se a lista de impacto pôde ser produzida a partir do registro e se as pessoas do rodízio sabiam qual degrau usar. Anote os tempos como medições suas e não tome emprestada a meta de outra organização, porque o número certo depende dos seus níveis de severidade e do seu quadro de pessoal.

Os runbooks envelhecem de maneiras específicas: uma ferramenta é renomeada, um operador sai do rodízio, uma flag muda para outro store. Uma mudança em qualquer controle que o runbook nomeia é, em si, um gatilho para verificar o runbook, e o responsável pelo controle é responsável pela atualização. Um runbook que ninguém abre há um ano é um documento, não um controle.

Trade-offs e custos

A preparação tem um preço em pessoas e em atenção. Um rodízio de on-call que inclui agentes tem mais a aprender: os degraus, as flags, os stores e o hábito de perguntar “qual versão” antes de “qual bug”. Uma simulação toma horas que o trabalho de funcionalidades não recebe. Um runbook precisa ser mantido, e um desatualizado é pior que nenhum, porque dá confiança.

A contenção custa clientes. O modo restrito e o enfileiramento significam espera, e parar um agente transfere o trabalho dele para pessoas que podem não ter capacidade. Uma equipe deve decidir de antemão quanta espera aceitará antes de um degrau mais amplo, para que a decisão não seja tomada sob pressão por quem está mais preocupado com a fila.

A evidência também tem um custo. Manter os registros de run por tempo suficiente para um incidente significa guardar dados sensíveis por mais tempo, de modo que a retenção, o controle de acesso e o redaction (Capítulo 17) precisam ser projetados para investigações, com um store restrito e um log de acesso.

O processo pode virar teatro. Uma revisão cujos itens de ação nunca são construídos, uma simulação que roda sempre o mesmo cenário e um incidente declarado a cada pico de recusas ensinam a equipe a deixar de prestar atenção.

Quando não usar toda a maquinaria: um protótipo sem efeitos reais e sem clientes precisa de uma forma de pará-lo e de um registro do que fez, e não de um rodízio. Uma equipe muito pequena pode fundir os papéis de líder, escriba e comunicador. O que ela não pode dispensar é o stop switch que outra pessoa que não o agente aciona, a lista de impacto a partir do registro e o hábito de terminar uma revisão em um controle.

Erros comuns

- **Escrever “erro do modelo” como causa-raiz.** É tentador porque é verdadeiro para o gatilho e encerra a reunião. Também não produz nenhum item de ação. Pergunte por que a proposta pôde importar e nomeie o controle que faltava.

- **Conter com o prompt.** É tentador porque é a edição mais rápida disponível, mas é um pedido a um componente pouco confiável e muda a versão, de modo que a evidência passa a abranger dois comportamentos. Use uma flag, uma recusa no gate ou uma revogação.
- **Deixar o agente desfazer os próprios efeitos.** É tentador porque o run do agente já guarda o registro do que ele fez. A compensação é executada com o mesmo tipo de contexto que produziu o primeiro erro. Encaminhe-a pelo gate e por uma pessoa, com chaves de idempotência.
- **Contar apenas o que o registro mostra.** É tentador porque o registro é a única contagem disponível e parece completo. Informe a contagem de desconhecidos ao lado da contagem de afetados e trate a diferença como um achado.
- **Um kill switch que ninguém nunca acionou.** É tentador porque um switch que existe parece um switch que funciona. O switch existe, o flag store dele é inalcançável pelos operadores do canal do incidente, e o runbook lista uma pessoa que saiu. Faça simulações dele e deixe o probe verificar o gate, e não a flag.
- **Itens de ação que nomeiam pessoas ou intenções.** São tentadores porque são rápidos de escrever e ninguém se opõe. “Tenha mais cuidado” e “lembre a equipe” não podem ser testados. Reescreva cada item até que ele nomeie um controle e uma verificação.
- **Restaurar o serviço antes que o caso de eval exista.** A pressão para reabilitar é real. Reabilitar com uma falha conhecida e sem um caso que a detecte significa que a próxima ocorrência será encontrada pelo mesmo caminho que esta.

Pontos-chave

- Um incidente é uma situação em que o comportamento de um agente causou ou ameaça causar dano, e a resposta é organizada; declarar um deve ser barato, porque esperar por certeza é esperar pelo dano.
- Os incidentes de agentes são mais difíceis que os de serviços porque os runs não podem ser reproduzidos chamando o modelo de novo, os efeitos se espalham por sistemas e o comportamento pode ter se movido com uma mudança que ninguém listou, de modo que a investigação precisa partir do registro.

- A contenção é uma escada de controles construída de antemão e escrita em um runbook (fixar uma versão, desabilitar uma ferramenta, modo restrito, fila, revogar, parar), e usa o degrau mais estreito que interrompa o dano sem destruir evidências.
- A análise de impacto faz um join do registro dos runs com os serviços responsáveis pelos efeitos, informa como desconhecido o que não consegue classificar, e a compensação é rastreada até a confirmação pelo serviço responsável, executada por pessoas ou pelo gate e não pelo agente que causou o incidente.
- “O modelo cometeu um erro” é o gatilho e não uma causa-raiz; a revisão classifica as causas nos eixos de modelo, contexto, ferramenta e controle, faz o replay do contexto e da proposta registrados e atribui ao modelo apenas o que um eval sustenta.
- Uma revisão sem culpa termina em controles, cada um com um responsável e uma verificação, e cada achado se torna um caso de eval, uma política, uma mudança de contrato, um alarme ou uma etapa de runbook; um caso de eval que não falha a uma taxa declarada na versão que teve o incidente não prova nada.
- Durante um incidente, o agente de operações ajuda com leitura e redação, a sua autoridade não se amplia, as suas hipóteses não são verificadas até que uma pessoa as confira, e nenhum dos dois agentes escreve a comunicação aos clientes.

Uma revisão transforma um incidente em casos de eval, e uma suíte de evals só é útil na medida do hábito de executá-la. O Capítulo 24 reúne os controles do livro inteiro em um checklist e em um modelo de maturidade, para que uma equipe veja quais deles tem, quais lhe faltam e que incidente está esperando.

Capítulo 24 — Um checklist de confiabilidade e reflexões finais

Imagine a sexta-feira anterior ao dia em que o agente de suporte vai receber seus primeiros tickets reais na Parcelport. Alex tem um documento chamado “prontidão para o lançamento” que, em seis semanas, cresceu até quarenta linhas, cada uma com uma caixa de seleção. Sam quer saber se a equipe de suporte pode contar com o agente na segunda-feira. Jordan quer saber se alguma coisa no documento é mais do que uma intenção. Robin quer saber como fica o rodízio de on-call se a resposta for não.

Alex lê a primeira linha: “Teto de reembolso aplicado.” Está marcada. Quem marcou, e o que essa pessoa olhou? Uma pessoa se lembra de uma conversa. Outra se lembra de um teste que existia em uma versão anterior do gate. Uma terceira supõe que o teto decorre do prompt. A linha provavelmente é verdadeira, e ninguém na sala consegue demonstrá-lo.

Um checklist desse tipo é um registro de confiança, e confiança é a grandeza sobre a qual este livro se recusa a construir desde o Capítulo 2. Por isso a pergunta do último capítulo é prática. Que perguntas uma equipe deve fazer antes de um agente tocar a produção, o que conta como resposta e quanto dessa resposta deve ser exigido em cada estágio de confiança?

Este capítulo percorre as seis partes do envelope de controle: Contexto, Proposta, Gate, Efeito, Limite e Registro. Ele não ensina um novo controle. Pergunta, para cada parte, o que você teria de ser capaz de demonstrar.

O problema e por que ele é difícil

A falha é uma decisão de lançamento tomada com base em afirmação. Ela não pertence a nenhuma parte isolada do envelope, porque é uma falha do Registro aplicada à própria equipe: o sistema pode ter os controles, e a equipe não consegue saber. Toda classe de falha, de F1 a F9, pode decor-

rer dela. A classe que ela mais produz é F8 (comportamento não observado), um nível acima: a equipe não sabe dizer quais controles existem, então não sabe dizer quais falhas estão cobertas.

A abordagem óbvia é uma lista de boas práticas, marcada por quem melhor conhece o sistema. Ela falha por três razões.

Primeiro, uma marca descreve um momento. O gate foi verificado em março, o contrato da ferramenta mudou em abril, o teto saiu do código para um arquivo de configuração em maio. Um checklist sem datas e sem evidências não distingue um controle que vale de um controle que valia.

Segundo, um checklist convida o tipo errado de evidência. “O prompt diz ao modelo que nunca ultrapasse o teto” é uma resposta que soa como uma marca. É um pedido, e a regra de que um prompt não é um controle vale para o documento de lançamento tanto quanto para o design. Cada item precisa nomear a coisa determinística que se mantém quando o modelo propõe o contrário.

Terceiro, a prontidão não é um limiar único. Um agente que redige resumos internos e um agente que movimenta dinheiro não precisam da mesma lista, e tratá-los da mesma forma produz uma cerimônia para o primeiro ou uma lacuna para o segundo.

Um checklist é um pequeno sistema de controle para as afirmações da própria equipe: aquilo que está sendo verificado é pouco confiável, então a verificação precisa ser outra coisa.

O checklist, agrupado pelo envelope de controle

Cada item abaixo é uma pergunta, a evidência que a responde e o capítulo que constrói o controle. Evidência significa um artefato que você pode abrir: um teste de contrato que falha quando o controle é removido, um trace que mostra o controle disparando, um registro de simulação, um painel de dashboard com um responsável. “Nós discutimos isso” não é evidência.

O Apêndice traz uma forma mais curta desta lista: os mesmos grupos, os mesmos itens na mesma ordem, cada um como uma pergunta com seu capítulo e sem a evidência. Esta seção é a versão com as razões.

Contexto

Classes de falha típicas: F4 (sequestro de instruções), F5 (loop descontrolado ou contexto obsoleto) e F3 (afirmação sem fundamento).

- **Proveniência.** Você consegue mostrar, para um run real, de onde veio cada item do contexto e que nível de confiança ele tinha? Evidência: o contexto registrado de um run, com as fontes. Capítulo 9.
- **O retrieval tem um piso.** Uma consulta sem boa resposta retorna “nenhuma correspondência boa” e não o documento fraco mais próximo, e os documentos carregam versões e datas `as_of`? Evidência: uma consulta sem resposta e o seu resultado. Capítulo 9.
- **O conteúdo não confiável é marcado, e a marca viaja junto.** Um valor que veio de um e-mail ou do resultado de uma ferramenta mantém a sua marca até que uma verificação a libere, inclusive quando é copiado para um argumento de ferramenta? Evidência: um teste que encaminha conteúdo marcado a um argumento sensível e espera uma recusa. Capítulo 16.
- **Os servers MCP são uma lista com responsável.** Existe um allowlist de servers e um allowlist de ferramentas com definições fixadas, e uma definição alterada deixa de ser invocável até que alguém a revise? Evidência: o allowlist, o seu responsável e um teste com uma definição alterada. Capítulo 8.
- **O estado é durável e retomável.** Um run interrompido em qualquer passo consegue ser retomado sem repetir um efeito, e um sweep encontra runs cujo estado registrado diverge do mundo? Evidência: um teste de retomada e a saída do sweep. Capítulo 10.
- **A memória tem uma política de escrita.** Toda escrita na memória é uma proposta que uma política aceita ou recusa, com uma expiração? Evidência: a política e uma escrita recusada. Capítulo 11.
- **Os dados PII são minimizados antes de serem montados.** As ferramentas retornam os campos de que a tarefa precisa e placeholders para o resto, e o registro aplica redaction ao que sobra? Evidência: uma amostra de resultado de ferramenta e uma amostra de trace, ambas inspecionadas. Capítulo 17.

Proposta

Classes de falha típicas: F1 (saída malformada), F2 (ferramenta incorreta ou argumentos incorretos) e F3.

- **Toda proposta é analisada e validada antes de qualquer outra coisa acontecer.** Uma proposta inválida recebe um caminho de correção contado e limitado, e não um efeito? Evidência: testes de propostas inválidas e o contador. Capítulo 5.
- **O inventário de decisões existe.** Para um tipo de ticket, está escrito quais decisões o modelo toma e quais o código toma, com valores, limites e permissões do lado do código? Evidência: o inventário. Capítulo 4.
- **A confiança não é uma entrada do gate.** Algo no caminho de controle lê a própria declaração de certeza do modelo? Se sim, que sinal independente a sustenta? Evidência: uma revisão das entradas do gate. Capítulo 2.
- **Uma mudança de modelo, prompt, ferramenta ou política é um deploy.** Cada uma passa pelo mesmo pipeline do código, com uma execução de eval anexada? Evidência: as três últimas mudanças e as suas execuções. Capítulos 2 e 21.
- **Um plano é validado e não é uma autorização.** O orquestrador verifica um plano contra os mesmos contratos, e cada passo dele ainda passa pelo gate quando é executado? Evidência: um plano com um passo que o gate recusa. Capítulo 12.

Gate

Classes de falha típicas: F2, F4 e F7 (efeito não autorizado).

- **Toda ferramenta tem um contrato.** Nome, descrição, esquema de entrada, classe de efeito, pré-condições, idempotência, permissões, timeouts e formato de erro, com as omissões justificadas. Evidência: os arquivos de contrato e os testes de contrato. Capítulo 6.
- **As verificações de teto e de propriedade rodam no gate.** Um reembolso acima de `refund_ceiling`, ou de um pedido que não é do cliente, vai para aprovação ou recusa sem envolver o modelo? Evidência: um teste que propõe os dois. Capítulos 4, 6 e 15.

- **A autoridade é delegada, estreita e de curta duração.** O agente detém alguma credencial que dure mais do que uma chamada? A autoridade de um ticket é a autoridade do cliente desse ticket, reduzida? Evidência: o log do emissor de credenciais e uma revisão de autoridade. Capítulo 7.
- **A aprovação está vinculada à chamada exata.** Um argumento alterado invalida a aprovação, e a autoridade é verificada de novo depois da espera? Evidência: um teste que edita um parâmetro após a aprovação. Capítulo 15.
- **A aprovação não é teatro.** A taxa de aprovação, o tempo até a decisão e a parcela de pedidos editados ou recusados são revisados, e alguém alterou um limiar por causa deles? Evidência: as notas da revisão. Capítulo 15.

Efeito

Classes de falha típicas: F6 (falha parcial silenciosa) e F7.

- **A intenção é registrada antes do efeito.** Se o processo parar entre as duas coisas, há um rastro do que estava prestes a acontecer, e algo o resolve? Evidência: um teste de falha entre a intenção e o resultado. Capítulos 5 e 10.
- **Um resultado desconhecido é resolvido perguntando, não repetindo.** Depois de um timeout em `issue_refund`, o sistema consulta o status antes de qualquer retry? Evidência: o teste de timeout. Capítulos 6 e 14.
- **Toda escrita reversível nomeia o seu desfazer.** A ação compensatória está no contrato e alguém a executou? Evidência: o campo do contrato e uma compensação executada. Capítulo 6.
- **Os secrets ficam fora do agente.** Não há secrets na configuração que o agente lê, no contexto, nos checkpoints nem nos traces, e você consegue revogar tudo o que um agente poderia tocar? Evidência: um teste de scrubber e uma simulação de revogação. Capítulo 18.
- **O código que roda, roda em um sandbox que foi testado.** `run_diagnostic` passa nos testes de conformidade de rede, sistema de arquivos e credenciais, no runtime real? Evidência: a execução dos testes. Capítulo 19.

Limite

Classes de falha típicas: F5 e F9 (explosão de custo ou latência).

- **Um run tem limites que ele não consegue elevar.** Passos, tempo e gasto, aplicados pelo orquestrador, com uma parada que faz o hand-off com um resumo. Evidência: um teste com um loop que nunca termina. Capítulos 12 e 13.
- **Os níveis de orçamento são limitados como um conjunto.** Cada nível do Capítulo 13 (run, subject, agente, tenant, global) tem um limite e um responsável, o nível mais estreito esgotado é o que vincula, e o teto global no gateway de modelos está igual ou abaixo do que você poderia pagar no pior dia? Evidência: a configuração por nível e um teste que esgota o nível do tenant enquanto cada run está dentro do seu próprio limite. Capítulos 13 e 22.
- **Os retries têm um responsável, uma classe e um limite.** Uma única camada faz retry, cada retry gasta do orçamento, e uma retry storm já foi provocada de propósito. Evidência: o teste de falhas. Capítulo 14.
- **O modo degradado está definido.** Quando o gateway de modelos está fora do ar ou um breaker está aberto, o agente faz algo declarado, como responder sem ferramentas ou fazer o hand-off, e isso foi testado? Evidência: a simulação. Capítulos 13 e 14.
- **O kill switch existe, fica fora do agente e já foi acionado.** Ele tem operadores nomeados e escopos mais estreitos do que “tudo”? Evidência: o último acionamento. Capítulo 13.
- **O custo é atribuído.** Você consegue dizer, a partir do trace, quanto custou um ticket e uma investigação? Evidência: o painel. Capítulo 22.

Registro

Classe de falha típica: F8, e a detecção de todas as outras.

- **Um run é um trace.** Quem está de on-call consegue abrir um run pelo id e ver, em ordem, toda chamada ao modelo, decisão do gate, aprovação e efeito? Evidência: um run real, aberto por alguém que não o construiu. Capítulo 20.
- **O conteúdo é guardado de propósito.** Está decidido quais prompts e saídas são armazenados, passam por redaction ou são amostrados, e

quem pode lê-los? Evidência: a política de retenção e uma verificação de acesso. Capítulos 17 e 20.

- **Existem alertas para falhas com formato de agente.** Taxa de recusa, taxa de hand-off, taxa de aprovação, anomalias de custo e distribuição de classes de falha, com um responsável por cada alerta. Evidência: as definições dos alertas e a última vez que um disparou. Capítulo 20.
- **Cada classe de falha tem uma detecção e uma limitação.** Para F1 a F9, você consegue nomear a detecção e a limitação que este agente tem, e toda célula vazia é uma lacuna conhecida? Evidência: a tabela do Capítulo 3 preenchida para este agente. Capítulo 3.
- **Um golden set barra mudanças.** Uma mudança de prompt, modelo, ferramenta ou política executa o conjunto, e uma regressão bloqueia o deploy? Evidência: uma mudança bloqueada. Capítulo 21.
- **Existe um caminho de incidente ensaiado.** Há um runbook com uma escada de contenção, uma consulta de impacto sobre o registro e um modelo de revisão sem culpa, e a equipe o executou? Evidência: a última simulação. Capítulo 23.
- **Os achados voltam como controles.** A última revisão produziu um caso de eval, uma mudança de política ou uma mudança de contrato, e não apenas um documento? Evidência: os três links. Capítulos 21 e 23.

Manter as respostas em dia

Um item é uma afirmação com idade. O checklist é mais útil como dado do que como documento, porque um dado pode ficar obsoleto de forma visível. A notação abaixo é ilustrativa.

```

checklist_item gate.refund_ceiling      // illustrative notation
question: "Does a refund above refund_ceiling reach
          payments-service without approval?"
evidence: { test: "refund_above_ceiling_needs_approval",
            last_run_at: time or empty }
watched: { thing: "tool contract and policy",
            version_changed_at: time }
chapter: 4, 6, 15
owner: Alex
required_at: controlled pilot          // levels are ordered

function itemStatus(item):
    // computed, never stored: a tick cannot outlive its evidence
    if item.evidence.last_run_at is empty:
        return "missing"
    if item.evidence.last_run_at < item.watched.version_changed_at:
        return "stale"          // the contract or policy changed after the last
run
    return "current"


function readyFor(run, level, items):
    gaps = []
    for each item in items:
        if item.required_at <= level:
            if itemStatus(item) != "current":
                gaps = gaps + [{ item: item.id, status: itemStatus(item) }]
    record(run, "readiness_gap", gaps) // every gap, not the first
    return length(gaps) == 0

```

O campo `watched` é o que importa. O status é calculado a partir dele e da última execução da evidência, de modo que um contrato alterado torna o item obsoleto sem que ninguém precise se lembrar de olhar.

Níveis de maturidade

A lista acima é o conjunto completo. Uma equipe não precisa de tudo no primeiro dia, e argumentaria que ela não deveria tentar, porque o custo do conjunto inteiro, gasto antes de existir uma tarefa real, vai para controles moldados para uma carga de trabalho imaginada. Quatro níveis oferecem um modo de acrescentar controles em uma ordem que segue o risco.



Olhe as setas que voltam. Um nível não é uma nota permanente. Uma nova ferramenta irreversível, um contrato alterado ou uma evidência que ficou obsoleta fazem aquela capacidade descer um nível até que a evidência seja renovada.

Nível	O que ele pode fazer	Controles mínimos antes de entrar
Protótipo	Ler dados de teste ou copiados, ou agir apenas em um ambiente onde um efeito não custa nada	Um limite de iterações e um timeout; um registro de toda proposta e resultado, ainda que tosco; nenhuma credencial do provedor e nenhum token de serviço amplo na configuração do agente

Nível	O que ele pode fazer	Controles mínimos antes de entrar
Piloto controlado	Tratar tarefas reais para uma pequena fatia, com uma pessoa diante de todo efeito acima de leitura	Um contrato e um gate para cada ferramenta; credenciais por chamada; aprovação exigida acima de leitura por política; um orçamento por run; o kill switch; um trace por run; PII minimizada; um primeiro golden set feito de casos reais; um responsável nomeado
Produção	Tratar a carga de trabalho completa, com aprovação apenas onde a política pedir	O checklist completo com evidência em dia: tetos e propriedade no gate; aprovação vinculada à chamada; injection tratada pela estrutura; execução em sandbox; secrets mantidos fora do agente, com rotação e revogação testadas; alertas e um objetivo; atribuição de custos; o eval como gate de deploy; um caminho de incidente ensaiado
Escala	Mais agentes, ferramentas, servers, tenants ou volume	Um processo de revisão para adicionar uma ferramenta ou um server; manutenção do golden set e uma verificação de overfitting; avaliação online com um canary; mudanças de roteamento validadas por eval; escopos do kill switch por ferramenta e por tenant; gestão da carga de aprovação; revisões programadas de autoridade e de memória

Duas regras mantêm a tabela honesta.

O nível pertence a uma capacidade, não a um agente. O agente de suporte pode ter `lookup_order` e `search_docs` em produção enquanto `issue_refund` ainda está em piloto, com Sam aprovando cada reembolso. Esse é um lançamento melhor do que reter as leituras, e melhor do que deixar as aprovações do piloto virarem hábito. A classe de efeito decide quanta evidência uma ferramenta precisa, que é o mesmo princípio da tabela de severidade do Capítulo 3.

A entrada em um nível é decidida pela evidência, nunca pelo calendário. “Duas semanas sem incidente” é uma afirmação sobre sorte. “O teste do teto, o acionamento do kill switch e o teste de retomada estão em dia” é uma afirmação sobre o sistema.

O Capítulo 1 recomendou a menor agência que resolva o problema, e o checklist é onde isso se paga: uma chamada única ou um fluxo de trabalho precisa de uma lista mais curta do que um loop. Onde um item perguntar sobre algo que não existe, escreva “não se aplica, porque não há ferramenta de escrita” ao lado dele, em vez de deixá-lo em branco.

Parcelport, do primeiro estado ao estado-alvo

O protótipo do Capítulo 1 tinha um prompt, um token amplo, um loop sem saída e nenhum registro além da resposta final. O estado-alvo da Parcelport são os mesmos dois agentes com um sistema ao redor que dá a cada parte do envelope um responsável. O orquestrador é responsável pelo loop, pelo registro e pela aplicação dos limites de cada run. O gateway de modelos guarda a credencial do provedor, mede o gasto e aplica o teto global. O gate decide e, quando permite uma chamada, o orquestrador inicia o efeito e o gateway de ferramentas anexa uma credencial para aquela única chamada. O serviço de aprovação coloca Sam ou Robin diante exatamente das ações que a política nomeia. O run store, o pipeline de traces e a suíte de evals guardam o estado, os spans e os casos que falharam antes.

Imagine uma segunda-feira comum, alguns meses depois do lançamento. O e-mail de um cliente contém um texto que parece uma instrução para a próxima chamada de ferramenta. O taint ficou com ele, o gate recusou o reembolso proposto a partir dele, e o run terminou em um hand-off para Sam com um resumo. Na revisão semanal, o caso entrou no golden set, nomeado com F4. Mais tarde nesse dia, o provedor do modelo fica lento, o breaker abre e o agente de suporte cai para o seu modo degradado declarado. Nas duas histórias o modelo propôs algo que não deveria ter efeito ou que não pôde ser concluído, e o sistema se comportou. Uma segunda-feira sem graça é o que o design compra.

O que muda e o que não muda

Muito do que este livro nomeia vai mudar: os modelos e o seu comportamento, os protocolos de ferramentas e de contexto (o MCP é uma especificação em movimento, razão pela qual o Capítulo 8 se apoiou nos papéis e na fronteira de confiança), os padrões de tracing, os frameworks, os graders e os preços. Qualquer ferramenta específica nestes capítulos é um exemplo de um padrão, e o padrão é a parte a guardar.

O que permanece é o invariante e os hábitos em torno dele. Uma proposta é entrada não confiável seja qual for a acurácia do modelo, porque o custo de uma proposta errada é definido pelo que o gate deixa passar, e o gate é medido no pior dia, não no dia médio. O que movimenta dinheiro, alcança

clientes ou toca nos dados deles mantém verificações determinísticas; afrouxá-las é uma mudança como outra qualquer, feita com base no golden set, na taxa de recusa e no histórico de aprovações, e não porque o último mês foi tranquilo. A evidência sobrevive à memória, e o hábito de perguntar “mostre-me” é a parte deste livro que mais gostaria que sobrevivesse. A ausência de culpa permanece, porque é ela que faz uma equipe relatar quase-acidentes. E o atrito permanece: todo controle custa algo a alguém, e o livro pode dizer que esse custo deve ser contado, não que vale sempre a pena pagá-lo.

Trade-offs e custos

Um checklist tem o seu próprio preço, e a primeira parte dele é tempo. Produzir evidência significa escrever testes para controles que já parecem funcionar, executar simulações que tiram engenheiros do roadmap e manter responsáveis ligados aos itens. Para uma equipe pequena, a lista completa no nível de produção pode dar um trimestre de trabalho. Isso é um motivo para sequenciá-la com os níveis acima, não para pulá-la.

O segundo é a falsa completude. Passar no checklist diz que os controles em que você pensou estão em dia, não que a lista está completa, e é a etapa de revisão do Capítulo 23 que a estende.

Onde não usá-lo como está escrito: para um notebook exploratório, um script descartável ou um sumário interno somente de leitura, a maior parte da lista não se aplica, e uma versão reduzida de três ou quatro itens basta. E não apresente um checklist concluído a ninguém como uma declaração de segurança ou de conformidade. Ele é um registro de engenharia. O que um regime desse tipo exige de você cabe aos seus colegas jurídicos e de conformidade interpretar, e eles podem pedir coisas que esta lista não contém.

Aviso: Um checklist cujos itens são marcados com base em afirmação é pior do que nenhum checklist, porque remove a lacuna visível. Para movimentação de dinheiro, exposição de dados de clientes e capacidade de reconstruir um run, exija evidência antes da marca.

Erros comuns

- **Tratar a lista como um certificado.** É tentador porque um lançamento quer um sim. A correção é anexar uma data e uma evidência a cada item e dizer, na nota de lançamento, o que a lista não cobre.
- **Responder com o prompt.** “O prompt do sistema proíbe” parece um controle porque o texto é claro. Nomeie o código que se mantém quando o modelo propõe o contrário, ou marque o item como ausente.
- **Deixar o Registro para o fim.** O trace e o eval parecem acabamento. Sem eles, nenhum outro item pode ser demonstrado, então construa o registro no nível de piloto, antes do resto.
- **Ler um mês tranquilo como evidência.** É tentador porque um mês tranquilo parece merecido, mas a ausência de incidentes pode significar ausência de sinal. Verifique se os alertas poderiam ter disparado e se uma falha semeada aparece no trace.
- **Deixar a lista virar o documento privado do responsável.** É tentador porque uma pessoa conhece melhor o sistema. Um item sem responsável nomeado e sem data da próxima revisão é um desejo. A correção é um responsável por item, e Jordan ou outro revisor de fora da equipe pede a evidência.

Pontos-chave

- Um checklist de confiabilidade é um conjunto de perguntas, cada uma respondida com um artefato que você pode abrir, como um teste, um trace, um registro de simulação ou um dashboard, e não com uma garantia.
- Agrupe a lista pelo envelope de controle, para que cada item aponte para a parte que serve e para o capítulo que constrói o controle, e para que uma lacuna seja uma parte ausente e não uma preocupação vaga.
- Vincule cada item ao que o torna obsoleto, como um contrato ou uma política alterados, para que a evidência envelheça de forma visível e não silenciosa.
- Passe de protótipo para piloto controlado, produção e escala com base em evidência, por capacidade, com a classe de efeito decidindo quanto uma ferramenta precisa, e deixe um nível voltar a descer quando a evidência expirar.

- Use a menor agência que resolva o problema, porque cada passo para baixo na ordem da menor agência encurta a lista que precisa ser demonstrada.
- Espere que modelos, protocolos e ferramentas mudem, e mantenha o invariante: o modelo é um tomador de decisão pouco confiável, e o que torna o sistema confiável é o sistema de controle ao seu redor.
- Um checklist registra evidência de engenharia e não é uma declaração de segurança ou de conformidade; a interpretação disso cabe aos seus colegas jurídicos e de conformidade.

Reflexão final

O livro defendeu uma frase, e vale a pena lê-la mais uma vez como uma regra de design e não como um slogan:

Os agentes de IA devem ser projetados como tomadores de decisão pouco confiáveis que operam dentro de sistemas de controle confiáveis.

A primeira metade é uma suposição da qual você não precisa se entristecer. Construímos sobre redes pouco confiáveis e discos pouco confiáveis por décadas, e o trabalho sempre foi o mesmo: dizer com clareza o que pode falhar, pôr algo determinístico em volta disso e guardar evidência suficiente para saber o que aconteceu. A segunda metade é engenharia comum, com esquemas, permissões, orçamentos, timeouts, filas, logs e testes, e é a parte que cabe a você construir.

Não prometeria que uma equipe que faz tudo isso nunca terá um incidente. Diria que os seus incidentes serão limitados, visíveis e corrigíveis, e que o próximo vai melhorar o sistema. Essa é uma afirmação mais modesta do que a confiabilidade como propriedade de um modelo, e é a que defenderia.

Apêndice

Este apêndice reúne em um só lugar o material de referência do livro: um glossário, os dois vocabulários de código (razões dos veredictos do gate e códigos de erro do gateway de ferramentas), uma referência rápida dos padrões, um contrato de ferramenta em branco, a tabela da taxonomia de falhas, um checklist de pré-lançamento e um modelo para revisar um incidente. Ele não acrescenta nenhuma ideia nova; cada entrada aponta para o capítulo que a detém e, quando uma entrada e o seu capítulo discordam, o capítulo vale e a entrada é um bug. O que cada entrada serve é a tese do livro, os agentes de IA devem ser projetados como tomadores de decisão pouco confiáveis que operam dentro de sistemas de controle confiáveis, e as seis partes do envelope de controle: Contexto, Proposta, Gate, Efeito, Limite e Registro.

Glossário

Os termos estão listados em ordem alfabética. A última coluna é o capítulo que detém o termo: o lugar onde ele é definido e desenvolvido. Os números na tabela são capítulos.

Termo	Definição	Ca- pí- tulo
agente	Um componente: um loop de orquestrador que chama um modelo, pede a um gate que verifique as suas propostas e aplica os efeitos aprovados por meio de ferramentas. Não é uma pessoa.	1
aprovação	Uma decisão humana vinculada a uma única ação proposta exata, registrada com quem decidiu e quando. O termo completo é “aprovação humana”.	15
autorida- de delegada	Autoridade que um principal detém em nome de outro, sempre mais estreita do que a do delegante e vinculada a uma tarefa.	7

Termo	Definição	Ca- pí- tulo
chamada de ferramenta	Uma proposta de usar uma ferramenta com argumentos. Ela só se torna um efeito depois que o gate a permite.	5
chave de idempotência	Um valor que permite a uma ferramenta reconhecer uma chamada repetida e devolver o primeiro resultado em vez de agir duas vezes. Derivada pelo runtime apenas de identificadores que ele atribui, nunca de identificadores de run ou de passo e nunca de um campo fornecido pelo modelo.	6
check-point	Um ponto salvo de um run a partir do qual ele pode ser retomado.	10
circuit breaker	Um controle que interrompe as chamadas a uma dependência que está falhando por um período, em vez de fazer retries. Um breaker no nível do agente observa as taxas do próprio agente em relação a um baseline.	13
classe de efeito	Um de quatro valores: leitura, escrita reversível, escrita irreversível, efeito colateral externo. A classe define um piso de controles; é a política, e não a classe, que decide a aprovação.	6
classe de falha	Uma de F1 a F9 da taxonomia de falhas.	3
confused deputy	Um componente que usa a própria autoridade para fazer o que uma parte com menos privilégios pediu. A forma padrão como um agente com um token amplo causa F7.	7
contrato de ferramenta	A descrição escrita e verificável por máquina de uma ferramenta: nome, descrição, esquema de entrada, classe de efeito, pré-condições, idempotência, permissões, timeouts, formato de erro.	6
direitos de decisão	Uma tabela que diz, para cada decisão em um run, se o modelo a propõe, se o código a decide ou se um humano a decide.	1
efeito	O que acontece no mundo depois que o gate permite uma chamada de ferramenta.	1
egress	Tráfego que sai de um ambiente.	19
envelope de controle	O modelo de seis partes deste livro: Contexto, Proposta, Gate, Efeito, Limite, Registro.	1
estado	Fatos sobre um run, mantidos pelo orquestrador no run store: passos, resultados, status.	10

Termo	Definição	Ca- pí- tulo
eval	Uma medição repetível do comportamento contra resultados esperados. Usado no lugar de “teste” quando aquilo que se mede é uma proposta probabilística.	21
fallback	Um caminho diferente usado quando o caminho primário falha ou não está disponível. Os fallbacks são ordenados como uma escada conforme a parte do comportamento primário que cada degrau preserva.	14
ferramenta	Uma capacidade nomeada que o agente pode pedir, com um contrato.	1, 5
fronteira de confiança	Uma linha que separa dados ou autoridade que vêm de uma fonte que você não controla.	8, 16
fronteira do determinismo	Uma linha, traçada por decisão, entre o que o modelo pode propor e o que o código deve decidir.	4
fundamentação	Vincular uma afirmação em uma resposta a uma fonte no contexto. Uma afirmação sem esse vínculo é uma afirmação sem fundamento (F3).	9
gate	A verificação determinística entre uma proposta e um efeito, com três resultados: allow, refuse, needs approval. No pseudocódigo: "allow", "refuse", "needs_approval".	1, 4
golden set	Uma coleção fixa de casos com resultados esperados, usada para evals.	21
grader	O código ou processo que decide se uma saída atende às expectativas. Um modelo usado como grader é um model grader e é, ele próprio, avaliado.	21
hand-off	O fim de um run em que uma pessoa assume, com um reason code e um resumo construído a partir do registro. Toda parada é um hand-off.	12
incidente	Uma situação em que o comportamento de um agente causou ou ameaça causar dano, e a resposta é organizada. Revisado sem culpa.	23
intenção	Um registro escrito antes de um efeito, de modo que uma falha entre o efeito e o seu resultado ainda deixe um rastro. Emparelhado com o registro do resultado.	5
janela de contexto	A quantidade de material que um modelo consegue receber em uma chamada. O livro nunca lhe dá um tamanho.	9

Termo	Definição	Ca- pí- tulo
kill switch	A extremidade manual do breaker no nível do agente: nenhum run novo, e os runs em andamento esperam na próxima fronteira de passo. Mantido fora do agente.	13
lease	Uma reivindicação que diz qual worker pode agir sobre um run por um tempo limitado. Parte dos controles de concorrência do run.	10
loop	O ciclo repetido de contexto, proposta, gate e efeito em um run.	12
manifesto	Um registro do que o modelo viu em um passo e do que foi descartado, escrito pelo montador de contexto.	9
memória	Informação mantida entre runs que pode moldar o contexto posterior. O estado diz respeito a um run; a memória diz respeito ao mundo depois do run.	11
modelo	O componente que transforma contexto em uma proposta.	2
modo degradado	Um comportamento reduzido e declarado (responde sem ferramentas, ou apenas faz o hand-off) em que o sistema entra quando um limite ou breaker dispara.	14
modo restrito	O segundo degrau do breaker no nível do agente: leituras e rascunhos continuam, todo efeito acima de leitura é recusado ou vira needs approval.	13
montagem do contexto	A etapa do orquestrador que escolhe, ordena e rotula o que entra no contexto de uma chamada ao modelo.	9
observação	O resultado de um efeito, ou o motivo de uma recusa, devolvido ao contexto para o próximo passo.	1
orçamento	Um limite sobre um recurso que um run pode usar: passos, chamadas de ferramenta, tokens, tempo ativo, gasto ou efeito cumulativo. Ele nomeia uma unidade, um limite, onde é medido e o que acontece quando se esgota.	13
orçamento de efeito	Um orçamento sobre o tamanho cumulativo dos efeitos, como o total reembolsado. Ele fecha a lacuna entre um teto por chamada e a soma.	13
orquestrador	O código determinístico que executa o loop (também chamado de runtime do agente).	1
passo	Uma passagem do loop dentro de um run: montar o contexto, propor, passar pelo gate e, talvez, aplicar um efeito.	1
permissão	Uma declaração de que um principal pode executar uma ação sobre um recurso.	7

Termo	Definição	Ca- pí- tulo
PII	Informação de identificação pessoal.	17
plano	Uma lista de passos pretendidos proposta pelo modelo. Uma proposta, não um compromisso; um plano validado não autoriza nada.	12
política	Uma regra que o gate avalia contra uma chamada proposta. Escrita como dados ou código, nunca como prosa em um prompt.	7
principal	Qualquer coisa que se autentica ou em nome de quem uma ação é executada: uma pessoa, um serviço, um agente.	7
prompt injection	Conteúdo que é dado sendo tratado como instrução. Direta: a própria entrada do usuário tenta sobrepor as instruções. Indireta: o conteúdo chega por meio do resultado de uma ferramenta, de um documento ou de um e-mail. A classe é F4.	16
proposta	Tudo o que o modelo retorna: uma chamada de ferramenta, um plano, uma resposta final. Tratada como entrada não confiável.	1, 2
proveniência	De onde veio uma parte do contexto.	9
redaction	Remover ou mascarar um valor de uma saída, de um log ou de um contexto.	17
retrieval	Buscar material em um armazenamento para colocá-lo no contexto.	9
retry	Repetir uma chamada que falhou, com um motivo classificado e um limite.	14
run	Uma execução de um agente para uma tarefa, do início até uma resposta final, um hand-off ou uma parada. Tem um id e um status.	1
runbook	Uma entrada escrita para cada agente que nomeia o gatilho, o controle, quem pode acioná-lo, como confirmar que ele fez efeito e o que dizer às pessoas afetadas.	23
sandbox	Um ambiente de execução com limites aplicados sobre o que o código consegue alcançar, em arquivos, rede e credenciais.	19
secret	Qualquer valor que concede acesso se divulgado. Nunca é colocado no contexto.	18
severidade	Até onde uma falha chegou: informação, reversível, irreversível ou externa. Pertence à instância, não à ferramenta.	3
span	Uma operação cronometrada dentro de um trace.	20
sweep de reconciliação	Um job agendado sobre o run store e os serviços proprietários que torna visíveis as lacunas entre sistemas separados. Tem um responsável e um heartbeat.	10

Termo	Definição	Ca- pí- tulo
taint	Uma marca de que um valor veio de uma fonte não confiável e não deve conduzir uma ação sensível sem uma verificação.	16
trace	O registro ordenado de um run através dos componentes.	20
turno	Uma troca entre o agente e um humano em uma conversa. Um run pode ter vários turnos; um turno pode ter vários passos.	1

Duas distinções merecem ficar diante de você. O veredicto “needs approval” é o que o gate retorna quando uma proposta espera por um humano; o código de erro `approval_required` é o que o gateway de ferramentas retorna quando uma chamada chega a uma ferramenta sem uma aprovação válida, o que, em um run saudável, aponta para um defeito (Capítulo 6). E estado não é memória: o estado pertence a um run, a memória sobrevive a ele (capítulos 10 e 11).

Razões dos veredictos do gate

O gate do Capítulo 5 é canônico, na ordem e nos nomes das razões. Todo capítulo que esboça uma parte dele usa esses nomes. Uma razão acompanha o veredicto `"refuse"`; as razões de aprovação acompanham `"needs_approval"`. A lista é fechada, e uma razão que não está aqui é um bug no capítulo que a usa. O Capítulo 12 acrescenta duas verificações para runs planejados, escopo da tarefa e classe do plano, e as razões delas estão na tabela. Uma exceção: o validador de planos do Capítulo 12 recusa um plano inteiro antes de qualquer uma de suas chamadas ser proposta, e as suas razões (`malformed_plan`, `plan_too_long`, `plan_cycle`, `tool_not_allowed`, `write_without_evidence`, `too_many_writes`) formam uma lista fechada separada que não faz parte da lista do gate.

Razão	Vere- dicto	Onde fica no gate do Capítulo 5	Repetí- vel	Ca- pí- tulo
<code>unparseable</code>	refuse	Parser: a saída não é uma proposta	não	5
<code>not_in_choice_set</code>	refuse	Parser e conjunto de escolha: a ferramenta ou o identificador não foi oferecido a este run	não	4, 5

Razão	Vere- dicto	Onde fica no gate do Capítulo 5	Repetí- vel	Ca- pí- tulo
<code>invalid_arguments</code>	refuse	Verificação de esquema, a primeira no gate	não	5
<code>ungrounded_arguments</code>	refuse	Vinculação de argumentos: os ids precisam vir do run	não	2
<code>argument_origin</code>	refuse	Verificação de taint em argumentos sensíveis	não	16
<code>upstream_unavailable</code>	refuse	Os fatos não puderam ser lidos, então a chamada não pode ser verificada	sim	7
<code>not_permitted</code>	refuse	Recusas de permissão, propriedade e política	não	7
<code>outside_task_scope</code>	refuse	Runs planejados: o alvo está fora do registro da tarefa do run, que é mais estreito do que a delegação	não	12
<code>off_plan</code>	refuse	Runs planejados: o classificador de plano não encontrou nenhum passo pendente correspondente, e a chamada é uma escrita ou uma leitura além da folga fora do plano	não	12
<code>precondition_failed</code>	refuse	Uma pré-condição do contrato falhou; a que falhou é nomeada em <code>field</code>	não	6
<code>outcome_unknown</code>	refuse	Uma escrita cujo resultado anterior não foi resolvido	até que o status seja conhecido	6
<code>ungrounded_claim</code>	refuse	Verificação de afirmações: nenhum resultado de ferramenta sustenta a afirmação	não	2
<code>mismatch</code>	refuse	Verificação de afirmações: a afirmação difere da sua fonte	não	2
<code>omission</code>	refuse	Verificação de afirmações: falta uma parte exigida	não	2
<code>tool_policy</code>	needs_ap- proval	Aprovação, a última: a política sempre pede aprovação para esta ferramenta	não se aplica	15

Razão	Vere- dicto	Onde fica no gate do Capítulo 5	Repetí- vel	Ca- pí- tulo
above_ceiling	ne- eds_ap- proval	Aprovação: o valor está acima do teto	não se aplica	15
repeat_refund	ne- eds_ap- proval	Aprovação: um segundo reembolso no mesmo pedido	não se aplica	15
unclassified_figure	ne- eds_ap- proval	Aprovação: um valor numérico em uma resposta que a verificação de afirmações não conseguiu classificar	não se aplica	15
run_locked	ne- eds_ap- proval	Aprovação, a última: o run leu conteúdo de terceiros e a regra da ferramenta pede um humano	não se aplica	16
run_locked	refuse	A última, depois das pré-condições: o run leu conteúdo de terceiros e a regra da ferramenta é recusar	não	16

Códigos de erro do gateway de ferramentas

Estes são os códigos do formato de erro do Capítulo 6. O conjunto é fechado, com modelos de mensagem fixos, e a coluna “Emitido por” diz quem retorna cada código: o gate, a ferramenta, o gateway de ferramentas ou o serviço. Cinco nomes (`invalid_arguments`, `precondition_failed`, `not_permitted`, `upstream_unavailable`, `outcome_unknown`) aparecem nos dois vocabulários porque o gate e o lado da ferramenta podem rejeitar a mesma coisa. Na primeira tabela, o nome é a razão anexada a um veredicto `refuse`; nesta, é o código em um erro devolvido ao modelo. Os dois vocabulários continuam separados, e um contador deve dizer qual deles está contando.

Código	Emitido por	Repetível	Capí- tulo
<code>invalid_arguments</code>	o gate	não	6
<code>precondition_failed</code>	o gate ou a ferramenta	não	6
<code>approval_required</code>	o gateway de ferramentas	não	6

Código	Emitido por	Repetível	Capítulo
not_permitted	o gate ou o gateway de ferramentas	não	6
duplicate_replayed	a ferramenta	não	6
upstream_unavailable	a ferramenta ou o seu serviço	sim	6
outcome_unknown	o gate ou a ferramenta	até que o status seja conhecido	6
result_invalid	o gateway de ferramentas, para ferramentas de servers externos	não	6, 8

Referência rápida de padrões

A tabela lista cada padrão como um problema e uma resposta, com as classes de falha que ele endereça principalmente e o capítulo que o desenvolve. Leia-a como um índice. Os custos de um padrão, e os casos em que você não deve usá-lo, estão na seção “Trade-offs e custos” do seu capítulo.

Padrão	Problema que endereça	Classes	Capítulo
Separar o orquestrador, o modelo e o gate	Controles sem endereço quando “o modelo” significa o sistema inteiro	todas	1
Tabela de direitos de decisão	Decisões que ninguém detém	F2, F7	1
Menor agência: chamada única, fluxo de trabalho, loop, múltiplos agentes, nessa ordem	Uma superfície maior do que o problema exige	todas	1
Nomear o tipo de incerteza (formato, conteúdo, intenção, omissão)	Escolher o detector errado	F1, F2, F3	2
Veredicto a partir de sinais determinísticos, nunca da confiança declarada	Um efeito irreversível permitido porque o modelo soou seguro	F2, F3	2
Mudança de modelo como um deploy	Comportamento que se move sem responsável nem evidência de eval	F2, F3	2
Três perguntas: classe, eixo da causa-raiz, severidade	Revisões que andam em círculos	todas	3
Decidir por decisão o que o código detém (cinco critérios)	Um modelo propondo valores que o código pode calcular	F2, F7	4

Padrão	Problema que endereça	Clas- ses	Ca- pítu- lo
O modelo propõe, o código dispõe	Uma proposta chegando a um efeito sem verificação	F1, F2, F7	4
Estreitar a faixa de escolha com enums e listas de identificadores	Valores de texto livre que o gate não consegue verificar	F1, F2	4
O cálculo pertence ao código	Valores, datas e limiares errados	F2, F7	4
Pré-condições e pós-condições sobre fatos que o código leu	Chamadas que cabem no esquema e não na situação	F2, F7	4
Analisar e validar com rigor, nunca reparar em silêncio	Argumentos adivinhados que ninguém revisou	F1, F2	5
Uma escrita por passo, uma observação por chamada	Resultados pouco claros quando várias chamadas rodam juntas	F6	5
Intenção antes do efeito, resultado depois, sweep para as lacunas	Nenhuma transação entre o run store e um serviço	F6, F8	5, 10
Contrato com nove campos em ordem fixa	Um esquema que nada diz sobre se a chamada pode acontecer agora	F1, F2, F6, F7	6
Chave de idempotência atribuída pelo runtime	Uma proposta repetida agindo duas vezes	F6	6
Vocabulário de erros fechado com mensagens fixas	Erros que vazam dados ou entregam ao modelo um limite para sondar	F2, F6	6
Autoridade efetiva como uma interseção	Um agente fazendo o que o seu delegante não poderia	F7	7
Credenciais por chamada, de curta duração e estreitas	Um token vazado ou amplo	F7	7, 18
Motor de políticas fora do modelo, negar por padrão	Autoridade apoiada em um prompt	F7	7
Contrato de propriedade do host, allowlist de servers e ferramentas, definição fixada	Texto fornecido pelo server agindo como o contrato	F4, F7	8
Contexto montado, não acumulado, com campos de proveniência	Material sem rótulo e obsoleto no contexto	F4, F5	9
Orçamento de contexto com um núcleo fixado	Linhas de política descartadas sob pressão de tamanho	F5, F9	9

Padrão	Problema que endereça	Clas- ses	Ca- pítu- lo
Piso de relevância, “nenhuma correspondência boa” como resultado	Um acerto fraco apresentado como evidência	F3	9
Run store durável, visão renderizada como contexto	Estado vivendo apenas na conversa	F5, F6	10
Lease, verificação de versão e retomada a partir do estado	Dois workers agindo sobre um run; uma retomada que repete efeitos	F5, F6	10
Escrita na memória como uma proposta, com escopo e expiração definidos pelo código	Uma entrada ruim afetando todos os runs seguintes	F3, F4	11
Plano como uma proposta, validado antes de rodar	Um plano tomado como uma autorização	F2, F5	12
Predicado de sucesso, limite de passos e detecção de progresso	Runs que nunca param ou se desviam da tarefa	F5, F9	12
Orçamentos em camadas, incluindo o orçamento de efeito	Gasto ou efeito cumulativo abaixo de todo limite por chamada	F7, F9	13
Breaker de dependência e breaker no nível do agente, com um kill switch	Fazer retries em uma dependência que está falhando; um agente cujo comportamento se moveu	F5, F9	13
Classificar a falha antes de repetir qualquer coisa	Fazer retry de uma escrita cujo resultado é desconhecido	F6, F9	14
Escada de fallbacks ordenada pelo comportamento preservado	Caminhos improvisados no pior dia	F9	14
Aprovação vinculada ao hash de uma chamada exata	Uma aprovação que cobre uma chamada alterada	F7	15
Tela de aprovação renderizada pelo código	Um humano aprovando o relato do modelo sobre a ação	F2, F7	15
Cortar um entre conteúdo não confiável, alcance e canal de saída	Injection chegando a um efeito	F4	16
Taint por campo, vence a fonte mais fraca	Um argumento sensível vindo de uma fonte não confiável	F4	16
Leitor sem ferramentas, ator com a saída estreitada	Texto não confiável conduzindo um passo que detém ferramentas	F4	16

Padrão	Problema que endereça	Clas- ses	Ca- pítu- lo
Classificar os campos uma vez, minimizar na ferramenta, tokens para o resto	PII em lugares onde não precisa estar	F3, F8	17
Redaction na hora da escrita, falhar fechado	PII e secrets persistindo em logs, traces e conjuntos de eval	F8	17
Credencial injetada fora do modelo	Um secret entrando no contexto	F7	18
Scrubber na fronteira da ferramenta, varredura de secrets nos diffs	Secrets chegando do mundo	F7	18
Sandbox com rede fechada e apenas um diretório de trabalho	Código escolhido pelo modelo alcançando o host	F7	19
Saída do sandbox tratada como entrada não confiável	Um resultado trazendo de volta instruções ou secrets	F4	19
Run como trace, chamadas como spans, com atributos	Comportamento que não deixa evidência utilizável	F8	20
Conteúdo guardado por resultado, em um armazenamento separado	Risco do conteúdo versus evidência necessária para a revisão	F8	20
Alertas específicos de agente com um responsável e uma primeira ação	Um alarme em que ninguém age	F8, F9	20
Níveis de eval, golden set e graders	Comportamento probabilístico medido como se fosse determinístico	F1 a F9	21
Eval como gate de deploy para prompt, modelo, ferramenta, política, limite	Regressões entregues sem serem vistas	F2, F3	21
Custo registrado como uso bruto, precificado na hora do relatório	Um custo que ninguém consegue atribuir	F9	22
Mais barato apenas quando o eval mostra que a qualidade se manteve	Economia que move o custo para respostas erradas ou para a fila humana	F9	22
Escada de contenção escrita como um runbook	Desligar tudo ou nada	todas	23
Lista de impacto a partir do registro, com a contagem de desconhecidos incluída	Não saber o que um incidente tocou	F6, F8	23

Padrão	Problema que endereça	Clas- ses	Ca- pítu- lo
Revisão sem culpa que termina em controles	“O modelo cometeu um erro” como causa-raiz	todas	3, 23

Modelo de contrato de ferramenta

O modelo abaixo segue a notação do livro: os nove campos em ordem fixa, em um bloco `text`. Copie-o, preencha-o e omita um campo apenas escrevendo `// not applicable` com uma razão. Os números em um contrato preenchido são ilustrações até que você tenha os seus próprios dados, e diga isso em um comentário. O Capítulo 6 desenvolve por completo o contrato canônico de `issue_refund`.

```

tool <tool_name>                                // snake_case, one effect per tool
  description: "<one sentence the model reads; a hint, never a check>"
  input schema:                                // fields the model supplies, nothing
  else
    type: object, additionalProperties: false
    required: [<field>, ...]
    properties:
      <field>: { type: <type>, <limits> }
      <field>: { enum: [<closed set>] }
    // no field that carries identity, authority or a credential
    effect class: <read | reversible write | irreversible write | external
side effect>
    preconditions:                                // checked by the gate, on facts it
read itself
      - <fact that must hold now>
      - <limit>, else needs_approval             // only where a human with standing
exists
    idempotency: key = hash(<identifier assigned by the runtime>, ...)
      // not applicable for a read, with the reason
      // never from run id, step id or any field the model supplies
    permissions: scope "<scope>", delegated for <the subject> only
    timeouts: call <n>s, deadline <n>s // illustrative
    // what the orchestrator does after a timeout on a write: query status
first
    error shape: { code, message, retryable, details }
      // code in [invalid_arguments, precondition_failed, approval_required,
      //   not_permitted, duplicate_replayed, upstream_unavailable,
      //   outcome_unknown]

```

Notas de preenchimento

- **name e description.** Gerados a partir do contrato, nunca escritos ao lado dele. Uma regra em uma descrição é um pedido, então a mesma regra também precisa ser uma pré-condição (Capítulo 6).

- **input schema**. Fechado com `additionalProperties: false`, sem nenhum campo que o runtime já conheça, como a identidade, e com o tipo, a faixa ou a enumeração mais estreitos por campo (capítulos 4 e 5).
- **effect class**. Pertence à ferramenta, não a uma chamada; uma ferramenta que às vezes lê e às vezes escreve deve ser dividida (Capítulo 6). A classe define o piso de controles abaixo, e a política decide a aprovação.

Classe de efeito	Controles mínimos no contrato
leitura	Esquema de entrada, escopo de permissões, timeout, um limite de saída; uma pré-condição apenas sobre quem pode ver os dados
escrita reversível	Os acima, mais pré-condições, uma chave de idempotência e um caminho de volta nomeado
escrita irreversível	Os acima, mais uma regra de resultado desconhecido, uma leitura de status de confirmação e uma política de aprovação
efeito colateral externo	Os acima, mais idempotência, verificações de conteúdo e uma intenção registrada

- **preconditions**. Fatos que o gate leu do sistema de registro, em uma ordem deliberada; o serviço proprietário aplica as mesmas regras de forma atômica (Capítulo 6).
- **idempotency**. Cada parte da chave é atribuída pelo runtime, de modo que uma proposta repetida com outros argumentos retorna o primeiro resultado (Capítulo 6).
- **permissions**. Um escopo vinculado à tarefa; a credencial é emitida por chamada e nunca é mantida pelo agente (capítulos 7 e 18).
- **timeouts**. Um timeout em uma escrita é um resultado desconhecido: consulte o responsável pelo estado antes de qualquer retry (Capítulo 14).
- **error shape**. Um conjunto de códigos fechado com modelos fixos; uma ferramenta de um server externo acrescenta `result_invalid` (capítulos 6 e 8).

Um contrato é um artefato versionado: entregue-o com um teste de gate que não precisa de modelo, e registre a sua versão em cada chamada (Capítulo 6).

Tabela da taxonomia de falhas

Os nomes e ids das classes são fixos em todo o livro; o Capítulo 3 pode acrescentar subclasses escritas F4.1, F4.2, mas nunca um novo id de nível superior. A primeira tabela é a forma compacta do Capítulo 3, lida por coluna quando você planeja controles e por linha quando revisa um incidente. Uma linha com uma célula vazia marca uma lacuna no design.

Classe	Deteccção	Prevenção	Limitação	Capí- tulos
F1 Saída malformada	Taxa de falha de esquema por ferramenta	Esquemas estreitos, enumerações fechadas	Reparo limitado, depois hand-off	2, 5, 6
F2 Ferramenta incorreta ou argumentos incorretos	Falhas de pré-condição, revisão por amostragem	Escolher a partir dos fatos do run, pré-condições de propriedade	Aprovação para chamadas irreversíveis	4, 5, 6
F3 Afirmação sem fundamento	Verificação de afirmações contra resultados de ferramentas	Fatos necessários no contexto, campos preenchidos pelo código	Revisão humana antes de uma resposta externa	2, 9, 21
F4 Sequestro de instruções	Taint em argumentos, passos anômalos	Conteúdo não confiável rotulado, regras de taint	Autoridade mínima, aprovação	8, 9, 16
F5 Loop descontrolado ou contexto obsoleto	Chamadas repetidas, idade dos fatos, divergência de versão	Verificações de progresso, proveniência, nova leitura	Limites, pré-condições de versão	9, 10, 12, 13
F6 Falha parcial silenciosa	Reconciliação de intenções e resultados	Intenção primeiro, idempotência, resultado desconhecido	Nada de “concluído” com intenções abertas	6, 10, 14
F7 Efeito não autorizado	Auditoria dos efeitos contra a autoridade emitida	Autoridade por chamada, tetos no código	Credenciais de curta duração, sandbox	7, 15, 18, 19
F8 Comportamento não observado	Cobertura de traces em relação aos efeitos	Um único formato de trace, intenção antes do efeito	Parar ou descartar efeitos quando o registro falha	17, 20, 21, 23
F9 Explosão de custo ou latência	Distribuições de custo e latência, contagens de retries	Orçamentos, orçamento de contexto, retries classificados	Circuit breakers, modo degradado	13, 14, 22

A tabela seguinte dá a cada classe o seu significado e a parte do envelope em que ela mais surge.

Clas- se	Significado	Parte do envelope
F1	A proposta não é analisada ou não corresponde à estrutura esperada	Proposta
F2	Bem formada, mas com a ferramenta errada, ou a ferramenta certa com valores que não se encaixam	Proposta, Gate
F3	O modelo afirma algo que o seu contexto não sustenta; o Capítulo 3 dá o termo comum para isso	Contexto, Proposta
F4	Conteúdo que é dado foi tratado como instrução, direta ou indiretamente	Contexto, Gate
F5	O run segue em frente sem progresso, ou age sobre um contexto que já não é verdadeiro	Contexto, Limite
F6	Parte de um efeito de vários passos aconteceu e nada diz isso	Efeito
F7	Aconteceu um efeito que este principal, neste momento, não deveria ter conseguido causar	Gate, Efeito
F8	O sistema fez algo e não deixou evidência utilizável	Registro
F9	O run está correto, mas custa caro demais ou demora demais	Limite

Dois outros eixos completam uma classificação: o **eixo da causa-raiz** (modelo, contexto, ferramenta ou controle; “o modelo cometeu um erro” é o gatilho, não uma causa-raiz) e a **severidade**, que segue o efeito que aconteceu (Capítulo 3).

Seve- rida- de	O que significa	Ferramentas típicas
Infor- mação	Nada mudou; uma respos- ta errada ou uma leitura desperdiçada	<code>lookup_order</code> , <code>query_logs</code> , <code>search_docs</code>
Rever- sível	O estado mudou e uma ação compensatória pode restaurá-lo	<code>update_shipping_address</code> , <code>open_pull_request</code> , <code>toggle_feature_flag</code> , <code>request_rollback</code>
Irre- versí- vel	A Parcelport não consegue desfazer	<code>issue_refund</code>

Seve-rida-de	O que significa	Ferramentas típicas
Externa	Alcançou uma pessoa ou um sistema que a Parcelport não controla	<code>send_customer_reply</code>

Quanto menos uma falha pode ser desfeita, mais cedo e de forma mais determinística ela precisa ser interrompida. Quando um incidente carrega várias etiquetas, ordene-as da proposta em direção ao efeito (Capítulo 3).

Checklist de pré-lançamento

Esta é a forma curta da lista do Capítulo 24: os mesmos seis grupos, os mesmos itens, na mesma ordem. Cada linha é uma pergunta, seguida do capítulo que constrói o controle. A evidência que responde a cada uma, e os níveis de maturidade, estão no Capítulo 24. Uma linha que você só consegue responder com “o prompt diz isso” ainda não é um controle.

Contexto

- ☐ Você consegue mostrar, para um run real, de onde veio cada item do contexto e que nível de confiança ele tinha? (Capítulo 9)
- ☐ Uma consulta sem boa resposta retorna “nenhuma correspondência boa”, e os documentos carregam versões e datas `as_of`? (Capítulo 9)
- ☐ O conteúdo não confiável mantém a sua marca até que uma verificação a libere, inclusive quando é copiado para um argumento de ferramenta? (Capítulo 16)
- ☐ Os servers e as ferramentas MCP estão em um allowlist com responsável e fixado, com as definições alteradas bloqueadas até serem revisadas? (Capítulo 8)
- ☐ Um run interrompido consegue ser retomado sem repetir um efeito, e um sweep encontra o estado que diverge do mundo? (Capítulo 10)
- ☐ Toda escrita na memória é uma proposta que uma política aceita ou recusa, com uma expiração? (Capítulo 11)

- ☐ As ferramentas retornam apenas os campos de que a tarefa precisa, e o registro aplica redaction ao que sobra? (Capítulo 17)

Proposta

- ☐ Toda proposta é analisada e validada, e uma inválida recebe um caminho de correção contado e limitado, e não um efeito? (Capítulo 5)
- ☐ Está escrito quais decisões o modelo toma e quais o código toma, com valores, limites e permissões do lado do código? (Capítulo 4)
- ☐ Algo no caminho de controle lê a própria declaração de certeza do modelo e, se sim, que sinal independente a sustenta? (Capítulo 2)
- ☐ Cada mudança de modelo, prompt, ferramenta ou política passa pelo pipeline do código, com uma execução de eval anexada? (capítulos 2 e 21)
- ☐ Um plano é validado contra os mesmos contratos, e cada passo dele passa de novo pelo gate quando é executado? (Capítulo 12)

Gate

- ☐ Toda ferramenta tem um contrato com nome, descrição, esquema de entrada, classe de efeito, pré-condições, idempotência, permissões, timeouts e formato de erro, com as omissões justificadas? (Capítulo 6)
- ☐ Um reembolso acima de `refund_ceiling`, ou de um pedido que não é do cliente, vai para aprovação ou recusa sem envolver o modelo? (capítulos 4, 6 e 15)
- ☐ A autoridade é delegada, estreita e de curta duração, sem nenhuma credencial no agente que dure mais do que uma chamada? (Capítulo 7)
- ☐ Um argumento alterado invalida a aprovação, e a autoridade é verificada de novo depois da espera? (Capítulo 15)
- ☐ A taxa de aprovação, o tempo de decisão e a taxa de recusas e edições são revisados, e já mudaram um limiar? (Capítulo 15)

Efeito

- ☐ A intenção é registrada antes do efeito, e algo resolve um run que parou entre as duas coisas? (capítulos 5 e 10)

- ☐ Depois de um timeout em `issue_refund`, o sistema consulta o status antes de qualquer retry? (capítulos 6 e 14)
- ☐ Toda escrita reversível nomeia a sua ação compensatória no contrato, e alguma já foi executada? (Capítulo 6)
- ☐ Não há secrets na configuração, no contexto, nos checkpoints nem nos traces, e tudo o que um agente poderia tocar pode ser revogado? (Capítulo 18)
- ☐ `run_diagnostic` passa nos testes de conformidade de rede, sistema de arquivos e credenciais no runtime real? (Capítulo 19)

Limite

- ☐ Passos, tempo e gasto têm limites que o run não consegue elevar, com uma parada que faz o hand-off com um resumo? (capítulos 12 e 13)
- ☐ Cada nível de orçamento tem um limite e um responsável, sob um teto global que você poderia pagar no pior dia? (capítulos 13 e 22)
- ☐ Exatamente uma camada faz retry, gastando do orçamento, e uma retry storm já foi provocada? (Capítulo 14)
- ☐ O modo degradado está definido e foi testado? (capítulos 13 e 14)
- ☐ O kill switch fica fora do agente, com operadores nomeados e escopos mais estreitos do que “tudo”, e já foi acionado? (Capítulo 13)
- ☐ Você consegue dizer, a partir do trace, quanto custou um ticket e uma investigação? (Capítulo 22)

Registro

- ☐ Quem está de on-call consegue abrir um run pelo id e ver, em ordem, toda chamada ao modelo, decisão do gate, aprovação e efeito? (Capítulo 20)
- ☐ Está decidido quais prompts e saídas são armazenados, passam por redaction e são amostrados, e quem pode lê-los? (capítulos 17 e 20)
- ☐ Existem alertas para taxa de recusa, taxa de hand-off, taxa de aprovação, anomalias de custo e distribuição de classes de falha, cada um com um responsável? (Capítulo 20)
- ☐ Para F1 a F9, você consegue nomear a detecção e a limitação que este agente tem? (Capítulo 3)

- ☐ Uma mudança de prompt, modelo, ferramenta ou política executa o golden set, e uma regressão bloqueia o deploy? (Capítulo 21)
- ☐ Existe um runbook ensaiado com uma escada de contenção, uma consulta de impacto e um modelo de revisão sem culpa? (Capítulo 23)
- ☐ A última revisão produziu um caso de eval, uma mudança de política ou uma mudança de contrato, e não apenas um documento? (capítulos 21 e 23)

Modelo de revisão de incidentes de agentes

Uma revisão examina o sistema que permitiu a ação ou a tornou invisível. Execute-a poucos dias depois do incidente, conduzida por alguém que não participou da resposta, usando o modelo abaixo. O Capítulo 23 explica cada campo. A revisão se aplica a incidentes de nível reversível para cima, e a qualquer incidente com uma lacuna de detecção, qualquer que seja a sua severidade; um quase-acidente no nível de informação vira um ticket e um caso de eval.

```
incident_review                                // illustrative template
summary:                                     two sentences, no names, no "the AI"
timeline:                                   from the trace and the flag store, not from memory
                                           // times of: first bad effect, detection, declaration,
                                           // containment confirmed, impact list complete
detected_by:                                signal name, or "reported by a person" (a finding)
impact:                                     the impact list summary, with the unknown count
classes:                                    F-ids in order, from proposal toward effect
severity:                                   information | reversible | irreversible | external
root_cause:                                 axis, rank, evidence link, for each cause
what_held:                                  controls that limited the harm
missing_control:                             the control that should have held
owner_team:                                  string          // the team that owns the missing control
action_items:                                list of { change, kind, owner, check }
                                           // kind: eval case | policy | contract | alarm | runbook
response_notes:                             what slowed the response; what the runbook lacked
```

O Capítulo 3 define o registro no centro deste modelo, `incident_record`, com os campos `id`, `run_ids`, `classes`, `root_cause`, `severity`, `detected_by`, `missing_control`, `owner_team` e `action_items`. O modelo traz todos os campos do registro, exceto `id` e `run_ids`, que o registro fornece; `summary`, `timeline`, `impact`, `what_held` e `response_notes` são o que a revisão acrescenta. Manter `severity` e `owner_team` permite aplicar a regra de escopo acima a partir do registro e rastrear um achado até a equipe que detém o controle ao qual ele retorna.

As regras são as do Capítulo 23: a linha do tempo vem do registro, as pessoas aparecem como papéis, cada item de ação é um controle com uma verificação, e “o modelo cometeu um erro” é o gatilho e não uma causa-raiz (capítulos 20, 21 e 23).

Onde vai um achado

Achado	Torna-se	Capítulo
Uma proposta que deveria ter sido recusada	Uma nova pré-condição no contrato de ferramenta	6
Um efeito que nenhum principal deveria ter conseguido causar	Uma permissão ou um teto mais estreito	7
Um pedido que não deu ao aprovador o que ele precisava	Uma mudança no que a aprovação mostra	15
Uma situação que ninguém viu chegar no registro	Uma nova métrica ou alarme	20
Uma situação que o sistema deveria tratar de forma diferente da próxima vez	Um caso de eval que falha na versão do incidente	21
Uma etapa de resposta que foi lenta ou estava ausente	Uma mudança no runbook e uma simulação	23

Uma revisão que termina sem um caso de eval está inacabada. O caso é construído a partir do contexto registrado, com redaction antes de ser armazenado (Capítulo 17), com o resultado esperado declarado como um comportamento, como “recusa” ou “escalona”, e etiquetado com a classe de falha. Ele só entra no golden set se falhar em uma taxa declarada ou acima dela ao longo das repetições, na versão que teve o incidente. Abaixo dessa taxa, é marcado como não reproduzido e vai para uma pessoa, e nunca é descartado.

SOBRE O LIVRO

Os agentes de IA devem ser projetados como tomadores de decisão pouco confiáveis que operam dentro de sistemas de controle confiáveis.

O modelo é um gerador de propostas, não uma autoridade. O que torna seguro executar um agente é o sistema de controle ao seu redor: o contexto que ele recebe, o gate que toda proposta precisa atravessar, os efeitos que ele pode causar, os limites de até onde pode ir e o registro do que ele fez.

Acompanhando a Parcelport, o livro constrói esse envelope de controle (Contexto, Proposta, Gate, Efeito, Limite, Registro) com engenharia comum: contratos de ferramentas, permissões, orçamentos, aprovação humana, sandboxing, tracing, avaliação e resposta a incidentes.

SOBRE O AUTOR

Muhammet Şafak desenvolve software desde 2008. Durante muitos anos atuou ativamente nas áreas de saúde, finanças e telecomunicações, e defende que o desenvolvimento deve se concentrar no problema, não na tecnologia. Desde 2024 projeta e desenvolve sistemas de alto tráfego escaláveis de ponta a ponta.

Faz mentoria de equipes de desenvolvimento de software de pequeno e médio porte, conduz projetos de código aberto e registra por escrito as decisões, com suas razões e seu custo.

Sistemas confiáveis não são construídos com peças confiáveis. São construídos em torno das peças que falham.

I

ACESSO

II

EVENTOS

III

AGENTES

