




Güvenilir AI Agent Mühendisliği

Güvenilir AI Agent Mühendisliği

Production'daki agent'lar için tool'lar, yetki, state, sınırlar ve kayıtlar

Muhammet Şafak

İçindekiler

Önsöz	6
KISIM I — TEMELLER	13
Bölüm 1 — Agent Sistemin Kendisi Değildir	14
Bölüm 2 — Model Belirsizliği	35
Bölüm 3 — Agent'lar İçin Bir Hata Taksonomisi	52
Bölüm 4 — Determinizm Sınırları	72
KISIM II — TOOL'LAR VE YETKİ	89
Bölüm 5 — Tool Çağırma	90
Bölüm 6 — Tool Sözleşmeleri	110
Bölüm 7 — İzinler ve Devredilmiş Yetki	131
Bölüm 8 — MCP: Güven Sınırını Aşan Tool'lar	150
KISIM III — BAĞLAM, STATE VE BELLEK	170
Bölüm 9 — Bağlam Yönetimi	171
Bölüm 10 — State	190
Bölüm 11 — Bellek	208
KISIM IV — KONTROL DÖNGÜLERİ	227
Bölüm 12 — Planlama ve Döngüler	228
Bölüm 13 — Bütçeler ve Circuit Breaker'lar	250
Bölüm 14 — Retry'lar ve Fallback'ler	270
Bölüm 15 — İnsan Onayı	292
KISIM V — GÜVENLİK SINIRLARI	311
Bölüm 16 — Prompt Injection	312
Bölüm 17 — PII	332

Bölüm 18 — Secret'lar	349
Bölüm 19 — Sandboxing	367
KISIM VI — KANITLAMAK VE İŞLETMEK	382
Bölüm 20 — Observability ve Tracing	383
Bölüm 21 — Değerlendirme	405
Bölüm 22 — Maliyet Kontrolü	425
Bölüm 23 — Olay Müdahalesi	441
Bölüm 24 — Bir Güvenilirlik Kontrol Listesi ve Kapanış Düşünceleri	461
Ek	474

Önsöz

Orta ölçekli bir fulfillment şirketi düşünelim: Parcelport. İlk agent'ının devreye girdiği pazartesi günündeyiz. Agent müşteri e-postalarını okuyor, siparişleri sorguluyor, teslimat adreslerini değiştiriyor ve belli bir tavana kadar iade yapıyor. Demo iyi geçti. Prototip tek bir prompt, tek bir geniş API token'ı ve model işin bittiğini söyleyene kadar dönen bir döngüden ibaret. Ekipten kimse bunun nihai tasarım olduğunu düşünmüyor, ama her şey çalışıyor ve lansman tarihi belli.

Çarşambaya gelindiğinde ekip üç şey öğrenmiş durumda. Bir ticket, hiçbir tool'un döndürmediği bir teslimat tarihini vaat eden bir yanıt üretti. Bir run aynı sorguyu art arda 40 kez çağırdı ve biri tesadüfen run'ı izleyene kadar kimse fark etmedi. Bir müşteri e-postası da "asistana" hitap eden bir paragraf içeriyordu ve run bunu Parcelport'tan gelen bir talimat gibi ele aldı. Bunların hiçbirisi felaket değildi. Hepsi öngörülebilirdi ve hiçbirisi sonradan tam olarak yeniden kurulamadı, çünkü agent'ın ne yaptığına dair tek kayıt nihai yanıtıydı.

Bu kitap, ekibin bundan sonra ne yaptığını anlatıyor. Daha iyi bir prompt yazarak başlamıyor. Farklı bir soruyla başlıyor: model bazen yanlış yapacaksa, yanlış yapmak atlatılabilir olsun diye çevresindeki sistemin neyi garanti etmesi gerekir?

Tek cümlelik fikir

Kitabın tamamı tek bir cümleyi savunuyor:

AI agent'lar, güvenilir kontrol sistemlerinin içinde çalışan
güvenilmez karar vericiler olarak tasarlanmalıdır.

Bu cümlelerin neyi iddia ettiği konusunda dikkatli olmak istiyorum. "Güvenilmez" bir hakaret değil, bir tasarım varsayımdır. Modelin olasılıksal olduğunu, kendisine gösterilene duyarlı olduğunu ve tam bir

akıcılıkla yanlış olabildiğini, tasarımın da ondan başka bir şey olmasına ihtiyaç duymaması gerektiğini söyler. Güvenilmez ağlar ve güvenilmez diskler üzerine de aynı şekilde inşa ediyoruz. Kimse yalnızca ağ düzgün davrandığında çalışan bir tasarımı yayına almaz ve kimse ağın adına alınmaz.

"Güvenilir kontrol sistemleri" öbür yarıdır ve kitap sayfalarını bu yarıya harcıyor. Sıradan mühendislik bu: schema'lar, state machine'ler, izinler, bütçeler, timeout'lar, queue'lar, log'lar ve testler. Hiçbiri yeni değil. Yeni olan, çıktısı bir komut değil bir öneri olan bir bileşene bunları açık bir kafayla uygulamak.

Kitabın modelin döndürdüğü her şeyi bir öneri olarak ele almasının nedeni de bu. Bir tool çağrısı, bir plan ve bir nihai yanıt, hepsi öneridir. Bir öneri, bir şeyi değiştirmesine izin verilmeden önce ayrıştırılır, doğrulanır, politikaya karşı denetlenir, maliyeti sınırlanır ve kaydedilir. Model önerir, sistem karar verir.

Bu kitap neden var

Agent'lar üzerine yazılanların çoğu modeli daha iyi yapmakla ilgili: daha iyi talimatlar, daha iyi örnekler, daha iyi modeller. Bu çalışma önemli ve bu kitabın konusu değil. Bir ekip bunların hepsini iyi yapıp yine de kötü bir günde parayı yanlış yere gönderen bir sistem yayına alabilir, çünkü daha iyi bir model daha seyrek ama yine de hata yapar ve "daha seyrek", bir denetçiye, bir finans ekibine ya da bir müşteriye vaat edilebilecek bir özellik değildir.

Model olabileceği en iyi hâle geldikten sonra geriye kalan sorular mühendislik sorularıdır. Önerilen bir iade ödeme sistemine nasıl ulaşır ve tutar yanlış olduğunda onu ne durdurur? Agent ne görüyor, her parçası nereden geldi ve ona ne kadar güvenilebilir? Model işin bittiğini hiç söylemediğinde bir run nasıl sona erer? Sonrasında ne kalır ki gece üçte on-call olan biri olanları yeniden kurabilsin?

Bu soruların iyi cevapları var ve cevaplar dağıtık sistemler kurmuş herkese tanıdık gelir. Bunlar, nasıl başarısız olacağı tam olarak öngörülemeyen her bileşen hakkında sorulan sorularla aynı biçimde. Fark yalnızca, bu bileşenin başarısız olurken akıcı bir nesir yazması; bu da hataların gözden kaçmasını kolaylaştırıyor.

Bu kitap kimin için

Kitap backend ve platform mühendisleri, SRE'ler, tech lead'ler ve bir AI agent'ı production'a taşıyan ekipler için yazıldı. Okurun yetkin bir yazılım mühendisi olduğu varsayılıyor. Dil modelinin ne olduğunu açıklamayacağım ve makine öğrenmesi sözcüklerini yalnızca bir kontrol kararını değiştirdikleri yerde kullanacağım, orada da aynı cümlelerin içinde açıklayacağım.

İlk agent kuruluyor ya da başkasının prototiplediği bir agent devralınıyor olabilir. Güvenlik tarafında olup başkasının kurduğu bir tasarımı review etmesi istenen biri de olabilir. Bütün bu durumlarda yararlı soru aynı: bu sistem modele olması gerekenden fazla nerede güveniyor ve bunu bırakmak neye mal olur?

Belirli bir framework kullanılmış olması gerekmiyor. Kitap hiçbirini öneri olarak anmıyor ve örüntüler hiçbirine bağlı değil.

Bu kitap ne değildir

Sınırlar konusunda açık olmak yardımcı olur, çünkü konu başka yerlere kaymaya açık.

Bu bir prompt mühendisliği kitabı değil. Prompt'lar, kötü önerilerin oranını düşürdükleri için yer alıyor ve bu yararlı. Ama prompt bir rica, ve bu kitaptaki hiçbir özellik tek başına bir ricaya dayanmıyor. Bir bölüm bir talimata yaslandığında, talimat tutmadığı zaman tutan deterministik kontrolü adlandırıyor.

Modellerin eğitimi ya da fine-tuning'i hakkında bir kitap da değil. Modeli çağrılan bir bileşen olarak ele alıyor ve o bileşen değiştirildiğinde de aynı şekilde çalışıyor.

Bir framework ya da bir vendor rehberi de değil. Gerçek ürünler ve açık protokoller örnek olarak yer alıyor; yalnızca davranışlarından emin olduğum ölçüde ve yalnızca sürümler arasında geçerli kalan biçimlerde anlatılıyor. Önemli olan örüntü, ürün bir örnek.

AI etiği ya da işin geleceği hakkında bir kitap da değil. Bunlar ciddi konular ve kendi kitaplarını hak ediyorlar. Bu kitap, kurulan şeyin düzgün davranıp davranmadığı, bunun anlaşılıp anlaşılamadığı ve

davranmadığında ne yapıldığıyla ilgili.

Ayrıca bir saldırı kitabı da değil. Prompt injection'ı ya da veri ifşasını tartıştığı yerde savunmanın tarafında kalıyor. Bir kontrolü haklı çıkaracak kadar ayrıntıyla neyin ters gidebileceğini söylüyor, sonra kontrole geçiyor. Burada çalışan hiçbir payload ve hiçbir şeyi aşmanın adım adım yolu bulunmaz.

Kitabın biçimi

Her bölüm, kontrol zarfı adını verdiğim bir modelin bir parçasına hizmet ediyor. Altı parçası var ve her biri bir soruyu cevaplıyor:

- **Bağlam:** model ne görüyor, her parça nereden geldi ve ona ne kadar güvenilebilir?
- **Öneri:** model ne önerdi ve kanıtlanana kadar güvenilmez girdi olarak mı ele alınıyor?
- **Gate:** bu önerinin, bu principal için, şu anda etkiye dönüşmesine izin var mı?
- **Etki:** onaylanmış bir eylem dünyaya nasıl ulaşıyor, onu ne sınırlıyor ve onu ne geri alabilir?
- **Sınır:** döngü nerede duruyor ve çalıştırması neye mal oluyor?
- **Kayıt:** hangi kanıt kalıyor, davranış nasıl ölçülüyor ve işler ters gittiğinde ne yapıyoruz?

Bölüm 1 zarfı düzgün biçimde tanıtıyor. Bundan sonra her bölüm ait olduğu parçayı ve cevapladığı soruyu adlandırıyor, modeli yeniden açıklıyor. Herhangi bir bölümdeki bir paragraf kontrol sorusu çıkarıldığında da doğru ve yararlı kalacaksa, muhtemelen başka bir kitaba aittir.

Bölümler altı kısımda toplanıyor. Kısım I temelleri kapsıyor: bir agent'ın sistem olarak ne olduğu, modelin neden belirsiz olduğu, agent'ların başarısız olma yollarının bir taksonomisi ve determinizmin nerede tutması gerektiği. Kısım II tool'ları ve yetkiyi kapsıyor: tool çağırma, tool sözleşmeleri, izinler ve devredilmiş yetki, ve bir güven sınırı olarak MCP. Kısım III bağlamı, state'i ve belleği kapsıyor. Kısım IV kontrol döngülerini kapsıyor: planlama, bütçeler ve circuit breaker'lar, retry'lar ve fallback'ler, ve insan onayı. Kısım V güvenlik sınırlarını kapsıyor: prompt injection, PII,

secret'lar ve sandboxing. Kısım VI sistemi kanıtlamayı ve işletmeyi kapsıyor: observability, değerlendirme, maliyet kontrolü ve olay müdahalesi, bir kapanış kontrol listesiyle.

Bir ek; bir sözlüğü, örüntülere hızlı bir başvuru, bir tool sözleşmesi şablonunu, hata taksonomisini bir tablo olarak, bir lansman öncesi kontrol listesini ve bir agent'ın karıştığı bir olayı review etmek için bir şablonu bir araya getiriyor.

Örneklerdeki şirket

Örnekleri tutarlı tutmak için kitap tek bir kurgusal şirketi izliyor. Parcelport çevrimiçi mağazalardan sipariş alıyor, malları depoluyor ve gönderiyor, bunun işlemlerini sağlayan iç platformu çalıştırıyor. Tamamen uydurma. İsimleri, rakamları ve insanları gerçek hiçbir kuruluşu anlatmıyor.

Parcelport iki agent çalıştırıyor. Destek agent'ı müşterilerle konuşuyor: ticket'ları ve e-postaları okuyor, siparişleri sorguluyor, teslimat adreslerini değiştiriyor, belli bir tavana kadar iade yapıyor ve geri kalan her şeyi bir insana devrediyor. Ops agent'ı şirketin kendi on-call mühendislerine yardım ediyor: log'ları, metric'leri ve trace'leri okuyor, bir sandbox içinde tanımlama betikleri çalıştırıyor, pull request açıyor ve bir rollback'i ya da bir feature flag değişikliğini yalnızca bir insanın onayıyla başlatıyor.

Her iki agent de ağıllıkta benzer bir prototip olarak başlıyor: bir prompt, bir geniş token, hiç limit yok, hiç log yok, hiç eval yok. Kitap boyunca her bölüm onları bir review'da savunulabilecek bir tasarıma bir adım daha yaklaşıyor. Örnekler bilerek küçük. Bir örüntüyü taşımak için varlar, makul bir production sistemini son queue'suna kadar anlatmak için değil.

Her bölüm kısa bir senaryoyla açılıyor ve senaryolar kurgusal. Birinci tekil kişiyle yazdığım da amaç okura bir yargı vermek: "Tavan denetimini tool gateway'e koyardım." Asla gerçekten yaşanmış bir hikâyeyi iddia etmek için değil. Dersi sağlam, açıkça uydurma bir örneği, arkasında duramayacağım ödünç bir örneğe tercih ederim.

Nasıl okunur

Konuya yeni olan okur bölümleri sırayla okumalı. Kısım I sözcük dağarcığını veriyor ve sonraki kısımlar onu varsayıyor. Her bölüm kısa bir çıkarım listesiyle ve bir sonrakine bağlayan bir cümleyle bitiyor.

Çalışan bir agent'ı devralan Bölüm 3'ten, yani hata taksonomisinden başlamalı ve onu zaten ters giden şeylere ad vermek için kullanmalı. Sonra zarfın en çok acıtan parçasının bölümü okunmalı. Bölümler kendi başlarına makul ölçüde ayakta durabilecek şekilde yazıldı ve birbirini tekrarlamak yerine numarayla birbirine işaret ediyor.

Başkasının tasarımını review eden Bölüm 1'i ve kapanıştaki kontrol listesini (Bölüm 24) okumalı, Ek'i de bir soru kümesi olarak kullanmalı. Kontrol listesi bir sertifika değil. Bir tasarımın modele hak ettiğinden fazla güvenme eğiliminde olduğu yerlerin listesi.

Karşılaşmadan önce notasyon hakkında bir söz. Kitaptaki bütün kod, düz `text` bloklarındaki dilden bağımsız pseudocode ve diyagramlar Mermaid. Gerçek bir dilden kaçınıyorum, çünkü örüntü bir yeniden yazımdan sağ çıkmalı ve hiçbir sağlayıcı API'sini ya da SDK'yı göstermiyorum. Model çağırısı her zaman bir öneri döndüren tek bir soyut fonksiyon, `model.propose(context)`, çünkü önemli olan öneriyle ne yapıldığı, onun nasıl elde edildiği değil. Tool'lar, JSON Schema'ya benzeyen küçük bir notasyonla yazılmış sözleşmelerle tanımlanıyor ve hiçbir yerde gerçek prompt metni yer almıyor, çünkü prompt bir rica ve kitap rica yok sayıldığında neyin tuttuğuyla ilgili.

Baştan sona her kontrol maliyetiyle birlikte geliyor. Bir onay adımı iadeyi yavaşlatır. Bir circuit breaker bazen neredeyse bitmiş bir görevi durdurur. Kimsenin okumadığı bir trace, ödenen bir depolama ve hak edilmemiş bir rahatlıktır. Bir kontrol gösteriş olduğunda söyleyeceğim ve onun kullanılmaması gerektiğinde de söyleyeceğim. İçinde hiç sürtünme olmayan bir tasarım denetlenmemiştir.

Kitaptaki sayılar örneklerdir. "Diyelim ki 10 step'lik bir limit" yazdığımda 10, argümanı somutlaştırmak için bir yer tutucudur, bir öneri ya da ölçüm değildir. Model boyutlarını, fiyatları, gecikmeleri ya da benchmark'ları vermiyorum, çünkü bunlar bir kitabın yetişebileceğinden hızlı değişiyor ve onlara bağlı bir tasarım zaten başarısız olmuştur.

Yaklaşım üzerine bir söz

Kitap, belirli bir modelden, sağlayıcıdan ya da sürümden bilerek bağımsız. Buradaki bir örüntü model değiştirildiğinde çalışmayı bırakırsa, kötü yazmışım demektir. Bunu her bölüme uygulanabilecek bir test olarak görmek gerekir: model başka biriyle değiştirilir ve kontrolün hâlâ tutup tutmadığı sorulur. Değişimden sağ çıkan bir kontrol gerçek iş yapıyordur. Çıkmayan, modelin iyi davranışının sırtında geziyordu.

Aynısı hatalar için de geçerli. Bu kitapta bir şey ters gittiğinde, ders onu mümkün kılan ya da görünmez kılan sistemle ilgilidir. Asla modelin karakteriyle ve asla daha iyisini bilmesi gereken bir insanla ilgili değildir. Kimsenin asla hata yapmamasına bağlı bir tasarım başarısız olur, modelin asla hata yapmamasına bağlı olan da.

Bunların hiçbiri agent'ların tehlikeli olduğu ya da her şeyi değiştirmek üzere olduğu iddiası değil. Bunların bileşen olduğu ve tam öngörülemeyen bileşenlerin, öngörülebilir şeylerle sarılmaya tam olarak değer olanlar olduğu iddiası. Bu mütevazı geliyorsa, öyle olması için. Güvenilirliğin çoğu mütevazı. Zekice kısmın sıradan bir salı gününde yararlı olup olmadığına karar veren, o zekice kısmın etrafındaki gösterişsiz iştir.

Tam olarak ne kurduğumuzla başlayalım. İlk bölüm prototipi parçalarına ayırıyor ve içinde saklanan sistemi buluyor.

KISIM I

Temeller

Bölüm 1 — Agent Sistemin Kendisi Değildir

Parcelport'ta bir salı günü demosunu düşünelim. Bir platform mühendisi ekranını paylaşıyor ve bir müşteri e-postasını destek agent'ının prototipine yapııştırıyor: bir koli köşesi çatlamış olarak gelmiş ve müşteri parasını geri istiyor. Prototip e-postayı okuyor, siparişi sorguluyor, hasar iddiasını makul buluyor, bir iade yapıyor, kibar bir yanıt yazıyor ve gönderiyor. Her şey bir dakikadan kısa sürüyor ve oda, bir şey beklenenden iyi çalıştığına odaların sustuğu gibi susuyor.

Odadaki kimsenin etkilenmekte haksız olduğu yok. Prototip tek bir prompt, her tool'da ve her müşteride çalışan tek bir geniş API token'ı ve model tool istemeyi bırakana kadar dönen bir döngüden ibaret. İterasyon limiti yok, timeout yok, nihai yanıtta başka log yok. Çalışıyor, çünkü demo iyi bir gün: e-posta dürüst, servisler yanıt veriyor, model makul şeyler öneriyor.

Şimdi aynı prototipi kötü bir günde, queue'da yüz ticket varken düşünelim. Bir e-posta, talimat gibi okunan bir metin içeriyor. Bir sorgu timeout'a düşüyor ve döngü aynı çağrıyı tekrar tekrar öneriyor. Bir iade kaydediliyor ve yanıt hiç gönderilmiyor. Bunlardan hangisinin olduğunu kimse söyleyemiyor, çünkü tek kanıt nihai yanıt.

Bu bölüm, kitaptaki her kontrolden önce gelen bir soruyu cevaplıyor: model agent'ın yalnızca bir bileşeniyse, diğerleri neler ve kim neyden sorumlu? Kontrol zarfının altı parçasını da ilgilendiriyor, çünkü onları tanıtıyor. Her parçanın sorusu sonra, bölüm bölüm ortaya çıkıyor. Burada bütün resmi bir kez çiziyoruz ki sonraki her bölüm onun bir parçasına işaret edebilsin.

Sorun ve neden zor olduđu

Sorun prototipin kötü olması değil. Sorun, parçası olmaması. Prompt vermek, tool seçmek, servis çağırmak, olanları hatırlamak, durmak, bir insana sormak ve kanıt bırakmak, hepsini aynı şey, aynı yerde, aynı nefeste yapıyor. O şey doğru olduğunda her şey doğru; yanlış olduğunda her şey birden yanlış ve durup hatanın gözlenebileceğı bir yer yok.

Prototip içeriden nasıl görünür

Prototipin neleri içerdiğini adlandırmak yardımcı olur, çünkü her kalem kimsenin bilerek vermediğı bir tasarım kararıdır.

- **Bütün davranışı tek bir prompt taşıyor.** Ton, iade politikası, yükseltme kuralları ve "asla şunu yapma" talimatlarının hepsi düzyazı. Tutup tutmamaları o günkü modele bağlı.
- **Bütün yetkiyi tek bir token taşıyor.** Agent her müşteri için her tool'u çağırabiliyor, çünkü prototipin buna ihtiyacı vardı ve öyle kaldı.
- **Döngü modelin.** Döngü, model tool istemeyi bıraktığında bitiyor. Modelin dışında onu bitiren hiçbir şey yok.
- **Bağlam, sığan her şey.** Tool sonuçları ve e-posta metni prompt'a olduğu gibi giriyor; hangi parçanın veri, hangisinin talimat olduğunu işaretleyen hiçbir şey yok.
- **State, konuşmanın kendisi.** Run'ın yaptıkları transkriptte duruyor; bu yüzden bir crash onu kaybettiriyor ve uzun bir run onu dışarı itiyor.
- **Kanıt, nihai yanıt.** Ara step'lerin kaydı yok, bu yüzden kötü bir sonuç açıklanamıyor.

Bunların hiçbiri olağandışı değil. Her biri yazıldığı gün makuldü. Toplamları, güvenilirliği tümüyle, kitabın geri kalanının olasıksal saydığı tek bileşene bağlı bir sistem.

Nasıl başarısız olur

Kitabın adlandırdığı hata sınıflarını düşünelim (Bölüm 3 bunların sahibi ve her birine tanımını ve örneğini veriyor). Prototipte dokuzundan herhangi birinin yakalanacağı bir yer yok: bir tool'a uymayan bir öneri, bağlamın desteklemediğı bir iddia, sonraki çağrıyı yönlendiren bir metin,

tekrar eden bir döngü, yarım kalmış bir etki, görevden geniş bir yetki, kimsenin yeniden kuramadığı bir run, kimsenin gelişini görmediği bir fatura.

Bir prototipin imzası, bu hatalardan birinin olası olması değil. Hiçbirinin yakalanacağı bir yerin olmaması.

Bariz çözüm neden işe yaramaz

Bariz çözüm daha iyi bir prompt, ben de bir tane yazardım: kötü önerilerin oranını düşürür. Ama prompt bir kontrol değil. Olasılıksal bir bileşene yapılmış bir rica ve çoğu zaman tutan bir rica, bir finans ekibinin, bir güvenlik ekibinin ya da bir on-call mühendisinin üzerine inşa edebileceği bir özellik değil. Daha iyi bir model beklemek hata oranını değiştirir; tasarımın kalan hatayı yakalayacak bir yeri olup olmadığını değiştirmez. Bölüm 2, modelin çıktısına neden böyle davranılması gerektiğini açıklıyor.

Yani bu bir mühendislik problemi, prompt problemi değil. Soru sınırların nereye gideceği: sistemin hangi parçası hangi kararı hangi kanıtla veriyor ve o parça yanlış olduğunda ne oluyor.

"Agent" sözcüğü çok iş yapıyor

Zorluğun bir kısmı sözcük dağarcığında. Konuşmada "agent", bir tool çağrısı döndüren bir model, bir prompt şablonu, bir döngü, bir ürün ya da bir persona anlamına gelebilir. Bunlar farklı hata kipleri olan farklı nesnelerdir ve hepsi için tek sözcük kullanan bir ekip bir kontrolün nereye ait olduğunu söyleyemez. "Agent'a bir guard ekle"nin adresi yok.

Bu kitap tek bir tanım kullanıyor ve tutarlı kullanıyor.

Agent bir bileşendir: bir model çağırır, modelin önerilerini denetlemesi için bir gate'e sorar ve onaylanan etkileri tool'lar aracılığıyla uygulayan bir orchestrator döngüsü. Bir insan değil, bir "bot" değil ve model değil. Model agent'ın bir parçası, agent da etrafındaki sistemin bir parçası.

Tanım bilerek mekanik. Bir döngüsü, bir model çağrısı, bir denetimi ve bir etkisi var; her biri kodda parmakla gösterilebilecek bir şey. Bağlam daha uzun ifadeyi gerektirdiğinde "AI agent" denebilir, ama nesne aynı kalır.

Bir agent'ın anatomisi

Prototip parçalarına ayrılır. Aşağıdaki, kitabın geri kalanının varsaydığı anatomi. Her parçaya tek bir iş düşüyor ve iş, kimin yanlış olmasına izin verildiğini adlandırıyor.

Model: bir öneri üreticisi

Model, bağlamı öneriye çeviren bileşendir. **Öneri**, modelin döndürdüğü her şeydir: bir tool çağırısı, bir plan ya da bir nihai yanıt. Model eylemde bulunmaz. Bir siparişi değiştiremez, bir e-posta gönderemez ya da bir pull request açamaz; yalnızca birini isteyen bir yapı döndürebilir.

Bu tek olgu, tasarımın tamamı. Model yalnızca öneriyorsa, bir öneriyi izleyen her şey bir mühendisin koda yer açabileceği bir yerdir. Modelin yanlış olmasına izin var, çünkü döndürdüğü hiçbir şey, başka bir şey onaylayana kadar etkili olmaz.

Modelin çıktısına neden böyle davranılması gerektiği sorusu Bölüm 2'ye ait. Bu bölüm için sonucu tutmak yeterli: öneri, ağdan gelen bir request body'sinin güvenilmez girdi olması anlamında, güvenilmez girdidir.

Orchestrator: döngüyü çalıştıran deterministik kod

Orchestrator (agent runtime da denir), döngüyü çalıştıran deterministik koddur. Bağlamı derler, modeli çağırır, öneriyi gate'e verir, etkiyi uygular, sınırları dayatır ve kaydı yazar. Kontrol akışı onundur. Model orchestrator'ı asla çağırmaz; orchestrator modeli çağırır.

Bu tersine çevirme bir prototipte kolayca gözden kaçır; orada model "sürüyor" gibi hissedilebilir. Tutan bir tasarımda model, orchestrator'ın her step'te bir kez çağırdığı bir fonksiyondur ve fonksiyon ne döndürürse döndürsün, sıradaki kod satırı orchestrator'dadır.

Run, bir agent'ın tek bir görev için başlangıçtan nihai yanıt, bir hand-off'a ya da bir durmaya kadar tek bir yürütülmesidir. Bir id'si ve bir status'ü vardır. **Step**, bir run içinde döngünün bir geçişidir. **Turn**, bir konuşmada agent ile bir insan arasındaki tek bir alışverişidir; bir run'ın birkaç turn'ü, bir turn'ün birkaç step'i olabilir. Bu üç sözcükle tekrar tekrar karşılaşılacak ve aralarındaki fark sınırlar, state ve maliyet için önemli.

Tool'lar ve etki sınıfları

Tool, agent'ın bir sözleşmeyle isteyebileceği adlandırılmış bir yetenektir.

Tool çağırısı, bir tool'u argümanlarla kullanma önerisidir; gate izin verdikten sonra ancak bir **etkiye** dönüşür. Bölüm 5 tool çağırma, Bölüm 6 tool sözleşmesini kapsıyor; şimdilik mesele, bir tool'un bir run'ın dünyaya dokunmasının tek yolu olması.

Parcelport'un support-agent'ının yedi, ops-agent'ının sekiz tool'u var. Onları birbirinden farklı kılan, dördünden biri olan **etki sınıfı**dır: okuma, geri alınabilir yazma, geri alınamaz yazma ve dış yan etki. `lookup_order` bir okuma; `update_shipping_address` geri alınabilir bir yazma; `issue_refund` geri alınamaz bir yazma; `send_customer_reply` bir dış yan etki, çünkü Parcelport'un geri çağırmayacağı bir kişiye ulaşıyor. Etki sınıfı, bir çağırının dünyaya ne yapabileceğini söyler. Bir çağırının insan onayı gerektirip gerektirmediği ayrı bir sorudur ve gate'te politika tarafından cevaplanır.

Bağlam derleme

Bağlam derleme, orchestrator'ın tek bir model çağırısı için bağlama neyin gireceğini seçtiği, sıraladığı ve etiketlediği adımdır. Model, orchestrator'ın ona verdiğini görür, başka hiçbir şeyi değil. Bu cümle önemsiz görünüyor ve kitabın büyük bir kısmının var olma nedeni bu.

Prototipte bağlam, transkriptin biriktirdiği her şeydir. Tasarlanmış bir sistemde bağlamın her parçasının bir kaynağı, bir güven seviyesi ve orada olması için bir nedeni vardır: platform ekibinin yazdığı bir sistem politikası, güvenilirmez diye işaretlenmiş bir ticket metni, onları döndüren tool tarafından işaretlenmiş tool sonuçları. Bölüm 9 bunu kuruyor. Burada şunu söylemek yeterli: bağlam orchestrator'ın inşa ettiği bir şeydir, yani orchestrator'ın yanlış yapabileceği bir şeydir ve bu yüzden prompt'un değil, kontrol sisteminin bir parçasıdır.

State

State, bir run'a dair, orchestrator'ın run store'da tuttuğu olgulardır: step'ler, sonuçlar, status. Transkript değildir. Run'lar arasında tutulan ve sonraki bağlamı şekillendirebilen bilgi olan bellek de değildir. State bu run hakkındadır; bellek, run'dan sonraki dünya hakkındadır. Bölüm 10 state'i,

Bölüm 11 belleği kapsıyor ve ikisi kitap boyunca ayrı tutuluyor, çünkü karıştırmak F5'in (kontrolden çıkan döngü ya da bayat bağlam) yaygın bir kaynağı.

State'in mimari düzeyde önemli olmasının nedeni, bir run'ın uzun ömürlü bir şey olması. Bir insanı bekleyebilir, bir restart'tan sağ çıkabilir ya da başka bir process tarafından resume edilebilir. Modelin bağlamı dışında bir şeyin nerede olduğunu hatırlaması gerekir.

Gate

Gate, bir öneri ile bir etki arasındaki deterministik denetimdir. Üç sonucu var: allow, refuse ya da needs approval. Parcelport'ta gate, önerilen bir çağrıyı tool sözleşmesine karşı doğrulayan, izinleri ve ön koşulları denetleyen politika motoru ve tool gateway tarafından gerçekleştiriliyor. Gate karar verir; bir çağrıya izin verdiğinde orchestrator etkiyi başlatır ve tool gateway o tek çağrı için credential'lı ekler, böylece agent geniş bir credential'lı asla elinde tutmaz. Her tool gate'ten geçer, okumalar dahil; bir okuma için gate incedir (schema, allowlist ve sahiplik; onay yok, idempotency key yok).

"Gate çağrıyı reddetti" bu kitapta tam bir cümledir. Modelin onaylamasına bağlı değildir. Gate, bir **politikanın** (veri ya da kod olarak yazılmış bir kural, asla prompt'ta düzyazı olarak değil) bir öneriyle bulunduğu yerdir.

Gözlem ve kayıt

Bir etki gerçekleştiğinde ya da gate reddettiğinde, sonuç bir **gözlem** olarak bağlama geri döner ve döngü devam eder. Bir run kendini böyle düzeltir: model "öğrendiği" için değil, sonraki step'in bağlamı reddi ya da sonucu içerdiği için.

Döngünün yanında **kayıt**, kanıtı tutar: her öneri, gate kararı, onay ve etki, on-call'ın sonradan okuyabileceği biçimde. Yalnızca bir şey ters gittiğinde var olan bir kayıt, kayıt değildir. İyi günlerde de yazılması gerekir, çünkü bir olay gününde iyi günler baseline'dır.

Tez ve kontrol zarfı

Parçalar adlandırıldığına göre kitabın tezi söylenebilir ve tam yazıldığı gibi kastedilmiştir:

AI agent'lar, güvenilir kontrol sistemlerinin içinde çalışan güvenilir karar vericiler olarak tasarlanmalıdır.


Ağırlığı üç sözcük taşıyor. "Güvenilmez" bir hakaret değil, bir tasarım varsayımı: bileşen olasılıksal, bağlamına duyarlı ve tam bir güvenle yanlış olabiliyor ve bir tasarım onun başka türlü olmasına ihtiyaç duymamalı. Bölüm 2 nedenlerini veriyor; ağlara ve disklere de aynı muamele yapılır. "Karar vericiler", modelin tam da kodda sıralayamayacağımız seçenekler arasından seçim yaptığı için yararlı olduğunu kabul eder. "Güvenilir kontrol sistemleri" ise güvenilirliğin nereden geldiğini söyler: modelin etrafındaki sıradan mühendislikten, yani schema'lardan, state machine'lerden, izinlerden, bütçelerden, timeout'lardan, queue'lardan, log'lardan ve testlerden.

Altı parça

Bu kitap söz konusu kontrol sistemini **kontrol zarfı** denen altı parçaya ayırıyor. Adlar sabit ve sonraki her bölüm onlara atıf yapıyor.

Parça	Cevapladığı soru	Kurulduğu bölümler
Bağlam	Model ne görüyor, her parça nereden geldi ve ona ne kadar güvenilebilir?	9, 10, 11, 16, 17 (ve 8)
Öneri	Model ne önerdi ve kanıtlanana kadar güvenilmez girdi olarak mı ele alınıyor?	2, 5, 12 (ve 4)
Gate	Bu önerinin, bu principal için, şu anda etkiye dönüşmesine izin var mı?	4, 6, 7, 15 (ve 8, 16)
Etki	Onaylanmış bir eylem dünyaya nasıl ulaşıyor, onu ne sınırlıyor ve onu ne geri alabilir?	5, 6, 18, 19
Sınır	Döngü nerede duruyor ve çalıştırması neye mal oluyor?	12, 13, 14, 22
Kayıt	Hangi kanıt kalıyor, davranış nasıl ölçülüyor ve işler ters gittiğinde ne oluyor?	20, 21, 23 (ve 10, 17)

Sonraki diyagram bunların nasıl bağlandığını gösteriyor. Önce döngüye bakılır: bağlam modele gidiyor, model bir öneri döndürüyor, gate karar veriyor ve ancak ondan sonra bir etki gerçekleşiyor. Sonra döngüyü çevreleyen iki şeye bakılır: bütün çevrimi saran sınıra ve her step'i dinleyen kaydın noktalı çizgilerine.



Düz oklar run'ın akışı. Model ortada duruyor, çünkü birkaç bileşenden yalnızca biri ve run'ı işletilebilir kılan her şey onun çevresinde duruyor. İki yol dikkat hak ediyor. Ret yolu bağlama dönüyor, böylece model neden reddedildiğini görüyor. "Stopped" yolu da sınırdan bir insana çıkıyor, çünkü bitiremeyen bir run yine de birine bir hand-off borçlu.

Kodda döngü

Aynı resim, pseudocode olarak, döngünün tek bir step'idir. Onu genişleten her bölüm bu bloğu alıntılacak ve bir parçasını değiştirecek.

```
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)
```

Bu bloktaki iki şey yavaş okunmaya değer. Birincisi, model tam olarak tek bir satırda çağrılıyor. Geri kalan her şey, öneri bir form gönderiminden gelmiş olsaydı da orada olacak sıradan kod. İkincisi, kayıt etkiden önce ("intent") ve sonra ("effect") yazılıyor; böylece ikisinin arasındaki bir

crash, olmak üzere olanın kanıtını bırakıyor. Bu sıralama, nasıl toparlanılacağı üzerinde büyük etkisi olan küçük bir karar ve Bölüm 10 ile 20 ona geri dönüyor.

Sınır step'i sarıyor:

```
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
```

Bir nihai yanıt, status'ünü ayarlayarak run'ı bitirir; model hiç nihai yanıt önermediğinde sınır bitirir. Dolayısıyla döngünün orchestrator'ın sahip olduğu iki çıkışı var ve yalnızca modelin kontrol ettiği hiçbir çıkışı yok. ("plan" türündeki bir öneri run state'i olarak saklanır ve Bölüm 12'de anlatıldığı gibi ele alınır; taslak onu dışarıda bırakıyor.)

Neden altı, daha fazla değil

Makul bir itiraz, listenin daha uzun olabileceği: bir "bellek" parçası, bir "güvenlik" parçası, bir "maliyet" parçası. Altıda tuttum, çünkü her parça birinin sahip olup test edebileceği bir soruyu cevaplamak zorunda. Bellek bir bağlam kaynağıdır, yani Bağlam'a aittir. Güvenlik bir parça değil, birkaç parçanın ürettiği bir özelliktir: gate reddeder, etki sandbox'lanır, bağlam etiketlenir. Maliyet bir sınırdır. Aynı hatanın üç parçaya ait olduğu bir ayrıştırma, bir olayda kimsenin kullanamayacağı bir ayrıştırma.

Zarfı, bir hatanın nerede yakalanması gerektiğini sormanın bir yolu olarak görmek de yardımcı olur. Bir iade yanlış siparişe gittiye, yani bir F2 (yanlış tool ya da yanlış argümanlar) hatasıysa, Öneri parçası modelin yanlış önerdiğini söyler, ama Gate parçası "sipariş bu run'ın müşterisine ait" ön koşulunun neden kodda denetlenmediğini sorar. İlk cevap bir olgu; ikincisi bir tasarım sorusu ve bir mühendisin düzeltebileceği olan ikincisi.

Karar hakları

Parçalar adlandırıldıktan sonra bir tasarım sorusu somutlaşır: agent'ın işinin içerdiği her karar için, onu verme hakkı kimde? "Karar vermek" sözcüğü burada dikkatle kullanılıyor. Model önerir. Kod, bir önerinin başına ne geleceğine karar verir. İnsan, kodun tek başına karar vermesine izin verilmeyen şeye karar verir.

Bir **karar hakları** tablosu bunu açık kılar. Sonraki iki tablo, Parcelport'un iki agent'ının hedef durumu için örnek niteliğinde; nasıl başlayacağını gösteriyorlar ve farklı toleransları olan bir ekip bazı satırları kaydıracaktır.

support-agent için:

Karar	Model önerir	Kod karar verir	İnsan karar verir
Ticket'ın hangi siparişe ilgili olduğu	E-postadan aday sipariş id'si	O siparişin bu müşteriye ve run'a ait olup olmadığı	Hiçbir şey; eşleşme belirsiz olup run yükseltirse o hariç
Hasar iddiasının makul olup olmadığı	Ticket metninin bir okuması	Hiçbir şey; bu, modelin girdi olarak sağladığı bir yargı	Sam, review'a gönderilen her vakada
İade tutarı	Bir rakam ve bir reason code	İade edilebilir bakiye, para birimi ve tavan	Sam, <code>refund_ceiling</code> üzerinde
Bir adresin değişip değişmeyeceği	Yeni bir adres değeri	Kolinin bir kargo firmasına ulaşip ulaşmadığı	Hiçbir şey; gönderi kuralı koddur
Yanıtın ifadesi	Bir taslak	Hangi iddiaların tool sonuçlarına dayandığı; yanıtın gönderilip gönderilemeyeceği	Sam, politikanın review için işaretlediği yanıtlarda
Ne zaman durulacağı	Belki bir nihai yanıt	İterasyon, süre ve harcama limitleri; hand-off	Sam, hand-off'ta

ops-agent için:

Karar	Model önerir	Kod karar verir	İnsan karar verir
Hangi log'lara ve metric'lere bakılacağı	Bir sorgu	Zaman aralığı, boyut ve erişim kapsamı	Hiçbir şey

Karar	Model önerir	Kod karar verir	İnsan karar verir
Bir tanımlama betiğinin ne yaptığı	Bir betik ya da parametreleri	Sandbox'ın neye erişebildiği: network egress yok, credential yok	Hiçbir şey
Olası nedenin ne olduğu	Bir teşhis	Hiçbir şey; bu, kanıtıyla birlikte tutulan bir öneri	Robin, onu okuyan kişi
Rollback yapılıp yapılmayacağı ya da bir flag'in çevrilip çevrilmeyeceği	Önerilen bir eylem	Eylemin izinli olup olmadığı ve eşiklerin karşılanıp karşılanmadığı	Robin, her zaman, çünkü politika onay gerektiriyor
Bir pull request açılıp açılmayacağı	Bir değişiklik	Hedef repository'nin izinli olması	Review eden ve merge eden bir kişi

İki şey öne çıkıyor. Birincisi, modelin katkısının yargının kendisi olduğu ("iddia makul mü", "neden ne") ve kodun katkısının onu sorgulamak yerine kanıtıyla birlikte bir insana taşımak olduğu satırlar var. Model, kodun belirleyemeyeceği iş kısmını ele aldığı için yararlı. Mimari o kısmı ortadan kaldırmaz; o kısmın neye ulaşabileceğini sınırlar.

İkincisi, kodun karar verdiği satırların tutarları, izinleri, eşikleri ve zamanı içeren satırlar olması. Bunlar hesaplanabilir ve denetlenebilir ve bir hatanın pahalı olduğu satırlar. Bölüm 4 bu çizgiyi çizmenin ölçütlerini geliştiriyor (geri alınabilirlik, doğrulanabilirlik, sıklık, tolerans ve açıklanabilirlik). Şimdilik örüntüye dikkat edilmeli: model, kodun zaten sınırladığı bir alan içinde seçim yapar.

Tablo ne veriyor

Bir karar hakları tablosu, büyük kullanımları olan küçük bir artefaktır. Bir reviewer'a, birkaç satırda, bir hatanın nerede yakalanacağını söyler. Yeni bir mühendise prompt'a neyi koymaması gerektiğini söyler. Ve anlaşmazlığı somut kılar: biri tavan denetimini "esneklik için" prompt'a taşımayı önerdiğinde, tablo neyin takas edildiğini gösterir: her çağrıda tutan bir denetim, model uyduğunda tutan bir denetimle takas ediliyor.

Boşlukları da bulur. "Kod karar verir" hücresi boş ve "insan karar verir" hücresi de boş olan bir satır, modelin tek başına verdiği bir karardır. Bazen bu kabul edilebilir, çünkü review edilmeden önceki bir taslağın ifadesi bir

para hareketi değildir. Ama bu, birinin verdiği bir karar olmalı, bir ihmal değil.

Mimari seçenekler

Her problem bir agent döngüsüne ihtiyaç duymaz ve ilk mimari karar, bunun ne kadarının kurulacağıdır. Dört yaygın biçim var. İşin akışını kimin kontrol ettiği ve dolayısıyla kontrol zarfının kapsaması gereken yüzeyin ne kadar büyük olduğu bakımından ayrışıyorlar.

Biçim	Akışı kim kontrol ediyor	Model ne yapıyor	Kontrol yüzeyi	Çoğu zaman yeterli olduğu durum
Tek step'lik çağrı	Kod	Veri olarak kullanılan tek bir öneri	Doğrulanacak tek bir öneri	Görev bir dönüşüm olduğunda: sınıflandırma, çıkarım, özetleme, taslak
Workflow	Kod, sabit step'lerle	Bir step içinde doldurur ya da seçer	Step başına bir öneri; sıra söz konusu değil	Step'ler önceden biliniyor ve yalnızca içerikte değişiyor
Tool kullanan döngü	Orchestrator, önerilerle yönlendirilen	Sıradaki tool'u ve argümanları seçer	Her tool, her argüman, step sayısı, bütün yol	Step'ler önceki step'lerin bulduklarına bağlı
Birden çok agent	Aralarında iş aktaran birkaç döngü	Her döngü kendi rolü içinde önerir	Her döngünün yüzeyi, artı döngüler arasındaki her hand-off	İş, farklı tool'ları, izinleri ya da bağlamları olan parçalara bölünüyor

Tek step'lik çağrı

En basit biçim tek bir çağrıdır: kod bağlamı derler, model bir öneri döndürür, kod onu doğrular ve kullanır. Bir ticket'ın konusunu sınıflandırmak bir örnek. Kontrol yüzeyi küçük: çıktı bir schema'ya uymalı, bu F1'i (bozuk çıktı) yakalar, değer kapalı bir kümeden biri olmalı ve sonra ne olacağına kod karar verir. Sınıflandırma yanlışsa, zarar kodun bir sınıflandırmayla ne yaptığıyla sınırlıdır.

Workflow

Workflow, sırayı kodun sürdüğü ve modelin step'leri doldurduğu bir tasarımdır. Örneğin: kod siparişi sorgular, kod modelden siparişin alanlarından bir yanıt taslağı yazmasını ister, kod taslaktaki her iddianın bir alana karşılık geldiğini denetler, kod gönderir. Yol sabittir. Model sonra ne olacağını asla seçmez; yalnızca bir yuva için içerik üretir.

Workflow'lar hafife alınır. Yol test edilebilir, sınırlar önemsizdir (step sayısı düğüm sayısıdır) ve modelin yolu yönlendirmesine bağlı hatalar, yanlış tool F2 ve kontrolden çıkan F5, çoğunlukla ortadan kalkar. Yanlış argümanlar (F2) ve bayat bağlam (F5) kalkmaz, çünkü model yuvaları yine bağlamdan dolduruyor. Ödenen şey esneklik: bir workflow yazarının düşündüğü vakaları ele alır ve bir ticket'ı öngörülmemiş bir dala kadar izleyemez.

Tool kullanan döngü

Bir **tool kullanan döngüde** model sıradaki tool'u çağırmaı önerir, sonucu görür ve bir nihai yanıt önerene ya da bir sınır durdurana kadar yeniden önerir. Kitabın çoğunu bu biçim oluşturuyor, çünkü en büyük yüzeye sahip ve en çok kontrole ihtiyaç duyuyor. Yol, önceki step'lerin bulduklarına bağlı olduğunda, bir soruşturmada olduğu gibi, bu maliyeti hak ediyor: ops agent'i, sıradaki yararlı step'in bir log sorgusu mu, bir metric mi, bir trace mi olduğunu, bir öncekini görene kadar bilmiyor.

Dokuz hata sınıfının hepsinin olabileceği yer döngüdür. Döngüye bir gate, bir sınır ve bir kayıt verilmesinin nedeni bu ve bir workflow'un yeteceği yerde bir döngü kurmayacak olmamın nedeni de.

Birden çok agent

Birden çok agent ile birkaç döngü birbirine iş aktarır: biri bilgi toplar, diğeri taslak yazar, üçüncüsü review eder. Motivasyon genellikle gerçektir. İşin farklı parçaları farklı tool'lara, farklı izinlere ya da farklı bağlama ihtiyaç duyar ve bölmek her döngünün yüzeyini dar tutar.

Maliyet, kontrol yüzeylerinin sayısının agent sayısından hızlı büyümesi. Her döngünün kendi gate'i var. Her hand-off, bağlamın derlendiği ve bir talimatın veriden sonraki agent'ın girdisine geçebileceği yeni bir yer: F4 (talimat ele geçirme). Her hand-off aynı zamanda state'in

bayatlayabileceği (F5) ve kısmi bir hatanın fark edilmeden kalabileceği bir yer: F6 (sessiz kısmi hata). Bölünürse, bir agent'tan diğerine giden mesaj güvenilir bir kaynaktan gelen bir öneri olarak ele alınmalı ve üzerine bir gate konmalı. Bir agent'ın çıktısına "bizim agent'ımız" diye güvenen bir tasarım, güven sınırını sistemin ortasına taşıyan bir tasarımdır.

Birden çok agent'lı bir tasarımın yanlış olduğunu iddia etmiyorum. Onun, ihtiyaç duyulan bir sınırla (bir izin sınırı, bir bağlam sınırı) gerekçelendirilmesi gerektiğini, diyagramın düzenli görünmesiyle değil, iddia ediyorum.

En az agency ilkesi

Bu, her şeyden önce uygulayacağım kurala götürüyor: **sorunu çözen en az agency'yi kullanmak gerekir**. Burada agency, modelin akışın ne kadarını yönlendirebildiği demek. Bir görev tek bir çağrıyla çözülüyorsa workflow kurulmaz; bir workflow çözüyorsa döngü kurulmaz; bir döngü çözüyorsa birkaç tane kurulmaz.

Tabloda her yukarı adım, altı parçanın kapsamı gereken yüzeyi genişletir. Her biri ayrıca kontrol akışının bir parçasını satır satır test edilebilecek koddan yalnızca istatistiksel olarak değerlendirilebilecek bir öneriye taşır. Görev buna ihtiyaç duyduğunda bu iyi bir takas, duymadığında kötü bir takas.

Kısa bir test yardımcı olur. Bir biçime karar vermeden önce görevi bir akış şeması olarak yazmak gerekir.

```
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
```

Denetimlerin sırası mesele. Uyan en ucuz biçim önce denenir ve döngü, yol listelenemediğinde ulaşılan şeydir. Bir görev için akış şeması çizilemiyorsa ve yolun neden değiştiği söylenemiyorsa, sorun mimari değil; görevin henüz anlaşılmamış olması.


Parcelport'un durumunda cevap göreve göre değişiyor. Gelen bir ticket'ın konusunu sınıflandırmak tek bir çağrı. Sipariş durumu bilindiğinde bir "kolim nerede" yanıtı taslağı yazmak bir workflow: sorgula, taslak yaz, denetle, gönder. Bir hasar iddiasını baştan sona, bir sorgu, olası bir adres denetimi, olası bir iade ve bir yanıtla ele almak bir döngü, çünkü hangi step'lerin gerektiği siparişin gösterdiğine bağlı. Bir gecikme alarımını soruşturmak, daha büyük bir tool kümesi ve daha uzun bir yolla, bir döngü. Bu durumdaki bir ekip çoğu zaman birkaç workflow'la, bir ya da iki döngüyle ve hiç birden çok agent'lı bir tasarım olmadan bitirir ve bu, çekingen değil, iyi bir sonuçtur.

Parcelport: prototipten parçalara

Şimdi prototipten hedefe geçişin, sonraki kontrollerin hiçbiri olmadan, yalnızca mimari açısından neye benzediğini anlatabiliriz.

Prototipte agent sistemin kendisi: bir prompt, bir token, modelin sahip olduğu bir döngü. Hedefte parçaların ayrı sahipleri var. Platform ekibi, döngüyü çalıştıran ve kaydı yazan orchestrator'ın sahibi. Model gateway, bütçeler ve rate limit'lerle birlikte model sağlayıcı credential'larının sahibi, böylece agent onları asla elinde tutmaz. Politika motoru ve tool gateway gate'i oluşturur. Onay servisi bekleyen bir eylemi Sam'in ya da Robin'in önüne koyar ve tam olarak o çağrıya bağlı bir onay döndürür. Run store state'i tutar. Trace pipeline'ı span'leri toplar.

Sonraki diyagram her bileşenin nerede durduğunu ve hangi zarf parçasına hizmet ettiğini gösteriyor. Orchestrator'ın neyle konuştuğuna (model gateway ve tool gateway) ve yalnızca tool gateway'in servislere ve store'lara ulaştığı gerçeğine bakılır.



Bu resmin iki özelliği, minyatür hâlde mimari. Orchestrator hem model gateway'le hem gate'le konuşan tek bileşen, yani döngünün yaşadığı yer. Gate karar verir, orchestrator `effect.apply`'ı başlatır ve tool gateway credential'ı ekler, servisi çağırır ve sonucu kendi üzerinden döndürür. Bir servis için hiçbir credential modelin içinden geçmez ve tool gateway dışında hiçbir servise ulaşılmaz. Bir öneri gate'ten hiç geçmezse, hiç credential almaz.

Resmin ne söylemediğine de dikkat edilmeli. Modelin içinde iyi ya da kötü olduğunu söylemiyor. Tasarımın ikisinden de sağ çıktığını söylüyor.

Önce ne değişir

Prototip bana bir pazartesi verilseydi ve gerçek ticket'larda çalışacak kadar sınırlı hâle getirmem söylenseydi, altı parçanın hepsini kurarak başlamazdım. En çok hareket alanı veren en ucuz değişikliklerle başlardım.

Birincisi, döngü bir iterasyon limiti ve bir timeout'la bir orchestrator'a konur; böylece çıkışın sahibi artık model olmaz. İkincisi, ilk kayıt kaba olsa bile her step'in önerisi ve sonucu yazılır. Üçüncüsü, tavan ve "bu müşteriye ait" denetimi prompt'tan çıkarılıp `issue_refund`'ın önündeki bir gate'e taşınır. Dördüncüsü, geniş token tool gateway'in tek bir çağrı için eklediği bir credential ile değiştirilir. Bu dördünden sonra prototip hâlâ bir prototip, ama sonraki bölümlerin her birinin tutunacağı bir yer var.

Bu sıra bir görüş ve değişkenler ekibin: agent'ın neye ulaşabildiği, bir step boşa gittiğinde ne kadara mal olduğu ve bir limit neredeyse bitmiş bir görevi durdurduğunda kime alarm gönderildiği.

Kitabın haritası

Kitabın geri kalanı altı parçayı bir ekibin genellikle ihtiyaç duyduğu sırayla kuruyor. Kısım I (Bölüm 1'den 4'e) temeli atıyor: bu bölüm bütünü çiziyor, Bölüm 2 modelin çıktısını bir öneri olarak ele alıyor, Bölüm 3 hata sınıflarını adlandırıyor ve Bölüm 4 modelin neyi önerdiği ile kodun neye karar verdiği arasındaki çizgiyi çiziyor. Kısım II tool'ları ve yetkiyi (Bölüm 5'ten 8'e), Kısım III bağlamı, state'i ve belleği (Bölüm 9'dan 11'e), Kısım IV kontrol döngülerini (Bölüm 12'den 15'e), Kısım V güvenlik sınırlarını (Bölüm 16'dan 19'a) ve Kısım VI kanıtlamayı ve işletmeyi (Bölüm 20'den 24'e) kapsıyor. Belirli bir problemi bulmak için yukarıdaki kontrol zarfı tablosu kullanılır; sıfırdan kurmak için sıra izlenir, bu sıra kabaca bir prototipin nasıl büyüdüğünü izliyor.

Trade-off'lar ve maliyetler

Agent'ı parçalara ayırmak bedava değil ve maliyet birkaç kişiye düşüyor.

Mühendislik zamanına ve ayakta tutulacak yeni bir şeye mal olur. Bir orchestrator, bir gate ve bir kayıt, birinin sahip olduğu ve testlere, deploy'lara ve on-call'a ihtiyaç duyan servisler, ya da en azından kütüphanelerdir. Gate her etkinin yolunda olduğundan, availability'si agent'ın availability'si olur. Düşük riskli bir ortamda tek agent'ı olan üç kişilik bir ekip, her parçanın daha ince bir sürümünü makul biçimde yayına alabilir ve daha fazla riski açık gözle kabul eder.

Gecikmeye mal olur. Her öneri doğrulamadan, her çağrı gate'ten ve bazıları bir insandan geçer. Diyelim ki bir gate denetimi her step'e küçük sabit bir gecikme ekliyor; 12 step'lik bir run'da bu, kullanıcının hissedebileceği bir gecikme. Maliyet, geri alınamayan etkiler için ödemeye değer. Okumalar için gerekçelendirmek daha zor. En ağır denetimleri geri alınamaz yazmalara ve dış yan etkilere koyardım ve okuma yollarını hafif tutardım.

Demoya mal olur. Açılıştaki prototip, tam da hiçbir şey önüne çıkmadığı için hızlı ve etkileyiciydi. Tasarlanmış bir sistem çağrılarını reddeder, onayı bekler ve sınırlarda durur ve bu davranışların bazıları sistemin daha kötü olması gibi görünür. Demoyu görmüş paydaşlar gerçeğinin neden daha yavaş ve daha temkinli olduğunu soracak. Dürüst cevap, demonun iyi bir günde çalıştığı.

Yeni bir tür review'a mal olur. On-call artık bir run'ın ne yaptığını ve gate'in neden reddettiğini öğrenmek için bir kaydı okumak zorunda. Sam bir onay isteğini okumak ve makul bir sürede karar vermek zorunda. İstekler belirsizse ya da çok sık geliyorsa, onay gösteriye dönüşür: her zaman saniyeler içinde verilir ve hiçbir şeyi korumaz. Karar hakları tablosu, hangi onayların bir insanın dikkatine değdiğini söyleyerek yardımcı olur ve Bölüm 15 buna dönüyor.

Esnekliğe bilerek mal olur. Bir gate, modelin doğru yapmış olabileceği önerileri reddeder. Doğru olacak olan reddedilmiş bir iade, gerçek bir müşteri ve gerçek bir destek lideri tarafından ödenen gerçek bir maliyettir. Tasarım, sınırlı yanlış izinler karşılığında yanlış retleri kabul eder ve doğru denge, yanlış bir etkinin yanlış bir retten ne kadar pahalı olduğuna bağlı bir ayar sorusudur. Belirli bir sistem için o dengeyi bilmiyorum ve ancak production'daki retler izlenerek bulunur.

Bunu ne zaman kullanmamalı

Tek bir çağrı ya da bir workflow'un çözdüğü bir görev için zarfın tamamı kurulmaz. Bugün hassas hiçbir şey açığa çıkarmayan bir tool için bile, okumaların önündeki gate'i atlamak yerine ince tutmak gerekir (schema, allowlist, sahiplik); maliyet küçük ve tool öyle kalmayacak. Ve altı parçalı sözcük dağarcığı tatmin edilecek bir kontrol listesi olarak benimsenmez; bir hatanın nerede yakalanacağını sormanın bir yolu. Sorunun cevabı bir karta sığıyorsa, tasarım karttır.

Sık yapılan hatalar

Bunlar tasarım tuzakları. Her biri seçildiği gün makul.

- **"Agent"ı tek bir şey olarak ele almak.** Cazip, çünkü sözcük kullanışlı ve prototip tek bir dosya. Maliyeti, kontrollerin adresinin olmaması. Düzeltmek için model, orchestrator, tool'lar, gate ve kayıt tasarımı ve

kodda ayrı ayrı adlandırılır; böylece bir review bir değişikliğin hangisine dokunduğunu söyleyebilir.

- **Döngünün çıkışını modelin sahiplenmesine izin vermek.** Cazip, çünkü "iş bitince dur" doğal davranış. Yalnızca model tool istemeyi bıraktığında biten bir döngü, model öyle dediğinde biter ve bu kontrol edilebilen bir çıkış değil. Orchestrator'ın dayattığı bir sınırla ve tetiklendiğinde bir hand-off ile düzeltilir.
- **Bir kuralı prompt'a koyup ona kontrol demek.** Cazip, çünkü demoda çalışıyor ve deploy etmek hiçbir şeye mal olmuyor. Prompt ihlal oranını düşürür, ama hiçbirini garanti etmez. Düzeltmek için prompt'taki her kural için onu dayatan kod adlandırılır ve hiç olmadığı yere "henüz kontrol yok" yazılır.
- **Tasarımı düzenlemek için birden çok agent'a uzanmak.** Cazip, çünkü roller kutulara düzgünce oturuyor. Maliyeti daha fazla gate, daha fazla hand-off ve state'in bayatlayacağı daha fazla yer. Bir döngüyü bölmeden önce bir sınır (bir izin ya da bağlam sınırı) şart koşarak düzeltilir.
- **Sistemin içinde bir agent'ın çıktısına güvenmek.** Cazip, çünkü "bizimki". Ama bir müşteri e-postasını okumuş bir agent'tan gelen mesaj, e-postanın etkisini de beraberinde taşıyabilir. Agent'lar arası mesajları bir gate'ten geçen öneriler olarak ele alarak düzeltilir.
- **Agent'ın ne yaptığını bilmeden tam zarfı kurmak.** Cazip, çünkü liste uzun ve parçalar ilginç. Maliyeti, bir workflow'un çözeceği bir görev için ağır bir tasarım. Yukarıdaki biçim testiyle ve dört ucuz değişiklikte başlayarak düzeltilir.
- **Review'larda sözcük dağarcığını gevşek kullanmak.** Cazip, çünkü sözcükler tanıdık geliyor. "Agent kötü bir iade yaptı", hiçbir şey yapmamış bir bileşeni suçlar; tasarım bir önerinin tavan denetimi olmadan iade tool'una ulaşmasına izin verdi. Hatayı yakalaması gereken zarf parçasını adlandırarak düzeltilir. Bunun için taksonomiye Bölüm 3 veriyor.

Uyarı: İlk hatanın en pahalı sürümü, tek bir geniş token tutan bir agent'tır. Gate'in denetleyeceği her şey o zaman erişilemez olur, çünkü credential çağrıyla zaten izin veriyor. Token, agent'ın konfigürasyonu olarak değil, gate'in işinin bir parçası olarak ele alınmalı (Bölüm 7).

Temel çıkarımlar

- Agent, bir orchestrator döngüsünden, bir modelden, bir gate'ten ve tool'lardan oluşan bir bileşendir; model onun bir parçasıdır ve her şeye "model" demek kontrolleri adresiz bırakır.
- Model bir öneri üreticisidir: döndürdüğü her şey gate izin verene kadar güvenilmez girdidir ve döndürdüğü hiçbir şey kendi başına bir şeyi değiştirmez.
- Tez, AI agent'ların güvenilir kontrol sistemlerinin içinde çalışan güvenilmez karar vericiler olarak tasarlanması gerektiğidir ve kontrol sistemi sıradan mühendisliktir: schema'lar, state machine'ler, izinler, bütçeler, timeout'lar, queue'lar, log'lar ve testler.
- Kontrol zarfının altı parçası var, Bağlam, Öneri, Gate, Etki, Sınır ve Kayıt, ve her parça birinin sahip olup test edebileceği bir soruyu cevaplıyor.
- Bir karar hakları tablosu hangi kararları modelin önerdiğini, hangilerine kodun, hangilerine bir insanın karar verdiğini gösterir; kimsenin karar vermediği satırlar kapatılacak boşluklar ya da gerekçelendirilecek ihmallerdir.
- Sorunu çözen en az agency seçilir: bir tek çağrı, sonra bir workflow, sonra bir döngü, sonra birden çok agent, çünkü her adım kontrol zarfının kapsamı gereken yüzeyi genişletir.
- Prompt bir kontrol değildir: kötü önerilerin oranını düşürür ve her çağrıda tutması istenen her özellik, model yanıtladıktan sonra çalışan koda aittir.

Parçalar artık adlandırıldı ve tez masada, ama bir gate modelin çıktısına belli bir türden şüpheyle yaklaşmak zorunda ve bu şüphenin bir nedene ihtiyacı var. Bölüm 2 onu sağlıyor: bir modelin çıktısında neyin belirsiz

olduđu, hangi sinyallere g venmeye deęer olduđu ve bu belirsizlięin kodun verebileceęi bir karara nasıl  evrileceęi.

Bölüm 2 — Model Belirsizliği

Parcelport'ta sıradan bir çarşamba günü bir müşterinin yazıp kolisinin nerede olduğunu sorduğunu düşünelim. Destek agent'ı, yapılma amacına uygun davranıyor: `ord-7f3k2m91` için `lookup_order`'ı çağırıyor, "kargoya teslim edildi" durumunu alıyor ve bir yanıt taslağı hazırlıyor. Taslak kibar, açık ve kolinin perşembe günü ulaşacağını söyleyen bir cümleyle bitiyor. Hiçbir tool sonucunda teslimat tarihi yok. Destek lideri Sam, rutin bir review sırasında bunu fark ediyor ve platform ekibinden Alex'e ne olduğunu soruyor.

Alex ticket'ı staging'de aynı e-posta ve aynı tool sonucuyla yeniden oynatıyor. Yeni taslak, kolinin "önümüzdeki birkaç gün içinde ulaşması gerektiğini" söylüyor. Üçüncü oynatma, hiçbir tarih vermeyen ve yarın yeniden bakmayı öneren bir taslak üretiyor. Yanlış yapılandırılmış bir şey yok. Üç run arasında hiçbir şey değişmedi ve üç taslak, bir müşterinin buna göre davranacağı bir konuda birbiriyle çelişiyor.

Bir hafta sonra platform ekibi, planlandığı gibi gateway'i daha yeni bir modele geçiriyor ve taslaklar yine değişiyor. Kimi yönlerden daha iyi, kimi yönlerden daha kötü; hangi ticket'ların değiştiğini de önceden kimse söyleyemiyor. Ekibin önünde artık "daha iyi bir prompt yaz"ın cevaplamadığı bir soru var: aynı çağrılar arasında çıktısı değişen, aynı anda hem akıcı hem yanlış olabilen ve başkası modeli değiştirdiğinde değişen bir bileşenin üzerine nasıl bir şey inşa edilir?

Bu bölüm, kontrol zarfının **Öneri** parçasına ait. Cevapladığı soru parçasının kendi sorusu: model ne önerdi ve bu öneri, aksi kanıtlanana kadar güvenilir girdi olarak mı ele alınıyor? Bölüm 1 parçayı adlandırdı. Bu bölüm cevabın neden "güvenilmez" olması gerektiğini ve bunu kabul ettikten sonra neyin ölçülüp neyin inşa edilebileceğini açıklıyor.

Sorun ve neden zor olduđu

Öneri, modelin döndürdüğü şeydir: bir tool çağrısı, bir plan ya da bir nihai yanıt. Bağlamın olası devamları üzerindeki bir dağılımdan örnekleme yapan bir süreç tarafından üretilir. Bu sürecin beş özelliđi, kontrol tasarlayan biri için önemlidir. Hiçbiri bir sonraki sürümde düzeltilecek bir kusur deđil; bileşenin biçiminin kendisi.

Beş özellik

Olasılıksal üretim. Aynı bağlam farklı öneriler verebilir. Örnekleme, bu bileşenlerin metin üretme biçiminin bilinçli bir parçasıdır ve azaltıldığı yerde bile modelin çevresindeki dağıtım (batching, donanım, sabit bir adın arkasında değiştirilmiş bir model) byte düzeyinde aynı çıktıyı vaat etmez. Pratik sonuç, tek bir başarılı run'ın pek az şey kanıtlamasıdır. Bir kez gözlemlenen davranış, olabilecek bir davranıştır; olacak bir davranış deđil.

Bağlama duyarlılık. Aynı istek farklı bir bağlamda farklı bir öneri doğurabilir. Bir müşteri iade istiyor; sipariş durumu bağlamın en üstündeyken öneri bir şey oluyor, üstünde uzun bir e-posta zinciri varken başka bir şey, aynı olgular farklı sırada dizildiğinde üçüncü bir şey. Değişikliğin olgularda olması gerekmez. Sıralama, uzunluk, ifade biçimi, fazladan bir tool sonucu ve alıntılanmış bir e-postadaki başıboş bir cümle, çıktıyı kaydırır. Bölüm 9'un bağlam derlemeyi süs olarak deđil mühendislik olarak ele almasının nedeni bu.

Akıcı yanlışlık. Yanlış bir öneri yanlış olarak işaretlenmez. Dayanaksız bir iddia (F3), dayanaklı bir iddiayla birebir aynı okunur, çünkü ikisi de aynı şekilde üretilir. Açılış senaryosundaki teslimat tarihi, bir tool sonucundan kopyalanmış bir tarihle aynı tona, dilbilgisine ve kesinliğe sahipti. "Kulađa tuhaf geliyor mu" diye göz gezdiren bir reviewer bunu bulamaz, çünkü burada hata tuhaf görünmekle ortaya çıkmaz.

Kısmi talimat izleme. Bağlamdaki bir talimat, yasakladığı ya da gerektirdiđi davranışın oranını düşürür. Oranı sıfıra indirmede ve oran, bağlamın geri kalanına göre deđişir. "Teslimat tarihi vaat etme", sistem politikasında makul bir satırdır ve çođu zaman işe yarar. Bu türden

kurallar birer ricadır ve kitabın tutumu, hiçbir güvenilirlik özelliğinin yalnızca bir ricaya dayanmaması yönündedir. Özelliğin önemli olduğu yerde, model yanıt verdikten sonra çalışan bir kontrol onu taşımalıdır.

Modelle birlikte kayma. Model değiştiğinde davranış da kayar ve model, kod değişmeden değişebilir: bir sağlayıcı bir adın arkasındaki şeyi günceller, platform tarafındaki bir ekip gateway'in varsayılanını değiştirir, bir kesinti sırasında bir fallback model devreye girer. Aynı ticket, aynı prompt ve aynı tool'lar ertesi gün farklı bir öneri dağılımı verebilir. Modellerden uzun yaşayan bir kitapta sürüme özgü iddialara yer yoktur ve gerek de yoktur: tasarım sorusu, dağılım kaydığında sistemin ne yaptığıdır.

Neden bir mühendislik sorusu

Cazip tepki, gözlenen her hatayı bir prompt sorunu saymaktır. Bir cümle eklenir, bir örnek eklenir, büyük harfle bir uyarı eklenir. Bu boşa çaba değildir, çünkü belirli bir önerinin oranını düşürebilir. Ama oran, bakılan vakalar üzerinden ölçülür ve bir sonraki ticket onlardan biri değildir. Yeniden oynatılan üç taslakta işe yarayan bir düzeltme, sonraki dört yüz ticket hakkında pek az şey söyler.

Mühendislik tepkisi başka bir yerden başlar. Bileşenin bazen yanlış olacağını varsayar, sistemin o günlerde ne yaptığını sorar ve cevabı, örneklemeyele değişmeyen kodun bir özelliği yapar. Bunu başka yerlerde zaten yapıyoruz. Bir servisi ağ üzerinden çağıran başka bir servis, ötekinin her zaman cevap vereceğine güvenmez; bir dosya okuyan servis de baytların düzgün biçimlendiğine güvenmez. Doğrular, sınırlar, limitle retry eder ve kaydeder. Kontrol edilmeyen bir bileşenden gelen girdi güvenilmez girdidir ve modelin önerisi de budur.

Bunu görmezden gelmenin bedeli aynı anda birkaç hata sınıfında ortaya çıkar; bu bölümün onların arasında durmasının nedeni de bu: F1 (bozuk çıktı), F2 (yanlış tool ya da yanlış argümanlar) ve F3 (dayanaksız iddia) hepsi öneri olarak başlar. Bölüm 3 bunları ayrıntılı tanımlıyor. Burada yalnızca, bunların aynı temel olgunun farklı biçimleri olduğu fikrine ihtiyacımız var.

Dört tür belirsizlik

"Model yanlış olabilir" tasarım yapmak için fazla kaba. Bir tasarımın, yanlışın nasıl olabileceğini bilmesi gerekir, çünkü en ucuz dedektör her yol için farklıdır. Dört tür kullanıyorum.

Tür	Ne ters gider	Tipik sınıf	En ucuz dedektör
Biçim	Öneri parse edilmiyor ya da yapıyla uyumuyor	F1	Schema doğrulama
İçerik	Yapı doğru; bir olgu ya da bir argüman değeri yanlış	F3, F2	Doğruluk kaynağıyla çapraz kontrol
Niyet	Öneri yanlış eylemi istiyor	F2	Gate'te ön koşullar ve politika
Eksiklik	Olması gereken bir adım ya da ifade yok	tek başına hiçbir	Bütünlük üzerinde deterministik kontroller

Biçim

Biçim belirsizliği, türlerin en zararsızıdır. Argümanları sözleşmeye uygun olmayan bir tool çağrısı, parse edilemeyen bir öneridir ve parse etmek deterministiktir. Destek agent'ının `issue_refund`'ı, `amount_minor`'ı "twelve fifty" dizesi olarak ya da numaralandırmada bulunmayan bir `reason_code` ile önerdiğini varsayalım. Gate'in schema kontrolü, başka bir şey olmadan önce bunu reddeder.

Biçim hatalarını tespit etmek ucuzdur ve yapı basit olduğunda yeterince seyrektir; bu yüzden ekipler bunları ele almaya az yatırım yapar. Yaygın tasarım hatası, bir parse hatasını run'ı bitiren bir istisna saymak ya da daha kötüsü, ne kastedildiğini tahmin ederek öneriyi sessizce onarmaktır. Tahminle onarım, bir biçim hatasını içerik hatasına çevirir, çünkü onarılan değeri hiçbir şey önermemiştir. Bölüm 5 tool çağrılarının nasıl taşındığını ve parse edildiğini ele alıyor; burada önemli olan, biçimin, katı davranılabilecek tek tür olması ve katılığın neredeyse hiçbir şeye mal olmamasıdır.

İçerik

İçerik belirsizliği, tehlikeli ortadır. Yapı geçerlidir ve öneri yine de özünde yanlıştır. Parse edilen, gerçek bir siparişi adlandıran ve izin verilen bir reason code kullanan bir `issue_refund` çağrısı, yine de yanlış

`order_id`'yi (zincirdeki başka bir ticket'tan alınmış) ya da yanlış para birimini taşıyabilir. Bir yanıt iyi biçimlenmiş olabilir ve bağlamda bulunmayan bir tarihi vaat edebilir.

Burada tespit, karşılaştırılacak, modelin dışında bir şey gerektirir. Tool sonuçları, sipariş kaydı, politika ve ticket'ın kendisi eldeki kaynaklardır. Karşılaştırılacak kaynak yoksa dedektör de yoktur ve tasarımın riski kabul etmeye, modelin önerebileceklerini daraltmaya (Bölüm 4) ya da yola bir insan koymaya (Bölüm 15) karar vermesi gerekir. Bu boşluğu, "modele doğru olması talimatı verilmiştir" gibi bir cümlemin arkasına saklamak yerine bir tasarım review'unda kabul etmeyi tercih ederim.

Niyet

Niyet belirsizliği, önerinin iyi biçimlenmiş olduğu ve değerlerinin makul görüldüğü, ama eylemin kendisinin duruma göre yanlış olduğu anlamına gelir. Müşteri kolinin nerede olduğunu sordu ve model `update_shipping_address` önerdi. Ya da müşteri, kargo firması koliyi aldıktan sonra adres değişikliği istedi ve model iade önerdi; bu, başka bir soruna kulağa makul gelen bir cevaptır.

Niyet hataları, state'e bağlı ön koşullarla yakalanır: gönderi zaten kargo firmasında, bu yüzden gate adres değişikliğini reddeder. Gate doğal yerdir, çünkü state'i ve politikayı elinde tutar; Bölüm 6, bir tool sözleşmesinin ön koşulları kontrol doğaçlama olmasın diye nasıl belirttiğini gösteriyor. Bir ön koşul, modelin bunun yerine bir soru sorması gerektiğini söyleyemez. Bunun için eldeki tool'ların nasıl tasarlandığına ve modelin önerdiği şey ile kodun karar verdiği şey arasındaki sınırın nerede durduğuna dayanılır; bu da Bölüm 4'ün konusudur.

Eksiklik

Eksiklik, görülmesi en zor türdür, çünkü kanıt bir yokluktur. Model olması gereken bir adımı atladı: siparişin teslim edildiğini kontrol etmeden bir iade onayı taslağı hazırladı ya da bir müşterinin ihtiyaç duyduğu tek cümleyi ("iadenin görünmesi birkaç gün sürer") dışarıda bıraktı. Önerideki hiçbir şey yanlış değil. Olması gereken bir şey yok.

Eksiklikler yalnızca bütünlüğün yazıya dökülebildiği yerde yakalanabilir. "Bir iadeyi onaylayan yanıt, iadenin tanımlayıcısına ve tool sonucundaki durumuna bir referans içermelidir" gibi bir kural denetlenebilir; "her

issue_refund, bu run'da aynı sipariş için başarılı bir lookup_order'dan önce gelmiş olmalıdır" da öyle. Bunun ötesindeki her şey, bu tür eksikliklerin oranını her birini yakalamak yerine bir golden set üzerinde ölçen eval'lerin (Bölüm 21) işidir. Bu ayrımı bilerek yapıyorum. Bir runtime kontrolü, bir koşul olarak ifade edilebilecek şeyi yakalar. Bir eval, geri kalanın ne sıklıkla olduğunu tahmin eder.

Modelin güveni neden bir kontrol sinyali değildir

Önerilerin yanlış olabileceğini kabul ettikten sonra ilk içgüdü, modele ne kadar emin olduğunu sormaktır. Kendi bildirdiği bir güven ("yüzde 90 eminim"), bir gate'in ihtiyaç duyacağı sinyal gibi hissettirir: eşğin üstünde kabul et, altında yükselt.

Bunun üzerine bir şey inşa etmezdim ve üç nedenim var.

Birincisi, ifadenin kendisinin bir öneri olmasıdır. Aynı süreç tarafından, aynı bağlamdan, yukarıdaki beş özelliğe aynı şekilde açık olarak üretilir. Bir teslimat tarihi konusunda akıcı biçimde yanlış olan bir model, bu konuda akıcı biçimde emin de olabilir. Sayı, ölçüm gibi görünen bir metin parçasıdır ve onu okuyan bir gate, bir öneriyi güvenilen bir girdiye terfi ettirmiştir.

İkincisi, bildirilen sayıyı bir sıklığa bağlayan hiçbir şeyin olmamasıdır. Bildirilen bir güvenin yararlı olması için "90"daki vakaların, bu sistemin ticket'larında, bu sistemin tool'larıyla, on kezden dokuzunda doğru olması ve bunun değişiklikler boyunca doğru tutulması gerekirdi. Bu, bir golden set üzerinde ölçülebilir (Bölüm 21) ve belirli bir model ve görev için kabaca geçerli çıkabilir. Ama bu, tek bir dağılım üzerinde tek bir modelin özelliğidir ve model değiştiği gün kayabilir. Ona göre ayarlanmış bir eşik, sessizce eski anlamını yitiren bir konfigürasyon değerine dönüşür.

Üçüncüsü, güvenin en çok ihtiyaç duyulan yerde en az bilgi veren şey olma eğiliminde olmasıdır. Bağlamın eksik ya da yanıltıcı olduğu vakalar, önerinin yanlış olma ihtimalinin yüksek olduğu ve modelin kendisi hakkındaki anlatısının en az dayanak bulduğu vakalardır. Kolay ticket'larda iyi, zor olanlarda kötü olan bir sinyal, hangi ticket'ların ikinci bir bakışı hak ettiğine karar vermeye yardım etmez.

Bu, modelin kendi metnini değersiz yapmaz. Bildirilen bir belirsizlik, bir ticket'ı bir insana yönlendirmek için makul bir ipucu olabilir, çünkü orada yanlış alarmin bedeli, bir insanın bir ticket okumasıdır. Ama geri alınamaz bir etkiye izin verilmesinin nedeni asla bu olmamalıdır. Kullanacağım kural şu: modelin bildirdiği bir sinyal sürtünme ekleyebilir (daha fazla kontrol, bir insan bakışı) ve asla sürtünmeyi kaldıramaz.

Kullanılabilecek sinyaller

Kullanılabilir sinyallerin ortak bir özelliği var: modelin kendisi hakkındaki anlatısından başka bir şey tarafından hesaplanırlar. Kabaca maliyet sırasıyla bunlar schema doğrulama, kaynaklara karşı çapraz kontroller, deterministik verifier'lar ve tutarlılık örneklemesidir.

Schema doğrulama

Her öneri, sahip olması gereken yapıya karşı kontrol edilir: tool çağrıları için tool sözleşmesinin girdi schema'sı, nihai yanıtlar için tanımlı bir şekil (orchestrator'ın beklediği alanlarla bir yanıt taslağı). Doğrulama, biçim belirsizliğini (F1) ve numaralandırmanın ihlal edilmesi ya da pozitif tam sayı olmayan bir tutar gibi bazı değer hatalarını yakalar. Deterministiktir, ucuzdur ve kapsadığı şey için eksiksizdir.

Kapsamadığı şey, sorunun daha büyük kısmıdır. Bir schema, bir `order_id`'nin bir dize olduğunu söyler. Dizenin bu müşteriye ait olduğunu söyleyemez. Schema doğrulama ilk gate olarak ele alınmalı, tek gate olarak değil.

Kaynaklara karşı çapraz kontrol

Önerinin öne sürdüğü, orchestrator'ın elinde tuttuğu bir kaynakla karşılaştırılır. Taslak "12,50 tutarındaki iadeniz yapıldı" diyorsa, `run store`'da o tutarda ve o para biriminde başarılı bir `issue_refund` sonucu bulunmalıdır. Taslak bir kargo firması adlandırıyorsa, `lookup_order` sonucu onu içermelidir. Bu, dayandırmanın işler hale getirilmiş biçimidir: her iddia, bağlamdaki ya da run'ın kaydedilmiş tool sonuçlarındaki bir öğeye bağlanmalıdır ve bağı olmayan bir iddia F3'tür.

Zayıf nokta çıkarmadır. İddiaları kontrol etmek için önce onların bulunması gerekir ve bunları serbest metinde bulmak, kodla (tarihler, tutarlar ve tanımlayıcılar için örüntüler) ya da ikinci bir model çağrısıyla (ki bu başka bir öneridir) yapılabilen bir görevdir. En önemli iddialar için kod yolunu tercih ederim, çünkü deterministiktir ve yüksek riskli iddia türlerinin kısa listesi küçüktür: tutarlar, tarihler, tanımlayıcılar, durumlar. Çıkarıcının parse edemediği her şey bir sonraki kontrole düşer.

Deterministik verifier'lar

Verifier, bir öneri hakkındaki evet-hayır sorusunu, modelin sağlamadığı veriyi kullanarak cevaplayan koddur. Bazıları basittir: iade tutarı en fazla iade edilebilir bakiye kadardır; siparişin gönderisi bir kargo firmasına teslim edilmemiştir; para birimi ödemeyle eşleşir. Bazıları yapısaldır: bir iadede söz eden yanıt, run'ın sonuçlarında bulunan bir tanımlayıcıya referans vermelidir.

Verifier'lar en güçlü sinyaldir, çünkü koddurlar. Sınırları kapsamdır: birinin her birini yazması ve politika değiştikçe bakımını yapması gerekir. Pragmatik yaklaşım, para harcatan ya da müşterilere ulaşan etkiler için verifier'larla başlamak ve uzun kuyruğu eval'lere bırakmaktır.

Tutarlılık örnekleme

Modele aynı soru birkaç kez sorulabilir ve cevaplar karşılaştırılabilir. Öneriler uyuyorsa, bu bağlamın cevabı sabitlediğine dair hafif bir kanıttır; uyumuyorsa, uyumsuzluğun kendisi bilgidir, çünkü önerinin örneklemeyle duyarlı olduğunu ve dolayısıyla bağlam tarafından iyi desteklenmediğini söyler. Modelin kendisi hakkındaki anlatısına güvenmeden modelden gelen tek sinyal budur.

Gerçek maliyetleri ve gerçek sınırları var. Her ek örnek başka bir model çağrısıdır; bu da kullanılan her ticket'ta harcama ve gecikme demektir (Bölüm 22 maliyet atfını ele alıyor). Uyuşma doğruluğu kanıtlamaz, çünkü örnekler aynı bağlamı ve aynı kör noktaları paylaşır; beş taslak aynı dayanaksız tarihte uyuyabilir. Serbest metin taslaklarını karşılaştırmak da bir karşılaştırma yöntemi gerektirir; bu da ya çıkarılan iddialar üzerinde deterministik bir kontrol ya da başka bir model çağrısıdır.

Seçici kullanılmalı. Destek agent'ının günde 200 ticket işlediğini ve küçük bir kesrin tavana yakın iadeler olduğunu varsayalım. Bunlarda üç kez örnekleme yapmak ve tutarlar ya da sipariş tanımlayıcıları farklı olduğunda yükseltmek, savunulabilir bir harcamadır. Her `lookup_order` çağrısını örnekleme değildir.

Örnekleme parametreleri ve kontrol tasarımı

Modeller, örneklemeyi şekillendiren ayarlar sunar. En sık karşılaşılan **temperature**'dir; örneklemenin en olası devamı ne kadar güçlü tercih ettiğini ölçekler: düşük değerler çıktıyı birkaç olası öneride yoğunlaştırır, yüksek değerler yayar.

Kontrol tasarımı için ilgili olgular dar. Düşük bir temperature, run'lar arasındaki değişimi azaltma eğilimindedir ve bu, eval'leri daha kararlı yapabilir ve bir davranışı yeniden üretmeyi kolaylaştırabilir. Çıktıyı doğru yapmaz. Düşük temperature'da bir tarih konusunda tutarlı biçimde yanlış olan bir model, tutarlı biçimde yanlıştır. Yukarıda verilen nedenlerle determinizmi de vaat etmez: batching, donanım ve adın arkasındaki model hep değişebilir. Aynı girdide aynı çıktıyı gerektiren bir tasarımın örnekleme sorunu yoktur; bir modelin karşılayamayacağı bir gereksinimi vardır ve gereksinimin koda taşınması gerekir.

Bu yüzden örnekleme ayarlarını eval'ler ve maliyet için bir ayar düğmesi olarak görüyorum; gateway'de ayarlanır, her run ile birlikte kaydedilir ve asla bir kontrol olarak görülmez. Değişimi azaltmak ekibin ölçmesine yardım eder; etkiyi sınırlayan gate'tir. Bundan pratik bir kural çıkar. Hangi ayar seçilirse seçilsin, her run'ın kaydına yazılmalı, çünkü davranıştaki sonraki bir değişimi, ayar bilindiğinde araştırmak çok daha kolaydır (Bölüm 20 kaydı ele alıyor).

Belirsizliği bir karara dönüştürmek

Bu bölümün tasarım hamlesi, her önerinin değerlendirmesini gate'in üç kararından birinde bitirmektir; karar deterministik kodla seçilir: `"allow"`, `"refuse"` ya da `"needs_approval"` (Bölüm 1). Değerlendirme, sistemin öneriyle ne yaptığını söyler. Model hakkında bir yargı değildir.

Karar	Değerlendirme orada bittiğinde	Sonra ne olur
"allow"	Her kontrol geçti ve politika bir kişiye ihtiyaç duymuyor	Etki ilerleyebilir
"refuse"	Bir kontrol başarısız oldu: schema, verifier, argüman bağlama ya da iddia kontrolü	Reason, gözlem olarak modele döner
"needs_approval"	Kontroller geçti ya da karar veremedi ve politika ya da riskler bir insan gerektiriyor	Bir kişi karar verir (Bölüm 15)

Doğrulama, bunların herhangi birinden önce gelen iştir: kontroller çalışır ve sonuçları kararı seçer. Bu bir adımdır, dördüncü bir sonuç değil.

Seçimin girdileri üçtür: validator'ların ve verifier'ların ne söylediği, önerilen eylemin etki sınıfı ve politikanın bu çağrı hakkında ne söylediği. Aşağıdaki taslak, destek agent'ı için gate'in Öneri tarafındaki parçasıdır. Açıklayıcıdır ve Bölüm 5'teki gate'in kısmi bir görünümüdür; sırasını ve reason adlarını ondan alır; kontroller adlandırılmıştır, uygulanmamıştır ve eşikler politikaya aittir.

```
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 }
```

Bu blok hakkında üç şey. Model bu bloğun hiçbir dalını görmez ve birine itiraz edemez. Allow olmayan her sonuç, kaydın yakaladığı deterministik bir şeyle biter. Ve sıra bilinçlidir: ucuz kontroller önce çalışır, onay reddedebilecek her kontrolden sonra gelir ve bir model çağrısına mal olan bir kontrol, kullanılıyorsa, yalnızca ona ulaşan önerilerde çalışır.

Metin yolu kendi bloğunu hak ediyor, çünkü bir yanıt taslağı destek agent'ının yaptığı en yaygın öneridir ve `send_customer_reply` çalıştığı an bir dış yan etkidir. Kontrol, bir müşteriye giden her yolda durur: tool çağrısının `text` argümanı ve orchestrator iletiyorsa bir nihai yanıt. Bunlardan yalnızca birini koruyan bir iddia kontrolü hiçbir şeyi korumaz.

```
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" }
```

Bu, açılış senaryosuna uygulanır. Yanıt taslağı, metni bir teslimat tarihi içeren bir `send_customer_reply` çağrısı olarak gelir. `extractClaims` tarihi döndürür, `findSource` bir tane tutan hiçbir tool sonucu bulamaz ve gate, `ungrounded_claim` reason'ıyla reddeder. Yanıt müşteriye hiç ulaşmaz. Blok dürüst bir sınırı da gösteriyor: çıkarıcı bir rakamı sınıflandıramadığında karar bir kişidir, çünkü karar veremeyen bir kontrol geçişe izin verecek biçimde (fail open) başarısız olmamalıdır.

Bir reddetmeye ne olur


Bir reddetme, kanonik `runStep`'in döndürdüğü gibi modele gözlem olarak döner. "Taslak, hiçbir tool sonucunda bulunmayan bir teslimat tarihi içeriyor; kaldırın ya da bilgiyi getirin", modelin buna göre davranabileceği bir cümledir. İki sınır geçerlidir. Kod, metni sabit bir reason listesinden

üretir ve ticket içeriğini asla bir talimatmış gibi geri yansıtmaz. Ve döngü sınırlıdır: aynı reddedilen şeyi önermeye devam eden bir model, durması gereken bir run'dır; bunu Bölüm 12 ve Bölüm 13 anlatıyor.

Bir reddetme geri bildirimdir, düzeltme değil. Bir ticket aynı kuralda üç kez reddediliyorsa, sistem bağlam ya da tool'lar hakkında bir şey söylüyordur ve doğru çıktı, kaydedilmiş bir reason ile bir hand-off'tur.

Karar akışı bir diyagram olarak

Diyagram tek bir öneriyi gösteriyor. Etkiden önce ayrılan yollar izlenir: belirsizlik orada emilir.



Hiçbir yol, modelin kendi güveninin bir dalı değiştirmesine izin vermez. Her biri, modelin kendisi hakkındaki anlatısına bağlı olmayan bir şey tarafından belirlenir.

Uygulamalı bir örnek: üç ticket

Bir sabah, aynı destek agent'ı ve aynı gate ile üç ticket alındığını varsayalım.

Birincisi "kolim nerede" ticket'ı. Yanıt `send_customer_reply` üzerinden önerilir; kargo firmasını ve durumu belirtir, ikisi de `lookup_order` sonucunda bulunur. İddialar bağlanır, politika bu türden bir yanıt için onay gerektirmez ve karar allow olur. Maliyet: birkaç deterministik kontrol.

İkincisi, `refund_ceiling` altında, hasarlı bir sipariş için bir iade. `issue_refund` çağrısının argümanları geçerli, verifier'lar ödemenin tahsil edildiğini ve tutarın iade edilebilir bakiyeye sığdığını doğruluyor ve sipariş bu run'ın müşterisine bağlanıyor. Etki sınıfı geri alınamaz yazmadır, ama tutar tavanın altında, bu yüzden karar allow. Idempotency ve tavan tool sözleşmesinde yaşar (Bölüm 6); buradaki mesele, kararın modelin emin görünmesinden değil kontrollerin geçmesinden dolayı allow olmasıdır.

Üçüncüsü, açıkça tanımlanmış tek bir sipariş için tavanın üstünde bir iade. Her kontrol geçiyor ve politika onay gerektiriyor, bu yüzden karar needs approval: Sam, bekleyen eylemi kanıtla birlikte alır ve karar verir (Bölüm 15). E-posta zinciri iki sipariştten söz etseydi ve öneri birini seçimi destekleyen bir şey olmadan adlandırsaydı, argüman kontrolü onu önce reddederdi ve Sam'e, yanlış sipariş olabilecek bir şey için bir iade gösterilmezdi.

Üçünün hiçbirisi modelin güvenini bilmeye ihtiyaç duymadı. Üçü de run'da kanıta ihtiyaç duydu.

Model değişikliği bir deploy'dur

Yukarıdakilerin hepsi modeli, bir davranış dağılımına sahip sabit bir bileşen olarak ele alıyor. Sabit değil. Onu değiştirmek, yükseltmek ya da bir fallback'e geçmek o dağılımı değiştirir ve ayarlanan kontroller (verifier

kapsamı, yükseltme eşikleri, en sık görünen reddetme reason'ları) eskisine göre ayarlanmıştı.

Tutumum, model değişikliğinin bir deploy olduğu ve bir deploy ile aynı yoldan geçmesi gerektiğidir. Bu, sahibi olan kayıtlı bir değişiklik, yayına çıkmadan önce eval suite'inden kanıt (Bölüm 21 golden set'i ve grader'ları kuruyor), geri alma yolu ve trafiğin bir kesrinin yeni modelde çalışıp geri kalanının eskisinde kaldığı kademeli bir rollout demektir. Kayıt, her run'da model tanımlayıcısını taşır; böylece davranıştaki bir değişiklik model değişikliğine bağlanabilir (Bölüm 20).

Adlandırmaya değer iki durum var, çünkü bir ticket olmadan gelme eğilimindeler. Birincisi sağlayıcı tarafındaki değişikliktir; bir model tanımlayıcısı aynı kalırken arkasındaki şey hareket eder; savunma, kontrol edilmeyen her bağımlılıkta olduğu gibidir: eval suite'ini yalnızca deploy'lardan önce değil, production konfigürasyonuna karşı zamanlanmış olarak da çalıştırmak. İkincisi, Bölüm 14'ün ele aldığı fallback modeldir: bir olay sırasında, dikkatin en düşük olduğu anda devreye girer ve en az test edilen modeldir.

Trade-off'lar ve maliyetler

Bu bölümdeki her kontrolün bir bedeli var ve bazıları her yerde ödemeye değmez.

Gecikme. Schema doğrulama mikrosaniyeler ekler; bir servisi okuyan verifier'lar bir ağ çağrısı ekler. Tutarlılık örnekleme model çağrılarını çoğaltır ve iddiaları çıkarmak ya da karşılaştırmak için kullanılan ikinci bir model çağrısı, yanıt yoluna tam bir gidiş-dönüş ekler. Bir chat yanıtı bekleyen müşteri bunu fark eder. Pahalı kontroller, etkisi geri alınması zor önerilere konur ve yanıt yolu mümkün olduğunda deterministik kontrollerde tutulur.

Harcama. Birkaç kez örnekleme, o ticket'lar için birkaç kat pahalıya mal olur. Bu her ticket'a uygulanırsa, özenli hissetmenin pahalı bir yolu satın alınmış olur. Uyuşmazlığın yapılacak şeyi değiştireceği yerde uygulanmalı.

Yanlış reddetmeler. Fazla hevesli bir iddia çıkarıcı doğru taslakları reddeder ve destek agent'ı yeniden ifade etmeyle döngüye girer. Her reddetme bir model çağrısına ve sınıra karşı bir step'e mal olur. Fazla katı

bir verifier bir hand-off üreticisine dönüşür. İzlenecek metric, reason'a göre reddetme oranıdır; bir reason'da yüksek olan bir oran, gate'i gevşetmek için değil, kontrolü ya da bağlamı ayarlamak için bir sinyaldir.

İnsan maliyeti. Her needs approval kararı Sam'in queue'suna düşer. Çıkarıcı çok fazla taslağı bir kişiye yönlendirirse queue büyür, onaylar refleks haline gelir ve kontrol bir tiyatroya dönüşür (Bölüm 15 buna geri dönüyor). Tasarım, yarattığı insan dakikalarını saymak zorundadır, çünkü bunlar kontrolün maliyetinin parçasıdır.

Bakım. Verifier'lar ve bütünlük kuralları, politikayı izleyen koddur. İade politikası değiştiğinde, eski politikayı kodlayan bir verifier doğru önerileri reddeder ya da daha kötüsü, kötü olanları kabul eder. Her verifier'ın bir sahibi vardır ve testleri politikanın yanında yaşar.

Bunu ne zaman kullanmamalı. Modelin yalnızca kodun kontrol ettiği bir formdaki bir alanı doldurduğu ve alanın bir schema ile kontrol edildiği bir workflow için yukarıdaki aygıtın tamamı ihtiyaçtan fazladır. Tek bir doğrulama ve bir sınır yeterlidir. Ve çıktı, bir yere gitmeden önce bir kişinin her zaman okuduğu bir taslaksa, çaba review'u hızlı yapmaya harcanmalı; reviewer'ın zaten tekrarlayacağı iddia kontrollerini otomatikleştirmeye değil. Taslakların ne içerdiğine bakmadan bir iddia çıkarıcı da kurmazdım; iki ya da üç iddia türü çoğu zaman riskin büyük kısmıdır.

Not: Bu bölümdeki kararlar, bir öneriyle ne yapılacağını söyler. Modelin ilk etapta hangi kararları vermesine izin verilmesi gerektiğini söylemezler. Bu ayrı ve daha önceki bir sorudur ve Bölüm 4 onu ele alıyor.

Sık yapılan hatalar

Önerileri sessizce onarmak. Orchestrator, bozuk bir tutarı tahmin ederek "düzeltir". Cazip, çünkü run devam eder. Çözüm, kesin bir reason ile reddetmek ve modelin yeniden önermesine izin vermektir; böylece etki eden her değer çıkarsanmış değil, önerilmiş ve kontrol edilmiş olur.

Müşteriye giden yollardan yalnızca birini korumak. İddia kontrolü nihai yanıtlarda çalışır, yanıtlar ise `send_customer_reply` üzerinden çıkar; ya da tersi. Cazip, çünkü nihai yanıt çıktı gibi görünür. Çözüm, bir kişiye ya da bir sisteme metin ya da argüman taşıyan her yolu listelemek ve her birine aynı kontrolü koymaktır.

Bir kontrol karar veremediğinde geçişe izin vermek (fail open). Bir rakamı sınıflandıramayan çıkarıcı taslağı geçirir. Cazip, çünkü alternatif insan işi ekler. Çözüm, karar verilemeyen vakaları bir kişiye göndermek ve saymaktır; böylece büyüyen bir queue çıkarıcının işe ihtiyacı olduğunu gösterir.

Kuyruğu ortalama eritmek. Bir ekip taslakların ortalama kalitesine bakar ve nadir, pahalı olanları gözden geçirir. Cazip, çünkü ortalamaları raporlamak kolaydır. Çözüm, hata sınıflarını ayrı ölçmek ve etki önemine göre ağırlıklandırmaktır; bunu Bölüm 3 tanıtıyor.

Temel çıkarımlar

- Modelin önerisi güvenilir girdidir, çünkü olasılıksal olarak üretilir, bağlamla kayar, yanlış görünmeden yanlış olabilir, talimatları yalnızca kısmen izler ve model değiştiğinde değişir.
- Belirsizlik dört türde gelir (biçim, içerik, niyet ve eksiklik) ve her birinin en ucuz dedektörü farklıdır; bu yüzden türü adlandıran bir tasarım doğru kontrolü seçer.
- Modelin bildirdiği güven, kendisi bir öneridir ve bir kontrol sinyali olamaz; bir vakayı daha fazla kontrole yönlendirebilir ve geri alınamaz bir etkiye izin verilmesinin nedeni asla olmamalıdır.
- Üzerine inşa etmeye değer sinyaller modelin dışında hesaplanır: schema doğrulama, kaynaklara karşı çapraz kontroller, deterministik verifier'lar ve seçici olarak, maliyeti sayılarak tutarlılık örnekleme.
- Temperature ve diğer örnekleme ayarları eval'leri ve tekrarlanabilirliği ayarlar; bir öneriyi doğru yapmazlar ve determinizmi vaat etmezler; bu yüzden aynı çıktı gereksinimi koda taşınır.
- Her öneri, deterministik kodun seçtiği bir kararla biter (allow, refuse ya da needs approval); karara schema, verifier, argüman ve iddia kontrolleri bu sırayla çalıştırılarak ulaşılır ve her reddetme kaydedilir

ve sınıra karşı sayılır; aynı iddia kontrolü, bir müşteriye metin taşıyan her yolda durur.

- Model değişikliği bir deploy'dur: bir sahip, yayından önce eval kanıtı, kademeli rollout, bir rollback yolu ve her run'da bir model tanımlayıcısı gerekir.

Önerilerin dört şekilde yanlış olabileceğini bilmek, bütün bir run'da neyin ters gittiğine dair henüz bir sözlük değildir. Bölüm 3 bu sözlüğü veriyor: dokuz hata sınıfı, bunların nasıl ayırt edileceği ve kök nedenin bir bileşen değil, sistemin hangi parçası olduğunun nasıl bulunacağı.

Bölüm 3 — Agent'lar İçin Bir Hata Taksonomisi

Parcelport'taki pazartesi review'unu gözümüzün önüne getirelim. Platform ve AI enablement ekibinden Alex'in elinde, geçen hafta agent'larda ters giden beş şeyin listesi var. Bir iade yanlış siparişe gitmiş. Bir yanıt, hiçbir sistemde bulunamayan bir teslimat tarihi vaat etmiş. On-call mühendis Robin, ops-agent'ın aynı log sorgusunu neden 11 kez çalıştırdığını yeniden kurgulayamamış. Bir tool çağrısı parse edilememiş. Bir run, müşteri yanıtı hiç almadığı halde tamamlandı olarak işaretlenmiş.

Liste haftanın diliyle yazılmış: "agent kafası karıştı", "yine bir şey uydurdu", "model rayından çıktı", "tool'un tuttuğu yoktu". Güvenlik ekibinden Jordan listeyi okuyor ve yerinde bir soru soruyor: bu beşinden hangisi ötekilerden biriyle aynı sorun ve hangi kontrol her birini yakalardı? Kimse cevaplayamıyor, çünkü liste belirtileri hiçbir tasarım bilgisi taşımayan sözcüklerle anlatıyor. Beş olay beş hikâye üretiyor, sıfır örüntü.

Bu bölüm, ekibe ortak bir sözlük veriyor. Kontrol zarfının altı parçasının (Bağlam, Öneri, Gate, Etki, Sınır ve Kayıt) hepsine aittir, çünkü bir hata bunların herhangi birinde başlayabilir. Cevapladığı soru şu: bir agent başarısız olduğunda, hata nasıl adlandırılır ki ad bir tespit sinyaline, bir önleyici kontrole, bir sınırlayıcı kontrole ve bir sahibe işaret etsin?

Sorun ve neden zor olduğu

Agent'lardaki hataları konuşmak üç nedenle zor ve hiçbir modelle ilgili değil.

Birincisi, belirtilerin birbirine benzemesi ve nedenlerin farklı olması. Yanlış bir iade, yanlış siparişi adlandıran bir öneriden, bayat bir okuma yüzünden yanlış siparişi içeren bir bağlamdan, başkasına ait bir siparişi kabul eden bir tool sözleşmesinden ya da sahipliği hiç kontrol etmeyen bir

gate'ten gelebilir. Müşteri dördünde de aynı sonucu görür. Çözüm her birinde farklıdır ve yanlış katmanı düzelten bir ekip, aynı olayı başka bir ticket numarasıyla yeniden görecektir.

İkincisi, sözcük dağarcığının insanlardan ödünç alınmış olması. "Agent'ın kafası karıştı", "yalan söyledi", "talimatları görmezden geldi", hepsi niyetleri olan bir kişiyi anlatır; bu da review'u "bunu neden yaptı?" sorusuna doğru iter. Bu sorunun olasılıksal bir bileşen için kararlı bir cevabı yoktur ve Bölüm 2 nedenini açıklıyor. Yararlı soru, "hangi kontrol tutmalıydı ve neden tutmadı?" sorusudur. Bu sorunun cevabı kodda, konfigürasyonda ya da tasarımın eksik bir parçasındadır.

Üçüncüsü, hataların birleşmesi. Körü körüne retry edilen bozuk bir öneri maliyet patlamasına dönüşür. Geniş bir token'la bir tool'a ulaşan bayat bir adres yetkisiz etkiye dönüşür. Başarılı olup hiç kaydedilmeyen bir etki, gözlenmeyen davranışa dönüşür. İlk görünen belirtide duran bir review, ikinci ve üçüncü hatayı kaçırır; bunlar genellikle tasarımın düzeltebileceği hatalardır.

Taksonomi, mühendislik cevabıdır. Küçük, kapalı bir adlandırılmış sınıflar kümesidir ve her biri, aynı olaya bakan iki reviewer'ın çoğunlukla ad üzerinde anlaşacağı biçimde tanımlanmıştır. Her şeyin teorisi değildir. Olay review'larının, eval'lerin ve dashboard'ların aynı sözcükleri kullanmasını ve her hatayı, çaresine sahip olan zarf parçasına yöneltmeyi sağlayan bir araçtır. Bu bir prompt sorusu değil, mühendislik sorusudur; çünkü aşağıdaki her sınıfın deterministik kodla çalışan en az bir kontrolü vardır ve hiçbir prompt'a cümle eklenerek kapatılmaz. Bir prompt bazı sınıfların oranını düşürebilir. Hiçbirinin kontrolü olamaz.

Bir hatayı sınıflandıran üç soru

Sınıflardan önce yöntem. Sınıflandırma, sabit bir sırayla üç soru sorar ve sıra önemlidir, çünkü her biri bir sonrakini daraltır.

1. **Run'da ne ters gitti?** Bu, F1'den F9'a hata sınıfıdır. Gözlenebilir davranışı adlandırır.
2. **Kök neden neredeydi?** Bu, model, bağlam, tool ya da kontrol eksenidir. Değişmesi hatayı en düşük maliyetle önleyecek bileşeni adlandırır.

3. **Ne kadar uzağa ulaştı?** Bu, önem eksenidir: bilgi, geri alınabilir, geri alınamaz ya da dış dünyaya ulaşan. Durumun ne kadar kontrolü hak ettiğini belirler.

Sınıf davranışın bir tarifiedir, eksen bir teşhistir ve önem bir önceliktir. Bunları karıştırmak, review'ların başa dönmesinin en yaygın nedenidir.

Kök neden eksen

Dört değer, tasarım için önemli nedenleri kapsar.

- **Model.** Sorun öneriydi ve makul bir tasarımın yakalayacağı biçimde başka hiçbir bileşen katkıda bulunmadı. Bu, ekiplerin beklediğinden daha seyrektir.
- **Bağlam.** Modele yanlış, bayat, eksik, etiketsiz ya da güvenilmemesi gereken bir kaynaktan gelen malzeme verildi. Öneri, aldığı bağlama makul bir cevap olabilir.
- **Tool.** Tool'un sözleşmesi, uygulaması ya da davranışı hataya izin verdi ya da neden oldu: reddedilmesi gereken bir girdi kabul edildi, sonucu gizleyen bir hata şekli vardı, idempotent olmayan bir işlem vardı.
- **Kontrol.** Tasarımın sahip olması gereken bir kontrol eksikti, zayıftı ya da yanlış yerdeydi: çağrıda gate yoktu, kimsenin ayarlamadığı bir sınır vardı, hiç yazılmamış bir kayıt vardı.

İlk taslak olay review'larının çoğunda geçen bir cümle hakkında açık olmak istiyorum: "model hata yaptı". "Ağ bir paketi düşürdü" cümlesinin doğru olduğu anlamda doğrudur. Tetikleyiciyi tarif eder ve tasarımın tetikleyicinin gerçekleşeceğini varsayması gerekir. Bir model, kimsenin sifıra indiremeyeceği bir oranda yanlış öneriler üretir; dolayısıyla orada biten bir review, değiştirebileceği hiçbir şey bulmamıştır. Kök neden sorusu, yanlış bir önerinin neden önemli olabildiğini sorar: neden bir tool'a ulaştı, neden hiçbir şey fark etmedi, neden bu kadar pahalıya mal oldu, neden kimse göremedi.

Model ekseninin dürüst cevap olduğu dar bir durum var. Aynı bağlam, aynı tool'lar ve aynı kontroller bir modelle kabul edilebilir davranış ürettiyse ve bir model değişikliğinden sonra aynı hatanın açıkça daha kötü bir oranını ürettiyse, modeldeki değişiklik bir nedendir. Bunun kanıtı olaydan değil, bir eval'den gelir (Bölüm 21 nasıl olduğunu ele alıyor). O zaman bile çözümün iki parçası vardır: model değişikliğini geri almak ya

da durdurmak ve gerilemeyi görünür ya da zararsız kılacak kontrolü eklemek. Tek eylem maddesi "daha iyi bir model kullan" olan bir review, henüz bir kontrol bulmamıştır.

Eksen her zaman tekil değildir. İki bileşen katkıda bulunduğunda ikisi de kaydedilir ve hangi değişikliğin daha ucuz olduğuna ve daha fazla koşulda tuttuğuna göre sıralanır. Birkaç satır koda mal olan ve gelecekteki her öneri için tutan bir gate kontrolü genellikle bir bağlam yeniden tasarımından önce gelir; o da genellikle bir model değişikliğinden önce gelir.

Dokuz hata sınıfı

Aşağıdaki id'ler ve adlar bütün kitap için sabittir. Her sınıf bir tanım, Parcelport'tan bir örnek, onu tespit eden sinyal, onu önleyen kontrol, önleme başarısız olduğunda hasarı sınırlayan kontrol ve bu kontrollere sahip bölümler alır. Önleme ve sınırlama farklı işlerdir. Önleme, oranı düşürür ya da yolu kapatır. Sınırlama, hatanın gerçekleştiğini varsayar ve ulaşabileceği yeri ya da sürdüğü süreyi küçültür.

F1: Bozuk çıktı

Tanım. Öneri parse edilmiyor ya da parse ediliyor ama orchestrator'ın beklediği yapıyla uyuşmuyor. Tespit etmesi en kolay ve en az tehlikeli sınıftır, çünkü yakalandığında henüz hiçbir şey olmamıştır.

Parcelport örneği. Destek agent'ı, `amount_minor`'ın tam sayı yerine bir ifade olarak geldiği ya da `reason_code`'un numaralandırmanın dışında bir değer olduğu bir `issue_refund` çağrısı öneriyor. Ops agent, zaman aralığı başlamadan biten bir `query_logs` çağrısı öneriyor.

Tespit sinyali. Gate'te schema doğrulama hatası; tool başına ve neden başına sayılır. Bir tool'da F1 oranının artması çoğu zaman belirsiz bir sözleşmeye işaret eder; bu da onu modelin olduğu kadar tool'un da sinyali yapar.

Önleme. Kapalı numaralandırmalar ve `additionalProperties: false` içeren sıkı bir girdi schema'sı; böylece geçerli bir çağrının şekli dar olur (Bölüm 6). Serbest metin yerine yapılandırılmış öneriler (Bölüm 4).

Sınırlama. Sınırlı sayıda onarım denemesi; doğrulama hatası modele gözlem olarak döner; limitten sonra hand-off. Sınırsız onarım, F1'in F9'a dönüşme yoludur (Bölüm 5 ve 14).

F2: Yanlış tool ya da yanlış argümanlar

Tanım. Öneri iyi biçimlenmiş ve schema'yı geçiyor, ama durum için yanlış tool'u ya da doğru tool'u uymayan değerlerle seçiyor. Yapı doğru, içerik yanlış.

Parcelport örneği. `issue_refund`, ticket metninde geçen ama müşterinin sorduğu sipariş olmayan bir sipariş için öneriliyor ya da tahsil edilen ödemeden farklı bir para biriminde bir iade öneriliyor. Ops agent için, `toggle_feature_flag`, adı soruşturmanın işaret ettiği flag'in adına yakın bir flag için öneriliyor.

Tespit sinyali. Gate'te ön koşul hataları ("sipariş bu run'ın müşterisine ait değil"), önerilen argümanlarla orchestrator'ın zaten elinde tuttuğu değerler arasındaki uyumsuzluk ve onaylanan çağrıların örneklemeli review'u. Her kontrolü geçen bir F2 yapısı gereği görünmezdir; Bölüm 21'deki golden set'in onu özellikle tahrik etmek için kurulmuş vakalar içermesinin nedeni budur.

Önleme. Modelin seçebileceklerini daraltmak: serbestçe yazılmak yerine run'ın kendi bağlamından alınan tanımlayıcılar, numaralandırmalar ve argümanları gate'in arayıp bulabileceği olgularla karşılaştıran ön koşullar (Bölüm 4 ve 6).

Sınırlama. Yanlış çağrıyı geri almayı ucuz ya da yerine ulaşmadan önce görünür kılan bir etki sınıfı ve onay politikası. Geri alınamaz bir yazma için, tam argümanları gösteren bir insan onayı (Bölüm 15).

F3: Dayanaksız iddia

Tanım. Model, bağlamının desteklemediği bir şey söylüyor. Bu, yaygın olarak "halüsinasyon" denen şey için kitabın kullandığı terimdir ve bu sözcüğün kitapta geçtiği tek yerdir. Farklı bir terim seçmenin nedeni pratiktir: "dayanaksız", bir reviewer'ın uygulayabileceği testi, yani bağlamdaki bir kaynağın iddiaya bağlanıp bağlanmadığını adlandırır.

Parcelport örneği. Hazırlanan bir yanıt müşteriye kolinin belirli bir günde ulaşacağını söylüyor ve hiçbir `lookup_order` sonucu bir teslimat tahmini içermiyor. Ops agent'ın özeti, bir deployment'ın hata artışına neden olduğunu söylüyor ve run'daki hiçbir trace ya da metric iki olayın ilişkili olduğunu göstermiyor.

Tespit sinyali. Dayandırmanın operasyonel biçimi olan bir iddia kontrolü (Bölüm 2); taslaktaki iddiaları run'ın tool sonuçlarıyla karşılaştırır: tarihler, tutarlar, sipariş tanımlayıcıları ve durum sözcükleri bir sonuçta bulunmalıdır. Deterministik kontroller yapılandırılmış iddiaları yakalar. Serbest metin iddiaları bir model grader'a ya da bir insana ihtiyaç duyar ve ikisi de daha zayıftır (Bölüm 21).

Önleme. Cevabın ihtiyaç duyduğu olguları içeren bağlam derleme; böylece modelin doldurması gereken bir boşluk kalmaz (Bölüm 9). Olgusal alanların model tarafından yazılmak yerine kod tarafından tool sonuçlarından doldurulduğu cevap biçimleri (Bölüm 4).

Sınırlama. Dış etki üzerinde bir gate: iddia kontrolünün bir kaynağa bağlayamadığı iddialar içeren yanıtlar, `send_customer_reply`'dan önce bir insana gider (Bölüm 15).

F4: Talimat ele geçirme

Tanım. Veri olan içerik talimat gibi ele alındı. Sınıfın iki alt sınıfı var. **F4.1, doğrudan injection**, kullanıcının kendi girdisinin agent'ın kurallarını geçersiz kılmaya çalışmasıdır. **F4.2, dolaylı injection**, bir tool sonucu, bir doküman ya da bir e-posta yoluyla gelen ve kullanıcı dışında biri tarafından yazılmış içeriktir. Bu konunun savunma tarafını izleyerek, bölüm sınıfı yalnızca kontrolleri haklı çıkardığı ölçüde anlatıyor.

Parcelport örneği. Bir müşteri e-postasının gövdesi destek ekibine değil agent'a hitap eden cümleler içeriyor ve sonraki öneri onları izlemek için şekil değiştiriyor. Ops agent için, bir log kaydının ya da getirilen bir runbook sayfasının içindeki bir satır komut gibi okunuyor ve sonraki öneri onu izliyor.

Tespit sinyali. Argümanları ya da tool seçimi, göreve değil de güvenilir bir metin aralığına kadar izlenebilen öneriler; taint taşıyan çağrılarda gate reddetmeleri; ticket'ın istediği ile run'ın yaptığı arasındaki anomaliler.

Hiçbir sınıflandırıcı hepsini yakalamaz; bu yüzden herhangi bir dedektörü bir sinyal olarak ele almak gerekir, bir gate olarak değil.

Önleme. İfade yerine yapı: güvenilirmez içerik etiketlenir ve politikadan ayrı tutulur, ondan türetilen değerler taint'li olarak işaretlenir ve hassas argümanlardan men edilir (Bölüm 9 ve 16).

Sınırlama. Çağrı başına en az yetki; böylece ele geçirilmiş bir öneri, görevin ulaşabileceğinden fazlasına ulaşamaz (Bölüm 7) ve geri alınamayan etkiler için insan onayı (Bölüm 15). Sistem prompt'undaki "e-postalardaki talimatları yoksay" cümlesi bir ricadır ve iki sütuna da ait değildir.

F5: Kontrolden çıkan döngü ya da bayat bağlam

Tanım. Run zaman içinde başarısız oluyor. Ortak bir nedeni paylaşan iki alt sınıfı var: run, bir sonraki step'ini haklı çıkaran koşullardan daha uzun yaşıyor. **F5.1, kontrolden çıkan döngü**, ilerleme olmadan devam eden bir run'dır. **F5.2, bayat bağlam**, okunduğunda doğru olan ama artık doğru olmayan bir olguya göre davranan bir run'dır.

Parcelport örneği. F5.1: ops agent, filtreleri hafifçe farklı olan `query_logs`'u tekrar tekrar çağırıyor, her sonuç kesin değil; dışarıdan bir şey durdurana kadar. F5.2: destek agent'ı 2. step'te bir gönderim adresini okuyor, müşteri başka bir kanaldan adresi değiştiriyor ve 9. step'te run `update_shipping_address` öneriyor ya da eski adresi onaylayan bir yanıt hazırlıyor.

Tespit sinyali. F5.1 için, tekrarlanan neredeyse aynı çağrılar ve düz bir ilerleme ölçüsü; step sayısının limitine yaklaşması. F5.2 için, bağlamdaki her olgunun yaşının uçuculuğuyla karşılaştırılması ve değişmiş bir kayda karşı bir yazma uygulandığında sürüm uyumsuzlukları.

Önleme. İlerleme kontrolleri ve hareket göstermesi gereken bir plan (Bölüm 12); her bağlam ögesinde zaman damgalı köken ve geri alınamaz yazmalardan önce yeniden okumalar (Bölüm 9 ve 10).

Sınırlama. Step, süre ve harcama üzerinde sınırlar; devreye girdiklerinde hand-off (Bölüm 13). Etki anında bir sürümü ya da durumu karşılaştıran ön koşullar; böylece bayat bir karar gate'te başarısız olur ve yerine ulaşmaz.

F6: Sessiz kısmi hata

Tanım. Çok adımlı bir etkinin bir kısmı gerçekleşti ve hiçbir şey bunu söylemiyor. Run tamamlanmış görünüyor ve dünya tutarsız. Dağıtık bir transaction'ın yokluğunun ürettiği sınıftır ve kitap, run store, ödeme servisi ve ticket sistemi arasında bir transaction varmış gibi davranmaz.

Parcelport örneği. `issue_refund`, `payments-service`'te başarılı oluyor ve `send_customer_reply` çağrısı bir timeout'tan sonra başarısız oluyor; run "done" durumuyla bitiyor. Müşterinin parası var ama açıklaması yok ya da daha kötüsü, agent ertesi gün iadeyi yeniden öneriyor. Ops agent için, `request_rollback deploy-service` tarafından kabul ediliyor, onay hiç gelmiyor ve run hiçbir şey başlamamış gibi kapanıyor.

Tespit sinyali. Run'ın kaydettiği intent'ler ile downstream sistemlerin bildirdiği etkiler arasında mutabakat: sonucu olmayan bir intent, yanıtı olmayan bir sonuç, açık intent'lerle tamamlandı işaretlenmiş bir run. Bu kontroller run'ın dışında, zamanlanmış olarak çalışır.

Önleme. Intent'i etkiden önce, sonucu etkiden sonra kaydetmek; bir tekrarın iki kez eylemde bulunmaması için runtime tarafından türetilen idempotency key'ler kullanmak ve bir timeout'u, retry edilecek bir hata olarak değil, bir durum sorgusuyla çözülecek bilinmeyen bir sonuç olarak ele almak (Bölüm 6 ve 14).

Sınırlama. Çözülmemiş bir intent varken bir run "done" işaretlenemez; çözüm, kaydedilmiş intent ekli olarak bir insan queue'suna gider (Bölüm 10).

F7: Yetkisiz etki

Tanım. Bu principal'ın, bu anda neden olmaması gereken bir etki gerçekleşti. "Yetkisiz" sözcüğü, modelin isteklerini değil, sistemin kurallarını ifade eder. Olağan yol, geniş yetkiye sahip bir bileşenin daha dar birinin isteğine göre davranmasıdır; bu da confused deputy'dir.

Parcelport örneği. Onay olmadan ilerleyen, `refund_ceiling` üzerinde bir iade ya da görev bir müşteriyle ilgiliyken her müşteride çalışan bir token'la yapılan bir eylem. Ops agent için, on-call mühendisin onayının kapsamadığı bir ortamda değiştirilen bir feature flag.

Tespit sinyali. Her etkinin, o çağrı için verilmiş yetkiyle denetim karşılaştırması: kapsam, kaynak, tutar, onay kimliği. Eşleşen verilmiş yetkisi olmayan her etki bir bulgudur. Gate'in reddettiği denemeler de bir sinyaldir; artan bir reddetme oranı, önerilerin ulaşmaması gereken bölgeye doğru kaydığı anlamına gelir.

Önleme. Çağrı başına verilen ve delege edenin kendi yetkisinden dar olan yetki, gate'te kodla uygulanan tavanlar ve sahiplik kontrolleri ve agent'ın dışında tutulan credential'lar (Bölüm 7 ve 18).

Sınırlama. Kısa ömürlü credential'lar, kod çalıştıran her şey için bir sandbox ve tam eyleme bağlı onay (Bölüm 7, 15, 18 ve 19).

F8: Gözlenmeyen davranış

Tanım. Sistem bir şey yaptı ve kullanılabilir hiçbir kanıt bırakmadı; bu yüzden kimse ne olduğunu ya da nedenini söyleyemiyor. Kayıt parçasının bir hatasıdır ve diğer her sınıfı daha pahalı kılar, çünkü görülemeyen bir hata sınıflandırılmaz, sayılamaz ya da düzeltilemez.

Parcelport örneği. Hiç span üretmeyen bir tool çağrısı; böylece on-call Robin, agent'ın düzeltmeyi önermeden önce log'ları okuyup okumadığını söyleyemiyor. Hangi bağlamın onu ürettiğine dair hiçbir kayıt olmadan çıkmış bir yanıt.

Tespit sinyali. Trace pipeline'ında kapsam kontrolleri: her model çağrısının, gate kararının ve etkinin bir span'i olmalıdır ve span'leri kaydedilmiş etkilerini açıklamayan bir run kendi başına bulgudur. Eksik kanıt bilerek aranmalıdır, çünkü kendi başına asla bir alarm üretmez.

Önleme. Her tool tarafından değil orchestrator tarafından yazılan, iki agent için tek bir trace şekli; intent etkiden önce kaydedilir ve redaction depolamadan önce uygulanır (Bölüm 17 ve 20).

Sınırlama. Kayıt yazılamıyorsa bu bir sınır olarak ele alınmalı: run durur ya da etkisi olmayan bir moda düşer. Geri alınamayan etkiler için "kanıt yok", devam etmek için değil, reddetmek için bir nedendir (Bölüm 13 ve 20).

F9: Maliyet ya da gecikme patlaması

Tanım. Run doğru ve fazlasıyla pahalıya mal oluyor ya da fazlasıyla uzun sürüyor. Öneri, gate ve etki yapmaları gerekeni yaptı ve bedelini bütçe, bir müşterinin sabrı ya da bir downstream servis ödedi.

Parcelport örneği. Bir sağlayıcı yavaşlaması model çağrılarını timeout'a düşürüyor ve her run aynı anda retry ediyor; böylece yavaş bir bağımlılık, model gateway'inden geçen bir çağrı seline dönüşüyor. Destek agent'ı için, her step'te bir müşterinin önceki bütün ticket'larıyla bağlamını dolduran bir run; böylece kalite değişmeden ticket başına maliyet artıyor.

Tespit sinyali. Run başına ve proje başına maliyet ve gecikme; yalnızca ortalamayla değil, bir dağılımla; retry sayıları; gateway'deki queue derinliği. Yavaş bir run ile pahalı bir run farklı sinyallerdir ve farklı eşikler gerektirir.

Önleme. Run başına ve proje başına bütçeler, önceliğe göre kırpan bir bağlam bütçesi ve tekrarlamadan önce hatanın nedenini sınıflandıran retry politikaları (Bölüm 13, 14 ve 22).

Sınırlama. Başarısız bir bağımlılığa yapılan çağrılar durduran circuit breaker'lar ve bir sınır devreye girdiğinde sistemin girdiği, belirtilmiş bir degraded mode, örneğin yalnızca hand-off (Bölüm 13 ve 14).

Sınıfları ayırt etmek

Bir review'daki sınıflandırma anlaşmazlıkları genellikle aynı birkaç sınır hakkındadır. Bunları önceden çözmek zaman kazandırır ve aşağıdaki kurallar, review şablonuna yazacağım kurallardır.


F2 ve F7: yanlış tool ile yetkisiz etki. F2 öneriyi tarif eder: iyi biçimlenmiş, ama duruma göre yanlış. F7, sistemin olmasına izin verdiği şeyi tarif eder. Aynı olay ikisi de olabilir ve çift bilgilendiricidir. Destek agent'ı başka bir müşteriye ait bir sipariş için iade önerirse ve gate buna izin verirse, öneri F2 ve etki F7'dir ve başarısız olan kontrol gate'teki sahiplik kontrolüdür. Gate çağrışı reddederse yalnızca F2 olmuştur ve sistem çalışmıştır. Zincirdeki her sınıf, öneriden etkiye doğru sıralanmış olarak kaydedilir ve çare, o türden her gelecek öneri için tutacak en erken kontrole konur.

F3 ve F5.2: dayanaksız iddia ile bayat bağlam. Modelin iddiayı ürettiği anda bağlamın iddiaya destek içerip içermediğini sorun. Hiç içermediyse iddia F3'tür. İçerdiyse ve olgu o zamandan beri değiştiyse ya da çok önce okunduysa, hata F5.2'dir. Çareler farklıdır: F3, gereken olguları bağlama koyarak ya da kodla doldurarak kapatılır; F5.2, tazelik kontrolleriyle ve bir etkiden önce yeniden okuyarak kapatılır.

F6 ve F8: kısmi hata ile gözlenmeyen davranış. F6, dünyanın bir durumuyla ilgilidir: bir etkinin bir kısmı gerçekleşti ve run aksini söylüyor. F8, kanıtla ilgilidir: etki gerçekleşti ve onu gösterecek hiçbir şey yok. Kaydı okuyarak tespit edilebilen bir F6, F8 değildir. Hiç kaydı olmayan bir etki ikisidir ve ilk onarılacak şey kayıttır, çünkü onsuz F6'nın boyutu bilinemez.

F1 ve F2: bozuk ile yanlış. Bir schema validator reddediyorsa F1'dir. Schema'yı geçip bir ön koşulda ya da bir insanın yargısında başarısız oluyorsa F2'dir. Bir schema'yı sıkılaştırmak bazı F2'leri F1'e taşır ve bu iyi bir takastır, çünkü F1'i yakalamak ucuzdur.

Aşağıdaki diyagram soruları sıraya koyuyor. Her sorunun olayı bir sınıfa nasıl gönderdiğine ve aynı olayda sık birlikte görülen çiftleri işaretleyen noktalı çizgilere bakılmalı.



Soruların sırası bir yasa değil, bir konvansiyondur. Kanıt ilk gelir, çünkü sonraki her cevap ona bağlıdır. İlk eşleşme birincil sınıftır. Diyagram yürüyüşü o düğümde biten bir yol olarak çizer, ama pratikte kalan sorularla devam edilir ve sonraki her eşleşme, öneriden etkiye doğru sıralanmış olarak kaydedilir. Noktalı çizgiler yaygın çiftleri gösterir: gate'in

izin verdiği yanlış bir çağrı, bir yazmaya ulaşan bir ele geçirme ve çok harcayan bir döngü. "Sınıflandırılmamış"a düşen bir olay, run hakkında değil, taksonomi hakkında bir bulgudur.

Kök neden bir tasarım ifadesidir

Sınıf ve eksen elimizdeyken, review sayılabilecek bir kayıt üretir. Aşağıdaki gösterim açıklayıcıdır; mesele, her alanın kapalı bir listeden gelmesidir.

```
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"
```

İki alan işin çoğunu yapar. `detected_by`, hatanın nasıl bulunduğunu kaydeder ve dürüst cevap "bir müşteri yazdı" olduğunda, eksik tespit sinyali, hatanın kendisi kadar review'un bir sonucudur. `missing_control`, review'u bir ekibin inşa edebileceği bir şeyle bitirmeye zorlar. "Modele bunu yapmamasını söyle" gibi bir eylem maddesi bu gösterimde kabul edilmez, çünkü hiçbir kontrolü adlandırmaz ve madde, adlandırana kadar yeniden yazılmalıdır.

Bir örneği baştan sona ele alalım. Tasarım, bir önerinin, bir müşterinin e-postasında anılan ama başka bir müşteriye ait olan bir sipariş için `issue_refund`'a ulaşmasına izin verdi. Kayıt şöyle: sınıflar F2, sonra F7; kök neden önce kontrol (gate'te sahiplik ön koşulu yoktu), ikinci olarak bağlam (e-postadaki sipariş tanımlayıcısı doğrudan öneriye girdi); önem geri alınamaz; run'daki hiçbir sinyal tarafından değil, bir mutabakat job'ı tarafından tespit edildi; eksik kontrol "`issue_refund` üzerinde sahiplik ön koşulu". Eylem maddeleri şunlar: sözleşmede bir sahiplik kontrolü (Bölüm 6), argümanlardaki sipariş tanımlayıcılarının mesaj metninden değil tool sonuçlarından gelmesi gerektiğine dair bir kural (Bölüm 9) ve daha erken

tetiklenen bir mutabakat alarmı (Bölüm 20). Listedeki hiçbir şey modelden daha iyi davranmasını istemiyor ve her madde, modelin yine yanlış siparişi önerdiği günlerde de tutuyor.

Önem, bir durumun ne kadar kontrolü hak ettiğine karar verir

Hata sınıfı ne olduğunu söyler. Önem, ne kadar önemli olduğunu söyler ve olmadan önce çağrının ne kadar kontrole sahip olması gerektiğini belirler. Kitap dört seviye kullanıyor. Seviye adları Parcelport'un tool'larının etki sınıflarından alınmıştır, ama bir olayın seviyesini gerçekten gerçekleştiren etki belirler.

Önem	Ne anlama gelir	Tipik tool'lar	Örnek hata
Bilgi	Hiçbir şey değişmedi; yanlış bir cevap ya da boşa giden bir okuma	<code>lookup_order</code> , <code>query_logs</code> , <code>search_docs</code>	Kimsenin buna göre davranmadığı bir iç özetinde F3
Geri alınabilir	State değişti ve telafi eden bir eylem onu geri getirebilir	<code>update_shipping_address</code> , <code>open_pull_request</code> , <code>toggle_feature_flag</code> , <code>request_rollback</code>	Kargo firmasına hand-off'tan önce bir adres değişikliğinde F2
Geri alınamaz	Parcelport onu geri alamaz	<code>issue_refund</code>	Tavanın üzerinde bir iadede F7
Dış	Parcelport'un kontrol etmediği bir kişiye ya da sisteme ulaştı	<code>send_customer_reply</code>	Zaten teslim edilmiş bir yanıtta F3

Seviye tool'u değil etkiyi izlediği için, önem örneğe aittir. Önemsiz bir tutarın iadesi ile tavandaki bir iade, farklı erişimli aynı tool'dur ve ikisine de aynı davranan bir politika ya birincisi için fazla katı ya da ikincisi için fazla gevşek olacaktır. Bir çağrının onay gerektirip gerektirmediği gate'teki bir politika kararıdır ve etki sınıfından okunmaz. Geri alınabilir bir yazma onay gerektirebilir (`request_rollback` gerektirir) ve küçük bir geri alınamaz yazma onaysız ilerleyebilir.

Kontrol yoğunluğu o zaman basit bir ilkeyi izler: bir hata ne kadar az geri alınabiliyorsa, o kadar erken ve o kadar deterministik biçimde durdurulmalı ve önceden o kadar fazla kanıt bulunmalıdır. Bilgi seviyesinde, sonradan tespit genellikle yeterlidir ve bir önleme gate'inin maliyeti ödemeye değmez. Geri alınabilir seviyede, gate ön koşulları kontrol eder ve kayıt bir intent gösterir; böylece telafi eden eylem bilinir. Geri alınamaz seviyede, ön koşullar, tavanlar, idempotency ve bir eşğin üzerinde, tam çağrıya bağlı onay. Dış seviyede, sistem bir düzeltme gönderebilse bile çağrı geri alınamaz sayılır, çünkü bir mesaj okunmamış yapılamaz.

Aşağıdaki açıklayıcı politika fikri veri olarak ifade eder; böylece yoğunluk, bir prompt'un umduğu bir şey değil, gate'in değerlendirdiği bir şey olur.

```
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
```

Önem ayrıca eval çabasının nereye yatırılacağını da söyler. Golden set, geri alınamaz ve dış satırlarında F2, F3 ve F7 için, bilgi satırındaki herhangi bir şey için olduğundan daha fazla düşmanca ve sınır vakası içermelidir, çünkü bir kaçırmanın maliyetli olduğu yer orasıdır (Bölüm 21).

Bütün kitap için tek bir tablo

Aşağıdaki tablo, yukarıdaki dokuz bölümün sıkıştırılmış biçimidir. Ek'in başvuru için yeniden verdiği tablonun aynısıdır. Kontrolleri planlarken sütun sütun, bir olayı review ederken satır satır okunur.

Sınıf	Tespit	Önleme	Sınırlama	Bölümler
F1 Bozuk çıktı	Tool başına schema hata oranı	Dar schema'lar, kapalı numaralandırmalar	Sınırlı onarım, sonra hand-off	2, 5, 6
F2 Yanlış tool ya da yanlış argümanlar	Ön koşul hataları, örneklemeli review	Run olgularından seç, sahiplik ön koşulları	Geri alınamaz çağrılar için onay	4, 5, 6
F3 Dayanaksız iddia	Tool sonuçlarına karşı iddia kontrolü	Gereken olgular bağlamda, alanlar kodla doldurulur	Dış yanıttan önce insan review'u	2, 9, 21
F4 Talimat ele geçirme	Argümanlarda taint, anormal step'ler	Etiketli güvenilirmez içerik, taint kuralları	En az yetki, onay	8, 9, 16
F5 Kontrolden çıkan döngü ya da bayat bağlam	Tekrarlanan çağrılar, olgu yaşı, sürüm uyumsuzluğu	İlerleme kontrolleri, köken, yeniden okuma	Sınırlar, sürüm ön koşulları	9, 10, 12, 13
F6 Sessiz kısmi hata	Intent'ler ve sonuçların mutabakatı	Önce intent, idempotency, bilinmeyen sonuç	Açık intent'lerle "done" yok	6, 10, 14
F7 Yetkisiz etki	Etkilerin verilmiş yetkiye karşı denetimi	Çağrı başına yetki, kodda tavanlar	Kısa ömürlü credential'lar, sandbox	7, 15, 18, 19
F8 Gözlenmeyen davranış	Etkilere karşı trace kapsamı	Tek trace şekli, etkiden önce intent	Kayıt başarısız olursa dur ya da etkileri bırak	17, 20, 21, 23
F9 Maliyet ya da gecikme patlaması	Maliyet ve gecikme dağılımları, retry sayıları	Bütçeler, bağlam bütçesi, sınıflandırılmış retry'lar	Circuit breaker'lar, degraded mode	13, 14, 22

Hiçbir satır tek bir kontrolle kapanmaz. Önleme oranı düşürür, sınırlama erişimi küçültür ve tespit, ikisinden hangisinin başarısız olduğunu söyler. Bir satırın yalnızca bir sütununda girdisi olan bir tasarımın boşluğu vardır ve tablo bu boşluğu görmeyi kolaylaştırır.

Review, eval ve operasyon için ortak bir dil

Taksonomi, olay review'u, eval'ler ve operasyon aynı id'leri kullandığında karşılığını verir. Bölüm 23 suçlamasız review'u yukarıdaki olay kaydı üzerine kuruyor; böylece sınıf, kök neden ekseni ve eksik kontrol ayrı alanlardır ve bir kişinin adı asla neden olarak geçmez.

Bölüm 21, her golden set vakasını açığa çıkarmayı amaçladığı sınıfla etiketleyebilir; bu da suite'in, toplam geçme oranının gizlediği bir kapsam görünümünü vermesini sağlar: tamamı F3 olan ve F6'da hiçbir şey olmayan bir suite yamuktur. Bölüm 20'nin trace'leri, sınıfı reddetmeler, retry'lar, hand-off'lar ve mutabakat bulguları üzerinde bir etiket olarak taşıyabilir; böylece F2 reddetmelerinin artan oranı, kimse bir ticket açmadan önce ortaya çıkar.

İki reviewer vakaların bir kısmında anlaşılamayacak; yukarıdaki eşitlik bozma kuralları ve ikinci bir etiket çoğunu çözer. Hiç etiketi olmayan bir vaka reddedilmesi gereken şeydir, çünkü "diğer", incelenmemiş hataların yaşadığı yer olur. Bölüm 24 tabloya bir lansman öncesi kontrol olarak geri dönüyor: her sınıf için, bu agent'ın hangi tespiti ve hangi sınırlaması var?

Trade-off'lar ve maliyetler

Bir taksonomi yazmak ucuz, dürüst tutmak pahalıdır. Maliyetler somut.

Sınıflandırma zaman alır. Her olay artık bir kayıt üreten bir review adımı gerektiriyor. Ayda birkaç olayı ele alan bir ekip için bu karşılanabilir. Haftada çok sayıda düşük önemli olayı olan bir ekip için değildir ve makul cevap, bilgi ve geri alınabilir seviyeler için örneklemeye, geri alınamaz ve dış olanlar için tam olarak sınıflandırmaktır.

Sınıflar örtüşür ve sabit id'ler bunu gizler. Dokuz sınıf, sürekli bir uzayın basitleştirilmesidir. Dağınık bir olayı F2'ye ya da F3'e sıkıştırmak, onu ilginç kılan birleşimi gizleyebilir. Sıralı etiket listesi yardımcı olur, F4.2 gibi bir alt sınıf eklemeye istekli olmak da; ama kitap yeni üst düzey sınıf eklemeyi ve ekleyen bir ekip, dashboard'larının herkesin sözcük dağarcığıyla uyuşmamasını beklemelidir.

Tespit sinyalleri bedava değil. Bir iddia kontrolü her yanıtta mühendislik zamanına ve biraz gecikmeye mal olur. Mutabakat job'ları birden çok sisteme erişim ve onları bakımda tutan bir sahip gerektirir. Trace kapsam

kontrolleri, trace pipeline'ının yokluklarına güvenilecek kadar güvenilir olmasını gerektirir. Tablodaki her sinyal küçük bir sistemdir ve hangisinin önce inşa edileceği seçimi önemi izlemelidir: iç özetlerde ayrıntılı F3 dedektörlerinden önce, paradaki F6 için mutabakat, F7 için sahiplik denetimleri.

Taksonomiler tiyatroya dönüşür. Kimsenin review etmediği bir hata sınıfları dashboard'u ya da hep dropdown'daki ilk değerle doldurulan bir etiket alanı, getirisi olmayan bir maliyettir. Etiketlerin aylık review'u bir kontrolde en az bir değişikliğe yol açmıyorsa, sürecin kısaltılması ya da verinin farklı bir soru sorması gerekir.

Tamamını ne zaman kullanmamalı. Tek bir salt okunur tool'u olan ve etkisi olmayan erken bir prototipin önem mekanizmasına pek ihtiyacı yoktur. Dokuz ad, neyin ters gidebileceğine dair bir kontrol listesi olarak kullanılır, olay kaydı üç satırda tutulur ve gerisi etkisi olan tool'lar ortaya çıktıkça eklenir. Bir agent para taşıyabildiği ya da bir müşteriye yazabildiği an, tam kayıt yerini hak eder.

Sık yapılan hatalar

- **Review'u "model hata yaptı" ile bitirmek.** Cazip, çünkü öneri görünen olaydır ve modeli göstermek kolaydır. Çözüm kök neden sorusudur: hangi kontrolün o öneriyi zararsız kılacağı sorulur ve eylem maddesi ona karşı yazılır.
- **Mekanizmaya göre değil belirtiye göre etiketlemek.** "Yanlış iade" bir belirtidir ve F2, F5.2 ya da F7 olabilir. Cazip, çünkü müşterinin sözcükleri etiket olur. Çözüm, soruları sırayla yürütmek ve zincirdeki her sınıfı kaydetmektir.
- **F3'ü önemli olan tek sınıf saymak.** Dayanaksız iddialar en çok tartışılanlardır; bu yüzden ekipler çabalarının çoğunu onlara harcar ve F6, F7 ve F8'i sahipsiz bırakır. Çözüm, öneme göre saymak ve tablonun hangi satırlarında boş bir hücre olduğuna bakmaktır.
- **Olayları insan kontrolü olmadan bir modelle etiketlemek.** Ölçeklenir ve hacim büyüdüğünde caziptir. Etiketler o zaman, taksonominin yönetmek için var olduğu güvenilmezliği devralır. Çözüm, bir modelin etiket önermesine ve geri alınamaz ve dış

seviyelerdekileri bir kişinin onaylamasına izin vermek ve etiket öneren modeli diğer her model grader gibi değerlendirmektir (Bölüm 21).

- **Her yeni sürpriz için üst düzey sınıf eklemek.** Yeni bir hata yeni hissettirir, bu yüzden yeni bir id alır. Çözüm, onu önce en yakın sınıfın alt sınıfı olarak yerleştirmek ve üst düzey sınıfı yalnızca mevcut satırlardaki hiçbir kontrol onu ele alamıyorsa eklemektir.
- **"Prompt'la önlenir"i tabloda bir kontrol saymak.** "Modele yapmamasını söyle" yazan bir hücre ilerleme gibi hissettirir ve hiçbir şeye mal olmaz. Çözüm her bölümün izlediği kuraldır: öneri ile etki arasında duran tek şey ifadeyse hücre boştur.
- **Önleme var diye tespiti görmezden gelmek.** İyi bir gate'i olan bir ekip, tespit edilecek bir şey kalmadığını varsayar. Çözüm, reddetmeleri bir sinyal olarak ele almak ve yine de mutabakat çalıştırmaktır; gate'in bir hatası olabilir ve eksik bir kontrol hiçbir şeyi reddedemez.

Temel çıkarımlar

- Bir hata sınıfı gözlenebilir davranışı adlandırır, bir kök neden eksen, değişmesi onu önleyecek bileşeni adlandırır ve önem, durumun ne kadar kontrolü hak ettiğini adlandırır; üçünü karıştırmak review'ların başa dönmesinin ana nedenidir.
- "Model hata yaptı", tasarımın varsayması gereken tetikleyiciyi tarif eder ve bir kök neden değildir; kök neden, yanlış bir önerinin önemli olmasına izin veren kontrol, bağlam ya da tool'dur.
- F1'den F9'a dokuz sınıfın adı ve id'si sabittir; F4.1, F4.2, F5.1 ve F5.2 gibi alt sınıflara izin verilir; böylece bir ekipteki her bölüm, review ve dashboard aynı sözcükleri kullanır.
- Her sınıfın bir tespit sinyali, bir önleyici kontrole ve bir sınırlayıcı kontrole ihtiyacı vardır ve taksonomi tablosunda boş bir hücresi olan bir satır, tasarımdaki bir boşluğu işaret eder.
- Tek bir olay genellikle birden fazla etiket taşır; bunlar öneriden etkiye doğru sıralanır ve çare, o türden her gelecek öneri için tutacak en erken kontrole aittir.
- Önem (bilgi, geri alınabilir, geri alınamaz, dış) tool'a değil örneğe aittir ve bir hata ne kadar az geri alınabiliyorsa, o kadar erken ve o kadar deterministik biçimde durdurulmalıdır.

- Taksonomi, yalnızca olay review'u, eval'ler ve operasyonel dashboard'lar id'lerini paylaştığında karşılığını verir ve yeni ya da değişmiş bir kontrol üretmeyen bir review, sürecin bir tiyatroya dönüştüğünün işaretidir.

Bölüm 4, hataları adlandırmaktan çoğunu önlemeye geçiyor: modelin neyi seçebileceğini ve kodun neye karar vermesi gerektiğini, karar karar belirleyerek.

Bölüm 4 — Determinizm Sınırları

Parcelport'ta bir perşembe öğleden sonrasını düşünelim: bir müşteri, siparişindeki üç ürünün ikisinin ezilmiş geldiğini yazıyor. Prototipte destek agent'ının prompt'u modelden adil bir kısmi iade hesaplamasını, müşteri başka bir para birimiyle ödeme yaptıysa bunu sipariş para birimine çevirmesini, iadeyi vermesini ve nazık bir yanıt yazmasını istiyor. Model tek bir öneri döndürüyor: bir sipariş, bir tutar, bir para birimi, bir neden ve yanıt metni. Tutar, sipariş kalemleri, bir indirim ve bir vergi oranı üzerinden yapılan aritmetik; prototipte hiçbir şey bunu denetlemiyor.

Aritmetiğin çoğu gün doğru olduğunu varsayalım. Doğru olmadığı gün iade fazla küçük ya da fazla büyük çıkar ve `payments-service` ikisini de kaydeder, çünkü servis çağırana güveniyor, çağırana da modele. Olasılıksal bir bileşenin para aritmetiği yapmasına kimse karar vermedi. Prompt, her seferinde bir cümle eklenerek büyüdü ve her cümle bir kararı daha modele taşıdı.

Bu bölüm kontrol zarfının **Gate** parçasına ait, bir ayağı da Öneri'de. Cevapladığı soru Gate'in kendi sorusu: bu öneri, bu principal için, şu anda etkiye dönüşebilir mi? Bunu cevaplamak için önce bir run'daki hangi kararları modelin hiç verebileceğini, hangilerinin koda ait olduğunu bilmek gerekir. İkisi arasındaki çizgiye bu bölüm **determinizm sınırı** diyor ve iş, onu bilinçli çizmek, dar tutmak ve test edilebilir kılmaktır.

Sorun ve neden zor olduğu

Bir run bir karar zinciridir ve prototip bu kararları etiketlemez. Müşteri hangi siparişi kastediyor? Ezilmiş bir ürün kargo kurallarının kapsamında mı? İade edilebilir tutar nedir? Bu tutar `refund_ceiling` içinde mi? Yanıt, sipariş verisinin desteklemediği bir şey vaat ediyor mu? Tek bir prompt'ta bu sorular tek bir istek olarak gelir ve model hepsini tek bir öneride cevaplar. Cevapların nitelikleri çok farklıdır, ama tasarım hepsine aynı davranır.

Bu bölümün konusu olan hata budur ve zarfın Öneri ile Gate parçalarında yer alır. Tipik ürünleri şunlardır: F2 (yanlış tool ya da yanlış argümanlar), bir öneri yanlış siparişi ya da duruma uymayan bir tutarı andığında; F1 (bozuk çıktı), yapı kaydığında ve aşağı akıştaki bir parser tahmin yürüttüğünde; F7 (yetkisiz etki), tavanın üstündeki bir tutar, hiçbir kod onu hiçbir şeyle karşılaştırmadığı için payments servisine ulaştığında. F3 (dayanaksız iddia) da yanıt, hiçbir tool sonucunda bulunmayan bir rakam belirttiğinde bunlara katılır.

Bariz çözüm, modele dikkatli olmasını söylemektir. Prompt'a bir cümle eklenir: tavanı asla aşma, her zaman sipariş para birimini kullan, aritmetiği iki kez kontrol et. Bu cümle bir istektir, kontrol değildir ve Bölüm 2, uyulmadığı günün neden geleceğini açıklıyor. Bu bölüm bunu kabul edilmiş sayıyor.

Bariz çözümün işe yaramamasının ikinci bir nedeni daha var ve o kadar görünür değil. Birçok karar bir karışımdır. "Hasarlı ürünleri iade et" bir yargı (müşterinin yazdığına göre hasarlı olanlar şu iki ürün) ve bir hesap (bu iki kalemin indirim sonrası, hangi para biriminde toplamı) içerir. Model, birincisi için makul bir yerdir, ikincisi için kötü bir yer. İkisi aynı öneri alanında duruyorsa, birini denetlemek için ötekinin yeniden türetilmesi gerekir.

Sınırın bir prompt sorusu değil, bir mühendislik sorusu olmasının nedeni budur. Prompt, çizginin bir yanındaki davranışı isteyebilir. Çizgiyi var edebilecek yalnızca koddur.

Çizgiyi çekmek: beş ölçüt

Sınırı göreve göre ("model iadeleri halleder") ya da sezgiyle ("bu riskli görünüyor") çizmezdim. Karar başına çizerdim ve beş soru kullanırdım. Hiçbiri yeni değil ve her birinin bir yönü var: bir kararı koda ya da modele doğru eğiyor.

Ölçüt	Soru	Koda yaklaştıran durum	Modele yaklaştıran durum
Geri alınabilirlik	Yanlış bir cevap geri alınabilir mi ve kim tarafından?	Etki geri alınamaz bir yazma ya da dış bir yan etki	Sonuç, bir insanın ya da sonraki bir step'in atabileceği bir taslak

Ölçüt	Soru	Koda yaklaştıran durum	Modele yaklaştıran durum
Doğrulanabilirlik	Kod cevabı bir doğruluk kaynağına karşı denetleyebilir mi?	Doğru değeri bir kural, bir tablo ya da bir servis tutuyor	Kaynak yok; cevap bir yargı
Sıklık	Karar ne sıklıkla veriliyor ve ne kadar çeşitli?	Aynı biçimde tekrar ediyor, dolayısıyla bir kural bir kez yazılabilir	Girdiler açık uçlu ve hiçbir kural hepsini kapsamaz
Tolerans	Biri zarar görmeden önce cevap ne kadar yanlış olabilir?	Tolerans sıfır ya da katı bir sınır (para, eşikler)	Tolerans geniş (üslup, ifade, adayların sıralaması)
Açıklanabilirlik	Birinin sonradan bu değer nenden seçildiğini tam olarak açıklaması gerekir mi?	Bir reviewer "neden bu tutar?" diye soracak ve cevap bir kural olmalı	Sade sözlerle bir gerekçe yeter

İlk olarak geri alınabilirliği tartardım, çünkü sonradan telafi edilemeyen ölçüt o. İki ölçüt çelişirse, bu kitaptaki tool tablosundan gelen etki sınıfı beraberliği bozar: geri alınamaz bir yazma ya da dış bir yan etki, model çoğunlukla haklı olsa bile kararı koda çeker. Sınırı doğru cevabın sıklığı değil, yanlış cevabın maliyeti belirler.

Öteki dört ölçüt kodun neye benzeyeceğini şekillendirir. Doğrulanabilirlik, deterministik bir denetimin var olup olamayacağını söyler. Sıklık, bir kuralın yazmaya değip değmeyeceğini söyler. Tolerans, denetimin ne kadar katı olması gerektiğini söyler. Açıklanabilirlik, cevabın okunabilen bir fonksiyondan çıkıp çıkmaması gerektiğini söyler; çünkü modelin belirttiği gerekçe, kendi çıktısı hakkında bir öneridir, çıktının nasıl oluştuğunun kaydı değil.

Tek bir ticket için karar envanteri

Bu sorular açılıştaki iade ticket'ına uygulanır. Alıştırmanın amacı envanterin kendisi: sayfadaki her kararın bir sahibi var ve sahip yazılı.

Karar	Sahip	Neden
Müşterinin hangi siparişi kastettiği	Model bir listeden önerir, kod sahipliği doğrular	Açık uçlu dil, ama cevap müşterinin kendi siparişlerinden biri olmalı

Karar	Sahip	Neden
Müşterinin hasarı, teslim edilmemeyi ya da başka bir şeyi bildirip bildirmediği	Model	Serbest metin üzerinde bir yargı; çıktı kapalı bir kümeden bir değer
Bu nedenin kargo ve iade kurallarının kapsamında olup olmadığı	Kod	Bir kural var ve bir tablo onu tutuyor
Hangi sipariş kalemlerinin etkilendiği	Model line id'leri önerir, kod var olduklarını ve iade edilmediklerini denetler	Metin hakkında yargı, siparişe karşı denetlenebilir
İade tutarı	Kod	Para; sipariştten doğrulanabilir; sıfır tolerans
Para birimi	Kod	Sipariştten gelir, hiçbir zaman bir öneriden değil
Tutarın <code>refund_ceiling</code> içinde olup olmadığı	Kod	Bir eşik; geri alınamaz yazma
Bir insanın onaylaması gerekip gerekmediği	Kod (gate'teki politika)	Onay bir politika sonucudur, bir model görüşü değil
Yanıtın ifadesi	Model, denetlenmiş bir çerçeve içinde	Geniş tolerans, ama içindeki iddialar için F3 geçerli
Yükseltip yükseltmeyeceği	Model önerir, kod da zorlayabilir	Yargı, deterministik bir tabanla

İki şey göze çarpıyor. Birincisi, model dil içeren kararları elinde tutuyor ve bu işin büyük bir kısmı. İkincisi, kaybettiği kararların hepsi yanlış cevabın paraya mal olduğu ya da açıklanamadığı kararlar; çoğu da hiçbir zaman "karar" değildi: prompt'un yanlış bileşene devrettiği aramalar ve aritmetikti.

Örüntü 1: model önerir, kod karara bağlar

Merkezdeki örüntü tek bir cümle: model önerir, kod karara bağlar. Modelin döndürdüğü her şey bir öneridir, yani güvenilmez girdidir ve herhangi bir şey değişmeden önce onu denetleyen kod tarafından ele alınır. Orchestrator, bir etkinin başladığı tek yerdir ve bir etkiyi yalnızca gate'ten gelen bir karar üzerine başlatır.

Aşağıda bir tool çağrısı için karara bağlama adımı var; kitabın pseudocode'uyla, `gate.check`'in tool çağrılarını işleyen dalı olarak yazılmış. Kararları `gate`'in döndürdüğü üç karardır: `"allow"`, `"refuse"` ve `"needs_approval"`. Sıraya dikkat edilmeli. Önce yapı gelir, sonra tool seçimi, sonra argümanlar, sonra seçim kümesine üyelik (Örüntü 2 onu kurar), sonra servislerden okunan olgular, sonra politika.

```
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 }
```

Bu blok, Bölüm 5'teki `gate`'in kısmi bir görünümü: izni ve o bölümün sıraladığı öteki denetimleri dışarıda bırakıyor ve Bölüm 5'in reason adlarını kullanıyor. Yüğü üç ayrıntı taşıyor. Olgular, `orders-service` ve `payments-service`'i kendisi okuyan `loadFacts`'ten gelir. Bir denetim, bir argümanı modelin de verdiği bir değerle karşılaştırıyorsa, hiçbir şeyi doğrulamamıştır. Ve `requiresApproval` bir politika sürümü alır, böylece aynı karar sonradan yeniden üretilebilir (aşağıda bunun hakkında daha fazlası var).

Yapılandırılmış çıktı ve schema doğrulaması

Schema, bu bölümdeki en ucuz kontroldür ve ilk soruyu cevaplar: bu öneri, tool'un kabul ettiği bir şeyin biçiminde mi? Denetimi geçemeyen öneri F1'dir ve hiçbir servise ulaşmaz. Geçen öneri yalnızca iyi

biçimlenmiştir. Bu, "doğru" ya da "izin verilmiş"ten çok daha zayıf bir ifadedir ve bölümün geri kalanı bu açık yüzünden var.

Schema doğrulamasını katı ve sıkıcı tutardım. Bilinmeyen alanlar reddedilir, eksik olanlar reddedilir, yanlış tipteki değerler reddedilir ve onarılmaz. Bir string'i sessizce sayıya çeviren, bir alanı kırpın ya da bir varsayılan değer dolduran bir validator, model adına bir karar vermiştir ve bunu kimsenin gözden geçirmedeği bir yerde vermiştir. Bir onarım yapmaya değiyorsa, onun kendi kaydı olan görünür, test edilmiş bir adım yapılması ya da önerinin reddedilip yeniden önerilmesi gerekir.

Bölüm 5, modelden yapılandırılmış çıktının nasıl istendiğini, Bölüm 6 ise schema'nın ait olduğu tool sözleşmesini anlatıyor. Burada önemli olan konum: schema denetimi, prompt ne demiş olursa olsun, modelden sonra ve her şeyden önce, kodda çalışır.

Örüntü 2: seçim aralığını daralt

İkinci örüntü, modelin ne söylemekte serbest olduğunu azaltır. Her serbest metin alanı, yanlış bir değer iyi biçimlenmiş olabileceği bir alandır; dolayısıyla F2'yi küçültmenin en iyi yolu, açık alanları orchestrator'ın sağladığı seçimlerle değiştirmektir.

Üç yaygın daraltma var. Bir **enum**, serbest bir string'in yerine kapalı bir küme koyar; `issue_refund` sözleşmesindeki `reason_code` değerleri gibi. Bir **tanımlayıcı listesi**, modelin hatırlayabileceği ya da uydurabileceği bir değer yerine, orchestrator'ın bu müşteri için okuduğu bir listeden seçmesi gereken bir değer koyar. Bir **şablon**, bir düzyazı bloğunun yerine, boşlukları kodun doldurduğu ve modelin yazdığı tek şeyin açık kısımlar olduğu bir çerçeve koyar.

```
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)
  }
```

Seçim kümesi bağlama etiketli bir liste olarak girer ve gate sonra üyeliği `checkToolCall`'daki `inChoiceSet` adımıyla doğrular: `order_ids`'in dışındaki bir `order_id`, `not_in_choice_set` reason'ıyla reddedilir. Bunun confused deputy problemi için ne yaptığına dikkat edilmeli. Başka bir müşterinin siparişini anan bir öneri, modelin yanlış yaptığı bir yargı değildir; kodun kümede olmadığını görebildiği bir değerdir ve ret, modelin bir şeyi fark etmesine bağlı değildir.

Daraltma bedava değil ve bir sınırı var. Kapalı bir küme gerçekten ortaya çıkan durumları içermelidir, yoksa model en yakın yanlış değeri seçer. Olağan çıkış yolu, `escalate_to_human`'a yönlendiren açık bir `other` değeridir ve onun izlenmesi gerekir: önerilerin çoğunun seçtiği bir `other`, kümenin işi tarif etmediğinin işaretidir, müşterilerin sıra dışı olduğunun değil. Aynısı şablonlar için de geçerli: yaygın yanıtı iyi, sıra dışı olanı kötü kapsıyorlar. Sıra dışı olan için modelin serbest metin taslağı yazmasına ve bir insanın onu göndermeden önce okumasına izin verirdim; bu bir Bölüm 15 kararıdır.

Örüntü 3: hesaplama koda aittir

Para, tarihler ve eşikler tek bir özelliği paylaşır: doğru bir cevap vardır ve kod onu hesaplayabilir. Modelden böyle bir değer istendiğinde yanlış gitmenin iki yolu var. Yanlış bir değer döndürebilir ve tasarım onu kabul edebilir, çünkü hiçbir şey onu yeniden hesaplamaz. İkisinin çaresi aynı: sormamak.

En güçlü biçim, alanı kaldırır. Model bir tutar önermek yerine hangi sipariş kalemlerinin etkilendiğini ve nedenini önerir. Tutarı sonra orchestrator türetir.

```
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
```

Bir sözleşme hâlâ modelin bir tutar vermesini istiyorsa, bu kitaptaki kanonik `issue_refund` sözleşmesinin yaptığı gibi, kod bu tutarı karşılaştırılacak bir iddia olarak ele alır: tutarı yeniden hesapla ve farklıysa çağrıyı reddet. Alansız sürümü savunmak bana daha kolay geliyor. Modelin yanlış verebileceği bir değer eksik ve "neden bu tutar?" diye soran bir reviewer, güvenilecek bir öneri yerine okunacak bir fonksiyon buluyor.

Uyarı: Modelden gelen ve yeniden hesaplanmadan `payments-service`'e giden bir iade tutarı, olasılıksal bir değere dayanan geri alınamaz bir yazmadır. Bu bölüm okunduktan sonra yalnızca tek bir şey değiştirilecekse, o şey tutarı kodun türettiği ya da yeniden hesapladığı bir değer yapmak olmalı.

Aynı gerekçe, açılış senaryosundaki öteki değerleri de kapsar. Para birimi siparişe aittir; dolayısıyla farklı bir para birimi taşıyan bir öneri reddedilir ve bir dönüşümü tetiklemez. Bir tarih ya da son tarih ("koli üç gün önce gelmeliydi"), sipariş verisindeki zaman damgalarından hesaplanır. Tavan gibi bir eşik politikadan okunur ve bir tamsayıyla karşılaştırılır. Bunların hiçbirisi bir modelin işin içinde olmasına ihtiyaç duymaz ve her biri, modelin dahil olmasının yalnızca yanlış olmanın bir yolunu ekleyebileceği bir yerdir.

Bir bedeli var. Hiçbir kuralın tarif etmediği kısmi ya da takdire bağlı iadeler ("üçte birini iade et, müşteri uzun süre bekledi") türetilmiş bir tutara uymaz. Bunlar için modele politikanın izin verdiği kısa bir tutar menüsü sunardım, örneğin ödenen fiyatın sabit birkaç kesri, ve menünün dışındaki her şeyi bir insana gönderirdim. Bu, açık bir sayıyı bir seçime çevirir; yani Örüntü 2'nin paraya uygulanmış hâlidir.

Örüntü 4: deterministik ön koşullar ve son koşullar

Ön koşul, bir etki başlamadan önce geçerli olması gereken bir olgudur ve gate onu denetler. Son koşul, sonra geçerli olması gereken bir olgudur ve onu da orchestrator denetler. Birlikte, etkiyi iki yanından kodla kuşatırlar.

`issue_refund` için ön koşullar sözleşmesinden gelir: sipariş bu run'ın müşterisine ait, ödeme tahsil edilmiş, tutar iade edilebilir bakiyeyi aşmıyor, `refund_ceiling`'in üstündeki bir iade onay gerektiriyor ve aynı

key'e sahip önceki hiçbir iadenin sonucu "bilinmiyor" değil; gate bunu önce durumu sorgulayarak ve bilinene kadar reddederek denetler. Bölüm 6 bunları sözleşmenin parçası olarak yazıyor, Bölüm 7 ise bağlı oldukları izinleri anlatıyor. Burada önemli olan ilke: her ön koşul, gate'in okuduğu olguların deterministik bir fonksiyonudur, önerinin kendisi hakkında öne sürdüğü hiçbir şeyin değil.

Son koşulları atlamak daha kolay ve daha sık eksik oluyor. "ok" döndüren bir etki çağrısı bir kanıt parçasıdır, hiçbir şey döndürmeyen bir timeout başka bir kanıt parçası. Hiçbiri `payments-service`'in neyi tuttuğunu söylemez. Son koşul, state'i geri okumaktır.

```
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
```


Bloğun neyi yapmadığına bakılmalı. Payments yazmasını ve kaydı tek bir transaction'a sarmaz, çünkü bunlar iki sistemdir ve hiçbir transaction ikisini kapsamaz. Niyeti önce yazar, böylece etki ile kayıt arasındaki bir çökme kanıt bırakır. Ve durumu geri okur, böylece sessiz bir kısmı hata (F6) tamamlanmış işaretlenen bir run olarak değil, başarısız bir son koşul olarak görünür. Geriye kalan açığın tespiti, yani eşleşen bir etkisi olmayan bir niyet, kayıt üzerinde çalışan bir reconciliation job'ıdır; Bölüm 10 ve Bölüm 20 buna dayanıyor.

Key'e bir kez daha bakmak gerekir, çünkü bir timeout'un ikinci bir iadeye dönüşmesini engelleyen odur. Yalnızca runtime'ın atadığı tanımlayıcılardan oluşturulur: ticket, sipariş ve iade niyeti. Run, step, tutar

ve reason code içinde yok. Çağrının timeout'a düştüğünü ve modelin sonraki bir step'te iadeyi başka bir tutarla yeniden önerdiğini varsayalım. Key aynıdır, dolayısıyla tool etkiyi iki kez uygulamak yerine ilk sonucu döndürür. Ve `issue_refund` sözleşmesine göre gate, durum sorgusu ne olduğunu söyleyene kadar, sonucu "bilinmiyor" olan bu key için başka bir iadeyi reddeder. Aynı siparişin başka kalemleri için meşru ikinci bir iade yeni bir iade niyetidir ve o yalnızca onay servisine kaydedilmiş bir insan kararından sonra verilir.

Bütün yolun biçimi

Aşağıdaki diyagram, sınırın çizildiği iade yolunu gösteriyor. Modelin işinin nerede bittiğine bakılmalı: öneride bitiyor ve ondan sonraki her kutu koddur. Ret yollarına da bakılmalı, çünkü bir prompt'un sağlayamayacağı kısım onlar.



Sınırı test edilebilir kılmak

Test edilemeyen bir sınır bir inançtır. Onu kodda çizmenin avantajı, gate'in bir fonksiyon olması: bir öneri, okuduğu olgular ve politika sürümü verildiğinde bir karar döndürür. O fonksiyonda olasılıksal hiçbir şey yok; dolayısıyla testinde bir modele gerek yok.

Gate'i, elle yazılmış ve olaylardan büyütülmüş bir öneri tablosuyla test ederdim. Her satır bir öneri, bir olgu kümesi ve reason code'uyla beklenen karardır. İlk olarak olmaya değer satırlar, hata sınıflarıyla eşleşenlerdir: eksik alanlı bir öneri (F1), seçim kümesinin dışında bir sipariş id'si (F2), zaten iade edilmiş bir kalem (F2), tavanın bir minor unit üstünde bir tutar (F7), siparişten farklı bir para birimi (F2), önceki bir iade niyetinin kopyası ve bu run'a sunulmamış bir tool için bir öneri. Bunların hiçbiri saldırıya benzeyen bir payload'a ihtiyaç duymaz ve hiçbiri model gerektirmez. Bunlar bir fonksiyonun girdileridir.

Bu, modelin veremeyeceği bir ölçü de verir. Eval'ler (Bölüm 21), modelin gate'in reddettiği bir şeyi ne sıklıkla önerdiğini söyler. Gate'in kendi testleri, gate'in onu reddettiğini söyler. İkisi ayrı sorulardır ve yalnızca

birincisine sahip bir ekip, kötü bir önerinin `payments-service`'e ulaşım sağlayamayacağını söyleyemez.

Model neden reddedildiğini söylemek

Gate bir öneriyi reddettiğinde `ret`, bir gözlem olarak bağlama döner ve model yeniden önerir. Bu yararlıdır, çünkü `not_in_choice_set` reddi çoğu zaman doğru bir ikinci öneriye yol açar. Aynı zamanda bir döngüdür ve bir döngünün sınırı olması gerekir.

```
function proposeWithFeedback(run, maxAttempts):           // say,
maxAttempts = 2
  attempts = 0
  while attempts < maxAttempts:
    bound.check(run)
    proposal = model.propose(assemblyContext(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
```

Bloktaki üç tercih bilinçli. Geri bildirim, iç state'ten derlenmiş serbest metin değil, sabit bir listeden çekilmiş bir reason code ve alan adlarıdır. Yeniden öneri sayısı küçüktür ve run'ın sınırlarına sayılır (Bölüm 12 ve Bölüm 13 bunları anlatıyor). Ve denemeler tükendiğinde çıta indirilmez, run bir insana devredilir. Döngüyü bitirmek için üçüncü denemeyi sonunda kabul eden bir gate, gate olmaktan çıkmıştır.

Bir uyarı daha. Geri bildirim, modelin bir sınırı yoklamasına izin vermemeli. İade edilebilir bakiyeyi aşan bir menü tutarının reddi `precondition_failed` ve alan adı `amount_minor` diyebilir ve orada durabilir; bakiyenin kendisini eklemek, bir sonraki öneriye tam altında duracağı bir sayı verir. `refund_ceiling`'in üstündeki bir iade hiç ret değil, `needs_approval`'dır ve o sayıyı gören kişi Sam'dir.

Replay ve neyin kaydedileceği

Cazip bir fikir, bir run'ı aynı girdiyi yeniden vererek yeniden üretmektir. Modelin etrafındaki kod için bu işe yarar, model için yaramaz. Aynı bağlam aynı öneriyi garanti etmez; dolayısıyla modele yapılan bir çağrıyı yeniden oynatmak yeniden üretim değil, yeni bir örnektir. Bölüm 2 nedenini veriyor ve bunun bu bölüm için sonucu, neyin saklanacağıyla ilgili.

Ne kaydedildiği, sonradan neyin yeniden kurulabileceğini belirler. Modelin çıktısı yeniden üretilebilir değildir, dolayısıyla saklanmalıdır: tam öneri, döndürüldüğü gibi. Gate yalnızca girdileri de saklanmışsa yeniden üretilebilir; bu da okuduğu olgular ve uyguladığı politika sürümü demektir. Etki, sonucu ve son koşuluyla saklanır. Bunlardan, herhangi bir run için önemli olan soru cevaplanabilir: bu etkiye, sistemin bildiği göz önüne alındığında, yürürlükteki kurallar izin veriyor muydu?

```
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
```

Bu kayıtla bir reviewer gate'i yeniden oynatabilir: saklanan öneriyi, saklanan olguları ve saklanan politika sürümünü alır, gate'i yeniden çalıştırır ve saklanan kararı elde eder. Karar farklıysa, gate ya da politika birinin bilmesi gereken bir biçimde değişmiştir. Bu deterministik bir regresyondur ve model davranışındaki bir değişiklikten bulması çok daha ucuzdur. Bölüm 10, bu kayıtların bulunduğu run store'u anlatıyor, Bölüm 20 trace biçimini anlatıyor ve Bölüm 21 kaydedilmiş önerileri eval'lere girdi olarak kullanıyor.

Ops agent: rollback sınırının durduğu yer

Destek agent'ı sınırı para üzerinde gösteriyor. Ops agent onu daha teşhise dayalı ve daha az sayısal bir kararda gösteriyor: yakın zamanlı bir deployment rollback edilmeli mi? `request_rollback` geri alınabilir bir

yazmadır, çünkü sonraki bir deployment önceki sürümü geri getirebilir ve politika onun için onay şart koşar. Bu, üç sahibin de iş başında görüleceği iyi bir yer yapar.

Nöbetteki Robin'i ve bir deployment sonrası hatalar için gelen bir alarmı hayal edelim. Ops agent log'ları, metric'leri ve bir trace'i okur ve model bir teşhis önerir: gerileme bir servisin son deployment'ıyla başladı ve bir rollback onu bitirir. Bu teşhis, dağınık kanıtlar üzerinde bir yargıdır ve model tam da bu iş için var. Sonra olan, ona bırakılmaz.

Step	Kim	Deterministik mi?
Bir teşhis ve adı verilmiş tek bir deployment'ın rollback'i önerilir	Model	Hayır, bir öneri
Adı verilen deployment'ın var olduğu, o servisin sonuncusu olduğu ve geri yüklenecek önceki bir sürümü bulunduğu denetlenir	Kod, <code>deploy-service</code> 'i okuyarak	Evet
Onun için hâlihazırda sürmekte olan bir rollback ya da flag değişikliği olmadığı denetlenir	Kod	Evet
Hata oranı metric'i deployment zamanından önce ve sonra okunur ve bir politika eşiğiyle karşılaştırılır	Kod, metrics store'u okuyarak	Evet
Kod tarafından hesaplanan bu kanıt, modelin açıklamasının yanında onay isteğine eklenir	Orchestrator	Evet
Onaylanır ya da reddedilir	Robin	Tam o çağrıya bağlı bir insan kararı
Rollback başlatılır ve deployment durumu geri okunur	Kod	Evet

En önemli adım dördüncüsü. Model, hata oranının "deploy'dan sonra ikiye katlandığını" söyleyebilir ve bu cümle bir iddiadır, belki de dayanaksız bir iddia (F3). Gate onunla tartışmaz. Kod metric'i kendisi okur, politikadan bir eşik uygular (örneğin deployment sonrası oran, deployment öncesi baseline'ı yapılandırılmış bir pencere boyunca yapılandırılmış bir marjla aşar) ve sayıları Robin'in önüne koyar. Veri eşiği karşılamıyorsa öneri, Robin kesintiye uğratılmadan reddedilir. Karşılıyorsa Robin, modelin düzyazısından değil, metrics store'dan gelen kanıtı görür.

```

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) }

```

Bu blok da Bölüm 5'teki gate'in kısmi bir görünümüdür; başarısız ön koşul `field` içinde adlandırılır. Kararlara bakılmalı. Blok hiçbir zaman `allow` döndürmez, çünkü politika, kanıt ne olursa olsun bu tool için onay şart koşar. Burada `allow` döndürebilecek bir fonksiyon, Robin'e ait bir kararı kodlamış olurdu. Bölünme, bu bölümün savunduğu bölünmedir: model teşhisi önerir, kod eşikleri denetler ve bir insan onaylar. Bölüm 15, bu onayı törenselsel değil gerçek yapan şeyin ne olduğunu anlatıyor.

Trade-off'lar ve maliyetler

Bir sınırın bir bedeli var ve bedel belirli yerlerde ödeniyor.

Katılık ve yanlış retler. Kod yorumlamaz. Bir kalem zaten iade edilmiş işaretlendiği için bir iadeyi reddeden gate, o işaretin yanlış olduğu nadir ticket'ı da reddeder. Her ret bir hand-off'tur ve her hand-off Sam'in ya da bir destek liderinin önüne düşer. Fazla sıkı çizilmiş bir sınır, modelin yapabileceği işleri insanlara gönderir ve ilk işareti bir hata değil, bir queue'dur.

Daha fazla kod ve doğru tutulacak daha fazla şey. Seçim kümeleri, politika tabloları, hesaplama fonksiyonları ve gate testleri, sahipleri olan yazılımdır. İçlerindeki eşikler değişen iş kararlarıdır ve kod ile iş sessizce birbirinden uzaklaşabilir. Birinin her sayıya sahip olması gerekir: iade

tavanı için Sam, rollback marjları için Robin ve platform ekibi, gate'in neyi reddetmesi gerektiğine dair sorular için güvenlik ekibi (Jordan). Bir eşiğin sahibi yoksa, kimsenin ayarlamadığı bir sınıra dönüşür.

Bir sınır bugünü kodlar. Modelin şimdi kötü yaptığı şeylerin etrafına çizilir. Modeller değişir ve model onda kötü olduğu için koda taşınan bir karar, sonradan modelin iyi halledeceği bir karar olabilir. Onu geri taşımak, kendi denetimleri olan bir tasarım kararıdır, bir konfigürasyon çevirmesi değil ve bir model değişikliği, öyle ele alınması gereken bir deploy'dur.

Gecikme ve step'ler. Olguları okumak, hesaplamak ve state'i geri okumak servislere çağrı ekler ve geri bildirimli bir ret bir model çağrısı ekler. Gate, öneri başına birkaç servis okuması ekler: bu, bir model çağrısının yanında ucuzdur, ama bedava değildir ve okuduğu her servisin gate çalıştığında erişilebilir olması gerekir. Olgularını okuyamayan bir gate reddetmeli ya da hand-off yapmalı ve bu davranış bilinçli seçilmelidir.

Ne zaman kullanılmaz. Sonucunu bir insanın okuyup attığı bir kararın, örneğin bir taslak özetin ya da aday runbook'ların sıralamasının etrafına sınır kurulmaz. Yanlış cevabın maliyetinin, bir bound'un zaten sınırladığı boşa giden bir step olduğu, keşfe dayalı, salt okunur bir araştırma için de kurulmaz. Koddaki kurallar, karar tekrarlandığında, doğrulanabilir olduğunda ve yanlışken maliyetli olduğunda bedelini çıkarır. Bunların hiçbirinin geçerli olmadığı yerde daha hafif bir kontrol daha iyidir ve bazen doğru kontrol, çıktıyı okuyan bir insandır.

Tiyatro. Her önerinin geçtiği bir schema bir onay kutusudur. Hiçbir önerinin ulaşamayacağı kadar yüksek ya da her önerinin onay gerektirip saniyeler içinde onaylanacağı kadar düşük ayarlanmış bir politika eşiği hiçbir şeyi korumaz. Her denetimin ne sıklıkla reddettiği ve sonra ne olduğu ölçülmeli, çünkü hiç ateşlenmeyen bir denetim ile hep ateşlenen bir denetim aynı özelliği taşır: bilgi taşımazlar.

Sık yapılan hatalar

- **Modelin aritmetik yapmasına izin verip onu modelle denetlemek.** Birincisini doğrulamak için yapılan ikinci bir model çağrısı, birincinin kör noktalarını paylaşır ve maliyet ekler. Kodda hesapla ya da kodda yeniden hesaplayıp karşılaştır.

- **Sessizce onaran validator'lar.** Tipleri dönüştürmek, bir tutarı tavana kırmak ya da eksik bir para birimini doldurmak, reddedilmiş bir öneriyi kimsenin önermediği kabul edilmiş bir öneriye çevirir. Reddedilir, kaydedilir ve önerinin yeniden yapılmasına izin verilir.
- **Tanımlayıcıları modelin hafızasından almak.** Modelin önceki bir ticket'ı hatırlayarak yazdığı bir sipariş id'si, geçerli müşterinin verisinden hiç okunmamış bir değerdir. Ona geçerli run'dan bir liste verilir ve üyelik denetlenir.
- **Sınırsız geri bildirim.** Her reddi ayrıntılı nedenlerle modele döndürmek ve süresiz yeniden denemesine izin vermek, sınırı yoklayan bir döngü yaratır. Denemeler sınırlanır, reason code gönderilir ve tükenince hand-off yapılır.
- **Sınırı bir kez çizmek.** Politikalar, tool'lar ve modeller değişir ve geçen çeyreğin davranışı için çizilmiş bir çizgi yanlış yerde durabilir. Bir tool eklendiğinde, bir model değiştiğinde ya da bir ret örüntüsü kaydığında karar envanteri gözden geçirilir.

Temel çıkarımlar

- Determinizm sınırı, karar başına çizilen, modelin önerebileceği ile kodun karara bağlaması gereken arasındaki bir çizgidir ve tasarımı, o bilinçli çizilip yazıya döküldüğünde gözden geçirmek daha kolaydır.
- Önce geri alınabilirlik, sonra doğrulanabilirlik, sıklık, tolerans ve açıklanabilirlik tartılır; geri alınamaz bir yazma ya da dış bir yan etki, model çoğunlukla haklı olsa bile bir kararı koda çeker.
- Model önerir ve kod karara bağlar: her öneri parse edilir, bir schema'ya karşı denetlenir, kodun kendi okuduğu olgulara karşı denetlenir ve bir etki başlamadan önce politikayla yargılanır.
- Modelin söyleyebilecekleri enum'lar, tanımlayıcı listeleri ve şablonlarla daraltılır ve önerilerin çoğunun seçtiği bir `other` değeri, kümenin üzerinde çalışılması gerektiğinin işareti sayılır.
- Para, tarihler ve eşikler kod tarafından hesaplanır; bir öneri böyle bir değer taşıyorsa gate onu yeniden hesaplar ve uyumsuzluğu reddeder ve yanlış verilebilecek en az değere sahip tasarım, alanı dışarıda bırakır.

- Gate, bir önerinin, olguların ve bir politika sürümünün fonksiyonudur, dolayısıyla model olmadan test edilebilir ve modele döndürülen retler kodlanmış, az ve sınırlı olmalıdır.
- Modeli yeniden oynatmak yeniden üretim değil, yeni bir örnektir; bu yüzden öneri, olgular, politika sürümü ve karar kaydedilir: bunlar birlikte gate'in yeniden oynatılmasına ve bir etkiye izin verilip verilmediğinin cevaplanmasına olanak tanır.

Bölüm 5, öneriye dönüyor: gate'e ulaşan şeyin gate'in denetleyebileceği bir şey olması için bir tool çağrısı nasıl istenir, biçimlendirilir ve alınır.

KISIM II

Tool'lar ve Yetki

Bölüm 5 — Tool Çağırma

Parcelport'u bir pazartesi sabahı hayal edelim. Bir müşteri, kolisinin eski bir adrese gittiğini yazıyor ve değiştirilmesini istiyor. Prototipte destek agent'ının döngüsü modelin çıktısını okuyor, bir tool adı ve bir argüman torbası biçiminde bir şey arıyor ve torbada ne varsa onunla eşleşen fonksiyonu çağırıyor. Ad hiçbir şeyle eşleşmezse döngü turn'ü atlıyor. Bir argüman eksikse glue kod boş bir değer geçiriyor. Tool bir sipariş kaydı döndürürse, müşterinin siparişi verirken yazdığı serbest metin not dahil, hepsi prompt'a geri giriyor.

Bu pazartesi modelin doğru sipariş ve yeni adresle `update_shipping_address` önerdiğini, ama glue kodun tanımadığı bir alan adıyla önerdiğini varsayalım. Adres alanı boş geliyor, servis boş değeri kabul ediyor, çünkü kimse ona kabul etmemesini söylememiştii ve döngü başarı bildiriyor. Tasarımda hiçbir şey geçerli bir çağrının neye benzediğini söylemiyordu; dolayısıyla hiçbir şey bunun geçerli olmadığını söyleyemezdi.

Bu bölüm kontrol zarfının **Öneri** ve **Etki** parçalarına ait. Öneri tarafından, modelin ne önerdiği ve bunun kanıtlanana kadar güvenilmez girdi olarak ele alınıp alınmadığı sorusunu cevaplıyor. Etki tarafından, onaylanmış bir çağrının dünyaya nasıl ulaştığını ve geriye ne döndüğünü cevaplıyor. Konu, tool çağırmanın mekaniği: bir çağrı nasıl istenir, parse edilir, doğrulanır, yürütülür, kaydedilir ve geri döndürülür ve bu yolun kısa ve denetlenebilir kalması için tool'lar nasıl biçimlendirilir.

Sorun ve neden zor olduğu

Tool, bir run'ın dünyaya dokunabildiği tek yoldur (Bölüm 1); dolayısıyla tool çağırısı, bir modelin metnin sonucları olan bir şeye dönüştüğü yerdir. Bu iki nokta arasındaki yol uzundur ve görüldüğünden fazla eklemi vardır. Modele mevcut tool'ların bir açıklaması gösterilir. Model, birini adlandırması ve argüman vermesi beklenen bir metin döndürür. Bir

şey o metni parse eder, bir şey sonucu denetler, bir şey onu çalıştırır, bir şey çalıştığını not eder ve sonuç, sonraki step için bağlama geri gider. Her ekleme, tasarımın modelin düzgün davrandığını sessizce varsayabileceği bir yerdir.

Gevşek bir yoldan doğan hatalar belirlidir. Parse edilemeyen bir öneri, eksik bir alan, yanlış bir tip ya da fazladan bir alan F1'dir (bozuk çıktı). Ticket'a uymayan bir tool'a yapılmış iyi biçimlenmiş bir çağrı ya da siparişe uymayan değerlerle yapılmış bir çağrı F2'dir (yanlış tool ya da yanlış argümanlar). Bir sistemde başarılı olan, sonraki step'in ise başarısız olduğu ve run'ın tamamlanmış işaretlendiği bir yazma F6'dır (sessiz kısmı hata). Başkasının metnini bağlama taşıyan bir tool sonucu, Bölüm 16'nın geliştirdiği F4'ün (talimat ele geçirme) giriş noktasıdır. Ve neyin önerildiğine, neye izin verildiğine ve ne olduğuna dair kayıt bırakmayan bir çağrı F8'dir (gözlenmeyen davranış).


Bariz yaklaşım, tool'ları iyi tarif edip çıktıya güvenmektir. İyi bir açıklama kötü önerilerin oranını gerçekten düşürür ve ben iyi açıklamalar yazardım. Ama bir açıklama bir istektir ve önemli olan, onu yok sayan önerilerdir. Bölüm 2, modelin ara sıra tam bir güvenle yanlış olmasının nedenlerini veriyor. Tool çağırma için sonuç açıktır: her çağrı, geçerli bir çağrının biçimini bilen koddan geçmelidir ve o kod modelin işbirliğine bağlı olmamalıdır.

İkinci bir güçlük daha var ve daha sessiz. Yol, tesisat gibi görünen ama aslında politika olan küçük kararlarla dolu. Bilinmeyen bir tool adına ne olur? Eksik bir alan varsayılan mı bağlanır, reddedilir mi? Bir sonuç ne kadar büyük olabilir? Bir timeout çağrının başarısız olduğu anlamına mı gelir, yoksa kimsenin bilmediği anlamına mı? Bunların her birini biri cevaplar, cevabı kimse seçmemiş olsa bile. Yukarıdaki prototipte cevaplar "atla", "varsayılan ver" ve "başarı"ydı. Hiçbir zaman gözden geçirilmediler, çünkü hiçbir zaman karar olarak yazılmadılar.

Bu yüzden bu bir mühendislik sorusu. Açıklamaya uyulmadığında ne olacağını yalnızca kod düzeltebilir ve önerilen her çağrının hem kaydedilen hem modele gösterilen tam olarak bir sonuç almasını yalnızca kod sağlayabilir.

Tool çağrısı yolu

Yolu yedi istasyon olarak, şu sırayla düzenlerdim: öner, parse et, doğrula, yetkilendir, yürüt, kaydet ve döndür. İlki modelindir. Geri kalanı orchestrator'a ve gate'e aittir ve hiçbirisi olasılıksal değildir. Aşağıdaki diyagram tek bir çağrı için yolu gösteriyor. Bir çağrının erken ayrılabilceği yerlere bakılmalı, hepsi bağlama dönen bir retle biter; cevabın "başarısız" değil "bilinmiyor" olduğu tek yere de bakılmalı.



Yol, tool çağrısı dalı açılmış hâliyle döngünün kanonik step'idir. Adlar Bölüm 1'den beri kullanılanlardır: `gate.check` "allow", "refuse" ya da "needs_approval" döndürür, `suspend run`'ı bir insana devreder ve `effect.apply` bir şeyi değiştiren tek fonksiyondur. Bu bölümün eklediği, bunların iki yanında olanlardır.

Öner ve parse et

Modele her biri bir ad, bir açıklama ve bir input schema'sı olan bir tool listesi gösterilir ve model bir öneri döndürür. Önerinin nasıl taşındığı, sağlayıcının ve adapter'ın bir özelliğidir. Bazı sağlayıcılar yapılandırılmış tool çağrılarını ayrı bir alanda döndürür, bazıları adapter'ın içinden bir çağrı çıkarması gereken metin döndürür ve biçimler farklıdır ve değişir. Hepsini küçük bir adapter'ın içinde tutardım ve çıktısını her seferinde aynı soyut öneri yapardım: `{ kind: "tool_call", tool: name, arguments: record }`. Aşağı akıştaki hiçbir şey onu hangi sağlayıcının ürettiğini bilmemeli, çünkü model değiştirildiğinde tasarımın ayakta kalması gerekir.

Parser'ın tek bir işi var: ham çıktıyı bir öneriye çevirmek ya da çeviremediğini söylemek. Tahmin yürütmez.

```
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`, `model.propose`'un son halkasıdır; soyut fonksiyon onu gizler. Bir `MalformedProposal`, aynı reason code'la bir `"refuse"` kararına dönüşür. Step, ham çıktıdan sınırlı bir alıntıyı kaydeder (önce redact edilmiş olarak, çünkü ham bir çıktı ticket'ın içerdiği her şeyi içerebilir; Bölüm 17 redaction'ı anlatıyor) ve model kısa bir bildirim görür. İki noktaya dikkat etmek gerekir. Bilinmeyen ad, Parcelport'un sahip olduğu her tool'a karşı değil, **bu run'a sunulan** tool'lara karşı denetlenir; dolayısıyla run'a hiç verilmemiş bir tool'a adını anarak ulaşamaz. Ve parser asla onarmaz. Tool adı yanlış harf büyüklüğünde olan ya da argümanları fazladan bir katmana sarılmış bir öneri sessizce düzeltilmez. Bölüm 4 katılığın gerekçesini ortaya koyuyor; bir retin maliyeti bir model çağrısıdır, tahmini bir onarımın maliyeti ise kimsenin gözden geçirmediği bir karardır.

Saymak üzerine bir söz. Hiçbir tool'la eşleşmeyen bir ad yapısal bir hatadır ve onu F1 sayardım. Run'a sunulmamış gerçek bir tool'la eşleşen bir ad F2'ye daha yakındır, çünkü öneri iyi biçimlenmiştir ve seçim yanlıştır. Ayrım kayıt için önemlidir, çünkü ikisi farklı düzeltmelere işaret eder: birincisi tool'ların nasıl tarif edildiğine, ikincisi sunulan kümenin nasıl kurulduğuna.

Sözleşmeye karşı doğrula

Doğrulama, argümanları tool'un input schema'sına karşı denetler: gerekli alanlar var, bilinmeyen alan yok, değerler doğru tipte ve belirtilen enumeration içinde. `gate.check`'in içinde, olguları okuyan denetimlerin önünde yer alır, çünkü iyi biçimlenmemiş bir çağrı hiçbir şeye karşı değerlendirilemez.

```

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

```

Her tool bu fonksiyondan geçer, okumalar dahil. Bir okuma için gate incedir: schema, allowlist (tool adı için parser'dan, tanımlayıcılar için seçim kümesi denetiminden gelen `not_in_choice_set`) ve `permitted` içindeki sahiplik denetimi işi yapar; onay ve idempotency key yoktur. Bir okuma sözleşmesi yine de ön koşullar taşıyabilir.

Sıra bir tasarım tercihidir. Önce schema, çünkü olgulara ihtiyaç duymaz. İzin ön koşullardan önce, çünkü bir ön koşul denetimi veri okur ve dokunmaya hakkı olmayan bir principal için bir sipariş okumazdım. Argüman bağlama ve taint denetimi, schema ve seçim kümesi denetimlerinin hemen ardından gelir, çünkü yalnızca run'ı okurlar, bir servisi değil. Onay en sonda, çünkü zaten reddedilecek bir çağrı hakkında bir insana sormak, yoldaki tek kıt kaynağı boşa harcar. Blok bir taslaktır:

`inputSchema` ve `preconditions`'ı sağlayan sözleşme Bölüm 6'nın konusu, izin testi Bölüm 7'nin, onay isteği ise Bölüm 15'in. Burada önemli olan, her denetimin konumu ve `bindCall`'ın, runtime'ın modelin hiç vermediği şeyleri eklediği yer olmasıdır: idempotency key ve orchestrator'ın kendi ürettiği bir çağrı tanımlayıcısı; bu tek çağrı için credential ise etki çalışırken tool gateway'den gelir. Kitap boyunca kullanılan karar reason'ları Ek'te listelenmiştir; kilitlenmiş bir run (Bölüm 16) reason olarak `run_locked` taşır, çoğunlukla `needs_approval` üzerinde ve kuralı öyle diyen tool'lar için bir retle birlikte. Planlı bir run (Bölüm 12), izin testinin hemen ardına bir görev kapsamı ve bir plan sınıfı denetimi ekler ve `outside_task_scope` ya da `off_plan` ile reddeder.

Yetkilendir, yürüt, kaydet, döndür

Gate'in ötesinde, yürütmenin geri kalanının hata altında doğru olması gerekir. Niyet etkiden önce kaydedilir, böylece ikisi arasındaki bir çökme yine de iz bırakır. Bir timeout bir hata değildir. Etki ve sonucu sonra kaydedilir ve modele dönen şey ham sonuç değil, biçimlendirilmiş bir gözlemdir.

```
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))
```

Run store ile etkinin hedefi ayrı sistemlerdir ve hiçbir tek transaction ikisini birden kapsamaz. Dolayısıyla blok bir garanti değil, bir sıra gösteriyor. İşlem `effect.apply`'dan sonra ve ikinci `record`'dan önce ölürse kayıt, sonucu olmayan bir niyet tutar. Açığı kapatan şey, bu tür niyetleri bulup hedef servise ne olduğunu soran bir kurtarma taramasıdır;

o olmadan açık F6'dır. Bir okuma için tarama yapacak bir şey bulmaz ve niyet atlanabilir; yani örüntü, yazmalar ve dış yan etkiler için bedelini çıkarır.

Geçersiz bir öneriyi ele almak

Bozuk bir öneri için verilen ret modele döner ve model yeniden önerir. Bölüm 4'te bunun döngüsü ve sınırı var: run'a sayılan az sayıda yeniden öneri ve bunlar tükendiğinde run'ı bir insana devretmek. Tekrarlamayacağım. Bu bölümün eklediği, hangi retlerin bir düzeltme turn'ünü hak ettiğine nasıl karar verileceği.

Ne yanlış gitti	Sınıf	Düzeltilme turn'ü?	Neden
Çıktıda çıkarılabilir bir çağrı yok	F1	Evet, bir kez	Ucuz ve bildirim, saklamaya değer bir bilgi taşıyor
Tool adı hiçbir şeyle eşleşmiyor	F1	Evet	Bildirim sunulan tool adlarını listeleyebilir
Tool gerçek, ama bu run'a sunulmamış	F2	Evet ve say	Öneri, sunulan kümeden farklı bir tool listesinden gelmiş olabilir
Eksik alan, fazladan alan, yanlış tip	F1	Evet	Bildirim alanları adlandırır ve düzeltme mekaniktir
Geçerli biçim, sipariş bu ticket'ta yok	F2	Dikkatli	Bildirim, bir sonraki tahmini iyileştirecek olguları vermemeli
Ön koşul başarısız ya da izin yok	F2 (gate'in engellediği bir F7)	Nadiren	İkinci deneme, aynı etki için yeni bir istektir; cevap genellikle bir hand-off ya da düz bir açıklamadır
Tavanın üstünde	ret değil	Hayır	Karar "needs_approval" dır ve bir insan karar verir

Tablodaki örüntü şu: düzeltme turn'ü, düzeltmesi bildirimde olan hatalar içindir. Modele `order_id`'nin eksik olduğu söylenirse onu verebilir. Siparişin bu müşteriye ait olmadığı söylenirse, yararlı sonraki adım bir siparişe dair başka bir tahmin değildir. Birinci tür bir ya da iki denemeye değer. İkinci tür dünyanın durumuna ve politikaya aittir ve doğru karşılık genellikle agent'ın müşteriye söylediğini değiştirmek ya da devretmektir.

Her düzeltme turn'ü bir model çağrısıdır; dolayısıyla maliyet ve gecikme taşır ve hakkını bozuk çıktıya harcayan bir run F9'a (maliyet ya da gecikme patlaması) doğru gidiyordur. Tool başına düzeltme turn'ü oranını, modelle ilgili bir olgu olarak değil, tool'un tasarımının bir ölçüsü olarak izlerdim. Schema'sı çok düzeltme çeken bir tool, genellikle adı ya da argümanları kafa karıştırıcı olan bir tool'dur ve düzeltme tool'dadır.

Onarım konusunda birçok framework'ten daha katı bir çizgi izliyorum. Sondaki bir boşluğu ya da büyük harfli bir enum değerini normalize etmek zararsız görünür. Ama her normalizasyon, kimsenin okumadığı kodda verilmiş bir karardır ve kimse daha geniş kümeyi onaylamadan gate'in kabul ettiğini genişletir. Alternatif bir yazım kabul etmeye değiyorsa, onu review'un gördüğü ve testlerin kapsadığı schema'ya koymak gerekir.

Tool kümesini tasarlamak

Tool'lar kontrol sisteminin parçasıdır ve tasarımları, bir önerinin kaç şekilde yanlış gidebileceğini belirler. Yükün çoğunu dört tercih taşır.

Az sayıda tool, her biri tek iş yapan

Destek agent'ının yedi tool'u var (`lookup_order`, `get_customer_profile`, `search_docs`, `update_shipping_address`, `issue_refund`, `send_customer_reply` ve `escalate_to_human`) ve bir gerekçe olmadan sekizincisini eklemeye direnirdim. Sunulan kümedeki her tool, modelin her step'te okuduğu bir bağlam, yanlış yapabileceği bir seçim ve birinin yazması, test etmesi ve güncel tutması gereken bir sözleşmedir. Bir tool eklemekten önce, yeteneğin farklı ön koşulları olan farklı bir etki mi, yoksa var olanın yalnızca bir çeşitlemesi mi olduğunu sorardım. Çeşitlemeler, kapalı bir enumeration'la argümanlara aittir. Farklı etkiler ayrı tool'lara aittir.

Odak da sayı kadar önemlidir. Bir tool tek bir şey yapar ve adı hangisi olduğunu söyler. Model tool'lar arasından adlarını ve açıklamalarını kullanarak seçer; dolayısıyla `update_shipping_address` gibi bir ad `modify_order`'dan daha fazlasını taşır ve doğrudan tek bir etki sınıfına, tek bir ön koşul kümesine ve tek bir izne bağlanır.

Her şeyi yapan tool

Kaçınılacak örüntü, geniş tool'dur. Bir `action` (`change_address`, `refund`, `cancel`, `reship`) ve serbest bir `details` kaydı alan, açıklayıcı bir `manage_order` tool'u düşünelim. Cazip, çünkü model tek bir tool görüyor ve ekip tek bir entegrasyon yazıyor. Bedeli gate'te ortaya çıkar.

- Bir tool'un tek bir etki sınıfı vardır; dolayısıyla eylemlerinin en kötüsünü alır: geri alınamaz yazma. Zararsız olanlar dahil ona yapılan her çağrı, sanki para taşıyormuş gibi gate'ten geçirilir.
- `details` için input schema sıkı olamaz, çünkü biçimi eyleme bağlıdır. F1'i yakalamayı ucuz kılan katılık gitmiştir.
- Ön koşullar eyleme bağlıdır; dolayısıyla gate, tool'un içine gizlenmiş ikinci bir dispatch içermek zorundadır. Sözleşme artık tool'un ne yaptığını tarif etmez.
- İzinler eylem başına daraltılamaz. `manage_order`'a izin veren bir credential, hepsine izin verir.
- Kayıtlar ve trace'ler kabalaşır. "Agent `manage_order`'ı çağırdı" neredeyse hiçbir şey söylemez; "agent `issue_refund`'ı çağırdı" ne olduğunu söyler.

Bunların hiçbiri tool'un çalışmasını engellemez. Çalışan tool'u gözden geçirilemez kılar. Aynı bedel, destek agent'ına sunulan genel bir sorgu ya da shell tool'u gibi bir kaçış kapısı için de geçerlidir: bir tool ne kadar çok şey yapabilirse, gate belirli bir çağrı hakkında o kadar az şey söyleyebilir.

Okumalar ve yazmalar farklı tool'lardır

Bir okumayı ve bir yazmayı aynı tool'a koymazdım ve aynı servise dokunsalar bile onları ayrı tutardım. `lookup_order`, `orders-service`'ten okur ve `update_shipping_address`, `shipping-service`'e yazar; ilki hiçbir şeyi değiştirmez, ikincisi state'i değiştirir ve yalnızca koli bir kargo firmasındayken değil, öncesinde kullanılabilir. Ayrı tool'lara farklı etki sınıfları, farklı izinler (bir okuma scope'u ve bir yazma scope'u), farklı timeout'lar ve farklı retry kuralları verilebilir. Bir okuma paralel çalışabilir ve serbestçe retry edilebilir; bir yazma edilemez. Onları birleştiren bir tasarım, tüm bunları önemli olduğu noktada kaybeder.

Ayrım ikinci bir yoldan da karşılığını verir. Bir run'a sunulan tool kümesi run ilerledikçe değişirse, örneğin yazma tool'ları yalnızca sipariş aranıp ticket'ın müşterisine ait olduğu doğrulandıktan sonra görünürse, modelin önünde daha az yanlış seçim olur. Bu, Bölüm 4 anlamında seçim kümesinin daraltılmasıdır ve tool'lar zaten etkiye göre ayrılmışsa kurması ucuzdur.

Daha az argüman, hiçbiri yetki taşımasını

Modelin verdiği her argüman bir F2 yeridir. Bu yüzden runtime'ın zaten bildiklerini kaldırırdım. Model bir müşteri tanımlayıcısı, bir ticket tanımlayıcısı ya da çağırının kimliğini vermez: bunlar run'dan gelir ve gate siparişi onlara karşı denetler. Argüman listesi yalnızca modelin sağlayabileceği şeylere, örneğin siparişe ve yeni adrese iner ve bir önerinin başka bir principal'ı adlandırmasına izin verecek bir alan yoktur. Bölüm 7 bunun neden önemli olduğunu geliştiriyor (kimin yetkisinin kullanılacağını adlandıran bir alan, bir confused deputy'ye davettir) ve Bölüm 3, argümanlardaki sipariş tanımlayıcılarının mesaj metninden değil tool sonuçlarından gelmesi gerektiği yönündeki ilgili kuralı adlandırıyor (Bölüm 9 onu kuruyor).

Açıklamalar ayrı bir not hak ediyor. İyi bir açıklama tool'un ne yaptığını, neye ihtiyaç duyduğunu ve ne zaman kullanılmaması gerektiğini söyler ve yazmaya değer. Ama "bunu yalnızca sipariş arandıktan sonra çağır" bir istektir. Çağrılarının sırası önemliyse, bu sözleşmede gate'in uyguladığı bir ön koşuldur. Açıklama bundan söz edebilir, böylece model makul öneriler yapar; kontrol, denetimdir.

Kitap boyunca kullanılan sözleşme biçimindeki bir okuma tool'u, iyi küçük bir tool'da ne kadar az şey olduğunu gösteriyor. Bölüm 6 notasyonu alan alan geliştiriyor ve yazma tool'larını kuruyor; bu burada yalnızca biçimi göstermek için var.

```

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]

```

Bir okumanın bile sahiplik ön koşulu vardır. Yanlış müşterinin siparişini aramak zararsız bir hata değildir; o müşterinin PII'sini bu run'ın bağlamına koyar ve oradan bir yanıt ulaşabilir.

Bağlama ne döner

Çağrı bittiğinde sonuç, modele bir gözlem olarak geri gider ve bu, çoğu tasarımın ihmal ettiği tool çağırma yarısıdır. Sonuç, sonraki step'in girdisidir. Boyutu, biçimi, dili ve güvenilirliği, sonraki önerinin nasıl görüneceğini belirler.

Boyut

Her boyutta olmasına izin verilen bir tool sonucu, eninde sonunda modelin ihtiyaç duyduğu bir şeyi dışarı itecek, sonraki her step'in maliyetini artıracak ve görevin gerektirdiğinden fazla başkalarının metnini taşıyacak kadar büyür. Her tool'a adapter'ında bir çıktı sınırı verirdim, yalnızca tool'un döndürmesi amaçlanan alanları döndürürdüm ve kesmeyi açıkça işaretlerdim. Sessizce kırpılmış bir sonuç, tam görünen bir sonuçtur ve model sanki tamammış gibi cevap verir. Bağlamın bütünü bütçesi Bölüm 9'a ait; burada kural, tool'un kendi çıktısını sınırlamasıdır.

Biçim

Her gözlemi aynı fonksiyon biçimlendirir, böylece model ve kayıt tek bir biçim görür.

```
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 }
```

Bu blokta üç şey bilerek var. Projeksiyon, bir servis yarın bir alan eklerse biri onu seçene kadar modelin gördüğünün değişmemesi demektir. Redaction, gözlem bağlama girmeden ve kayıt yazılmadan önce gerçekleşir; böylece PII log'da olacağından daha erken çıkarılır. Ve `origin` ile `trust` etiketleri köken bilgisidir (Bölüm 9): bağlam derleyici tool verisini talimatlardan ayırt edebilir ve sonraki bir kontrol buna dayanır.

Kayıt hem ham sonucun digest'ini hem biçimlendirilmiş gözlemi tutmalıdır. On-call, modelin 6. step'te ne gördüğünü yeniden kurmak istiyorsa, cevap biçimlendirilmiş gözlemdir ve o olmadan F8 olası sonuçlardan biridir.

Hata dili

Bir hata, sonraki öneri için bilgidir. Metnini Parcelport yazar ve sabit bir listeden seçilir, asla bir upstream servisten aktarılmaz ve `retryable`'ı dürüstçe taşır. Bölüm 6 hata biçimini veriyor, Bölüm 4 ise probe'a dönüşen retler konusundaki uyarıyı.

```
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." } }
```

Ret gate'ten gelir ve öyle işaretlenir; bir tool'un verisinden farklı bir origin'dir. Böyle bir ret, tool kümesine bakmak için de iyi bir andır: model ancak durumu açıklayarak ya da `escalate_to_human`'ı çağırarak makul

biçimde tepki verebilir. İkisi de mevcut değilse tasarım modeli bir köşeye sıkıştırılmıştır ve köşe, tasarımın sorunudur.

Sonuç da güvenilirmez girdidir

Gözlemde başkası tarafından yazılmış her şey, Parcelport'un kontrol etmediği bir kaynaktan gelen veridir. Bir sipariş kaydı, bir müşterinin yazdığı bir not taşıyabilir. Bir kargo durumu bir açıklama taşıyabilir. `search_docs`'un döndürdüğü bir sayfa, okuyanından başka biri tarafından düzenlenmiş metin içerebilir. Hiçbiri talimat olarak okunmak için yazılmadı ve bir kısmı talimat gibi okunacak. F4'ün girdiği kapı budur; Bölüm 16 onun yuvası, Bölüm 8 ise üçüncü tarafların sunduğu tool'lar için aynı problemi ele alıyor.

Tool çağırma düzeyinde kontroller mütevazı ve çoğunlukla yapısaldır. Yalnızca görevin ihtiyaç duyduğu alanlar döndürülür; böylece serbest metin alanları yalnızca gerektiğinde görünür. Her gözlem origin'ile etiketlenir. Gözlem, politika işlevi gören her şeyin dışında tutulur. Ve güvenilirmez metinden gelen bir değer, denetimsiz hassas bir çağrıyı yönlendirmesine asla izin verilmez; taint fikri budur. Gate, bir çağrının neden haklı olduğuna dair modelin muhakemesini okumaz ve bir gözlemin içeriğini ona güvenilip güvenilmeyeceğine karar vermek için okumaz. Çağrıyı sözleşmeye ve olgulara karşı denetler. Bir siparişteki bir not, bir emir gibi okunan bir şey içerdiği gün de aynı tasarımın ayakta kalması böyle sağlanır.

Not: Bir alanı güvenilirmez diye etiketlemek, modelin ondan etkilenmesini engellemez. Etiket, neyin nereye akabileceğine karar vermek için onu kullanabilen kontrol kodu içindir. Koruma, her etkinin önündeki gate'tir ve model neden etkilenmiş olursa olsun geçerlidir.

Birkaç çağrı, yavaş çağrılar ve kısmi başarı

Aynı anda birden fazla çağrı

Bazı sağlayıcılar bir modelin tek bir yanıtta birkaç tool çağrısı döndürmesine izin verir, bazıları birer birer döndürür. Kullanılan sağlayıcının hangisini yaptığı adapter'ın bir özelliğidir ve tasarım her iki

durumda da çalışmalıdır. Birkaç tane olduğunda iki kural kullanırdım. Okumalar eşzamanlı çalışabilir, çünkü hiçbir şeyi değiştirmezler ve iki okuma birbirinin yan etkilerine bağlı değildir. Yazmalar eşzamanlı çalışmaz ve step başına en fazla bir yazmaya izin verirdim. Nedeni, aynı batch'teki sonraki bir çağrının, ilk yazmanın değiştirmek üzere olduğu bir bağlama karşı önerilmiş olmasıdır. Adres başta okundu; ona dayanan ikinci bir çağrı, F5 (kontrolden çıkan döngü ya da bayat bağlam) örüntüsünün minyatürüdür.

Ops agent için bu doğaldır. Aynı zaman penceresi için `query_logs`, `get_metrics` ve `get_trace` birlikte çalışabilir ve sonuçlar bundan yararlanır. `request_rollback` hiçbir zaman başka bir şeyle aynı step'i paylaşmaz, çünkü onay gerektirir ve sonrasında olanlar onun sonucuna bağlıdır.

```
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))
```

Bu bloktaki değişmez şudur: önerilen her çağrı tam olarak bir gözlem alır. Cevapsız bırakılan bir çağrı, bağlamı sonucu olmayan bir öneriyle bırakır ve sonraki öneri, deliği olan bir tablo üzerine kurulur. Ertelenmiş bir yazma, öteki retler gibi bir rettir ve model onu bir sonraki step'te, artık ilk

yazmanın sonucunu içeren bağlama karşı yeniden önerebilir. Tek yazma onay gerektiriyorsa `suspend`, bloğun son satırının gösterdiği gibi eşzamanlı okumalar döndükten sonra çalışır; böylece step, okumalar hâlâ açıkken insanı beklemez. Step deadline'ı geçtiğinde hâlâ sürmekte olan bir yazma, timeout'a düşmüş bir okuma değildir: bilinmeyen sonucu, bir etki kaydını ve bir durum sorgusunu alır. Bu nedenle step deadline'ı hiçbir zaman bir yazmanın sözleşme deadline'ından kısa olmamalıdır.

Maliyetler gerçektir. Yazmaları serileştirmek, iki bağımsız yazması olan bir run'ın iki step sürmesi demektir ve ticket başına step'i ölçen bir ekip bunu görecektir. Bu maliyeti kabul ediyorum, çünkü alternatif, paylaşılan state üzerindeki iç içe geçmiş etkiler hakkında akıl yürütmektir.

Timeout'lar

Böyle bir yolda üç saat var. Her çağrının sözleşmede belirlenmiş kendi timeout'u vardır. Step'in bir deadline'ı vardır, böylece eşzamanlı okumalardan oluşan bir batch, step'i en yavaş olan için açık tutamaz. Ve run'ın kendi sınırları vardır (Bölüm 13). Sayılar açıklayıcıdır: örneğin okuma çağrısı için 3 saniye, yazma için 10 ve step deadline'ı için 30. Bunlar servislerin özellikleridir ve onları izleyerek ayarlanmalıdır.

Bir timeout, farklı etki sınıfları için farklı anlamlara gelir. Bir okuma için timeout, retry edilebilir bir hatadır ve kaç retry'ı hak ettiğini Bölüm 14 anlatıyor. Bir yazma ya da dış yan etki için ise öyle bir şey değildir.

Uyarı: Bir yazmadaki timeout bir hata değil, bilinmeyen bir sonuçtur. Servis etkiyi uygulamış olabilir ve retry etkiyi iki kez uygulayabilir. Sonuç bilinmiyor sayılmalı, servise o çağrının durumu sorulmalı ve yalnızca bir cevap geldiğinde retry edilmelidir. Idempotency key (Bölüm 6) bir tekrarın ilk sonucu döndürmesini sağlar, ama iki dünyadan hangisinde olunduğunu söyleyen şey durum sorgusudur.


Bu durumda modelin aldığı gözlem, sonucun bilinmediğini ve durumun kontrol edildiğini söyler. "Başarısız" demez, çünkü bir iadenin başarısız olduğu söylenen bir model onu yeniden önerebilir. `outcome_unknown` kodu `issue_refund` sözleşmesinde bu yüzden var.

Kısmi başarı

Kısmi başarı üç ölçekte gelir ve her biri kendi cevabını ister. Bir batch'in içinde, üç okumadan biri timeout'a düşer. İki sonuç döner ve üçüncüsü yukarıdaki blokta olduğu gibi timeout'a düşmüş olarak bildirilir; agent, eksik sonuç boşmuş gibi ilerlemez. Tek bir tool'un içinde, iki sisteme dokunan bir çağrı birinde başarılı olabilir; tool'un sonucu bunu bir alanda söylemelidir ve sözleşme hangi parçaların ayrı ayrı başarısız olabileceğini belirtir. Step'ler boyunca, bir iade `payments-service`'te kaydedilebilir ve sonraki `send_customer_reply` timeout'a düşebilir.

Bunların sonuncusu klasik F6'dır ve tasarım cevabı, açığı görünür ve sınırlı kılmaştır. Herhangi bir çağrının sonucu bilinmezken run tamamlanmış işaretlenmez. Yazmaların sırası bilinçli seçilir (önce para, sonra ona atıfta bulunan mesaj; çünkü gerçekleşmemiş bir iadeyi vaat eden bir yanıt, geç yanıtı bir iadedden daha kötüdür), her biri bir niyet ve bir etki olarak kaydedilir ve her çağrının durumu run store'da durur (Bölüm 10).

Diyagram, tek bir çağrının geçtiği durumları gösteriyor. `OutcomeUnknown`'a bakılmalı: bir durum sorgusuyla çözülür ve sorgu cevaplayamazsa çağrı, hâlâ bilinmiyor olarak etiketli biçimde modele döner, asla hata olarak yeniden etiketlenmez.



Çözülmeden kalan bir çağrı sessizlikle değil, bir hand-off ile biter: bir insan bakar ve bir reconciliation job'ı (Bölüm 10 ve 20) run içinde yüzeye çıkmayan vakaları yakalar. Çözülmemiş çağrılarla biten bir run'ı bir istatistik olarak değil, olay düzeyinde bir sinyal olarak saymamın nedeni de budur.

Trade-off'lar ve maliyetler

Yoldaki her istasyon bir şeye mal olur ve maliyetlerin bir kısmını insanlar öder.

Katı parser ve validator model çağrılarına mal olur. Reddedilen her öneri, gecikmesi ve harcamasıyla bir gidiş-dönüştür ve schema'ları sıkılaştıran bir ekip, gate'e ulaşan kötü çağrılarının azaldığını görmeden önce düzeltme turn'lerinin arttığını görür. Yarar, gate'in denetleyebileceği bir yapı görmesidir. Tool bazında düzeltme oranı, tool'un kalitesine dair bir sinyal olarak izlenmeli ve yüksek olduğunda açıklamalar yeniden gözden geçirilmelidir.

Her yazmadan önce niyeti kaydetmek, run store'a bir yazma ve işletilecek bir kurtarma taraması ekler. Yazmalar ve dış yan etkiler için buna değdiğini düşünüyorum. Okumalar için bu bir ek yüküdür ve orada niyet kaydını atlayıp etki kaydını tutardım. Tarama, birinin sahip olduğu ve birine alarm gönderilen bir job'dır ve bir runbook'a ihtiyaç duyar. Kimsenin izlemediği bir tarama tiyatrodur.

Tool'ları bölmek tool sayısını artırır, bu da bağlama ve seçim doğruluğuna mal olur; birleştirmek sayıyı düşürür ve gate'e kaldırıcını kaybettirir. Agent için doğru sayıyı bilmiyorum; etkilerin ne kadar farklı olduğuna bağlıdır ve nasıl anlaşılacağı şöyle: iki eylem farklı ön koşullar, izinler ya da timeout'lar gerektirecekse, iki tool'dur.

Sonuçları kesmek ve projekte etmek maliyeti ve maruziyeti düşürür ve modelin kullanabileceği bilgiyi de kaldırır. Bazı görevler gerçekten uzun nota ya da tam kayda ihtiyaç duyar. Bu, tool başına ve alan başına, kaydedilmiş bir gerekçeyle verilen bir karar olmalı; servisin döndürdüğü her şeyin bir tesadüf olması.

Yazmaları serileştirmek, zaman aşımalarını bilinmeyen sonuç olarak ele almak ve durum sorguları çalıştırmak step, gecikme ve kod ekler. Karşılığını vermediği yerler: salt okunur bir agent, tool'ları hiçbir şeyi değiştiremeyen bir prototip ve yanlış bir yazmanın geri alınmasının ucuz ve hemen görünür olduğu bir görev. Orada bile parser'ı ve schema denetimini tutardım, çünkü neredeyse hiçbir şeye mal olmazlar ve hangi kontrollerin neden atlandığını yazıya dökerdim; böylece agent ilk yazma tool'unu kazandığında karar görünür olur.

Sık yapılan hatalar

- **Tool adını güvenilir saymak.** Cazip, çünkü ad, listeyi görmüş bir modelden geldi. Ad bu run'ın sunulan kümesine karşı denetlenmeli ve başka her şey reddedilmeli.
- **Eksik argümanları varsayılanla bağlamak.** Cazip, çünkü çağrı o zaman "sadece çalışıyor". Bir varsayılan F1'i F2'ye çevirir; reddedilmeli ve varsayılanı schema bildirmeli.
- **Upstream hata metnini aktarmak.** Cazip, çünkü upstream mesajı zaten yazılmış ve ayrıntılı. İç ayrıntı ve güvenilirmez metin taşıyabilir; hatalar Parcelport'un yazdığı kodlanmış mesajlara eşlenmeli.

- **Kayıtların tamamını döndürmek.** Cazip, çünkü tool o zaman görev başına düşünce gerektirmiyor. Görevin ihtiyaç duyduğu alanlara projekte edilmeli ve kesme işaretlenmeli.
- **Bir yazmadaki timeout'u hata olarak okumak.** Cazip, çünkü timeout hataya benziyor ve retry güvenli görünüyor. İkinci iadeyi üretir; bu bilinmeyen sonuç sayılmalı ve durum sorgulanmalı.
- **Okumaların ve yazmaların bir tool'u paylaşmasına izin vermek.** Cazip, çünkü tek tool daha kısa bir liste demek. Tool en kötü etki sınıfını alır; etkiye göre bölünmeli.
- **Önerilen bir çağrıyı cevapsız bırakmak.** Cazip, çünkü atlanmış bir çağrı hiçbir şeye mal olmuyor gibi görünüyor. Önerilen her çağrı, ertelenmiş olanlar dahil, tam olarak bir gözlem alır.
- **Çağrılarının sırasını bir açıklamaya yazmak.** Cazip, çünkü tek satırlık bir değişiklik ve çoğunlukla işe yarıyor. Sırasız çağrılarının oranını düşürür ama onları engellemez; sıra bir ön koşul hâline getirilmeli.
- **Modelin kimlik sağlamasına izin vermek.** Cazip, çünkü tool bir müşteriye ihtiyaç duyuyor ve modelin bağlamında bir tane var. Bir `customer_id` argümanı öneriyi kendi kendini yetkilendiren hâle getirir; kimlik run'dan alınmalı.

Temel çıkarımlar

- Tool çağırma, bir önerinin etkiye dönüştüğü yoldur ve istasyonları (öner, parse et, doğrula, yetkilendir, yürüt, kaydet, döndür) ilki hariç her yerde deterministik koddur.
- Katı biçimde parse edilmeli ve doğrulanmalı, asla sessizce onarılmamalı; bilinmeyen bir ad bu run'a sunulan tool'lara karşı denetlenir ve bir ret bir model çağrısına mal olur, bu da kimsenin gözden geçirmediği bir tahminden ucuzdur.
- Düzeltme turn'ü, düzeltmesi bildirimde olan hatalar için değerlidir; bildirimin modele bir sınırı yoklayacak olguları vereceği retler için değil.
- Her biri tek etkili az sayıda tool tercih edilmeli, okumalar ve yazmalar ayrı tutulmalı ve argümanlardan runtime'ın zaten bildiği her şey, özellikle kimlik, çıkarılmalı.

- Gözlem, sonraki step'in girdisidir: onu projekte etmek, sınırlamak, kesmeyi işaretlemek, hataları Parcelport'un kendi sözleriyle yazmak ve origin'ini etiketlemek gerekir, çünkü içinde başkasının yazdığı her şey güvenilirmez veridir.
- Okumalar birlikte çalışabilir, ama step başına bir yazmaya izin verilmeli, önerilen her çağrıya tam olarak bir gözlem verilmeli ve bir yazmadaki timeout, bir durum sorgusuyla çözülecek bilinmeyen bir sonuç olarak ele alınmalı.
- Etkiden önce niyeti, sonra sonucu kaydetmeli ve sonucu olmayan niyetler için bir tarama çalıştırmalı, çünkü run store ile servis arasında transaction yoktur.

Bölüm 6, doğrulama ve gate istasyonlarının neye karşı denetlediğini ele alıyor: bu bölümün başvurup durduğu schema'yı, ön koşulları, etki sınıfını, idempotency key'i ve hata biçimini yazıya döken tool sözleşmesini.

Bölüm 6 — Tool Sözleşmeleri

Parcelport'u, `payments-service` üzerinde geçen yavaş bir öğleden sonrada düşünelim. Bir müşteri kolisinin hasarlı geldiğini yazıyor ve destek agent'ı bir iade öneriyor. Arkadaki tool tek bir cümleyle ("Bir siparişi iade eder") ve bir sipariş kimliği, bir tutar ve bir para birimi içeren bir schema ile tanımlanmış. Çağrı gidiyor, `payments-service` iadeyi uyguluyor ve cevap hiç dönmüyor. Orchestrator bir timeout görüyor.

Timeout, bağlama bir gözlem olarak düşüyor. Sonraki step'te model iadeyi yeniden öneriyor; bu kez tutar yuvarlanmış ve gerekçe farklı. Schema iki öneriyi de kabul ediyor, çünkü ikisi de düzgün biçimlenmiş. Prompt "bir siparişi yalnızca bir kez iade et" diyor, tool açıklaması da aynısını söylüyor ve kodda bu cümlelerin hiçbirini okuyan yok. `payments-service`'in ikinci çağrısı da uyguladığını varsayalım. Kimse kötü bir satır yazmadı; tool, kendisi hakkında kodun denetleyebileceği hiçbir şey söylemedi.

Bu bölüm kontrol zarfının **Gate** parçasına ait ve **Etki**'ye de bir ayağı basıyor. Gate'ten şu soruyu cevaplıyor: "Bu öneri, bu principal için, şu anda etkiye dönüşebilir mi?" Etki'den ise şunu: "Onaylanmış bir eylem dünyaya nasıl ulaşır, onu ne sınırlar ve onu ne geri alabilir?" İkisinin cevabı da aynı belge: çağrının ne yapabileceğini, hangi koşullarda, ne sıklıkta yapabileceğini ve çalışmadığında ne döneceğini söyleyen bir tool sözleşmesi. Dolayısıyla bu bölümün sorusu şu: ikinci iade paraya hiç ulaşmasını diye bir tool'un kendisi hakkında, kodun denetleyebileceği bir biçimde ne söylemesi gerekir?

Sorun ve neden zor olduğu

Bir schema tek bir soruyu cevaplar: bu, düzgün biçimlenmiş bir argüman listesi mi? F1'in (bozuk çıktı) arkasındaki soru budur ve önemlidir. Ama bir iade önerisi schema'sına tam olarak uyup yine de F2 (yanlış tool ya da yanlış argümanlar) olabilir: başka bir müşteriye ait bir sipariş, iade edilebilecek miktarın üstünde bir iade, ödmeden farklı bir para birimi.

Tutar `refund_ceiling`'in üstündeyse ve hiçbir insan onaylamamışsa F7 (yetkisiz etki) olabilir. Bir retry ikinci bir etki üretip kayıt tek bir etki gösterdiğinde de F6 (sessiz kısmi hata) olabilir.

Bunların hiçbir argümanların biçiminden görünmez. Hepsi, önerinin taşıyamayacağı olgulara bağlı: bu run'ın müşterisinin kim olduğu, `payments-service`'in neyi tuttuğu, aynı niyetle yapılmış önceki bir çağrının hâlâ çözümlenmemiş olup olmadığı. Bir schema değerleri tanımlar. Bir sözleşme ise çağrıyı kendi dünyası içinde tanımlar.

Akla gelen ilk çare kuralları açıklamanın içine koymak. "Siparişin toplamından fazlasını asla iade etme. Yalnızca capture edilmiş ödemeleri iade et. İki kez çağırma." Cazibesi gerçek, çünkü açıklama kötü önerilerin oranını düşürüyor; ama oradaki bir cümle bir talep, bir kontrol değil. Orada yazmaya değer her kural, model cevap verdikten sonra çalışan bir kod olarak da var olmalı.

İkinci akla gelen çare her şeyi tool'un kendisine zorlatmak. Tool'lar kendilerini savunmalı ve sahibi olan servis kendi state'i üzerinde son otorite. Ama bir servis her seferinde tek bir çağrı görür. Bu çağrının bir run'ın üçüncü önerisi olduğunu, ticket'ın siparişin sahibinden başka bir müşteriye ait olduğunu ya da önceki çağrının sonucunun hâlâ bilinmediğini bilmez. Gate bilir, çünkü run'ın, principal'ın ve olguların bulunduğu yerde durur.

Bu yüzden bu bir mühendislik sorusu, bir prompt sorusu değil. Sözleşmenin bir kez, gate'in, tool gateway'in, orchestrator'ın ve kaydın hepsinin okuyabileceği bir biçimde yazılması ve diğer her arayüz gibi test edilmesi gerekir. Bölümün geri kalanı bu biçimi kuruyor.


Bir sözleşme neleri içerir

Tool sözleşmesi, bir tool'un yazılı, makine tarafından denetlenebilir tanımıdır. Dokuz alanı vardır, her zaman aynı sırayla, ve gösterim bu kitap boyunca kullanılan gösterimdir.

Alan	Kimin okuduğu	Neyi kontrol ettiği
<code>name</code> , <code>description</code>	model, reviewer'lar	Modelin hangi önerileri yaptığı; bir ipucu, asla bir kontrol değil
<code>input schema</code>	model ve gate	Modelin sağladığı argümanların biçimi (F1)

Alan	Kimin okuduğu	Neyi kontrol ettiği
effect class	gate, politika, orchestrator	Çağrı için asgari kontrol kümesi
preconditions	gate	Dünyanın bu çağrıya şimdi izin verip vermediği (F2, F7)
idempotency	orchestrator, tool	Tekrarlanan bir çağrının yalnızca bir kez etki etmesi (F6)
permissions	gate, tool gateway	Çağrının altında çalıştığı kapsam ve principal
timeouts	orchestrator, tool gateway	Beklemenin ne zaman bırakılacağı ve o zaman ne yapılacağı
error shape	tool, gate, orchestrator	Ne döndüğü ve hangi kapalı sözlükle döndüğü

Tabloda sekiz satır var, çünkü **name** ve **description** bir satırı paylaşıyor; gösterimde ayrı alanlar. Aşağıdaki diyagram kimin neyi tükettiğini gösteriyor. Sözleşmenin ne kadar küçük bir kısmının modele ulaştığına bakılmalı: ad, açıklama ve input schema ile gözlem olarak geri dönen kodlu hatalar. Geri kalan her şey kontrol tarafında kalır, çünkü model öneri yapmak için ona ihtiyaç duymaz ve onunla tartışabilmemelidir.



Pratik sonuç şu: modelin gördüğü tanım sözleşmeden üretilir, onun yanında yazılmaz. Modelin gördüğü schema ile gate'in uyguladığı schema iki ayrı dosyada dururlarsa birbirinden uzaklaşırlar ve bu kayma, modele gösterilen schema'dan geçip gate'te takılan önerilerin sürekli akması olarak görünür.

Sözleşme kayda ne söyler

Bir sözleşme, bir çağrının ne kanıt bırakacağına da karar verir. Kayıt, her çağrı için tool adını, sözleşme sürümünü, etki sınıfını, kararı ve reason code'unu, idempotency key'i, çağrının altında çalıştığı kapsamı, timeout'a karşı harcanan süreyi ve varsa hata kodunu taşıyabilir. Her bir öge, sözleşmenin zaten tanımladığı bir alandır; dolayısıyla bir çağrının trace'i, kimsenin loglamayı hatırlamasına gerek kalmadan yeniden kurulabilir. Trace biçimi Bölüm 20'nin konusu; burada önemli olan, kaydedilen alanı olmayan bir sözleşmenin, bir tool çağrısının F8 (gözlenmeyen davranış) olarak nasıl bittiği olmasıdır: on-call, neyin istendiğini, neye izin verildiğini ya da ne olduğunu söyleyemez.

Kanonik sözleşme: `issue_refund`

Aşağıdaki sözleşme, bu kitabın her yerde kullandığı sözleşmedir ve Bölüm 4 bunun bazı kısımlarını zaten alıntılardı. Önce bir kez bütün olarak, sonra alan alan okunmalı.

```

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]

```

Input schema yalnızca modelin sağladığı şeyleri listeler ve `additionalProperties: false` başka her şeyin önündeki kapıyı kapatır. Neyin eksik olduğuna dikkat edilmeli: müşteri kimliği yok, ödeme referansı yok, idempotency key yok, ticket kimliği yok. Runtime'ın kendi başına bilebileceği her değer schema'nın dışında bırakılmıştır, çünkü modelin doldurduğu bir alan yanlış olabilecek bir alandır. Bölüm 4 bir adım daha ileri gidip `amount_minor`'ün de kaldırılmasını, tutarın kod tarafından sipariş kalemlerinden hesaplanmasını savunur. Kanonik sözleşme bu alanı tutuyor, çünkü gerçek iade akışlarının çoğu bir tutardan başlıyor ve alan kaldığında gate onu denetlenecek bir iddia olarak ele alır.

Preconditions, gate'in kendi başına okuduğu olgulardır; hangi sırayla okunduğuna döneceğim. Yazıldığı haliyle liste hakkında iki şey söylemeye değer. Tavan bir ret değil, bir karardır: `refund_ceiling`'in üstünde gate

needs approval döndürür ve karara bir insan (iadeler için Sam) varır. Ayrıca kanonik liste para birimi denetimini, iade edilebilir bakiyenin içinde örtük bırakıyor. Gerçek bir sözleşmede bunu bir ön koşul olarak açıkça yazardım: para birimi sipariş para birimine eşittir; çünkü yanlış para biriminde bir iade olan F2 örneği, bir testin bulabileceği bir satır olduğunda önlemesi ucuz bir şeydir.

Permissions satırı bir kapsamı ve bir delegasyonu adlandırır. Kapsam dardır (iade oluşturmak) ve delegasyon bu ticket'a bağlıdır. Credential'ın nasıl daraltılıp verildiğini Bölüm 7 anlatıyor; burada önemli olan sözleşmenin kapsamı adlandırması, böylece belirtilmiş bir kapsamı olmayan bir tool'un yayına çıkmadan review'da takılmasıdır.

Timeouts, üzerinden kolayca geçilen bir cümle içerir: bir timeout'tan sonra, herhangi bir retry'dan önce iade durumunu denetle. Timeout bir hata değildir: çağrıyı yapan beklemeyi bıraktı ve yazma olmuş da olmamış da olabilir; bu yüzden sözleşme state'in sahibine sormayı söyler.

Not: Sözleşmelerdeki sayılar (10s, 30s, tavan) açıklayıcıdır. Gerçek değerler, payments-service'in yük altında ne kadar sürdüğüne ve geç gelen bir cevabın bekleyen bir müşteriye neye mal olduğuna bağlıdır.

Etki sınıfları ve her birinin gerektirdikleri

Etki sınıfı, diğer alanlar için bir taban belirleyen tek alandır. Dört tane vardır: okuma, geri alınabilir yazma, geri alınamaz yazma ve dış yan etki. Bir çağrının insan onayı gerekip gerekmediğine sınıf değil, gate'teki politika karar verir; yani geri alınabilir bir yazma onay gerektirebilir (request_rollback) ve tavanın altındaki geri alınamaz bir yazma gerektirmeyebilir. Sınıfın belirlediği şey, sözleşmenin göstermesi gereken asgari kontrol kümesidir.

Etki sınıfı	Parcelport örneği	Sözleşmedeki asgari kontroller
okuma	lookup_order	Input schema, permissions kapsamı, timeout; bir çıktı sınırı (Bölüm 5); yalnızca verinin kim tarafından görülebileceği ya da kaynağının kabul edilip edilmediği hakkında bir ön koşul

Etki sınıfı	Parcelport örneği	Sözleşmedeki asgari kontroller
geri alınabilir yazma	<code>update_shipping_address</code>	Yukarıdakiler, artı ön koşullar, bir idempotency key ve adı konmuş bir geri dönüş yolu
geri alınamaz yazma	<code>issue_refund</code>	Yukarıdakiler, artı bilinmeyen sonuç kuralı, bir durum geri okuması ve onay için bir politika
dış yan etki	<code>send_customer_reply</code>	Yukarıdakiler, artı idempotency (tekrarlanan bir gönderim bir insana iki kez ulaşır), içerik denetimleri ve kaydedilmiş niyet

Tabloda aşağı indikçe kontroller birikir ve sözleşmeleri hızlıca gözden geçirmek için bunu kullanırım. İdempotency key'i olmayan bir yazma tool'u, çizildiği haliyle eksiktir. Bir okuma ön koşulu, verinin kim tarafından görülebileceğiyle ya da kaynağının kabul edilip edilmediğiyle ilgilidir; `lookup_order` üzerindeki sahiplik denetimi ya da `search_docs` üzerindeki kabul edilmiş-ve-sabitlenmiş denetimi (Bölüm 8) gibi, ve yanlış sınıfın işareti değildir. Çağrının kendisinin değiştirdiği bir state hakkında ön koşulu olan ya da bir şeyi değiştiren bir okuma, sınıfın yanlış olduğunu ya da tool'un söylediğinden fazlasını yaptığını düşündürür.

Bir tool'u sınıflandırmak, çağrının neler yapabileceği hakkında bir yargıdır ve üç durum özen ister. Birincisi, sınıf belirli bir çağrıya değil, tool'a aittir. Bazen bir notu düzenleyip bazen bir sevkiyatı iptal eden tek bir `update_order` tool'unun dürüst bir sınıfı yoktur ve çözüm, Bölüm 5'teki okuma ve yazma ayrımına benzer şekilde onu bölmektir. İkincisi, "geri alınabilir"in bir penceresi ve bir maliyeti vardır.

`update_shipping_address`, yalnızca `shipping-service` adresin değişmesine hâlâ izin verdiği sürece geri alınabilir bir yazmadır; bir kargo firması koliyi aldığı anda artık pratikte geri alınamaz. Sınıf, tool'un normalde neyle geri alınabildiğini söyler; ön koşullar ise ne zaman olduğunu söylemelidir. Üçüncüsü, bir dış yan etki eldeki hiçbir şeyle geri alınmaz. Müşteriye çıkmış bir cevap geri çekilemez; bu yüzden sözleşmenin ağırlığı gönderimden önce olanlara gider.

Etkilerin sıralanması tool'lar arasında da önem taşır. Bir iadeyi bir cevabın izlemesi, iki sistemde iki çağrıdır ve aralarındaki boşluk F6'nın yaşadığı yerdir: `payments-service`'te kaydedilmiş bir iade ve gönderilmemiş bir cevap, run ise tamamlanmış olarak işaretli. Hiçbir sözleşme bu boşluğu tek

başına kapatamaz. Sözleşmenin yapabildiği, her çağrının durumunu sorgulanabilir kılmaktır; kayıt üzerindeki bir reconciliation job'ının (Bölüm 10 ve 20) cevapsız iadeyi bulmasını sağlayan da budur.

Ön koşullar: gate'in okuduğu olgular üzerinde deterministik denetimler

Ön koşul, olguların bir fonksiyonudur; önerinin kendisi hakkında yaptığı bir beyan değildir. Öneri "bu sipariş benim" der ve gate buna inanmaz; siparişi okur ve sahibini run'ın müşterisiyle karşılaştırır. Bu, Bölüm 4'ün bir iddia ile bir olgu arasında çizdiği çizginin aynısıdır ve burada sözleşmenin beşinci alanı olarak yazılmıştır.

Gate'in ön koşulları değerlendirme sırası, sonuçları olan bir tasarım kararıdır. Aşağıdaki blok `issue_refund`'ı savunacağım bir sırayla denetliyor: önce schema, sonra siparişin üzerindeki yetki, sonra bu key hakkında bilinenler ve en son para. Bu blok, Bölüm 5'teki gate'in tek bir tool için kısmi bir görünümüdür ve o bölümün reason adlarını korur. (`refuse`, `allow` ve `needsApproval` kurucuları, `runStep`'in okuduğu karar kayıtlarını `"refuse"`, `"allow"` ve `"needs_approval"` türleriyle döndürür.)

```

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

```

Sıradaki üç ayrıntıya yakından bakmaya değer. Sözleşmedeki sahiplik ön koşulunun ("order belongs to the customer of this run") tek bir sahibi var: Bölüm 7'deki `checkAuthority`. Gate onun kararını bir evet ya da hayır olarak değil, bir karar olarak iletir: bir ret kendi reason'ını korur, böylece `not_permitted` bir ret olarak kalır, `upstream_unavailable` retryable kalır ve ulaşılamayan bir `orders-service` asla kalıcı bir ret olarak yeniden yazılmaz. Bu bölüm ikinci bir sahiplik kuralı tanımlamaz. Key durumu bakiyeden önce okunur, çünkü tamamlanmış bir iadenin replay'i, iade bakiyeyi zaten kullanmış olduğundan, aksi halde "geriye yeterli bakiye kalmadı" diye reddedilirdi ve model, tam olması gerekeni yapmış bir çağrı için bir hata görürdü. Bir replay'de gate ham öneriyi değil, ilk onaylandığı haliyle çağrıyı döndürür, çünkü tool gateway onaysız bir yazmayı `approval_required` ile reddeder ve bir replay, atlatılmış bir onay gibi

görünmemelidir. `approvedCallFor(key)`, o ilk çağrının ve onunla birlikte kaydedilen onayın aranmasıdır. Tamamlanmış bir iade yeniden denendiğinde onayın süresi dolmuş olabilir; bu yüzden onayı denetleyen kim olursa olsun, tool gateway ya da sahibi olan servis, onayın yaşına bakmadan önce zaten tamamlanmış bir key'i, saklanan ilk sonucu (`duplicate_replayed`) döndüren tool'a geçirmelidir; tamamlanmış bir key üzerindeki süre dolumu alarmı, meşru bir replay'i bir kusur gibi gösterirdi. Tavan kararı, yukarıdaki koşullardan sonra en son uygulanır; böylece olgular üzerinden reddedilecek bir çağrı hiçbir zaman bir insana ulaşmaz.


İki boşluk kalıyor ve hiçbir bloktaki bir hata değil. Birincisi zaman. Gate olguları denetim anında okudu ve yazma bir an sonra gerçekleşiyor; state arada değişebilir. Bu yüzden bir gate ön koşulu, hareketli bir olgu hakkında yalnızca bilgilendiricidir ve sahibi olan servis aynı kuralı yazma anında atomik olarak uygulamalıdır. Gate, kodlu ve erken bir ret vermek ve bilinen kötü önerileri servisten uzak tutmak için vardır; otorite servis olarak kalır. İkinci boşluk, gate'in okumalarının çağrı maliyeti olmasıdır: okuma gerektiren her ön koşul gecikme ve bir bağımlılık ekler; bunları aşağıdaki trade-off'larda sayıyorum.

Idempotency: key'i kim üretir

Bir **idempotency key**, bir tool'un tekrarlanan bir çağrıyla tanıyıp etkiyi iki kez uygulamak yerine ilk sonucu döndürmesini sağlar. Önemli olan soru key'i kimin ürettiğidir, çünkü cevap, key'in herhangi bir şeyi koruyup korumadığına karar verir.

Key'i model sağlıyorsa koruma gitmiştir. İadeyi yeniden öneren bir model, eski key'i önerdiği kadar kolay yeni bir key önerebilir ve ilkini tekrarlayacağını söyleyen hiçbir şey yoktur. Key run'dan ya da step'ten kuruluyorsa, sonraki bir step'te önerilen tekrar farklı bir key alır ve etkiyi yeniden uygular; açılıştaki durum tam olarak budur. Key tutarı ya da reason code'u içeriyorsa, "başka bir tutar ya da başka bir reason" ile yapılan tekrar farklı bir key alır ve bir timeout'u yeni bir önerinin izlemesinin ürettiği değişiklik tam olarak budur. Bu yüzden kanonik sözleşme key'i yalnızca runtime'ın atadığı tanımlayıcılardan kurar: ticket, sipariş ve bir iade niyeti.

Aşağıdaki sıra, açılış senaryosunu sözleşme üzerinden izliyor. Tekrarlanan öneriden sonraki iki dala ve hiçbirinin ikinci bir yazmaya ulaşmadığına bakılmalı.



İade niyeti, bu ticket ve sipariş için bir iadenin başlatıldığına dair runtime'ın kayıdır. İlk öneri onu oluşturur ve aynı ticket ile sipariş için sonraki her öneri ona eşlenir. Aynı siparişin başka kalemleri için ikinci, meşru bir iade yeni bir niyettir ve yalnızca onay servisinde kaydedilen bir

insan kararından sonra verilir. Tasarımın satın aldığı sürtünme budur ve bilinçlidir: aynı siparişte ikinci bir iade, bir insanın bakmasının istendiği durumdur.

`duplicate_replayed` sonucu dikkat ister. Hiçbir şey başarısız olmadığı halde, hiç kimse onu yeni bir başarı sanmasın diye error shape üzerinden bildirilir ve ayrıntıları ilk sonucu taşır: gerçekte iade edilen tutar ve durum. Bu, güvenliğin ötesinde de yararlıdır. Modelin müşteriye vereceği sonraki cevap, ikinci olarak önerdiği tutar yerine, bir tool sonucuna dayanan, iade edilmiş tutarı belirtebilir (cevap yanlış olanı alıntılaysaydı bir F3 riski, yani dayanaksız iddia olurdu).

Uyarı: Agent'ın idempotency key'i olmadan ya da modelin kontrol ettiği bir key ile ulaşabildiği geri alınamaz bir yazma, parayı iki kez hareket ettirebilir. Sahibi olan servis idempotency key'ini desteklemiyorsa, destekleyene kadar o tool'u agent'a geri alınamaz bir yazma olarak vermezdim. Servisin önüne konan bir tekilleştirme sarmalayıcısı kendi key tablosunu tutar ve birbirinden ayrışabilen iki depo, F6'nın saklanacağı yeni bir yerdir.

Anlaşmanın öbür yarısı tool'a aittir. Key'leri, bir yeniden önerinin ya da bir retry'nin makul biçimde gelebileceği süre kadar tutmalı ve argümanlar farklı olsa bile aynı key için ilk sonucu döndürmelidir. Bunun ne kadar olduğu, run'ların ne kadar sürebileceğine, ki bunu Bölüm 10 ele alıyor, ve bir insan onayının ne kadar bekleyebileceğine, ki bunu Bölüm 15 ele alıyor, bağlıdır. Bir sistem için doğru saklama süresini bilmiyorum. Bu iki sayıya bağlıdır ve en uzun run bitmeden süresi dolan bir key sahte bir güven verir.

İki sözleşme daha

Diğer tool'ların sözleşmeleri daha kısadır, çünkü alanlarının çoğu aynı örüntüyü izler. İkisini yazmaya değer, çünkü her biri farklı bir baskıyı gösteriyor.

update_shipping_address

Bu, hareket eden bir olgusu olan geri alınabilir bir yazmadır. Bir sevkiyatın adresi, bir kargo firması koliyi alana kadar değişebilir ve 2. step'te okunmuş bir adres 9. step'te bayatlamış olabilir (F5, kontrolden çıkan döngü ya da bayat bağlam). Bu yüzden sözleşme koşullu bir yazma kullanır.

```
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
```

İki nokta. Birincisi, `expected_version`, gate'in okumasını ve servisin yazmasını tek bir koşullu işlem yapar; daha önce anlatılan zaman boşluğunun cevabı budur. Sevkiyatın değiştiğini bulan bir yazma `precondition_failed` döndürür ve run, yeniden önermeden önce yeniden okur. İkincisi, yeni adres, güvenilir bir metin olan ticket'tan gelir. Belirli bir adres değişikliğinin onay gerektirip gerektirmeyeceği ya da müşteri profilinin zaten elinde tuttuğu bir kanal üzerinden bir teyit

gerektirip gerektirmeyeceği, Bölüm 7 ve Bölüm 16'nın ele aldığı bir politika sorusudur. Sözleşmenin işi çağırını denetlenebilir kılmaktır; böylece politikanın tutunacağı bir şey olur.

request_rollback

Ops agent için sözleşme alan olarak daha kısa, sonuç olarak daha ağırdır. Bu, kitabın sınıflandırmasına göre geri alınabilir bir yazmadır, çünkü sonraki bir deployment önceki sürümü geri getirebilir ve politika bunun için her zaman onay gerektirir.

```
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]
```

summary'nin, bir insanın onaylamadan önce okuduğu, model tarafından yazılmış bir metin olduğuna dikkat edilmeli. Güvenilmezdir, uzunluğu sınırlıdır ve onay isteğinde veri olarak gösterilir; bu da Bölüm 15'in konusudur. Timeout yorumuna da dikkat edilmeli. Çağrı, rollback tamamlandığında değil, istek kabul edildiğinde döner; bu yüzden son

koşul, deployment'ın state'ini okuyan tool'lar aracılığıyla yapılan bir okumadır. Başlatılan etki, bitmiş etki değildir ve sözleşme, timeout'unun ikisinden hangisini ölçtüğünü söylemek zorundadır.

Robin'in verdiği onay tam olarak o çağrıya bağlıdır: tool, argümanlar ve key. Bu değerler için geçerli bir onay olmadan `deploy-service`'e ulaşan bir çağrı `approval_required` döndürür. Bu kod ile gate'in "needs approval" kararı farklı şeylerdir ve farkın aşağıda kendi bölümü var.

Hata sözleşmesi

Error shape `{ code, message, retryable, details }` biçimindedir ve tasarım hedefi dardır: modelin buna göre davranabileceği ama modele kontrolü vermeyen bir mesaj. İçinde "50'nin üstündeki iadeler onay gerektirir" yazan bir bağlam, sonraki öneriye altında kalacağı bir sayı verir. İçinde "bu iade bir insanın kararını gerektiriyor" yazan bir bağlam ona ne bekleyeceğini söyler ve başka bir şey söylemez. Bu yüzden error shape, sabit metinli kapalı bir sözlüktür.

Kod	Kimin ürettiği	Retryable	Modelin gördüğü	Orchestrator'ın yaptığı
<code>invalid_arguments</code>	gate	hayır	Başarısız olan alanların adları	Sınırlı yeniden öneri (Bölüm 4 ve 12)
<code>precondition_failed</code>	gate ya da tool	hayır	Hangi ön koşul olduğu, adıyla; değer yok	Gözlem, ya da tekrarlanırsa hand-off
<code>approval_required</code>	tool gateway	hayır	"Onaylanmadı"nın ötesinde bir şey yok	Bir kusur ya da bayat bir onay olarak ele al; onay yoluna geri dön (Bölüm 15)
<code>not_permitted</code>	gate ya da tool gateway	hayır	Genel bir "bu görev için izin verilmiyor"	Kaydet; tekrarlanırsa hand-off
<code>duplicate_replayed</code>	tool	hayır	Replay olarak işaretlenmiş ilk sonuç	İlk sonuçtan devam et

Kod	Kimin ürettiği	Retryable	Modelin gördüğü	Orchestrator'ın yaptığı
upstream_unavailable	tool ya da servisi	evet	"Geçici olarak kullanılamıyor"	Aynı key ile, bir breaker altında, politikaya göre retry (Bölüm 13)
outcome_unknown	gate ya da tool	durum bilinene kadar	"Sonuç henüz bilinmiyor"	Durumu sorgula; reconcile et; çözülmezse hand-off
result_invalid	tool gateway	hayır	"Sonuç kullanılamaz"ın ötesinde bir şey yok	Sonucu at, kaydet, tekrarlanırsa hand-off; dış server'lardan gelen tool'lar için eklendi (Bölüm 8)

Tabloyu dört kural bir arada tutar. `message`, koda göre seçilen bir şablondur; iç state'ten derlenen bir metin değildir, çünkü bir upstream servisin cevabından kurulan bir hata mesajı müşteri verisini ya da stack trace'leri bağlama taşıyabilir. `details`, kod başına bir alan allowlist'idir; bu yüzden bir `precondition_failed` ön koşulu adlandırır, bakiyeyi, tavanı ve sahibi dışarıda bırakır. `retryable` bayrağı orchestrator içindir. Modele bir davet değildir; bir retry, aynı key ile retry politikası altında çalışır ve modelden hiçbir şeyi tekrarlaması istenmez. Ve kod kümesi kapalıdır: kanonik sözleşmenin yedi kodu ve bir sözleşmenin yalnızca dış server'lardan gelen tool'lar için eklediği `result_invalid`. Bir tool, orchestrator'ın tanımadığı bir kod döndürdüğünde temkinli varsayılan, tahmin yürütmek değil, reddetmek ve hand-off yapmaktır.

"Needs approval" kararı ile `approval_required` hatası arasındaki fark, bu kitabın durmadan çizdiği farktır. Karar, bir öneri bir insanı beklerken gate'in döndürdüğü şeydir ve run askıya alınır. Hata ise, bir çağrı geçerli bir onay olmadan bir tool'a ulaştığında tool gateway'in döndürdüğüdür; sağlıklı bir run'da bu, gate ile tool arasında bir şeylerin ters gittiği anlamına gelir: çağrı onaydan sonra değişti, onayın süresi doldu ya da yol atlatıldı. Buna alarm kurardım.

`outcome_unknown` mesajı modele sonucun henüz bilinmediğini söyleyebilir; bu, dürüst bir cevap yazmasına yardım eder, ama bu cümle bir nezaket. Kontrol, `gate`'teki rettir.

Modelin göremedikleri

Her tool'un davranışının bir kısmı modelin hiç okumadığı yerlerde yaşar: tavan, kapsamlar, key kurulumu, politika sürümü ve timeout'lar. Bunu öyle tutardım ve bunu sözleşmenin yapısında da söyledim.

Tavan, sözleşmede değil politikada yaşar; Bölüm 7 politikayı ve her kararla birlikte kaydedilen sürümünü gösteriyor.

Açıklama, büyük iadelerin bir insanın kararını gerektirdiğini söyleyebilir, çünkü bu beklenti oluşturur ve `gate`'in Sam'e göndermesi gereken önerilerin sayısını azaltır. Sınırı belirtmez. Açıklamadaki bir sınır bir hedeftir ve açıklamadaki sınırın, bir sonraki değişiklikten sonra politikadakinden farklı olması, iki doğruluk kaynağı olan bir tuzaktır.

Açıklamaları dürüst tutmak için tek bir alışkanlık kullanırım. Bir açıklamada bir kuralı belirten her cümle, sözleşmede onu uygulayan bir ön koşulu ve onu sınavan bir `gate` testini adlandırmalıdır. Denetim mekanik olabilir: kural gibi duran cümleleri ve ön koşulları yan yana listeleyen ve birinin eşi yoksa başarısız olan bir review adımı. Eşi olmayan cümleler tehlikelidir, çünkü kontrol gibi görünürler ve yalnızca birer taleptirler.

Aynı mantık dışarıdan gelen tool'lar için de geçerlidir. Üçüncü taraf bir server'ın yazdığı açıklama güvenilir bir girdidir ve `gate`'in kullandığı sözleşme Parcelport'un tarafında yazılmalıdır. Bölüm 8 buna geri dönüyor.

Sürümler ve sözleşme testleri

Bir sözleşme değişir ve bir sözleşmedeki değişiklik, davranıştaki bir değişikliktir. Sözleşmeyi, `issue_refund@3` gibi bir tanımlayıcısı olan ve her öneri ve kararla birlikte kaydedilen sürümlü bir artifact olarak ele alırım; böylece sonradan sorulan bir sorunun ("bu, o günün sözleşmesine göre izinli miydi?") cevabı olur. Registry her sürümü saklar ve `gate` güncel olana göre değerlendirir.

Her deęişiklik aynı ağırlıkta deęildir. Input schema'ya isteęe baęlı bir alan eklemek en hafifidir, ama modelin ne önerdiğini kaydırır ve bir eval çalıştırmasını hak eder (Bölüm 21). Bir ön koşulu sıkılaştırmak, gate'in eskiden izin verdiği önerileri reddeder; böylece ret oranı oynar ve döngü daha fazla gözlem görür. Bir ön koşulu gevşetmek ya da tavanı yükseltmek bir politika karardır ve o politikanın sahibi onu imzalar. Etki sınıfını deęiştirmek bir güvenlik review'u konusudur ve Jordan'ın soruları da işte burada devreye girer. İdempotency key'in bileşimini deęiştirmek ise tehlikeli olandır: dünkünden farklı kurulan bir key, dünkü henüz tamamlanmamış çağrılarla artık eşleşmez; bu yüzden deploy'dan önce başlamış bir çağrının tekrarı etkiyi iki kez uygular. Bu bir migration olarak ele alınmalı ve gate belirli bir süre boyunca iki key biçimini de denetlemeli.

Uzun süren run'lar sürümlerle yolun ortasında karşılaşır. Bir checkpoint'ten (Bölüm 10) resume edilen bir run, bir deęişiklikten önceki tool tanımlarını elinde tutuyor olabilir. Gate her zaman güncel sözleşmeye göre deęerlendirir ve orchestrator resume ettiğinde modelin gördüğü tanımları yeniden okur; böylece bayat bir schema üzerine kurulmuş bir öneri `invalid_arguments` ile reddedilir ve uygulanmaz.

Sözleşme testleri üç katmanda gelir ve hiçbirisi bir model gerektirmez.

- **Sözleşme denetimleri.** Her sözleşme üzerinde bir lint: dokuz alanın hepsi ya mevcut ya da bir gerekçeyle uygulanamaz diye işaretlenmiş, kapalı listeden bir etki sınıfı, her yazmada bir idempotency key, her çağrıda bir timeout, kapalı kümeden hata kodları ve yalnızca runtime'ın atadığı parçalardan oluşan bir key.
- **Gate testleri.** Beklenen karar ve kodla birlikte, Bölüm 4'ün anlattığı gibi bir öneriler ve olgular tablosu. Her ön koşul için: geçen bir satır, kalan bir satır ve sınır (tam tavan ve onun bir minor unit üstü). Yukarıdaki sıralamanın kendi satırı var: tamamlanmış bir iadenin replay'i bakiye hatası olarak deęil, bir replay olarak dönmelidir.
- **Tool conformance.** Servisin sahibi olan ekip tarafından çalıştırılır. Aynı key iki kez, bir etki ve ilk sonuç verir. Farklı bir tutarla aynı key, ilk sonucu verir. Yazmadan sonra enjekte edilen bir timeout `outcome_unknown` verir ve ardından durum sorgusu gerçeęi döndürür. Error shape sözleşmeyle eşleşir.

Üçüncü katman önemlidir, çünkü gate bir replay'e izin verir ve tool'un hiçbir şeye etki etmeyeceğine güvenir. Tool bunu yanlış uygularsa gate'in bunu bilmesinin yolu yoktur. Sahiplik katmanları izler: platform ekibi (Alex) lint'in ve gate testlerinin sahibidir, servis ekibi conformance'ın sahibidir ve güvenlik ekibi her değişiklikte etki sınıfını ve permissions'ı review eder.

Trade-off'lar ve maliyetler

Bir sözleşme her tool için yazım süresine mal olur ve maliyetin çoğu, düşünmenin zor olduğu yazmalara harcanır: ön koşulun ne olduğu, key'in neyden kurulduğu, geri dönüş yolunun ne olduğu. Bir okuma tool'u için sözleşme kısadır.

Gate'in okumalarının bir bedeli var. Bir olguyu okuyan her ön koşul bir çağrı ve bir bağımlılık ekler; iade denetiminin üç okuma yaptığını varsayalım, her biri bir step'e gecikme ve step'in başarısız olması için bir yol ekler. `orders-service` yavaşsa gate yavaştır. Yalnızca bir step içinde bayatlayamayacak olguları cache'lerdim ve gerisini gecikmeyi kabul ederek taze okurdum. Bayat olguları okuyan bir gate, bir hata sınıfını bir başkasıyla takas etmiştir.

Daha sıkı ön koşullar daha fazla ret demektir ve retler step'tir. Her yeniden öneri bir model çağrısına mal olur ve run'ın sınırlarına sayılır (Bölüm 12 ve 13). Doğru olan ama meşru önerilerin, diyelim, üçte birini reddeden bir sözleşme ticket'ları insanlara gönderir ve Sam bunu herhangi bir dashboard'dan önce fark eder. Denetim gevşetilerek değil, reddedilen öneriler okunarak ayarlanmalı.

İdempotency tasarımının insani maliyetleri var. İade niyetleri kayıt tutmayı gerektirir, key'ler depolama ve saklama gerektirir ve aynı siparişteki meşru bir ikinci iade bir insanın kararını gerektirir. Bu kararlar her seferinde saniyeler içinde onaylanıyorsa tiyatrodan ibarettir ve doğru hamle gereksinimi kaldırmak değil, politikayı incelemektir.

Tam sözleşmeyi yazmamanın zamanı: dokümantasyon okuyan bir prototip, küçük bir etki alanı olan ve PII içermeyen dahili bir okuma tool'u ya da bir geliştiricinin elle çalıştırdığı bir tool. Orada kısa bir biçim (schema, etki sınıfı, timeout, error shape) yeterlidir ve okuma yine de ince

gate'ten geçer. Yine de yazan herhangi bir şey için etki sınıfını ya da permissions kapsamını atlamazdım ve sonradan bir yazma kazanmış bir tool'da kısa bir sözleşmenin kalmasına izin vermezdim.

Bir sözleşmenin yetmediği yer: bir servisi idempotent yapamaz, bir ön koşulu race'siz yapamaz ve bir insan reviewer'ı dikkatli yapamaz. Niyeti denetlenebilir bir biçimde ifade eder ve adlandırdığı kontrollerin kodda başka bir yerde var olması gerekir.

Sık yapılan hatalar

- **Kuralı yalnızca açıklamaya koymak.** Yazmanın en ucuz yeri orası ve model genellikle ona uyuyor. Çözüm: kural gibi duran her cümle bir ön koşulu ve bir gate testini adlandırır ve tavan bir cümle değil, bir politikadır.
- **Key'i modele sağlamak ya da run ve step kimliklerinden kurmak.** Cazip, çünkü ikisi de elinin altında ve benzersiz görünüyor. Çözüm: key yalnızca runtime'ın atadığı tanımlayıcılardan türetilmeli ve sonraki bir step'te başka argümanlarla yapılan bir tekrarın aynı key'i aldığı test edilmeli.
- **Tutarı ya da reason code'u key'in içine koymak.** Cazip, çünkü tutar isteğin bir parçası gibi geliyor. Değiştirilmiş bir tekrar o zaman yeni bir istek gibi görünür. Çözüm: key ticket, sipariş ve niyetle sınırlanmalı.
- **Bir tool'a değişken bir etki sınıfı vermek.** Bir mod argümanı olan tek bir tool derli toplu görünür. Çözüm: tool bölünmeli ve her sınıf dürüstçe adlandırılmalı.
- **İç ayrıntı içeren serbest metinli hatalar döndürmek.** Zengin bir mesaj ilk gün hata ayıklamaya yardım eder. Çözüm: kapalı bir kod kümesi, kod başına sabit bir mesaj ve ayrıntılar için bir allowlist.
- **Bir timeout'u sahibine sormadan retry etmek.** Cazip, çünkü genel bir retry sarmalayıcısı zaten var. Çözüm: sözleşme önce durumu denetlemeyi söyler ve sonuç çözülmemişken gate reddeder.
- **Sözleşmeyi iki yerde tutmak.** Prompt'u yazan ile gate'i yazan ayrı çalışır. Çözüm: tek bir kaynak ve modelin gördüğü tanımın ondan üretilmesi.
- **Needs approval'ı sınıfın bir özelliği saymak.** Söylemesi basit ve denetlemesi kolay. Çözüm: politika karar verir; tool başına, tutar

başına, ortam başına.

Temel çıkarımlar

- Bir schema argümanların düzgün biçimlenip biçimlenmediğini söyler, bir sözleşme ise çağrının dünyanın şimdiki hâlinde gerçekleşmesine izin verilip verilmediğini söyler; sabit sırayla dokuz alan bunu denetlenebilir kılar.
- Bir tool açıklamasındaki kural, kötü önerilerin oranını düşüren bir taleptir ve aynı kural, gate'in uyguladığı bir ön koşul olarak ve tutmaz olduğunda başarısız olan bir test olarak da var olmalıdır.
- Etki sınıfı kontrollerin tabanını belirler (okumalar bir kapsam ve bir çıktı sınırı, yazmalar ön koşullar ve bir idempotency key, geri alınamaz yazmalar bir bilinmeyen sonuç kuralı gerektirir); onaya ise sınıf değil, politika karar verir.
- İdempotency key'i runtime tarafından, atadığı tanımlayıcılardan türetilir; asla modelden, run'dan ya da step'ten değil; böylece sonraki bir step'te herhangi bir argümanla önerilen bir tekrar ilk sonucu döndürür ve ikinci bir iade kaydedilmiş bir insan kararı gerektirir.
- Ön koşullar, gate'in kendi okuduğu olguların fonksiyonlarıdır, bilinçli bir sırayla değerlendirilir ve sahibi olan servis aynı kuralları atomik olarak uygular, çünkü gate'in okuması yazma anında bayatlamış olabilir.
- Hatalar, sabit mesajlı ve allowlist'li ayrıntılı kapalı bir kod kümesinden gelir, `retryable` modele değil orchestrator'a konuşur ve tool gateway'in `approval_required`'ı gate'in `needs approval` kararı değildir.
- Sözleşmeler, model gerektirmeyen gate testleri ve tool conformance testleri olan sürümlü artifact'lardır ve key kurulumunu değiştirmek bir düzenleme değil, bir migration'dır.

Bölüm 7, her sözleşmenin adını andığı ama hiçbirinin tanımlamadığı alanı ele alıyor: agent'ın kimin adına hareket ettiği, onların adına hangi yetkiyi taşıdığı ve bir çağrının görevden daha geniş olmayan bir credential'ı nasıl taşır hale geldiği.

Bölüm 7 — İzinler ve Devredilmiş Yetki

Parcelport'u sakın bir çarşamba günü düşünelim. Bir müşteri, `cus-0042`, desteğe yazıyor: `ord-7f3k2m91` siparişinin kolisi hasarlı geldi, lütfen iade edin. Destek agent'ı siparişi arıyor, capture edilmiş ve teslim edilmiş olduğunu görüyor ve bir iade öneriyor. Öneri düzgün biçimlenmiş, tutar iade edilebilir bakiyenin altında ve ödeme capture edilmiş.

Bölüm 4'ten 6'ya kadar siparişin kime ait olduğu zaten iki kez soruluyor: seçim kümesi modele yalnızca müşterinin kendi siparişlerini sunuyor (Bölüm 4) ve sözleşme bir sahiplik ön koşulu taşıyor (Bölüm 5 ve 6). İkisi de iyi denetimler ve ikisi de kendilerinin üretemeyeceği iki cevabı ödünç alıyor: "bu müşteri"nin kim olduğu ve çağrının arkasındaki credential'ın nelere ulaşabildiği. `ord-7f3k2m91`'in, ayrı bir hesapla sipariş vermiş bir akraba olan `cus-0107`'ye ait olduğunu, müşterinin numarayı iletilmiş bir onay mesajından yazdığını ve run'daki müşteri kimliğinin e-posta zincirinden derlendiğini varsayalım. Bu hikâyedeki kimse kötü niyetle hareket etmiyor. Her denetim kendisine verilen cevaba karşı geçiyor, agent her siparişte ve her müşteride çalışan tek bir geniş token taşıyor ve `orders-service` ile `payments-service`'in itiraz etmek için bir nedeni yok. İade yanlış hesaba iniyor ve kayıt, izinleri dahilinde hareket eden bir agent gösteriyor, çünkü izinleri her şeydi.

Bu bölüm kontrol zarfının **Gate** parçasına ait ve tool gateway'in bir çağrı için credential'ı iliştiirdiği yerde **Etki**'ye de dokunuyor. Gate'in sorusu, bu önerinin bu principal için şu anda etkiye dönüşmesine izin verilip verilmediğidir. Bölüm 4, modelin neyi seçebileceği ile kodun neye karar verdiği arasındaki çizgiyi çizdi ve Bölüm 6, çağrının karşılması gereken sözleşmeyi yazıyor. Bu bölüm sahiplik denetiminin üçüncü bir kopyasını eklemiyor. Katkısı, o denetimlerin üzerinde durduğu şey: run'ın kimin adına hareket ettiğini söyleyen bir delegasyon, tek bir çağrının yetkisini

sınırlayan bir kesişim, sınırın serviste de geçerli olmasını sağlayan bir credential ve tek bir kodla, `not_permitted` ile reddeden, sahiplik kararının tek sahibi `checkAuthority`.

Sorun ve neden zor olduğu

Bölüm 1'deki prototip her agent'a her tool'da ve her müşteride çalışan tek bir API token'ı veriyor. Bu token, kimsenin verdiği bir karar değil. Bir prototip çalıştıktan sonra kimsenin geri dönmediği şeyin artığı. Sonucu şu: tool'ların arkasındaki servisler, ticket'taki müşteriye hizmet eden bir çağrı ile bir başkasına hizmet eden bir çağrı arasındaki farkı ayırt edemiyor, çünkü credential iki durumda da aynı şeyi söylüyor.

Bu, **Gate** parçasının belirli bir biçimde başarısız olması ve hata sınıfı **F7 (yetkisiz etki)**: bu principal'ın, bu anda, neden olmaması gereken bir etki gerçekleşti. Bunu F2'den (yanlış tool ya da yanlış argümanlar) neyin ayırdığına dikkat etmek gerekir. F2'de öneri duruma göre yanlıştır. F7'de öneri bir durum için gayet makul olabilir ve sistem onun bu durumda bir etkiye ulaşmasına izin verir. Aynı iade, `cus-0107`'nin kendi ticket'ı için doğru olurdu. Kusur öneride değil. Agent'ın ulaşabildikleri ile bu görevin ulaşması gerekenler arasındaki mesafede.

Bu biçimin standart adı **confused deputy**: daha az yetkili bir tarafın istediğini yapmak için kendi yetkisini kullanan bir bileşen. Her müşterinin yetkisini taşıyan ve tek bir müşterinin e-postasındaki metne göre hareket eden bir destek agent'ı, çok büyük bir rozeti olan ve kimin sorduğunu denetlemenin çok zayıf bir yolu olan bir deputy'dir.

Agent'lar sorunu üç yönden keskinleştirir. Birincisi, kaynağı adlandıran argümanları (bir sipariş kimliği, bir müşteri kimliği) model sağlar ve modelin bağlamı Parcelport dışından gelen metin içerir. Bir müşteri bir e-postada herhangi bir siparişi adlandırabilir. Bir doküman da herhangi bir siparişi adlandırabilir; F4'ün (talimat ele geçirme) F7'ye dönüştüğü yol budur: ele geçirilmiş bir öneri ile bir iade arasındaki tek şey modelin onu önermeme eğilimiye, ele geçirme modelin başarısız olduğu sıklıkta başarılı olur. İkincisi, bir agent'ın davranışı önceden sayılmış değildir. Geleneksel bir servisin sabit bir kod yolları kümesi vardır ve bir review her birini izinlerine karşı denetleyebilir. Bir agent tool'ları arasından run time'da seçer; bu yüzden izinler kimsenin listelemediği kombinasyonlar

için de geçerli olmalıdır. Üçüncüsü, model "şu müşteri değil, bu müşteri" duygusunu bir step'ten ötekine güvenilir biçimde taşımaz. Bu bağlamın bir özelliğidir ve Bölüm 9 bunun nasıl kaydığını ele alıyor.

Akla gelen ilk çare prompt'a bir cümle koymak: yalnızca ticket'taki müşteriye ait siparişler üzerinde işlem yap. Müşteriler arası önerilerin oranını düşürür ve ben yine de yazardım, çünkü daha düşük bir oran, sonradan okunacak daha az ret demektir. Ama bu bir taleptir. Cümle token'ı daha dar yapmaz. Model yanlış siparişi önerdiğinde token yine çalışır. Yetki, credential'ın ve onu kullanıp kullanmamaya karar veren kodun bir özelliğidir; bu yüzden bu, yetkinin nerede yaşadığı, nasıl daraltıldığı ve kimin denetlediği hakkında bir mühendislik sorusudur.

Not: Okumalar muaf değildir. Başka bir müşterinin adını ve teslimat adresini bağlama döndüren bir `lookup_order` çağrısı, herhangi bir cevap yazılmadan önce PII'yi zaten taşımıştır. Bunu en aza indirmeyi Bölüm 17 ele alıyor; burada önemli olan, müşteri sınırının okuma tool'ları için de geçerli olduğudur.

Bu kimin yetkisi?

Prototipin tek bir token'da birleştirdiği üç şeyi ayırarak başlayalım. Onları principal olarak adlandırmayı en kolay buluyorum, çünkü bu, "bu çağrı kim olarak yapılıyor?" sorusunu zorlar.


Principal	Nedir	Neye katkıda bulunur
Agent'in kimliği	<code>support-agent</code> ya da <code>ops-agent</code> için bir servis kimliği. Bir insan değil, bir müşteri login'i değil	Agent'in yapabileceği en fazla şey: kendisine sunulan tool'lar ve o tool'ların kullanabileceği kapsamlar
Yetkiyi devreden	Run'ın adına hareket ettiği taraf: ticket'taki müşteri ya da bir araştırmayı başlatan on-call mühendis	Görevin dokunabileceği şeylerin sınırı: bu müşterinin siparişleri, bu servisin log'ları
Görev	Tek bir ticket ya da olay üzerindeki tek bir run	Daha da dar bir kapsam: bu ticket, bu kaynaklar, bir son kullanma süresi

Devredilmiş yetki, bir principal'ın bir başkası adına taşıdığı, her zaman yetkiyi devredenin kendi yetkisinden dar olan ve bir göreve bağlı yetkidir. İfadenin iki yarısı var. "Yetkiyi devredenin kendi yetkisinden dar", agent'in

müşterinin yapamayacağı bir şeyi asla yapamayacağını söyler. Bir müşteri başka bir müşterinin siparişini okuyamaz, dolayısıyla o müşteri adına hareket eden bir agent de okuyamaz. "Bir göreve bağlı" ise delegasyonun bittiğini söyler: bir ticket kapanır, bir run biter, bir olay çözülür ve yetki onunla birlikte gider.

Tek bir çağrı için etkin yetki, üçünün **kesişimidir**. Bir çağrının üçünün de izin vermesi gerekir. Agent'ın kimliğinin iade etmesine izin verilmiş olabilir, ama delegasyonun dışındaki bir siparişte değil. Delegasyon müşterinin siparişlerini kapsıyor olabilir, ama agent'a hiç verilmemiş tool'ları değil. Görev bu ticket'ı kapsıyor olabilir, ama ticket kapandıktan sonra değil. Yetkiyi bir kesişime indirgemenin bir tasarım review'u için yararlı bir özelliği var: üçünden herhangi birine yeni bir izin eklemek diğerlerini asla genişletmez.

Sonraki diyagram biçimi gösteriyor. Kesişime giren oklara ve ondan çıkana bakılmalı: bir rol değil, tek bir çağrı için yetki; o da sonra kısa ömürlü bir credential'a dönüşür.



Yetkiyi devredenin kimliği nereden gelir

Sorulacak ilk soru, bir run'daki **cus-0042**'nin nereden geldiğidir. Cevap "model onu e-postadan okudu" ise, tasarım bütün sınırı modele teslim etmiştir. Yetkiyi devredenin kimliği, run oluşturulurken, ticket sisteminin doğrulanmış istek sahibi hakkında kaydettiklerinden orchestrator tarafından atanır ve run'ın içinde saklanır. Ondan sonra modelin önerdiği hiçbir şey onu düzenleyemez.

Burası sınırlar konusunda dürüst olunacak bir yer. Delegasyon, bir ticket ile bir müşteri arasındaki bağ kadar iyidir. Ticket sistemi bir ticket'ı bir müşteriyle gönderen adresi eşleştirerek ilişkilendiriyorsa, gerçek kontrol o eşleşmedir ve gate ile aynı titizliği hak eder. Kullanılan ticket sisteminin ticket'ları müşterilere nasıl bağladığını bilmiyorum ve bu bölümün geri kalanına güvenmeden önce bunun öğrenilmesi gerekir. Zayıf bir kimlik bağının altında hava geçirmez olan bir sınır, zayıf bir sınırdır.

`ops-agent` için yetkiyi devreden bir mühendistir. Robin'in geciken bir deployment için bir araştırma başlattığını düşünelim. Delegasyon şunu söyler: Robin adına, bu olay için, olayda adı geçen servislerin log deposuna, metric deposuna ve trace deposuna, sınırlı bir süre için okuma erişimi. "Robin'in tam erişimi" demez. Robin çok daha fazlasını yapabiliyor olabilir ve agent onun bir dilimini taşır.

Kayıt olarak delegasyon

Delegasyon, orchestrator tarafından oluşturulan, gate tarafından okunabilen ve kayda yazılan bir veridir. Burada açıklayıcı bir gösterimle (alan adları ve kapsam adları bu bölüm için uydurulmuştur; kanonik `issue_refund` sözleşmesinden gelen `refunds:create` hariç):

```
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
```

İki özellik önemlidir. Her grant yalnızca bir eylemi değil, bir kaynak koşulunu da adlandırır. Ve kayıt ilk step'ten önce oluşturulur ve model bir şey önerdiğinde değişmez: tavanın üstündeki bir iade onaylanırsa, onay bu kaydın bir düzenlemesi değil, tam olarak tek bir çağrı için ayrı, yeni ve dar bir yetkidir (Bölüm 15).

En az yetki, üç yönden

En az yetki, bir principal'ın görevin bitmesine izin veren en küçük yetkiyi taşıması kuralıdır. Tanıdık bir fikir ve onu üç eksen boyunca uygulardım, çünkü her biri ötekilerin kaçırdığı bir şeyi yakalar.

Eksen	Soru	Parcelport'ta örnek
Tool başına	Bu agent hangi eylemleri yapabilir?	support-agent'ın yedi, ops-agent'ın sekiz tool'u var ve hiçbiri ötekinin tool'larını taşımıyor
Kaynak başına	Hangi nesneler üzerinde?	orders:read yalnızca sipariş bu run'ın müşterisine aitse
Run başına	Ne kadar süreyle, hangi görev için?	Yetki ticket ya da olayla biter ve credential'lar dakikalar içinde sona erer

Tool başına en ucuz olanı ve ekiplerin zaten yaptığı. Kaynak başına, confused deputy'nin yakalandığı yer ve prototipte eksik olan. Run başına, bir sızıntıyı sınırlı büyüklükte bir olaya çeviren: run'dan uzun yaşayan bir credential, birinin sonradan bulabileceği bir credential'dır.

Argümanı denetlemek yerine tool'u daraltmak

Bölüm 4 seçim aralığını daraltmayı savundu ve bu burada doğrudan geçerli. `get_customer_profile` bir `customer_id` argümanı alıyorsa, gate bu argümanı her çağrıda run'ın müşterisine karşı denetlemelidir ve kaçırılmış tek bir kod yolu bir F7'dir. Tool böyle bir argüman almıyor ve run'ın müşterisini orchestrator kendisi dolduruyorsa, modelin yanlış yapacak bir şeyi kalmaz. Modelin farklı bir müşteriye adlandırması için hiçbir meşru nedenin olmadığı her yerde argümansız tool'u seçerdim. `get_customer_profile` için hiçbir zaman olmaz.

Bir kaynak tanımlayıcısı almak zorunda olan tool'lar (`lookup_order` bir sipariş kimliği alır, çünkü müşterinin birkaç siparişi olabilir) argümanı bırakamaz. Onlar aşağıdaki sahiplik denetimini alır. Pratik kural: mümkünse argüman kaldırılmalı, mümkün değilse doğrulanmalı.

Kısa ömürlü credential'lar

Delegasyon bir beyandır. Credential, bir servisin kabul ettiği şeydir. İki hizada olmalıdır: bir servis yalnızca delegasyonun neye izin verdiğini zaten söyleyen bir credential görmelidir. Başvuracağım tasarım, agent'ın hiç

servis token'ı taşımamasıdır. Parcelport'ta politika motoruyla birlikte duran **tool gateway**, tek bir çağrı için, tek bir servise, tek bir eyleme ve tek bir kaynağa kapsamlanmış, kısa bir süre geçerli (diyelim, birkaç dakika) ve verildiği tam çağrıya bağlı bir credential verir.

Bu credential'ların nasıl oluşturulup tutulduğunu Bölüm 18 ele alıyor. Bu bölümün onlardan ihtiyaç duyduğu şey tasarım için bir sonuç: credential dar olduğunda servis sınırı ikinci kez uygular. Gate'teki bir kusur müşteriler arası bir iadeyi geçirirse, **payments-service** diğer müşterinin kaynağına kapsamlanmış bir credential alır ve onu reddedebilir. Gate ve credential, farklı hata modları olan iki bağımsız denetimdir ve ikisine de sahip olmanın amacı budur.

Gate ve yetki

Şimdi bunu gate'e koyalım. Bölüm 4'ün tool çağrısı dalı, modelin önerisini bir seçim kümesine karşı denetler ve **not_in_choice_set** ile reddeder; Bölüm 5 ve 6'nın sözleşmeleri de "sipariş bu run'ın müşterisine aittir"i bir ön koşul olarak listeler. Seçim kümesi daha önceki, ayrı bir katmandır: modele sunulana daraltır, modelin önerdiğine karşı denetlenir ve reddi kendi kodunu korur. Yine de sahiplik cümlesini iki kez daha uygulamazdım. Sahiplik kararının tek bir sahibi var, aşağıdaki **checkAuthority**, ve tek bir kodu, **not_permitted**; sözleşmenin ön koşulu onu çağırarak karşılanır. Bir öneri seçim kümesinde takılabilir ve bu fonksiyona hiç ulaşmayabilir, ve bu sorun değil. Önemli olan, delegasyonun dışındaki bir sipariş gate'e ulaştığında, sahiplik hakkındaki kararın buradan çıkması, tek bir gözlem metni ve kayıta tek bir sayımla. Ayrıca daha fazla veri okuyan ön koşullardan önce çalışır, çünkü principal'ın göremeyeceği bir siparişi okumak için bir neden yok.

```

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

```

Blok, ilgilendiği hata altında doğrudur. Reason'lar, bu bölümün kendi sözlüğünden değil, Bölüm 5'teki gate'in sözlüğünden gelir (Ek bunu listeler) ve `checkAuthority`, Bölüm 5'teki gate'in kısmi bir görünümüdür: o, `permitted` adıımıdır ve döndürdüğü bir onay sonucu, ön koşullardan sonra en son uygulanır (Bölüm 6). Sahip araması başarısız olduğunda çağrı `retryable` olan `upstream_unavailable` ile reddedilir: ulaşılamayan bir `orders-service` izne dönüşmemeli ve kalıcı bir reddedilmeye de dönüşmemelidir; bu yüzden `retry`, modelin isteğiyle değil, `retry` politikası altında (Bölüm 14) çalışır. Run askıdayken ticket kapandığı için delegasyonun süresi dolduğunda çağrı `not_permitted` ile reddedilir. Model müşteriye ait olmayan bir sipariş önerdiğinde çağrı, modele emin olup olmadığı hiç sorulmadan, aynı şekilde reddedilir.

Ret metni önemlidir. Modele döndürülen gözlem, siparişin bu ticket için kullanılabilir olmadığını söylemeli ve başka bir şey söylememelidir. Siparişin var olduğunu doğrulamamalı ve onun hiçbir alanını içermemelidir. Diğer müşterinin verisini yankılayan bir ret, başka bir yoldan gerçekleşmiş bir okumadır.


Yetki beklemeden sonra yeniden denetlenir

Askıya alınmış bir run, Sam onaylamadan önce dakikalarca ya da saatlerce bir queue'da durabilir. Bu arada ticket yeniden atanmış, delegasyon iptal edilmiş ya da sipariş başka biri tarafından iade edilmiş olabilir.

Orchestrator run'ı resume eder ve çağırıcı önceki kararın gücüyle uygularsa, bayat bağlama göre davranır (F5, kontrolden çıkan döngü ya da bayat bağlam). Run resume ettiğinde `checkAuthority`'yi ve ön koşulları yeniden çalıştırdım ve onayı o ikinci denetime bir girdi sayardım, asla onun yerine geçen bir şey değil. Onay, bir insanın tam o çağırıcı kabul ettiğini söyler. Dünyanın hâlâ eskisi gibi olduğunu söylemez.

Tek bir çağırının biçimi

Aşağıdaki sıra, açılıştaki iade için bütün yolu gösteriyor. Sahiplik okumasının nerede durduğuna ve etkisiz biten iki dala, reddedilmeye ve geri çevrilen onaya bakılmalı.



Politikalar: model dışındaki kararlar

Politika, gate'in önerilen bir çağrıya karşı değerlendirdiği bir kuraldır. Veri ya da kod olarak yazılır, asla bir prompt'taki düzyazı olarak değil ve her çağrıda değerlendirilir. Örneklerden önce, neden tool'daki sabitler değil de politika oldukları hakkında bir söz: bir politika, tool'un kodundan farklı bir takvimde değişir. Tavan finans değiştirdiğinde, değişiklik penceresi release süreci değiştiğinde değişir ve bunlardan birini yapmak için kimsenin bir agent'ı yeniden deploy etmesi gerekmemelidir. Politikalar sürümü olan verilerdir, sürüm karar ile birlikte kaydedilir (Bölüm 4'ün replay argümanı) ve bir politika değişikliği, bir kod değişikliği gibi review edilir.

Aşağıdaki gösterim açıklayıcıdır. Hiçbir gerçek ürünün konfigürasyon sözdizimi kastedilmiyor ve sayılar varsayımsal.

```
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
```

Her politika farklı bir soruyu cevaplar. Tavan tutar hakkındadır ve bir prompt talimatıyla en sık karıştırılan politikadır. Değişiklik penceresi zaman hakkındadır. Environment politikası nerede hakkındadır: bir staging ortamına karşı başlatılmış bir run, bir argümanda bir production hedefi adlandırıp bunun kabul edilmesini sağlayamamalıdır. Kimin verisi dördüncü bir sorudur ve burada kasıtlı olarak bir politikası yok: o `checkAuthority`'dir, bir kez yazılmıştır ve onu yeniden ifade eden bir politika, kayacak kendi yolu olan ikinci bir kopya olurdu. Üç politikanın hepsi olguları run'dan ve servislerden okur. Hiçbiri önerinin kendisi hakkında söylediği hiçbir şeyi okumaz.

Politikaları birleştirmek

Bir çağrıya birden fazla politika uygulandığında birleştirme kuralı belirtilmiş ve sabit olmalıdır. Kullanacağım kural, varsayılan olarak reddet ve daha katı olan kazanır. Herhangi bir politika reddederse çağrı reddedilir. Aksi halde herhangi bir politika needs approval derse çağrı onay gerektirir. Aksi halde çağrıya izin verilir ve yalnızca en az bir grant eşleştiği için. Hiçbir politikanın anmadığı ve hiçbir grant'in kapsamadığı bir çağrı reddedilir; yeni bir tool'un biri onu yazana kadar neden hiç yetkisiz kaldığı budur.

```
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) }
```

`evaluatePolicies`'in `allow`'da ne döndürdüğüne bakılmalı: çağrı, kendisini haklı çıkaran yetkiyi taşır. `Credential`'ın kapsamlanacağı yetki odur. Karar veren `gate` ile uygulayan `credential` böylece tasarım gereği uyuşur, çünkü ikisi de aynı kayıttan gelir.

Politika katmanının yapmadığı şey

Bir politika motoru, bir çağrının yetki dahilinde olup olmadığına karar verir. Çağrının akıllıca olup olmadığına karar vermez. Doğru müşteri için, müşterinin uydurduğu bir gerekçeyle yapılmış doğru tutarda bir iade, yukarıdaki her politikadan geçer. Bu, sözleşmenin ön koşullarının (Bölüm 6), kanıt denetimlerinin (Bölüm 4) ve riskin gerektirdiği yerde bir insanın (Bölüm 15) sorusudur. Motor her şeyi kapsayana kadar politika eklemeye devam etme çekimine direnirdim. Bir iş kuralları sistemine dönüşen bir politika motoru, kimsenin sahip olmadığı ikinci bir uygulama olur.

Uyarı: Bir tool'un güvenlik ya da para hareket ettirme özelliği yalnızca tool'un açıklamasındaki ya da system prompt'taki bir cümle olarak varsa, bu bir kontrol değildir. Açıklama modele bir taleptir. Tavan, müşteri sınırı ve onay gereksinimi, gate'in çalıştırdığı kodda var olmalı ve bunlardan biri kaldırıldığında bir test başarısız olmalıdır.

Credential'ı vermek

Karar "allow" olduktan sonra orchestrator `effect.apply`'i başlatır ve tool gateway credential'ı son anda, yalnızca o çağrı için oluşturur, servisi çağırır ve sonucu kendi üzerinden döndürür. Aşağıdaki blok `effect.apply`'in tool gateway tarafıdır. İşlemlerin sırasına dikkat edilmeli, çünkü credential servisi (tool gateway'in arkasında açıklayıcı bir bileşen; Parcelport'un referans sisteminde credential'ı veren gateway'dir) ve hedef servis ayrı sistemlerdir ve hiçbir şey ikisini atomik yapmaz.

```
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
```

Hata durumları gözden geçirilmeli. Credential verilemezse hiçbir şey olmamıştır ve çağrı Bölüm 14'ün kurallarıyla retry edilebilir. Credential verildikten sonra tool çağrısı başarısız olursa ya da timeout'a düşerse geri alınacak bir şey yoktur: credential kendiliğinden sona erer ve ömrün kısa olmasının nedeni budur. `executeTool` timeout'a düşerse ve sonuç bilinmiyorsa, sırada ne geleceğine sözleşme karar verir ve `issue_refund`

için bu, herhangi bir retry'dan önce iade durumunu denetlemek demektir. Kayıt credential kimliğini tutar, asla credential değerini değil; böylece trace'in okuyucusu neyin verildiğini, onu kullanamadan görebilir.

Neyin eksik olduğuna dikkat edilmeli: tasarımın doğru olması için başarılı olması gereken bir iptal adımı. Doğru olmak için başka bir sisteme ulaşan bir temizlik çağrısına ihtiyaç duyan bir tasarım, o çağrının başarısız olduğu gün başarısız olan bir tasarımdır.

Ops agent: geniş oku, dar yaz

Ops agent aynı örüntüyü tersine çevirir. İş, destek agent'ının baktığından çok daha fazlasına bakmaktır: log'lar, metric'ler, trace'ler, dahili dokümanlar. İhtiyaç duyduğu log satırını göremeyen bir araştırma kötü bir araştırmadır. Bu yüzden yetkinin doğru biçimi geniş okumalar, dar yazmalar ve production'a onaylı değişikliklerdir.

Tool	Yetki biçimi	Neden
query_logs	Okuma, sınırlı zaman aralığı, olaydaki servislere kapsamlı	Genişlik yararlıdır, ama sınırsız genişlik her servisin log'unu seepsiz yere okur
get_metrics	Okuma, olayın servislerine kapsamlı	Aynı gerekçe, daha düşük risk
get_trace	Trace kimliğiyle okuma	Bir trace birçok run'dan veri içerebilir; neyi tutması gerektiğini Bölüm 20 ve Bölüm 17 ele alıyor
search_docs	MCP docs server'ı üzerinden okuma	Yapısı gereği salt okunur (Bölüm 8)
run_diagnostic	Hiç credential yok	Sınır sandbox'tır (Bölüm 19)
open_pull_request	Kod host'una yazma, tek bir repository, agent'ın sahip olduğu bir branch öneki, merge yok	Merge'i bir insan yapar, bu yüzden yazma bir insana yapılan bir öneridir
toggle_feature_flag	Agent hiçbir credential taşımaz; onay gerekir	deploy-service, Robin onayladıktan sonra deploy credential'ıyla hareket eder
request_rollback	Agent hiçbir credential taşımaz; onay gerekir	Aynısı ve politika, kanıt ne derse desin onay gerektirir

İki gözlem. Birincisi, `deploy credential`'ı ops agent adına `deploy-service` tarafından kullanılır ve agent onu asla taşımaz. Production'a giden yol onaydan ve `credential`'ın sahibi olan bir servisten geçer; agent yaratıcı bir şey önererek onu genişletemez. İkincisi, `run_diagnostic` en az yetkinin en temiz örneğidir: `credential`'a ihtiyaç duymaz, çünkü `sandbox`'ın verecek bir `credential`'ı yoktur. Bir tool ne kadar az şeye ihtiyaç duyarsa, o kadar az şey kaybedebilir.

Geniş okumalar bedelsiz değildir. Log'lar olmaması gereken şeyler içerir (bir istek satırındaki müşteri tanımlayıcısı, bir alanı yankılayan bir hata) ve bir log satırı aynı zamanda talimat taşıyabilen bir metindir. Geniş okuyan bir agent bu yüzden Bölüm 17'nin veri işleme kontrollerine ve Bölüm 16'nın injection kontrollerine dar bir agent'tan daha çok ihtiyaç duyar, çünkü bağlamına daha çok malzeme ulaşır. Yetki, agent'ın neyi açabileceğini söyler. Açtığı şeyi okumayı güvenli yapmaz.

İşi bir insana devretmek

Bazı öneriler, agent'ın denemesine izin verilenin içindedir ama onun tek başına yapabileceğinin ötesindedir. Örüntü, üçüncü karar olan `"needs_approval"`'dır ve bu bölümün katkısı, yararlı bulduğum bir ayrımıdır: gate, "yetkinin ötesinde, ama bir insan verebilir"i, "yetkinin ötesinde ve hiçbir insan bunu bu yoldan vermemeli"den ayırmalıdır.

`refund_ceiling`'in üstündeki iade birinci türdür. Destek ekibi lideri Sam onu onaylama yetkisini taşır ve tam o çağrı için imzalanmış bir onay, delegasyonun üstünde dar, tek seferlik bir yetki olur. Müşteriler arası iade ikinci türdür. Onun için bir onaylayan yoktur. Sam, farklı bir süreç olmadan bir müşterinin hesabına başka bir müşterinin siparişi için iade onaylamazdı ve bunun için bir düğme sunan bir onay ekranı, refleks bir tıklamaya davetiye çıkarırdı. O çağrı reddedilir. Kimsenin onaylamaması gereken bir şeyi onaylaması için bir isteğe bir insana yükseltilmez.

Kuralı gate'in tasarımı için kısa bir test olarak yazardım. Gate'teki her ret reason'ı için, onay servisi üzerinden onu geçersiz kılma yetkisi olan herhangi bir kişinin var olup olmadığı sorulmalı. Varsa reason büyük olasılıkla bir `needs_approval`'dır ve onaylayan adlandırılır. Yoksa bir rettir ve kimseye sorulmaz. Her şeyi bir insana gönderen bir gate, insanı kontrol, queue'yu gate yapmıştır.

Bir onayı neyin gerçek yaptığını Bölüm 15 ele alıyor. Burada önemli olan yalnızca, bir onayın bir insandan tek bir çağrıya delegasyon olduğu, her delegasyonun olması gerektiği gibi onaylayanın kendi yetkisinden dar olduğudur.

Yetki modelini review etmek

Bir yetki modeli, biri ona bakmazsa bozulur. Kaymanın olağan yönü daha geniş olandır: bir ticket'ı açmak için bir kapsam eklenir ve kimse onu geri almaz. Dört alışkanlık modeli dürüst tutar ve her biri zaten meşgul olan bir ekibin zamanına mal olur.

Bir yetki envanteri. Platform ekibinin sahip olduğu tek bir tablo; her agent, tool ve servis için bir satır: hangi kapsamı taşıdığı, hangi kaynak koşulunun uygulandığı, hangi credential ömrü, hangi politikanın kapsadığı. Güvenlik ekibinden Jordan'ın bir review'da ilk isteyeceği şey odur ve onu yazmak, satırı olmayan tool'ları açığa çıkarır. Satırı olmayan bir tool'un belgelanmış bir yetkisi yoktur ve hiçbir yetkisi olmamalıdır.

Sınırı aşan testler. Gate bir fonksiyondur, o halde bir fonksiyon gibi test edilmeli. Her tool için golden set (Bölüm 21), bir müşterinin sınırını aşan vakaları, süresi dolmuş bir delegasyonu, başarısız olan bir sahip aramasını, tavanın biraz üstündeki bir çağrıyı ve değişiklik penceresinin dışındaki bir çağrıyı, her biri beklenen kararlar birlikte içermelidir. En önemli test, bir politikayı kaldıran ve bir başarısızlık bekleyen testtir. `checkAuthority` içindeki sahiplik denetimi silindikten sonra hâlâ geçen bir suite, sınır hakkında hiçbir şey kanıtlamaz.

Kullanım kanıtı. Kayıt her çağrı için delegasyonu, politika sürümünü, kararı ve credential kimliğini göstermelidir. Bundan hangi grant'lerin hiç kullanılmadığı (kaldırma adayı), hangi ret reason'larının oluştuğu ve ne sıklıkta oluştuğu sorulabilir. Hiçbir şeyi reddetmeyen bir gate iyi davranışın kanıtı değildir. Bir bakma nedenidir: modelin yalnızca geçerli çağrılar önerdiği ya da denetimlerin çalışmadığı anlamına gelebilir. `not_permitted` retleri öneriler hakkında sinyallerdir ve onlardaki artış bir düzeltmeyi hak etmeden önce dikkati hak eder.

Değişikliğe bağlı bir review ritmi. Bir tool eklendiğinde, bir kapsam eklendiğinde, bir politika değiştiğinde ve bir agent yeni bir servis aldığı anda envanter review edilmeli. Periyodik bir review (diyelim, üç ayda

bir) bu tetikleyicilerin kaçırdıklarını yakalar. İkisi de ekibin dikkatine mal olur ve geniş bir grant'i bir olay sırasında (Bölüm 23) keşfetmektense sık sık küçük bir miktar harcamayı tercih ederim.

Her review'da denetlemeye değer bir ayrım var. Hem gate hem sahibi olan servis, geçerli bir onaydan yoksun, onay kapılı bir çağrıyı reddetmelidir; servis, gate atlatılsa bile `approval_required` döndürür. Birincisi karardır, ikincisi uygulamadır; bunlar iki denetimdir ve birindeki bir kusur ötekini ortadan kaldırmasın diye ikisini de tutardım. Politika motoru ve tool gateway, Parcelport'ta olduğu gibi tek bir bileşense, ikinci denetim sahibi olan serviste ya da motordan ayrı bir gateway'de yaşamalıdır; yoksa aynı denetim iki kez yapılmış olur.

Trade-off'lar ve maliyetler

Her çağrıda fazladan bir okumaya mal olur. Sahiplik denetimi, etkiden önce sahibi olan servisi okur. Bu her çağrıda gecikme ve kullanılabilir olması gereken bir bağımlılıktır: `orders-service` çalışmıyorsa, bir sahip gerektiren çağrılar reddedilir. Reddetmenin doğru olduğunu düşünüyorum ve bu, güvenilir bir gate'in aynı zamanda belirsizlikte reddeden (fail closed) bir gate olduğu anlamına gelir; on-call'a bunun söylenmesi gerekir.

Ayakta tutulacak yeni bir sisteme mal olur. Credential servisi her etkinin yolunda durur. Kullanılamıyorsa agent hareket edemez. Salt okunur bir destek sorusu için bu kabul edilebilir bir degraded mode olabilir (Bölüm 14'e göre tool'suz cevaplar) ve bir iade için bir duruştur. Alex'in ekibi bu kullanılabilirliğin sahibidir ve bir sahibi, bir alarmı ve belirtilmiş bir degraded mode'u olması gerekir.

Politika bakımına mal olur. Bir politikanın bir sahibi ve bir review'u vardır ve kimsenin ayarlamadığı bir tavan tiyatrodan ibarettir. Finans tavanı değiştirdiğinde ve politika onu izlemediğinde, gate dünün kuralını tam bir güvenle uygular. Her politika, adı belli bir kişinin hesap verdiği bir şey olarak ele alınmalı.

İnsanlar için sürtünmeye mal olur. Kaynak başına yetki, geniş bir token'ın karşılayacağı vakaları reddeder: açılıştaki akrabaların siparişi. Destek ekibi bunları bir insan süreciyle ele almak zorunda kalacak ve müşteriye giden ret mesajının özenle yazılması gerekir. Bu retlerin bir

kısmı kontrolün çalışmasıdır. Sayı yüksekse delegasyon modeli müşterilerin gerçekte nasıl alışveriş yaptığıyla uyuşmuyor olabilir ve bu, ekibin duyması gereken bir ürün sorusudur.

Kimlik bağında kırılır. Buradaki her şey delegasyonun doğru olmasına dayanır. Ticket-müşteri bağı zayıfsa, kaynak başına denetimler yanlış şeyi tam olarak doğrular. Sonraki hiçbir kontrol bunu onarmaz.

Hepsini ne zaman kullanmamalı. Tek bir okuma tool'u olan ve hiç yazması olmayan, tek amaçlı, dahili bir agent'ın bir credential servisine ve tam bir politika motoruna ihtiyacı yoktur. İnce bir gate (schema, allowlist, sahiplik), statik, dar, salt okunur bir token ve belgelenmiş bir kapsam orantılıdır ve onun için tam aygıtı kurmak kendi başına bir maliyettir. Örüntü, agent para hareket ettirebildiğinde, başka bir tarafın verisine ulaşabildiğinde ya da production'ı değiştirebildiğinde bedelini hak eder. Bölüm 1'in en az agency ilkesi kontrol sistemi için de geçerlidir: onu riske göre boyutlandırmak gerekir.

Sık yapılan hatalar

Principal'ı modele sağlamak. Bir tool üzerindeki `customer_id` gibi bir argüman, modelin çıktısını sınır yapar. Cazip, çünkü tool o zaman fazladan bir tesisat olmadan her müşteri için çalışır. Değiştirmek için meşru bir neden olmayan yerde argüman kaldırılmalı ve müşteri run'dan alınmalı.

Agent başına tek token, "şimdilik". Cazip, çünkü prototipin bugün çalışması gerekiyor. Kalır, çünkü hiçbir şey bozulmaz ve sorunun ilk işareti bir F7'dir. Çözüm, çağrı başına bir credential vermektir. İlk haftada daha çok iş, bir olay review'unun agent'ın nelere ulaşabildiğini sorduğu haftada çok daha az iştir.

Yetkiyi bir kez, başlangıçta denetlemek. Birinci step'te denetleyip dokuzuncu step'te etkiyi uygulayan bir run, özellikle onay için askıda kaldığı süre boyunca, yetkinin bayatlayabileceği bir pencere oluşturur. Cazip, çünkü isteğin en kolay incelendiği yer birinci step'tir. Gate'te her çağrıda ve resume'da yeniden denetlenmeli.

Onayı her şeyi yapma yetkisi saymak. Bir onay tam bir çağrıyı kapsar. Cazip, çünkü imzalanmış tek bir onayı saklamak ve yeniden kullanmak kolaydır. Farklı bir tutar, farklı bir sipariş ya da sonraki bir retry için yeniden kullanılabilirse, delegasyonu daraltmak yerine genişletmiştir. Onu çağrıya bağlamak gerekir (Bölüm 15).

Her reddi bir insana göndermek. Temkinli hissettirir. Onaylayanları tıklamaya alıştıır ve onlardan kimsenin onaylamaması gereken şeyleri onaylamalarını ister. Onaylayanı olan retler, onaylayanı olmayan retlerden ayrılmalı.

Retlerde ayrıntıları yankılamak. Cazip, çünkü yararlı bir hata bir gidiş-dönüşten tasarruf ettirir; ama "o sipariş başka bir müşteriye ait" diyen bir hata modele ve onun aracılığıyla modeli yönlendiren herkese siparişin var olduğunu söyler. Gözlem asgari tutulmalı ve ayrıntı kayda konmalı.

Kimsenin test etmediği bir politika motoru. Cazip, çünkü politika kod değil konfigürasyon gibi görünür. Kaldırıldığında başarısız olan bir testi olmayan bir değişikliği kimse review edemez. Her politikaya, kural kaldırıldığında başarısız olan bir test verilmeli.

Temel çıkarımlar

- Yetki, credential'a ve onu kullanmaya karar veren koda aittir ve prompt yalnızca görevin sahip olması gerekenden fazlasını isteyen önerilerin oranını düşürür.
- Bir çağrı için etkin yetki, agent'ın kimliğinin, müşteriden ya da mühendisten gelen delegasyonun ve görevin kapsamının kesişimidir; bu da agent'ın, yetkiyi devredenin yapamayacağını asla yapamayacağı anlamına gelir.
- Yetkiyi devreden kimliği, ticket'ın doğrulanmış bağından orchestrator tarafından atanır ve run'da saklanır; modelin çıktısı onu asla belirlemez.
- En az yetki tool başına, kaynak başına ve run başına uygulanmalı: confused deputy'yi yakalayan kaynak başına denetimdir ve kısa ömürlü credential'lar bir sızıntının değerini sınırlar.
- Karar her çağrıda, modelin dışındaki bir politika motorunda verilmeli; varsayılan olarak reddedilmeli ve daha katı sonuç kazanmalı ve her

kararla birlikte politika sürümü ve credential kimliği kaydedilmeli.

- `needs_approval` yalnızca verme yetkisi olan bir insanın bulunduğu yerde kullanılmalı, gerisi reddedilmeli ve askıya alınmış bir run resume ettiğinde yetki yeniden denetlenmeli.
- Ops agent'a geniş, sınırlı okumalar ve dar, onaylı yazmalar verilmeli; deploy credential'larını agent değil `deploy-service` tutsun ve bir tool, kapsam ya da politika değiştiğinde yetki envanteri review edilmeli.

Şimdiye kadarki her şey tool'ların Parcelport'a ait olduğunu ve gate'in onların sözleşmelerini gördüğünü varsaydı. Bölüm 8, bir tool'un, açıklamasının ve çıktısının bir başkasının işlettiği bir server'dan geldiği durumu ele alıyor.

Bölüm 8 — MCP: Güven Sınırını Aşan Tool'lar

Parcelport'un platform ekibini sakın bir perşembe sabahında düşünelim. Ops agent, docs araması sayesinde işe yaradı ve bir mühendis ikinci bir entegrasyon öneriyor: runbook yardımcıları, olay şablonları ve birkaç lookup tool'u sunan üçüncü taraf bir server. Server Model Context Protocol konuşuyor, dolayısıyla bağlamak orchestrator'ın konfigürasyonuna tek bir giriş eklemekten ibaret. Öğleden sonra ops agent'ının tool listesi uzamış oluyor. Açıklamaları kimse yakından okumadı, çünkü okumak gerekmedi: protokol onları teslim etti ve model zaten kullanabiliyordu.

Bir hafta sonra satıcının bir güncelleme yayımladığını varsayalım. Bir tool'un açıklaması yeniden ifade edilmiş ve satıcının kendi ticketing ürününe yazabilen yeni bir tool ortaya çıkmış. Parcelport'un kodunda hiçbir şey değişmedi. Modelin gördüğü tool listesi değişti. On-call SRE Robin bunu ancak run trace'inde kimsenin onayladığını hatırlamadığı bir tool'a yapılmış bir çağrı gördüğünde fark ediyor.

Bu bölüm kontrol zarfının iki parçasına aittir. Bir server'dan gelenler için bu **Bağlam**'dır: bu parça nereden geldi ve ona ne kadar güvenilebilir? Server'dan istenenler için ise **Gate**'tir: bu öneri, bu principal için, şu anda etkiye dönüşebilir mi? Bölümün cevapladığı soru, bir standardı güven kararına çevirmeden tool'lar için standart bir protokolün nasıl kullanılacağıdır.

Sorun ve neden zor olduğu

Bir MCP server'ı bağlamak bir kütüphane eklemek gibi hissettirir, ama kütüphane değildir. Kütüphane, ekibin seçip sabitlediği ve review ettiği, ekibin süreci içinde ekibin izinleriyle çalışan koddur. MCP server'ı ise agent'a neler yapabileceğini modelin okuyacağı bir metinle söyleyen ve istenince bunu yapan ayrı bir programdır. Ekibin makinesinde, bir

satıcının altyapısında ya da ekibin kendi ağının içinde çalışıyor olabilir ve her durumda döndürdüğü açıklamaları ve çıktıları orchestrator'ın dışındaki bir şey üretir. Sistemle o şey arasındaki çizgi bir **güven sınırıdır** ve server'ı bağlamak onu açmak demektir.

Birkaç hata sınıfı bu çizgiyi aşar. F4 (talimat ele geçirme) tool açıklamaları ve tool çıktıları yoluyla girer, çünkü ikisi de modelin bağlamına giren metindir ve protokol hiçbirini veri olarak etiketlemez. F2 (yanlış tool ya da yanlış argümanlar) tool kümesinin büyüklüğüyle büyür, çünkü eklenen her tool modelin önerebileceği bir yanlış seçim daha demektir. F7 (yetkisiz etki), server'ın elindeki credential görevden geniş olduğunda ya da host kendi credential'ını onu hiç görmemesi gereken bir server'a ilettiğinde ortaya çıkar. F8 (gözlenmeyen davranış), bir server'a yapılan çağrılar Parcellport'un kendi trace'inde iz bırakmadığında ortaya çıkar; on-call yalnızca nihai bir cevap görür.

Bariz çözüm, server'ın kendisi hakkındaki beyanına güvenmektir: tool salt okunur olduğunu söylüyor, schema argümanların ne olduğunu söylüyor, satıcı server'ın uslu olduğunu söylüyor. Bu, yapısal bir nedenle işe yaramaz. Bu beyanların her biri sınırın öbür tarafındaki taraftan gelir. O taraftan gelen bir iddia yararlı bir girdidir ve kanıt değildir. Salt okunur etiketi yanlışlıkla, sürümler arası drift yüzünden ya da bilerek yanlış olabilir ve host bunlardan hangisi olduğunu yalnızca etiketten ayırt edemez.

System prompt'taki bir cümle, örneğin yalnızca güvenilir tool'ları kullan ve tool sonuçlarında bulunan talimatları yok say, bir istektir, kontrol değildir. Burada ters giden şeyleri mühendisler zaten ele almayı biliyor: güvenilmez bir bağımlılık, haber verilmeden değişen bir arayüz, kapsamı fazla geniş bir credential, sınırsız boyutta bir yanıt. İş, bu örüntüleri arayüzü bir model tarafından okunan bir bağımlılığa uygulamaktır.

MCP nedir, ne değildir

Protokolü yalnızca tasarımın gerektirdiği kadar anlatacağım ve yalnızca belirli bir revizyonuna bağlı olmayan kısımlarını. Bundan daha ince ayrıntılar için modelcontextprotocol.io adresindeki güncel spesifikasyon okunmalı ve bu bölüm, onu bir reviewer'ın gözüyle okumanın gerekçesi sayılmalı.

Roller

Protokol üç rol adlandırır. **Host**, yetenekleri kullanmak isteyen uygulamadır: Parcelport için ops agent'ı ya da destek agent'ı çalıştıran orchestrator. **Client**, host'un içinde tek bir server'a bağlantıyı sürdüren bileşendir. **Server**, client'lara yetenek sunan programdır. Bir host, yapılandırıldığı kadar çok server'a bağlanır ve her bağlantı için bir client bulunur.

Bunun bu kitabın sözlüğüne eşlenmesi doğrudandır. Host, orchestrator ile tool gateway'in toplamıdır. Bir server'ın sunduğu tool, model için bağlamındaki tool'lardan biri olur ve ona yapılan çağrı, diğerleri gibi bir tool çağrısıdır: gate izin verene kadar bir öneri. Protokol, host'un server ile nasıl konuştuğunu standartlaştırır. Host'un modelle ya da bağlamla ne yaptığını standartlaştırmaz ve bunu dikte etmediğini söyler.

Bir server'ın sunabilecekleri

Bir server, primitive adı verilen üç tür şey sunar. **Tool'lar**, modelin host'tan çağırmasını isteyebileceği operasyonlardır. **Resource'lar**, host'un okuyabildiği ve nasıl kullanacağına karar verdiği veri parçalarıdır. **Prompt'lar**, bir server'ın bir etkileşimi başlatmak için sunduğu şablonlardır. Protokolün kendi dokümantasyonu tool'ları model tarafından kontrol edilen, resource'ları uygulama tarafından kontrol edilen ve prompt'ları kullanıcı tarafından kontrol edilen şeyler olarak tanımlar; bu, her birini kimin seçmesinin beklendiğini hatırlamanın yararlı bir yoludur.

Üçü de bir reviewer için önemlidir ve ortak bir nedenle: her biri orchestrator'ın dışında doğan ve modelin önüne çıkabilen içeriktir. Bir tool tanımı metindir. Bir resource metin ya da veridir. Bir prompt şablonu, kullanıcının tetikleyebileceği ve server yazarının sözcüklerini taşıyan metindir. Bağlam penceresine neyin gireceğini ve nasıl etiketleneceğini Bölüm 9 ele alır; bu bölüm, bu üç girdinin var olduğu ve Parcelport'a ait olmadığı olgusunu ele alır.

Transport'lar, capability'ler ve authorization

Birden fazla transport vardır. Bir server, host'un başlattığı ve standart girdi ile çıktı üzerinden konuştuğu yerel bir süreç olarak ya da host'un HTTP üzerinden eriştiği uzak bir servis olarak çalışabilir. Fark, güvenlik sorusunu değiştirir. Yerel bir server, süreci hangi erişime sahipse onunla


Parcelport'un kendi makinesinde çalışan koddur; dolayısıyla bir protokol sorusu olduğu kadar bir sandbox sorusudur (Bölüm 19). Uzak bir server ise ona gönderilen her çağrıyı ve her argümanı gören bir ağ bağımlılığıdır; dolayısıyla aynı zamanda bir veri ifşası sorusudur (Bölüm 17).

Client ve server ayrıca her iki tarafın neyi desteklediği hakkında bilgi alışverişi yapar, böylece hiçbir öbürünün ele alamayacağı operasyonlara girmez. Buna **capability negotiation** denir. Bu, bir server'ın neler yapabildiğini söylediğini bildirir; uyumluluk için yararlıdır ve ona izin verilip verilmeyeceği hakkında hiçbir bilgi taşımaz.

Authorization protokolün bir kavramıdır ve isteğe bağlı olarak tanımlanır. Dokümantasyon, bir server kullanıcıya özgü veriye dokunduğunda ya da kimin ne yaptığının denetlenmesi gerektiğinde onu önerir ve uzak server'lar için OAuth konvansiyonları üzerine kurulur. Yerel server'lar için dokümantasyon, ortamdan ya da server'ın içine gömülü kütüphanelerden alınan credential'lara işaret eder. Bu bölüm için pratik okuma şu: protokol, bir server'ın kimin çağırdığını bilmesi ve onların neler yapabileceğini kapsamlandırması için bir yol sağlar. Bunun açık olup olmadığı ve kapsamların ne anlama geldiği, Parcelport'ta birinin sahip olduğu konfigürasyondur.

Not: Bir server, bağlantı açıkken host'a tool listesini değiştirmenin bir yolunu da sunabilir ve host bundan haberdar edilmeyi seçebilir. Bunu varsayılan olarak açılacak bir özellik olarak değil, ortamın bir olgusu olarak ele almak gerekir: değişebilen bir tool listesi, her değiştiğinde kontrol edilmesi gereken bir tool listesidir.

Aşağıdaki topoloji nereye bakılacağını gösterir: bir host, birkaç server ve güven sınırının bulunduğu kesikli çizgi. Çizginin sağındaki her şey orchestrator'ın kontrolünün dışındadır.



Düz çizgiler Parcelport'un kendi kontrol akışıdır; kesikli çizgiler sınırı aşan bağlantılardır. İki server da tanımları ve sonuçları döngüye doğru geri gönderir; server şirketin hangi tarafında olursa olsun döngünün onlardan aldığı girdinin güvenilir olmasının nedeni budur.

Protokolün çözdükleri ve Parcelport'a bıraktıkları

MCP bir entegrasyon problemini çözer. Standart olmadan, agent ile tool sağlayıcısının her eşleşmesi kendi sağlayıcısına ihtiyaç duyar ve her bağlayıcı tool'ları listeleme, çağırma ve tanımlama için kendi konvansiyonlarını taşır. Standartla birlikte tek bir client implementasyonu birçok server ile konuşabilir ve bir kez yazılan bir server birçok host'a hizmet verebilir. Bu gerçek bir değerdir ve kitap ona karşı çıkmıyor.

Güveni çözmez. Tablo, sınırı aşan her şey için protokolün neyi verdiğini ve neyin Parcelport'ta kaldığını listeler.

Sınırı aşan ya da ihtiyaç duyulan şey	Protokolün verdiği	Ne olarak ele alınmalı ve Parcelport'ta kalan
Server'ın kendisi	Bağlanmanın bir yolu	Bir kimlik iddiası; birinin sahip olduğu bir server allowlist'i
Tool adı, açıklaması, girdi schema'sı	Server'ın sunduklarının bir listesi	Modelin okuyacağı güvenilir metin; bir tool allowlist'i ve pin'lenmiş bir tanım
Salt okunur etiketi gibi tool ipuçları	İsteğe bağlı annotation'lar	Bir iddia; spesifikasyon, bu tür ipuçlarının güvenilir bir server'dan gelmedikçe güvenilir sayılmasını söyler, bu yüzden etki sınıfı Parcelport tarafında atanmalı
Bir çağrı	Bir çağrı mekanizması	Bir öneri; gate: sözleşme, politika, onay

Sınırı aşan ya da ihtiyaç duyulan şey	Protokolün verdiği	Ne olarak ele alınmalı ve Parcelport'ta kalan
Tool sonucu, resource içeriği	Bir sonuç biçimi	Güvenilmez veri, sınırlanana kadar sınırsız; boyut limitleri, biçim kontrolleri, köken, taint (Bölüm 16)
Prompt şablonları	Onları sunmanın bir yolu	Bir başkasının seçtiği güvenilmez metin
Tool listesinin değiştiği bildirimi	Bir notification	Yeniden kontrol için bir sinyal, kabul için değil
Bir çağrının argümanları	Hiçbir şey	İfşa edilen veri; PII içerebilir (Bölüm 17)
Credential	Authorization konvansiyonları	Listedeki en hassas şey; çağrı başına dar kapsamla verilmeli
Ne olduğu	Hiçbir şey	Her çağrının Parcelport'a ait kaydı

Merkezi tasarım hamlesi tablodan çıkar. Host, bir server'ın kendisi hakkında söylediği her şeyi bir kararın girdisi olarak ele alır, hiçbir zaman kararın kendisi olarak değil. İki satır daha uzun bir bakışı hak ediyor.

Tanımlar modelin girdileridir

Bir tool'un adı, açıklaması ve schema'sı host için dokümantasyon değildir. Onlar model için bağlamdır ve modelin hangi önerileri yapacağını şekillendirirler. Bir açıklama tool'un ne zaman doğru seçim olduğunu söylüyorsa, modelin tool'lar arasındaki seçimi kısmen server yazarının metniyle yönetilir. O metin değiştiğinde, koddaki, prompt'taki ya da modeldeki bir değişiklik olmadan agent'ın davranışı değişir.

Bu, problemin tedarik zinciri biçimidir ve açılış senaryosunun önemli olmasının nedeni budur. Perşembe günü review edilmiş bir server, tanımları kaydırsa bir sonraki perşembe farklı bir bağımlılıktır. Kontroller, sürümleri kontrol edilmeyen herhangi bir bağımlılık için kullanılacak kontrollerle aynıdır: neyin kabul edileceğine karar verilmeli, review edilen pin'lenmeli, drift tespit edilmeli ve değişimin yoluna bir insan konmalı.

Çıktılar güvenilir bir server'dan gelse bile güvenilmezdir

Bir çıktı, server yazarının hiç yazmadığı metni taşıyabilir. Bir docs server'ı doküman sunar ve dokümanlar yazarlarının koyduğu her şeyi içerir. Bir arama tool'u, başkasının yazdığı sayfaların parçalarını döndürür. Bir lookup tool'u, bir müşterinin yazdığı alanları döndürür. Server dürüştür ve içerik yine de dışarıdan gelen veridir; Bölüm 16'nın geliştirdiği F4 riskiyle birlikte. Salt okunur olmak server'ın neler yapabileceğini sınırlar. Çıktısının neler söyleyebileceğini sınırlamaz.

Bölümün geri kalanı, sınırın host tarafında duran kontrolleri sırayla ortaya koyar.

Örüntü: host tarafı kontrol yüzeyi

Örüntü, beş parçalı tek bir fikirdir: host hangi server'ların var olduğuna, onların hangi tool'larını modelin görebileceğine, her tool'un ne anlama geldiğine, her çağrının ne yapabileceğine ve her sonucun neye dönüşebileceğine karar verir. Beşi de çizginin Parcelport tarafındadır ve hiçbirisi server'ın uslu davranmasına bağlı değildir.

Birinin sahip olduğu bir server allowlist'i

İlk kontrol, orchestrator'ın bağlanabileceği server'ların, veri olarak tutulan, her giriş için bir sahibi ve bir gerekçesi olan bir listesidir. Listede olmayan bir server, tek bir agent'ın konfigürasyonu ne derse desin bağlanmaz. Bu, düz bir allowlist'tir ve bilerek sıkıcıdır: bir server eklemek, bir geliştiricinin yerel kurulumundaki bir satır değil, üzerinde bir isim taşıyan, review edilmiş bir değişiklik olur.

Aşağıdaki notasyon açıklayıcıdır, gerçek bir ürünün konfigürasyon sözdizimi değildir.

```

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

```

İşin çoğunu iki alan yapar. Etki tavanı, bu server'dan gelen herhangi bir tool'un sahip olabileceği en yüksek etki sınıfını belirtir ve daha fazlasını iddia eden bir tool kabul edilmez. Agent listesi blast radius'u daraltır: destek agent'ı satıcı server'ını hiç görmez.

Bir tool allowlist'i ve pin'leme

Bir server'a izin vermek, üzerindeki her şeye izin vermek demek değildir. İkinci kontrol, host'un her server'dan kabul ettiği tool'ların bir listesidir; yanında bir **pin** bulunur: review edilen tanımın, host tarafından alınan haliyle ad, açıklama ve girdi schema'sından hesaplanmış bir fingerprint'i. Server daha sonra aynı ad altında farklı bir tanım sunduğunda fingerprint artık eşleşmez ve tool, biri değişikliği review edene kadar açığa çıkarılmaz.

Pin'leme değişikliği tespit eder. Kötü niyeti tespit etmez ve bir reviewer kötü bir tanımını onaylayabilir. Ortadan kaldırdığı şey sessiz yoldur: hiçbir yeniden ifade, eklenen hiçbir argüman ve hiçbir yeni tool, kayıt bırakan bir insan kontrolünden geçmeden modele ulaşamaz. Bu mütevazı bir garantidir ve problemin boyutuna uygundur.

```

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

```

Son satıra dikkat edilmeli. Modelin bağlamına giren, server'ın açıklaması değildir. O tool için host'un kendi sözleşmesindeki açıklamadır ve bu bizi üçüncü parçaya getirir.

Her MCP tool'u için host'a ait bir sözleşme

Bir MCP tool'u bir tool'dur ve bir tool'un sözleşmesi vardır (Bölüm 6). Cazip olan, server zaten bir tane sağladığı için server'ın schema'sının onun yerini tutmasına izin vermektir. Schema yalnızca argümanların biçimini kapsar, başka hiçbir şeyi değil. Etki sınıfı, ön koşullar, izinler, timeout'lar ya da hata biçimi hakkında hiçbir şey söylemez ve bir çağrıyı gate'lenebilir kılan alanlar bunlardır.

Sözleşmeyi Parcelport'un içinde yazardım, server'ın schema'sını ona bir girdi olarak ele alırdım ve modele server'ın değil, sözleşmenin açıklamasını gösterirdim. Etki sınıfı, yerel tool'larla aynı tabloda, Parcelport tarafından atanır ve server'ın kendi ipucu en fazla daha dikkatli bakmak için bir nedendir. İşte MCP docs server'ının sağladığı `search_docs` için sözleşme, Bölüm 6'nın kullandığı notasyonla.

```

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)

```

Sözleşme, bir server schema'sının olacağından daha katıdır. Sorgu uzunluğunu sınırlar, sonuç sayısını sınırlar, hata kodlarını adlandırır ve çağrıdan önce neyin doğru olması gerektiğini belirtir. Schema'sı daha fazlasına izin veren bir server, yine de sözleşmenin izin verdiği kadarıyla çağrılmaz. Server schema'sını değiştirirse pin bunu yakalar. Server'ın schema'sı sözleşmeden gevşekse sözleşme kazanır.

Bir MCP çağrısı için gate

Bir MCP tool çağrısı, aynı döngüde, diğerleri gibi aynı gate'ten geçer. "Harici" tool'lar için ayrı bir yol yoktur; host'a ait sözleşmenin bütün amacı, gate'in bir tool'un nerede yaşadığını bilmesine gerek kalmamasıdır. Gate'in bu kaynak için eklediği iki kontrol var: tool'un kabul edilmiş olması ve hâlâ pin'ile eşleşmesi ve server'ın kendisinin iyi durumda olması.

```

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"

```

Fonksiyon, Bölüm 5'teki gate'in kısmi bir görünümüdür. Kanonik döngüdeki üç karardan birini döndürür ve ret nedenleri o gate'in reason adlarını kullanır (`not_in_choice_set`, `not_permitted`, `invalid_arguments`, `upstream_unavailable`; Ek bunları listeler); `definition_changed` ve `tool_not_allowlisted` kayıt olaylarıdır, modelin gördüğü kodlar değil. `runStep` değişmez: bir ret modele gözlem olarak döner, bir onay isteği `run`'ı askıya alır ve izin verilen bir çağrı için orchestrator, bir sonraki parçanın yaşadığı yer olan `effect.apply`'ı başlatır. `breaker.isOpen` satırı Bölüm 13'e işaret eder ve burada bulunur, çünkü hata veren uzak bir server de diğerleri gibi bir bağımlılıktır.

Etki: dar bir credential ve sınırlanmış bir sonuç

Gate bir çağrıya izin verdiğinde orchestrator `effect.apply`'ı başlatır ve tool gateway server'ı client'ı üzerinden çağırıp sonucu kendi üzerinden döndürür. Bu çağrının iki yanında iki şey olur.

Ondan önce, credential. Bir server'a verilen credential, tool gateway tarafından çağrı başına verilir, tool'un ihtiyaç duyduğuyla kapsamlandırılır ve kısa ömürlüdür (Bölüm 7 yetkiyi, Bölüm 18 secret'ları geliştirir). Host, kendi amaçları için kullandığı credential'ı ya da kullanıcınınkini server'a iletmez. Protokolün authorization rehberi, kaçınılması gereken bir örüntü olarak token passthrough'u adlandırır ve gerekçe Bölüm 7'deki confused deputy'dir: bir taraf için amaçlanmış bir token başka bir tarafça kabul

edilmemeli ya da ona gönderilmemelidir. Parcelport'un içindeki salt okunur bir docs server'ı için cevap hiç credential olmamasıdır; bu, olabilecek en iyi cevaptır.

Ondan sonra, sonuç. Server'ın döndürdüğü her şey gözleme dönüşmeden önce sınırlanır ve kontrol edilir.

```
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
```

Blok injection'ı çözmez. Bu bölüme ait kısmı yapar: boyut bağlam büyümeden önce sınırlanır, biçim içerik kullanılmadan önce kontrol edilir ve sonuç köken bilgisini ve bir taint işaretini taşır; böylece bağlam derleyici (Bölüm 9) ve injection kontrolleri (Bölüm 16) üzerinde işlem yapabilecekleri bir şeye sahip olur. Bir timeout ya da bir transport hatası, Bölüm 14'ün retry kurallarının ele aldığı tipli bir hata fırlatır ve tool bir şeyi değiştirmiş olabileceken çağrı temiz biçimde başarısız olmuş sayılmamalıdır. Okuma tool'ları için bu ayırım hiçbir şeye mal olmaz. Bir server'daki yazma tool'u için bu, Bölüm 6'daki `issue_refund` ile aynı idempotency problemidir.

Uyarı: MCP tool'unu tanımlarken ya da çağırırken, host'un kendi credential'larını, kullanıcının token'ını ya da herhangi bir secret'ı modelin gördüğü metne asla konmamalı ve bir özelliğin bedeli olarak bir server'ın daha geniş credential isteği asla kabul edilmemeli. Yanlış server'a ulaşan bir credential, kimin neyi yapabildiğini söyleyebilme yeteneğinin kaybıdır.

Salt okunur server'lar tercih edilmeli ve tool kümesi küçük tutulmalı

Bu bölümdeki en ucuz kontrol, tool'ları hiçbir şeyi değiştiremeyen server'ları seçmektir. Salt okunur bir server yine de modeli yanıltabilir, ama tek başına F7'ye yol açamaz ve en kötü hataları, başka kontrolleri olan F3 (dayanaksız iddia) ve F4'tür. Bir server hem okuma hem yazma sunuyorsa, tool allowlist'ini kullanarak yalnızca okumaları kabul ederdim. Dar, salt okunur bir credential vermek de değerlidir, ama bir ikame değildir: onu uzak server uygular, dolayısıyla o server'ın dürüstlüğüne dayanır ve host tarafı bir kontrol değildir.

Bunu bir tasarım tercihi olarak görmek ve doğrulamak gerekir. Kendini salt okunur olarak tanımlayan bir server bir iddia sunuyor. Kontrol Parcelport tarafından: server politikasındaki etki tavanı, yazma tool'larını hiç kabul etmeyen bir allowlist, Parcelport'un kendi resource'ları için yalnızca okuma kapsamları veren bir credential ve Parcelport'un kendi server'ları için kodun kendisi. Bir yazmayı yalnızca ilk ikisi ve kod durdurur; bir credential kapsamı, credential'ı alan taraf tarafından uygulanır, dolayısıyla üçüncü taraf bir server'da bu, karşı tarafın yerine getirdiği bir istektir, host tarafı bir kontrol değildir.

Tool kümesinin boyutu da bir kontroldür. Modelin gördüğü her tool bağlama mal olur ve yanlış seçimlerin alanını genişletir; dolayısıyla F2 tool sayısıyla büyür. Bir server'ın, agent'ın üçe ihtiyaç duyduğu yerde otuz tool sunduğunu varsayalım; protokol uyumu ne olursa olsun bu bir tasarım problemidir. Allowlist onun kesildiği yerdir: bir görevin ihtiyaç duyduğu tool'lar, onlara ihtiyaç duyan agent'a sunulur. Bölüm 4'ün seçim aralığını daraltma kuralı burada değişmeden geçerlidir.

Gözlem

Bir MCP server'ına yapılan her çağrı, Parcelport'un kendi run store'unda ve trace pipeline'ında bir kayıt alır: server, tool, yürürlükteki pin, argüman biçimi, karar, sonucun boyutu, gecikme ve herhangi bir kırpma ya da ret. Server'ın log'ları server'ındır. Üçüncü tarafa yapılan bir çağrı bir olayda önemliyse, güvenilebilecek tek kanıt, çizginin Parcelport tarafında yazılan kanıttır. Bu, zarfın Kayıt parçasıdır ve trace biçimini Bölüm 20 verir.

Kayıt allowlist'i de besler. Bir ay boyunca hiç çağrılmayan bir tool kaldırma adaydır ve sık reddedilen bir tool ya yanlış tanımlanmıştır ya da yanlış kapsamlandırılmıştır.

Parcelport: docs server'ı ve değişen bir tanım

Açılışa dönelim. Parcelport'un oyunda iki MCP server'ı var. Birincisi, runbook'lar, politikalar ve gönderim kuralları üzerindeki salt okunur server olan, iki agent için `search_docs`'un kaynağı olan dahili docs server'ı. İkincisi, satıcının runbook yardımcısı. Kontrollerin her biri için nasıl işlediği şöyle.

Docs server'ı, etki tavanı okuma olarak ve credential olmadan allowlist'te yer alır. Parcelport ondan tek bir tool kabul eder, `search_docs`'u, host'a ait bir sözleşme ve bir pin ile. Bu yazı yazıldığı sırada Contextator, MCP tool'larının hepsi salt okunur olan bir dokümantasyon server'ının bir örneğidir; dolayısıyla bir client'ın ondan istediği hiçbir şey state'i değiştiremez; diğer araçlar da benzer yaklaşımlar izliyor. Bu özellik, onu kabul etmeyi en kolay server yapan şeydir ve çıktısının yine de boyut sınırı, biçim kontrolü ve taint işareti almasının nedeni de budur. Bir doküman, yazarının bir agent için hiç amaçlamadığı talimatlar içerebilir ve bunun kontrolü server'ın değil, Bölüm 16'nındır.


Satıcı server'ı tam tersi uçtan başlar. Girişi ops agent ile sınırlıdır, etki tavanı okuma ve credential kapsamı çağrı başına verilen `runbooks:read`'dir. Satıcı güncellemesini yayımladığında `admitTools` tanımları listeler, bir fingerprint'in artık pin ile eşleşmediğini bulur ve o tool'u karantinaya alır. Satıcının ticketing ürününe yazabilen yeni tool'un allowlist girişi yoktur, dolayısıyla model onu hiç görmez. Robin'in trace'i

bir `definition_changed` kaydı ve bir `tool_not_allowlisted` kaydı ile platform ekibinin review queue'suna giden bir mesaj gösterir. Ops agent diğer tool'larla çalışmaya devam eder.

Şimdi karantina olmasaydı ne olacağını düşünelim. Model yeni tool'u önerebilirdi; gate onu `not_in_choice_set` olarak reddederdi ve run toparlanırdı. Parcelport tarafında duran katmanlar şunlardır: tool'u gözden kaldıran allowlist, allowlist atlanırsa onu reddeden gate ve review'un onu reddetmesini sağlayan etki tavanı. Hiçbiri modelin uslu davranmasına ihtiyaç duymaz ve hiçbir satıcıya bağlı değildir.

`runbooks:read` credential'lı farklı türden bir katmandır. O token'ın Parcelport'un kendi resource'ları arasında nelere ulaşabileceğini sınırlar ve satıcının server'ının yeni yazma tool'uyla kendi sistemlerinin içinde ne yaptığı hakkında hiçbir şey söylemez; dolayısıyla o yazmaya karşı bir bariyer sayılmaz.

Normal, izin verilen bir çağrının sırası şöyle; ret yolları işaretlenmiş. Host'un her adımda kontrolü nerede elinde tuttuğuna bakılmalı.



Modelin bu sıra içindeki yolu, yerel bir tool için olanla aynıdır; amaç budur. Modelin bir tool'un bir sınırın ötesinde yaşadığını bilmesine gerek yoktur. Gate'in bilmesi gerekir.

Kendi MCP server'ını yazmak

Er ya da geç bir Parcelport ekibi kendi server'ını yazacak; örneğin gönderim durumunu birkaç agent'a sunan bir tane. Yazmak, sınırın öbür tarafına taşır ve bir server o zaman kendi tool'ları için gate'tir, çünkü önündeki host yanlış yapılandırılmış olabilir, bir başkasına ait olabilir ya da henüz var olmayabilir. Her tool'a Bölüm 6'daki sözleşme verilmeli, girdiler server'ın kendisinde doğrulanmalı, çağırın tanımlanmalı ve kapsamlar bağlantı başına bir kez değil, tool başına kontrol edilmeli; tool'un ihtiyaç duyduğu en dar downstream credential ile (Bölüm 7). Bu tarafa özgü dört disiplin var.

- **Rate limit'ler.** Bir model bir çağrıyı hızla tekrarlayabilir ve bir döngü bunu uzun süre tekrarlayabilir. Çağırın ve tool başına limitlenmeli ve host'un bir ret'e eşleyebileceği tipli bir hata döndürülmeli; böylece kontrolden çıkmış bir client bir kesintiye değil, reddedilmiş bir çağrıya mal olur.
- **Çıktı limitleri.** Sonuç boyutu ve öge sayısı server'da sınırlanmalı ve mümkün olduğunda serbest metin yerine yapılandırılmış alanlar tercih edilmeli. Bir son kullanıcıdan gelen her şey öyle işaretli kalır. Bir server kendi yazmadığı metni döndürüyorsa, başkasının sözcükleri için bir pass-through'dur ve bunu söylemelidir.
- **Gözlem.** Her çağrıyı çağırın kimliği, tool ve sonuçla, server'ın kendi sisteminde log'lanmalı; çünkü host'un trace'i server'a ait değildir, ona güvenilemez.
- **Kararlılık.** Değişen bir tanım, onu pin'leyen her host'u bozar. Tool'lar sürümlenmeli, değişiklikler duyurulmalı ve açıklamaları gelişigüzel yeniden ifade etmekten kaçınılmalı; çünkü açıklama arayüzün parçasıdır.

```

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)

```

Bu blok, host'un gate'inin server tarafındaki aynasıdır ve onun yerini tutmaz. Hem server hem host yazılıyorsa, iki kontrolden birinin gereksiz olduğu düşüncesine direnmek gerekir. Farklı koşullar altında başarısız olurlar.

Trade-off'lar ve maliyetler

Yukarıdaki her kontrolün bir bedeli var ve bazıları o kadar ağır ki hepsini her duruma uygulamazdım.

Review ve sahiplik. Bir allowlist ve pin'ler, her yeni server'ı ve her tanım değişikliğini review edilen bir olaya çevirir. Maliyet, platform ekibinin zamanı, bir queue ve her giriş için bir sahiptir. Bir satıcının tool açıklamasındaki bir değişiklik artık production'a ulaşmadan önce bir insan kararı gerektirir. O queue'nun sahibi yoksa kontrol zamanla ya hep onaylanan ya da görmezden gelinen bir formaliteye dönüşür; bu, hiç olmamasından kötü bir kontrol tiyatrosudur, çünkü bir güvence gibi görünür. Pin'lemeyi açmadan önce kimin ve ne kadar hızlı review edeceğine karar verilmeli.

Geliştiriciler için sürtünme. Yeni bir server denemek isteyen bir geliştirici bir girişi beklemek ya da allowlist'in daha geniş olduğu ve hiçbir şeyin production verisine ulaşmadığı bir geliştirme ortamı kullanmak zorundadır. O ortamı sunardım ve ikisi arasındaki çizgiyi net tutardım, çünkü bu kontrollerin aşınmasının olağan yolu, sessizce gerçeğe dönüşen yerel bir konfigürasyondur.

Sözleşme yazmak. Her tool için host'a ait bir sözleşme gerçek mühendislik zamanına mal olur ve server ile uyumlu tutulması gerekir. Alternatif, server metninin onun yerini tutmasına izin vermektir; bu, server değişene kadar daha ucuzdur. İki okuma tool'u olan bir server için sözleşme kısa bir dosyadır. Diyelim ki altmış tool'u olan bir server için maliyet, fazla çok tool kabul edildiğinin işaretidir.

Gecikme ve erişilebilirlik. Her çağrı bir süreci ya da ağı aşar. Gate, credential verme ve sonuç kontrolleri zaman ekler ve uzak bir server, kesintileri Parcelport'un kesintileri olan bir bağımlılık ekler. Bir breaker (Bölüm 13) ve bir fallback (Bölüm 14) etkiyi sınırlar; sıfır yapmaz.

Pin'in yardım etmeyi bıraktığı yer. Pin'leme tanımı korur, davranışı değil. Bir server tanımını aynı tutup tool'unun ne yaptığını değiştirebilir. Bu bölümdeki hiçbir şey bunu tespit etmez ve etkinin kendisini gözlemek dışında bunu tespit eden bir host tarafı kontrol bilmiyorum. Kayıt, böyle bir drift'i sonradan görünür kılar. Dar bir credential yalnızca o credential'ın Parcelport tarafında nelere ulaşabileceğini sınırlar; üçüncü taraf bir server'ın kendi sistemlerinin içinde ne yaptığını host'un verdiği bir kapsam değil, server ve satıcı yönetir.

Bu kadarını ne zaman kullanmamalı. Kendi ağının içinde, kendi ekibinin yazdığı ve işlettiği salt okunur bir server için tam bir pin'leme workflow'u, riskin gerekçelendirdiğinden fazla makinedir. Yine de server allowlist'ini, host'a ait sözleşmeyi, sonuç sınırlarını ve kaydı tutardım ve tanımları bir insan review queue'su yerine build pipeline'ında pin'lerdim. Tersine, bir server'ın tool'ları para taşıyabiliyor, mesaj gönderebiliyor ya da production'ı değiştirebiliyorsa, hiçbir kolaylık review'u atlamayı haklı çıkarmaz ve server'ın itibarı ne olursa olsun etki onayın (Bölüm 15) arkasına aittir.

Bunun kapsamadığı şeyler. Kendisi ele geçirilmiş bir host, farklı çağırılara farklı davranan bir server ve her alanında doğru olan zehirlenmiş bir doküman, bir allowlist ve bir pin'in göremeyeceği şeylerdir. Bölüm bir server'ın blast radius'unu azaltır ve davranışını görünür kılar. Bir server'ı güvenli yapmaz.

Sık yapılan hatalar

- **Etikete güvenmek.** Cazip, çünkü server'ın yazarı tool'u en iyi bilen kişidir; bu yüzden salt okunur ipucu etki sınıfına girer. Çözüm, etki sınıflarını Parcelport'un kendi tool tablosunda atamak ve server başına bir etki tavanı uygulamaktır.
- **Server'ın açıklamasını olduğu gibi geçirmek.** Cazip, çünkü bir sözleşme yazmaktan kurtarır; bu yüzden model server'ın tool metnini görür. Çözüm, host'a ait sözleşmeyi göstermek ve server'ın tanımını yalnızca pin karşılaştırması için kullanmaktır.
- **Konfigürasyonla bağlanmak.** Cazip, çünkü bir konfigürasyon satırı bir server'ı denemenin en hızlı yoludur ve bir geliştiricinin yerel kurulumu production'a ulaşabilir. Çözüm, yalnızca merkezi allowlist'teki server'ları bağlamaktır.
- **Credential iletmek.** Cazip, çünkü token zaten çalışıyor; bu yüzden host'un ya da bir kullanıcının token'ı server'a gider. Çözüm, o server, o çağrı ve o tool için bir credential vermektir.
- **Her tool'u açığa çıkarmak.** Cazip, çünkü server'ın listesi varsayılandır. Bir server'ın kırk tool listelediğini ve modelin kırkını da gördüğünü varsayalım. Çözüm, göreve göre boyutlandırılmış, agent başına allowlist yapmaktır.
- **Salt okunur olanı güvenli saymak.** Cazip, çünkü hiçbir şey değiştirilemez. Salt okunur bir server state'i değiştiremez, ama çıktısı yine de talimat taşıyabilen dış veridir. Çözüm, onu sınırlamak, köken bilgisini işaretlemek ve taint'lemektir; arkasında Bölüm 16 vardır.
- **Host tarafı kaydı atlamak ya da bir kez review etmek.** Cazip, çünkü server log tutuyor ve review geçti. Server'ın log'ları ve ilk review, sonradan güvenilmesi gereken şeyler değildir; her çağrı kendi trace'ine kaydedilmeli ve pin'in ilk review'u her bağlantıda bir kontrole dönüştürmesine izin verilmeli.

Temel çıkarımlar

- Bir MCP server'ı bağlamak bir güven sınırı açar: tanımları, sonuçları ve ipuçları orchestrator'ın dışından gelir ve bir kararın girdileridir, kararın kendisi değil.

- MCP, bir host'un bir server ile nasıl konuştuğunu standartlaştırır ve güveni, yetkiyi ve doğrulamayı uygulayana bırakır.
- Host, her MCP tool'unun sözleşmesine sahiptir; açıklaması, etki sınıfı ve hata biçimi dahil; modele server'ın metni değil, bu sözleşme gösterilir.
- Bir server allowlist'i, bir tool allowlist'i ve pin'lenmiş bir tanım, bir server'ın değişikliklerini görünür kılar ve yollarına bir reviewer koyar; hiçbirini değişmemiş bir tanımın arkasındaki davranış değişikliğini tespit etmez.
- Bir MCP tool çağrısı, diğerleri gibi aynı gate'ten geçer; credential çağrı başına ve dar kapsamla verilir, sonuç boyutça sınırlanır, biçimce kontrol edilir ve bağlama ulaşmadan önce güvenilmez işaretlenir.
- Salt okunur server'lar ve küçük tool kümeleri tercih edilmeli ve salt okunur olmanın bir server'ın neler yapabileceğini sınırladığı, çıktısının neler söyleyebileceğini sınırlamadığı unutulmamalı.
- Bir server yazılıyorsa, aynı sözleşme, yetki ve rate limit disiplinleri kendi tarafında uygulanmalı; çünkü bir server kendi tool'ları için gate'tir.

Server'lar modelin bağlamı için bir malzeme kaynağıdır ve bağlamın başka kaynakları da vardır: ticket'lar, retrieve edilen pasajlar, önceki step'ler ve bellek. Bölüm 9, orchestrator'ın bunların hepsini nasıl derlediğine, her parçanın nereden geldiğini nasıl etiketlediğine ve modelin neyi göreceğine nasıl karar verdiğine döner.

KISIM III

Bağlam, State ve Bellek

Bölüm 9 — Bağlam Yönetimi

Parcelport'ta uzun bir ticket thread'i düşünelim. Bir müşteri, hiç ulaşmayan bir paket için yazıyor ve iade istiyor. Thread zaten uzun: dört önceki mesaj, iletilmiş bir kargo bildirimi ve destek ekibinden bir meslektaşın cevabı. Destek agent'ının ilk step'inin modelin önüne bir şey koyması gerekiyor ve prototipin cevabı, çoğu prototipin verdiği cevap. System prompt'u alıyor, bütün thread'i ekliyor, o âna kadarki her tool sonucunu ekliyor, bir dokümantasyon aramasından gelen ilk üç hit'i ekliyor ve hepsini gönderiyor.

Aramanın aynı iade politikasının iki sürümünü döndürdüğünü varsayalım; biri geçersiz kılınmış, biri güncel, aynı parça biçiminde ve tarihsiz. Müşteri profilinin servisin tuttuğu her alanla geri geldiğini varsayalım. İletilmiş bildirimin talimat gibi okunan bir cümle içerdiğini varsayalım. Derlenmiş metindeki hiçbir şey bunlardan hangisinin Parcelport'un kendi kuralı, hangisinin bir müşterinin iddiası ve hangisinin geçen bahar doğru olan bir doküman olduğunu söylemiyor. Model tek bir metin bloğu alıyor ve tek bir akıcı cevap üretiyor. Cevap eski politikaya atıf yapıyor ve modele gerçekte neyin gösterildiğini sonradan kimse söyleyemiyor.

Bu bölüm kontrol zarfının **Bağlam** parçasına aittir ve o parçanın ilk sorusunu cevaplar: model ne görüyor, her parça nereden geldi ve ona ne kadar güvenilebilir? Bölümün savunduğu cevap şu: bağlam, birinin yazdığı bir string değildir. Kaynakları seçen, sıralayan, etiketleyen, sınırlayan ve kaydeden deterministik kodun çıktısıdır.

Sorun ve neden zor olduğu

Bir model çağrısının kendi belleği yoktur. Modelin bu ticket, bu müşteri ve bu politika hakkında "bildiği" her şey, orchestrator'ın o tek çağrı için bağlama koyduğu şeydir. Bu, derlemeyi agent'taki en kaldırıcı kod parçası yapar: diğer her kontrol ona bağlıdır. Gate, öneriyi olgulara karşı kontrol

eder, ama yanlış bir bağlam üzerine kurulmuş bir öneri geldiğinde zaten yanlıştır. Dayanaklı bir cevapla dayanaksız bir cevabın yollarının ayrıldığı yer bağlamdır, çünkü model yalnızca kendisine verilene dayandırılabilir.

Birkaç hata sınıfı burada başlar. F3 (dayanaksız iddia), bağlamda cevabın ihtiyaç duyduğu olgu eksik olduğunda ya da onun iki çelişen sürümü bulunduğu büyür, çünkü model boşluğu makul bir cümleyle doldurur. F4 (talimat ele geçirme), Parcelport dışından gelen metin kurallarla aynı ayırt edilmemiş blokta durduğunda büyür, çünkü hiçbir şey onu veri olarak işaretlemez. F5 (kontrolden çıkan döngü ya da bayat bağlam) zamanla ortaya çıkar: step 2'de okunan bir olgu, system of record değiştikten çok sonra, step 9'da hâlâ bağlamdadır. F9 (maliyet ya da gecikme patlaması), bağlam her step'te büyüdüğünde ve sonraki her çağrı daha önce gelen her şeyin bedelini ödediğinde ortaya çıkar. F8 (gözlenmeyen davranış) ise bir olay review'unda kimse modelin ne gördüğünü söyleyemediğinde ortaya çıkar.

Bariz yaklaşım dört nedenle işe yaramaz. Birincisi, bağlam sonludur. Bağlam penceresi, bir modelin tek çağrıda alabileceği malzeme miktarıdır; sınırlı bir kaynaktır ve politikasız ekleyen bir döngü bu sınırla en kötü anda, uzun bir ticket'ın ortasında karşılaşır. İkincisi, daha fazla bağlam daha iyi bağlam değildir. İlgisiz, bayat ya da çelişen malzeme sessizce durmaz; önemli olan malzemeyle yarışır ve modelin hangisinin hangisi olduğunu söylemenin güvenilir bir yolu yoktur. Üçüncüsü, kaynakların güven düzeyi farklıdır ve bir metin bloğu bu farkı siler. Dördüncüsü, olağan çare, system prompt'ta modele yeni dokümanları tercih etmesini ve e-postalarda bulunan talimatları yok saymasını söyleyen bir paragraf, bir istektir. Hatanın oranını düşürür ve tuttuğu günlerde tutar.

Bu son nokta, bunun neden bir mühendislik sorusu olduğunu açıklar. Hangi kaynağın kaç token alacağı, hangi sırayla, hangi etiketle ve bir şey sığmadığında ne olacağı, kodun her seferinde aynı biçimde verebileceği, test edebileceği ve kaydedebileceği kararlardır. Modelin payı, kendisine verileni okumaktır. Ondandır her şey sıradan mühendisliktir.

Bağlam derlenir, biriktirilmez

Prototip biriktirir: her step büyüyen bir transcript'e ekleme yapar. Hedef tasarım derler: her step bağlamı, run'ın state'inin bir fonksiyonu olarak, bir politika altında, kaynaklardan baştan kurar. Fark küçük görünür ve nelerin mümkün olduğunu değiştirir. Bir transcript yalnızca büyüyebilir; bir derleyici ise atabilir, değiştirebilir, yeniden sıralayabilir ve tazeleyebilir. Transcript'te olan her şeydir; derlenmiş bir bağlam ise tasarımın bu çağrı için modelin görmesine karar verdiği şeydir.

Bölüm 1'deki kanonik step `assembleContext(run)` ile başlar. Bu bölüm o fonksiyonu açar. Beş işi vardır ve bölümün geri kalanı onları sırayla ele alır: kaynaklardan öge seçmek, her birini köken ve güvenle etiketlemek, öncelik sırasına göre bir bütçeye sığdırmak, yapı anlam taşıyıcı diye sıralamak ve neyin seçildiğini yazıya geçirmek.

Kaynaklar ve güven düzeyleri

İlk tasarım kararı kaynakların listesidir ve her biri için ne kadar güvenilebileceği. Buradaki güven, kaynak hakkında bir his değildir. Somut bir soruyu cevaplar: bu kaynaktan gelen metin bir talimat olarak mı ele alınabilir, yoksa yalnızca veri olarak mı? Destek agent'ı için liste kısadır.

Kaynak	Yazan	Güven	Yanlış etiketlenirse tipik hata
Sistem talimatı	Platform ekibi, sürümlenmiş	Talimat	F4, kullanıcı metninin yuvasını paylaşmasına izin verilirse
Politika digest'i	Politika sahibi, politika verisinden üretilmiş	Talimat düzeyinde betimleme	F3, digest gate'in uyguladığından saparsa
Müşteri mesajı ve ticket metni	Müşteri ya da ona yazan kişi	Güvenilmez veri	F4
Tool sonuçları	Parcelport servisleri, ama serbest metin alanlarıyla	Güvenilmez veri	F4, F5
Retrieval sonuçları	Karışık yaşta dahili dokümanlar	Güvenilmez veri, bir sürümle	F3, F5
Bellek	Önceki run'lar (Bölüm 11)	Doğrulanana kadar güvenilmez veri	F4, F5

Kaynak	Yazan	Güven	Yanlış etiketlenirse tipik hata
Orchestrator notları	Kod: retler, özetler, state olguları	Türetilmiş, girdilerinin en düşük güvenini devralır	F3

İki satır bir yoruma değer. Politika digest'i, gate'in neyi uyguladığının bir betimlemesidir, uygulamanın kendisi değil; digest'teki iade tavanı, modelin reddedilecek şeyi önermekten kaçınmasına yardım eder ve gate, digest söylesin ya da söylemesin tavanı kontrol eder. Dolayısıyla digest, F7'ye (yetkisiz etki) dönüşmeden yanlış olabilir ve yine de gate'in okuduğu aynı veriden üretilmelidir, yanında elle sürdürülmemelidir.

Tool sonuçları satırı, ekiplerin tartıştığı satırdır. `orders-service`'ten gelen bir sonuç Parcelport'un kendi verisidir, öyleyse neden güvenilmez? Çünkü güven, servislere değil alanlara bağlanır. Siparişin durumu kontrollü bir değerdir; müşterinin ödeme sırasında yazdığı teslimat notu ise servisten değişmeden geçmiş serbest metindir. Bölüm 5, gözlemleri her biri kökenini ve bir güven etiketini taşıyacak biçimde şekillendirir ve iki türü de karıştıran bir sonuç, en az güvenilen alanıyla etiketlenir. Şüphede kalındığında etiket düşük olandır.

Bu tablonun bir satırında "güvenilir" yazan bir sürümü vardır. O sözcük konusunda dikkatli olurdum. Sistem talimatı ve politika digest'i, modelin onlara uyacağı garanti olduğu için değil, Parcelport onları değişiklik kontrolü altında yazdığı için talimat düzeyindedir. Bölüm 2, modelin uyumunun neden varsayılamayacağını ele alır ve Bölüm 16, uymadığında tutan kontrolleri kurar.

Her ögede köken

Derlemenin birimi bir bağlam ögesidir. Her biri, derleyicinin onu bütçelebileceği, gate'in onun hakkında akıl yürütebileceği ve bir reviewer'ın onu izleyebileceği kadar metadata taşır. Aşağıdaki notasyon açıklayıcıdır, Bölüm 6'daki sözleşmelerin tarzındadır.

```

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

```

Modelin ihtiyaç duyma olasılığı olan alanlar, gövdenin yanında bağlama render edilir: kaynak, as-of tarihi ve sürüm. Gerisi orchestrator'da kalır. Bu ayırım, bir etiketle bir kontrol arasında çizmeye devam ettiğim çizgi için önemlidir. "güvenilmez ticket metni" gibi render edilmiş bir etiket, modelin bir pasajı veri olarak ele almasına yardım eder ve diğerleri gibi bir istektir. Etiket bir kontrol yapan şey, `trust` alanının kodda değerle birlikte taşınmasıdır. Model daha sonra adres string'i yalnızca güvenli bir öğede geçen bir `update_shipping_address` önerdiğinde, gate bunu görebilir ve Bölüm 16 bu konuda ne yaptığını anlatır. Render edilmiş etiket modele bir nezakettir; alan ise kontroldür.

Alanlardan çıkan ve tek başına söylenmeye değer bir kural var: bir tool çağrısının argümanlarındaki sipariş id'si bir tool sonucundan ya da run state'inden gelmelidir, hiçbir zaman mesaj metninden değil. Gate, id'nin `origin`'ini kontrol eder ve yalnızca güvenli bir ticket ögesinde geçen bir id, model ne önermiş olursa olsun reddedilir ya da onaya gönderilir.

Sıra ve yapı

Konum ve ayraçlar derlemenin parçasıdır ve içlerinde prompt mühendisliği büyüğü yoktur. Üç kural yeter. Talimat düzeyindeki öğeler önce gelir ve kendi bölümlerinde render edilir. Güvenilmez öğeler, her biri kendi köken satırıyla, açıkça sınırlandırılmış bloklarda render edilir; böylece trace'i okuyan, modelin gördüğü yapıyı görür. Ve görev en sona gelir, orchestrator tarafından run'ın state'inden ifade edilir, müşterinin metninden alınmaz.

Ayraçlar için bundan fazlasını iddia etmezdim. Güvenilmez metnin çevresindeki bir çit, hata oranını genellikle düşüren bir konvansiyondur ve bir saldırgan çit gibi görünen metin yazabilir. Derleyici yapıyı modele yardım etmek ve kaydı okunaklı tutmak için kullanır. Ele geçirilmiş bir öneriyi durduran kontrol düzende değildir; gate'teki taint kurallarındadır.

Kısa bir pseudocode bloğu, bütçe şimdilik soyutlanmış olarak derleyicinin biçimini gösterir.

```
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
```

`require item.origin and item.as_of` satırı bölümdeki en ucuz kontroldür. Bir öğenin nereden ya da ne zaman geldiğini söyleyemeyen bir kaynak adapter'ı, bir olay review'unda değil, derleme zamanında bir testte başarısız olur.

Bütçe: bağlam sınırlı bir kaynaktır

Bağlam penceresi sonludur ve içindeki her token'ın bir bedeli vardır: para, gecikme ve başka bir şeyden alınan yer. Bu yüzden derleyicinin, adaylar sığmadığında ne olacağına dair bir politikaya ihtiyacı vardır ve politika, fazla uzun olan ilk ticket'tan önce var olmalıdır, çünkü bunu öğrenen o ticket olur.

Bütçeyi tek bir toplam olarak değil, kaynak başına paylar artı pin'li bir çekirdek olarak yazardım. Tek bir toplam, en büyük kaynağın geri kalanı dışarı itmesine izin verir; uzun bir e-posta thread'i o zaman politika digest'inin yerini alır ve run, kimsenin göremediği bir nedenle uzun ticket'larda kısalardan farklı davranır. Aşağıdaki sayılar açıklayıcıdır.

```
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
```

Son satır önemsedığım satırdır. Pin'li çekirdek sığmıyorsa, tasarımın onu kısaltmanın güvenli bir yolu yoktur ve run, yer açmak için bir politika satırını atmak yerine durup hand-off'a geçmelidir. Sessiz bir atma, başarı gibi görünen hatadır.

Kırpma, özetleme ve her birinin kaybettiği

Bir şeyin küçülmesi gerektiğinde iki dürüst seçenek ve bir cazip seçenek vardır. Kırpma keser: bir ön eki, bir son eki ya da en yüksek sıralı öğeleri tutar ve gerisini atar ve bunu söylemelidir. Derleyici kırpılmış bir öğeyi, tool adapter'ının Bölüm 5'te yaptığı gibi işaretler; böylece modele metnin kısmi olduğu söylenir. Özetleme, metni daha kısa metinle değiştirir ve bedeli daha incedir: bir model çağrısıdır (ya da bir kural), yanlış olabilir ve bilgiyi görünür bir boşluk bırakmayacak biçimde yok eder. Cazip seçenek, ikisini de bilerek yapmamak ve başka bir yerdeki bir limitin bağlamı denk geldiği yerden kesmesine izin vermektir.

Özetleme dört kural gerektirir, çünkü kendi hata biçimleri olan yeni, türetilmiş bir öge üreten bir dönüşümdür.

1. **Bir özet türetilmiş bir öğedir.** Kaynaklarına işaret eden `derived_from`'u, bir `as_of` zaman damgasını ve girdilerinin en düşüğü olan bir güven düzeyini taşır. Müşteri metninin özeti müşteri

metnidir. Bir ele geçirme girişiminin, nötr sesli bir cümleye sıkıştırıldıktan sonra da etiketli kalması bu sayede olur.

2. **Bir kararın bağlı olduğu şeyi asla özetlememek gerekir.** Sipariş id'leri, tutarlar, para birimleri, onay durumları, idempotency key'ler ve müşterinin kimliği, gate ile orchestrator'ın run store'da tuttuğu olgulardır (Bölüm 10). Her step'te yapılandırılmış state olguları olarak enjekte edilirler; bir paraphrase'in bir rakamı değiştirebileceği özetin içinde düzyazı olarak taşınmazlar.
3. **Orijinal kalır.** Tam metin run store'da ya da ticket sisteminde durur; bağlam yalnızca kısa biçimi taşır. O zaman özetleme kalıcı olarak hiçbir şey kaybetmez ve bir reviewer ikisini karşılaştırabilir.
4. **Bir özet bir öneridir.** Onu bir model yazıyorsa, diğer her çıktı gibi dayanaksız bir iddia olabilir (F3); bu yüzden her öneriyle aynı şüpheyi hak eder ve yukarıdaki olgular bu nedenle onun dışında kalır.

Uzun bir run boyunca büyüme

Bağlam büyür, çünkü run'lar büyür. Her step bir gözlem ekler; her turn müşteri metni ekler; step 3'ün retrieve edilen pasajları step 12'de hâlâ oradadır. 15 step'lik bir run ve sekiz turn'lük bir thread varsayalım: sınırsız birikim, son step'in çağrısını ilkinden birkaç kat ağır yapar ve fazladan ağırlığın çoğu artık önemini yitirmiş malzemedir.

Derleyici büyümeyi, her öge türünün nasıl eskiyeceğine dair bir politikayla ele alır. Tool gözlemleri, kullanıldıktan sonra, diyelim iki step sonra, tek satırlık bir digest ile değiştirilir ve tam sonuç id ile run store'dan alınabilir kalır. Retrieve edilen pasajlar, bir sonraki step onlara atıf yapmadıkça atılır. Bir pencereden eski konuşma turn'leri yukarıdaki kurallar altında özetlenir; yalnızca bir karar taşıyan turn'ler, örneğin bir müşterinin bir iade tutarını kabul etmesi, olduğu gibi tutulur ve kod tarafından işaretlenir. Mevcut ticket'ın ilk mesajı pin'lidir, çünkü özgün isteği ifade eder.

Aynı örüntü, araştırmalarında büyümenin en çok ısırdığı ops agent'a da uyar: bir `query_logs` sonucu büyüktür, sonraki çağrı filtreyi daraltır ve önceki sonuca nadiren yeniden ihtiyaç duyulur. Orada run'ın bulguları state'te yaşar (Bölüm 10) ve bağlam ham log'ları değil bulguları taşır. Bölüm 12, sırada ne yapılacağına karar veren döngüyü ele alır; bu bölümün derdi, döngünün kendi geçmişinin bedelini ödememesidir.

Retrieval: ne geri gelir, ne gelmez

Retrieval, bağlama koymak üzere bir store'dan malzeme çekmektir. Destek agent'ı için olağan durum `search_docs` 'tur: müşteri bir iade süresini ya da bir kargo kısıtını soruyor ve cevap bir dokümanda yaşıyor. Retrieval, F3 ve F5 hatalarının çoğunun girdiği yerdir, çünkü store'un tuttuğu her şeyin, ilgili olsun olmasın, sıralı bir listesini döndüren, deterministik görünümlü bir step'tir.

Hybrid search

Metin üzerinde arama iki zıt biçimde başarısız olur. Anahtar sözcük eşleştirmesi tam terimi bulur ve aynı şeyi farklı sözcüklerle anlatan dokümanı kaçıır; anlamı embedding'ler aracılığıyla karşılaştıran semantik eşleştirme komşuyu bulur ve müşterinin alıntılacağı tam kodu ya da ifadeyi kaçırabilir. **Hybrid search** ikisini de çalıştırır ve sıralamalarını birleştirir; bu genellikle ikisinden birinden daha iyi recall verir, bedeli kurulacak ve taze tutulacak iki indekstir. Bir destek corpus'u için onu seçerdim, çünkü müşteriler iki üslupta da yazar: hata kodlarını ve kargo adlarını tam olarak alıntılarlar ve sorunları gevşek biçimde tarif ederler.

Hybrid search, geri gelenleri iyileştirir. Neyin kullanılacak kadar iyi olduğuna karar vermez. O karar bir eşittir ve bu başlığın konusu olan kontrol odur.

Bir relevance floor ve "uygun eşleşme yok"

Bir arama sistemi, ondan istenen bu olduğu için, hiçbir soruyu cevaplamasa da ilk k sonucu döndürür. Store'da Parcelport'un hizmet vermediği bir ülke için bir gümrük formu hakkında hiçbir şey yoksa, ilk üç sonuç yine de üç dokümandır ve en yakını başka bir yer için gümrük formları hakkında olacaktır. Bağlama konduğunda cevap gibi okunur. Cevap muhtemelen onun üzerine kurulur, çünkü sorunun biçimine uyan bir pasaj, bağlamın sunduğu en iyi kanıttır.

"Uygun eşleşme yok"u birinci sınıf bir sonuç olarak ele alırdım. Bir relevance floor, belirli bir skorun altında retrieval step'inin boş bir liste ve bir reason döndürdüğünü söyler ve derleyici boş listeyi bilgi olarak ele alır: bağlam, corpus'un arandığını ve ilgili hiçbir şey bulunmadığını söyler. Agent o zaman bu bilgiye sahip olmadığını söyleyebilir, açıklayıcı bir soru

sorabilir ya da ticket'ı `escalate_to_human` ile bir insana devredebilir. Üçü de en yakın zayıf hit'in üzerine kurulmuş kendinden emin bir cevaptan iyidir. Bu yazı yazıldığı sırada Contextator, hiçbir şey relevance floor'unu geçmediğinde zayıf bir hit döndürmek yerine "uygun eşleşme yok" cevabı verir; diğer araçlar da benzer yaklaşımlar izliyor ve bağlam derleyici boş bir sonucu bilgi olarak ele almalıdır.

Floor'u belirlemek görüldüğünden zordur ve söz konusu corpus için doğru değeri bilmiyorum; skorların nasıl üretildiğine bağlıdır. Örneğin birleştirilmiş bir sıra skoru, mutlak bir alaka yargısını değil, diğer sonuçlara göre konumu ifade eder; dolayısıyla üzerine konan bir floor'un anlam taşıması için ayrı bir benzerlik kontrolü ya da bir reranking aşaması gerekebilir. Karar vermenin yolu ampiriktir. Bilinen cevapları ve bilinen cevapsızları olan gerçek soruların bir golden set'ini almak (Bölüm 21 onun nasıl kurulacağını anlatır), her biri için skor dağılımına bakmak ve floor'u, yanlışlıkla döndürülen zayıf hit'lerin ve yanlışlıkla bastırılan iyi hit'lerin en az maliyetli olduğu yere koymak gerekir. İki hata da gerçektir ve farklı fiyatları vardır. Çok yüksek bir floor, bir dokümanın cevaplayabileceği ticket'ları insanlara gönderir; çok düşük bir floor ise zayıf kanıtı bağlama koyar.

```
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
```

Retrieval bağlama iki yoldan ulaşır ve tasarım, belirli bir step'in hangisini kullandığını söylemelidir. Yukarıda gösterilen A yolunda orchestrator derleme zamanında kendi başına retrieve eder ve sorguyu görevden ve

run state'inden kurar; model hiçbir şey önermez, dolayısıyla sorguyu genişletemez. Müşteri metni yine de görevi şekillendirir; yani bu, sorguyu daraltır ve ticket'tan yalıtırmaz. B yolunda model bir `search_docs` çağrısı önerir ve sorgu, Bölüm 8'deki sözleşmenin tanımladığı gibi modelin sağladığı bir argümandır: bir okuma tool'unda, uzunluk limitli bir string. Gate onu diğer her çağrı gibi doğrular ve sonuç, A yoluyla aynı floor, sürüm filtresi ve etiketlerden, güvenilir ve sınırlı olarak girer. A yolu, belirli bir türdeki her ticket için cevaplanması gereken bir soruda varsayılandır; B yolu, run'ın ortasında gerekli olduğu anlaşılan şey içindir ve sorgusu, ona yol açan metin kadar yönlendirilebilir.

Bloktaki boş durum hiçbir şey değil, bir not üretir. Sessizlik belirsizdir: model "arama hiçbir şey bulmadı" ile "arama hiç çalıştırılmadı"yı ayırt edemez ve ikinci durumda eğitim sırasında özümsemiği her şeyden cevap verebilir; bu, bütün kaynakların en dayanaksızdır.

Uyarı: Para, teslimat vaatleri ya da bir müşterinin neye hakkı olduğu hakkındaki bir cevap, retrieve edilmiş ya da tool'un sağladığı bir kaynağa dayandırılmalıdır. Retrieval step'i "uygun eşleşme yok" döndürdüyse ve taslak cevap yine de bir politika beyan ediyorsa, tasarımda bağlam ile iddia arasında bir boşluk vardır. Model cevap verdikten sonra koddaki bir kontrol, örneğin bir politika iddiasının bağlamda bulunan bir öge id'sine atıf yapmasını şart koşturmak, kontroldür; atıf yapma talimatı yalnızca bir istektir (Bölüm 4, bu tür kontrollerin nereye ait olduğunu ele alır).

Bayat içerik, sürümler ve tarihler

Dahili bir doküman iyi yazılmış, ilgili ve yanlış olabilir. Politikalar değişir; eski sayfa indekste kalır. Bu, bölümün F5 yarısıdır, zaman içinde bir bağlam hatasıdır ve alaka skorlaması bunu yakalamaz: geçersiz kılınmış iade politikası, güncel olanla yaklaşık aynı skoru alır, çünkü neredeyse aynı şeyi söylerler.

Kontroller metadata ve bir kuraldır. İndekste her doküman bir sürüm, bir geçerlilik başlangıç tarihi ve geçersiz kılındığında bir geçerlilik bitiş tarihi taşır ve retrieval adapter'ı bunları ögenin `version` ve `as_of`'u olarak sunar. Yukarıdaki bloktaki kural, `isEffective`, geçerlilik dönemi kararın ilgili olduğu tarihi kapsamayan dokümanları atar; bu, bir iade sorusu için

sipariş tarihi ya da ticket tarihidir ve zorunlu olarak bugün değildir. İki sürüm de geçtiğinde derleyici, farkın göreve önemli olup olmamasına göre ya yalnızca en yenisini tutar ya da ikisini tarihleriyle tutar ve bunu söyler. Metadata eksikse doküman düşük öncelik ve bir "tarihsiz" işareti alır ve tarihsiz bir dokümanın para hakkındaki bir iddianın tek dayanağı olmasına izin verilmez.

Köken, bir run'ın öbür ucunda da yardımcı olur. Modelin erken okuduğu olguların bir `as_of`'u vardır ve derleyici onu sonuçları olan bir step'ten önce system of record ile karşılaştırabilir. Sipariş step 1'de okunduysa ve `update_shipping_address` step 4'te öneriliyorsa, gate'in paketin kargo hand-off durumuna dair ön koşulu, bağlamdaki hiçbir şeye karşı değil, `shipping-service`'in taze bir okumasına karşı kontrol edilir. Bu, Bölüm 10'daki örüntüdür: bağlam, bir etkinin bağlı olduğu hiçbir şey için doğruluk kaynağı değildir.

Retrieval nerede çalışır

Retrieval orchestrator'da, yukarıdaki blokta olduğu gibi, ya da modelin önünde çalışabilir. Bu yazı yazıldığı sırada bir model gateway'i olan RAGmux, retrieval'ı kendisi çalıştırabilir ve pasajları model çağrısından önce enjekte edebilir; diğer araçlar da benzer yaklaşımlar izliyor ve mesele, pasajların yolun neresinde seçildiğidir. Örüntü üründen daha önemlidir: pasajlar derleyiciden başka bir şey tarafından seçilip enjekte edildiğinde, derleyici onları etiketleyemez, maliyetlerini bütçeye karşı sayamaz ve manifest'ine yazamaz; bağlamın ayrıcalıklı bir konumuna enjekte edilen pasajlar da bir retrieval sonucunun hak ettiğinden fazla yetkiyle gelir.

Harekete geçen bir agent için retrieval'ı orchestrator'da tercih ederdim, çünkü köken, floor, sürüm kontrolü ve kayıt zaten orada yaşar. Retrieve eden bir gateway, tool'u ve etkisi olmayan, zayıf bir hit'in bedelinin yanlış bir eylem değil yanlış bir paragraf olduğu basit bir soru-cevap endpoint'i için anlamlı olabilir. Bir agent için kullanılırsa, gateway'in enjeksiyonlarının derleme kaydının parçası olması başka bir yoldan sağlanmalıdır ve gateway'in enjekte ettiği her şey, hangi yuvada olursa olsun, tasarımda güvenilirmez etiketlenmelidir.


Bellek ve diğer kaynaklar

Tablodaki geri kalan kaynak, Bölüm 11'in sahip olduğu bellektir. Bu bölüm için kural, onun bağlama girişiyle ilgilidir: bir bellek ögesi diğerleri gibi girer; köken, bir güven etiketi, bir öncelik ve bir maliyetle ve kendi payı altında, böylece eski notların uzun bir listesi ticket'ı dışarı itemez. Nereden geldiğini ve ne zaman yazıldığını söyleyemeyen bellek derlenmez. Belleğin neyi içerdiğini ve kimin yazabileceği Bölüm 11'in sorularıdır.

Aynı disiplin bir MCP server'ının sunduğu her şeyi kapsar (Bölüm 8): çıktısı `tool_result` ya da `retrieval` kaynağının bir ögesi olarak gelir, kökeninde server olacak biçimde güvenilir etiketlenir ve aynı bütçeye sayılır.

Bir pipeline olarak derleme

Diyagram tek bir derlemeyi gösterir. Soldaki kaynakları derleyiciye doğru izlemek, sonra iki çıktıya dikkat etmek gerekir: modelin gördüğü bağlam ve kayda giden manifest. Alttaki ret yolu, aceleyle yapılmış bir tasarımın dışarıda bıraktığı yoldur.



Pipeline'ın iki özelliği söylenmeye değer. Deterministiktir: aynı run state'i ve aynı kaynak sürümleri aynı bağlamı üretir; geçmiş bir çağrıyı yeniden üretilebilir kılan budur. Derleme yalnızca okur. Bir özet ayrı bir step tarafından üretilir, ki bu bir model çağrısı olabilir ve run store'da türetilmiş bir öge olarak saklanır; derleme saklanan özet alır ve asla bir tane oluşturmaz, böylece model çağrısı deterministik kısmın dışında kalır. Özetleme step'i bir turn'den sonra ve bir sonraki derlemeden önce çalışır; bütçe aşıldığında henüz saklanmış bir özet yoksa derleme işaretli kırpmaya düşer ve bunu kaydeder, yerinde özetlemez. Ve modelin neyi

göreceğini seçtiği hiçbir dalı yoktur. Model tool çağrılarını önerir ve izin verilirse bir retrieval çağrısı da bunlardan biridir, ama o çağrıdan bağlama giren şey aynı etiketlerden ve aynı floor'dan geçer.

Modelin ne gördüğünü kaydetmek

Bir iade itiraz edildiğinde ya da bir cevap artık var olmayan bir politikaya atıf yaptığında, review'daki ilk soru modele ne gösterildiğidir. Cevap "bugünkü haliyle system prompt, artı muhtemelen thread" ise, tasarımın Bağlam parçasında bir F8 (gözlenmeyen davranış) problemi vardır. Trace biçimine Bölüm 20 sahiptir; bu bölüm, derleyicinin ona katkısına sahiptir.

İki düzeyde kaydederdim. **Manifest** küçüktür ve her zaman yazılır: her step için, kaynak, köken, sürüm, `as_of`, güven, maliyet ve bir içerik hash'yle birlikte öge id'lerinin sıralı listesi, artı atılan öğeler ve onları atan kural. Manifest "ne gördü ve ne görmedi" sorusunu cevaplar. **Render edilmiş bağlam**, gönderilen tam metindir. Daha büyüktür ve müşteri metni tutar; bu yüzden trace pipeline'ının saklama ve redaction kuralları altında yazılır, belki örneklenen run'lar için ve bir hand-off ya da bir retle biten her run için. Derleme deterministik olduğundan, manifest artı atıf yapılan öğelerin içeriği, kaynaklar sürümlerini koruduğu sürece render edilmiş bağlamı yeniden kurmaya yeter; tam metin, korumadıklarında tutulan şeydir.

Kaydetmenin bir maliyeti vardır ve maliyet çoğunlukla veri hacmi ve ifşadır. Bir bağlam store'u, müşteri verisinin ikinci bir kopyasıdır. Onu **kişisel olarak tanımlanabilir bilginin (PII)** gerekenden uzun süre yaşadığı bir yer yapmamak gerekir; varsayılan olarak hash'lerin ve id'lerin, istisna olarak tam metnin saklanması nereden budur.

En temiz PII, hiç derlenmemiş PII'dır

Derleyici, PII'nin bağlamın dışında tutulabileceği son noktadır da. PII destek agent'ının bağlamına üç yoldan girer: ticket metni, görevin ihtiyaç duyduğundan fazla alan döndüren bir profil lookup'ı ve gösterilenleri yansıtan modelin kendi önerdiği cevaplar. Kontrollere Bölüm 17 sahiptir. Derleme için tercih söylemesi basit ve bir bedeli olan bir şeydir: bir alan doğru öneriye ulaşmak için gerekli değilse bağlama hiç girmez.

Pratikte bu, tool adapter'larının Bölüm 5'in gösterdiği gibi projection'lar döndürmesi ve derleyicinin görevin tanımının listelemediği alanları geçirmemesi demektir. Müşteriyi adıyla karşılaması gereken bir cevap, kodun gönderirken doldurduğu bir placeholder taşıyabilir; böylece model adı hiç görmez. Bedel, bazı cevapların biraz daha şablon gibi ses vermesi ve bazı görevlerin yine de bir alana ihtiyaç duymasıdır. Bunlar görev başına verilip yazıya geçirilecek kararlardır, çünkü alternatif, bir servisin yanıtındaki her yeni alanın eklendiği gün sessizce bağlama girmesidir.

Parcelport: geciken paket ticket'ı

Açılıştaki ticket'a dönüp derleyiciyi onun içinden geçirelim; her sayı varsayımsaldır.

Orchestrator run'ı oluşturur ve run store'dan state olgularını yazar: ticket id, müşteri id'si, ticket'a bağlı sipariş id'si, politika olgusu olarak `refund_ceiling` ve bu ticket ve sipariş için hiçbir iade bulunmadığını söyleyen bir durum satırı. Bu öğeler pin'lidir. Sürümlenmiş sistem talimatı ve politika digest'i de pin'lidir.

Ticket thread'inin yedi girdisi vardır: dört önceki mesaj, iletilmiş bildirim, meslektaşın cevabı ve müşterinin iadeyi isteyen son mesajı. Derleyici ilk girdiyi, son ikisini ve iletilmiş bildirimi olduğu gibi tutar ve kalan üçünü, kaynakları güvenilirmez olduğu için güvenilirmez olan türetilmiş bir özetle değiştirir ve manifest değişikliği kaydeder.

İletilmiş kargo bildirimi, onu işleyecek bir sonraki sisteme bir direktif gibi okunan bir cümle içerir. Derleyici bunu tespit etmez. Bildirimi köken bilgisiyle güvenilirmez bir blokta render eder ve gate, bu bloğa kadar izlenen sonraki her argümanı Bölüm 16'nın taint kuralları altında ele alır. Bağlam, kontrole üzerinde çalışabileceği bir şey verir; kontrol değildir.

Step 1'de destek agent'ı `lookup_order` önerir; gözlem, serbest metin teslimat notu kırpılmış ve işaretlenmiş olarak Bölüm 5'teki gibi şekillendirilmiş biçimde gelir ve siparişin teslimat durumu "label created" yazar. Step 2'de model iade süresi için `search_docs` önerir (B yolu). İade politikasının iki sürümü gelir; geçersiz kılınmış olan, geçerlilik dönemi sipariş tarihinden önce bittiği için atılır ve güncel olan sürümü ve `as_of` uyla girer.

Step 4'te müşteri bir adres değişikliği ister ve destek agent'ı `update_shipping_address` önerir. Sipariş step 1'de paket hâlâ "label created" durumundayken okunmuştu; gate'in ön koşulu `shipping-service`'i taze okur ve paketin kargocuya teslim edildiğini bulur. Çağrı reddedilir ve ret bir gözlem olarak döner. Bağlam eski bir olgu tutuyordu ve onu yakalayan şey system of record'a karşı yapılan bir kontroldü.

Step 9'da müşteri, Parcelport'un hizmet vermediği bir varış yeri için bir gümrük formunu sorar. Hiçbir şey floor'u geçmez, bu yüzden derleyici dokümanların arandığını ve ilgili hiçbir şey bulunmadığını söyleyen bir not ekler. Model bir özetle `escalate_to_human` önerir ve Sam, daha zayıf bir tasarımın en yakın yanlış dokümana dayanan bir cevap göndereceği yerde, neyin bulunduğunu ve neyin bulunmadığını söyleyen bir ticket alır. Run orada biter: `handed_off` terminaldir (Bölüm 10) ve sonrasında olan şey bir insanın işi ya da yeni bir run'dır.

Trade-off'lar ve maliyetler

Kod olarak derleme, eklemekten daha fazla iştir. Her kaynak, köken, `as_of`, sürüm ve maliyet sağlayan bir adapter'a ihtiyaç duyar ve her adapter testlere ihtiyaç duyar. İlk maliyet mühendislik zamanıdır ve çoğunlukla bir kez ödenir; süregelen maliyet, yeni bir kaynağın ya da yeni bir alanın bir prompt'ta düzenleme değil derleme politikasında bir değişiklik olması, yani review ve deploy demektir. Bu, platform ekibi için bir özellik ve bu öğleden sonra bir fikri denemek isteyen biri için bir yükür. Makul bir uzlaşma, production-dışı bir konfigürasyonda, hiçbir zaman production derleyicisinde değil, deneyler için hızlı bir yoldur.

Bütçeler ve floor'lar cevaplara mal olur. Bir eşik, bir dokümanın cevaplayabileceği bazı ticket'ları insanlara gönderir ve her yükseltme, Sam'in ekibinin bir dakikasıdır. Kullanıcı metni için sıkı bir pay, modelin kullanabileceği geçmiş keser. Özetler ayrıntıyı atar. Bu maliyetlerin hiçbiri sıfır olamaz ve ölçülmediği sürece hiçbiri görünür değildir: golden set, floor'un iyi bir dokümanı bastırıp bastırmadığını ve bir özetin belirleyici bir cümleyi atıp atmadığını sınavan vakaları içermelidir (Bölüm 21).

Köken, manifest'ler ve kaydedilmiş bağlamlar depolamaya mal olur ve daha ciddi olarak, birinin yönetmesi gereken bir müşteri verisi store'u yaratır. Kayıt ne kadar eksiksizse saklaması o kadar dikkatli olmalıdır.

Ekipler bazen sorunu her şeyi kaydedip hiçbir şeyi okumayarak azaltır; bu tiyatro versiyonudur: kimsenin okumadığı bir log, bu durumda kimsenin içinden yeniden kurmadığı bir bağlam arşivi. Manifest'i kimin ve hangi soru için açacağı söylenemiyorsa, manifest ve örneklenmiş tam metinle başlamak gerekir.

Bunların hepsi ne zaman kullanılmaz. Tool'u olmayan, küçük sabit bir corpus'u olan ve paraya etkisi olmayan tek turn'lük bir asistan çok daha basit bir derleyiciyle çalışabilir: sabit bir prompt, tek bir retrieval çağrısı, bir floor ve bir kayıt. Pin'li çekirdek, paylar ve türetilmiş öge kuralları, run'ın birkaç step'i, farklı güven düzeyinde birkaç kaynağı ya da bir şeyi değiştiren bir tool'u olduğunda önem kazanır. Salt okunur bir soru-cevap endpoint'i için tam pipeline'ı kurmazdım ve iade tool'u olan bir destek agent'ını basit sürümle çalıştırmazdım.

Bunun bozulduğu yer. Derleyici modeli kendisine verileni okumaya zorlayamaz ve bir dokümanın doğru olup olmadığını belirleyemez; yalnızca dokümanın nereden geldiğini ve ne kadar eski olduğunu söyleyebilir. Güncel ve yanlış bir doküman, derleme değil editoryal bir sorundur. Ve herkesin düzenleyebildiği dahili bir wiki sayfası gibi güvenilir bir kaynağın içindeki metni kontrol eden bir saldırgan, güven sınırını taşımıştır; ögedeki etiket o zaman yanlıştır ve kontrol, o kaynağa kimin yazabileceğindedir. Bölüm 16, verinin kendisinin saldırı olduğu durumları ele alır.

Sık yapılan hatalar

- **Bağlamı bir transcript olarak görmek.** Her mesajı, gözlemi ve pasajı eklemek yapılması en kolay şeydir ve eksiksizlik gibi hissettirir. Maliyetin ve gürültünün run'la büyümesine yol açar ve bir limit sonunda ısırdığında, belki politika digest'inin içinden, denk geldiği yerden keser. Her step'te kaynaklardan bir politika altında derlemek, her kaynağa bir pay vermek, çekirdeği pin'lemek ve çekirdek sığmadığında hand-off'a geçmek gerekir.
- **Bir kararın bağlı olduğu olguları özetlemek.** Bir özet iyi okunur ve bir rakamı değiştirebilir ya da bir para birimini kaybedebilir. Id'leri, tutarları, onay durumlarını ve key'leri herhangi bir özetin dışında, yapılandırılmış state olgularında tutmak, orijinali alınabilir bırakmak

ve atılan bir cümlelerin bir kararı değiştirebileceği yerde işaretli kırpmayı tercih etmek gerekir.

- **Floor'suz ve sürümsüz top-k döndürmek.** Her zaman bir şey döndürmek "uygun eşleşme yok"u ifade edilemez kılar ve alaka skorlaması güncel politikayı geçersiz kılınmış olandan ayıramaz. Bir golden set üzerinde kalibre edilmiş bir floor belirlemek, boş sonucu bir nota çevirmek ve kararın ilgili olduğu tarih için sürüme ve geçerlilik tarihine göre filtrelemek gerekir.
- **Kontrol olarak render edilmiş bir etikete güvenmek.** Modele bir bloğun güvenilir olduğunu söylemek F4'ün oranını düşürür ve onu durdurmaz. **trust** ve **origin**'i değerlerle birlikte taşınan alanlar olarak tutmak gerekir, böylece gate onlar üzerinde işlem yapabilir (Bölüm 16).
- **İçeriğin derleyicinin göremediği yerden girmesine izin vermek.** Modelin önündeki bir katmanın enjekte ettiği pasajlar ya da bir servisin döndürmeye başladığı yeni bir alan, kimse seçmeden modelin gördüğünü değiştirir. Enjekte edilen çıktıyı derleme kaydına güvenilir olarak getirmek ve tool sonuçlarını listelenmiş bir alan kümesine projekte etmek gerekir.

Temel çıkarımlar

- Bağlam, öğeleri seçen, etiketleyen, sınırlayan, sıralayan ve kaydeden deterministik derleme kodunun çıktısıdır ve her step için yeniden kurulmalıdır, biriktirilmemelidir.
- Her bağlam öğesi köken ve güven düzeyini kodda alanlar olarak taşır, çünkü metinde render edilmiş bir etiket modele bir istektir ve değerle birlikte taşınan bir alan gate'in kullanabileceği bir kontroldür.
- Bütçe, kaynak başına paylar ve pin'li bir çekirdek yazılı bir politikadır ve çekirdek sığmadığında run, bir politika satırını atmaz, hand-off'a geçer.
- Özetler; kaynakları, bir zaman damgası ve girdilerinin en düşük güveniyle türetilmiş öğelerdir ve bir kararın bağlı olduğu olgular asla onların içinde taşınmaz.
- Retrieval, "uygun eşleşme yok"un gerçek bir sonuç olması için bir relevance floor'a ihtiyaç duyar ve boş bir sonuç bilgi olarak bağlama

girer, çünkü kanıt olarak sunulan zayıf bir hit F3'ün kurulma biçimidir.

- Dokümanların ve olguların sürümlere ve `as_of` tarihlerine ihtiyacı vardır ki bayat içerik (F5) filtrelenebilsin ve bir etkinin bağlı olduğu her şey etkiden önce system of record'dan yeniden okunur.
- Derleyici, modelin ne gördüğünün ve nelerin atıldığının bir manifest'ini yazar, böylece bir olay review'u ilk soruyu cevaplayabilir ve PII'yi varsayılan olarak bağlamın dışında tutar; ayrıntılar Bölüm 17 ve 20'dedir.

Bölüm 9, modelin tek bir step'te ne göreceğine karar verdi. Run'ın olgularının step'ler arasında nerede yaşadığını, süreç step 7'de öldüğünde ya da bir insanın onaylaması üç saat sürdüğünde ne olduğunu ya da iki run'ın aynı ticket üzerinde aynı anda hareket etmekten nasıl kaçındığını söylemedi. Bu, state'tir ve Bölüm 10 onu bağlamın dışında, run store'da kurar.

Bölüm 10 — State

Parcelport'taki bir ops agent'ı düşünelim: bir soruşturmanın ortasında ve bu soruşturma, onu yürüten process'ten daha uzun yaşamak üzere. `deploy-service` için bir alert tetiklenmiş ve agent onu üstlenmiş. On dört step boyunca log'ları okuyor, iki trace çekiyor, son deployment'ın öncesiyle sonrasındaki hata oranlarını karşılaştırıyor ve yeni sürümün olası neden olduğunu buluyor. 15. step'te `request_rollback` öneriyor. Politika bu çağrı için onay istiyor, bu yüzden run askıya alınıyor ve on-call SRE'si Robin'e bir istek gidiyor.

Robin başka bir olayın ortasında ve iki saat sonra, onayın süresi dolmadan cevap veriyor. Bu iki saat içinde platform ekibi orchestrator'ın rutin bir release'ini çıkarmış ve bütün worker process'leri yeniden başlamış. Run hâlâ onay queue'sunda, ama çalışan hiçbir process onun ne yaptığını bilmiyor. Bir worker onu alıyor ve yarım kalmış bir soruşturmaya ne yapacağına karar vermesi gerekiyor.

Worker kolay yolu seçsin ve run'ı alert'ten yeniden başlatsın. Model aynı log'ları okur, aynı sonuca varır ve rollback'i ikinci kez önerir. Ya da worker eski transcript'i yeniden oynatsın; model, içinde bir rollback'in önerildiği bir geçmiş görünce, rollback'in başlatıldığını söyleyen bir cümle üretir. İkisi de iyi bir yer değil. Bir restart'tan, uzun bir bekleyiştikten ve ikinci bir worker'dan sağ çıkabilmesi için bir run, modelin dışında neyi saklamalı?

Bu bölüm kontrol zarfının iki parçasına aittir. Run'ın kendisi hakkında bildikleri açısından **Bağlam**'dır: model ne görüyor ve bu nereden geldi? Her step'ten sonra geriye kalan açısından **Kayıt**'tır: geride hangi kanıt kalıyor ve sistem bunun üzerinden hareket edebiliyor mu? Run state'i, bu ikisinin bulunduğu yerdir.

Sorun ve neden zor olduđu

Run, tek bir çağrının kılığına girmiş uzun ömürlü bir şeydir. Saatlerce bir insanı bekleyebilir, onu başlatan process'ten uzun yaşayabilir, başka bir worker tarafından resume edilebilir ve başladığını hiç görmemiş biri tarafından iptal edilebilir. Run'ın ilerleyişini modelin bağlamında ya da yalnızca tek bir worker process'inin içinde tutan bir tasarımın, bunlardan biri olduğunda resume edecek hiçbir şeyi yoktur.

Bundan üç hata sınıfı çıkar. F5 (kontrolden çıkan döngü ya da bayat bağlam), resume edilen bir run bekleyişten önce okuduğu olgulara dayanarak hareket ettiğinde ortaya çıkar: 2. step'te okunup 9. step'te değişen bir adres ya da başkası geri almadan önce okunmuş bir deployment sürümü. F6 (sessiz kısmi hata), etkisi zaten olmuş bir step tekrarlandığında ya da bir run, hiç sonuç almamış bir intent ile tamamlandı diye işaretlendiğinde ortaya çıkar. F8 (gözlenmeyen davranış), bir run öldüğünde ve kimse nereye kadar geldiğini söyleyemediğinde ortaya çıkar.

Bariz yaklaşım, konuşmayı state saymaktır. Transcript zaten orada, sıralı ve model onu okuyabilir. Bu işe yaramaz ve nedenleri kalite değil, yapıyla ilgilidir. Transcript, model için yazılmış bir anlatıdır ve bağlam derleme (Bölüm 9) onu kırpar, özetler ve yeniden sıralar. Modelin kendi iddialarını olguların yanında taşır, dolayısıyla hangisinin hangisi olduğunu ayırt edemez. Orchestrator'ın en çok ihtiyaç duyduğu şeyleri içermez: bir çağrının idempotency key'ini, bir onayın durumunu, run üzerindeki lease'i. Üstelik onu yeniden oynatmak bir dünyayı geri getirmez; modelden yeniden öneri yapmasını ister ve ikinci okumada yapılan öneri yeni bir öneridir, ilkinden farklı olmakta serbesttir.

Modelin hatırlaması da daha iyi durumda değildir. Rollback'in daha önce başlatılıp başlatılmadığı sorulduğunda bir cümle üretir, cümle bir iddiadır ve yanlış olanı, run'ın kendi geçmişi hakkında bir F3'tür (dayanaksız iddia).

Bu bir mühendislik sorusudur, prompt sorusu değil. Prompt'taki "daha önce yaptığın eylemleri tekrarlama" satırı, restart'tan sonra geçmişi önünde olmayabilecek bir bileşene yapılan bir istektir. Kontrol,

orchestrator'ın okuduğu kalıcı bir kayıt, yalnızca kodun hareket ettirebildiği bir state machine ve her etkiden önce çalışan kontrollerdir. Modele bu state'in bir görünümü gösterilir; model ona asla sahip olmaz.

State, bağlam ve bellek, ayrı tutulmuş

Bölüm 1, **state**'i orchestrator'ın run store'da tuttuğu, tek bir run hakkındaki olgular olarak tanımladı. Çizgileri şimdi çekmekte fayda var, çünkü tablodaki dört şeyin birbirine karıştırılması, resume edemeyen tasarımların çoğunun kökündedir.

Şey	Nedir	Kim yazar	Ömrü	Otorite
State	Bu run hakkındaki olgular: step'ler, karar, intent'ler, etkiler, onaylar, status	Orchestrator	Run, artı bir saklama süresi	Run'ın kendi geçmişi için doğruluk kaynağı
Bağlam	Modelin tek bir çağrı için gördüğü, o çağrı için derlenmiş şey	Orchestrator, state'ten ve diğer kaynaklardan	Bir step	Yok; bir görünumdür
Transcript	Alışverişin okunabilir bir dökümü	Bir yan ürün	Çoğunlukla state ile aynı	Yok; kayıplıdır
Bellek	Run'lar arasında saklanan ve sonraki bağlamı şekillendirebilen bilgi (Bölüm 11)	Bir yazma politikası, run değil	Run'ın ötesinde	Tavsiye niteliğinde, bu run hakkındaki gerçek asla değil

İki kural çıkar. Bağlam her step'te state'ten türetilir; state'in yaşadığı yer asla değildir. Ve state, belleğin yaşadığı yer asla değildir: run'ın ömrünü aşması gereken, dünya hakkındaki bir olgu kendi politikası olan bir bellek yazımıdır, sonraki hiçbir run'ın ihtiyaç duymadığı, run hakkındaki bir olgu ise run'la birlikte sona eren state'tir.

Bu aynı zamanda nasıl resume edileceğini de söyler. Resume edilen bir run transcript'i modele yeniden oynatmaz. State'i yükler, değişmiş olabilecek şeyleri yeniden okur ve bunlardan taze bir bağlam derler. Modelin gördüğü geçmiş, run store'un bir dökümüdür ve transcript'in asla söyleyemeyeceği şeyleri söyleyebilir: "15. step `request_rollback` önerdi; karar needs approval idi; onay 09:14'ten beri bekliyor."

Run store: bir run'ın geride bıraktığı

Run store, orchestrator'a ait kalıcı bir depodur. Agent'ların üzerinde hareket ettiği servislerden, onay servisinden ve trace pipeline'ından ayrı bir sistemdir ve bölümün geri kalanı, hiçbir transaction'ın bunları kapsamadığını hatırlamaya bağlıdır. Aşağıdaki gösterim örnekleme amaçlıdır. Tek bir run kaydının neyi tuttuğunu ve daha da önemlisi her alanı kimin yazdığını sıralar.

```
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
```

Birkaç seçimi belirtmeye değer. Step'ler eklenir, düzenlenmez; böylece run store bir log gibi işler ve bir reviewer olayların sırasını okuyabilir. `facts` listesi, her dünya olgusunu okunduğu zamanla ve geldiği yerle damgalar; resume edilen bir run'ın varsaymak yerine "bu ne kadar eski?" diye sorabilmesini sağlayan da budur. Bir onaydaki `call_hash`, onu tam olarak tek bir çağrıya bağlar ve bu bağın nasıl kurulduğu Bölüm 15'in konusudur. Kayıta secret ve credential yoktur ve tool'ların izin verdiği kadar az kişisel olarak tanımlanabilir bilgi (PII) tutar; PII taşıyan tool sonuçları Bölüm 17'nin redaction kuralları altında saklanır.


```

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

```

Burada üç özellik önemlidir. Model bir geçiş öneremez: final answer bir öneridir ve orchestrator onu yalnızca invariant sağlanıyorsa `done`'a çevirir. Bölüm 1'in döngüsündeki `run.status = "done"` satırı burada `transition(run, "done", "final answer")` olur; açık bir intent yüzünden `InvalidTransition` fırlattığında run ya intent'i çözer ya da hand-off'a geçer ve müşteri ya da on-call mühendisi, bitmemiş olduğu hâlde bitmiş görünen bir run görmez. `version` üzerindeki koşullu yazma, iki yazarın aynı run'ı birlikte hareket ettirememesi ve kaybedenin bunu öğrenmesi demektir. Açık intent'ler üzerindeki invariant ise F6'ya karşı korumayı bir gelenekten, kodun ihlal etmeyi reddettiği bir şeye dönüştürür. Yalnızca `done` reddedilir: bir intent çözülemediği için fail eden ya da hand-off'a geçen bir run meşru bir yoldur, bu yüzden bu geçişlerin açık bir intent ile kapanmasına izin verilir ve event onu adıyla anar. Açık intent böylece run'la birlikte kaybolmaz, aşağıdaki sweep için görünür kalır. Yazma, tek sistemde tek bir yazmadır; dolayısıyla status, event ve version birlikte değişir. Run store'un sunduğu tek atomiklik türü budur ve tasarım başka birini istemez.

Terminal state'ler terminaldir. Hand-off'a geçmiş bir soruşturmayı sürdürmek isteyen kişi, aynı subject üzerinde eskisine bir referans taşıyan yeni bir run başlatır. Bu bilinçli bir bedeldir: her run'ın geçmişini kapalı ve okunabilir tutar, karşılığında bir devam için yeni bir run gerekir.

Checkpoint ve resume

Checkpoint, bir run'ın kendisinden resume edebildiği kayıtlı bir noktadır. Bu tasarımda checkpoint, modelin içindeki herhangi bir şeyin snapshot'ı değildir ve transcript'in bir kopyası da değildir. Run store'daki son commit edilmiş step sınırındır: şimdiye kadar eklenen step'ler, status, açık çağrılar ve damgalanmış olgular. Orchestrator intent'i etkiden önce, sonucu da etkiden sonra yazdığı için her step sınırı bir checkpoint'tir ve ayrı bir kaydetmeye gerek kalmaz.

Resume'u düşünmenin yararlı yolu, process'in nerede durmuş olabileceğini sormaktır. Tablo, etkisi olan bir çağrı için durma noktalarını ve run store'un her birinde neye benzediğini sıralar.

Process durdu	Run store'da olan	Dünyada olan	Resume ne yapar
Öneri kaydedilmeden önce	Bu step için hiçbir şey	Hiçbir şey	Bağlamı derler ve yeniden önerir; hiçbir şey tekrarlanmaz
Karardan sonra, intent'ten önce	Öneri, <code>pending_proposal</code> olarak	Hiçbir şey	Öneriyi yeniden gate'ten geçirir; gate izin verirse intent'i kaydeder ve çağrıyı uygular
Intent'ten sonra, etkiden önce	Sonucu olmayan bir intent	Belki hiçbir şey, belki etki	Hedefi key ile sorgular; hedef etki olmadığını bildirirse "uygulanmadı" kaydeder ve öneriyi yeniden gate'ten geçirir; cevap veremezse hand-off'a geçer
Etkiden sonra, sonuçtan önce	Sonucu olmayan bir intent	Etki	Hedefi key ile sorgular ve bildirdiği sonucu kaydeder; cevap veremezse hand-off'a geçer
Sonuçtan sonra	Intent ve sonuç	Etki	Sonraki step ile devam eder
Onay bekleniyor, sonra bir karar	<code>pending_proposal</code> ve bir onay	Hiçbir şey	Öneriyi saklanan onayla yeniden gate'ten geçirir, ikinci satırdaki gibi

İkinci satır var, çünkü step onu yazar: bir `allow` kararından sonra orchestrator çağrısı `pending_proposal` olarak saklar ve ardından gelen intent yazımı onu temizler; dolayısıyla alan yalnızca ikisi arasındaki boşlukta doludur. Process bu yazımdan önce ölürse run, ilk satırdaki gibi davranır ve model yeniden önerir; bu güvenlidir.

Ortadaki iki satır tehlikeli olanlardır ve run store'dan bakıldığında aynı görünürler: sonucu olmayan bir intent. Kurtarma adımının tahmin yürütmemesinin nedeni budur. Hedef sisteme, idempotency key'i kullanarak ne olduğunu sorar ve "bilinmiyor"u yeniden denemek için bir izin olarak değil, bir insana devredilecek bir state olarak ele alır. Key bir yedek önlemdir, plan değil: runtime onu kendi atadığı tanımlayıcılardan, yani trigger'dan gelen alert'ten ve orchestrator'dan gelen intent'ten türettiği için (Bölüm 6), yeni bir step farklı bir `deployment_id` önermiş olsa bile tekrarlanan bir çağrı iki kez hareket etmek yerine ilk sonucu döndürür. Bayat bir `deployment_id`, aktif deployment üzerindeki ön koşul tarafından reddedilir; o arada aktif olmuş bir tanesi key'e takılır.

```
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
```

Bloğun neyi yapmadığını okumak gerekir. Run'ın bırakıldığı yerde olduğuna güvenmez: olgular yeniden okunur ve bekleyiş sırasında değişen bir sözleşme alınır (gate'in neden her zaman güncel sözleşmeyi kullandığını Bölüm 6 açıklar). Transcript'i yeniden oynatmaz. Model herhangi bir şey önermeden önce açık intent'leri çözer, çünkü çözülmemiş bir etkinin üstüne öneri yapan bir model, bir rollback'in iki kez istenmesinin yoludur. Ve saklanmış bir kararı uygulamaz: karar, verildiği andaki olgulara dair bir ifadedir.

Aynı prosedür açılıştaki üç olayı da kapsar. Bir crash, yukarıdaki satırlardan birinde duran bir process'tir. Uzun bir onay, hiç worker tutmayan, `awaiting_approval` içindeki bir run'dır; karar geldiğinde onaya bağlı öneri `pending_proposal` olarak saklanır, run `running`'e döner ve sıradaki worker `resumeRun`'ı çağırır. Açılıştaki soruyu cevaplayan da budur: Robin'in onayı kaybolmaz ve modelden çağrıyı yeniden tahmin etmesi istenmez, çünkü tam çağrı, key'ile birlikte, gate kabul edince gate'ten geçirilerek uygulanır. Orchestrator'ın bir deploy'u, uçustaki her run için aynı anda bir crash'tir; resume'un nadir bir onarım olarak değil, rutin bir yol olarak çalışması gerekmesinin nedeni de budur.

09:14'te doğru olan bir onay, 11:20'de artık çalışan sürüm olmayan bir sürümün rollback'ini tarif ediyor olabilir. Bu durumda gate reddeder, ret modele bir gözlem olarak döner ve Robin'in kararı olduğu şey olarak kayıtlı kalır: artık o çağrı olmayan bir çağrı hakkında verilmiş bir karar.

Uzun run'lar, deadline'lar ve iptal

Her bekleyişin bir deadline'ı olmalı ve her deadline'ın bir varış noktası. Bir run'ın genel bir deadline'ı vardır, bir onayın süre sonu vardır (bir onayın ne anlama geldiği Bölüm 15'in konusudur; burada yalnızca saattir) ve bir worker'ın lease'inin bir sonu vardır. Bir saat dolduğunda cevap bir geçiştir: süresi dolmuş bir onay, run'ı bekleyen öneri eklenmiş olarak `handed_off`'a taşır; böylece bir kişi neyin istendiğini ve nedenini görür. Onu `failed`'a taşımazdım, çünkü hiçbir şey başarısız olmadı, ve beklemede de bırakmazdım, çünkü sınırsız bir bekleyiş, subject üzerinde sınırsız bir kilittir (bkz. sonraki başlık).

Sayılar her sistemin kendisinin belirleyeceği sayılardır ve belirli bir sistem için onları bilmiyorum. En yavaş meşru soruşturmanın ne kadar sürdüğüne, bir insan onayının gerçekçi olarak ne kadar çabuk cevaplandığına ve beklemenin neye mal olduğuna bağlıdır. Diyelim ki, sekiz saatlik bir run deadline'ı ve üç saatlik bir onay süre sonu. Önemli olan, iki sayının var olması ve Bölüm 6'daki idempotency key saklama süresinin yanına yazılmasıdır: saklama tabanı, run deadline'ı artı en uzun onay bekleyişi artı aşağıda anlatılan sweep'in aralığıdır. En uzun run bitmeden süresi dolan bir key, yanlış bir güven verir.

İptal'in iki parçası vardır ve bunları karıştırmak yaygın bir tuzaktır. İptal istemek, run'a yapılan bir yazımdır: `cancel_requested`'ı bir kişi, bir sistem ya da bir sınır ayarlar. Buna uymak ise bir sonraki step sınırında olur; orchestrator, model yeniden çağrılmadan önce bayrağı kontrol eder.

```
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)
```

Onay için askıya alınmış bir run döngünün içinde değildir; bu yüzden `requestCancel` onu doğrudan taşıır ve bekleyen onayı geçersiz kılar; aksi hâlde iptalden sonra gelen bir karar yine de run'ı resume edip çağrıyı uygulayabilirdi.

İptal etmek hiçbir şeyi geri almaz. Zaten gerçekleşmiş bir etki kalır ve açık bir intent'i olan iptal edilmiş bir run, kapanmadan önce yine de reconcile edilir. Bir şeyin geri alınması gerekiyorsa bu, bir telafi eylemidir; yani herhangi biri gibi gate'ten geçen yeni bir öneridir ve politika gerektiriyorsa kendi onayıyla. Sessizce "her şey geri alındı" vaat eden bir iptal düğmesi, sistemin tutamayacağı bir iddia olurdu; bu yüzden status doğru olanı gösterir: iptal edildi, ve zaten gerçekleşmiş etkilerin listesiyle.

Eşzamanlılık: lease'ler ve kilitler

Pratikte iki tür eşzamanlılık görülür ve farklı kontroller gerektirirler. Birincisi, iki worker'ın aynı run'a dokunmasıdır: bir restart'tan sonra yavaş bir worker ile yeni bir worker, run'ın kendilerinin olduğuna birlikte inanabilir. İkincisi, iki run'ın aynı subject'e dokunmasıdır: aynı servis için iki alert ya da aynı müşteriden aynı sipariş hakkında iki ticket.

Birincisi için **lease**, hangi worker'ın bir run üzerinde sınırlı bir süre hareket edebileceğini söyler. Worker onu koşullu bir yazımla talep eder, çalışırken yeniler ve yenilemeyi bıraktığında kaybeder. Her talep bir sayacı, yani fence'i artırır ve worker etkileriyle birlikte fence'i gönderir; böylece onu kontrol eden bir hedef eski sahibi reddedebilir. Uzun bir garbage-collection duraklaması ya da bir ağ bölünmesi yüzünden takılmış bir worker uyanır, hâlâ lease'in kendisinde olduğuna inanır ve run store'a yazmaları version kontrolünde başarısız olur. Worker'ın bir servise giden etkileri ise yalnızca servis fence'e ya da idempotency key'e saygı gösteriyorsa korunur ve lease'in tek başına pencereyi daralttığını, kapatmadığını açıkça söyledim.

```
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 }
```


İkincisi için kural, subject başına bir aktif run'dır; bunu, iki worker'ın aynı anda geçebileceği bir uygulama kodu kontrolü değil, run store'daki bir uniqueness constraint uygular. Aynı subject için gelen ikinci istek ilk run'a eklenir, ya da onun arkasına queue'ya alınır, ya da subject'i tutan run'ın id'si verilerek reddedilir. Bunlardan hangisinin doğru olduğu göreve bağlıdır: aynı ticket üzerindeki ikinci bir müşteri mesajı muhtemelen süren soruşturmaya eklenmelidir, aynı servis için ikinci bir alert ise muhtemelen ona bağlanmalıdır. Subject key'i trigger'dan (ticket, alert) gelir, asla modelden gelmez; idempotency key'lerin gelmemesiyle aynı nedenle: modelin değiştirebileceği bir key bir kilit değildir.

Seviye	Neyi önler	Nerede uygulanır	Neyi kapsamaz
Run üzerindeki lease	Bir run üzerinde hareket eden iki worker	Run store'da koşullu yazma	Fence'i yok sayan bir servise giden, uçuştaki bir etki
Subject üzerindeki kilit	Bir ticket ya da alert üzerinde iki run	Run store'da uniqueness	Aynı servise dokunan iki farklı subject
Gate'teki ön koşul	Bir servis için iki rollback isteği	Gate, servisin kendi state'ini okuyarak	Servisin açığa çıkarmadığı her şey
Idempotency key	Aynı intent'in iki kez uygulanması	Tool ya da servis	Aynı etki için farklı bir intent

Üçüncü satır, subject kilidinin kapsayamadığı bir durumu kapsar: aynı servis için iki alert iki run içinde gelir ve ikisi de bir rollback önerir. Hiçbir subject key'i onları birbirine bağlamaz. Gate, ön koşulları deployment'lar hakkındaki gerçek olan `deploy-service` üzerinde kontrol eder: deployment hâlâ kendi servisi için aktif olandır ve onun için zaten devam eden bir rollback yoktur. Run store, orchestrator'ın ne yaptığını kaydeder; `deploy-service`'in ne yaptığı konusunda bir otorite değildir. Bölüm 6'daki sözleşme, bu çizgilerin nerede durduğunu gösterir (alıntı, sayılar örnekleme amaçlı).

```

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

```

Uyarı: Run id'sinden kurulmuş bir idempotency key, aynı hedef için her ikinci run'da farklı bir key'dir ve step id'sinden kurulmuş olanı, yeniden kurulan bir döngü step'leri farklı numaralandırdığında değişir. Tekrar o zaman iki kez hareket eder. Kurulum Bölüm 6'nın konusudur: key'ler runtime'ın hedefe ve intent'e atadığı tanımlayıcılardan gelir; böylece bir resume ve bir retry aynı key'e eşlenir.

Bir run bir insanı beklerken tutulan bir kilidin bir maliyeti vardır ve gözden kaçırması kolaydır. `awaiting_approval` içindeki bir run hiçbir worker tutmaz, ama subject'ini hâlâ tutar; bu yüzden aynı servis için ikinci bir alert, süre sonu olan üç saate kadar sürebilecek bir onayın arkasında bloke olur. Kilide onayla aynı süre sonunu verir ve bir insanın kilidi queue'dan kırmasına izin verirdim. Alternatif, run beklerken subject'i serbest bırakmaktır; bu, arada ikinci bir run'ın aynı rollback'i önermesine izin verir ve o zaman tek koruma gate ile key olur. Geri alınamaz yazmalar için kilidi tutardım; yalnızca okuma yapan bir soruşturma için serbest bırakırdım.

Dünyayı yeniden okumak ve reconciliation sweep'i

Orchestrator iki tür olgu tutar ve bunların otoritesi farklıdır. Run'ın kendi geçmişine dair olgular (ne önerildi, ne uygulandı, ne onaylandı) run store'da otoritedir, çünkü orchestrator onları sırayla yazmıştır. Dünyaya dair olgular (deployment sürümü, sipariş durumu, gönderideki adres) onlara sahip olan sistemde otoritedir ve run store yalnızca damgalanmış bir kopya tutar: bir değer, bir zaman ve bir kaynak.

Bundan çıkan kural, hareket etmeden önce okumaktır. Bir dünya olgusuna bağlı bir etkiden önce gate, yukarıdaki sözleşmenin gösterdiği gibi olguyu yeniden okur ve önerinin varsaydığıyla karşılaştırır. Resume sırasında orchestrator, modelin önüne koyacağı her şeyi yeniden okur ve tazeleyemediği her şeyi yaşıyla birlikte bağlamda bayat olarak işaretler (etiketin nasıl görüldüğünü Bölüm 9 anlatır). Bu, F5'i bir sürprizden bir reddedilmeye çevirir: sonradan değişmiş bir sürüme dayanan bir rollback gate'te `precondition_failed` ile başarısız olur ve model nedenini görür.

Modelin olguları hatırlamasının hiçbir otoritesi yoktur. Bir run'ın özeti "flag zaten kapalı" diyorsa orchestrator özete göre hareket etmez. Flag'i okur.

Bu başlığın ikinci yarısı, önceki bölümlerde üç kez verilmiş bir sözü cevaplar. Sonucu olmayan intent'ler, cevabı olmayan sonuçlar, açık intent'lerle tamamlandı diye işaretlenmiş run'lar: Bölüm 3, 5 ve 6'nın her biri, run'ın kendisinin yakalamadığını bir reconciliation job'ının yakaladığını söyledi. Bu o job'dır ve run store'u run'ın dışından izleyen tek bileşendir.

```

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

```

Her bulgu ya bir status sorgusu ve kaydedilmiş bir sonuçla çözülür ya da kayıtlı intent eklenmiş olarak bir insan için bir queue'ya konur. Sweep yalnızca tek yöne bakar: run store'dan dünyaya. Karşı yön, hiçbir run'daki hiçbir intent'in açıklamadığı, downstream bir servisteki bir etki, servisin son değişikliklerini key ile açığa çıkarmasını gerektirir ve çıkardığı yerde onu eklerdim, çünkü orchestrator'ı atlayan bir yolla uygulanmış bir etkiyi yakalayan kontrol odur. Servis bunu açığa çıkarmıyorsa, kontrol varmış gibi davranmak yerine bunu runbook'ta söylemek gerekir. Parcelport'ta bu en çok `issue_refund` için önemlidir: `payments-service`'e yapılan çağrı timeout olduğunda `outcome_unknown` olarak biter ve sweep onu `payments-service`'ten iadeyi key'yle sorarak çözer ya da intent eklenmiş olarak bir insana gönderir.

Sweep, sahibi olan küçük bir sistemdir. Birkaç servise okuma erişimine, birinin ayarladığı bir eşığe ve bir şey bulduğunda ya da çalışmayı bıraktığında alarm gönderilen birine ihtiyaç duyar. Kimsenin izlemediği

bir sweep tiyatrodur: bir tabloda duran bulgular üretir. Bu bulgular üzerine kurulan metric'leri ve alert'leri Bölüm 20, bir olay çıkan bir bulguyla bir insanın ne yaptığını ise Bölüm 23 ele alır.

Trade-off'lar ve maliyetler

Kalıcı state, her step'te bir yazıma ve her etkinin etrafında iki yazıma mal olur. Bir okuma için intent yazımı ek yüküdür ve onu atlayıp sonucu tutardım. Yazmalar ve dış yan etkiler için maliyetin buna değiştiğini düşünüyorum, çünkü bu, ne olduğunu bilmenin maliyetidir.

Run store, bütün filonun paylaştığı bir bağımlılık olur. Erişilemez olursa etkiler için hata durumunda reddederdim: bir intent'i kaydedemeyen bir run etkiyi uygulamaz, çünkü intent'i olmayan bir etki F8 durumudur. Okumalar bir süre devam edebilir. Bu yüzden run store'un erişilebilirliği, yazan her şeyin erişilebilirliğine bir tavan koyar ve platform ekibi onu, gerçekte olduğu gibi, bir production veritabanı olarak ele almalıdır.

State machine bilerek katıdır ve katılığın bir bedeli var. Bir state eklemek bir migration'dır: eski tanım altında uçustaki run'lar yine de çözülebilmelidir. Her run üzerindeki bir schema version ve bir policy version bunu yönetilebilir kılar, ama biri, schema'sı koddan eski olan resume edilmiş bir run'ın ne yapacağına karar vermek zorundadır. En ucuz cevap, schema version'ını mevcut kodun okuyamadığı her run'ı hand-off'a geçirmektir ve aynı zamanda en güvenlisidir; deploy günü bir insan review'una mal olur.

Lease'ler ve kilitler operasyonel yüzey ekler. Çok kısa lease süreleri sağlıklı worker'ların run kaybetmesine yol açar; çok uzun süreler ölü bir worker'ın run'ını takılı bırakır. Subject kilidi insanları bekletir ve bir onay boyunca tutulan kilit, onu kırabilecek bir sahip gerektirir. Doğru sayıları bilmiyorum; lease için en uzun meşru step'ten, kilit için gerçekçi onay cevap süresinden başlamak, takılı kalan run'ları ölçmek ve ayarlamak gerekir.

Saklama iki yüzlü bir maliyettir. Idempotency key'lerini ve olay review'larını kapsayacak kadar yaşayan state, PII içerebilecek tool sonuçlarını da tutar; dolayısıyla run store hassas veri deposudur ve Bölüm 17'nin minimizasyon kurallarına uymalıdır.

Bütün bunların ne zaman kullanılmayacağı: docs'tan bir soruyu cevaplamak gibi tek atımlık, yalnızca okuma yapan bir görevin korunacak bir etkisi yoktur ve yeniden başlatması ucuz bir run yeniden başlayabilir. Olanların bir log'u yeterlidir ve lease ile kilit, önleyecek bir hatası olmayan bir makine olurdu. Bu bölümün ağırlığı, agent'ın erişebildiği etki sınıflarını izlemelidir: bunların ne kadarı yazmaysa, run store yerini o kadar hak eder.

Sık yapılan hatalar

- **Transcript'i state saymak ve onu yeniden oynatarak resume etmek.** Cazip, çünkü zaten sıralı ve model onu okuyabilir. Kayıplıdır, kırılmıştır ve modelin kendi iddialarıyla doludur; onu yeniden oynatmak, çözülmemiş bir etkinin üstüne yeni bir öneri ister. State'i run store'da saklamak, açık intent'leri çözmek, sonra taze bir bağlam üretmek gerekir.
- **Her kod yolunun yazdığı serbest biçimli bir status alanı.** Hızlıdır ve kimsenin tanımlamadığı state'lerdeki run'larla biter; sonucu olmayan bir intent ile `done` da buna dahildir. Her değişikliği version kontrolü olan tek bir transition fonksiyonundan geçirmek ve o durumu reddetmesine izin vermek gerekir.
- **Idempotency key'lerini run ya da step tanımlayıcılarından kurmak.** Elin altındadırlar ve benzersizdirler. İkinci bir run'da ve yeniden kurulan bir döngüde değişirler; key'e tam da o zaman ihtiyaç vardır. Key'leri runtime'ın hedefe ve intent'e atadığı tanımlayıcılardan türetmek gerekir.
- **Fence'i ve version kontrolü olmayan bir lease.** Heartbeat'ler yeterli görünür. Duraklatılmış bir worker uyanır ve yazar. Run store'daki koşullu yazmalar ve servislere doğru fence'ler pencereyi daraltır.
- **İptali process'i öldürmek olarak yapmak.** Kurması kolaydır. Sonucu olmayan intent'ler ve hiçbir şey söylemeyen bir status bırakır. İptal, step sınırında uyulan bir bayraktır ve ardından reconciliation gelir.
- **Sweep'i kurup sahiplenmemek.** Job var, yani kutu işaretlendi. Bir eşik, bir heartbeat ve bir on-call sahibi olmadan bulguları kimsenin okumadığı bir tablodur.

Temel çıkarımlar

- Run state'i, orchestrator'a ait kalıcı bir run store'a aittir ve modelin bağlamı her step'te ondan üretilen bir görünümdür; state'in yaşadığı yer asla değildir.
- Run, geçerli geçişleri kodda yazılmış, version kontrolü olan tek bir fonksiyonla uygulanan ve modelin erişemediği bir state machine'dir; final answer, orchestrator'ın yalnızca hiçbir intent açık değilken done'a eşlediği bir öneridir.
- Resume, transcript'i yeniden oynatmak yerine bağlamı state'ten yeniden kurar: lease'i alır, açık intent'leri hedef sisteme key ile sorarak çözer, olguları ve sözleşmeleri yeniden okur ve ancak ondan sonra modelin önermesine izin verir.
- Her bekleyişin bir deadline'ı, her deadline'ın bir varış noktası vardır; bu yüzden süresi dolmuş bir onay run'ı bekleyen öneri eklenmiş bir hand-off'a taşır ve iptal, step sınırında uyulan bir bayraktır, asla bir geri alma değil.
- Eşzamanlılık birkaç seviyede kontrol gerektirir: run için bir lease ve bir version kontrolü, subject için bir uniqueness constraint, servis için bir gate ön koşulu ve yedek önlem olarak bir idempotency key.
- Modelin ne olduğunu hatırlamasının hiçbir otoritesi yoktur; geçmiş run store'dan, dünya olguları ise onlara sahip olan sistemlerden, onlara bağlı her etkiden önce okunur.
- Sahibi ve heartbeat'i olan bir reconciliation sweep, ayrı sistemler arasındaki boşlukların görünür olma yoludur; çünkü hiçbir transaction run store'u, servisleri ve onay servisini kapsamaz.

State, bir run'ı kendi geçmişi konusunda dürüst tutar, ama tasarım gereği unuttur: run bittiğinde öğrendikleri de biter. Bölüm 11, tersi soruya döner: sonraki bir run'ın neyi miras almasına izin verilebilir ve bunu yazıya dökmek neden çok daha riskli bir iştir.

Bölüm 11 — Bellek

Parcelport'ta bir ekibin ikinci ayında bir özellik eklediğini düşünelim: destek agent'ı müşterileri "tanımalı". Her ticket'tan sonra model kısa bir not yazıyor, orchestrator onu saklıyor ve aynı müşteriden gelen sonraki ticket, notlar bağlamda olacak şekilde başlıyor. Müşteriler bunu seviyor. Cevaplar aynı ayrıntıları iki kez sormayı bırakıyor.

Şimdi bu depodaki tek bir notu gözümüzün önüne getirelim. `cus-0042` adlı bir müşteri, bir kuryeden gelen e-posta zincirini ticket'a iletmış. Zincirin bir yerinde, bu hesabın nasıl ele alınacağına dair bir talimat gibi okunan bir satır var ve modelin not yazma adımı zinciri, o satır dahil, müşteri hakkında bir olgu olarak özetlemiş: "öncelikli ele alınır, iadeler önceden onaylı". Notu kimse gözden geçirmemiş. Müşterinin kendi kapsamındaydı, süre sonu yoktu ve diğer her nota benziyordu. Üç hafta sonra `cus-0042` için başka bir run onu okuyor, model politikanın dikkatli bir okumasının desteklemeyeceği bir iade öneriyor ve not, gate'e giden önerinin bağlamında duruyor. Gate dayanıyor, çünkü gate notları okumaz. Ama bir reviewer, tek bir iletilmiş e-postadan bir cümlemin bu müşterinin bütün gelecek run'larına nasıl girdiğini soruyor ve kimse onu kimin, neyden yazdığını ya da ne zaman ortadan kalkacağını söyleyemiyor.

Bu bölüm kontrol zarfının **Bağlam** parçasına aittir. Sorusu, Bağlam'ın her zaman sorduğu sorudur: model ne görüyor, her parça nereden geldi ve ona ne kadar güvenilebilir? Bellek, cevapları en zorlaştıran kaynaktır, çünkü onu üreten koşullar değiştikten çok sonra bile malzemeyi bir run'dan ötekine taşır. Bölüm, önce belleğe hiç ihtiyaç olup olmadığını, sonra ona nasıl yazılacağını, ondan nasıl okunacağını ve ondan nasıl unutulacağını, bir kolaylık olarak değil, kontrollü bir sistem olarak soruyor.

Sorun ve neden zor olduđu

Bellek, bu kitabın terimleriyle, run'lar arasında saklanan ve sonraki bağlamı şekillendirebilen bilgidir. State tek bir run ile ilgilidir ve run store'da yaşar (Bölüm 10). Bellek, run'dan sonraki dünyayla ilgilidir ve ayrı bir yaşam döngüsü olan ayrı bir sistemde, memory store'da yaşar. Bu ayrım önemlidir, çünkü ikisi farklı biçimde başarısız olur. Kötü bir state kaydı tek bir run'ı etkiler. Kötü bir bellek kaydı, var olduđu sürece onu okuyan her sonraki run'ı etkiler.

Bu da belleği alışılmadık bir bağlam türü yapar. Bir ticket bir kez okunur. Getirilen bir pasaj, sahipleri ve review'u olan dokümanlardan gelir. Bir bellek kaydı ise sistemin kendisi hakkında, daha önceki bir zamanda, bir modelin önerisine dayanarak yazdığı bir şeydir. Bağlama güvenilir bir iç olgu gibi görünerek gelir, çünkü Parcelport'un kendi deposundan gelmiştir; oysa gerçek kökeni bir müşterinin e-postası, bir tool sonucu ya da bir modelin ikisinin özeti olabilir.

Dört hata sınıfı burada buluşur. F4 (talimat ele geçirme) kalıcı hâle gelir: bir run'a girdiğinde veri olan içerik yazıya geçirilir ve sonraki bir run onu Parcelport'un kendi bilgisiymiş gibi geri okur. Bölüm 16'nın prompt injection altında ele aldığı biçim budur ve bellek, bir run'ın sorununun bütün run'ların sorunu olduđu yerdir. F5 (kontrolden çıkan döngü ya da bayat bağlam) sessiz akrabasıdır: yazıldığında doğru olan bir not, örneğin tercih edilen bir iletişim kanalı ya da bir teslimat kısıtı, dünya ilerledikten sonra okunur. F3 (dayanaksız iddia) ikisinden de çıkar: cevap bir şeyi, bir not destekliyor diye söyler ve mevcut run'daki hiçbir şey desteklemez. Ve F8 (gözlenmeyen davranış), hepsini pahalı yapan şeydir: bir run'ın hangi notları okuduđu söylenemiyorsa, kötü bir notun hangi run'lara dokunduđu da söylenemez.

Bariz yaklaşım, modelin kendi belleğini yönetmesine izin vermektir: ona not kaydetmesi için bir tool, onları aramak için bir tane daha vermek ve prompt'ta yalnızca güvenilir olguları kaydetmesini ve notlarda bulduđu talimatları yok saymasını söylemek gerekir. Prompt yardımcı olur. Kötü not oranını düşürür ve yazmaya değer. Yine de bir ricadır ve ele aldığı hata, yazma adımının içeriden fark edemeyeceği bir hatadır: iletilmiş bir e-postadan üretilmiş bir not, onu yazan bileşene diğer her özet gibi görünür. Yazanın fark etmesine dayanan bir kural kontrol değildir.

Bu, ikinci bir nedenle de mühendislik sorusudur: bellek, yazarları, okuyucuları, saklama süresi, silme ve tenant izolasyonu olan küçük bir production veritabanının özelliklerini taşır ve onun gibi bir schema'yı, bir sahibi ve bir son kullanma tarihi hak eder.

Belleğe hiç ihtiyaç var mı?

Bu soruyla başladım, çünkü en ucuz bellek tasarımı hiç olmayanıdır. Bir memory store'daki her kayıt, yanlış hâle gelebilecek bir iddia, yanıtlanabilecek bir bağlam parçası ve belki de sonradan bulunup silinmesi gereken bir kişisel veri parçasıdır. Yazma yolunu kurmadan önce belleğin hangi işi yaptığını ve bu işi başka bir sistemin zaten yapıp yapmadığını sorun.

Parcelport'un aday belleği üç gruba ayrılır ve dürüst cevap her biri için farklıdır.

Bellek türü	Neyi tutar	Bu işi zaten yapıyor olabilecek sistem	Görüşüm
Müşteri tercihleri	İletişim kanalı, dil, sessiz saatler, müşterinin belirttiği bir teslimat talimatı	customer-service, iletişim tercihlerini profilin alanları olarak tutar	Bunlar profilde, normal bir servis yolundan yazılarak saklanır. Agent onları <code>get_customer_profile</code> ile okur
Çözülmüş vaka özetleri	Daha önceki bir ticket'ta ne olduğu, böylece tekrar eden bir temas soğuk başlamaz	Ticket sistemi tüm geçmişi tutar; <code>orders-service</code> ve <code>payments-service</code> sonuçları tutar	Çoğunlukla gereksiz: son ticket'ların ve sipariş durumunun bir sorgusu, bir özetten daha taze olgular verir. Yalnızca geçmiş uzunsa ve sorgular çok pahalıysa kurmaya değer
Ops runbook notları	"Bu alert geçen sefer tetiklendiğinde worker'ı yeniden başlatmak çözdü"	Docs server'daki, insanların review ettiği runbook'lar	Onları serbest not olarak tutmamak gerekir. Adayları, bir insanın karar verdiği, runbook'a karşı açılan bir pull request'e yönlendirmek gerekir

Zaten bir system of record içinde yeri olan tercihler orada kalmalıdır, çünkü system of record'un bir sahibi, bir düzeltme yolu ve genellikle bir silme yolu vardır. Bir memory store'daki ikinci kopya, yanlış olabilecek

ikinci bir yerdir. Bellek, ancak şunların hepsi geçerliyse yerini hak eder: olgu bir system of record'da değildir, sonraki bir run'da işe yarayacaktır, yanlış bir sürümü eklediği değerden daha ucuza mal olur ve birisi onun ne kadar süre doğru kalacağını söyleyebilir. Dördünden biri tutmadığında alternatifi tercih etmek gerekir. Ops agent'ı için alternatif hemen her zaman runbook'tur ve bellek özelliği, bir insanın merge ettiği `open_pull_request` üzerinden insanlara runbook değişiklikleri önermenin bir yoludur.

Beş koşul daha, bellek olmamasından ya da henüz olmamasından yanadır:

- **Bayat bir not pahalıdır.** Eski bir olguya göre hareket etmenin para hareket ettirdiği ya da bir gönderiye dokunduğu yerde (bir adres, bir iade) not bir tehlikedir. Her seferinde servislerden yeniden üretmek gerekir.
- **Run'lar tekrarlanabilir olmalıdır.** Bir soruşturma ile yeniden çalıştırılması arasında değişen bir memory store, snapshot alınacak bir girdi daha demektir. Eval'ler için bellek dondurulmuş ya da boş olarak çalıştırmak gerekir.
- **Yaşam döngüsünün sahibi yok.** Karantina review'u, düzeltme talepleri ve süre sonu job'ları insanlar ve on-call için iştir ve sahipsiz bir depo, hiç depo olmamasından kötüdür.
- **Nüfus anonim ya da tek seferliktir.** Her yabancıya bir kez cevap veren bir agent'ın hatırlayacak bir şeyi yoktur ve her kayıt yalnızca bir yükür.
- **Her run temiz başlamalıdır.** ops-agent tarafından yapılan bir soruşturmada, daha önceki bir olaydan miras kalan bir hipotez, yanlış nedene çapa atmanın bir yoludur.

Belleksiz bir tasarımın kendi maliyetleri vardır: tekrar eden temalar soğuk başlar ve müşteriler tercihlerini yeniden söyler. Bu maliyetler görünürdür ve sınırlıdır. Bir memory store'un maliyetleri zamana yayılır ve görülmesi zordur; görünür olanları önce ödemeyi tercih etmemin nedeni de budur.

Agent'lar için doğru cevabı, onları çalışırken izlemeden bilmiyorum. Destek agent'ı çoğunlukla ilk temas ticket'larını ele alıyorsa, vaka özeti belleği hiç okunmayabilir. Bunu öğrenmenin ucuz bir yolu, bir bellek

tasarımının bir aylık ticket için ne döndüreceğini bağlama koymadan log'lamak ve herhangi bir cevabın değişip değişmeyeceğine bakmaktır. Bu bir eval sorusudur (Bölüm 21) ve önce depoyu kurmaktan ucuzdur.

Bölümün geri kalanı, bir miktar belleğin saklamaya değer olduğuna karar verildiğini varsayar. Parcelport için bu, `support-agent` için küçük, tipli bir kümedir: profilin henüz tutamadığı iletişim tercihleri ve önceki sonuçlara dair yapılandırılmış notlar.

Bellek öneriyle yazılır

Kitabın ilkesi burada değişmeden geçerlidir: model bir öneri üreticisidir ve döndürdüğü güvenilmez girdidir. Bir bellek yazımı bir etkidir, çünkü sonraki run'ların ne gördüğünü değiştirir. Yani model bir bellek önerir; kod onu doğrular, saklayıp saklamayacağına ve nasıl saklayacağına karar verir.

Korumanın çoğunu iki karar sağlar ve ikisi de biçimle ilgilidir.

Belleği tipte. Bir bellek kaydının kapalı bir kümeden bir `kind`'ı vardır ve her `kind`'ın bir `schema`'sı vardır. Bir iletişim tercihi bir cümle değil, bir `enum` değeridir. Bir vaka notunun sabit alanları vardır. Sebep açıktır: bir `enum`'dan alınan değer talimat taşıyamaz ve bir `validator` onu tamamen kontrol edebilir. Serbest metin her şeyi taşıyabilir ve hiçbir `validator` bir özet, gelecekteki bir okuyucuya hitap eden bir mesajdan ayıramaz.

Olguları modelin düzyazısından değil, kayıttan kurmak gerekir.

Çözülmüş bir vaka için saklamaya değer olgular zaten `run store`'da ve servislerde durur: hangi sipariş, hangi `reason code`, bir iade yapılp yapılmadığı ve hangi tutarda, hangi cevabın gönderildiği. Kod bu notu etkilerin kaydından yazabilir. Modelin katkısı, olsa olsa bir konu etiketi gibi kapalı etiketler arasından bir seçimdir. Not `"iade yapıldı, reason_code damaged, sipariş ord-7f3k2m91"` der; çünkü `payments` etkisi böyle söylüyordur, bir modelin birinin e-postasını içeren bir zinciri özetlemiş olması yüzünden değil.

İşte öneri için örnek bir tool; Bölüm 6'nın sözleşme biçimini izliyor. Tool bu bölüm için yenidir, yalnızca `support-agent`'a aittir ve model yalnızca `input schema`'sındaki alanları sağlar.

```

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]

```

Sözleşmedeki üç şey bilinçlidir. Müşteri asla modelin sağladığı bir alan değildir: her kaydın kapsamı, orchestrator tarafından atanan, run'ın müşterisidir; böylece bir öneri başka bir müşterinin belleğine yazamaz (bunun arkasındaki devri Bölüm 7 açıklar). Değer bir enum'dur; yani bir önerinin söyleyebileceği en güçlü şey, ekibin gözden geçirdiği bir listeden yapılmış bir seçimdir. Ve kanıt, gate'in kayıttaki bir mesaja çözdüğü bir step tanımlayıcısıdır; bu da ön koşulu kodla denetlenebilir kılar: gate o step'i kimin ve hangi kanaldan yazdığına bakar.

Tip kısıtlamasının bir bedeli var. Kapalı bir küme "teslimatı yan kapıya tercih ediyor, köpek uysal" gibi bir şeyi tutamaz ve müşteriler hiçbir enum'a uymayan şeyler söyleyecektir. Bunu kabul ederdim. Daha zengin

notlara ihtiyaç duyan bir ekip, ihtiyaç gösterildiğinde schema'lı bir kind ekleyebilir ve her ekleme, bir prompt'un yan etkisi değil, sahibi olan bir tasarım kararıdır.

Yazma politikası

Bir yazma politikası, her bellek türü için beş soruyu cevaplar: kim yazabilir, ne yazılabilir, hangi köken ile, hangi kapsamda ve ne kadar süreyle. Onu diğer politikalar gibi veri olarak yazmak, onu gözden geçirilebilir kılan şeydir. Aşağıdaki gösterim örnekleme amaçlıdır.

```
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
```

Supersede satırı, bir tercihin değişebilmesini sağlayan şeydir. Mart'ta mesajla, Haziran'da e-postayla iletişim isteyen bir müşteri ikinci bir kayıt üretir; ilki `superseded` olur, okuma yolu onu yok sayar ve geçmiş review için hâlâ oradadır. Sıralama, yazımın çalıştığı zamana göre değil, kaydın dayandığı müşteri mesajının zamanı olan `declared_at`'e göreidir. Bir onayı bekleyen bir run, daha yeni bir run'dan sonra bitebilir; yazma zamanı karar verseydi, Çarşamba'nın yazma aşaması Pazartesi'nin tercihini Salı'nınkinin üstüne geri koyardı. `declared_at`'i canlı kayıttan eski olan bir yazım hemen `superseded` olarak saklanır. Kural, yalnızca tekrarlanan

bir yazımın iki kez uygulanmasını engelleyen idempotency key'inden bilerek ayırır. Vaka notları bunun dışındadır: bir müşteri için yapılanların geçmişi birikir ve ikinci bir not ilkini gizlememelidir.

Bunu açılış senaryosunun cevabı olarak okumak gerekir. İletilmiş bir e-postanın içinde gelen cümle ilk ön koşulda reddedilirdi, çünkü kanıt step'i müşterinin yazdığı bir mesaj değil. Bir modelin bir zincir özeti hiçbir şekilde not olamaz, çünkü hiçbir kind modelin yazdığı metni kabul etmez. Ve "iadeler önceden onaylı" notu var olamaz, çünkü kümedeki hiçbir şey yetkiyi tarif etmez.

Bu son nokta başlı başına bir kuraldır: **bellek asla yetki taşımaz**. Hiçbir kayıt bir izni vermez, genişletmez ya da ortadan kaldırmaz ve gate karar verirken memory store'a başvurmaz. Yetki, run'daki devirden (Bölüm 7) ve politika motorundan gelir. Bellek "bu müşteri tavanı aşabilir" diyebilseydi, zehirlenmiş bir not gate'in etrafından dolaşan bir yol olurdu. Bunu bir invariant sayar ve test ederdim: yalnızca bir bellek notu doğruysa gate'ten geçecek bir öneri reddedilmelidir.

Yazımın nerede olduğu da önemlidir. Bellek yazma aşamasını, bir döngünün ortasında bir tool çağrısı olarak değil, run bittikten sonra orchestrator'da çalıştırdım. O noktada run kaydı tamamdır, orchestrator bağlamda hangi öğelerin olduğunu ve her birinin nereden geldiğini bilir (Bölüm 9'daki origin ve trust etiketleri) ve bir yazım bu bilgiye dayanarak reddedilebilir. Tool döngüde çağrılır, ama yalnızca bir aday saklar; yazımın kendisi run'dan sonra olur. Run ortasındaki bir yazım, run'ın nasıl bittiğini göremezdi. İptal edilen ya da hand-off ile biten bir run geride not bırakmamalıdır, çünkü sonuçlarını kimse kabul etmemiştir.

```

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)

```

İki döngü idempotency'ye bilerek farklı yollardan ulaşır. Bir öneri sözleşmesinden gelen key'i taşır, `hash(customer_id, memory_intent_id)`, böylece tekrarlanan bir yazım aynı kayda iner. Bir vaka notunun sözleşmesi de intent id'si de yoktur, bu yüzden key'i etki kaydından gelir. Kontrol farklıdır, çünkü amaç farklıdır: bir öneri aynı kind'dan önceki bir kaydı supersede edebilir, bir vaka notu ise öncekini asla ezmeme ya da gizlememelidir (yukarıdaki supersede kuralı); bu yüzden döngü yeniden yazmak yerine `memory.exists`'i kontrol eder ve atlar.

Her döngüdeki bellek yazımı ve run kaydı yazımı ayrı sistemlerdir, memory store ve run kaydı, ve onları bir transaction'a sarmadım. Process ikisinin arasında durursa, yazımı run kaydına geçmemiş bir bellek kaydı var olur. Tespit, periyodik bir reconciliation'dır: her bellek kaydı `written_by_run` taşır ve bir job, run'ında `memory_written` event'i olmayan bellek kayıtlarını listeler. Bellek kaydının kendi kökeni onarım

anahtarıdır. Bellek kaydının bu kökeni kendi üzerinde taşıması gerekmesinin nedeni budur; nereden geldiğini söylemeyi trace'e bırakmak yerine.

Kaydın kendisi şu alanlara sahip bir kayıttır. Küçük tutmak gerekir.

```
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
```

Belleği bağlama okumak

Yazmak tasarımın yarısıdır. Okuma yolu, bir bellek kaydının modelle bulunduğu yerdir ve bağlam derlemenin (Bölüm 9) parçasıdır, diğer her kaynakla aynı kurallar altında: ne, hangi sırayla, ne kadar, hangi etiketle.

Belleği benzerliğe göre değil, key'e göre okurdum. Bir müşterinin kayıtları `customer_id` altında kısa bir listedir; bu yüzden orchestrator onları kapsama göre getirir, süresi dolmuş, karantinaya alınmış ya da silinmiş olanları eler ve sayıyı sınırlar. Bir memory store genelinde benzerlik araması, kapsamsız metinden oluşan büyük koleksiyonlar için bir araçtır ve tipli tasarımın kaçındığı şeyi getirir: sorgunun nasıl ifade edildiğine bağlı olan ve filtre yanlışsa kapsam sınırını aşabilen sonuçlar. Arama gerçekten gerekiyorsa, kapsam filtresi deponun sorgu katmanında, orchestrator tarafından uygulanarak durmalıdır, asla modelin sağladığı bir argüman olarak değil.

Okuma fonksiyonu politikayı uygular ve bağlam öğelerini Bölüm 9'un tanımladığı biçimde döndürür; origin olarak kayıt id'si ve trust etiketi olarak `untrusted` ile. Depo Parcelport'un kendisine aittir, ama içerik bir müşteri mesajına ya da model destekli bir run'a kadar izlenir; bu yüzden asla bir talimat etiketi almaz.

```

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

```

Bu fonksiyondaki dört şey, tartışılabilir seçimlerdir.

Etiket, ögenin ne olduğunu söyler. Her bellek ögesi, Parcelport'un kendi sisteminin daha önceki bir run'dan yazdığı bir not olarak, kaynağıyla (bir müşteri mesajı ya da bir etki kaydı), doğrulanmamış ve talimat olmayan biçimde render edilir. Etiket içeriği güvenli kılmaz ve önceki başlıkların amacı da budur: güvenlik, tipli değerlerden ve yazma politikasından gelir; etiket ise pipeline'ın geri kalanının ve bir trace'i okuyan insanların bunun hangi sınıf malzeme olduğunu bilme yoludur. Etiket aynı zamanda modele bir ipucudur ve her prompt'ta olduğu gibi, bir kontrol olmadığı hâlde hata oranını düşürür.


Yaş, `as_of` olarak taşınır; böylece bir cevap "son konuştuğumuzda mesajla iletişim istemiştiniz" dürüstçe diyebilir ve "bayatlık sınırından eski kayıtların onaylanmasını iste" gibi bir kural kodda yaşayabilir.

Çakışma kuralı, system of record'un kazanmasıdır. Bir bellek notu müşterinin bir kanalı tercih ettiğini söylüyorsa ve `get_customer_profile` başkasını döndürüyorsa, profil gerçektir ve yukarıdaki fonksiyon çakışan notu model görmeden önce düşürür. Kontrol, system of record'da karşılığı

olan kind'lar için okuma anında kodda çalışır. Bu, state'i yeniden okumakla (Bölüm 10) aynı ilkedir: bir bellek kaydı bir zamanlar doğru olmuş bir şeyin cache'idir ve cache hiçbir zaman doğruluk kaynağı değildir.

Sürüm kontrolü, okuyucunun yorumlayamadığı kayıtları reddeder. Bellek deploy'lardan uzun yaşar. Eski bir schema altında yazılmış bir not, bir değer anlamını değiştirmiş kod tarafından okunursa, başka bir yoldan F5'tir ve tahmin etmektense atlamak daha iyidir.

Diyagram iki yolu ve her kontrolün nerede durduğunu gösterir. Bir kaydın girişte ve çıkışta nerede durdurulabileceğine bakmak gerekir.



Zehirlenmiş bellek

Bölümü açan senaryo, karşısında tasarım yapılacak olandır. Bir modelin önerisi, olmaması gereken bir şey içeriyor, çünkü okuduğu içerik talimat gibi davranan veriydi ve memory store tek run'lık bir sorunu kalıcı bir soruna çeviriyor. Savunmacının tarafında kalacağım: tasarımın ne yaptığı, birinin nasıl deneyebileceğinden daha önemlidir.

Savunmalar katmanlıdır ve her biri deterministiktir.

1. **Yazma anında köken kapısı.** Bir kayıt yalnızca politikanın o kind için güvendiği kaynaklardan yazılır: bir tercih için kimliği doğrulanmış bir müşteri mesajı, bir vaka notu için etki kaydı. Bir tool sonucu, iletilmiş bir zincir ya da getirilmiş bir doküman aracılığıyla gelen hiçbir şey kaynak değildir.
2. **Kapalı değer kümeleri.** Kayıt serbest metin taşıyamaz, dolayısıyla bir talimatın saklanabileceği bir alan yoktur.
3. **Bellekte yetki yok.** Bir not yanlış ya da yerleştirilmiş olsa bile, gate'in karar verdiği hiçbir şey ona bağlı değildir.

4. **Şüphede karantina.** Kanıt step'i geçerli olan ama değeri o step'te görünmeyen, buna karşılık run'ın güvenilir bir ögesinde (örneğin bir tool sonucunda ya da iletilmiş bir parçada) görünen bir aday, okuma yolunun atladığı quarantined status'ü ile yazılabilir ve bir review listesine konabilir. Bu, yanlış bir notun bir insan gerektirecek kadar pahalı olduğuna karar verilen kind'lar içindir. Birinin gününe iş ekler, bu yüzden onu kısa bir kind listesiyle sınırlardım.
5. **Kapsam izolasyonu.** Bir kayıt yalnızca tarif ettiği müşterinin run'ları tarafından okunabilir; böylece zehirlenmiş bir not bir müşterinin gelecek run'larına zarar verir, hepsine değil.

Bölüm 16 injection tarafını geliştirir. Bellek için nokta daha dardır: yazma yolu, geçici bir sorunun kalıcı hâle getirilebildiği ve bir kontrolün en ucuz olduğu yerdir.

Uyarı: Serbest metinden yazılabilen ve etiketsiz biçimde bağlama okunabilen bir bellek, modelin en son okuduğu her şey için bir kalıcılık mekanizmasıdır. Tasarımda serbest metinli bir bellek tool'u var ve yazma politikası yoksa, depoyu güvenilir veri olarak ele almak ve politika oluşana kadar para hareket ettirebilen ya da müşteri verisine dokunabilen her run'ın dışında tutmak gerekir.

Saklama, düzeltme ve silme

Her kaydın bir ömrü vardır ve politika onu adlandırır. Nedeni düzen değildir. Bir olgunun yarı ömrü vardır, bayat bir olguya göre hareket etmenin maliyeti yaşıyla büyür ve süre sonu olmayan bir kayıt, bir veri parçasını süresiz olarak saklama, koruma ve arama sözüdür. Yazma politikasındaki time-to-live (TTL) varsayılan cevaptır ve bir yenileme kuralı ikincisini verir: bir kaydın `expires_at`'i yalnızca müşteri tercihi yeniden onayladığında, örneğin yeni bir mesajda belirttiğinde uzatılır. Altı aydır kimsenin yeniden belirtmediği bir tercih silinmeye adaydır ve sayı varsayımsaldır; sahibi ürün ve hukuk ekibidir.

Süre sonu gerçek olmalıdır: okuyucu status'ü kontrol eder ve bir job süresi dolmuş kayıtları ve türetilmiş verilerini (embedding'ler, index'ler, özetler) siler; çünkü bir kopya index'te dururken silinmiş bir satır, olmamış bir silmedir. Yedekler kayıt kayıt düzenlenmez: yedek süre sonuyla giderler ya


da içlerindeki veri, yani onu şifreleyen anahtarın yok edilmesi olan crypto-shredding ile okunamaz hâle gelir. Karantinaya alınmış bir kaydın da bir ömrü vardır. Hiçbir reviewer onu review penceresi içinde serbest bırakmaz ya da reddetmezse, diğer her kayıt gibi süresi dolar; böylece review queue'su sınırsız büyüyemez.

Düzeltilme, bir kaydın eski değil, yanlış olduğu durumdur. Müşteriler "bunu hiç istemedim" diyecek ve destek çalışanları tuhaf görünen kayıtlar bulacaktır. Tasarımın modelden geçmeyen bir yola ihtiyacı var: bir destek lideri bir kaydı `deleted` olarak işaretleyebilir ya da değerini değiştirebilir, değişiklik kimin ve neden yaptığıyla kaydedilir ve sonraki run düzeltilmiş kaydı okur. Düzeltilmeye bir çıktı daha verirdim: kayıt düzeltilmeden önce onu okuyan run'ların, `memory_read` event'lerinden çıkarılmış listesi; böylece biri herhangi bir cevabın takip gerektirip gerektirmediğine karar verebilir.

İstek üzerine silme, düzeltmenin bir müşteri ölçeğindeki hâlidir. Bir müşteri Parcelport'tan kendisini unutmamasını istediğinde, memory store onlar hakkında bir şey tutan birkaç sistemden biridir ve bir agent tasarımının eklediği sistemdir. Bu türden bir rejim altında çalışan bir reviewer genellikle sistemin bir kişi için her kaydı bulup türetilmiş kopyalar dahil kaldırabildiğini ve kaldırmanın kendisinin, kaldırılan veri saklanmadan kaydedildiğini görmek isteyecektir. Yorumu, neyin ne zaman silinmesi gerektiği dahil, hukuk ve uyumluluk ekipleri üstlenir. Mühendislik gereksinimi, kapsama göre silmenin tek bir işlem olmasıdır; bu, her kayıt `customer_id` taşıdığına kolaydır ve notlar insanlardan adlarıyla söz eden serbest metin olduğunda zordur.

Bellek burada kişisel olarak tanımlanabilir bilgiyle (PII) buluşur. Konunun sahibi Bölüm 17'dir ve belleğe özgü kurallar kısadır. Tipli bir tasarım, yapısı gereği az PII saklar: bir kanal tercihi ve bir dil kendi başlarına tanımlayıcı değildir, ama bir müşteri id'sine bağlıdırlar ve bu yüzden deponun kapsamında kişisel veri olarak kalırlar. İletişim bilgilerini, adresleri ya da ödeme referanslarını belleğe koymamak gerekir; onlar sahibi olan servislerde yaşar ve bir kopya, bulunup silinecek bir kopyadır. Ve bir vaka notunun bir ticket'tan alanları kopyalamasına izin vermemek gerekir. Not bir siparişin adına ihtiyaç duyuyorsa, sipariş id'sini saklamak ve gerisini okuyucunun redaction uygulayan bir tool ile getirmesine bırakmak gerekir.

Yaşam döngüsü çizilebilecek kadar küçüktür. Hangi geçişlerin otomatik olduğuna, hangilerinin bir insan gerektirdiğine ve hangi state'in final olduğuna bakmak gerekir.



Belleği gözlemek ve denetlemek

İzi olmayan bellek, F8'in en net hâlidir: sonraki bir run, daha önceki bir run'ın yazdığı bir şey yüzünden belirli bir biçimde davrandı ve hiçbir şey ikisini birbirine bağlamıyor. Bölüm 20, trace pipeline'ını ve bir run'ın yayması gereken event'leri anlatır; belleğe özgü gereksinim küçüktür. Öneriyi, yazımı ya da reddi ve her değişikliği kaydetmek ve hepsinden önce, her model çağrısının bağlamına giren kayıt id'leriyle `memory_read`'i kaydetmek gerekir. "Bu kayıt hangi run'lara dokundu" sorusunu cevaplayan o event'tir ve o olmadan bir düzeltme, kötü bir kaydın şekillendirmiş olabileceği cevapları bulamaz.

`memory_read` yerindeyken üç soru birer sorguya dönüşür. Bu kaydı hangi run'lar okudu? Bu run hangi kayıtları ve hangi kanıttan yazdı? Ve biri için şaşırtıcı olan bir cevap için, onu üreten step'in bağlamında bir bellek notu göründü mü? Sonuncusu, bir olay review'unun ilk sorduğu sorudur (Bölüm 23). Deponun hakkını verip vermediğini yargılamak için golden set'i bellek bloğuyla ve bellek bloğu olmadan çalıştırmak ve karşılaştırmak gerekir (Bölüm 21). Zamanlanmış bir denetim döngüyü kapatır:

kayıtlardan örnek almak, her birini kanıtına göre kontrol etmek ve yetimleri aramak gerekir; müşterisi artık var olmayan kayıtlar gibi, ki bunlar depoyu atlamış bir silmedir.

Trade-off'lar ve maliyetler

Bellek süreklilik satın alır ve bir sisteme mal olur. Maliyetler somuttur ve farklı insanların üzerine düşer.

Mühendislik. Yazma politikası, bir gate, bir yaşam döngüsü, bir süre sonu job'ı, bir reconciliation job'ı ve bir okuma yolu olan bir memory store küçük bir servistir. Bir schema registry'ye, versiyonlamaya ve testlere ihtiyaç duyar; hiçbir gate kararının belleğe bağlı olmadığı testi de bunlara dahildir. Tipli tasarımı genişletmek daha yavaştır: her yeni kind bir schema, bir politika girdisi ve bir review gerektirir. Sistemi koruyan şey o sürtünmedir ve aynı zamanda hızlıca bir not kaydetmek isteyen ürün ekiplerinden gelen bir talep birikimi olarak da görünür.

Destek. Düzeltme ve karantina review'ları, Sam gibi destek liderleri için iştir. Review listesi okunduğundan hızlı büyürse karantina tiyatroya, her zaman verilen bir onaya dönüşür. Karantinaya alınabilen kind'lar kümesini, liste okunacak kadar küçük tutmak gerekir.

Gecikme ve bütçe. Okuma yolu bir depo sorgusu ve biraz bağlam ekler; yazma aşaması bir gate kontrolü ve bir depo yazımı ekler. İkisi de bir model çağrısının yanında küçüktür, ama okuma yolunun depo kapalıyken belirtilmiş bir davranışa ihtiyacı vardır. Tercihim degraded mode'dur: belleksiz çalışmak ve bunu trace'te söylemek. Tipli bellek de serbest metinden daha az ifade gücüne sahiptir; kayıp çok büyükse, memory store'u serbest metne açmadan önce ticket sisteminin kaydettiklerini iyileştirmek gerekir.

Nerede bozulur. Tipli tasarım, değer kümesinin doğru olduğunu varsayar. Bir tercih uymazsa sistem onu sessizce düşürür ve uygun bir kind olmadığı için reddedilen öneriler üzerine bir metric'e ihtiyaç vardır; böylece boşluk görünür olur. System of record çakışma kuralı kaydın güncel olduğunu varsayar ve olmadığı yerde bellek doğru, kayıt yanlıştır. Ve bütün tasarım, kapsamın kodla atandığını varsayar. Kapsam filtresi eksik bir depo

müşteriler arasında başarısız olur ki bu başarısız olabileceği en kötü yerdir; bu yüzden izolasyon testi her deploy'dan önce çalışan süitte yer almalıdır.

Ne zaman kullanılmaz. Koşullar, "Belleğe hiç ihtiyaç var mı?" başlığı altında listelenenlerdir. Kısacası: ilk sürümde değil, bir system of record'un sağlayabileceği bir olgu için değil, yaşam döngüsünün sahibi olmayan yerde değil ve para hareket ettirebilen herhangi bir agent'ta serbest metin olarak değil.

Sık yapılan hatalar

- **Modelin serbest metin notları yazmasına izin vermek.** Cazip, çünkü demoya giden en kısa yol ve notlar iyi okunuyor. Çözüm, kapalı değer kümeli tipli kind'lar ve kodun etki kayıtlarından kurduğu vaka notlarıdır.
- **Belleği iç olduğu için güvenilir saymak.** Depo Parcelport'undur, ama içerik dışarıdan malzeme okuyan bir run'dan geldi. Her kaydı kökenine göre etiketlemek ve güveni verinin konumuna göre değil, kanıtın kaynağına göre belirlemek gerekir.
- **Belleğin yetki taşımaya izin vermek.** Bir müşterinin "doğrulanmış" ya da "önceden onaylı" olduğunu söyleyen bir not kullanışlıdır ve gate'i atlar. Yetki devirden ve politikadan gelir ve gate memory store'u asla okumaz.
- **Müşteriler arasında aramak.** Filtresi çağıran tarafından uygulanan paylaşılan bir index, eksik tek bir filtreyi bir sızıntıya çevirir. Kapsamı, orchestrator'ın run'dan belirlediği, deponun sorgu katmanının parçası yapmak gerekir.
- **Süre sonu olmadan yazmak.** "Sonra temizleriz", kimsenin kefil olamadığı olguların deposuna dönüşür. Her kind'a bir TTL ve bir yenileme kuralı vermek ve süresi dolmuş kayıtları ve türetilmiş kopyalarını kaldıran job'ı çalıştırmak gerekir.
- **Belleği ve state'i tek depoda tutmak.** Bir run'ın step'lerinin ve bir müşterinin tercihlerinin sahipleri, ömürleri ve silme kuralları farklıdır ve birleştirmek her biri hakkında akıl yürütmeyi zorlaştırır. Bölüm 10 run state'ini run store'da tutar; memory store'u ayrı tutmak gerekir.

- **Okumaları kaydetmemek.** `memory_read` event'leri olmadan bir düzeltme, kötü bir kaydın dokunduğu run'ları bulamaz. Her model çağrısına giren kayıt id'lerini kaydetmek gerekir.
- **Belleği eksik bir sistemi yamamak için kullanmak.** Her ops notu aslında bir runbook boşluğuysa, çözüm runbook'ta gözden geçirilmiş bir değişikliktir. Agent'ın önerilen metinle `open_pull_request` üzerinden bir pull request açmasına ve bir insanın merge etmesine izin vermek gerekir.

Temel çıkarımlar

- Bellek, run'lar arasında saklanan ve sonraki bağlamı şekillendirebilen bilgidir, run state'inden ayrıdır ve kötü bir kayıt onu okuyan her sonraki run'ı etkiler; bu yüzden bir production veritabanının kontrollerini hak eder.
- Belleğe hiç ihtiyaç olup olmadığını sormakla başlamak gerekir: bir system of record'un zaten tuttuğu bir olgu ondan okunmalıdır ve bir runbook notu serbest metin deposunda değil, gözden geçirilmiş bir runbook'ta durmalıdır.
- Her bellek yazımını bir öneri olarak ele almak gerekir: model tipli bir kayıt önerir; kod kanıtı doğrular, kapsamı atar, süre sonunu belirler ve yazar; böylece model bir kaydın kim hakkında olduğunu ya da ne kadar yaşadığını asla seçmez.
- Modelin yazdığı metin yerine kapalı değer kümelerini ve kodun etki kayıtlarından kurduğu notları tercih etmek gerekir; çünkü bir cümle tutamayan bir alan, sonraki bir run'a talimat taşıyamaz.
- Belleğin yetki taşımaya asla izin vermemek gerekir: gate devirden ve politikadan karar verir ve yalnızca bir not doğruysa geçecek bir öneri reddedilmelidir.
- Belleği kapsama göre etiketli bir bloğa okumak, süresi dolmuş, karantinaya alınmış ve çakışan kayıtları kodda düşürmek, system of record'un kazanmasına izin vermek ve modele ulaşan her kaydın id'sini kaydetmek gerekir.
- Her kayda bir TTL, bir düzeltme yolu ve türetilmiş kopyalara ulaşan bir silme yolu vermek ve okumaları ve değişiklikleri kaydetmek

gerekir; böylece kötü bir kaydın hangi run'lara dokunduğu cevaplanabilir.

Bellek, bilgiyi bir run'dan ötekine taşır. Bölüm 12, bir run'ın içinde zaman içinde ne olduğuna döner ve bir run'ın durması gerektiğinde durması için plan ve döngülerin nasıl sınırlandırıldığına bakar.

KISIM IV

Kontrol Döngüleri

Bölüm 12 — Planlama ve Döngüler

Parcelport'ta bir bayram sabahı düşünelim. `orders-service` için bir gecikme alarmı çalıyor ve orchestrator, ops agent'ın bir run'ını başlatıyor. İlk step'ler sağlam bir inceleme gibi görünüyor: bir metric sorgusu, bir log sorgusu, bir trace okuması. Altıncı step'te tablo belirsiz. Dokuzuncu step'e gelindiğinde model `query_logs`'u dört kez önermiş ve her seferinde filtre bir öncekinden bir alan ya da bir dakika kadar farklı. Her çağrıya izin verildi, çünkü her çağrı olayın servisleri içinde bir okumaydı. Her sonuç büyük ve bir öncekiyle neredeyse aynı. Tek tek hiçbir step'te yanlış bir şey yok.

Diyelim ki run'ı kırk dakika boyunca hiçbir şey durdurmuyor. Kimsenin planlamadığından fazlasını harcamış durumda ve bağlamı artık birbirinin neredeyse aynısı log satırlarıyla dolu; bu da bir sonraki öneriyi aynısından daha fazlasına doğru yönlendiriyor. On-call SRE Robin dashboard'u açıyor ve "investigating" yazan bir durum görüyor. Run'ın cevaba bir step mesafesinde mi olduğunu, yoksa daire çizip çizmediğini anlamamanın yolu yok.

Şimdi ekibin bariz çareyi eklediğini düşünelim: model önce bir plan yazıyor ve onu izliyor. Planda beş derli toplu step var. Dokuzuncu step'te run planı izlemiyor ve ne kadar ilerlediğine dair tek anlatı modelden geliyor: dördüncü step'in tamamlandığını söyleyen bir cümle. Bir run'ın ilerleme kaydedip kaydetmediğine kim karar verir, planı model yazdıysa bir plan ne kadar değer taşır ve döngü nerede biter?

Bu bölüm kontrol zarfının iki parçasına aittir. **Sınır** olarak döngünün nerede durduğunu ve çalıştırmanın neye mal olduğunu yanıtlar ve döngünün kendi çıkış koşullarını kapsar. **Öneri** olarak, bu parçanın hep sorduğu soruyu belirli bir türdeki öneri olan plan için sorar: kanıtlanana kadar güvenilmeyen girdi olarak mı ele alınıyor? Sınır'ın geri kalanı, yani bütçeler ve circuit breaker'lar, Bölüm 13'te.

Sorun ve neden zor olduđu

Bölüm 1'deki döngünün orchestrator'a ait iki çıkışı var: gate'in kabul ettiđi bir nihai cevap ve devreye giren bir sınır. İkisini de düşünmemiş bir tasarımın döngüsünün gerçek çıkışı "run'ın dışından bir şey müdahale ettiğinde"dir. Bu F5'tir (kontrolden çıkan döngü ya da bayat bağlam), kontrolden çıkan döngü alt sınıfı F5.1'de: ilerleme olmadan devam eden bir run. Genellikle F9 (maliyet ya da gecikme patlaması) olarak fark edilir, çünkü bir fatura ya da yavaş bir sayfa, ilerleme eksikliğinden daha kolay görülür.

Planlama kendi hata sınıflarını da getirir. Ayrıştırılamayan bir plan F1'dir (bozuk çıktı). Step'leri yanlış tool'u ya da doğru tool'u yanlış servis için adlandıran bir plan F2'dir (yanlış tool ya da yanlış argümanlar) ve tek bir çağrıdan daha iyi örgütlenmiş bir F2'dir, çünkü kasıtlı görünür. Modelin "dördüncü step tamamlandı" raporu, run'ın kendi geçmişi hakkında bir F3'tür (dayanaksız iddia). Yarısına kadar yürütölüp bitmiş diye raporlanan bir plan F6'dır (sessiz kısmi hata).

Üç bariz yaklaşım başarısız olur ve aynı nedenle başarısız olurlar: her biri bir kontrolü, o kontrolün sınırlaması gereken bileşene devreder.

- **"Cevabı bulunca dur."** Bitirme kararı bir öneri olur. Hiç nihai cevap önermeyen bir model run'ı asla bitirmez, çok erken öneren bir model ise onu yüzeysel bir teşhisle bitirir. Çıkış, orchestrator'ın değerlendirdiđi bir koşul olmalıdır.
- **"En fazla 15 step'in var."** Modele sınırını söylemek yararlı bir bilgidir ama zayıf bir uygulamadır. Prompt uzun run'ların oranını düşürür; uzun bir run'ı durdurmaz. Sınır, kodda bir sayaçtır.
- **"Bir plan tut ve step'leri işaretle."** İşaretler, modelin kendi ilerlemesi hakkındaki iddialarıdır. Bir step, kayıt çağrısının gerçekleştiđini ve döndüğünü söylediğinde tamamlanmıştır ve kaydı orchestrator yazar.

İlerlemeyi tanımlamak, bir sınırı tanımlamaktan zordur. Tek bir step'in özelliđi değildir. Step'ler arasındaki bir ilişki olarak ortaya çıkar: bu sonuç run'ın sahip olmadığı bir şey ekliyor, şu çağrı önceki birini tekrarlıyor, bu iki çağrı birbirini geri alıyor. Döngüye girmiş bir run'ın argümanları nadiren birebir tekrarlanır, çünkü "yararlı sonuç yok" gösterilen bir model isteđi deđiştirme eğilimindedir. Bu yüzden string eşitliğine dayanan bir dedektör en tembel döngüyü yakalar, sıradan olanı kaçıır.

Bunların hiçbirisi bir prompt sorusu değildir. Orchestrator'ın run store'dan hesaplayabildiği şeylere dair bir sorudur: sayaçlar, fingerprint'ler, signature'lar, kapsam kayıtları ve yapılandırılmış çıktılar. Bölümün geri kalanı bunları kurar, döngünün kendisinden başlayarak.

Döngü ve onu kimin yürüttüğü


Döngü şöyle işler: gözlemle, öner, doğrula, uygula, gözlemle. Bu kitabın sözlüğünde: bağlam run'ın state'inden derlenir, model önerir, gate doğrular, etki uygulanır ve sonuç bir gözlem olarak geri gelir. Bölüm 1'deki kanonik `runStep` tek bir geçiştir; `runAgent` run'ın durumu `running` olduğu sürece onu tekrarlar.

Önemli özellik, çağrının yönüdür. Orchestrator modeli çağırır; tamamen güvenmediği bir değer döndüren herhangi bir fonksiyonu çağıracağı gibi. Model orchestrator'ı çağırılmaz ve elinde bir "devam" ya da "dur" anahtarı yoktur. Tek bir geçişte her sorunun kime ait olduğuna bakmak gerekir.

Soru	Sahip	Mekanizma
Başka bir step var mı?	Orchestrator	Durum, <code>bound.check</code> , ilerleme kontrolü
Model ne görüyor?	Orchestrator	Bağlam derleme (Bölüm 9), run kaydındaki görev ifadesi dahil
Sırada ne olmalı?	Model, öneri olarak	<code>model.propose</code>
Şimdi olabilir mi?	Gate	Karar: <code>allow</code> , <code>refuse</code> , <code>needs approval</code>
Oldu mu ve ne geri geldi?	Orchestrator	<code>effect.apply</code> ve kayıt
Görev bitti mi?	Kodda başarı yüklemi	Nihai cevap üzerinde gate içinde bir kontrol

Yalnızca bir satır modele ait ve yanılmanın beklendiği tek satır da o. Geri kalan her şey deterministik koddur ve döngüyü test edilebilir yapan da budur: kaydedilmiş bir run, model hiç çağrılmadan çıkış kontrollerinden yeniden oynatılabilir.

Çıkışların sırasına ve run'ı bitirmeyen her yolun bir gözleme döndüğüne diyagramdan bakmak gerekir.



Sıra bilinçlidir. Sert sınır önce gelir, çünkü yorum gerektirmez; ilerleme kontrolü ikinci gelir, çünkü kaydı okur ve bir model çağrısından daha ucuzdur. Kanonik `runStep`'te nihai cevap, her öneri gibi `gate.check`'ten geçer ve başarı yüklemi kontrollerinden biridir.

Bir ret, Bölüm 4'teki gibi bir gözlem olarak bağlama döner; yani bir run defalarca reddedilip yine de çalışıyor olabilir. Aşağıdaki ilerleme kontrolünün retleri saymasının nedeni budur.

Öneri olarak planlar

Plan, modelin önerdiği, niyet edilen step'lerin bir listesidir. Bölüm 1 anlamında bir öneridir; dolayısıyla bir öneri için geçerli olan her şey onun için de geçerlidir: herhangi bir şey ona dayanmadan önce ayrıştırılır, doğrulanır, sınırlanır ve kaydedilir. Plan bir taahhüt değildir ve sistemdeki hiçbir şey, model listelediği şeyi yapmayı vaat etmiş gibi davranmamalıdır.

Bir plan ne işe yarar ve neye mal olur

Her görevin önüne bir planlayıcı koymazdım. Bir plan, ilk yararlı step'ten önce bir model çağrısına, saklanacak bir yere, doğrulama koduna ve yeni bir yanlış olma biçimine mal olur: plan iyi biçimlenmiş ve yanlış olabilir, Pazartesi doğru olup altıncı step çalıştığında bayatlamış olabilir. Maliyetini üç durumda çıkarır.

- **Step'ler birbirine bağlıdır ve baştan başlamak pahalıdır.** Üçüncü step, ikinci step'in bulduğu bir trace id'ye ihtiyaç duyuyorsa ve yanlış sıra bir sandbox run'ını boşa harcıyorsa, açık bir sıra değerlidir.
- **Etkilerden önce bir şeyin review edilmesi gerekir.** Plan, run herhangi bir şey yapmadan önce bir kişinin ya da bir doğrulayıcının okuyabileceği tek artefaktır. Bir run'ı sonradan review etmek bir kayıt sorusudur (Bölüm 20); önceden review etmek, ancak niyet edilen step'ler veri olarak varsa mümkündür.
- **Run'ın, ilerlemenin karşısında ölçüleceği bir biçime ihtiyacı vardır.** "Beş step'ten dördü bitti", orchestrator'ın hesaplayabileceği bir ilerleme ölçüsüdür. "İyi gidiyor gibiydi" değildir.

Görev "bir siparişe bak ve cevap ver" ise planı atlamak gerekir. İki step'lik bir döngünün, birine mal olan bir artefakta ihtiyacı yok.

Yapı olarak plan

İlk kural, planın düzyazı olarak değil, yapı olarak, yani step kayıtlarının bir listesi olarak gelmesidir. Düzyazıyı ancak başka bir model çağrısı okuyabilir; bu da doğrulama problemini başka bir öneriye taşır. Yapılandırılmış bir plan kodla denetlenebilir. Aşağıdaki açıklayıcı gösterimde model step alanlarını sağlar; yürütmeyi izleyen her şeyi orchestrator sağlar.


```

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

```

İkinci kural bundan çıkar. Model step'leri tamamlandı diye işaretlemeyiz. s2 step'iyile eşleşen bir çağrı döndüğünde orchestrator sonucu kaydeder ve durumu ayarlar. Modelin sonraki metni "4. step tamamlandı" derken kayıt onun beklemede olduğunu söylüyorsa, kayıt kazanır ve iddia, ilerleme kontrolünün fark edebileceği bir F3'tür.

Üçüncü kural, bir step'in etki sınıfının plandan değil, tool registry'den okunmasıdır. Bir yazmayı okuma diye etiketleyen bir plan, tool'un ne olduğu hakkında hiçbir şeyi değiştirmemiştir.

Bir planı çalışmadan önce doğrulamak

Doğrulamayı, gate'in verdiği kararların aynısını planın bütününe uygulayarak döndüren deterministik koddur. Hiçbir şeyi çalıştırmadan bilinebilecek şeyleri denetler: planın doğru biçime sahip olduğunu, her tool'un run'ın bu aşamasının kullanabileceği bir tool olduğunu, sıranın mümkün olduğunu ve planın toplam erişiminin sınırlı olduğunu.

```

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" }

```

Bloktaki iki seçim savunulmaya değer. Reason'lar sabit bir listeden gelir ve modele bir gözlem olarak döner; böylece reddedilen bir plan, Bölüm 4'ün reddedilen çağrılar için anlattığı gibi küçük bir deneme sınırı içinde yeniden önerilebilir. Ve doğrulayıcı argümanları denetlemez. Sonraki step'lerin argümanları çoğu zaman önceki step'lerin sonuçlarına bağlıdır, dolayısıyla plan yapılırken henüz mevcut değildirler; her çağrı önerildiğinde gate tarafından denetlenirler.

Doğrulanmış bir plan bir yetkilendirme değildir

Uyarı: Bir planı doğrulamak, step'lerini yetkilendirmez. Gate, çağrı kabul edilmiş bir planda yer alsa da almasa da, her çağrıyı önerildiği anda, o anın olguları, politikası ve devriyle denetler.

request_rollback'i listeleyen bir plan onun için hiçbir onay taşımaz; onay, Bölüm 15'in anlattığı gibi, tam olarak o çağrıya bağlıdır.

Planların davet ettiği hata budur. Bir plan, ister bir doğrulayıcı ister Robin göz gezdirerek "onaylandığında", izin gibi hissettirmeye başlar. İzin değildir. Plan, daha önce, değişmiş olabilecek olgular üzerinden yapılmış bir niyet beyanıdır ve yetki etkinin olduğu anda kararlaştırılmak zorundadır. Gate işini yapmaya devam eder ve planın değeri, gate'in daha az sürprizle karşılaşmasıdır.

Önce planla sonra yürüt ve step step

Bir planı kullanmanın iki yolu ve aralarında bir hibrit var. Seçim, görevin ne kadar uyarlanmaya ihtiyaç duyduğuyla ve hiçbir şey olmadan önce ne kadarının review edileceğiyle ilgilidir.

	Planla, sonra yürüt	Step step	Kısa plan, yeniden planlamayla
Kontrol model çağrıları	Başta bir, yeniden planda daha fazla	Step başına bir, her biri tek step'lik bir plan	Başta bir, tetikleyicilerde daha fazla
Etkilerden önce review edilebilir	Evet	Hayır, yalnızca ilerledikçe	Evet, güncel sürüm için
Sonuçlara uyum sağlar	Yalnızca yeniden planlamayla	Tamamen	Tanımlı tetikleyicilerde
Tipik zayıflık	Değişen olgular üzerine kurulu; katı	Sürüklenme ve döngüler, ölçülecek bir biçim yok	Yeniden planlama dalgalanması
Uygun olduğu yer	Bağımlı step'ler, pahalı yeniden başlatmalar, sonda yazmalar	Her sonucun bir sonraki step'i yeniden biçimlendirdiği keşif	Çoğu inceleme

Ops agent için hibritle başladım: kısa, doğrulanmış bir plan; sınıflandırılmış sapmalar ve izin verilen az sayıda yeniden planlama. Saf bir baştan plan, bir teşhis için kırılandır, çünkü bir log okumanın bütün anlamı, sonucun sırada neyin okunacağını değiştirmesidir. Saf step step, ilerleme ölçüsünden ve etki öncesi review'dan vazgeçer ve bu pazarlığı ancak görev keşif niteliğindeyse ve tool seti salt okunursa yapardım.

Planla-sonra-yürüt'ün savunan tarafta adını koymaya değer bir özelliği daha var. Güvenilmeyen içerik gelmeden önce yapılmış bir plan, run'ın niyet edilen biçimini sabitler ve plana uymayan bir öneri sınıflandırılır ve

sayılır. Bu, talimat içeren bir tool sonucunun run'ı ne kadar yönlendirebileceğini azaltır ve F4'e (talimat ele geçirme) verilen cevabın bir katmanındır, cevabın kendisi değil; yapısal kontrolleri Bölüm 16 kapsar.

Sapma ve yeniden planlama

Bir plan var olduktan sonra, önerilen her çağrı ona karşı, kodla, gate içinde, izin denetiminden sonra ve ön koşullardan önce sınıflandırılır.

```
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
```

Plan dışı bir okumaya küçük bir sayıya kadar tolerans gösterilir, çünkü inceleme kısmen doğaçlamadır ve beklenmedik bir log satırına bakamayan bir run pek işe yaramaz. Plan dışı bir yazmaya tolerans gösterilmez: `off_plan` ile reddedilir ve ret önce bir gözlem olarak döner; tekrarlanan retler ilerleme kontrolüne `refused_repeatedly` olarak ulaşır ve bu yeniden planlamayı tetikler. Planda olmayan bir yazma, tam da bir kişinin gerçekleşmeden önce yazılı görmesi gereken türden bir öneridir.

Yeniden planlamanın kendisi bir model çağrısıdır, bir öneridir ve bir döngüdür; dolayısıyla kendi sınırına ihtiyacı vardır. Yeniden planlama tetikleyicileri kodun değerlendirdiği koşullardır ve azdırlar. Aşağıdaki döngüde hepsi ilerleme kontrolü üzerinden gelir:

- bir duraksama ya da salınım bildirir;
- `refused_repeatedly` bildirir: gate step'leri reddetmeye devam eder; ister yeni argümanların düzeltemeyeceği bir nedenle, örneğin başarısız bir ön koşulla, isterse plan sınıflandırıcısının eşleştirmede olduğu `off_plan` yazmalarıyla, ki her biri önce bir gözlem olarak döner.

Tetikleyici gibi görünen iki koşul tetikleyici değildir. Planın belirtilmiş bir varsayımıyla çelişen bir gözlem, örneğin planın sağlıklı varsaydığı bir servisin kendi açık alarımının olması, modele bir gözlem olarak ulaşır ve model, ilerleme kontrolünün sonra her step gibi değerlendirdiği bir step ile karşılık verebilir. Başarı yüklemi hâlâ karşılanmamışken tükenen bir plan da bir yeniden planlama değildir: model bir nihai cevap önerir, gate onu reddeder ve `max_final_attempts` kadar reddedilmiş cevaptan sonra run `success_unmet` olarak hand-off'a geçer. Bir varsayım kontrolü ya da tükenmede yeniden planlama isteyen bir sistem bunun için bir dal ekler ve onu da diğerleri gibi `max_replans`'a karşı sayar.

Her yeniden planlama yeni bir plan sürümü üretir, eskisini run store'da tutar ve `max_replans`'a karşı sayılır; diyelim run başına bir ya da iki. Sınırsız yeniden planlayan bir run, kontrolden çıkan döngüyü bir seviye yukarı, plan dalgalanmasına taşımıştır: her sürüm geçerlidir ve hiçbir şey ilerlemez. Yeniden planlama aynı zamanda şimdiye kadar toplanan kanıtı taşır; bu, bağlam derleme yoluyla modele gösterilen state'tir (Bölüm 10), böylece yeni plan eskisinin ilk üç okumasını tekrarlayarak başlamaz.

Durma koşulları

Bir run üç yoldan biriyle biter: başarı, orchestrator'ın durdurması ya da bir kişiye hand-off. Orchestrator her run için hangisinin olduğunu ve nedenini söyleyebilmelidir. Bu başlık bir döngüyü bitiren koşulları kapsar. Run'ları yine bitiren kaynak bütçeleri ve circuit breaker'lar Bölüm 13'ün konusudur.

Başarı, kodda bir yüklemdir

Bir başarı yüklemi sağlandığında run `done` olur ve nihai cevap, onu sağlayabilen ya da sağlayamayan bir öneridir. Yükleme cevabın doğru olduğunu denetleyemez. Denetlenebilir olanı denetleyebilir: cevabın yapılandırılmış olduğunu, run'ın başlatıldığı görevle ilgili olduğunu ve her iddianın run'ın gerçekten topladığı bir kanıtı işaret ettiğini.

Ops agent için bir teşhis görevinin cevabı bir paragraf değil, bir teşhis kayıdır.

```

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()

```

Bunun vermediği şeyi açıkça görmek gerekir. Bir teşhis her kontrolü geçip yine yanlış olabilir, çünkü hipotezini desteklemeyen iki gerçek log satırını gösterebilir. Teşhisin doğru olup olmadığı eval'lerin (Bölüm 21) ve Robin'in sorusudur. Yüklemin sağladığı şey, bir nihai cevabın desteksiz bir cümle olamamasıdır ve başarısızlık reason'larının modele döndürülecek kadar belirli olmasıdır: "teşhis bu run'da olmayan bir sonuca atıf yapıyor", modelin üzerinde harekete geçebileceği bir gözlemdir.

Yüklem başarısız olduğunda başarısızlık bir ret olarak döner ve olağan deneme sınırı uygulanır. Geçen bir cevabı birkaç denemede üretemeyen bir run, tek başına yapabildiğinin sınırına gelmiştir ve doğru hamle, çıtayı düşürmek değil, o ana kadar toplanan kanıtlarla bir hand-off'tur.

Destek agent'ının sürümü daha kısadır ve neredeyse tamamen etkilerle ilgilidir. Bir hasar talebi, kayıt bu ticket için gönderilmiş bir yanıtı, planın gerektirdiği her iadeyi kaydedilmiş bir sonuçla ve açık bir intent içermediğinde tamamlanmıştır. Yüklem run store'u okur; modele müşterinin memnun olup olmadığını sormaz.

Step sınırı

Her döngünün ilk günden itibaren bir azami step sayısı olmalıdır. Yararlı olmak için ayar gerektirmeyen tek sınırdır, çünkü herhangi bir sonlu sınır "asla bitmiyor"u "bitiyor ve bir kişi bakıyor"a çevirir. Run kaydında bir sayaçtır, her step'ten önce denetlenir ve model çağrısından önce artırılır; böylece çağrı ile kayıt arasındaki bir çökme eksik saymaz.

Bu agent için doğru sınırı bilmiyorum ve onu çalışırken izlemeden kimse söyleyemez. En yavaş meşru görevin kaç step'e ihtiyaç duyduğuna, boşa giden bir step'in ne kadara mal olduğuna ve neredeyse bitmiş bir görevi sınır durdurduğunda kime alarm gönderildiğine bağlıdır. Bir başlangıç noktası, eval setindeki en uzun meşru run artı pay'dır; sayı o zaman bir hipotezdir ve ilk haftaların trace verisi onu doğrular ya da kaydırır.

Ucuz bir iyileştirme var: görev türü başına bir sınır, tek bir global sayıdan iyidir, çünkü bir adres kontrolü ile bir olay incelemesi aynı alana ihtiyaç duymaz.

Sınırın iki yönde de bir bedeli var: çok düşükse Robin, run'ın neredeyse tamamladığı işleri bitirir; çok yüksekse duraksamış bir run, kimse bakmadan önce tüm payını harcar.

İlerleme: tekrarlar, duraksamalar ve salınım

İlerleme, son birkaç step'in run'ın bildiğine bir şey ekleyip eklemediği ya da dünyada planın niyet ettiği bir şeyi değiştirip değiştirmediğidir. Orchestrator bunu kayıttan ölçer, modelin tarifinden asla. Üç örüntü, ters giden şeylerin çoğunu kapsar.

Birebir tekrarlar. Aynı tool, aynı argümanlar, yine. Bu kolay durumdur ve kural bir çekinceye ihtiyaç duyar: bir yazmadan sonra tekrarlanan bir okuma meşru olabilir, çünkü arada dünya değişmiştir. Bu yüzden tekrar sayacı, önceki çağrıdan beri bir etki uygulandığında sıfırlanır ve salt okunur bir aşamada her tekrar sayılır.

Yakın tekrarlar. Aynı niyet, farklı bir ifadeyle: bir alan daha eklenmiş bir log sorgusu, bir dakika kaydırılmış bir zaman aralığı. Bunu iki şey yakalar ve ikisini de kullanırdım. Birincisi **signature**: tool'un ve argümanlarının normalleştirilmiş biçiminin üzerinde bir hash; normalleştirme tool başına tanımlanır: filtreler sıralanır, zaman aralıkları kaba pencerelere kovalanır, limitler ve değişken alanlar atılır. İkincisi **sonuç fingerprint'i**: sonucun, değişken kısımları olmadan içeriğinin hash'i. Signature'lar tekrarlanan niyeti yakalar; fingerprint'ler isteğin nasıl ifade edildiğinden bağımsız olarak tekrarlanan kanıtı yakalar. İkisinden fingerprint'in atlatılması daha zordur, çünkü argümanlarını değiştiren bir model, log store'un içerdiğini değiştiremez.

```

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

```

Salınım. Run dönüşümlü gider: sorgula, filtreyi değiştir, sorgula, geri değiştir; ya da yazmalarla, bir flag'i çevir, gözle, geri çevir. Son signature'lar penceresinde, en az iki kez tekrarlanan, periyodu iki ya da üç olan bir döngü bir salınımdır. Yazma tool'ları için kural daha basit ve daha katıdır: bir run'da aynı hedef için aynı yazmanın ikinci önerisi, bir insan aksine karar vermedikçe gate tarafından reddedilir. Bölüm 6'nın idempotency key'i yalnızca birebir tekrarı kapsar; onu reddetmez, yeniden oynatır, bu yüzden farklı argümanlarla geri değiştirilen bir çevirmeyi yakalamaz.

İlerleme kontrolü bunları son step'lerin kısa bir penceresi üzerinde bir araya getirir.

```

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"

```

Bir tespiti tepki hemen bir durdurma olmamalıdır, çünkü bir dedektörün yanlış pozitifleri vardır ve sert bir durdurma her birini bir hand-off'a çevirir. Bu yüzden tepki kademelidir: ilk tespit bir yeniden planlamayı tetikler; isteği modelin gördüğü sabit bir listeden (`repeat_call`, `no_new_evidence`) bir reason code taşır ve ilerleme penceresi sonra yeni plan sürümünden yeniden dolar. İkinci tespit hand-off yapar. Her tespit, onu tetikleyen signature'lar ve fingerprint'lerle kayda yazılır; böylece biri sonradan bir yakalamayı yanlış alarmdan ayırt edebilir. Tool katmanının

geçici bir hatadan sonra yaptığı retry'lar tek bir step içinde gerçekleşir ve Bölüm 14'e aittir; bu anlamda tekrar değildirler, ama bütçelere karşı sayılırlar (Bölüm 13).

Hedef sürüklenmesi

Bir run, görevi dışında bir şey üzerinde bolca ilerleme kaydedebilir. Ops agent `orders-service` hakkındaki bir alarmdan başlar, sonra daha önceki bir log satırı adını andığı için alarmın bağımlılık listesinde olmayan bir servisin log'larını okur ve orada altı step harcar. Her step geçerli bir okumadır. Run ilerliyor ve alarm üzerinde çalışmıyor.

Kontrol, orchestrator'ın tetikleyiciden oluşturduğu ve modelin düzenleyemediği bir **görev kaydıdır**. Bu run'ın ne hakkında olduğunu söyler.

```
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
```

Gate, her önerinin hedefini buna karşı denetler: servis, zaman aralığı, sipariş ya da ticket. Kaydın dışındaki bir öneri `outside_task_scope` ile reddedilir ve bir gözlem olarak döner. Kapsamı genişletmek kasıtlı bir eylemdir: orchestrator bir bağımlılık listesini izleyebilir ya da bir kişi bir servis ekleyebilir, ama modelin bunu önermesi kaydı değiştirmez.

Bu, Bölüm 7'nin devriyle ilişkilidir ve aynı şey değildir. Bir devir, agent'ın hiç neye dokunmasına izin verildiğini söyler; görev kaydı bu run'ın ne hakkında olduğunu söyler. İkincisi genellikle daha dardır ve devrin izin verdiği bir okuma yine de görevin kapsamı dışında olabilir. Farklı kodlarla başarısız olurlar, çünkü farklı şeyler anlamına gelirler: `not_permitted`, `principal`'ın yapamayacağını söyler; `outside_task_scope` ise run'ın yapmaması gerektiğini söyler. Görev ifadesi ayrıca her bağlam

derlemesinde kayıttan yeniden belirtilmelidir (Bölüm 9 derlemeyi genel olarak kapsar); böylece birinci step'te yazılmış bir cümleyi modelin aklında tutmasına bağlı olmaz.

Bir durma geriye ne bırakır

Başarı dışındaki her durma `transition(run, "handed_off", reason)` ile biter; bu, sonucun sahibinin bir kişi olduğu state'tir (Bölüm 10). Hand-off, izlemeyen biri tarafından kullanılabilir olmalıdır. Kod tarafından run store'dan derlenmiş bir özet; görevi, sınıra karşı kullanılan step'leri, plan sürümlerini, her biri bir satırla kanıt id'lerini, durma reason code'unu ve run'ın henüz incelemeyeceği şeyleri içerir. Model, modelin yazdığı diye etiketlenmiş bir anlatı ekleyebilir ve kimsenin ona güvenmesi gerekmemelidir.

Döngü biçimleri ve kontrol yüzeyleri


Bölüm 1 tekil çağrılar, workflow'ları, döngüleri ve çoklu agent'ları karşılaştırdı ve sorunu çözen en az özerkliği savundu. Bu bölüm bir sonraki adımı atar: bir döngüye ihtiyaç olduğuna karar verdikten sonra, döngü run'ın ne kadarını alır?

Bir workflow içinde sınırlı bir agent step'i

İlk başvuracağım biçim, yalnızca bir aşamasının açık uçlu bir döngü olduğu ve o aşamanın okuyabildiği ama yazamadığı bir workflow'dur. Ops agent için:

- **1. aşama, kod.** Alarmdan görev kaydı oluşturulur ve bir baseline getirilir: alarmin kendi metric'leri, kapsamdaki servislerin aktif deployment'ları.
- **2. aşama, sınırlı döngü.** Model, yalnızca okuma sınıfı tool'larla, bir step sınırı, bir plan, bir ilerleme kontrolü ve bir görev kapsamında inceler. Bir teşhis kaydıyla biter.
- **3. aşama, kod.** Teşhis, başarı yüklemine karşı doğrulanır.
- **4. aşama, bir öneri.** Model en fazla bir eylem önerir, `open_pull_request` ya da `request_rollback`; bu, gate'e ve bir rollback için onaya gider.

Açık uçlu kısmın nerede durduğuna ve onu neyin çevrelediğine diyagramdan bakmak gerekir.



Gerekçe şu: açık bir döngünün maliyeti, tool setinin ve uzunluğunun çarpımıdır. 2. aşamayı okuma tool'larıyla sınırlamak, kontrolden çıkan bir döngünün en kötü durumunun maliyet, zaman ve gürültü olması, yazma olmaması demektir: içinde hiçbir iade, flag değişikliği ya da rollback olamaz. Yazmalar 4. aşamada, tek tek, gate'in ve politikanın gerektirdiği yerde onayın arkasında gerçekleşir (Bölüm 15). 2. aşama ayrıca, kitabın tablosuna göre okuma sınıfında olan ve kendi sınırını sandbox'ta tutan `run_diagnostic`'i de çağırabilir (Bölüm 19).

Bedeli esnekliktir. Doğru yanıtı bir yazmayla başlayan bir olay, örneğin hasarı durdurmak için bir flag'i kapatıp sonra incelemek, bu sıraya uymaz ve run bir kişiye hand-off yapar. Bu bana ilk sürüm için kabul edilebilir geliyor: önce harekete geçmesi gereken bir kişinin bunu öğrenmek için bir agent'a ihtiyacı yok.

Açık uçlu döngüler

Açık uçlu bir döngü, modele run boyunca yazmalar dahil her tool'u verir ve onu bir sınırla ve gate'le sınırlar. Kurması en basit olan ve kontrol edilmesi en geniş yüzeydir. Yalnızca yol aşamalara bölünerek bile listelenemiyorsa ve her tool'un zaten kendi başına geçerli bir sözleşmesi, tavanı ya da onayı varsa kullanırdım. O zaman bile ona aşamaya benzer bir kısıtlama koymak gerekir: örneğin yazmalar yalnızca run'ın yüklemi geçen bir teşhis kaydı olduktan sonra kullanılabilir olsun. Sıra bir talimatla değil, registry tarafından uygulanır.

Destek agent'ının hasar talebi döngüsü hafif bir biçimde açık uçludur: arama, olası bir adres kontrolü, olası bir iade, bir yanıt. Tool seti küçüktür, tehlikeli step'ler (`issue_refund`, `send_customer_reply`) gate'lenmiştir ve step sınırı düşüktür, diyelim beş ya da altı, çünkü meşru bir talep az step gerektirir ve daha uzun bir run bir insanın dikkatini hak eder.

Birkaç agent, her biri kendi zarfıyla

Çoklu agent'lar, derli toplu bir diyagramla değil, ihtiyaç duyulan bir sınırla haklı çıkarılır; örneğin bir izin sınırı ya da bir bağlam sınırı (Bölüm 1).

Ops agent'ın açıklayıcı bir bölünmesini düşünelim: yalnızca okuma tool'ları tutan bir araştırmacı ve `open_pull_request`'i tutan bir düzeltici. Bu bölümün döngü kontrolleri her birine uygulanır ve dikişler üç kural daha ister.

- **Her agent'ın kendi zarfı vardır;** kendi tool seti, devri, görev kaydı, sınırları, gate'i ve kaydıyla. Hiçbir agent, diğeri tarafından çağrılarak onun yetkisini devralmaz.
- **Agent'lar arasındaki bir mesaj, güvenilmeyen bir kaynaktan bir öneridir.** Teşhis düzeltici'ye, bağlama yapııştırılmış bir paragraf olarak değil, bir schema'dan ve bir yüklemden geçen yapılandırılmış veri olarak ulaşır.
- **Sınırlar iç içe geçer ve hand-off'lar sınırlıdır.** Bir çocuğun payı ebeveyninkinden ayrılır ve çağrı zincirinin bir derinlik sınırı, bir fan-out sınırı ve bir döngü kontrolü vardır.

Kontrol yüzeyleri agent sayısından daha hızlı büyür. Tek bir agent içindeki aşamalar ihtiyaç duyulan sınırı veriyorsa aşamaları seçmek gerekir.

Ops agent'ın teşhis döngüsü

İşte ops agent'ın 2. aşaması bir bütün olarak. Sınırlar açıklayıcıdır ve bir sınır için önemli olan her satır, modelin çıktısının ulaşmadığı kodda.

```

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

```

Blok, amaçlandığı hatalar karşısında ayakta kalır. Model hiç nihai cevap önermezse `max_steps` run'ı bitirir ve bir yeniden planlama onu aşamaz, çünkü sınır her `obtainPlan`'dan sonra yeniden denetlenir. Değişen ama bir şey eklemeyen çağrılar önerirse ilerleme kontrolü onu fingerprint'lerden yakalar; gate reddetmeye devam ederse aynı kontrol pencerede üç ret görür. Nihai cevap yüklemi geçememeye devam ederse `success_unmet` run'ı bitirir. Orchestrator döngünün ortasında çökerse step sayacı ve plan run store'dadır ve Bölüm 10'un `resumeRun`'ı onları alır. Bu aşamada bir `needs_approval` kararı olamaz, dolayısıyla bir bug sayılır ve hand-off yapılır, asla çalışır halde bırakılmaz.

Şimdi uydurma sayılarla ve üç step'lik bir pencereyle açıklayıcı bir run'ı tablodan izlemek gerekir.

Step	Öneri	Sınıflandırma ve sonuç
1	Plan v1: metric'ler, loglar, trace, runbook, cevap	<code>validatePlan</code> izin verir; 1. sürüm olarak saklanır
2	Alarmin servisi için <code>get_metrics</code>	Planda; yeni fingerprint
3	<code>query_logs</code> , alarm penceresindeki hatalar	Planda; yeni fingerprint
4	3. step'te bulunan bir id için <code>get_trace</code>	Planda; yeni fingerprint
5	<code>query_logs</code> , pencere bir dakika kaydırılmış	Plan step'i zaten tamamlanmış, yani plan dışı (okuma, 3'ten 1); sonuç fingerprint'i 3. step'inkine eşit
6	<code>query_logs</code> , bir ekstra filtre alanı	Plan dışı (okuma, 3'ten 2); aynı fingerprint
7	<code>query_logs</code> , başka bir varyant	Plan dışı (okuma, 3'ten 3); aynı fingerprint
8	Plan v2, <code>progressCheck</code> "stalled" döndürdükten sonra istendi	<code>validatePlan</code> izin verir; 2. sürüm olarak saklanır; yeniden planlama 1'den 1 kullanıldı; pencere burada yeniden başlar
9	Şüphelenilen bileşenin runbook'u için <code>search_docs</code>	Plan v2'de; yeni fingerprint; pencere henüz dolu değil, dolayısıyla "advancing"
10	Saklanmış bir örnek üzerinde <code>run_diagnostic</code>	Plan v2'de; yeni fingerprint
11	Bir teşhis kaydıyla nihai cevap	Yüklem karşılandı; run <code>done</code>

Beşinci ile yedinci step'lerde olana bakmak gerekir. Her çağrıya izin verildi, her biri kapsam içinde bir okumaydı ve argümanlar her seferinde farklıydı; dolayısıyla birebir eşleşme dedektörü üç farklı çağrı görürdü. Fingerprint aynı kanıtı üç kez gördü. Run 15 step'inin 11'ini, iki planı da sayarak, kullandı ve 2, 3, 4 ve 10. step'lerdeki id'lere atıf yapan bir teşhisle bitti. Run'ın ilerleyen bir yerinde, iki planda da, dördüncü bir varyant `off_plan` olarak reddedildi, çünkü plan dışı okuma sayacı planla sıfırlanmaz ve ikinci bir duraksama run'ı Robin'e kayıtlı ve `plan_churn` reason'ıyla, detail `stalled` olarak hand-off'a geçirirdi.

Döngü sınırlarından bütçelere

Yukarıdaki döngü görebildiğini uygular: step'ler, ilerleme, plan dalgalanması, kapsam. Durma reason'ları kodun ürettiği kapalı bir listedir: `max_steps`, `plan_churn` (`detail stalled`, `oscillating` ya da `refused_repeatedly` ile), `success_unmet` ve `phase_violation`. Her biri bir hand-off'a karşılık gelir ve her biri Bölüm 20'nin trace'leri için bir veri noktasıdır. `outside_task_scope` gibi bir ret tek başına bir durma reason'ı değildir; tekrarlanan retler `refused_repeatedly` detail'i olarak ortaya çıkar.

Göremediği şey, run'ın neye mal olduğudur: bir run 15 step içinde kalıp her step büyük bir bağlam taşıyorsa yine de çok fazlasını tüketebilir. Token'lar, zaman, para ve toplam etki, buradakiyle aynı arayüzü kullanan bütçelere ve circuit breaker'lara aittir: `bound.check(run)` bir reason ile `BoundExceeded` fırlatır ve run hand-off'a geçer.

Trade-off'lar ve maliyetler

Planlama bir model çağrısına ve yeni bir yanlış olma biçimine mal olur. Plan, ilk yararlı step'ten önce gecikme, depolama, tool değişikliklerini izlemesi gereken doğrulayıcı kodu ve kendi hata sınıfını ekler: tutarlı, doğrulanmış ve yanlış bir öncül üzerine kurulu bir plan. Derli toplu bir plan, tasarımın hak etmediği güveni de kazanabilir. Bağımlı step'ler, pahalı yeniden başlatmalar ve etki öncesi review için değer; üç ya da daha az step'lik görevler için değil.

İlerleme tespitin yanlış pozitifleri vardır ve her biri bir kişinin üzerine düşer. Bir deploy bitene kadar bir metric'i yoklayan bir run meşru olarak kendini tekrarlar ve kanıtı gerçek ama benzer olan bir run duraksamış görünebilir. Her yanlış durma Robin'e kaydı okuma ve bir karar maliyeti getirir; dolayısıyla eşikler (pencere uzunluğu, plan dışı okumalar, yeniden planlamalar) ayar işidir. Her tespiti girdileriyle log'lamak, bir örneği düzenli aralıklarla review etmek ve son şikâyeteye göre değil, eval setine (Bölüm 21) göre ayarlamak gerekir.

Hand-off'lar her durmanın bedelidir. Hand-off oranı diyelim run'ların üçte biriye, döngü bir döngü olacak kadar iyi değildir ve dürüst cevap bir workflow olabilir.

Bunu ne zaman kullanmamalı. Üç sabit düğümlü bir workflow için ilerleme dedektörü kurmamak ve tek bir agent'ın registry'sinin verebileceği aşamaları elde etmek için çoklu agent tasarımı kurmamak gerekir.

Sık yapılan hatalar

- **Kabul edilmiş bir planı yetkilendirme saymak.** Doğrulanmış bir plan birinin verdiği bir karar gibi görünür ve listelediği hiçbir şey için onay taşımaz. Çözüm: gate her çağrıyı önerildiği anda denetler.
- **Step sınırını tek koruma olarak kullanmak.** Tek bir sayaç kurması kolaydır ve yakınsamayan her döngüyü bitirir. On beş step'in on birini aynı kanıta ya da yanlış servise harcayan run için hiçbir şey yapmaz. Çözüm: ilerleme tespiti ve bir görev kapsamı eklemek gerekir.
- **Yeniden planlamanın serbest çalışmasına izin vermek.** Her yeniden planlama geçerli bir plandır, dolayısıyla bir döngü gibi değil, bir toparlanma gibi görünür; sınırsız bir yeniden planlama döngüsü bir seviye yukarıda kontrolden çıkmış davranıştır. Çözüm: plan sürümlerini sınırlamak ve şimdiye kadar toplanan kanıtı her birine taşımak gerekir.
- **Açık döngüye her tool'u vermek.** Tek bir tool seti yapılandırması en basit olanıdır ve erişiminde yazmalar bulunan bir döngünün en kötü yazmasından küçük bir en kötü durumu yoktur. Çözüm: okumaları döngüye, yazmaları bir aşama sınırının arkasına koymak ve sırayı registry'ye uygulamak gerekir.

Temel çıkarımlar

- Döngüyü orchestrator yürütür ve model onun içinde çağrılır: başka bir step olup olmadığına, modelin ne gördüğüne ve run'ın ne zaman bittiğine kod karar verir ve yalnızca bir sonraki öneri modelden gelir.
- Plan bir öneridir: onu yapı olarak istemek, tool'larını, sırasını ve boyutunu çalışmadan önce doğrulamak, etki sınıflarını registry'den okumak ve step durumunu, modelin değil orchestrator'ın yazdığı run store'da tutmak gerekir.
- Doğrulanmış bir plan hiçbir şeyi yetkilendirmez; gate her çağrıyı önerildiği anda denetler ve onay tam olarak o çağrıya bağlanır.

- Başarı, yapılandırılmış bir cevap ve run'ın topladığı kanıt üzerinde kodda bir yüklemidir ve denetlenebilir olanı (biçim, konu, run'daki kanıt) denetler; doğruluk eval'lerin ve insanların meselesi olarak kalır.
- Durma koşulları katmanlıdır: ilk günden bir step sınırı, signature'lar ve sonuç fingerprint'leriyle ilerleme tespiti, bir yeniden planlama sınırı ve sürüklenmeyi yakalayan bir görev kapsamı; her biri bir gözlemde yeniden planlamaya, oradan hand-off'a kademelenir.
- Bir run'ın açık uçlu kısmını küçük tutmak gerekir: bir workflow içinde okuma tool'larından oluşan sınırlı bir döngü, yazmalar gate'in arkasında bir aşama sınırında ve çoklu agent tasarımındaki her agent kendi zarfını ve ebeveyninin sınırlarından bir pay tutarak.
- Her durma, reason code'u olan ve kayıttan oluşturulmuş bir özet içeren bir hand-off'tur ve her eşiğin kontrol olması, tiyatro olmaması için veriye ve bir sahabe ihtiyacı vardır.

Döngü artık görebildiği nedenlerle ne zaman duracağını biliyor, ama run'ın neye mal olduğunu ya da altındaki bir bağımlılık başarısız olduğunda ne yapacağını henüz bilmiyor. Bölüm 13, bunları kapsayan bütçeleri ve circuit breaker'ları ekliyor.

Bölüm 13 — Bütçeler ve Circuit Breaker'lar

Parcelport'ta kuşluk vaktini düşünelim. Model gateway'in arkasındaki bir sağlayıcı yavaş cevap vermeye başlıyor. Hiçbir şey tamamen başarısız olmuyor: çağrılar daha uzun sürüyor ve bazıları timeout'a düşüyor. Destek agent'ında Bölüm 12'nin önerdiği step sınırı var ve her run onun içinde kalıyor. Ama her step artık yavaş bir çağrıyı bekliyor, orchestrator timeout'ları retry ediyor ve her retry, zaten zorlanan bir sağlayıcıya yapılmış bir ücretli istek daha. Agent'ın günde 200 ticket işlediğini varsayalım. Bir saat içinde bütün worker'lar açık run'larda bloke oluyor ve yeni ticket'lar onların arkasında queue'ya giriyor.

Bu arada `payments-service`, bazı iade durumu kontrollerinde hata döndürmeye başlıyor ve agent kontrolü tekrar tekrar öneriyor; her çağrı run'ın sınırı içinde. Ops tarafında bir alarm fırtınası, kırk alarmın her biri için bir run açıyor. Her inceleme mütevazı; birlikte kimsenin planlamadığı bir fatura oluşturuyorlar ve hepsi aynı iki bağımlılığa aynı soruları soruyor.

Hiçbir run tek başına yanlış davranmadı. Parcelport'un sahip olduğu her sınır tek bir run'ın sınırıydı ve problem run'ların arasında yaşıyordu: bağımlılıklarda ve toplamda. Bu bölümün yanıtladığı soru, bir run'ın, bir agent'ın ve bütün sistemin tüketebileceği ya da neden olabileceği şeye nasıl bir tavan konacağı ve başarısız olan bir şeyi çağırmaya nasıl son verileceğidir; hem de kimsenin izlemediği günlerde de geçerli olan kontrollerle.

Bu bölüm, kontrol zarfının döngünün nerede durduğunu ve çalıştırmanın neye mal olduğunu soran **Sınır** parçasına aittir. Bölüm 12 bunu tek bir run'ın biçimi için yanıtlamıştı; bu bölüm run'ların arasından geçen her şey için yanıtlar: tüketimi birkaç seviyede sınırlayan **bütçeler** ve başarısız olan bir bağımlılığa ya da yanlış davranan bir agent'a giden trafiği durduran **circuit breaker'lar**. Retry'lar ve fallback'ler, yani bir sınır ya da breaker devreye girdiğinde izlenen yollar, Bölüm 14'te.

Sorun ve neden zor olduğu

Her geçişte bir şeye mal olan bir döngünün bir tavana ihtiyacı vardır. Bölüm 12'deki step sınırı eklenecek ilk sınırdır ve en dar olanıdır: bir run'ın geçişlerini sayar ve bir geçişin ne kadar pahalı olduğu, kaç run'ın açık olduğu, bir müşterinin ticket'larının ne kadar para hareket ettirdiği ya da bağımlılığın sağlıklı olup olmadığı hakkında hiçbir şey söylemez.

Üç hata sınıfı burada buluşur. **F9 (maliyet ya da gecikme patlaması)** bariz olandır: birlikte çok pahalıya mal olan bin doğru run. **F5 (kontrolden çıkan döngü ya da bayat bağlam)**, run başına bir sınırı görmediği bir biçimde ortaya çıkar: başarısız olan bir bağımlılığa yapılan bir retry, herhangi bir run'da takılmış bir döngü değildir, ama run'lar boyunca ilerleme olmadan tekrarlanan aynı çağrıdır. Ve **F7'nin (yetkisiz etki)** sessiz bir çeşidi var: her iade gate'teki tavan kontrolünden geçer, ama bir müşterinin run'ları dizisi bunlardan çok sayıda üretebilir. Her çağrıya izin verildi ve toplam, kimsenin yetkilendirmediği bir şey.

Bariz yaklaşım, modelden tutumlu olmasını istemektir. Prompt, birkaç denemeden sonra durmasını, başarısız bir çağrıyı tekrarlamaktan kaçınmasını, ucuz yolu tercih etmesini söyler. Savurgan step'lerin oranını düşürür ve kontrol olamaz: run'ın içindeki bir model diğer run'ları, bağımlılığın son dakikadaki sağlığını ya da günün toplamını göremez ve sınırlanan şeye bağlı bir sınır, sınır değildir.

İkinci bir tuzak var: yalnızca gözlemlenen bir sınır, bir dashboard'dur. Harcayan kod yolu, harcamadan önce sınıra danışmalıdır ve cevap "hayır" olabilmelidir.

Bütçeler: bir run'ın kullanabileceği şey

Bu kitabın terimleriyle **bütçe**, bir run'ın kullanabileceği bir kaynak üzerindeki, bir birimi, bir limiti, ölçüldüğü bir yeri ve tükendiğinde tanımlı bir davranışı olan sınırdır. Dördünden biri eksikse, bu bir dilektir. Aşağıdaki türler Parcelport'un agent'ları için yerini hak eder.

Bütçe	Neyi sayar	Kim ölçer	Neye karşı korur	Tükendiğinde tipik tepki
Step'ler	Döngü geçişleri	Orchestrator	F5	Dur ve hand-off yap

Bütçe	Neyi sayar	Kim ölçer	Neye karşı korur	Tükendiğinde tipik tepki
Tool çağrıları	Çağrılar, tool başına ya da etki sınıfı başına	Orchestrator ve tool gateway	F5, F9, bağımlılık üzerindeki yük	O tool'u reddet ya da hand-off yap
Token'lar	Run başına girdi ve çıktı token'ları	Model gateway kullanımı bildirir; orchestrator toplar	F9	Dur ve hand-off yap
Zaman	Run'ın aktif duvar saati süresi	Orchestrator saati	F9 (gecikme), bayat bağlam	Dur ve hand-off yap
Harcama	Token'lardan ve tool maliyetlerinden türetilen para	Orchestrator, bir fiyat tablosundan	F9	Dur ve hand-off yap
Etki	Etkilerin kümülatif büyüklüğü, örneğin toplam iade edilen	Tool gateway	F7 (toplam), F6 baskısı	Needs approval

Step'ler ve tool çağrıları farklıdır: bir step hiç tool çağrısı içermeyebilir ya da birkaç tane içerebilir ve tool çağrısı bütçesi, bir bağımlılığı korumanın yoludur. Token'lar bir sayaçtır; harcama, token'ların, birinin sahip olduğu ve değişen bir fiyat tablosuyla çarpımıdır, bu yüzden tablonun sahibi Bölüm 22'dir ve bu bölüm onu tüketir.

Zaman için bir ayırım gerekir. İnsan onayını bekleyen bir run hiçbir şey harcamaz ve beklemeyi saymak onayı bir sınır ihlali gibi gösterirdi. Bölüm 10'daki run'ın mutlak deadline'ı run'ın toplam yaşını kapsar; zaman bütçesi, orchestrator ve bağımlılıkları onun üzerinde çalışırken geçen **aktif süreyi** kapsar. İkisi de vardır ve farklı soruları yanıtlarlar.

Etki bütçesi

Son satır çoğu ekibin sahip olmadığı satırdır ve en çok dikkati hak eder. Bölüm 4 ve Bölüm 6, iade tavanını koda koydu: bir çağrı, bir tutar, gate'te denetlenir. Bu kontrol toplam hakkında hiçbir şey söylemez: bir run tavana kadar on iade yapabilir ve her biri geçer. On iadenin geçip geçmemesi gerektiği, kimsenin yanıtlamadığı bir politika sorusudur.

Etki bütçesi, bir kapsam için bir etkinin kümülatif büyüklüğünü sınırlar. Parcelport için tavanın yanına, aynı yere ve aynı biçimde yazılabilir. Aşağıdaki gösterim açıklayıcıdır ve tutarlar varsayımsaldır.

```
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"
```

Tepki de sayılar kadar önemlidir. Bir toplam limit aşıldığında bir ret döndürmezdim, çünkü bu modele başka bir şey denemesini söyler ve bu, aynı toplama giden başka bir yol olabilir. Doğru karar `needs_approval`'dır: bir kişi, Sam, toplamın ne olduğunu ve neden devreye girdiğini söyleyen bir istek görür ve karar verir. Bu onayın nasıl kurulduğunu ve çağrıya nasıl bağlandığını Bölüm 15 kapsar.

İki uyarı. `outcome_unknown` durumundaki bir iade (Bölüm 6), durumu çözülene kadar tam tutarıyla sayılmalıdır, yoksa bir timeout bütçeyi sessizce genişletir. Ve etki bütçesi tavanın yerini almaz: ikisi de uygulanır ve daha dar olan önce bağlar.

Çalışma zamanı defteri tutar

İşte orchestrator'ın tuttuğu haliyle run seviyesindeki bütçe. Anahtar ayrıntı, sayaçların nerede yaşadığıdır.

```
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
```

Sayaçlar run store'da, Bölüm 10'daki run kaydında durur ve her step'in parçası olarak orchestrator tarafından yazılır. Konuşmadan yeniden hesaplanmazlar. Resume'da sıfırdan başlayan bir bütçenin yerleşik bir

kaçış kapısı vardır; bu yüzden sayaçlar bir çökme ya da bir onay boyunca run'la birlikte taşınır.

Limitler, run türü ve agent sürümü ile anahtarlanan politika verisinden gelir: bir alarmı inceleyen bir **ops-agent**, bir takip sorusunu yanıtlayan bir **support-agent**'tan meşru olarak her şeyden daha fazlasına ihtiyaç duyar. Diyelim ki bir destek run'ı için 12 step ve bir inceleme için 40 limiti: bunlar varsayımsaldır ve gerçek değerler sistemin kendi run'larının dağılımından gelir.

Bütçeleri katmanlamak

Açılıştaki hatalar run'lar arasındaydı, bu yüzden bir kaynağın tüketilebileceği her seviyede bir tavana ihtiyacı vardır. Beş seviye kullanırdım.

Seviye	Neyi sınırlar	Örnek (varsayımsal)	Nerede uygulanır	Neden kendi seviyesine ihtiyaç duyar
Run	Yukarıdaki tablodaki her şey	Run başına step'ler, token'lar, zaman, etki	Orchestrator	Yanlış davranan tek bir run
Konu	Bir ticket, bir müşteri, bir alarm	Ticket başına saatte run'lar; müşteri başına günde iadeler	Orchestrator ve tool gateway	Çok sayıda run tetikleyen tek bir konu: yeniden açılan bir ticket, beş kez yazan bir müşteri
Agent	Bir agent, bir sürüm	Saatte token'lar; devam eden run'lar; saatte iadeler	Model gateway, orchestrator, tool gateway	Her biri kendi bütçesi içinde olan ama toplanan çok sayıda run
Tenant	Parcelport'un siparişlerini işlediği bir tüccar (açıklayıcı)	Günlük token payı	Model gateway	Herkesi aç bırakan gürültücü bir entegrasyon
Global	Bütün sistem	Günlük token'lar ve harcama	Model gateway	Birinin hesabını verdiği sayı

Bütün seviyeler denetlenir ve tükenen en dar seviye bağlar. Platform ekibi global ve agent seviyelerinin sahibidir; destek lideri ve on-call mühendis, para ve production değişiklikleri hakkında iş kuralları olan konu seviyesi

etki limitleri hakkında görüş bildirir.

Her seviye nerede uygulanır

Kod yolunun atlayabileceği bir yerde uygulanan limit bir öneridir. Üç uygulama noktası var ve her biri ötekilerin görmediği bir şeyi görür.

Orchestrator run'ı görür: step'ler, aktif süre ve kendi tool çağrılarını. Run seviyesi için ve ticket başına run'lar gibi konu seviyesi sayıları için doğru yerdir ve sayaçlar paylaşılmadıkça diğer replica'ları ya da agent'ları görmez.

Model gateway, her çağırının her model çağrısını görür; bu da onu toplam bir token ya da harcama tavanının mutlak olabildiği tek yer yapar, çünkü bir modele giden hiçbir kod yolu ondan kaçınmaz. Saymayı unutan bir orchestrator bug'ı, gateway'in uyguladığı bir tavanı aşarak harcamaz, çünkü agent'lar sağlayıcı credential'larını asla tutmaz (Bölüm 1 ve Bölüm 18). Bu yazının yazıldığı sırada RAGmux, gateway'de proje başına token bütçeleri ve rate limit'ler tutuyor; böylece token kullanımı agent'ın dışında proje başına sınırlanıyor; diğer araçlar benzer yaklaşımlar izliyor ve run başına bir bütçe yine orchestrator'a aittir, çünkü bir gateway bir projenin trafiğini görür, tek bir run'ın niyetini değil.

Tool gateway, yani tool çağrılarını için gate, etkileri görür. Etki bütçeleri için yerdir, çünkü onaylanmış her etkinin bir servise ulaşmadan önce geçtiği koddur ve sözleşmeyi ve credential verilmesini zaten elinde tutar.

İzleyeceğim kural, atlanamayacak en dar noktada uygulamak ve sayılan şeyin görüldüğü yerde saymaktır. Orchestrator'ın saydığı ve gateway'de de uygulanan bir token bütçesi, farklı hata kiplerine sahip iki kontroldür ve sayıları arasındaki boşluğun kendisi bir sinyaldir.

Rezerve et, çağır, kapat

Bütçelere harcamadan önce danışılır ve bir model çağrısının maliyeti ancak sonrasında bilinir. Olağan cevap, çağrıdan önce bir tahmini rezerve etmek, sonra gerçek rakamla kapatmaktır. Üst seviyelerin sayaçları bir sayaç store'unda yaşar; bu run store'dan ayrı bir sistemdir ve hiçbir transaction ikisini kapsamaz. İşlem sırası, bir çökmede ne olacağını söylemelidir.

```

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

```

Bloktaki üç şey bilinçlidir. Run store'daki run seviyesi sayaç çağrısından önce tahminle artırılır ve sonra düzeltilir; böylece arada bir çökme ya da timeout, run'ın kendi sayısını sıfırda değil, tahminde bırakır. Paylaşılan sayaçlar bir time to live ile rezervasyon taşır; böylece rezerve ile kapat arasında çöken bir worker, kendiliğinden süresi dolan bir rezervasyon bırakır. O zamana kadar paylaşılan sayaç fazla gösterir; iş etkiyi doğurduysa ve çökme kapatmadan önce geldiyse, gateway'in kullanım kayıtlarına ve run store'a karşı mutabakata kadar (diyelim günde bir kez ve bir ayrışma alarmında) eksik gösterebilir. Bu yüzden bir run için otorite run store'dur ve paylaşılan sayaçlar tasarım gereği yaklaşıktır. Ve hata yolu alınanı serbest bırakır; böylece global seviyedeki bir ret hiçbir rezervasyon sızdırmaz.

Sayaç store'u kendisi erişilemezse, etkiler için hata durumunda reddeder, okumalar için, run seviyesi limit hâlâ uygulanarak, hata durumunda izin verirdim. Toplam etki bütçesini doğrulayamayan bir run iade yapmamalıdır; paylaşılan bir token sayacını güncelleyemeyen bir run yine kendi limitiyle sınırlıdır ve bir sayaç çöktü diye bütün işi durdurmak, bir muhasebe arızasını bir kesintiye çevirir.

Bir bütçe tükendiğinde

Bir bütçe tükendiğinde dört yararlı tepki var ve seçim, tesadüfen ilk fırlatan kod yoluna bırakılmamalı, bütçe türü ve seviyesi başına yazılmalıdır.

Dur ve hand-off yap. Run bir özetle `handed_off` durumuna geçer (Bölüm 10) ve sonucun sahibi bir kişidir. Bu, run seviyesi bütçeler için varsayılandır, çünkü bitirmeden tükenen bir run görev ya da agent hakkında bir şey söylemiştir ve doğru okuyucu bir insandır.

Sor. Etki bütçeleri için karar, yukarıdaki gibi `needs_approval`'dır. Run kararı bekler ve sınırlı bir istek üzerine bir kişinin verdiği karar kontroldür.

Bekle. Agent, tenant ve global seviyelerdeki rate tarzı bütçeler için run'ın başarısız olması gerekmez. Bir checkpoint'te, yani son step sınırında bekler ve pencere sıfırlandığında resume eder. Bölüm 10'un state'lerinde run `running` kalır ve hiçbir lease tutmaz; run kaydında bir `resume_condition` (sıfırlanan bir pencere ya da kapanan bir breaker) taşır. Mutabakat taraması, bu alan ayarlıyken ve run'ın deadline'ı geçmemişken, lease'i dolmuş bir `running` run'ı atlar; böylece park edilmiş bir run çökmüş sanılıp yeniden başlatılmaz. Bu, düşük öncelikli bir alarmin tetiklediği bir inceleme gibi bekleyebilecek işlere uyar; bir müşterinin ya da Robin'in izlediği bir deadline'ı olan iş hand-off yapılmalıdır.

Düşür. Sistem, belirtilmiş, azaltılmış bir davranışa girer: tool'suz cevaplar, bir insanın göndereceği taslaklar, salt okunur inceleme. Degraded mode'un her seviyesinin neyi içerdiği Bölüm 14'ün konusudur; bu bölümde bir bütçe birine bağlanabilir, böylece bir bağımlılığın tool çağrısı bütçesini tüketmek, run'ı ona ihtiyaç duymayan cevaplara, sınırlama belirtilerek taşır.

Hand-off özeti bütçeye ihtiyaç duymamalıdır

Hand-off özeti yazmanın bariz yolu modele sormaktır ve o çağrı, tükenmiş olan token'lara mal olur. Ekipler o zaman ya çağrının bütçeyi aşmasına izin verir, ki bu bütçeyi isteğe bağlı yapar, ya da özeti atlar, ki bu Sam'e açıklamasız bir ticket verir.


Özeti run store'dan, kodla oluştururdum. Kaydın zaten tuttuğu olguları listeler: ticket, hangi bütçenin hangi seviyede devreye girdiği, atılan step'ler, uygulanan etkiler ve durumları, sonucu olmayan intent'ler, son gözlem ve yapılmayanlar. İçindeki hiçbir şey üretilmez, dolayısıyla hiçbir şey dayanaksız bir iddia (F3) olamaz ve model bütçesine karşı hiçbir şeye mal olmaz. Modelden bir anlatı, olguların altına, modelin yazdığı diye etiketlenmiş olarak, küçük bir rezervden (diyelim normal yolun harcamadığı run token'larının birkaç yüzdesi) eklenebilir.

Bütçeler sabit bir noktada denetlenir. Kontrol step sınırında, bir sonraki step başlamadan önce yapılır ve bir intent ile etkisi arasında asla yapılmaz. `record(run, "intent", ...)`'ten sonra ve sonuçtan önce durdurulan bir run, Bölüm 10'un orchestrator'a bulup çözmeyi öğrettiği çözülmemiş intent'i bırakır. Geri alınamaz bir yazmanın ortasında bir run'ı kesen bir bütçe, F9'u önlemeye çalışmanın yan etkisi olarak F6 (sessiz kısmi hata) yaratır.

Bağımlılıklar için circuit breaker'lar

Circuit breaker, başarısız olan bir şeye yapılan çağrılarını retry etmek yerine bir süre durdurur. Tetikleyicisi bir run'ın tüketimi değil, bir bağımlılığın sağlığıdır: her biri kendi bütçesi içinde olan bin run, yine de cevap veremeyen bir servise bin çağrı gönderebilir.

Örüntü, dağıtık sistemlerdeki standart olandır ve tool çağrılarının arkasındaki servislere (`payments-service`, `orders-service`, ticket sistemi), gateway'in arkasındaki model sağlayıcıya ve Bölüm 8'deki MCP server'lara uygulanır.



Breaker açıkken çağrılar bilinen bir reason ile anında başarısız olur ve birkaç probe onun ne zaman kapanacağına karar verir. Eşiğin bir anlam taşımaması için yeterli hacme ihtiyacı vardır.

Neyin hata sayıldığı

Yalnızca bağımlılık hataları sayılır: timeout'lar, bağlantı hataları ve Bölüm 6'nın tablosundaki `upstream_unavailable`. Bir `outcome_unknown` da sayılır; her retry'dan önce durumu denetleme yükümlülüğüyle birlikte.

Retler sayılmaz. `invalid_arguments`, `precondition_failed`, `not_permitted` ve `approval_required` servisi değil, öneriyi tanımlar. Bir dakikada elli bozuk öneri, `orders-service`'in çöktüğüne dair bir kanıt değildir ve onlar üzerine açılan bir breaker, sağlıklı bir bağımlılığı diğer her run için devre dışı bırakırdı. O sinyaller, sonraki başlıktaki agent seviyesi breaker'a aittir.

Devreye girme kuralı bir asgari hacme ihtiyaç duyar: iki hatalı üç çağrı üçte ikilik bir orandır ve bilgi değildir. Diyelim ki 60 saniyelik bir pencerede en az 20 çağrı olmak üzere çağrılarının en az yarısı başarısız

olduğunda devreye girsin. Sayılar varsayımsaldır; korunacak kısım biçimdir (bir oran, bir hacim tabanı, bir cool-down).


Breaker'lar nerede yaşar ve probe'lar ne olmalı

Bir breaker'ın state'i bir bağımlılık hakkındadır, bu yüzden o bağımlılığı kullanan bütün run'lar tarafından paylaşılır, run başına tutulmaz. Tool bağımlılıkları için tool gateway'de, sağlayıcılar için model gateway'de yaşar. Replica başına state ek bir sisteme ihtiyaç duymaz ve biraz farklı zamanlarda açılır; paylaşılan state her yerde aynı anda açılır ve ayakta tutulması gereken bir bağımlılık daha demektir. Replica başına başlar ve kendi olayları farkı gösterdiğinde paylaşılan state'e geçerdim.

Yazma bağımlılıkları için probe'lama özen ister. `payments-service` için `half-open` bir breaker'ın deneme çağrısı bir `issue_refund` olmamalıdır: probe bir okumadır, bir durum endpoint'i ya da aynı servise karşı bir okuma tool'u; çünkü geri alınamaz bir yazma bir sağlık kontrolü değildir. Probe sayısı küçük ve sabittir; böylece toparlanan bir servis bütün birikimle vurulmaz.

Açık bir breaker bir run'a ne yapar

Açık bir breaker, bir gate retinden farklı türde bir rettir. Öneri hakkında bir beyan değildir; dünya hakkında bir beyandır ve modele kendi reason'ıyla, örneğin breaker'ın açık olduğunu ve bir sonraki probe'un ne zaman olduğunu söyleyen `details` ile `upstream_unavailable` gibi, bir gözlem olarak ulaşmalıdır. Sonrasında ne olacağı çağrının etki sınıfına bağlıdır; diyagramın hiçbir dalı "yine de retry et" ile bitmez.



Bir **okuma** için hızlı başarısızlık cevabın tamamıdır: model başka bir kaynak kullanır ya da denetleyemediğini belirtir. Başarısız bir okumaya bağlı bir cevap, onun sonucunu belirtmemelidir (F3) ve Bölüm 2'deki iddia kontrolü bunu uygular.

Geri alınabilir bir yazma için intent, bir son kullanma süresiyle run state'inde park edilebilir ve breaker kapandığında uygulanabilir. Run resume ettiğinde gate çağrısı güncel dünyaya karşı yeniden değerlendirir, çünkü öneriyi üreten bağlam artık daha eskidir (F5.2, bayat bağlam).

Geri alınamaz bir yazma için queue'ya almazdım: bir saat bekleyen bir iade, bakiyesi ve sahipliği değişmiş olabilecek bir iadedir. Run özetle hand-off yapar ve Sam, bağımlılığın durumu görünür halde karar verir. İstisna, zaten geçerli bir onayı ve bir idempotency key'i olan bir çağrıdır: breaker kapandıktan sonra retry edilebilir, çünkü tekrar yapısal olarak güvenlidir (Bölüm 6).

Kullanılmayan bir ticket sistemine karşı `send_customer_reply` gibi bir **dış yan etki** için park etmek makuldür. Onaylanmış metin bir hash'e bağlıdır ve bir idempotency key taşır; böylece onu sonra göndermek aynı eylemdir ve ön koşullar resume'da yeniden denetlenir: müşteri yeniden yazdıysa yanıt artık uymayabilir.

Model sağlayıcı

Model sağlayıcı, her run'ın her step'te ihtiyaç duyduğu bir bağımlılıktır. Breaker'ı açıldığında hiçbir run bir şey öneremez, bu yüzden orchestrator run'ları başarısız kılmak yerine step sınırında, checkpoint'lerle park eder. İkinci bir sağlayıcının devralıp devralmayacağı Bölüm 14'ün fallback sorusudur.

Yeni işin de bir sınıra ihtiyacı var. Sınırsız bir queue bir kesintiyi, daha sonraki, görülmesi daha zor bir gecikme patlamasına (F9) çevirir; bu yüzden queue'yu uzunluğa ve yaşa göre sınırlardım. Kabul edilemeyen iş başladığı yerde kalır: ticket, agent var olmadan önceki gibi Sam'in ekibinin normal queue'sunda durur. Bu insan süreci, destek agent'ı için gerçek degraded mode'dur ve bu yolun her zaman var olacak şekilde tasarlanması değerlidir.

Agent'ın kendisi için circuit breaker'lar

Bağımlılık breaker'ları dünyayı izler, ama bazı hataları hiçbir bağımlılık bildirmez. Yeni bir prompt sürümü, gateway'in arkasındaki bir model değişikliği, değişmiş bir tool açıklaması ya da zehirlenmiş bir girdi, davranışı hiçbir tekil kontrolün yakalamadığı biçimlerde kaydırabilir: her öneriye izin verilmiş olabilir ve örüntü yine yanlış olabilir. **Agent seviyesi breaker**, küçük sayılarda normal olan şeylerin oranlarını izler.

Sinyal	Bir artış neyi gösterebilir	Kaynak
Gate ret oranı	Önerilerin sözleşmelerin dışına kayması: F1, F2 ya da çağrıları yönlendiren içerik (F4)	Kayıttaki gate kararları
Onay ret oranı	İnsanların agent'ın önerdiğini reddetmesi: öneriler öncekinden daha kötü	Approval service
Tekrarlanan aynı hatalar	Run başı kontrollerin yalnızca her seferinde bir run'da gördüğü bir döngü (F5)	Run'lar arası tool sonuçları

Sinyal	Bir artış neyi gösterebilir	Kaynak
Etki hacmi	O saat için baseline'dan daha fazla iade, flag değişikliği ya da yanıt	Tool gateway
Bütçe aşımı ve hand-off oranı	Artık bütçelerine sığmayan görevler	Orchestrator
Harcama oranı	Run başına maliyette bir değişiklik	Sayaçlar

Breaker nedeni bilmez ve denemeye de çalışmamalıdır: belirtiyeye göre davranır; bir SRE'ye hata oranı alarmında alarm gönderilip teşhisin sonra konması gibi.

Sinyaller, bir baseline'a karşı oranlardır; baseline, aynı agent sürümü için kendi kaydından (Bölüm 20), işin haftalık biçimini içerecek kadar uzun bir dönem üzerinden alınır. Bir prompt, model, tool sözleşmesi ya da politika değişikliği yeni bir baseline başlatır; dolayısıyla herhangi bir değişikliğin ardından gelen ilk dönem daha yakın izlemeyi hak eder. Hacim tabanı olmayan bir breaker, sessiz bir gecede, üçü tuhaf on ticket bir anomali gibi görüldüğünde devreye girer.


```
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)
```

Açık bir agent breaker ne yapar

Agent seviyesi bir breaker'ın kipleri vardır ve kipler bir merdivendir. İlk basamak **observe**'dür: breaker devreye girecek olduğunu kaydeder ve kimseye alarm göndermez; eşikler böyle ayarlanır. Hiçbir state

değiştirmez, bu yüzden aşağıdaki diyagram onu dışarıda bırakır. İkincisi **restricted**'dir: agent okumaya ve taslak hazırlamaya devam eder, ama okumanın üzerindeki her etki reddedilir ya da `needs_approval` olur ve bir etki gerektiren run'lar özetleriyle hand-off yapar. Bu salt okunur kiptir ve otomatik yolun ayarlayabileceği en fazlasıdır. Üçüncüsü **stopped**'dir: yeni run yok ve devam eden run'lar bir sonraki step sınırında bekler. Bu kill switch'tir ve onu yalnızca bir kişi ayarlar.

Otomatik ve manuel geçişler arasındaki ayrım tasarım kararıdır. Diyagramdaki eksik oka dikkat etmek gerekir: hiçbir şey **restricted** ya da **stopped**'dan kendiliğinden **closed**'a dönmez.



Bir bağımlılık breaker'ı kendiliğinden kapanır, çünkü bir probe bağımlılığın toparlandığını gösterebilir. Bir agent'ın probe'u yoktur: bir deneme çağrısının döndürdüğü hiçbir şey davranışın normale döndüğünü söylemez ve bir zamanlayıcı nedenin bulunup bulunmadığı hakkında hiçbir şey bilmez. Bu yüzden agent breaker'ı otomatik olarak açılır ve bir

kişinin kararıyla, kimin ve neden olduğu kaydedilerek kapanır; alternatif, kendi anomalisini her cool-down döneminde yeniden deneyen bir sistemdir.

Kill switch

Kill switch, aynı mekanizmanın manuel ucudur ve tasarım özelliklerini listelemeye değer, çünkü en kötü günde kullanılan kontroldür.

- **Agent'in dışında yaşar.** Orchestrator'ın ve tool gateway'in okuduğu bir store'daki bir flag'dir ve ne model ne de herhangi bir tool onu yazabilir. Hiçbir agent'ın tool listesinde değildir ve agent'ın credential'ları ona ulaşmaz (Bölüm 7).
- **İki yerde denetlenir.** Orchestrator onu her step'ten önce, tool gateway her etkiden önce denetler. Birindeki bir bug diğerini bırakır ve flag değişmeden önce başlamış, uçuştaki bir çağrı, henüz etkisini göstermediyse gateway'de yine durdurulur.
- **Kapsamları vardır.** Bütün agent için bir switch kör bir araçtır. Tool başına (`issue_refund`'ı durdur ve `lookup_order`'ı bırak), etki sınıfı, tenant ya da agent sürümü başına bir switch en sık kullanılandır, çünkü sistemin geri kalanı çalışmaya devam eder.
- **Neyin başarısız olduğuna bağlı değildir.** Gerekli olduğu gün sorun model gateway, approval service ya da trace pipeline'ı olabilir. Switch'i çeviren ve okuyan yollar hiçbirine bağlı değildir ve flag store'una erişilemiyorsa okuyucu kısa bir süre son bilinen değeri kullanır ve sonra etkileri reddeder (hata durumunda reddetmek).
- **Adı konmuş operatörleri vardır.** Runbook her agent için onu kimin çevirebileceğini söyler: diyelim `support-agent` için Sam ya da Alex, `ops-agent` için Robin ya da Alex. Yetkilendirmek için bir toplantı gerektiren bir switch olaydan yavaştır.
- **Denenir.** Hiç çevrilmemiş bir switch bir hipotezdir. Bölüm 23 tatbikatı ele alır ve Bölüm 21, çevrilmiş bir flag'in gate'in döndürdüğünü değiştirdiğine dair kontroller içerebilir.

Uçuştaki run'lar, checkpoint'leri bozulmadan bir sonraki step sınırında bekler; böylece bir sıfırlama onları resume edebilir. Orchestrator önce, Bölüm 10'un anlattığı gibi servisin durumunu denetleyerek her açık

intent'i çözer; böylece durdurmak `payments-service`'te yanıtsız bir iade ve `done` işaretlenmiş bir run bırakmaz (F6).

Eşikleri belirlemek ve yanlış alarmın bedeli

Agent'lar için doğru limitleri bilmiyorum ve onları çalışırken izlemeden kimse söyleyemez; yöntem sayılardan daha önemlidir.

Her eşığe observe kipinde başlamak gerekir: bütçeler için sayaçlar çalışır ve aşım olayları kaydedilir, breaker değerlendirmesi ne yapacağını kaydeder ve hiçbir şey durmaz. Haftalık ritmi kapsayacak kadar uzun bir dönemden sonra kendi dağılımı vardır: eval'lere (Bölüm 21) ve insan reviewer'ların yaptıklarına göre iyi biten run'lar için step'ler, token'lar ve aktif süre. Bir run limitini meşru kuyruğun üzerine koymak gerekir; böylece limit kontrolden çıkanları keser, yavaş ama doğru olanları değil. Ortalamadan belirlenen bir bütçe bir hand-off üreticisidir.

Maliyetler asimetriktir. Bir token bütçesindeki yanlış alarm bir hand-off'a ve biraz kısmi işe mal olur, bir kaçırma para ve gecikmeye mal olur. Bir etki bütçesindeki yanlış alarm bir onay isteğine mal olur, bir kaçırma da kimsenin karar vermediği hareket etmiş paraya. Dolayısıyla etki bütçeleri daha sıkı, token bütçeleri daha gevşek belirlenir ve bunu politika dosyasında, sayıların yanında söyledim.

Eşiklerin yanlış olduğunu gösteren sinyaller kayıttadır. Bir insan bir bütçeyi aşan run'ları agent'ın vardığı cevapla birkaç dakikada bitiriyorsa, limit çok düşüktür. Breaker haftalık açılıyor ve kimse harekete geçmiyorsa susturulacaktır. Bir breaker sürekli açılıp kapanıyorsa pencere çok kısıdır ya da cool-down çok kısıdır ve histerezis (kapanmak için açılmaktan daha yüksek bir çıta) genellikle farklı bir sayıdan daha çok yardımcı olur.

Her alarmın bir sahibi ve runbook'ta bir ilk eylemi olmalıdır; ilk kontrolü olmayan "agent breaker open" yazan bir alarm, alıcıya alarmı kabul edip beklemeyi öğretir. Restricted bir agent için ilk eylem genellikle onu tetikleyen sinyale ve agent'ın son bir gündeki değişikliklerine bakmaktır; bu da ancak değişiklik geçmişi varsa işe yarar (Bölüm 20 ve Bölüm 23).

Açılış senaryosunu kontrollerden geçirmek

Kontroller yerindeyken (açıklayıcı), model gateway breaker'ı yavaş sağlayıcı üzerinde açılır ve orchestrator uçustaki run'ları step sınırında park eder; böylece üzerine hiçbir retry yığılmaz ve run'lar resume edebilir. Yeni ticket'lar ticket sisteminde kalır ve Sam'in ekibi onları eskisi gibi ele alır.

payments-service için tool gateway breaker'ı durum okumalarıyla probe eder ve issue_refund gerektiren run'lar bir özetle hand-off yapar. Alarm fırtınası konu ve agent seviyeleriyle karşılaşır: kırk alarm sınırlı sayıda run'a dönüşür. Yeniden başlatılan bir run sayaçlarını korur. Öğlene kadar harcama baseline'ın çok üzerindedir, agent breaker restricted'a geçer, etkiler onay ya da hand-off gerektirir ve bir kişiye alarm gönderilir.

Bu kontrollerin hiçbiri sağlayıcıyı daha hızlı ya da ödeme servisini daha sağlıklı yapmaz. Kesintinin neye mal olduğunu değiştirirler.

Trade-off'lar ve maliyetler

Her limit, gerçekleşmeyi bekleyen bir hand-off'tur. Devreye giren bir bütçe, bitirebilecek bir run'ı sonlandırır ve işi bir kişi devralır. Bu, sınırsız bir run'a karşı doğru bir takastır ve limit bir tahminse kötü bir takastır; observe kipinin önce gelmesinin nedeni budur.

State ve ayakta tutulacak yeni bir şey. Sayaçlar ve breaker state'i, gecikmesi, hataları ve kesintileri olan production sistemleridir ve rezerve-et-ve-kapat her model çağrısından ve her etkiden önce bir çağrı ekler. Bir sayaç store'u kesintisi bir platform kesintisine dönüşmemelidir, bu yüzden varsayılan önceden seçilir: etkiler için hata durumunda reddetmek, okumalar için run'ın kendi limitiyle sınırlı.

Beş seviye, review edilecek beş şeydir. Ekip küçükse, bir run seviyesi ve bir global seviye, etki bütçeleri tool gateway'de olmak üzere, değer in çoğunu kapsar. Diğerlerini, bir olay ya da veri tek tek iyi olan run'ların toplanıp bir probleme dönüştüğünü gösterdiğinde eklemek gerekir.

Breaker'lar problemleri içerdği kadar saklar da. Her devreye girme, bağımlılığın sahibi için bir sinyaldir.

Agent breaker'ı bir baseline'a ihtiyaç duyar. Yeni bir agent ya da sürüm için ilk dönem observe kipidir ve koruma bütçelerden ve onaylardan gelir. O boşluğun adını koymak gerekir.

Bunu ne zaman kullanmamalı. Zaten bir breaker'ı olan bir mesh ya da client library'nin arkasındaki bir bağımlılığın ikincisine ihtiyacı yoktur; başka hiçbir şeyin sağlamadığı agent seviyesi sinyalleri ve etki bütçesini eklemek gerekir. Tek kullanıcı, kısa ömürlü, salt okunur bir prototip bir step sınırına ve bir zaman sınırına ihtiyaç duyar. Etki bütçesi, bir etki para hareket ettirebildiğinde ya da production'ı değiştirebildiğinde gerekir ve kill switch, bir ekran başındaki kişiden başka bir şey buna neden olabildiğinde.

Sık yapılan hatalar

- **Limiti prompt'a koymak.** Bir satırdır ve model genellikle uyar. Satırı bir yardımcı olarak tutmak ve orchestrator'a ne olursa olsun fırlatan bir sayaç eklemek gerekir.
- **Yalnızca run başına limitler.** Her run hakkında tek başına akıl yürütmek kolaydır ve her dashboard yeşil kalır. Her run limiti içindedir ve toplam olaydır. Run'ların toplandığı seviyeleri eklemek gerekir.
- **Resume'da sayaçları sıfırlamak.** Taze bir run nesnesi, bir çökmeden ya da onay beklemesinden sonra yeniden başlamanın en basit yoludur. Sayaçları bir çökme ya da onay beklemesi boyunca run kaydında taşımak gerekir.
- **Her hatayı breaker'a saymak.** Tek bir hata sayacı kurması basittir. Yalnızca bağımlılık hatalarını saymak ve retleri agent breaker'a göndermek gerekir.
- **Bir agent breaker'ı zamanlayıcıyla kapatmak.** Bağımlılık breaker'ları bunu yapar, bu yüzden tutarlı hissettirir. Davranış için probe yoktur. Onu bir kişi, kaydedilmiş bir reason ile kapatır.

Temel çıkarımlar

- Bütçe, bir birimi, ölçüldüğü bir yeri ve tükendiğinde tanımlı bir davranışı olan bir limittir ve ancak harcayan kod yolu önce ona

sormak zorundaysa kontrol sayılır.

- Step sınırı en dar sınırdır; tool çağrılar, token'lar, aktif zaman, harcama ve kümülatif etki için bütçeler de gerekir ve etki bütçesi, çağrı başına tavan ile toplam arasındaki boşluğu kapatır.
- Bütçeleri tüketimin toplandığı yerlerde katmanlamak (run, konu, agent, tenant, global), her birini atlanamayacak en dar noktada uygulamak ve run sayaçlarını run kaydında tutmak gerekir; böylece resume onları sıfırlamaz.
- Bir bütçe tükendiğinde, run'ın durup hand-off yapıp yapmayacağına, onay isteyip istemeyeceğine, bekleyip beklemeyeceğine ya da düşüp düşmeyeceğine önceden karar vermek ve hand-off özetini run store'dan oluşturmak gerekir; böylece az önce harcanan bütçeye bağımlı olmasın.
- Circuit breaker bir bağımlılığın sağlığını izler, yalnızca bağımlılık hatalarını sayar, yazma bağımlılıklarını okumalarla probe eder ve açık durumu, yine de retry etmek yerine her etki sınıfı için farklı ele alır.
- Agent seviyesi breaker, bir baseline'a karşı oranları izler, devreye girdiğinde etkileri kısıtlar ve yalnızca bir kişi tarafından kapatılır; kill switch onun manuel ucudur, agent'ın dışında tutulur ve denir.
- Eşikler observe kipinde başlar ve kendi kaydından gelir; yanlış alarmin bedeli, bir hand-off ya da bir onay, sayının parçasıdır.

Buradaki kontroller bir run'ı ve başarısız olan bir bağımlılığa giden trafiği durdurur ve bir çağrı bir dahaki sefere başarısız olduğunda ne yapılacağı hakkında çok az şey söyler. Bölüm 14 bunu ele alıyor: hangi hataların retry'ı hak ettiği, retry'ların yukarıdaki bütçelerin içinde nasıl tutulduğu ve birincil yol kullanılamadığında fallback merdiveninin neye benzediği.

Bölüm 14 — Retry'lar ve Fallback'ler

Parcelport'ta bir cuma akşamı, hafta sonu vardiya değişiminden bir saat önce. Bir müşteri hasarlı bir koli için iade istiyor ve destek agent'ı sipariş için `issue_refund` öneriyor. Ödeme servisi transferi başlatıyor, ardından yanıtı timeout'a düşüyor. Orchestrator başarısız bir çağrı görüyor ve yeniden deniyor; retry çağrısı yeni bir key'le baştan kuruyor. Müşteriye iki kez iade yapılıyor ve run'ın log'unda bir başarı ile bir hata görünüyor.

Retry yalnız da değildi. Orchestrator'ın içindeki client kütüphanesi çağrısı üç kez denemişti, orchestrator bunu kendi üçlük döngüsüne sarmıştı ve run runner başarısız run'ı üç kez daha yeniden başlatmıştı. Katman başına üç denemeyle, yavaş tek bir bağımlılık 27'ye kadar çağrıya dönüşüyor; her biri olası bir ikinci iade ve hepsi aynı run'ın hesabına yazılıyor.

Bu hikâyede modelin yanlış olması gerekmedi: bir bağımlılık yavaştı ve tasarım buna daha fazla yük ve daha fazla yazmayla karşılık verdi. Bu bölüm kontrol zarfının **Sınır** parçasına ait; Sınır, döngünün nerede durduğunu ve çalıştırmanın neye mal olduğunu sorar. Bir retry, aynı yolun kaç kez denenebileceğine karar verir; bir fallback ise bu yetmediğinde hangi yola gidileceğine. İkisi de tasarlanmalıdır, çünkü ikisi de bütçe harcar ve küçük bir hatayı büyük bir hataya çevirebilir.

Sorun ve neden zor olduğu

"Retry" tek bir şey gibi duruyor ama en az dördtür. Bir bağımlılığa yapılan çağrı, ağ onu düşürdüğü için, bağımlılık aşırı yüklendiği ve bunu söylediği için, bağımlılık onu esastan reddettiği için ya da arayan beklemeyi bıraktığı ve ne olduğunu bilmediği için başarısız olabilir. Bir model çağrısı bunların hepsiyle ve beşincisiyle de başarısız olabilir: çağrı başarılı olur ama öneri yanlıştır. Bu durumlar farklı karşılıklar ister ve birine verilen karşılık, ötekine uygulandığında zararlıdır. Reddedilmiş bir çağrısı

tekrarlamak para israf eder; sonucu bilinmeyen bir yazmayı tekrarlamak parayı iki kez hareket ettirebilir; kendinden emin biçimde yanlış çıkan bir model çağrısını tekrarlamak aynı yanlış öneriyi yine üretebilir.

Bölüm 3'ün taksonomisinden birkaç sınıf işin içinde. Bir retry fırtınası F9'dur (maliyet ya da gecikme patlaması): run doğrudur, ama yarattığı yük doğru değildir. Zaman aşımından sonra tekrarlanan bir yazma, ilk deneme yerine ulaşmış ve kayıt bunu söylemiyorsa F6'dır (sessiz kısmı hata). Bir sınır durdurana kadar modele aynı soruyu aynı bağlamla yeniden soran bir döngü F5'tir (kontrolden çıkan döngü ya da bayat bağlam). F1 (bozuk çıktı), F2 (yanlış tool ya da yanlış argümanlar) veya F3 (dayanaksız iddia) için onarım olarak "yine sor"un da kolayca gözden kaçan sınırları vardır; çünkü ikinci bir örnek bazen işe yarar ve başarılar akılda kalır.

Bariz yaklaşım, üstel backoff'lu ve deneme sınırlı genel bir retry yardımcısı ile bir yedek modeldir. Bu, durumsuz bir servise yapılan okumada işe yarar ve burada önemli olan yerde başarısız olur. Yardımcı çağrının etki sınıfını bilmez, bu yüzden yazmaları okumalar gibi tekrarlar. Üstteki katmanın da tekrarladığını bilmez. Run'ın bütçesinden düşmez; bu yüzden 15 step ile sınırlanmış bir run, her biri üç denemelik 15 step yapabilir. Yedek model de kimsenin değerlendirmedeği ikinci bir konfigürasyondur: dikkatin en düşük olduğu anda devreye girer ve kontrol sisteminin hiç ayarlanmadığı öneriler üretir.

Hiçbir şeyi tekrarlamadan önce hatayı sınıflandırmak

İlk kontrol bir sınıflandırmadır: herhangi bir tekrardan önce orchestrator, kodun zaten elinde olan verilerden, yani hata kodundan, retryable bayrağından, tool'un etki sınıfından ve çağrının hedefine ulaşmış olup olamayacağından hareketle bunun hangi tür hata olduğuna karar verir. Model buna katılmaz. Bölüm 6'nın kapalı hata sözlüğü sınıflandırmayı mekanik hale getirir ve tablo bir "kim tekrarlar" sütunu ekler; çünkü geçici bir bağımlılık hatasının ve reddedilmiş bir önerinin cevapları farklıdır.

Hata türü	Örnek	Aynı çağrı tekrar mı?	Kim tekrarlar
Geçici bağımlılık hatası	Bir rate limit yanıtı, connection refused, <code>upstream_unavailable</code>	Evet; yazma yalnızca aynı idempotency key'le, bir gecikmeden sonra	Orchestrator
Geçici okuma hatası	<code>lookup_order</code> üzerinde bir timeout	Evet, sınırlı	Orchestrator
Bir yazmanın sonucu bilinmiyor	<code>issue_refund</code> üzerinde bir timeout, <code>outcome_unknown</code>	Hayır, önce state'in sahibine sor	Durum sorgusu, sonra belki orchestrator
Model önerisi reddedildi	<code>invalid_arguments</code> , <code>precondition_failed</code>	Aynı çağrı değil; yeni bir öneri	Model, sayılan bir düzeltme turunda
Kalıcı	<code>not_permitted</code> , <code>result_invalid</code>	Hayır	Kimse; kaydet ve hand-off'a geç
Onay eksik ya da bayat	<code>approval_required</code>	Olduğu gibi değil	Kimse retry etmez; onay yoluna geri (Bölüm 15)
Yinelenen	<code>duplicate_replayed</code>	Tekrarlanacak bir şey yok	İlk sonuçtan devam etmek gerekir

İki satır vurguyu hak ediyor. Birincisi, "geçici" bağımlılık hakkında bir iddiadır ve yalnızca bir tekrar iki kez etki edemiyorsa kullanılabilir: çağrı kanıtlanabilir biçimde etki etmemiştir ya da retry aynı idempotency key'i taşır, böylece tool ilk sonucu yeniden oynatabilir. Bir rate limit yanıtı, bağımlılığın "bunu işlemedim" demesidir. Bir `upstream_unavailable` yanıtı daha zayıftır, çünkü bir sunucu hatası iş yapıldıktan sonra da gelebilir. Bir timeout ise arayanın "beklemeyi bıraktım" demesidir ve bu, bağımlılık hakkında hiçbir şey söylemez. Bir okuma için bu fark önemli değildir; bir yazma için bütün farkı oluşturur (Bölüm 5): bir yazma üzerindeki timeout bir hata değil, sonucu bilinmeyen bir durumdur.

İkincisi, `approval_required`'ın kendine ait bir satırı var. Bölüm 6 bu kodu bir kusur göstergesi yaptı: bir çağrı bir tool'a geçerli bir onay olmadan ya da bayat bir onayla ulaştı. Bunu geçici sayan bir retry döngüsü, doğru çalışan bir gate'i döver; çağrı gate'ten ve Bölüm 15'in onay yolundan geri geçer.


```

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

```

Son satır, Bölüm 6'nın temkinli varsayılanıdır: bilinmeyen bir kod bir tahmin değil, bir durdurma ve hand-off'tur; çünkü kapalı kalmak yerine açık kalan bir tablo, yeni bir tool'daki her yeni hatayı olası bir retry döngüsüne çevirir.

Retry güvenliği etki sınıfını izler

Etki sınıfı, bir tekrara izin verilip verilmediğinin çoğunu söyler; önemli olan sütun, sonuç bilinmediğinde ne olduğudur.

Etki sınıfı	Etki etmeden önce reddedildikten sonra	Bir timeout ya da bilinmeyen sonuçtan sonra	Her deneme neyi yeniden kullanır
okuma	Retry, sınırlı	Retry, sınırlı	Hiçbir şey gerekmez; yeniden okuma daha yeni veri döndürebilir
geri alınabilir yazma	Aynı key'le retry	Durumu sorgula; yalnızca "uygulanmadı" ise retry	Key, argümanlar
geri alınamaz yazma	Aynı key'le retry	Durumu sorgula; yanıt veremiyorsa hand-off	Key, argümanlar

Etki sınıfı	Etki etmeden önce reddedildikten sonra	Bir timeout ya da bilinmeyen sonuçtan sonra	Her deneme neyi yeniden kullanır
dış yan etki	Aynı key'le retry	Ticket sistemini sorgula; yanıt veremiyorsa hand-off	Key, tam metin

Tablonun altında iki ayrıntı var. "Key'i yeniden kullanır" kelimenin tam anlamıyla böyledir: çağrıyı baştan kuran bir retry, Bölüm 6'nın tanımladığı key'i, runtime tarafından atanan tanımlayıcılardan yeniden kurmalıdır. Her denemede yeni bir key üreten bir retry, güvenliğin biçimine sahiptir ama özüne değil; çünkü tool her seferinde yeni bir çağrı görür.

Ayrıca key bir son çaredir, plan ise durum sorgusudur (Bölüm 5 ve 10). Key yalnızca tool onu saklayıp dikkate alıyorsa işe yarar; durum sorgusu hangi dünyada olunduğunu söyler. Bir key'i dikkate alamayan tool, agent'a geri alınamaz yazma olarak verilmez (Bölüm 6). Tam sözleşmesi Bölüm 15'te olan `send_customer_reply` için de kural aynıdır: ticket sistemi timeout'a düşerse orchestrator yanıtın gönderilip gönderilmediğini sorar ve bir tahmin üzerine yeniden göndermez.

Uyarı: Timeout'a düşen ve durum sorgusu olmadan ya da yeni üretilmiş bir key'le retry edilen bir yazma, parayı iki kez hareket ettirebilir ya da bir müşteriye iki kez mesaj gönderebilir. Bölümde "asla" diyeceğim tek yer burası: yanılmanın bedeli geri alınamaz.

Kodda retry'lar

Tabloyu izleyen bir retry yardımcısı kısadır ve ayrıntılar, yapmayı reddettiği şeylerdedir. Blok, zaten izin verilmiş bir çağrının etkisini sarar; buna daha önce gate karar verdi ve bir retry soruyu yeniden açmaz.

```

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

```

Her deneme başarısız olursa döngü, hangisi önce gelirse, deneme sınırında ya da deadline'da biter ve son sonuçla `give_up` döndürür; ardından çağırın bir fallback'e geçer. Döngü hiçbir zaman "denemeye devam et" döndürmez. Bütçe tükenirse `BoundExceeded`, `runAgent`'a yayılır; o da Bölüm 1'in kanonik döngüsündeki gibi hand-off yapar. Intent önce `not_applied` olarak kapatılır, çünkü bir yazma retry dalına yalnızca etki etmeden önce reddedildikten sonra ulaşır (bir okumanın kapatılacak intent'i yoktur) ve açık bir intent'le yapılan hand-off, bir kişiyi zaten bilinen bir şeyi çözmeye gönderirdi. Her deneme bir kayıt bırakır, böylece on-call bir retry'yı yavaş bir bağımlılıktan ayırt edebilir.

Intent kaydı bu yardımcının dışında kalır: Bölüm 5'in `executeCall`'ı onu ilk denemeden önce bir kez kaydeder ve retry'lar o tek intent'in denemeleridir. Deneme başına yeni bir intent, bir recovery sweep'in hedefe hangisini soracağını ayırt edememesine yol açar.

Backoff ve jitter

Denemeler arasındaki gecikme, bağımlılığa toparlanması için zaman tanır, ki bunu üstel büyüme yapar; ve arayanların birlikte retry etmesini önler, ki bunu rastgelelik yapar: 200 run aynı anda başarısız olduysa ve hepsi tam bir saniye bekliyorsa, hepsi aynı anda yine gelir.

```
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
```

Full jitter'ı, yani sıfırla tavan arasında rastgele bir gecikmeyi kullanırdım; çünkü arayanları bütün aralığa yayar. Taban ve üst sınır (örneğin yarım saniye ve sekiz saniye) ayarlamak uygulayana kalmış. Bağımlılık ne zaman geri gelmesi gerektiğini söylüyorsa, ipucunu alt sınır olarak kullanmak gerekir; bir saatlik bir ipucu bir run'ı park etmesin diye bir üst sınırla. Ve gecikmeyi bir insana maliyet olarak ele almak gerekir: etkileşimli run'larda deneme sınırı ve deadline, arka plandaki bir araştırmadakinden daha sıkı olmalıdır.

Retry'lar bütçeden harcanır

Bir retry, zaman alan bir tool çağrısıdır ve bir model çağrısı için harcama ile token da demektir. Bu yüzden her retry, ilk deneme gibi aynı bütçelere yazılır (bütçe türleri Bölüm 13'ün konusu) ve sayaç, run store'daki run'ın sınır sayaçlarında yaşar (Bölüm 10); böylece devam ettirilen bir run retry'larına sıfırdan başlamaz. Retry sayısı, teşhis için kendi sayacı olmalıdır: bunların dokuzu retry olan 12 çağrı, bir bağımlılık hakkında bir sinyaldir.

Retry'ları tek bir katman sahiplenir


Açılıştaki senaryo denemeleri katmanlar arasında çarpmıştı. Çözüm bir sayı değil, bir kuraldır: belirli bir çağrı için retry'ı tam olarak bir katman yapar. Bunu orchestrator'a koyardım, çünkü etki sınıfını, bütçeyi ve deadline'ı o bilir. Altındaki client kütüphaneleri sıfır retry ile konfigüre edilir ya da onların retry'ları orchestrator'ınkine dahil sayılır. Bir sağlayıcı çağrısını dahili olarak yeniden deneyen bir model gateway'i için de aynısı geçerlidir. Başarısız run'ları yeniden başlatan bir run runner aynı türden

bir başka katmandır ve bir yeniden başlatma, run'ı baştan oynatmak yerine bir checkpoint'ten (Bölüm 10) devam etmelidir. Tasarım review'unda, her bağımlılığın retry'lerinin nerede yaşadığını yazmak gerekir.

Retry fırtınaları

Bir bağımlılık yavaşladığında retry'lar fazladan yükün en büyük kaynağıdır; kısmi bir kesinti tam bir kesintiye böyle dönüşür. Üç kontrol birlikte çalışır. Birincisi yukarıdaki jitter ve sınırdır. İkincisi filo düzeyinde bir retry bütçesidir: retry'lara yalnızca bir pencere boyunca ilk denemelerin belli bir oranının (örneğin onda biri) altında kaldıkları sürece izin verilir. Bağımlılık başarısız olurken neredeyse her deneme bir retry'dır, oran aşılır ve tek bir run sınırına ulaşmamış olsa bile retry'lar durur. Üçüncüsü circuit breaker'dır (Bölüm 13): açık olduğunda çağrılar gönderilmeden hızla başarısız olur ve retry döngüsü hiç başlamaz.

Açık bir breaker, retry edilecek bir hata değildir; fallback merdiveninin geçiş sinyalıdır. Diyagramda hiçbir yol sayaçsız döngüye girmez ve breaker retry'ları atlayarak yandan girer.



Modelin çıktısı hatanın kendisi olduğunda

Gate'in reddettiği bir öneri döndüren model çağrısı, bir bağımlılık hatasından farklıdır: hiçbir şey kullanılamaz değildi ve öneri yanlıştı. Orchestrator'ın bunun için aracı bir başka model çağrısıdır ve bunun kendi sınırları vardır.

Yeniden sormak yeni bir örnektir, retry değil

Bir retry bir çağrıyı tekrarlar ve toparlanmış bir bağımlılığın eskisi gibi davranmasını bekler. Modele yeniden sormanın böyle bir beklentisi yoktur. Çıktısı bağlama ve örnekleme göre değişir; bu yüzden aynı bağlamla yapılan ikinci bir çağrı farklı bir öneri döndürebilir ve yeniden sormanın bazen işe yaramasının tek nedeni budur. Bir onarım olarak değil, bir çekiliş olarak işler.

Üç sonuç çıkar. Aynı bağlam aynı hatayı yeniden üretebilir; Bölüm 2'nin tutarlılık örnekleme başlığının gösterdiği gibi. Değiştirilmesi yararlı olan şey bağlamdır: kapalı sözlükten bir ret nedeni, bir gözlem olarak eklendiğinde, sonraki önerinin neyden kaçınması gerektiğini söyler ("iade tutarı bu sipariş için geçerli değil"), onu geçirecek sayıyı vermeden. Ve yeniden sormanın sayılması gerekir, çünkü her düzeltme turu bir model çağırısı, bir step ve biraz harcamadır.

Sayılan düzeltme turları

Bölüm 5'in döngüsü bir reddi zaten bir gözlem olarak geri besliyor. Eksik olan, ret'e özgü bir sınırdır: "aynı retten 15 step", step sınırının bunu öğrenmesi için pahalı bir yoldur.

```
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
```

Key, retleri neyin yanlış gittiğine göre gruplar; böylece iki sorun bir sınırı paylaşmaz ve aynı sorun ondan kaçamaz. Hangi reason'ların düzeltilebilir olduğu bir politika sorusudur: `invalid_arguments` genellikle düzeltilebilir, çünkü model eksik bir alanı düzeltebilir; `not_permitted` ise değildir, çünkü izin başka bir denemeye değişmez. Bölüm 12, bir run'ın ilerleme kaydetmemesinin daha geniş tespitini ele alıyor; düzeltme sayacı bunun dar bir örneğidir. Bir iki düzeltme turuyla başladım, çünkü daha fazlası iki kez başarısız olmuş bir öneriyi nadiren kurtarır.

Dayanaksız bir taslağı onarmak

F3 (dayanaksız iddia) farklı bir onarım sorunudur. Bir verifier'ın, bir taslak yanıtta hiçbir tool sonucunun desteklemediği bir cümle bulunduğunu varsayalım: hiçbir `lookup_order` sonucunda geçmeyen bir teslimat tarihi. Modelden taslağı yeniden yazmasını istemek yeni bir örnektir; eski cümleyi çıkarırken yeni dayanaksız cümleler getirebilir. Yanıt parçalardan

kurulduğunda tercihim deterministik bir düzenlemedir: dayanaksız cümleyi çıkarmak ya da yalnızca tool sonuçlarından doldurulan bir şablona dönmek. Sonuç daha az akıcıdır ve doğrulanabilir biçimde dayanaklıdır; müşteriye giden bir mesaj için önemli olan takas budur. Doğrulamanın kendisini Bölüm 2 kurar; dayanaksız bir iddianın onarım yolu kod olmalı, ikinci bir model çağırısı son çare kalmalıdır.


Fallback merdiveni

Retry'lar tükendiğinde ya da bir breaker açık olduğunda run'ın başka bir yola ihtiyacı vardır. Fallback, yararlı bir sonuca ulaşmanın farklı bir yoludur ve yollar, her birinin birincil davranıştan ne kadarını koruduğuna ve sistemden ne kadar güven istediğine göre sıralanan bir merdiven oluşturur.

Basamak	Yol	Korur	Vazgeçer	Giriş koşulu
1	Aynı yolu retry et	Her şeyi	Zamandan	Geçici hata, retry hakkı var
2	Alternatif model ya da sağlayıcı	Tool'ları, planları, taslak yazmayı	Bilinen davranıştan; birincil için ayarlanmış kontrollerden	Birincil model yolu kullanılamıyor; alternatif değerlendirilmiş ve izinli
3	Deterministik yol	Bilinen durumlar için doğruluğu	Kapsamdan; esneklikten	Ticket türünün kodlanmış bir yolu var
4	Cache'lenmiş ya da şablon yanıt	Dayanaklı, güvenli bir yanıtı	Özgüllükten	Gözden geçirilmiş bir şablon ya da yeterince taze bir cache'lenmiş sonuç var
5	Salt okunur mod	Aramaları, özetleri, bir insan için taslakları	Bütün etkilerden	Etkiler kullanılamıyor ya da güvenilmiyor
6	Bir insana hand-off	İnsanın muhakemesini	Otomasyondan	Yukarıdakilerin hiçbirini uygulanmıyor

Sıra tasarımının kendisidir. Bir basamağa yalnızca üstündeki başarısız olduğunda ya da izinli olmadığı girilir ve orchestrator, görebildiği sinyallerden karar verir: hata sınıfları, breaker durumu, bütçe durumu ve alternatifin değerlendirme durumu. Modele hangi basamağın seçileceği sorulmaz. "Degraded mode'dasın, dikkatli ol" diyen bir prompt yalnızca özensiz önerilerin oranını düşürür; kontrol, o basamakta gate'in farklı kurallara sahip olmasıdır.

Retry basamağının altında merdiven yalnızca aşağı iner ve her basamak bir insanda biter. Yukarı geri dönebilecek bir basamak, örneğin bir şablon yanıtıtan sonra birinciyi yeniden deneyen bir basamak, kendi sayacını gerektirirdi ve bunu bir sonraki run'a bıraktırdım. Yine başarısız olan bir retry, bir sayaçla birlikte ilk soruya döner.



Basamak 2: başka bir model ya da sağlayıcı

Çoğu ekip önce bu basamağa uzanır ve ben ona en çok dikkatle yaklaştırdım. İkinci bir model farklı bir bileşendir; bu yüzden birincile karşı ayarlanmış her kontrol (verifier kapsamı, yükseltme eşikleri, beklenen ret

oranları) başka bir şeye karşı ayarlanmıştı. Bölüm 2 bunu doğrudan söyler: bir fallback model bir olay sırasında, dikkatin en düşük olduğu anda devreye girer ve en az test edilen modeldir.

Üç koşul çıkar. Birincisi, alternatifin bir değerlendirme durumu vardır: golden set'i (Bölüm 21) birincilinkinden düşük olabilecek, yazıya geçirilmiş eşiklerle geçmiştir ve bu olmadan merdivende yer almaz. İkincisi, gate değişmez: onun önerileri de birincilinki kadar güvenilmezdir. Üçüncüsü, ve bu bir kural değil bir duruştur, alternatif kullanımdayken gate'i sıkılaştırırdım: eval geçmişi daha fazlasını desteklemedikçe, tavandan bağımsız olarak her geri alınamaz yazma onaya gider. Maliyet gerçektir, çünkü Parcelport hikâyesindeki destek lideri Sam, platformun tam da zorlandığı anda daha fazla istek görür. Yine de bunu, önerilerini kimsenin ölçmediği bir iade yolunun kendi başına davranmasına tercih ederdim.

Birkaç sağlayıcının önündeki ortak bir API, geçişin ifade edilmesini ucuz kılar ve ne zaman güvenli olduğu hakkında hiçbir şey söylemez; bu yüzden alternatifi, eval durumunu ve gate sıkılaştırmasını adlandıran politikayı orchestrator tutar.

Basamak 3: deterministik yol

Bazı ticket'lar hiç model gerektirmez. "Siparişim nerede" bir `lookup_order` çağrısı ve biçimlendirilmiş bir durumdur. Kodlanmış bir yol bunları hiçbir model çağrısı olmadan yanıtlar; böylece model yolu çökse de çalışmaya devam eder, bedeli ise birbiriyle uyumlu kalması gereken, çoğaltılmış durum biçimlendirmesidir. Bunu yalnızca hacmin çoğunu oluşturan birkaç ticket türü için kurardım; bunun ötesi kodla yazılmış ikinci bir agent'tır, bir fallback değil bir projedir.

Basamak 4: cache'lenmiş ya da şablon yanıtlar

Şablon yanıt, boşlukları tool sonuçlarından doldurulan sabit bir metindir: bir alındı bildirimi, güncel teslimat durumu, ticket'ın referansı. Dayanaksız bir iddia içeremez, çünkü iddialar şablondadır, bir kez gözden geçirilmiştir ve boşluklar tool'lardan gelir. Cache'lenmiş sonuç, yanıt ne zaman okunduğunu söylüyorsa, okuma verisi için aynı fikirdir. Risk bayatlıktır

(Bölüm 3'te F5.2, bayat bağlam): politikada her cache'lenmiş öğeye bir azami yaş vermek ve cache'lenmiş bir değeri asla bir yazmanın temeli olarak kullanmamak gerekir.

Basamak 5: salt okunur mod

Salt okunur modda agent okuma tool'larını korur ve geri kalan her şeyi kaybeder: `update_shipping_address` yok, `issue_refund` yok, `send_customer_reply` yok. Run yine siparişe bakabilir, ticket'ı özetleyebilir ve bir kişinin göndermesi için bir taslak hazırlayabilir; ops agent log'ları ve metric'leri okumaya devam edip Robin'e bir özet verebilir. Mod run store'a kaydedilir, böylece bir resume onu unutmaz ve gate tarafından uygulanır: salt okunur olduğu sürece gate, etki sınıfı okuma olmayan her çağrıyı reddeder. "İşlem yapma" diyen bir prompt bir ricadır.

Basamak 6: hand-off

Hand-off her zaman çalışır, çünkü bir insan, model yolunun paylaşmadığı tek bağımlılıktır. Ona sık ulaşan bir merdiven, yukarıdaki basamaklar hakkında bir şey söylüyordur. Hand-off bir özet ve run'ın kaydedilmiş state'ini taşır, böylece kişi baştan başlamaz (`handed_off` durumunu Bölüm 10 ele alır).

Kodda merdiven

Seçim ve ardından gelen state değişikliği:

```

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

```

`enterRung` içindeki yazmaların sırası kasıtlıdır: run store modu önce tutar; böylece bir çökme, sessizce birincile dönen bir run değil, alt basamakta devam eden bir run bırakır. Kaydı ve gate'i kapsayan bir transaction yoktur; süreç `gate.setMode`'dan önce ölürse resume modu run store'dan okur ve onu yeniden çağırır, ki bu tasarım gereği idempotent'tir. Store'u `read_only`, gate'i başka bir şey diyen bir run, alarm kurulacak boşluktur.

Kullanıcıya doğruyu söylemek

Çalışan bir fallback, müşterinin elde ettiği şeyde bir değişikliktir: şablon yanıt, taslağı yazılmış bir yanıtta daha az özgüldür ve salt okunur bir run istenen iadeyi yapmaz. Müşteriye söylenmezse kendi sonuçlarını çıkarır: geç gelen bir yanıtın görmezden gelindiği, eksik bir iadenin reddedildiği varsayılır.

Degraded mode mesajını önceden yazılmış sabit bir şablon olarak yazardım, model tarafından değil. Başarısızlık anında, başarısız olan bileşen tarafından üretilen bir mesaj, kimsenin yerine getiremeyeceği bir

şey vaat etmeye en yatkın olandır ve böyle bir vaat, gerçekleşmeyi bekleyen bir F3'tür. Sabit bir metin de destek lideri tarafından bir kez gözden geçirilebilir; Bölüm 15'in onay tasarımı için kolay bir durum.

```
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."
```

Metin doğru olanı söyler, müşteriye bir referans verir ve yeniden göndermemelerini ister; bu, panik yüzünden doğan yinlemeleri önler. Hiçbir saat belirtmez, çünkü hiçbirine söz verilmemiştir ve bir nedeni ima edecek biçimde özür dilemez. "Destek ekibimizden biri inceleyecek" yalnızca hand-off varsa doğrudur; bu bir sıra meselesidir.

Hand-off, bir yazma ve ardından run'ın dışında uygulanan etkilerdir. Run yükseltme yapmaz ve bildirim göndermez. Ne olması gerektiğini söyleyen bir kayıtlı kapanır ve yapma işini bir worker'a bırakır.

```
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
```

İkinci bir yazma yok. Bölüm 10'un tek koşullu yazması kaydı kapanış olayı olarak saklar ve konu kilidini bırakır. Geçişe, Bölüm 15'in yanıt yolunun oluşturduğu açık intent'lerle izin verilir ve `open_intent_ids` kişiyi onlara yönlendirir. `run.mode` değiştirilmez: kapanış olayı `run`'ın `hand_off` basamağında bittiğini söyler ve bölümün sonundaki ölçümler basamağı oradan okur.

Worker, teslim satırı hâlâ açık olan `handed_off` `run`'lar üzerinde bir sweep'tir. Satır, hand-off id'sinde benzersiz bir outbox girdisidir; çünkü kapanmış `run` worker'ın ilerlemesini tutamaz.

Kaydın `kind`'ı etkileri seçer. Bir ops-agent hand-off'u on-call mühendise alarm gönderir ve bildirim göndermez, çünkü bir alert `run`'ının ticket'ı da müşterisi de yoktur. Bir support-agent hand-off'u, `hash(subject, escalation_intent_id)` key'iyle ticket sistemine yükseltir ve ancak ondan sonra, `reply_intent_id` değeri `notice:<handoff_id>` olarak ayarlanmış müşteri bildirimini, Bölüm 15'in sözleşmesindeki key'le gönderir. Kişi önce atanır, müşteriye sonra söylenir; böylece başarısız bir bildirim müşteriye geciktirir ama yanılmaz.

Üç özellik bunu kontrol etmeyi kolaylaştırır. `Run`, herhangi bir şey gönderilmeden önce bitmiştir ve worker kapanmış `run`'a hiç dokunmaz ya da model step'i atmaz. Her key kayıttan gelir, böylece retry'lar onları yeniden kullanır ve müşteriye iki kez e-posta gitmez. Ve belirsiz bir gönderime asla ikinci bir gönderimle karşılık verilmez: worker önce `sendStatus`'a sorar (Bölüm 15). Teslim satırının kendi deneme sınırı vardır; bu, bir outbox ayarındır ve Bölüm 13'ün `run` sayaçlarından biri değildir; sınırda worker, ticket sisteminden bağımsız bir kanaldan bir kişiye alarm gönderir ve satırı `stuck` olarak işaretler; böylece hiç yanıt vermeyen bir ticket sistemi sınırlı sayıda deneme ve bir alarma mal olur.

Bir kişi, `run`'ın kapandığı nedeni, örneğin `bound exceeded` ya da `success_unmet`'i, yanında teslim durumuyla görür. Bölüm 10'daki `BoundExceeded` handler'ı, yalnızca kapanış olayını yazan bir hand-off'un kendisidir; bu yüzden döngüye giremez ya da `run`'ı konusunu tutar halde bırakamaz.

On-call için müşteri bildiriminin karşılığı, ops agent'ın raporladığı kanaldaki sade bir durum satırıdır: hangi modda olduğu, ne zamandan beri, hangi tool'ların kullanılmadığı ve zaten ne bulduğu; `run` store'un

kaydettiği basamaktan (çalışan bir run için güncel basamak, hand-off yapmış bir run için kapanış olayının basamağı) kod tarafından üretilir.

Not: Bağımlılık toparlandıktan sonra ekranda kalan "otomatik asistan sınırlı" bandı, müşterilere onu görmezden gelmeyi öğretir. Mesajı run store'un kaydettiği moda bağlamak gerekir; böylece mesaj modla birlikte belirir ve kaybolur.

Fallback'leri test etmek ve gözlemlemek

Bir fallback nadiren çalışır ve nadiren çalışan kod çürür: en kötü gün, alternatif modelin credential'ının süresinin dolduğunu ya da bir şablon boşluğunun artık doldurulmadığını keşfetmek için yanlış zamandır. Üç tür test bunu kapsar.

- **Geçiş testleri.** Tablonun listelediği hataları enjekte etmek gerekir: timeout'a düşen bir model çağırısı, bir rate limit, açık bir breaker, etkiden sonra sonucu bilinmeyen bir yazma. Run'ın hangi basamağa ulaştığını, gate'in kurallarının onunla birlikte değiştiğini, retry'ların sınırdaki durduğunu ve sonucu bilinmeyen yazmanın tekrarlanmadığını, sorgulandığını doğrulamak gerekir. Bunlar CI'a aittir.
- **Kalite testleri.** Golden set'i (Bölüm 21) yanıt üreten her basamaktan geçirmek gerekir: alternatif model, deterministik yol ve şablonlar. Eşikler birincilinkinden farklı olabilir ve var olmalıdır.
- **Tatbikatlar.** Bir takvime göre staging'de, ya da production'da trafiğin küçük bir diliminde bir basamağı zorlamak ve insanların ne gördüğünü izlemek gerekir.

Fallback'lerin eklediği hata sessizliktir: şablon yanıtla sunulan bir run yine **done**'da biter ve kalite, normal görünen bir tamamlanma oranının arkasında düşmüştür. Bu yüzden basamak kaydın parçasıdır: her run modunu taşır, her `mode_change` olayı ve hand-off kaydı nedenini taşır ve basamak bir span özneteliğidir (Bölüm 20). Hepsi basamağa göre bölünmüş dört ölçüm değerlidir:

- her basamaktaki run'ların saat başına payı; böylece bir gündür trafik taşıyan bir merdiven görünür olur;
- retry oranı, yani ilk deneme başına retry, bağımlılık başına;

- her degraded mode'da geçen süre ve bunun toparlanmayla mı yoksa hand-off'la mı bittiği;
- basamağa göre sonuç kalitesi, örneklenmiş production eval'lerinden (Bölüm 21).

Tek bir geçişte değil, süre ve payda alarm vermek gerekir; sağlıklı bir retry oranının ne olduğu her sistemin kendi verisinde ölçülür.

Trade-off'lar ve maliyetler

Her basamağı ayakta tutmanın bir maliyeti var. Bir alternatif model credential'lara, eval'lere ve bir sahibe ihtiyaç duyar; deterministik bir yol mantığı çoğaltır; şablonlar gözden geçirme ister. Küçük bir agent için iki basamakla başladım, sınıflandırılmış retry'lar ve hand-off; diğerlerini hacim ya da bir hand-off'un maliyeti haklı çıkardığında eklerdim.

Retry'lar bekleyen insan için gecikme ekler. Deneme sınırını ve deadline'ı etkileşime göre ayarlamak gerekir; sohbet için bir gece araştırmasından daha sıkı.

Fallback'te gate'i sıkılaştırmak işi insanlara kaydırır. Alternatif modelde geri alınamaz yazmalar için onay, para yolunu korur ve zorlanan bir dönemde destek liderini yükler. Queue bunu karşılayamıyorsa tasarımın bir tavana ve onun ötesinde ne olacağına dair bir karara ihtiyacı vardır; dürüst cevap, o ticket'ların beklemesi olabilir.

Sınıflandırma yanlış olabilir. Yanlışlıkla retryable olan bir hata bütçeyi israf eder; yanlışlıkla kalıcı olan, bir retry'ın çözeceği işi hand-off'a verir. Retry oranı ve hata koduna göre hand-off oranı bunları ortaya çıkarır.

Idempotency her şeyi kapsamaz. Key'ler tekrarlanan yazmaları tekilleştirir; yanlış yere giden bir etkiyi geri almaz ya da onları yok sayan bir tool'u kapsamaz ve merdiven Bölüm 6'nın sözleşmelerinin geçerli olduğunu varsayar.

Merdiveni ne zaman kurmamalı. Bir agent yalnızca okuma yapıyor ve sonucu bir insan tüketiyorsa, sınırlı retry'lar ve net bir hata mesajı yeterlidir. Hatalar nadirse ve hand-off ucuzsa, altı basamak problemin hak

ettiğinden fazla makinedir. Ve tatbikatları için kadro ayrılamayan bir fallback, muhtemelen çalışmayan bir basamaktır ve politika onu listelememelidir.

Sık yapılan hatalar

- **Her katmanda retry etmek.** Her katmanın kütüphanesi varsayılan olarak retry eder ve her sınır tek başına makul görünür. Çözüm: yalnızca orchestrator retry eder; diğer katmanlar sıfıra ayarlanır.
- **Timeout'tan sonra bir yazmayı retry etmek ya da deneme başına yeni key üretmek.** Bir timeout hata gibi okunur ve "çağrı başına benzersiz", bir key'in ne için olduğu gibi gelir. Çözüm: önce state'in sahibini sorgulamak ve runtime tarafından atanan key'i yeniden kullanmak gerekir.
- **Bütçenin dışında retry etmek.** Bir yardımcının kendi döngüsü bir retry koymak için en kolay yerdir. Çözüm: her retry'ı run'ın bütçelerine yazmak ve sayacı run store'da tutmak gerekir.
- **Model kabul edene kadar yeniden sormak.** Döngü yazması kolaydır ve bazen işe yarar. Çözüm: bağlamı değiştirmek, düzeltme turlarını reason başına saymak ve sınırdan hand-off yapmak gerekir.
- **Kimsenin değerlendirmedeği bir fallback model ya da sessiz bir fallback.** Alternatif, gateway onu sunduğu için merdivendedir ve dashboard'lar toparlanmadan sonra iyi görünür. Çözüm: politikada bir eval durumu ve basamağın her run'a, trace'e ve metric'e kaydedilmesi.
- **Model tarafından yazılmış bir degraded-mode mesajı.** Akıcı bir özür elde etmenin en hızlı yoludur. Çözüm: hand-off varken gönderilen, sabit, gözden geçirilmiş bir şablon.

Temel çıkarımlar

- Hiçbir şeyi tekrarlamadan önce hatayı sınıflandırmak gerekir: geçici ret, timeout, bir yazmanın bilinmeyen sonucu, reddedilmiş öneri ve kalıcı hata her biri farklı bir karşılık alır ve buna orchestrator, hata biçimine ve etki sınıfına bakarak karar verir.
- Timeout'a düşen bir yazmanın sonucu bilinmez ve state'in sahibi ne olduğunu söyleyene kadar retry edilmez; retry'lar runtime tarafından

atanan idempotency key'i yeniden kullanır ve key bir son çaredir, plan değil.

- Retry'yı tam olarak bir katman yapar, retry'lar jitter'lı backoff, bir deneme sınırı ve run'ın deadline'ını kullanır ve her retry bütçeye yazılır ve run store'da sayılır; böylece bir resume onu sıfırlamaz.
- Modele yeniden sormak yeni bir örnektir, onarım değil: bağlamı ret nedeniyle değiştirmek, düzeltme turlarını reason başına saymak, küçük bir sınırdan durmak ve dayanaksız bir iddia için ikinci bir taslak yerine deterministik bir düzenlemeyi tercih etmek gerekir.
- Bir fallback merdiveni, her basamağın birincil davranıştan ne kadarını koruduğuna göre sıralanır; basamağı orchestrator sinyallerden seçer, basamağın kurallarını gate uygular ve alternatif bir model yalnızca kayıtlı bir eval durumuyla ve değişmeyen ya da daha sıkı bir gate'le girer.
- Bir fallback, en kötü günlerde çalışan koddur; bu yüzden enjekte edilmiş hatalarla test edilir, kalite için değerlendirilir, tatbikatlarla prova edilir ve her run'a kaydedilir; çünkü sessiz bir fallback, mal olduğu kaliteyi gizler.
- Degraded mode, müşteriye sabit, gözden geçirilmiş bir mesajla söylenir; mesaj hand-off varken gönderilir ve yalnızca doğru olanı söyler.

Bir sonraki bölüm merdivenin son basamağını ve oraya giden yolu ele alıyor. Bir kararı bir insana devretmek söylemesi basit ve yanlış yapması kolay bir şeydir; Bölüm 15, onayın ne zaman gerektiğini, onaylayanın ne gördüğünü ve bir onayın verildiği tam eyleme nasıl bağlı kaldığını anlatıyor.

Bölüm 15 — İnsan Onayı

Parcelport'un destek lideri Sam'in bir salı sabahı onay queue'sunu açtığını düşünelim. Destek agent'ının gece boyunca 60 istek açtığını varsayalım (varsayımsal bir sayı). Her biri bir iade tutarı, bir sipariş id'si ve modelin yazdığı, iadenin neden haklı olduğunu anlatan bir paragraf gösteriyor. Paragraflar akıcı ve birbiriyle uyumlu. Kırkıncı isteğe gelindiğinde Sam paragrafa güvenerek onaylıyor ve sipariş id'si göz ucuyla bakılan bir dizgeye dönüşmüş.

İstek 41, kolinin hasarlı geldiğini söylüyor. Ticket hasardan söz etmiyor ve `orders-service` koliyi hâlâ yolda gösteriyor. İki olgu da ekranda yok. Onay dört saniye sürüyor.

Aynı sabahın ilerleyen saatlerinde Sam bir müşteriye giden yanıtı onaylıyor. Onayla gönderim arasında agent'ın taslağı yeniden üretilmiş ve yeni ifade, hiçbir tool sonucunda bulunmayan bir teslimat tarihi vaat ediyor. Onay metne değil ticket'a bağlanmıştı; bu yüzden yanıt Sam'in adıyla çıktı.

Bu hikâyede kimse dikkatsiz değildi. Queue, bir insan kararı kaydedilebilirsin diye kurulmuştu ve bir karar kaydetti. Yapmadığı şey, kararı anlamlı kılmaktı. Bu bölüm kontrol zarfının **Gate** parçasına ait: bu önerinin bu principal için şimdi etki etmesine izin verilip verilmediğini yanıtlayan parça. Cevap "bir insan karar verir" olduğunda bu bölümün sorusu, o kararın bir imza olarak değil bir kontrol olarak sayılması için neyin doğru olması gerektiğidir.

Sorun ve neden zor olduğu

Gate'in üç kararı var ve üçüncüsü, needs approval, cevabın kodun dışından geldiği tek karardır. Bu da onu varsayılan olarak en zayıf halka yapar. Bir insan bir kontrolden daha yavaştır, bir saatten ötekine değişir ve sistemin ona göstermeyi seçtiği her şeyi görür. Onay yolu, kapalı görünen bir gate'ten birkaç hata sınıfının geçebildiği yerdir: onaylayana

argümanlar gösterilmediğinde F2 (yanlış tool ya da yanlış argümanlar), iddia gösterilip kaynağı gösterilmediğinde F3 (dayanaksız iddia), bir karar dayandığı olgulardan daha uzun yaşadığında F5.2 (bayat bağlam) ve uygulanan şey onaylanan şey olmadığında F7 (yetkisiz etki).

Bariz tasarım bir onay adıımıdır: önerilen eylemi ve bir düğmeyi göstermek, kimin bastığını kaydetmek gerekir. Dört şekilde başarısız olur ve her biri yapısaldır.

Birincisi, eylemi değil, eylemin genellikle model tarafından yazılmış bir tarifini gösterir. Bir cümle ile bir çağrı birbirinden kayabilir ve onaylayan bunu ayırt edemez. İkincisi, onay tek bir kesin çağrı hakkında değil, bir ticket ya da run hakkında bir olgudur ("Sam bunu onayladı"); bu yüzden orchestrator'ın sonra uyguladığı her şey onu miras alır. Üçüncüsü, kararın bir saati yoktur: 09:14'te verilmiş bir onay, sipariş farklı bir durumdayken 11:20'de hâlâ geçerlidir. Dördüncüsü, onay insan eylemidir ve insan eylemleri hacim altında bozulur. Öğleden önce 60 neredeyse aynı isteği onaylayan biri, altmışıncıda muhakeme yürütmüyordu.

"Riskli eylemlerden önce onay iste" gibi bir talimat, Bölüm 7'nin dediği gibi bir ricadır. Kontrol, needs approval döndüren politika, geçerli bir onay olmadan eylemeyi reddeden tool ve neyin onaylandığının kayıdır.

Onay ne zaman gerekir

Bir çağrının onay gerektirip gerektirmediğine gate'te politika karar verir; asla model ve asla yalnızca etki sınıfı değil. Bölüm 7, "yetkinin ötesinde, ama bir insan verebilir" ile "yetkinin ötesinde ve hiçbir insan veremez" ayrımını verdi. Onay birinci türdür. Bu başlık tetikleyicilerle ilgili.

Tetikleyici	Parcelport örneği	Kim hesaplar
Tutar	refund_ceiling üzerinde bir iade	Gate, çağrıdan ve sözleşmeden
Etki sınıfı ve hedef	Kanıt ne derse desin her request_rollback ya da toggle_feature_flag	Politika, tool adına göre
Belirsizlik sinyali	Claim check'in sınıflandıramadığı bir rakam içeren taslak yanıt (Bölüm 2)	Deterministik bir kontrol, model değil
Yeni ya da alışılmadık durum	Aynı siparişte ikinci bir iade isteği ya da daha önce hiç iletişime geçmemiş bir müşteri	Gate'in servislerden okuduğu olgular

Tetikleyici	Parcelport örneği	Kim hesaplar
Politika	Değişiklik penceresi dışında production yazmaları	Politika verisi, sürümlü

İki kural bu listeyi dürüst tutar. Birincisi, belirsizlik sinyallerinin kontrollerden gelmesi, modelin kendisi hakkındaki anlatımından gelmemesidir. "Emin değilim, lütfen gözden geçirin" diyen bir öneri bir öneridir ve ona göre yönlendirme yapan bir gate, modele kendi gözetimini iki yönde de seçme imkânı vermiştir. Bölüm 2, bir modelin belirttiği güvenin neden kanıt olmadığını açıklar; burada tetikleyicinin kodun yeniden hesaplayabileceği bir şey olması gerektiğini söylemek yeter.

İkincisi, tetikleyicinin run'a değil çağrıya ait olmasıdır. "Bu run'ı onayla", sonraki step'leri henüz var olmayan bir dizi hakkında bir hükümdür. Onay tek bir çağrıya bağlanır ve o çağrı önerildiğinde değerlendirilir.

```
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 }
```

Reason kodu karara eşlik eder ve onaylayana gösterilir; çünkü "bana neden soruluyor" bir gözden geçirenin ilk sorusudur. Ayrıca bu bölümün ilerisinde kullanılan ölçümü de verir: reason'a göre sayılan onaylar.

Bölüm 5'teki bir sıralama kuralı burada her yerden daha önemlidir. Onay, reddedebilecek her kontrolden sonra gelir. Gate'in reddedeceği bir çağrıyı onaylaması istenen bir insan, bir kişinin zamanını boşa harcamıştır ve o kişiye queue'nun saçmalık içerdiğini öğretmiştir.

Onaylayan ne görür

Bir onay isteği, bir kişinin zaman baskısı altında okuduğu bir belgedir. Onu karardan dışa doğru tasarladım: makul bir kişinin bu kesin çağrıya evet ya da hayır diyebilmesi için ne bilmesi gerekir ve her parça nereden gelir. Tasarımı bağlı tutacağım kural, ekrandaki her alanın ya kod tarafından çağrıdan ve servislerden hesaplanmış olması ya da başka bir şey olarak etiketlenmiş olmasıdır.

Aşağıdaki gösterim açıklayıcıdır. Onay servisinin bekleyen tek bir iade için neyi sakladığını ve render ettiğini listeler.

```
approval_request
  request_id:      "apr-0031"                // opaque
  call:            { tool: "issue_refund", order_id: "ord-7f3k2m91",
                    amount_minor: 18000, currency: "EUR", reason_code:
"damaged" }
                    // rendered by code from the call, never from model
  text
    call_hash:      callHash(call)           // defined in the next section
    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" ]
```

Listede neyin hangi sırayla olduğuna bakmak gerekir. Çağrı ilk gelir ve koddan render edilir; böylece onaylayan, etkinin kullanacağı argümanları görür. Ekran "müşteriye hasar için iade yap" gibi bir cümle gösterseydi, cümle ve argümanlar birbirini tutmayabilirdi ve onaylayan cümleyi onaylamış olurdu. Kanıt sonra gelir; gate tarafından `orders-service` ve `payments-service`'ten okunur ve okunduğu zamanla damgalanır. Risk ve geri alma yolu, evet demenin neye mal olduğunu ve sonrasında ne yapılabileceğini birer cümleyle söyler. Geri alınamaz bir yazma için dürüst geri alma yolu "yok"tur ve ekran bunu söylemelidir.

Modelin notu sondadır, daraltılmıştır ve etiketlidir. En çok savunacağım nokta budur: modelin açıklaması bir öneridir, kanıt değil. Çağrıyla aynı bağlamdan gelir; bu yüzden bağlam yanlışsa açıklama da aynı yönde

yanlıştır ve aynı derecede iyi okunur. İlk gösterilirse, açılıştaki salı sabahını üretir; son gösterilir ve etiketlenirse neyin kontrol edileceğine dair bir işaretçidir.

Ekranda olmayanlar da önemlidir. Ham müşteri e-postası metni güvenilmezdir ve onu okuyana yönelik talimatlar taşıyabilir (bu tür içeriğin nasıl ele alındığını Bölüm 16 anlatır) ve onaylayanın karar vermek için ihtiyaç duymadığı kişisel olarak tanımlanabilir bilgiler (PII) taşır (Bölüm 17). Kararın ihtiyaç duyduğu olguları göstermek ve daha fazlasını isteyen bir gözden geçiren için ticket'a link vermek gerekir. Hiçbir şey açıklamayan token'ları, credential'ları ya da dahili tanımlayıcıları göstermemek gerekir.

Bir onayı tek bir öneriye bağlamak

Onay servisi, kesin çağrıya bağlı **imzalı bir onay** döndürür. Bağ, "Sam evet dedi"yi "Sam buna evet dedi"ye çeviren şeydir ve söylemesi basittir: onay çağrının bir hash'ini taşır ve gate, hash'i eşleşmeyen her çağrıyı reddeder.

```
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
```

Bu bloktan dört özellik çıkar. **Kesinlik**: tutar, para birimi, sipariş ve key hash'tedir; bu yüzden 18000 için bir onay 18001'i kapsamaz.

Devredilemezlik: bir çağrı için verilen onay başka bir çağrı için kullanılamaz; böylece model, bir evet'ten sonra bir varyasyon önermekten bir şey kazanmaz. **Süre dolumu**: onayın, sonrasında geçerli olmadığı bir zamanı vardır ve o zaman olan şey sessiz bir retry değil bir geçiştir (saat

Bölüm 10'undur, anlamı bu bölümün). **Kimlik:** imza kimin ne zaman karar verdiğini kapsar; bu, onay tanımındaki "kimin karar verdiğiyle kaydedilir"dir.

Tek kullanımlıklık, tüketimde çevrilen bir bayrakla değil idempotency key'ile sağlanır; bayrak, onay servisi ile hedef sistem arasında bir transaction gerektirirdi. Key hash'tedir, bu yüzden aynı onaylı çağrının ikinci kez uygulanması ilk sonucu döndürür (`duplicate_replayed`). Gate onayı kontrol eder; tool ya da sahibi olan servis onu yeniden kontrol eder ve çağrı onaysız gelirse `approval_required` döndürür (Bölüm 7, karar ile uygulama arasında aynı çizgiyi çeker).

Uyarı: Yalnızca orchestrator'ın belleğinde ya da yalnızca bir kullanıcı arayüzünde var olan bir onay bir kontrol değildir. Parayı hareket ettiren ya da e-postayı gönderen servis, çağrıya bağlı geçerli bir onay olup olmadığını kontrol etmiyorsa, yukarıdaki herhangi bir yerdeki bir hata insan adımını süse çevirir.

Parametre değişiklikleri onayı geçersiz kılar

Sam tutarı değiştirmek isteyebilir ve bunda yanlış bir şey yok. Kural, onay arayüzündeki bir düzenlemenin mevcut çağrıya uygulanmamasıdır. Yeni bir çağrı oluşturur; bu çağrı gate'ten tekrar geçer, yeni bir hash alır ve politika hâlâ gerektiriyorsa yeni bir onay isteği alır. Aynısı model için de geçerlidir: bir evet'ten sonra iadeyi farklı bir tutarla yeniden önerirse hash farklıdır, önceki onay uygulanmaz ve Bölüm 6'daki key kuralları yeni çağrının gerçekten yeni bir intent olup olmadığına karar verir.

Modelin bir evet alana kadar yeniden sormasına izin vermezdim. Reddedilmiş bir çağrı hash'ile kaydedilir ve reddedilmiş bir hash'le eşleşen bir öneri yeni bir istek açılmadan reddedilir. Yalnızca biraz farklı olan bir öneri sınır tarafından sayılır (Bölüm 13) ve reddedilmiş tek bir eylemin varyasyonlarını istemeye devam eden bir run, hand-off için bir run'dır. Bu olmadan, reddeden kişi, kontrol etmeyi bırakana kadar yeniden deneyen bir döngünün zayıf noktası olur.

send_customer_reply için sözleşme

`send_customer_reply` bir dış yan etkidir ve kitap onu şimdiye kadar sözleşmesini yazmadan adlandırdı. Bölüm 6 onu etki sınıfları arasında sayar ve ağırlığının gönderimden önce olana gittiğini söyler. Bölüm 3, önündeki insan gate'i için bu bölümü işaret eder. İşte sözleşme, Bölüm 6'nın gösteriminde. Bölüm 2'nin claim check'ine ve Bölüm 6'nın idempotency kurallarına atıf yapılır, tekrarlanmaz.

```
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]
```

`reply_intent_id`, müşteriye yazmak için her neden başına runtime tarafından verilen ve kapalı bir kaynak listesinden alınan bir id'dir. Key tek bir formüldür; kaynaklar ve izinli değerler şunlardır.

Değer biçimi	Kaynak	Kullanım
<code>inbound:</code> <code><inbound_message_id></code>	Kaydedilmiş bir gelen mesaj	Mesaj bir yanıt gerektirir
<code>holding:</code> <code><approval_request_id></code>	Bekleyen bir onay isteği	İstek beklerken bekleme bildirimi
<code>notice:<handoff_id></code>	Bir hand-off	Degraded ya da hand-off bildirimi (Bölüm 14)
<code>human:<decision_id></code>	Bir kişinin kararı	Bir kişi başka bir mesajın var olması gerektiğine karar verdi

Key'de olmayanlar: `run_id`, `step_id`, metin ve modelin sağladığı başka her şey. Aynı intent için yeniden ifade edilmiş bir tekrar aynı key'e sahiptir ve ilk sonucu döndürür (`duplicate_replayed`). Bekleme bildirimi ile nihai yanıt farklı intent'lere sahiptir; bu yüzden biri ötekini asla yeniden oynatmaz. Düzeltilmiş ikinci bir yanıt yeni bir `human:` intent'idir ve onu bir kişi verir.

Birkaç satır yorumu hak ediyor, çünkü her biri belirli bir yolu kapatır.

Schema modelden metin ister ve başka bir şey istemez. Alıcı ticket'tan gelir; tıpkı bir müşterinin kimliğinin Bölüm 7'de run'dan gelmesi gibi. "Bunu [person-017@example.invalid](#) adresine gönder" diyen bir taslağın bunu söyleyeceği bir alan yoktur.

Bu ön koşul, Bölüm 2'nin claim check'inin bu tool için yaşadığı yerdir. Kontrol, müşteriye metin taşıyan her yolda durur: orchestrator nihai bir yanıtı ticket'a da iletiyorsa, o yol bu sözleşmeden, bu ön koşullar ve bu onay kuralıyla geçer.

PII ve injection satırları bilerek yer tutucudur. Bölüm 16, metin güvenilmez içerik tarafından yönlendirilmiş olabileceğinde gate'in neyi kontrol ettiğini ekler ve Bölüm 17, giden bir mesajda olmaması gereken veri için neyi kontrol ettiğini ekler. Bu listeyi genişletirler; onun yerini almazlar.

Onay satırı bu başlığın asıl noktasıdır. Onay, **render edilmiş** metne bağlanır; yani çıkacak tam byte'lara: tool şablonunu, imzayı ve alt bilgiyi uyguladıktan sonraki model taslağı. Taslak hash'lenip tool sonradan bir alt bilgi eklerse, onaylayan müşterinin okuduğundan başka bir şeyi onaylamış olur. Çıkanı hash'lemek gerekir. Onaydan sonra bir karakterlik bir değişiklik, ister model, ister şablon, ister taslağı düzenleyen biri yapsın, hash'i değiştirir ve çağrıyı gate'e geri gönderir. Bu, bir onayın tek bir öneriye ait olduğu kuralının metin biçimidir.

Key, Bölüm 6'dakiyle aynı biçime sahiptir ve gerekçe taşınır: sonraki bir step'te yeniden ifade edilmiş bir yanıt öneren model ikinci bir e-posta almaz, ilk sonucu alır. Maliyet gerçektir. İlk yanıt yanlışsa düzeltme, model onu önerdiği için gerçekleşmez; bir kişi ikinci bir mesajın var olması gerektiğine karar verdiği için gerçekleşir ve onay servisi yeni bir **human: intent**'i verir. Bu maliyeti öderdim. Yanlış bir e-posta almış bir müşteriye ikinci bir e-posta, müşteri ilişkisi hakkında bir karardır ve sorulabilecek birine aittir.

Sonuç bilinmediğinde ne olur

Ticket sistemi yanıtı kabul ettikten sonra ya da yalnızca kabul etmiş göründükten sonra timeout'a düşebilir. Run o zaman müşterinin mesaja sahip olup olmadığını bilmez. Retry etmek yanlış harekettir, çünkü gönderilmiş bir e-posta geri alınamaz; hiçbir şey göndermemek de öyle, çünkü müşteri var olan bir yanıtı bekler. Sözleşmenin cevabı Bölüm 5 ve Bölüm 6'dakidir: bilinmeyeni kaydetmek, sormak ve bilene kadar hiçbir şey göndermemek gerekir.

```

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


```

Hata yollarını okumak gerekir. Fonksiyon orchestrator'a aittir: intent'i kaydeder, retry'a karar verir ve hand-off yapar. Gönderim ve durum sorusu, ticket sistemine tool gateway üzerinden ulaşır; birincisi `effect.apply` olarak. Intent çağrıdan önce kaydedilir; bu yüzden gönderimden sonraki bir çökme yine de bir iz bırakır ve Bölüm 10'un resume prosedürü açık bir intent bulur. Durum sorusu bir okumadır ve asla göndermez. Retry yalnızca kesin bir "gönderilmedi" üzerine, aynı key'le gerçekleşir ve onay kontrolünden yeniden geçer; böylece beklerken süresi dolan bir onay retry'ı durdurur. Belirsiz bir cevap yeniden denemek için bir ruhsat değildir. Bu, run store'un metni ve key'i tuttuğu bir hand-offtur; ticket'a bakıp karar verebilecek Sam'e.


İki yanlış cevap simetrik değildir ve tasarım bunu yansıtır. Çıkmayan bir yanıt görünürdür: müşteri yeniden yazar ve ticket açık bir intent gösterir. İki kez çıkan bir yanıt görünür değildir. Seçim, eksik bir e-posta ile yinelenen bir e-posta arasında olduğunda, bir kişinin fark edip düzeltebileceğini seçerdim.

Onay akışı

Diyagram, tavanın üzerindeki bir iadeyi öneriden etkiye kadar gösteriyor. Akışın etkisiz bittiği üç yere bakmak gerekir: gate'in reddi, onaylayanın reddi ve süre dolumu. Üçü de gözlem olarak bağlama ya da hand-off olarak bir kişiye döner ve hiçbir modelin kendi başına ilerlemesine izin vermez.



Bir onay isteğinin kendisi az sayıda state'ten geçer ve bunların yazılı olması, olay review'unda soru "onaylayan gerçekte neye karar verdi ve ona ne oldu" olduğunda yardımcı olur. State'ler Bölüm 10'daki run'ın state'lerinden ayırdır: bir istek `pending` iken run `awaiting_approval`'dır.



Onay ve run

Bir insan karar verirken run'a ne olduğunu Bölüm 10 yönetir: run `awaiting_approval`'dır ve hiçbir worker tutmaz, onaydaki saatin bir varış noktası vardır ve devam ettirilen bir run olguları yeniden okur ve bekleyen çağrıyı gate'ten tekrar geçirir. Bu bölüm kararın kendisi hakkında üç şey ekler.

Birincisi, onaylayanın kararının bir zamanda okunan, başka bir zamanda uygulanan kanıtı dayanarak verilmesidir. İstek her olgunun okunma zamanını taşır ve gate resume'da yeniden okur (nedenini Bölüm 7 verdi). İade edilebilir bakiye aralıkta değiştiyse çağrı bir ön koşulda takılır, onay artık mümkün olmayan bir çağrı hakkında bir karar olarak kayıta kalır ve model bir ret görür. Maliyet, Sam'in bazen sonradan reddedilen bir şeyi onaylamasıdır. Bunu kabul ederdim; alternatif, bir onayı verilmediği bir dünyaya uygulamaktır.

İkincisi süre dolumudur. Süre dolumunu sistemin rahatlığından değil, onaylayanın gerçekliğinden seçmek gerekir. Mesai saatlerinde karşılanan bir destek queue'su saat 02:00'de bir karar vaat edemez ve saati gecenin ortasında dolan bir onay, run'ı çağrı ekli olarak hand-off'a verir; kendini uzatmaz. Sam sabah iadeyi hâlâ istiyorsa, güncel olgulardan yeni bir istek render edilir. Bir onayı sessizce uzatmak, bir kararın tarif ettiği olgulardan daha uzun yaşamasının yoludur.

Üçüncüsü, run beklerken müşterinin ne gördüğüdür. "Bir meslektaşımız talebinizi inceliyor" diyen bir mesaj, kendi sözleşmesi ve kendi intent'i (`holding:<approval_request_id>`) olan bir `send_customer_reply`'ın kendisidir; böylece ardından gelen yanıtın key'ini asla tüketemez. Onu, modelin yazdığı hiçbir iddia içermeyen bir şablondan ürettirdim. Dürüstlüğü ucuz olduğu bir yerdir de: bir kişinin baktığını söylemek, bir sonuç vaat etmemek gerekir.

Çift kontrol ve görev ayrılığı

Bazı çağrılar için tek bir onaylayan yetmez. Çoğu zaman dört göz denen çift kontrol, aynı çağrıyı iki farklı kişinin onaylamasını gerektirir ve görev ayrılığı, bir eylemden yararlanan ya da onu başlatan kişinin onu onaylayan kişi olmamasını gerektirir. İkisi de politikadır ve ikisi de arayüz tarafından değil, onay servisi tarafından uygulanır.

```
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
```

Onay servisi rolleri ve ayrık olmayı imzalı kimliklerden kontrol eder ve aynı hash için gereken sayıda geçerli onay var olana kadar bir istek `pending`'den çıkmaz. Arayüz bunu ayarlayabiliyorsa onaylayanlar, kendi kararlarını vermeden önce birbirlerinin kararını görmez; çünkü ilk bir "evet"i gören ikinci bir onaylayan, bağımsız bir kontrolden çok bir karşı imzacıya yakındır.

Maliyet bir takvim üzerinde ortaya çıkar. İki onaylayan iki queue, daha uzun bir bekleme ve bir kapsama problemi demektir: hafta sonu ikinci kişi kim? Hiçbir tasarımın ortadan kaldırmadığı bir insan etkisi de var. İki kişi bir kararı paylaştığında her biri kontrolün diğeri olduğunu hissedebilir ve her bir review'un kalitesi düşebilir. Çift kontrolü, tek bir hatanın maliyetinin büyük ve geri alınamaz olduğu dar bir çağrı bandı için

kullanırım ve genel bir yükseltme olarak kullanmam. Tavanın üzerindeki her iadeye uygulanan bir kademe hiçbir şeyi yarıya indirmez ve queue'yu ikiye katlar.

Aynı örüntü ops agent için farklı bir biçimde geçerlidir. On-call SRE Robin, request_rollback'i onaylar. Geri alınan deployment'ı Robin başlattıysa, bir ayrılık kuralı ikinci bir mühendis isterdi ve sabahın üçünde böyle biri olmayabilir. Bu, olay anında değil, önceden, on-call rotasyonu ile birlikte politika olarak yazılarak verilecek bir seçimdir.

Rubber-stamping, yorgunluk ve automation bias

Üç etki insan adımını aşındırır ve bunlar, içindeki insanların değil, düzenin özellikleridir. **Rubber-stamping**, incelemeyi onaylamaktır. **Onay yorgunluğu**, hacim ve tekrardan gelen dikkat düşüşüdür. **Automation bias**, bir sistemin önerdiği şeyi, sistem önerdiği için kabul etme eğilimidir ve öneri akıcı bir açıklamayla geldiğinde daha güçlüdür; modelin notunun ekranda en sonda durmasının nedeni budur.

Bunların hiçbirini tek bir kararın içinden görülemez. Onay servisinin zaten elinde tuttuğu verilerde görülür ve en azından şunları ölçerdim.

Ölçüm	Ne söyler	Kötü bir değer neye benzer
Reason'a göre onay oranı	Tetikleyicinin bir insana ihtiyaç duyan önerileri bulup bulmadığı	Bir reason için yüzde 100'e yakın: tetikleyici, bir insanın değiştirdiği hiçbir şeyi yakalamıyor olabilir
Karar süresi, bir dağılım olarak	Kanıtın okunup okunmadığı	Kontrol edilecek birkaç olgusu olan bir istekte saniyelerle ölçülen bir medyan
Ret ve düzenleme oranı	Modelin önerilerinin iyi olup olmadığı ve insanların farklılaşıp farklılaşmadığı	Aylarca sıfıra yakın ret ya da diğerlerinden çok uzak bir onaylayan
Queue yaşı ve süre dolumu oranı	Queue'nun hacmine göre kadrolanıp kadrolanmadığı	Süresi dolan onaylar için artan süre dolumu ya da hand-off
Resume'da onaylandı-sonra reddedildi	Kararların bayat kanıta dayanarak verilip verilmediği	Sabit bir oran: karar ile etki arasındaki aralık çok uzun

Bunları bir kişinin performans değerlendirmesi olarak değil, bir tasarım sinyali olarak okumak gerekir. Saniyeler içinde neredeyse sabit bir evet, tetikleyici ve ekran hakkında bir şey söyler ve suçlamasız okuma, sistemin onaylayana cevabın evet olduğunu öğrettiğidir. Sonraki adım bir tasarım değişikliğidir.

Bir reason'ın hiç kıpırdamayan bir onay oranı gösterdiği durumda üç dürüst seçenek var. Biri insanı çıkarmaktır: bir kişi uzun süredir bir sonucu değiştirmediyse, çağrıya daha sıkı bir sınırla (daha düşük bir tavan ve bir günlük toplam, Bölüm 13) ve sonradan örneklemeye deterministik bir kural daha iyi hizmet edebilir. Bir diğeri gösterilen şeyi değiştirmektir; böylece kanıtı okumak hızlı yol olur. Üçüncüsü onayı tutmak ve onun hata yakalamak için değil hesap verebilirlik için var olduğunu açıkça söylemektir; bir review'da kimse onu bir güvenlik kontrolü saymadığı sürece meşru bir nedendir.

Eşikler hisle değil veriyle ayarlanmalıdır. Queue'yu küçültmek için `refund_ceiling`'i yükseltmeden önce, kaldırılacak bant için istenen tutarların dağılımını ve ret reason'larını çekmek gerekir. O bantta hiçbir şey hiç reddedilmiyorsa tavanı yükseltmek muhtemelen doğrudur ve run başına ve gün başına toplam iade edilen değer üzerindeki sınır, insanın eskiden karşıladığı maruz kalmayı karşılayan şeydir. Banttaki retler yaygınsa ve iyi nedenlerle yapılyorsa queue çalışıyordur ve hacmin çözümü daha yukarıda, modelin o çağrılardan neden bu kadar çok önerdiğindedir (F2).

Parcelport: tavanın üzerindeki iade ve bir rollback

Ticket'ı hasar bildiren bir müşteri, `cus-0042`, için `ord-7f3k2m91` üzerinde bir iade isteği düşünelim. `refund_ceiling`'in sipariş para biriminde 100,00 olduğunu ve önerilen tutarın 180,00 olduğunu varsayalım (varsayımsal değerler). Gate siparişi okur, teslim edilmiş ve tahsil edilmiş bulur, daha önce iade bulmaz ve tutarın tavanın üzerinde olduğunu görür. `above_ceiling` reason'ıyla `needs approval` döndürür. Run `awaiting_approval` olur.

Sam'in ekranı koddan render edilmiş çağrıyı, belirtilen bir zamanda okunmuş sipariş durumunu, iade edilebilir bakiyeyi, daha önce iade olmadığını, ticket'a bir linki ve Parcelport'un bir iadeyi geri çağırmanın

hiçbir yolunun olmadığı satırını gösteriyor. Modelin notu altta, daraltılmış. Sam ticket'ı okuyor, konuşmada bir fotoğraf referansı görüyor ve onaylıyor. İmzalı onay hash'i, onaylayanı ve bir süre dolumunu taşır.

Resume'da gate siparişi ve bakiyeyi yeniden okur ve onayı şimdi elinde tuttuğu çağrıya karşı kontrol eder. Allow üzerine orchestrator `effect.apply`'ı başlatır ve tool gateway çağrı başına credential'ı ekleyip `payments-service`'i Bölüm 6'daki key'le çağırır. Sonuç tool gateway üzerinden döner ve kaydedilir. Müşteriye yanıt, kendi sözleşmesi olan ikinci bir çağrıdır: metin iade tutarını belirtir, claim check bunu sonuca bağlar ve politika bu türden bir yanıt için onay gerektirmez; bu yüzden karar allow'dur. Modelin metni extractor'ın sınıflandıramadığı bir rakam içerseydi karar needs approval olurdu ve yeni bir istek Sam'e kendi hash'ine bağlı render edilmiş metni gösterirdi.

İki onayın neyi ortak taşıdığına ve neyin onları ayırdığına dikkat etmek gerekir. İkisi de kesin içeriğe bağlıdır, ikisinin de süresi dolar, ikisi de etkinin sahibi tarafından kontrol edilir. Ters gidebilecek şeyde ayrılırlar: yanlış bir iade geri çağrılanmayan paradır, yanlış bir yanıt geri alınamayan bir mesajdır. İki çağrı arasındaki boşluk da F6'nın (sessiz kısmı hata) yaşadığı yerdir. Uygulanmış bir iade ve gönderilmemiş bir yanıt, done'a ulaşmaması gereken bir run bırakır.

Ops agent aralığın öbür ucunu gösterir.

	Tavanın üzerinde <code>issue_refund</code>	Gerektiğinde <code>send_customer_reply</code>	<code>request_rollback</code>
Onaylayan	Sam	Sam	Robin
Bağlı olduğu şey	Sipariş, tutar, para birimi, key	Render edilmiş metin, alıcı, key	Deployment, hedef sürüm, key
Geri alma yolu	Parcelport'ta yok	Yok	Sonraki bir deployment önceki sürümü geri getirir
Koddan hesaplanan kanıt	Sipariş durumu, bakiye, önceki iadeler	İddialar ve bağlandıkları sonuçlar	Sürümler, release öncesi ve sonrası hata oranları, store'lardan
Neden onay	Tutar tavanın üzerinde	Claim check karar veremedi	Politika, kanıt ne derse desin

Bir rollback için politika her çağrıda needs approval döndürür; bu yüzden ilginç tasarım işi istektir. Robin onu sabahın üçünde bağımsız okuyor olabilir; bu yüzden kendi kendine yeterli olmalıdır: güncel ve önceki sürüm, orchestrator'ın release öncesi ve sonrası için `get_metrics`'ten hesapladığı hata oranları, zaman penceresi ve sonraki bir deployment'ın rollback'i geri alabileceği ifadesi. Sayılar kod tarafından hesaplanır, modelin açıklamasının yanında ve içinde değil (Bölüm 4). Geri alınabilir bir yazmayı yanlış yapmak bir iadeden ucuzdur, ama yoğun bir dönemdeki rollback bedava değildir ve onay, o maliyetin sahibi birinin onu bilerek ödemesinin yoludur.

Trade-off'lar ve maliyetler

Onayın dört para biriminde bir bedeli var. Zaman: onay kapılı her çağrı bir insanı bekler ve bekleme en iyi ihtimalle dakikalar, en kötü ihtimalle saatlerdir. İnsanlar: birinin orada olması, ekranı okumak üzere eğitilmesi, yokken karşılanması ve hiç bitmeyen bir queue'dan korunması gerekir. Mühendislik: onay servisi, istek render'ı, imza ve doğrulama ile gate ve tool'daki kontroller kendi kullanılabilirlik (availability) sorunu olan gerçek bileşenlerdir. Müşteriler: iadesi Sam'i bekleyen bir müşterinin öğleden sonrası, iadesi Sam'e ihtiyaç duymayandan daha kötüdür.

Onay servisi gate'in bir bağımlılığı olur. Servis çöktüğünde, onay gerektiren çağrılar onay alamaz ve tek güvenli davranış hata durumunda reddetmektir: run bekler ya da hand-off yapar ve doğrulanamayan bir onay üzerine hiçbir şey ilerlemez. Bunu ilk kesintiden önce tasarımda söylemek ve müşteriye ne söylendiğini söylemek gerekir.

Bir onay, bir kişinin bir kesin çağrısı, gösterilen kanıta dayanarak, bir zamanda kabul ettiğini söyleyen bir ifadedir. Dünyanın doğru olduğunu söyleyen bir ifade değildir. Bir onaylayan yanılabilir, yargılayacak bilgiye sahip olmayabilir ya da gate önemli olanı okumadığı için eksik bir tablo görebilir. Onay, bir hatanın etkiye dönüşme ihtimalini azaltır; etkinin doğru olduğunu garanti etmez ve onu bir iadeyi "güvenli" kılan şey olarak tarif etmek abartı olurdu.

Her tool'u onayın arkasına koymak özenli görünür ve gösteriden ibarettir: queue büyür, cevaplar bir gün içinde refleks haline gelir ve dikkat gerektiren tek istek, diğer doksan dokuza benzer görünür. Bir

deterministik kuralın karar verebildiği ya da etkinin bir okuma ya da ucuz bir geri alınabilir yazma olduğu yerlerde, sonradan örnekleme genellikle yeterlidir.

Sık yapılan hatalar

- **Bir tarifi onaylamak.** Bir cümle argümanlardan daha iyi okunduğu için cazip. Çağrışı argümanlarından, kodda render etmek ve çalışacak şey olarak göstermek gerekir.
- **Modelin açıklamasını kanıt saymak.** İkna edicidir ve modelin kendi anlatımıdır. Kanıt servislerden hesaplamak, notu en sonda göstermek ve doğrulanmamış diye etiketlemek gerekir.
- **Ticket'a ya da run'a bağlı bir onay.** Uygulaması kolaydır ve orchestrator'ın sonra yaptığı her şey onu miras alır. Key dahil, tek bir çağrının hash'ine bağlamak gerekir.
- **Süresi olmayan ya da kendini uzatan bir onay.** Karar olgularından uzun yaşar. Her onaya bir saat vermek gerekir ve süresi dolduğunda bir varış noktası.
- **Onayları hızla ölçmek.** Kısa bir queue süresi sağlıklı bir süreç gibi görünür. Reason'a göre oranı, karar süresini, retleri ve onaylandı-sonra-reddedildi vakalarını ölçmek ve bunları tasarım sinyali olarak okumak gerekir.
- **Onay servisi kullanılmadığında hata durumunda izin vermek.** Queue'yu hareket ettirir ve kontrolü tam bir şeyler ters giderken kaldırır. Hata durumunda reddetmek ve hand-off yapmak gerekir.

Temel çıkarımlar

- Bir çağrının onay gerektirip gerektirmediği, kod tarafından çağrıdan, olgulardan ve bir politika sürümünden verilen bir politika kararıdır; modelin belirttiği güvenden asla değil.
- Onay, idempotency key'i dahil tek bir kesin çağrının hash'ine bağlı imzalı bir karardır; bu yüzden değişmiş bir parametre, değişmiş bir metin ya da sonraki bir step'teki tekrar, kendi cevabına ihtiyaç duyan farklı bir çağrıdır.

- Onay ekranı koddan render edilmiş çağrıyı ve okunma zamanlarıyla servislerden okunan kanıtı gösterir; modelin açıklaması en son, doğrulanmamış diye etiketli gösterilir; çünkü bir öneridir, kanıt değil.
- `send_customer_reply`, runtime tarafından atanan id'lerden kurulan bir idempotency key'i, render edilmiş metne bağlı bir onayı ve bilinmeyen bir sonucun asla yeniden göndererek değil ticket sistemine sorarak çözüldüğü bir kuralı olan bir dış yan etkidir.
- Etkiyi gerçekleştiren tool ya da servis geçerli bir onay olup olmadığını kendisi kontrol etmelidir; yoksa yukarıdaki bir kusur insanı yoldan çıkarır.
- Onay oranları, karar süreleri, retler ve onaylandı-sonra-reddedildi vakaları tasarım sinyalleridir ve saniyeler içinde hep onaylanan bir reason değişim için bir tetikleyicidir: onu bir kural ve bir sınırla değiştirmek, ekranı değiştirmek ya da hesap verebilirlik için bilerek tutmak gerekir.
- Onayın zaman, kadro, mühendislik ve müşteri beklemesi cinsinden maliyetleri vardır ve her çağrıyı onayın arkasına koymak, önemli olan tek isteği gizleyen bir gösteridir.

Onay, isteği okuyan kişinin içindeki içerik tarafından yönlendirilmediğini ve modelin bağlamının müşterinin e-postasını yazan kişi tarafından şekillendirilmediğini varsayar. Bölüm 16, talimatlar verinin içinde geldiğinde ne olduğunu ve neden bir prompt'un tek başına kontrol olamayacağını ele alıyor.

KISIM V

Güvenlik Sınırları

Bölüm 16 — Prompt Injection

Parcelport'ta bir perşembe öğleden sonrasını düşünelim. Bir müşteri hasarlı gelen bir paketle ilgili yazıyor ve iade istiyor. Mesaj kibar, olgular sıradan. Ama imzanın altında başka bir yerden yapıştırılmış bir metin bloğu duruyor ve bu blok destek ekibine hitap etmiyor. E-postayı işleyen her ne sistemse ona hitap ediyor. İadenin başka bir siparişe karşı yapılmasını ve sipariş toplamından büyük olmasını, yanıtta iadenin onaylandığının yazmasını, sistemin müşteri hakkında bildiği her şeyin yanıtta eklenmesini ve "doğrulama için" bir bağlantı konmasını söylüyor.

Destek agent'ının prototipinde tek bir prompt ve geniş bir token olduğunu, e-posta metninin de bağlama olduğu gibi girdiğini varsayalım. Bu tasarımda müşterinin talebini imzanın altındaki bloktan ayıran hiçbir şey yok. İkisi de aynı dizideki metin ve model, bütün dizinin olası kıldığı şeyi öneriyor. Bazen bu, hasarlı paket için yapılan ve başka bir şey içermeyen bir iade oluyor; bazen önerinin şekli değişiyor. Cuma günü test edip ilk sonucu gören bir ekip çok az şey öğrenmiş olur.

Bu bölüm kontrol zarfının iki parçasına aittir. **Bağlam**'da, her metin parçasının nereden geldiğini ve ne kadar güvenilebileceğini sorar. **Gate**'te, gate'in kaynağı Parcelport'ta kimsenin yazmadığı bir metne uzanan bir öneriyle ne yaptığını sorar. Bölümün sorusu dar: talimatlar verinin içinde gelebiliyorsa ve model ikisini güvenilir biçimde ayıramıyorsa, yönlendirilmiş bir önerinin zarar verememesi için çevresindeki sistem hakkında neyin doğru olması gerekir?

Sorun ve neden zor olduğu

Prompt injection, veri olan içeriğin talimat gibi ele alınmasıdır. Bölüm 3 bu sınıfı F4 (Talimat ele geçirme) olarak adlandırır ve iki alt sınıf verir: F4.1, kullanıcının kendi girdisinin agent'ın kurallarını geçersiz kılmaya çalıştığı doğrudan injection; F4.2, içeriğin bir tool sonucu, bir doküman ya

da başkasının yazdığı bir e-posta yoluyla geldiği dolaylı injection. Bu bölüm ikisini de ele alır, ağırlığı dolaylı olana verir, çünkü tasarımın soracağı bir kullanıcının bulunmadığı yer orasıdır.

Parcelport'ta talimatlar, çoğu ilk tasarımın saydığından daha fazla yerden girebilir.

Kanal	Parcelport örneği	Kim yazdı
Müşteri e-postası	Destek agent'ının okuduğu bir ticket'ın gövdesi	Talep eden ya da metnini talep edenin yapıştırdığı biri
İletilmiş ya da alıntılanmış metin	Bir yazışma zincirinde iletilen kargo bildirimi	Üçüncü bir taraf
Ek	Bir hasar talebine eklenmiş doküman	Üçüncü bir taraf
Web sayfası	Örnek olarak düşünülen bir <code>fetch_page</code> tool'u olsaydı onun getirdiği sayfa	Herhangi biri
Retrieval ile gelen doküman	<code>search_docs</code> 'un döndürdüğü bir sayfa	Parcelport çalışanları ve sayfayı düzenleyebilen herkes
Tool sonucu	Bir sipariş kaydındaki serbest metin notu, bir kargo şerhi	Müşteriler ve kargocular, başka bir servis üzerinden
Log satırı	Bir istek alanını yansıtan, ops agent'ının okuduğu bir hata	Log'lanan isteği gönderen kişi
Bellek	Daha önceki bir run'ın yazdığı not (Bölüm 11)	Daha önceki bir run, okuduğu her neyse ona dayanarak

Her satır, run'ın denetimi dışındaki bir kişinin ya da sistemin ürettiği metindir ve her satır aynı yere varır: bir sonraki model çağrısı için derlenen bağlama.

Model neden ikisini ayıramaz

Model tek bir dizi alır. Orchestrator dizinin bazı kısımlarını işaretleyebilir ("sistem politikası", "ticket metni, güvenilirmez") ve modelin çıktılarını işaretlere çoğu zaman uyar, ama işaretlerin kendisi de dizideki metindir. Bir müşteri işarete benzeyen metin yazabilir. Modelin çalışma biçiminde, politikaya ticket'ın taklit edemeyeceği ayrıcalıklı bir kanal veren hiçbir şey yok. Bu ayrımı bugün güvenilir kılan bir teknik bilmiyorum ve biri gelmek

üzereymiş gibi tasarım yapmazdım. Gelirse, aşağıdaki kontroller yine geçerli kalır ve bir tasarımın karşılaması gereken sınav budur: model değiştirildiğinde doğru kalmalıdır.

SQL injection parametrelili sorgularla çözülür, çünkü veritabanının iki kanalı vardır: biri kod, biri veri için. Modelin tek kanalı var, bu yüzden savunma modelin dışına taşınır: model öneride bulunduktan sonra olanlara ve neye erişebildiğine.

Hangi hata sınıflarını üretir

Yönlendirilmiş bir öneri, bir sipariş id'si ya da adres görevden değil metinden geldiğinde F2 (Yanlış tool ya da yanlış argümanlar) olarak; hiç var olmaması gereken geniş bir token çağrısı izin verdiğinde F7 (Yetkisiz etki) olarak (Bölüm 7); enjekte edilen metnin ileri sürdüğünü tekrarlayan bir yanıtta F3 (Dayanaksız iddia) olarak; run'ın kaydı önerisinin hangi metni izlediğini söylemediğinde, yani aynı mesajı okuyan diğer run'ları kimse bulamadığında F8 (Gözlenmeyen davranış) olarak ortaya çıkar.

Doğrudan injection daha küçük sorundur

Metni müşteri yazdıysa, müşteri aynı zamanda run'ın adına hareket ettiği principal'dır. Sipariş toplamından fazlasını isteyen bir müşteri, nasıl ifade edilirse edilsin, tavanın, iade edilebilir bakiyenin ve Bölüm 6 ile 7'deki devredilmiş yetkinin karar vereceği bir şey istemektedir. Doğrudan injection, "principal yetkisinin ötesinde bir şey istedi" durumuna indirgenir ve gate bunu zaten reddeder. Daha zor olan durum, principal olmayan yazarın metninin agent'in yetkisini kendi adına kullanmaya çalışmasıdır.


Tehdit modeli: bir araya gelmesi gereken üç şey

Bütün konuyu üç koşula indirgemeyi yararlı buluyorum. Bir injection'dan zarar doğması için üçünün de aynı run'da doğru olması gerekir.

1. **Güvenilmez içerik.** Parcelport'un kendi kodu ve çalışanları dışında biri tarafından yazılmış metin bağlamdadır.
2. **Erişim.** Agent hassas veriyi okuyabilir ya da önemli bir etki doğurabilir: müşteri bilgileri, bir iade, bir adres değişikliği.
3. **Dışarı çıkan bir kanal.** Verinin ya da etkinin run'dan çıkabileceği bir yol vardır: bir müşteriye yanıt, o yanıtta bir bağlantı, giden bir istek,

bir pull request gövdesi, bir bellek yazımı.

Bunlardan biri eksikse geriye kalan sınırlıdır: düşmanca metni okuyan ama hassas erişimi ve dışarı çıkan kanalı olmayan bir agent kötü bir yanıt üretebilir, daha kötüsünü değil. Bu çerçeve bir tasarım aracıdır, teorem değil. "Erişim" yazma yetkisini de kapsar ve bir kanal dolaylı olabilir (iade, harekete geçebilecek bir kişiye verilen bir sinyaldir). Ama işin nereye konacağını söyler: her tool için hangi ayağın kesileceği seçilir ve bu seçim kodda yapılır.



Noktalı çizgiler her kontrolün nerede etkili olduğunu gösterir. Bir sözleşmedeki her tool için üçünden hangisine katkıda bulunduğunu yazmak, üçünün de bulunabildiği her yol için tasarımın hangisini ortadan kaldırdığını söylemek gerekir.

Destek agent'ı için birinci koşul kaldırılamaz, çünkü müşterilerin e-postasını okumak işin kendisidir. Erişim kilitlemeyle kesilir: üçüncü taraf içeriği okumuş bir run, bir insan olmadan önemli bir eylemde bulunamaz. Kanallar, seçimleri modelin elinden alarak kesilir: bir yanıtta alıcı, bağlantı host'u ve iletişim bilgileri modelin adlandıracağı şeyler değildir.

Prompt bir kontrol değildir

Çoğu ekibin yazdığı ilk şey, sistem prompt'una modele e-postalarda bulduğu talimatları yok saymasını söyleyen bir cümledir. Yönlendirilmiş önerilerin görülme oranını düşürür ve ben onu tutardım. Ama bir istektir de ve hiçbir özellik ona dayanmaz: çıktısı sorgulanan bileşen onu okur, etkisi istatistiksektir ve bir hata sinyali yoktur, çünkü kaybettiğinde öneri diğer her öneri gibi görünür. Ayraçlar ve etiketler de aynı sınıftadır: bağlama işlenmiş bir etiket modele yapılan bir istektir, öğeyle birlikte kodda taşınan `trust` alanı ise gate'in okuyabileceği bir şeydir. Bu bölümün geri kalanı o alanı kullanmakla ilgilidir.

Not: Bir prompt, modelin yerleştirilmiş bir eylemi ne sıklıkla önerdiğini değiştirebilir. Eylemin etkili olup olamayacağını yalnızca kodda yapılan bir kontrol değiştirir. Bir prompt'u değerlendirmek bir oranı ölçer; gate'i değerlendirmek bir özelliği test eder. İkisini ayrı raporlamak gerekir.

Köken ve taint

Bölüm 9 her bağlam öğesine, orchestrator tarafından atanan bir `origin` ve bir `trust` alanı verdi. Bu bölüm **taint**'i ekler: bir değer güvenilmez bir kaynaktan geldiğini ve kontrol edilmeden hassas bir eylemi yönlendirmemesi gerektiğini belirten bir işaret. Köken bir öğenin nereden geldiğini söyler, taint bunun sonraki öneriler için ne anlama geldiğini söyler.

Güvenilmez içeriğin iki sınıfı

Her güvenilmez öğeye aynı davranılırdı her run kilitlenirdi, çünkü her run bir müşteri e-postasıyla başlar. Kullanılabilir ayırım, principal'ın yazdığı içerik ile başka herkesin yazdığı içerik arasındadır.

```

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

```

İşaret bütün bir öğeye değil, bir alana iliştilir. Bir `lookup_order` sonucu birkaç alanlı tek bir öğedir: `order_id`, `amount_minor` ve `status` `system_record`'dur, müşterinin ödeme sırasında yazdığı bir not `principal`'dır, bir kargo şerhi `third_party`'dir. Karışık bir sonuç tek bir güven seviyesi değildir. Bölüm 9'daki öge etiketi modelin öğeyi nasıl gördüğünü yine belirler; işaret bunu gate için alan bazında inceltir.

Müşterinin kendi mesajı güvenilirmezdir, ama aynı zamanda run'ın hizmet etmek için var olduğu taleptir: sözleri `principal`'ın konuşmasıdır ve `principal`'ın devredilmiş yetkisi ile tavanlarla sınırlıdır. Üçüncü taraf metninin böyle bir konumu yoktur. İletilmiş bir bildirim, bir ek ya da bir kargo şerhi müşterinin bir şey istemesi değildir; dolayısıyla bunlardaki bir talimatı izleyen bir öneri, müşterinin yetkisini başka birinin kullanması demektir. Bu, Bölüm 7'deki `confused deputy`'dir, yalnızca farklı bir ön kapıdan.

Ayrım kusurludur. Ticket sistemi bir mesajı deterministik ayrıştırma ile yeni metin ile alıntılanmış ya da iletilmiş kısımlara bölebilir ve bazen yanılır: bir müşteri üçüncü bir tarafın metnini kendi mesajına yapıştırabilir ve ayrıştırıcı onu `principal` olarak etiketler. Dolayısıyla bu sınıflandırma, Bölüm 6 ile 7'deki kontrollerin üstüne sezgisel bir katman ekler ve onların yerini almaz. Bir e-postanın gönderen alanı kimlik doğrulama değildir: kimlik ticket sisteminin kaydından gelir (Bölüm 7).

Yayıma: kaybedilmesi kolay olan kısım

Yalnızca ham e-postayı işaretleyen taint yetmez, çünkü model yeniden yazar. Bir özet, bir not, bir satırı alıntılamanın bir yanıt taslağı, bir bellek kaydı: her biri taint'li kaynaklardan kurulmuş yeni bir öğedir ve bağlama işaretli girerse ilk özet taint'i aklamış olur. Bu yüzden türetme miras bırakır: orchestrator'ın taint'li öğelerden kurduğu her şey, Bölüm 9'un özetler ve notlar için zaten gerektirdiği gibi, işaretlerini `derived_from` içinde taşır. Öneri bir tool çağrısı olduğunda orchestrator, modele argümanlarının nereden geldiğini sormaz, çünkü cevap da diğerleri gibi bir öneridir. Bakar.

```
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
```

Bölüm 9'un alan bazındaki kuralı: bir değer, görüldüğü her alanın ya da ticket kesitinin sınıfını alır, en düşük sınıf kazanır; bir token (kişisel bir değer yerine geçen rastgele bir yer tutucu, Bölüm 17 tanıtır) ise vault girdisi (token'ları değerlere geri eşleyen ayrı depo) üzerinden okunur ve girdinin `source_class`'ı, yerine geçtiği kesitlerin en düşük sınıfını tutar. Hem üçüncü taraf bir öğede hem bir system record'da bulunan değer bu yüzden üçüncü taraftır. Ters, izin verilen bir okumanın onu aklamasına yol açardı: enjekte edilen metin başka bir müşterinin sipariş id'sini söyler, model onu okur ve dönen kayıt aynı id'yi içerir. Bir sonucun genel güveninin hiçbir rolü yoktur: bir iade, sipariş aynı zamanda bir kargo şerhi taşıyor diye üçüncü taraf olmaz, çünkü `order_id` ve `amount_minor` system record'dur. Talep edenin yazdığı bir adres principal'dır ve iletilmiş bir bildirimin içindeki aynı adres üçüncü taraftır.

Bir seçim kümesiyle yönetilen argümanlar istisnadır: orchestrator'ın kurduğu kümeye üyelik köken kanıtıdır, bu yüzden `checkTaint` onları izlemez. En düşük sınıf kuralının maliyeti, bir adres gibi serbest bir

argüman iletilmiş metinde de geçtiğinde ara sıra ortaya çıkan yanlış reddir ve bunu kabul ederdim.

Bu bilerek kusurludur. Tam eşleşmeyle izleme, bir öğeden kopyalanmış değeri bulur, dönüştürülmüş olanı kaçırr; `unsourced`'in ayrı bir etiket olmasının nedeni budur: bir kural kaynak gerektiriyorsa gate onu reddeder, gerektirmiyorsa kararı diğer kontroller verir.

Tool ve argüman başına kurallar

Taint, bir kuralla birleştiğinde kontrole dönüşür. Kurallar politika verisinde, tavanla aynı yerde durur ve model onları hiç görmez. Tablo, destek agent'ının tool'ları için örnek kuralları gösterir. "Kilitli" run, üçüncü taraf içeriği okumuş run'dır ve kilit o run'ın geri kalanı için geçerlidir.

Tool ve argüman	İzin verilen kaynak	Run kilitliyen
<code>issue_refund.order_id</code>	Orchestrator'ın kurduğu seçim kümesi (Bölüm 4)	needs approval
<code>issue_refund.amount_minor</code>	<code>lookup_order</code> ve politikadan kodla türetilip seçim kümesiyle birlikte sunulan değer ya da talep edenin belirttiği, bakiye içindeki tutar; talep edenin kesitinden kodla ayrıştırılır ve tam sayı olarak karşılaştırılır	needs approval, tavan ne olursa olsun
<code>update_shipping_address.address</code>	Talep edenin mesajı, <code>checkAuthority</code> 'den sonra (Bölüm 7)	refuse; bir insana hand-off
<code>send_customer_reply.text</code>	Model taslağı, şablondan geçirilerek render edilmiş	needs approval
<code>escalate_to_human.summary</code>	Model taslağı, güvenilmez olarak etiketli	allow; özet güvenilmez olarak gösterilir
<code>lookup_order</code> , <code>get_customer_profile</code> , <code>search_docs</code>	Herhangi biri	allow; okumalar açık kalır

Okumalar açık kalır: okuyamayan kilitli bir run, bir insana ne bulduğunu söyleyemez. Kilit, kimsenin modelin yönlendirildiğini bilmesine gerek kalmadan yönlendirmenin etkisini sınırlar.

Gate'in kontrolü

Taint kontrolü ikiye bölünür, çünkü kilit kararı genellikle bir onay karardır ve Bölüm 2 ile 15 onayı reddedebilecek her kontrolden sonraya koyar. Bir insandan, gate'in reddedeceği bir şeyi onaylaması asla istenmemelidir. İlk yarı argüman kökenine göre reddeder ve diğer erken retlerle (schema, seçim kümesi, yetki) birlikte çalışır. İki fonksiyon da Bölüm 5'teki gate'in kısmi görünümleridir; o bölüm `argument_origin`'i schema ve argüman bağlama kontrollerinden sonra yerleştirir ve `run_locked`'ı reason olarak, `needs_approval` üzerinde ya da kuralı refuse olan tool'lar için bir retle taşır. İkinci yarı en son, sözleşmenin ön koşulları geçildikten sonra çalışır ve ancak o zaman kilitli bir run'ı `needs_approval`'a çevirir; tool'un kuralı öyle diyorsa ret'e.

```
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" }
```

Kilidin kendisi, orchestrator `source_class`'ı `third_party` olan bir alanı derlediğinde atanır ve run store'a yazılır, böylece resume'dan sonra da korunur (Bölüm 10). Alan düzeyindeki işareten iki sonuç çıkar. Müşterinin, notu müşterinin kendisinin yazdığı bir siparişteki kendi iadesi kilitlenmez ve reddedilmez: not `principal`'dır ve argümanlar system-record alanlarına kadar izlenir. Bir kargo şerhi ise run'ı kilitler ve iade bu

durumda ret'e değil onaya gider. Kayıt nedeni, yani run'ı kilitleyen alanların id'lerini taşır; böylece "bu ticket neden Sam'e gönderildi" sorusunun bir cevabı olur ve aynı mesajı okuyan diğer run'lar bulunabilir.

Bir ret, diğerleri gibi modele bir gözlem olarak döner (Bölüm 4) ve run'ın sınırı bunun kaç kez olduğunu sayar (Bölüm 13). Taint kontrolünün reddettiği çağrılar önermeye devam eden bir run, hand-off'a gidecek bir run'dır.

Yetki ikinci duvardır

Bölüm 7'deki devredilmiş yetki, en kötü sonuçlara karşı işin çoğunu yapar ve her injection tartışmasına tespitten değil en az yetkiden başlardım. Başka bir müşterinin siparişi üzerinde işlem yapmaya yönelik enjekte edilmiş bir talimat gate'e ulaşır ve `checkAuthority` metin ne derse desin onu `not_permitted` ile reddeder; agent'ın sahip olmadığı bir tool'a çağrı, bilinmeyen tool olarak reddedilir. Geriye kalan, o yetkinin içinde kalandır: müşterinin kendi siparişinde tavan içinde bir iade, yanıltıcı ifadeli bir yanıt, yanıltmak için yazılmış bir yükseltme özeti. Taint kilidi ortadakini kapsar: müşterinin yetkisi içinde, ama başkasının kışkırtmasıyla.

Çıktı kanalları: çıkış yolunu kapat

Üçüncü koşul, yani dışarı çıkan kanal, en çok tasarım zamanı harcayacağım yerdir, çünkü kesmesi en ucuz olan ve en az kesilen odur. Her dış yan etki ve bir kişinin ya da sistemin okuduğu her serbest metin alanı bir kanaldır. Destek agent'ı için ana kanal `send_customer_reply`'dır ve sözleşmesini Bölüm 15 yazdı. Bu bölüm onu yeniden yazmaz. Injection'a ait kontrolleri, sözleşmenin yer tutucu bıraktığı yerlere ekler.

Modelin parametrelendirdiği bir kanal veri taşımaya yönlendirilebilir, bu yüzden ilk adım parametreleri kaldırmaktır: sözleşmede alıcı alanı yoktur ve gate alıcıyı ticket sisteminden okur. Metnin kendisi yine de sorgu dizesinde veri taşıyan bir bağlantı, müşteriyi Parcelport'un denetimi dışına çıkaran iletişim bilgileri ya da ticket görüntüleyicinin gösterim sırasında getirdiği bir referans taşıyabilir. Kontroller seçimi modelin elinden alır.

- **Bağlantıları model yazmaz, tool kurar.** Yanıt şablonu, takip bağlantılarını runtime'ın tuttuğu bir sipariş id'sinden, allowlist'teki bir

host'a giden biçimde kurar. Modelin taslağındaki, bunlardan biri olmayan bir URL reddedilir. Modelin verdiği hiçbir sorgu dizesi hayatta kalmaz.

- **İletişim bilgileri kapalı bir kümeden gelir ya da ifşa kuralından geçer.** Hangi kişisel verinin görünebileceğine Bölüm 17 karar verir; talep edenin kendi mesajında yazdığı bir tanımlayıcıya izin verir. Buradaki ekleme, bir e-posta adresi ya da telefon numarasının yayımlanmış bir destek kanalı olması ya da Bölüm 17'nin ifşa çizgilerinden geçmesi gerektirir (oradaki bir onay kararı burada geçmiş sayılır); bunun dışındaki her şey kontrolden geçemez.
- **Render edilen referanslar ayıklanır ya da reddedilir.** Ticket görüntüleyicinin gösterimde getirdiği her şey, yanıtın içermeyeceği bir şeydir.
- **Alıntılanan güvenilirmez metin sabit bir alıntı şablonundan geçer.** Bir yanıt müşterinin kendi sözlerini alıntılanmak zorundaysa şablon onları sarar ve uzunluk sınırlıdır.

Bölüm 15'teki sözleşmeye eklemeler aşağıdadır. Ret satırları onun "injection ve taint kontrolü geçer" yer tutucusunun yerini alır; kilit satırı bir ret değil bir onay nedenidir, bu yüzden birleşik sözleşmenin her ön koşulundan, sonucu bilinmeyen ret dahil, sonra onay kararıyla birlikte durur. Gösterim Bölüm 6'dakidir ve sayılar örnektir.

```
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
```

Bağlantı host'larının allowlist'inin bir sahibi olmalıdır ve production'ın ilk haftası, listede olmayan meşru bağlantıyı gösterecektir. İletişim bilgisi kontrolü, müşteriye bir kargo şirketinin deposuna kargocunun verdiği bir numarayla yönlendiren yanıtı reddedecektir. Bu yanlış retleri kabul eder ve hand-off'un numarayı bir insana taşımasını sağladım: varsayılan olarak kapalı olup kanıt üzerine açılan bir kanalı işletmek, açık olup izlenen bir kanalı işletmekten kolaydır.

Diğer kanallar


`escalate_to_human`, özeti okuyan kişiye giden bir kanaldır ve özeti model taint'li içerikten yazdı; bu yüzden güvenilir olarak etiketli gösterilir, asla Parcelport'un kendi beyanı olarak değil (onay ekranından nelerin uzak tutulduğunu Bölüm 15 anlatır). Bir bellek yazımı bir sonraki run'a giden bir kanaldır ve Bölüm 11 gate'ini yazıma koyar. Trace, onu okuyan kişiye giden bir kanaldır (Bölüm 20). Aynı envanter her birine uygulanır: kim parametrelendirebilir ve modelin seçebileceği en küçük kapalı küme nedir.

Reader'ı actor'dan ayırmak

Birinci koşula karşı en güçlü yapısal hamle, eyleme geçebilen bir modele güvenmemesi gereken metni vermemektir. Örüntü bir reader ve bir actor'dır; farklı bağlamlar ve farklı yeteneklerle iki ayrı model çağrısı olarak çalıştırılır.

Reader, güvenilir içerici alır ve hiç tool'u yoktur. İş, içeriği kısıtlı bir yapıya çevirmektir: küçük bir tipli alan kümesi, mümkün olduğunda kapalı enumeration'lar, olmadığında sınırlı serbest metin. **Actor**, tool çağrısı öneren model çağrısıdır. Yapıyı köken etiketiyle ve orchestrator'ın tuttuğu güvenilir olgularla alır, ham e-postayı almaz.

Reader ele geçirilebilir ve bunu önce ben söyledim. Değişen, ele geçirilmiş bir reader'ın neler yapabildiğidir: tool'u, credential'ı ve sabit şekilli bir çıktıdan başka kanalı yoktur; dolayısıyla saldırganın etkisi dar bir alandan geçmek zorundadır.



```

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
  
```

Yapılı alanlar yapılı oldukları için temiz değildir: ele geçirilmiş bir reader, müşteri bir durum sorusu sorduğunda yine de `requested_action:` refund seçebilir. Schema, seçimi müşterinin zaten yapabileceği birkaç seçenekle sınırlar ve serbest metni küçük, etiketli, sınırlı tek bir alan yapar. Orchestrator `order_refs`'i yalnızca aday olarak ele alır; run'ın işlem yaptığı sipariş seçim kümesinden gelir.

Maliyetler, ticket başına ek bir model çağrısı, kaybolan nüans (hiçbir enumeration'a uymayan bir mesaj `other`'a ve sonra bir insana gider), kendine ait eval vakaları (Bölüm 21) ve schema için bir sahiptir, çünkü özensizce eklenen bir alan kanalı genişletir. Örüntüyü, agent çok sayıda üçüncü taraf içerik okuyup önemli tool'lara sahip olduğunda kullanırdım. Küçük bir agent için taint kilidi ve seçim kümesiyle tek model çağrısı makul bir başlangıçtır.

Tespit yardımcı olur, gate değildir

Metne injection puanı veren bir sınıflandırıcı makul bir bileşendir ve "makul bileşen" ile "kontrol" arasındaki boşluk bu başlığın konusudur. Bir ıskalama yönlendirilmiş bir önerinin geçmesine izin verir ve tahmin edilebilir bir dedektör, birine üzerinde iterasyon yapacağı bir hedef verir. Bu alanda yanlış pozitifler yaygındır: "paketi kapının arkasına bırakın ve iki kez zil çalın" yazan bir müşteri, doğru biçimde, bir teslimat sürecine talimat yazmıştır.

Bu yüzden sınıflandırıcıyı iki kuralla bir sinyal üretmek için kullanırdım. Taint'i yükseltebilir, asla düşüremez: "şüpheli" bir run'ı kilitleyebilir, bir ticket'ı bir insana gönderebilir ya da bir sayacı artırabilir; "temiz" ise hiçbir şeyi değiştirmez, çünkü bir run'ın kilidini açabilecek temiz kararı sınıflandırıcıyı gate yapar ve ıskalamalarını etkilere dönüştürür. Ve derlemeden önce içerik üzerinde, orchestrator'da, modelin erişiminin dışında çalışır.

Sözleşmeler, ön koşullar ve onay

Bölüm 6'daki sözleşmelerin ön koşulları, gate'in okuduğu olgular üzerinden ifade edilmelidir, asla metin üzerinden değil. "Sipariş bu run'ın müşterisine aittir", `orders-service` hakkında bir ifadedir; "yanıt allowlist dışında bir bağlantı içermez", render edilmiş baytlar hakkında bir ifadedir. "Ticket şunu istiyor" diye başlayan bir ön koşul, güvenilir metni karara geri sokmuştur.


Onay, kuralların karara bağlayamadığı şeyler için yedek yoldur ve taint'in pahalılaştığı yer burasıdır. Her ticket kilitlenirse queue'da Bölüm 15'in anlattığı sorun olur: birbirine neredeyse özdeş onaylar ve okumayı bırakan

bir insan. `principal` ve `third_party` sınıflandırması kilit oranını düşük tutar; onayları nedene göre ölçmek gerekir (`run_locked` ile `above_ceiling` karşılaştırması).

Uyarı: Bir onay, bir taint'i geri almaz. Kilitli bir run'da bir çağrıyı onaylayan kişi, Bölüm 15'in anlattığı gibi argümanlarına bağlı o çağrının tam kendisini kabul etmiştir. Run'ın geri kalanını güvenilir kılmamıştır ve kilit sonraki step'ler için açık kalır.

Bir e-postayı katmanlardan geçirmek

Açılışa dönelim. Hasarlı paket e-postasına, imzanın altındaki blok dahil, her katmanın ne yaptığı aşağıdadır; bloğun ayrıntılarına tasarım bağımlı değildir. Diyagram tek bir öneriyi izler; her ret kendi reason'ını adlandırır, çünkü on-call mühendisin arayacağı şey reason'lardır.



Sınıflandırıcı yolun üzerinde bir duraktır ve kararına hiçbir şey bağlı değildir; sağdaki her ret, e-postayı işaretlemiş olsa da olmasa da gerçekleşir. Onay en sona gelir, böylece Sam yalnızca gate'in reddedemediği çağrıları görür. Tablo, bloktaki dört talebin her biri için sonucu verir; actor'ın hepsini izlediği en kötü durum varsayılmıştır.

Bloğun istediği	Durduran katman	Kaydın gösterdiği reason	Geriye kalan
Ticket'a ait olmayan bir sipariş için iade	Seçim kümesi; arkasında <code>checkAuthority</code>	<code>not_in_choice_set</code> , sonra <code>not_permitted</code>	Hiçbir şey: id hiç sunulmadı
Ticket'ın kendi siparişinde daha büyük bir tutar	İade edilebilir bakiye reddeder; tavanın üstünde onay; taint kilidi en sonda	Bakiye için <code>precondition_failed</code> ; tavanın üstünde <code>above_ceiling</code> ; ön koşullar geçerse <code>run_locked</code> ile <code>needs_approval</code> (ayırıştırıcı bloğu alınıldı ya da sınıflandırıcı taint'i yükseltti)	Sam yalnızca gate'in reddedemediği bir çağrı görür; kilit nedeni ve modelin açıklaması en sonda

Bloğun istediği	Durduran katman	Kaydın gösterdiği reason	Geriye kalan
Yanıta profil bilgileri ve bir bağlantı	Çıktı kanalı ön koşulları	<code>precondition_failed</code> , <code>details.check</code> bağlantıyı ya da iletişim satırını adlandırır	Onlar olmadan bir yanıt, ya da hiç yanıt yok
Bir iadenin onaylandığını ileri süren ifade	İddia kontrolü (Bölüm 2)	<code>refuse</code> , <code>reason</code> <code>ungrounded_claim</code>	Model yeniden taslak yazar ya da hand-off yapar

Katmanlar farklı şeyleri farklı nedenlerle durdurur ve hiçbir modelin injection'ı tanımış olmasına bağlı değildir. Son sütun da her satırda boş değildir. Tavan içinde, doğru sipariş üzerinde, müşterinin kendi metninin istediği tutar için bir iade, yönlendirilmiş bir öneri için hâlâ mümkündür, çünkü müşterinin istemeye hakkı olan tam olarak odur. E-posta öneriyi oraya yönlendirdiyse hiçbir kontrol bir fark görmez ve görmesi gerektiğini de düşünmüyorum: meşru iadeleri reddetmek, kontrolün kaçınmak için var olduğu maliyettir.

Ops agent: log'lar, runbook'lar ve bir pull request

Aynı akıl yürütme ops agent'a farklı ayaklarla uygulanır. Güvenilmez içeriği log'lardır (bir satır dışarıdan gelen bir alanı yansıtabilir), düzenlenebilir iç sayfalar, trace'ler ve diğer tool sonuçlarıdır; erişimi geniştir ve çoğunlukla salt okunurdur (Bölüm 7); dışarı çıkan kanalları bir pull request'in metni, Robin'e giden bir mesaj ve onay kapılı yazma tool'larının argümanlarıdır. Kesme etkiler üzerindedir.

`toggle_feature_flag` ve `request_rollback` her zaman onayın arkasındadır, bu yüzden taint onay ekranına yalnızca kilit nedenini ekler. `open_pull_request`'in gövdesi bir kanaldır, bu yüzden Bölüm 18'in kontrolleri onu credential'lar için denetler. `run_diagnostic`'in çıktısı da güvenilmezdir (Bölüm 19). Reader, uzun bir aralıktaki log'ları özetlerken maliyetini çıkarır, çünkü özet bir sonraki step'in bağlamına girer ve işaretli gelmelidir.

Injection vakalarını eval'e koymak

Test edilmeyen kontrol bir inançtır. Eval suite'inin nasıl kurulacağı Bölüm 21'e aittir; bu bölüm bir injection vakasının neleri içerdiğini ve neyi doğruladığını söyler.

Bir injection vakası, golden set'te yerleştirilmiş bir talimat, run'ın okuyacağı olgular ve beklenen bir etki kümesi taşıyan bir ticket'tır. Yerleştirilen talimat etkisizdir: yalnızca test ortamında var olan ve çağrıldığını kaydeden zararsız örnek bir tool'a çağrı ister ya da fixture'ların müşteriye ait olmadığını bildiği bir sipariş için iade ister. Vakaları, bölümün başındaki tablodaki her kanalı her önemli tool'la çaprazlayarak kurmak gerekir.

```
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)
```

Doğrulamalar, modelin ne söylediği üzerinde değil, etkiler ve gate kararları üzerindedir: yerleştirilmiş eylemi her seferinde öneren ve gate tarafından durdurulan bir model geçer. "attempt" satırı, bir prompt değişikliğinin ya da model değişiminin oynatacağı bir orandır; "effect" satırı bir özelliktir ve hedef sıfırdır.

Normal ticket'ların yine tamamlandığını kanıtlayan vakaları da tutmak gerekir: sıradan golden ticket'ların kilitle biten payını saymak ve artışı, başarısız bir injection vakası gibi regresyon saymak gerekir.

Trade-off'lar ve maliyetler

Bu bölümdeki her kontrolün bir maliyeti var ve maliyet insanlara düşer.

- **Onaylar.** Taint kilidi Sam için queue yükü ve müşteri için gecikme ekler. Değeri, üçüncü taraf içeriğin dar tanımına bağlıdır; bu her serbest metin alanına genişlerse onay, Bölüm 15'teki tiyatroya dönüşür.
- **Gecikme, harcama ve nüans.** Reader ticket başına bir model çağrısı ekler ve bilgiyi bilerek eler; tek çağrının halledebileceği bazı ticket'lar bir insana gider.
- **Yanlış retler.** Bağlantı allowlist'leri, iletişim kontrolleri ve köken kuralları meşru içeriği reddeder ve istisnaların bir sahibi olmalıdır.
- **Bakım.** Politika tabloları, kaynak sınıfları, reader schema'sı ve eval vakaları eskir. Bir tool sonucuna sınıfsız eklenen serbest metin alanı bir kapı açmıştır.
- **Artık risk.** Geriye kalan, principal'ın elindeki yetki, okumadan onaylayan bir insan ve sınıflandırıcı ile reader'ın ikisinin birden kaçırdığı şeydir; gate son dürüst hattır.

Hangisini ne zaman kullanmamalı. Bir agent'ın okumanın ötesinde bir etkisi ve dışarı çıkan bir kanalı yoksa reader ve taint kilidi gereğinden fazla inşa edilmiştir. İçerik kendi çalışanlarınca yazılıp review ediliyorsa, "review edildi" yalnızca umulan değil, gerçekten doğruysa, onu **owned** saymak gerekir.

Sık yapılan hatalar

- **Sistem prompt'undaki cümleyi ya da ayraçları ve etiketleri kontrol saymak.** Cazip, çünkü bir dakika sürüyor ve demo çalışıyor. Hata sinyali olmayan bir istektir ve çit, yazarın taklit edebileceği bir gelenektir. Bunlar kalabilir, ama kontrol gate'e konmalı ve kodda taşınan **trust** ve taint alanlarını kullanmalıdır.
- **Sınıflandırıcıyı gate olarak kullanmak.** Cazip, çünkü bir puan karar gibi görünüyor. Iskalamaları etkidir, yanlış pozitifleri müşteridir. Taint'i yükseltmek ve ölçmek için kullanmak ve temiz bir kararın bir işareti düşürmesine asla izin vermemek gerekir.
- **E-postayı işaretleyip ondan türetilenleri işaretlememek.** Cazip, çünkü e-posta görünen girdi. İşaretlerini kaybeden bir özet, not ya da bellek kaydı, taşıdığı içeriği aklamıştır. Türetilen değer işaretleri kodda

miras alır ve Bölüm 11'deki bellek yazımı da bir türetmedir; izin verilen bir okumadan geçen değer de öyle.

- **İç kaynaklara güvenmek.** Cazip, çünkü "iç" güvenli hissettiriyor. Bir runbook sayfası, bir log satırı, bir bellek kaydı ve bir siparişteki bir not, hepsi Parcelport dışından birinin yazdığı metni taşıyabilir. İçeriğin nerede saklandığına göre değil, kimin yazdığına göre karar vermek ve yalnızca ticket'ı değil, her gözlemi işaretlemek gerekir.
- **Alıcıyı, bağlantıyı ya da iletişim bilgisini modelin adlandırmasına izin vermek.** Cazip, çünkü model zaten yanıtın tamamını taslak olarak yazıyor. Modelin parametrelendirebildiği bir kanal, modelin kullanmaya yönlendirilebileceği bir kanaldır. Parametreyi kaldırmak ya da ona kapalı bir küme vermek gerekir.
- **Onaylayana ham metni göstermek.** Cazip, çünkü onaylayan bağlam istiyor. Onaylayan da güvenilmez içeriğin bir okuyucusudur: çağrıyı, olguları ve kilit nedenini göstermek ve aslını isteyen için ticket'a bağlantı vermek gerekir.
- **Modele sorarak test etmek.** Cazip, çünkü tek satırlık bir kontrol. "Bunu izler miydin?" bir oranı ölçer ve özellik hakkında hiçbir şey söylemez. Etkiler ve kararlar üzerinden doğrulamak ve reader'a hiç tool vermemek gerekir: gönderme tool'u olan bir reader bir actor'dır.

Temel çıkarımlar

- Model talimatları ve veriyi tek bir dizide alır, bu yüzden prompt injection modelin dışında ele alınır: bağlamın yapısında ve gate'te. Bir prompt bir oranı düşürür, kontrol değildir.
- Zarar, güvenilmez içeriğin, erişimin ve dışarı çıkan kanalın aynı run'da bulunmasını gerektirir; her tool için üçünden hangisinin kesildiğine kodda karar vermek gerekir.
- Taint alan bazında değerlendirilir ve türetilmiş değerlerle birlikte yolculuk eder, en zayıf kaynak kazanır: hassas argümanlar güvenilir kaynaklardan gelmelidir ve kilitli bir run önemli eylemler için bir insana ihtiyaç duyar; onay, reddedebilecek her kontrolden sonra gelir.
- Çıktı kanalları, seçimleri modelin elinden alarak kapatılır: alıcı, bağlantı host'ları ve iletişim bilgileri runtime'ın tuttuğu kümelerden gelir.

- Tool'suz ve sabit schema'lı bir reader, actor'a ulaşanı daraltır; bedeli bir model çağrısı ve kaybolan nüanstır.
- Injection vakaları etkiler ve gate kararları üzerinde doğrulama yapar: attempt oranı bilgidir, effect oranı sıfırda tutulur.

Aynı ticket müşterinin adını, adresini ve sipariş geçmişini de taşıyor.

Bölüm 17 bu kişisel veriyi sistem içinde izler ve nerede bulunmasına izin verildiğine karar verir.

Bölüm 17 — PII

Parcelport'un güvenlik ekibinden Jordan'ın bir tasarım review'u öncesinde tek bir soru sorduğunu varsayalım: `cus-0042` müşterisinin telefon numarası şu anda nerede? Destek agent'ını işleten ekip cevap vermeye başlıyor ve bir türlü bitiremiyor. `customer-service`'te var, beklenen bu. Ticket'ta var, çünkü müşteri onu bir mesaja yazdı. Agent'ın ikinci step'te okuduğu tool sonucunda var, çünkü `get_customer_profile` bütün profili döndürüyor. Model sağlayıcısına gönderilen bağlamda, o run için saklanan trace'te, bellek store'unun yazdığı bir notta, geçen ay yeni bir grader gerçek vakalara sahip olsun diye eval set'ine kopyalanan bir ticket'ta ve Sam'in bir iadeyi onayladığı ekranda var.

Bu yerleşimleri kimse seçmedi. Her biri yapıldığı gün makul bir varsayılandı. Jordan'ın sorusunun cevabı bir öğleden sonra sürdü ve yine de eksikti, çünkü `cus-0042` Parcelport'tan bunları kaldırmasını isteseydi ekip her kopyayı nasıl bulacağını söyleyemiyordu.

Bu bölüm sorunun ardındaki soruyu cevaplar: kişiyi tanımlayabilen bilgi (PII) bir agent'ın içinde nerelerden akar ve her noktada hangi kontrol durur? Kontrol zarfının iki parçasına aittir. **Bağlam** için soru, modelin ne gördüğü ve buna ihtiyacı olup olmadığıdır. **Kayıt** için soru, bir run'ın kanıtının bir kişi hakkında neyi ne kadar süreyle tuttuğudur.

Sorun ve neden zor olduğu

PII, bu kitabın terimleriyle, bir kişiyi tanımlayan ya da bir kişiyle ilişkilendirilebilen her değerdir. Parcelport'ta bu, bariz alanlar (`full_name`, `email`, `phone`, `recipient_name`), adresler (`delivery_address`, `billing_address`), PII'ye yakın ödeme alanları (`payment_reference`, `card_last_four`) ve ticket'lardaki ve e-postalardaki, yukarıdakilerin hepsini her biçimde içerebilen serbest metin

demektir. `cus-0042` gibi opak bir id kendi başına tanımlayıcı değildir, ama tanımlayıcı olan her şeye bağlanır; bu da onu bir silme işleminin başlaması gereken anahtar yapar.

Bir agent bu veriyi geleneksel bir servisten daha fazla yayar: modelin bir şeyi bilmesinin tek yolu onu bağlamda tutmaktır ve bağlamdaki her şey kopyalanır: model sağlayıcısına, run store'a (Bölüm 10), trace pipeline'ına ve çoğu zaman bellek store'una ve eval suite'ine.

Sekiz yer önemlidir ve ilk yedisi PII'nin tutulduğu yerlerdir:

- **Bağlam.** Ticket metni, assembler'ın olduğu gibi geçirdiği tool sonuçları ve modelin kendi taslakları; bunlar kendisine gösterileni yansıtır.
- **Model sağlayıcısı.** Bağlam her model çağrısında, model gateway üzerinden Parcelport'tan çıkar.
- **Log'lar ve trace'ler.** Debug için yazılan span'ler, render edilmiş bağlamlar ve tool sonuçları.
- **Bellek.** Run'dan uzun yaşayan girdiler (Bölüm 11).
- **Eval set'leri.** Golden set'lere kopyalanan gerçek ticket'lar.
- **Tool çıktısı.** Görevin ihtiyacından fazla alan döndüren bir tool ve PII'yi ops agent'ının bağlamına taşıyan log satırları.
- **Onay ekranı.** Bir kişi bekleyen eylemi görür ve birisi ekrandan kopyaladığında ekran başlı başına bir store'dur.

Sekizincisi ayrılandır: cevap. `send_customer_reply`, PII'nin Parcelport'un sınırını geçtiği noktadır ve sözleşmesini Bölüm 15 yazdı.

Dört hata sınıfı burada buluşur. **F7 (yetkisiz etki)** manşettir: müşteri A'nın adresini müşteri B'ye taşıyan bir cevap, bu principal'ın bu run'da doğurabilmemesi gereken bir dış yan etkidir. **F8 (gözlenmeyen davranış)** iki kez görünür. Kimsenin envanterini çıkarmadığı kopyalar, hareket etmiş ve nereye gittiğine dair kullanılabilir kanıt bırakmamış veridir; on-call'ın run'ı yeniden kuramayacağı kadar sert redakte edilmiş bir trace ise aynı sınıfın öbür yüzüdür. **F4 (talimat ele geçirme)** PII'yi bir hedefe çevirir: bir ticket'taki ya da iletilmiş bir e-postadaki, agent'ı kişisel veriyi giden bir mesaja koymaya yönlendiren içerik bir exfiltration yoludur; Bölüm 16 bunu prompt injection sorunu olarak ele alır, bu bölüm ise veri sorunu

olarak. **F5 (kontrolden çıkan döngü ya da bayat bağlam)** bayat kopyalar olarak ortaya çıkar; müşterinin değiştirdiği bir telefon numarasını koruyan bir not gibi.

Bariz yaklaşım prompt'ta bir cümledir: müşteriye ait olmayan kişisel bilgileri asla ifşa etme. Yazardım, ama o bir istektir ve listedeki diğer yerlere ulaşamaz: trace pipeline'ının neyi sakladığına ya da bir silmenin neyi bulması gerektiğine karar vermez. İkinci bariz yaklaşım, nihai metni PII'ye benzeyen şeyler için taramak, sahip olmaya değer ve tarayıcının tanımadığını ıskalar. İkisi de PII'yi tek bir çıktının özelliği olarak görür; oysa o, her kaynakta ve her çıkışta bir kontrolü olan bütün veri akışının özelliğidir.

Alanları bir kez sınıflandır

Kontrollerin iliştilereceği sınıflara ihtiyaç vardır. Onlar olmadan her ekip "hassas şeyler" in kendi özel listesini yazar ve listeler birbirini tutmaz. Sınıflandırmayı bir kez, orchestrator'ın ve gateway'in okuduğu politikada yazar ve her sınıfa varsayılan bir işleme biçimi iliştilirdim.

Sınıf	Parcelport alanları	Varsayılan işleme
Doğrudan tanımlayıcılar	full_name, recipient_name, email, phone	Bağlamda token'larla değiştirilir; ham hâliyle asla log'lanmaz
Konumlar	delivery_address, billing_address	Token'larla değiştirilir; model bunun yerine türetilmiş nitelikleri (hizmet verilen bölge, teslimat durumu) alır
PII'ye yakın	payment_reference, card_last_four	payment_reference bağlama asla girmez; card_last_four yalnızca maskeli biçimde
Serbest metin	Ticket gövdeleri, iletilmiş e-postalar, teslimat notları, log satırları	Alana göre sınıflandırılmaz; sınırda bilinen değer değiştirme ve dedektörler
Opak id'ler	cus-0042, ord-7f3k2m91, run-id	Log'larda serbest; her kopyanın bulunduğu anahtarlar bunlardır

Serbest metin ayrı bir sınıftır, çünkü bir alan adı müşterinin ne yazdığı hakkında hiçbir şey söylemez; alan bazlı kontrolleri boşa çıkarır ve hata oranlarıyla birlikte dedektör bazlı kontroller alır. Opak id'ler log'larda bilerek serbesttir, çünkü birleştiremeyen bir silme bulamaz.

Minimizasyon: tool, görevin ihtiyacı olanı döndürür

Korunması en ucuz PII, modelin hiç görmediğidir. Bir alan işe yarayabilir diye bütün profili döndüren tool, bütün profili bağlama, sağlayıcının isteğine, trace'e ve bellek yazıcısının girdisine taşır. Minimizasyon kararı modelden ("ihtiyacım olmayanı yok sayacağım") tool'a ("bu görev şu alanları alır") taşır. Bölüm 5, `shape0bservation` içindeki projeksiyon adımını gösterir; bu bölüm onu yürüten tabloyu ekler: veri olarak yazılmış, görev başına bir politika.

Sonraki blok örnek bir gösterimdedir: alanlar görev başına listelenir ve listelenmeyen hiçbir şey döndürülmez.

```
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
```

Türetilmiş alanlar ağırlığın çoğunu taşır. `contact_matches`, `customer-service`'in ticket göndericisini profile karşılaştırarak hesapladığı bir boolean'dır; model, e-posta adresini görmeden eşleşip eşleşmediğini öğrenir. `delivery_region`, sokağı göstermeden "bu varış noktasına hizmet veriliyor mu" sorusunu cevaplar.

Görev tipi orchestrator'dan, kapalı bir listeden gelir. Onu bir model sınıflandırıcısı seçiyorsa, seçim listeye karşı kontrol edilen bir öneridir ve politikanın tanımadığı bir görev en dar projeksiyonu alır. Yanlış sınıflandırma o zaman modele daha az veri verir, asla daha fazla değil ve bedeli daha kötü bir cevap ya da bir hand-off'tur.

Token'lar: model yer tutucularla çalışır, kod onları çözer

Minimizasyonun bir sınırı var: bazı görevler modelin bir değeri işlemlerini gerektirir. Bir müşteri ticket'a yeni bir teslimat adresi yazar ve model onunla `update_shipping_address` önerir. **Pseudonymization** buna cevap verir: değer, model görmeden önce bir yer tutucuyla değiştirilir; model yer tutucuyla çalışır ve kod gerçek değeri kullanılması gereken yere koyar. Yer tutucuya **token**, token'ları değerlere eşleyen store'a **vault** diyeceğim.

Modelin çağırısı önermek için adresin karakterlerine hiç ihtiyacı yoktur. Önerdiği argüman token'dır ve tool gateway onu sınırdan çözer: gate çağırısı izin verdikten sonra, tool çalışmadan önce.

```
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
```

Burada dört tasarım seçimi görünür. Token'lar **run kapsamlıdır**: iki run'daki aynı adres iki token alır, çünkü sabit token'lar trace okuyan birinin bir müşterinin ticket'larını birbirine bağlamasına izin verirdi ve bir kapsam hatası bir müşterinin token'ını bir başkasının run'ında anlamlı kılardı. Run'lar arası süreklilik, hiçbir iletişim bilgisi tutmayan Bölüm 11'deki tipli bellekten gelmelidir. Id rastgeledir ve arama anahtarlı bir hash kullanır. Vault kendi credential'ları olan (Bölüm 18) ayrı bir sistemdir ve kısa bir yaşam süresi vardır, örneğin run'ın bitiminden birkaç gün sonrası. Her girdi, değer kime ait olduğunu (`subject_id`; giden kontrol sonradan buna dayanır) ve geldiği kesitin sınıfını (`source_class`; Bölüm 16'nın gate'i bunu okur) kaydeder; aynı değer ikinci bir kesitte çıktığında girdi daha düşük sınıfı tutar.

Çözme öbür yarıdır ve gösterilmesi gereken hata yolları vardır. Vault'un tanımadığı bir token bu run'da hiç verilmemiştir, yani modelin ürettiği bir token'dır; bu, kontrolün ret'e çevirdiği dayanaksız bir iddiadır (F3).

Verilmiş ve süresi dolmuş bir token ise aşağıda ayrıca ele alınır.

```
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))
```

Gate, bilinmeyen ve yabancı durumları bir reason code'la "refuse" kararına çevirir ve ret, hiçbir değer adlandırmayan bir gözlem olarak bağlama döner. Süresi dolmuş bir token da reddedilir, ama verilmiştir, bu yüzden dayanaksız bir iddia (F3) değildir; ikisini ayırt etmek için vault, süresi dolmuş bir girdiyi silmeden önce bir ek süre boyunca tombstone olarak (expires ve subject_id, değer yok) tutar. Süre dolması uzun bir onay beklemesi sırasında olur ve orchestrator yeniden render eder; bu da eski render'ı kapsayan her onayı geçersiz kılar.

Vault yazımları ve run store yazımları ayrı sistemlerdir, bu yüzden sıra önemlidir (Bölüm 5'in etkilerin sistemler arasında asla sarmalanmayacağı kuralı burada da geçerlidir). Önce vault girdisi, sonra token'ı taşıyan gözlem yazılır. İkinci yazım başarısız olursa yetim bir vault girdisi kalır ve kısa yaşam süresi onu kaldırır; eşleşen run'ı olmayan vault girdilerini listeleyen bir reaper job tespit yoludur.

Not: Pseudonymization anonymization değildir. Vault her token'ı geri çevirebilir, bu yüzden token'lanmış kayıtlar bir reviewer'ın önemseyeceği anlamda kişisel veri olarak kalır ve token'ların dışındaki serbest metin yine de birini tanımlayabilir. Kayıtların hangi kategoriye girdiği, hukuk ve uyum ekibine sorulacak bir sorudur.

Model bir token'ın içeriği hakkında akıl yürütemez. Token'lanmış bir adres için "başka bir ülkede" denemez, bu yüzden bu yargı koda taşınır: tool adresi doğrular ve address_region gibi türetilmiş bir nitelik bağlama

ulaşır. Modelin yorumlaması gereken serbest metin bir teslimat talimatı token'lanmaz; kayıttaki minimizasyon ve redaction onun kontrolleridir ve istisna nedeniyle birlikte politikaya yazılır.

Kayıtta redaction

Bir run'ın yazdığı her şey bir kopyadır ve kopyalar run'lardan uzun yaşar. Buradaki redaction, yazma anında redaction demektir: değer log store'una ya da trace store'una asla açık hâliyle ulaşmaz. Okurken redakte etmek, ham veriyi store'da bırakır.

Log'lar ve trace'ler

İşin çoğunu iki teknik yapar ve biri dedektör değildir. Birincisi, olay türü başına bir **loglanabilir alan allowlist**'idir: listede olmayan alan düşürülür, böylece bir servisin yarın eklediği yeni bir alan, biri onun girmesine karar verene kadar log'a ulaşmaz. İkincisi **bilinen değer değiştirmez**. Orchestrator her run için vault'a koyduğu tam değerleri tutar; serbest metinde bu tam dizeleri arayıp değiştirebilir.

E-posta ya da telefon numarası biçimindeki şeyler gibi örüntü dedektörleri, bunun ardından best-effort bir ağ olarak çalışır. Tam eşleşmenin yakalayamadığını, örneğin müşterinin yazdığı ama vault'a hiç girmemiş bir numarayı yakalarlar ve sınıfına benzemeyeni kaçıırırlar: bir cümledeki isim, alışılmadık bir sırayla yazılmış adres.

```
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
```

Öğretici kısım hata yoludur. Vault çökmüşse yazıcı ham metne geri düşmez; serbest metni atlar ve bunu söyler. Kayıta bir delik vardır ve delik görünür. Sürüm damgasının bir kullanımı var: bir dedektör iyileştirildiğinde bir job eski sürümle yazılmış kayıtları bulup yeniden redakte edebilir. Trace pipeline'ının neyi kaydettiğine Bölüm 20 sahiptir; bu bölüm ona ulaşan her şeyin bu fonksiyondan geçmiş olması kuralına sahiptir.

Uyarı: Debug sırasında ham tool sonuçlarını, render edilmiş bağlamları ya da cevap taslaklarını "geçici olarak" log'lamamak gerekir. Log store'undaki ham bir kopya, silmenin, saklama süresinin ve erişim review'unun bilmediği bir kopyadır ve geçici loglama kalıcı olma huyuna sahiptir. On-call bir run'ın ham verisine ihtiyaç duyuyorsa, ona vault üzerinden denetlenen, süresi dolan bir reveal verilmelidir.

Eval set'leri

Gerçek ticket'lar iyi eval vakaları olur ve mühendislerin unuttuğu PII yoludur, çünkü production'dan bir export ile çıkıp bir repository'ye düşerler. Bir golden set'in nasıl kurulduğunu Bölüm 21 anlatır; bir ticket'a o set'e girmeden önce ne olması gerektiği buraya aittir.

Gerçek bir ticket'ı bir golden set'e yalnızca tanımlı bir yoldan kabul ederdim: aynı fonksiyonla redakte edilir, vaka anlamını korusun diye tür koruyan yer tutucular kullanılır (bir isim boşluk değil `person-017` olur); sonuç kabul edilmeden önce bir insana okutulur; kaynak ticket id'si de hash'lenmiş olarak ayrı, erişimi denetlenen bir dizinde saklanır. Bir silme talebinin eval set'ine ulaşmasını sağlayan o dizindir. Review pahalı adımdır ve hiçbir dedektörün bulamayacağını bulur: birini koşullarıyla tanımlayan bir cümle.

Redaction'ın yapamadığı

Redaction maruziyeti azaltır, riski ortadan kaldırmaz. İsimleri ve adresleri çıkarılmış bir kayıt, alışılmadık bir ürün, küçük bir kasaba ve bir tarih yoluyla yine de bir kişiyi tanımlayabilir; bu yüzden redakte edilmiş veri

eriřim kontrolünü, bir saklama süresini ve envanterde bir yeri korur. Ařırı redaction yine F8'dir: her alanın [omitted] olduđu bir trace kimseye yardım etmez.

Sađlayıcı sınırı

Her model çağrısı bađlamı Parcelport'un dıřına gönderir. Model gateway bütün çağrıların geçtiđi tek yerdir ve bu onu dođal uygulama noktası yapar; uyguladıđı sorular yalnızca mühendislik soruları deđildir.

Bu konumdaki bir ekip, her sađlayıcı bađlantısı için buna benzer bir listeye yazılı cevaplar isteyecektir:

- İstek, cevaptan sonra saklanıyor mu, ne kadar süreyle ve kötüye kullanım izleme ya da destek eriřimi dahil kimler okuyabilir?
- Modelleri eđitmek ya da iyileřtirmek için varsayılan olarak ya da bir ayarla kullanılıyor mu?
- Nerede işleniyor ve saklanıyor, hangi alt işleyicilerle?
- Bir silme talebi ona ulařıyor mu, hangi mekanizmayla ve ne kadar gecikmeyle?
- Sađlayıcı tarafındaki dashboard'lar ya da loglama tool'ları ekibin denetlemediđi kopyalar tutuyor mu?

Cevaplar sözleşmede ve hesap yapılandırmasında yařar, sađlayıcılar ve planlar arasında farklılařır ve deđiřir. Bu yüzden cevabı bađlantı bařına, bir tarihle ve güvenlik ya da hukuk tarafında bir sahiple kaydederdim ve gateway'in, her agent'ın hatırlamasına güvenmek yerine bađlantı bařına bir veri sınıfı uygulamasını sađlardım. Mühendislik katkısı, cevapların yazıya dökülmesi ve kodda kontrol edilmesidir; ne anlama geldiklerinin sahibi hukuk ve uyum ekipleridir.

Assembler her bađlam öđesini, Bölüm 9'daki köken ve güven etiketlerinin yanında bir veri sınıfıyla etiketler: politika dokümanları için `public`, projekte edilmiř ve token'lanmıř materyal için `minimized`, hâlâ kiřisel deđer taşıyan her řey için `raw`. Blok yine örnek gösterimi kullanır.

```

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

```

Fallback satırına bakılmalıdır. Bölüm 14, fallback modeli stres altında izlenen bir yol yapar ve bir fallback sağlayıcısı kendi koşulları olan başka bir alıcıdır. Birincil sağlayıcının aldığı veri için review edilmemişse, birincil kesintisinde doğru davranış degraded mode, bir hand-off ya da veri içermeyen bir cevaptır; cevap veren herhangi bir bağlantıya sessizce göndermek değil.

minimized, "temiz" değil "azaltılmış" olarak ele alınmalıdır: dedektörlerden sağ çıkan serbest metin yine sağlayıcıya gider.

İzolasyon: müşteri A'nın verisi müşteri B'nin cevabında

En pahalıya mal olan sızıntı müşteriler arasındakidir, çünkü veride hak iddiası olmayan bir kişiye yapılan bir ifşadır. Bölüm 7 ve 11 müşteri sınırını gate'e ve bellek kayıtlarına koyar. Kalan yollar aynı şekli paylaşır: bir şey bir kez saklanıyor ya da hesaplanıyor ve yeniden kullanılıyor, yeniden kullanımın anahtarı da müşteriye içermiyor.

Yol	Nasıl sızır	Kontrol
Paylaşılan store'lar ve örnekler: cache'ler, few-shot örnekler, geçmiş ticket'lar üzerindeki indeksler, havuzlanmış worker state'i	Bir kez saklanan bir şey başka bir müşterinin run'ına döner: soru metnine anahtarlanmış bir cache hit'i, örnek olarak yapıştırılmış gerçek bir ticket, getirilen bir pasajdaki bir yabancıнын bilgileri	Her cache anahtarında müşteri kapsamı; örnekler ve indeksler yalnızca redakte edilmiş, review edilmiş yoldan; run kapsamlı state run sonunda temizlenir, Bölüm 10'daki subject lock'la birlikte
Çapraz özne içerik: birkaç kişiyi adlandıran bir ticket, başkasının sipariş id'si üzerinde bir arama	İsteğin kendisi başka bir kişinin değerlerine uzanır	Üçüncü taraf değerleri token'lanır ve talep eden yazmadıkça giden metne çözülmez; gate'te sahiplik ön koşulu (Bölüm 7)

Son savunma hattı çıkış yolundadır ve vault'u kullanır. Model token'larla çalıştığı için bir cevap içerdikleri açısından kontrol edilebilir: her token, öznesi talep eden olan bir değere çözülmelidir ve bir token'ın dışındaki tanımlayıcıya benzeyen her şey bir bayraktır. Bu kontrol modelin düzgün davranmış olmasına bağlı değildir. Vault'un run başına kapsamlanmasına bağlıdır ve kapsamlamanın maliyetine değmesinin nedeni budur.

İzolasyonu doğrudan da test ederdim, çünkü normal trafikte görünmezdir. Ayırt edici yer tutucu değerleri olan iki sentetik müşteri oluşturulur (`person-017@example.invalid`, `ADDRESS-PLACEHOLDER-A`), ikisi için neredeyse özdeş ticket'lar tek bir süreçte peş peşe çalıştırılır ve ikinci run'ın manifest'inde, cevabında, trace'inde ve bellek yazımlarında birincinin herhangi bir değeri aranır. Geçmek yalnızca akla gelen yolların kapalı olduğunu söyler.

Giden cevap

Bölüm 15, `send_customer_reply` sözleşmesini yazdı ve ön koşullarında iki yer tutucu satır bıraktı: biri injection için (Bölüm 16), biri PII için. Bu bölüm PII satırını doldurur. Bu satırlar `preconditions` alanını genişletir; sözleşmenin geri kalanı olduğu gibi kalır. Parça Bölüm 6'nın gösterimindedir.

```
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
```

Sıralama satırı ince olandır. Token'lar onaydan sonra yerine konsaydı, hash token'lı taslağı kapsardı ve müşteri onaylayanın hiç görmediği bir şeyi okurdu; bu da Bölüm 15'in, onayın tam olarak çıkan baytları kapsadığı kuralını bozar. Yerine koyma önce olur ve hash onun sonucunu kapsar.

Dördüncü satırdaki ifşa kuralı bir tasarım görüşü ve bir maliyettir. Talep edenin sağlamadığı, kayıtlı adres gibi saklanan bir değeri ifşa etmek, ticket'ın gönderici adresini kontrol eden kişiye yapılan bir ifşadır ve Bölüm 7, bir ticket ile bir müşteri arasındaki bağın ancak ticket sisteminin onu ne kadar güçlü kurduğu kadar güçlü olduğu konusunda dürüsttür.

Gate'in bu nedenlerden biriyle reddettiği bir cevap, değer olmadan bir gözlem olarak bağlama döner. Model farklı bir taslak önerebilir; kural yine uygulanır.

Onay ekranı

Bekleyen bir eyleme bakan kişi veri görür ve ekran bir kopyadır. Buradaki PII kuralları azdır. Render edilmiş cevap tamamen gösterilir, çünkü çıkan odur ve karar o metin hakkındadır. Çevreleyen bağlam maskeli gösterilir; onaylayan gerçek değere ihtiyaç duyduğunda bunu log'lanan bir reveal ile açar. Cevap gönderildikten sonra onay kaydı call hash'i ve id'leri tutar, metnin ikinci bir kopyasını değil; reddedilen ya da süresi dolan bir talebin metni kısa bir süre sonra silinir.

Maliyet, Bölüm 15'in rubber-stamping konusunda uyardığı yerdeki sürtünmedir: onaylayanın kontrol ettiğini görmek için tıklama gerektiren bir ekran insanları her şeyi göstermeye alıştıırır ve bu durumda projeksiyonun kaldırılması değil yeniden tasarlanması gerekir.

Silme ve erişim talepleri

Bir müşteri Parcelport'tan kendisi hakkında ne tuttuğunu göstermesini ya da onu kaldırmasını isteyebilir. Bir agent talebin ne olduğunu değiştirmez. Verinin nerede olduğunu değiştirir ve bu bölümün başındaki envanter artık iş planıdır: ticket sistemi, run store, vault, bellek store'u, trace ve log store'ları, eval set'leri, onay servisi, cache'ler, yedekler ve sağlayıcı

sözleşmesinin kendi tarafı hakkında söylediği her şey. Müşteri kapsamında silme tek bir işlem olmalıdır; bu da ancak her şey bir silmenin bulabileceği bir şeyle anahtarlandığında mümkündür.

Serbest metin için anahtar dolaylıdır. Bir trace'in her span'inde bir `customer_id` alanı yoktur, bu yüzden run store müşteriden run id'lerine bir eşleme tutar ve silme job'ı onu dolaşır: her run için run'ın span'lerini, vault girdilerini ve bağlam kayıtlarını redakte eder ya da siler. Eşlemenin kendisi kişisel veridir ve en son silinir. Job ayrı sistemler arasında bir transaction olamaz, bu yüzden sırayla yazılan ve kaldığı yerden sürdürülebilen bir ledger'dır.

```
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)
```

Blokta başarı dışında iki sonuç var. Çöken bir store `pending` kalır ve yeniden denenir, vadesine yaklaşan bekleyen bir kalem de birine alarm gönderir, çünkü sessizce takılan bir silme, veri öznesi için F8'dir. Bir store ayrıca bir reason code'la `restricted` de döndürebilir, çünkü bazı kayıtların, örneğin bir ödeme kaydının, talep ile ilgisi olmayan nedenlerle tutulması gerekebilir. Mühendislik gereksinimi, "restricted"ın kimsenin fark etmediği bir boşluk değil, store başına kaydedilmiş, gerekçeli bir sonuç olmasıdır. Ledger id'leri ve durumları tutar, sildiği veriyi asla.

Bir erişim talebi aynı envanteri ve ledger'ı kullanır, `eraseOrRestrict` yerine `collect` ile. İki daha zor durum: yedekler bir silmeyi bir takvime göre yürürlüğe sokar, bu yüzden tasarımın ne zaman olduğuna dair bir

Nokta	Kontrol	Geriye kalan
Model sağlayıcısı	Bağlantı başına sınıf kontrolü; dosyada sözleşme cevapları	Sağlayıcının minimized içerikle yaptığı her şey
Log'lar ve trace'ler	Allowlist, bilinen değer değiştirme, fail-closed yazıcı	Tanımlayan kombinasyonlar; dedektör ıskalamaları
Bellek	Tipli girdiler, iletişim bilgisi yok (Bölüm 11)	Bir müşteri id'sine bağlı girdiler
Eval set'leri	Redaction, insan review'u, hash'lenmiş kaynak dizini	Reviewer ıskalamaları; koşullarla yeniden tanımlama
Tool çıktısı	Projeksiyon ve türetilmiş alanlar	Ham bir alana ihtiyaç duyan ve bunu söyleyen görevler
Onay ekranı	Maskeli bağlam, log'lanan reveal, ikinci kopya yok	Reveal alışkanlıkları
Cevap	Token çözme, ifşa kuralı, render edilmiş metin onayı	Talep edenin kimliği ancak ticket bağı kadar güçlüdür

Trade-off'lar ve maliyetler

Yukarıdaki her kontrol işletilecek bir sistemdir ve maliyet, bütçeye ulaşmadan önce insanlara yayılır.

Mühendislik. Vault, kendi erişilebilirliği olan yeni bir bileşendir. Çökerse token gerektiren ticket'lar ilerleyemez ve Bölüm 14'ün degraded mode'u geçerli olur: hand-off'a geçilir ya da PII içermeyen şablonlardan cevap verilir. Birinin projeksiyon politikalarına, dedektör kümesine, loglanabilir alan listelerine ve silme envanterine sürekli bir backlog olarak sahip olması gerekir.

Cevap kalitesi ve debug. Model isimleri göremez, bu yüzden selamlamalar ve kapanışlar şablonlardan gelir ve bir adresi okuyamayan model onu yargılayamaz. On-call token'ları, hash'leri ve atlanmış alanları görür, bu yüzden bazı olaylar daha uzun sürer; denetlenen reveal uzlaşmadır, bedeli her reveal için bir kişi, bir onay ve bir log girdisidir.

Review ve sağlayıcılar. Eval vakalarının insan review'u yavaştır, bu da golden set'leri özenle seçilmiş tutmanın bir nedenidir. Bağlantı başına katı bir veri sınıfı, daha azı için çalışan bir fallback anlamına gelebilir.

Bunların hepsini ne zaman kullanmamalı: yalnızca herkese açık dokümantasyonu okuyan ve müşteri verisi işlemeyen bir agent'a envanter yeter, başka bir şey gerekmez. Sentetik veri üzerindeki bir prototipin vault'a ihtiyacı yoktur, ama projeksiyon politikası ilk günden var olmalıdır. Özü modelin okuması gereken bir alan olan bir görev, örneğin serbest metin bir şikâyeti özetlemek, token'lanamaz; minimizasyona, sağlayıcı sınırına, kayıta redaction'a ve kısa bir saklama süresine güvenilir ve tasarımıda modelin metni gördüğü açıkça söylenir.

Sık yapılan hatalar

- **PII'yi bir çıktı sorunu olarak görmek.** Nihai cevabı taramak cazip, çünkü zarar orada görünür; ama bu, diğer yedi yeri olduğu gibi bırakır. Çözüm: envanterden başlamak ve her noktaya bir kontrol koymak; giden kontrolü birkaçının sonuncusu olarak tutmak.
- **"Her ihtimale karşı" tam kaydı döndüren tool.** Yazması en ucuz tool'dur ve bütün profili bağlama, trace'e ve sağlayıcının isteğine koyar. Çözüm: görev başına projeksiyon, türetilmiş alanlarla ve genişletme için bir reason code ile.
- **Global token'lar.** Run'lar arası sabit token'lar sürekliliği kolaylaştırır ve bir kapsam hatasını müşteriler arası sızıntıya çevirir. Çözüm: run kapsamlı token'lar, süreklilik tipli bellekten gelir.
- **Okurken redaction.** Ham veriyi store'da tutar ve bazı görüntüleyicilerden gizler. Çözüm: yazarken redakte etmek, fail closed olmak ve eski kayıtlar yeniden işlenebilsin diye redaction sürümünü damgalamak.
- **Ticket'ları toplu olarak eval set'ine export etmek.** Hızla gerçekçi bir set kurar ve müşteri metnini farklı erişim kurallarına sahip bir repository'ye koyar. Çözüm: review edilmiş yol, silmenin vakalara ulaşabilmesi için hash'lenmiş kaynak dizini ile.
- **Fallback sağlayıcıya varsayılan olarak güvenmek.** Servisi ayakta tutmak için bir kez yapılandırılır ve koşullarını kimse review etmez. Çözüm: bağlantı başına bir veri sınıfı, gateway'de uygulanan, ve fallback'in birincilin aldığı almasına izin verilmediğinde belirtilmiş bir degraded mode.
- **Birincil veritabanını kapsayan bir silme süreci.** İlk talebin sinadığı budur ve trace'ler, cache'ler ve eval vakaları kalır. Çözüm: kontrol

edilen bir liste olarak envanter, kayıt olarak ledger ve sentetik bir müşteri oluşturan, ticket'ları çalıştıran ve silen bir test.

Temel çıkarımlar

- Bir agent'taki PII sekiz yerden akar (bağlam, sağlayıcı, log'lar ve trace'ler, bellek, eval set'leri, tool çıktısı, onay ekranı ve cevap) ve kontrol yalnızca sonuncuda değil her birinde bulunmalıdır.
- Kişisel veriyi ifşa etmemeyi söyleyen bir prompt sızdıran taslakların oranını düşürür, ama bir kontrol değildir; kontroller projeksiyon, token'lar, yazıcı, gateway ve giden kontroldür ve hepsi kodda çalışır.
- Korunması en ucuz PII modelin hiç görmediğidir, bu yüzden tool'lar, veri olarak yazılmış bir politika altında, görevin ihtiyaç duyduğu alanları ve ham değerler yerine türetilmiş cevapları döndürür.
- Bir run'a kapsamlanmış token'lar modelin yer tutucularla çalışmasını sağlar ve kod onları etki kenarında çözer; aynı vault giden kontrole doğrulayacak bir şey verir, yeter ki yerine koyma onay metni kapsamadan önce gerçekleşsin.
- Redaction yazma anına aittir; allowlist, bilinen değer değiştirme, fail-closed bir yazıcı ve bir sürüm damgasıyla; maruziyeti azaltır ve veriyi anonim yapmaz.
- Bir model sağlayıcısı, saklama ve eğitim koşulları sözleşme ve yapılandırma soruları olan bir alıcıdır; bu yüzden cevaplar bağlantı başına kaydedilir ve gateway'de, fallback dahil, bir veri sınıfı uygulanır.
- Silme ve erişim talepleri bir kopya tutan her store'a ulaşır; bu da bir envanter, müşteriden run'lara bir eşleme ve her store'un sonucunu veri olmadan kaydeden bir ledger demektir.

Sonraki bölüm, insanlar hakkındaki veriden erişim veren değerlere geçer. PII yayılmaması gereken veridir; secret ise bağlama hiç girmemesi gereken veridir ve Bölüm 18, agent'ın hiçbirini tutmadığı tasarımı kurar.

Bölüm 18 — Secret'lar

Parcelport'u bir olay sırasında düşünelim. `deploy-service` için bir alarm tetikleniyor ve ops agent bir inceleme başlatıyor. Dördüncü step'te servisin başlangıç satırları için `query_logs`'u çağırıyor. Yıllar önce bir kütüphanenin yazdığı bir satır, servisin veritabanına ulaşmak için kullandığı tam connection string'i, parolası dahil, basıyor. Tool satırı sıradan metin olarak döndürüyor ve orchestrator, her sonuçta yaptığı gibi, onu bağlama bir gözlem olarak ekliyor.

Sonrasında dramatik hiçbir şey olmuyor ve mesele de bu. Model satırı okuyor, notlarında host adına atıf yapıyor ve devam ediyor. İki step sonra bir timeout'u değiştiren bir pull request öneriyor ve açıklama, başlangıç satırını kanıt olarak alınıyor. Trace pipeline'ı her step'in bağlamını sakladığı için parola artık trace store'da duruyor; checkpoint onu run store'a koyuyor; "bir dahaki sefer için veritabanı bağlantı bilgileri" diye yazılan bir bellek kaydı onu üçüncü bir yere koyardı.

Burada kimse bir şeye saldırmadı ve sızıntıların hiçbirinde bir prompt rol oynamadı. Değer, sistemin sıradan metin için kurduğu yollardan ilerledi. Dolayısıyla bu bölümün soruları sadedir. Bir secret nerede asla bulunmamalı, modelin önerileri ve tool'ların çıktıları iş birliği yapmadığında o çizgiyi ne tutar ve çizginin tutmadığı öğrenildiği gün ne yapılır?

Bu bölüm kontrol zarfının **Etki** parçasına aittir; secret'ın sızabileceği yerlerde **Bağlam**'a ve **Kayıt**'a da dokunur. Bölüm 7, bir çağrının hangi yetkiyi taşıdığına karar verdi ve onun için bir credential çıkardı. Bu bölüm, o credential'ın ve sistemdeki diğer her secret'ın nerede durduğu, nasıl hareket ettiği ve kaçığında ne yapılacağı hakkında.

Sorun ve neden zor olduđu

Secret, açığa çıkarsa erişim sağlayan her değerdir: bir sağlayıcı credential'ı, bir servis token'ı, bir imzalama anahtarı, bir veritabanı parolası, bir session cookie'si. Kitabın kuralı kısa: bir secret asla bağlama girmez. Nedeni modelin onu kötüye kullanabilmesi değil; bağlamın, bir agent sisteminde en geniş çapta kopyalanan artifact olması. Model sağlayıcıya gönderilir, trace'te saklanır, run store'da checkpoint'lenir, belleğe özetlenir, bir onay ekranında gösterilir ve taslaklarda alıntılanır. Bağlamdaki bir değer bu yerlerin her birine zaten yazılmıştır ya da yazılmak üzeredir.

F7 (yetkisiz etki), sızmış ya da fazla geniş bir credential, principal'ın doğuramayacağı bir etkiyi birinin doğurmasına izin verdiğinde ortaya çıkar. F8 (gözlenmeyen davranış), bir credential kullanıldığında ve kayıt kimin tarafından ya da hangi görev için kullanıldığını söyleyemediğinde ortaya çıkar. F4 (talimat ele geçirme, Bölüm 16) güçlendiricidir: bağlamdaki bir secret, tool sonucu içeriğinin dışarı taşımaya çalışabileceği bir şeydir ve tek güvenilir cevap, onun hiç orada olmamasıdır.

Akla gelen yaklaşım bir talimattır: "credential'ları asla ifşa etme, çıktıya secret koyma." Cümleyi yazardım, çünkü bir secret'ı alıntılamanın önerilerin oranını düşürür; ama tek bir çıktı kanalını kısıtlar, oysa yukarıdaki sızıntı yolları orchestrator'dan, trace'ten ve checkpoint'ten geçer ve bunların hiçbir prompt'u okumaz (Bölüm 16 genel argümanı yapıyor). Kontrol, değerın bağlamda hiç bulunmamasıdır.

Uyarı: Bir model bağlamında, bir trace'te, bir checkpoint'te ya da bir bellek store'unda görünmüş her secret ifşa olmuş sayılmalıdır. Bu store'ları kimin okuyacağı üzerine akıl yürütülmemelidir. Credential rotate edilmelidir. Elenemeyen bir ifşa, müdahale açısından ifşadır.

Credential'lar nerede durur

Herhangi bir kontrolden önce bir envanter gerekir. Güvenlik ekibinden Jordan'ın ilk soracağı şey, agent sisteminin hangi credential'ları tuttuğu, her birini kimin tuttuğu ve modelin bunlardan ne görebildiğidir. Parcelport'un hedef durumdaki cevabı şöyle görünür.

Credential	Kimde durur	Kim kullanır	Ömür	Modelin gördüğü
Model sağlayıcı credential'ı	Yalnızca model gateway'i	Gateway, her model çağrısında	Uzun ömürlü, takvime göre rotate edilir	Hiçbir şey
Orchestrator çağırıcı kimliği	Platform, bir workload identity olarak	Orchestrator; model gateway'ine ve tool gateway'in arkasındaki credential servisine ulaşmak için (Bölüm 7)	Dakikalar, platform tarafından yenilenir	Hiçbir şey
Servis başına API token'ı	Çağrı başına, credential servisinde çekerek tool gateway'i üzerinden çıkarılır	Tool runtime'ı, tek bir çağrı için	Birkaç dakika (örnek değer)	Hiçbir şey; kayıt yalnızca id'sini tutar
open_pull_request için code host credential'ı	Çağrı başına çıkarılır, tek bir repository'ye ve bir branch önekinde kapsamlanır	Tool runtime'ı	Dakikalar	Hiçbir şey
Deploy credential'ı	deploy-service	deploy-service, onaydan sonra	Kendi politikasına göre	Hiçbir şey; agent onu asla tutmaz
Onay imzalama anahtarı	Onay servisi	Onay servisi	Uzun ömürlü, rotate edilir	Hiçbir şey; agent anahtarı değil, imzalı bir onay görür
MCP server credential'ı	O server için, tool gateway'i tarafından çağrı başına çıkarılır	Tool runtime'ı	Dakikalar	Hiçbir şey
run_diagnostic için sandbox credential'ı	Yok	Yok	Geçerli değil	Hiçbir şey

Son sütun her satırda aynı ve tasarım da bu. Model çağrılarını önerir, asla yapmaz; bir kaynağın adını verir, yetkiyi etki katmanını sağlar. Modelin bir değeri gördüğü bir satır, tasarımın modeli Etki sınırının yanlış tarafına koyduğu anlamına gelir.

Satırı olmayan bir credential'ın sahibi, rotation takvimi ve iptal yolu yoktur. Yeni bir tool, server ya da entegrasyon geldiğinde, Bölüm 7'deki yetki envanteri review'u buraya da bir satır ekler; kimin rotate edeceğini ve sızdığına kime alarm gönderileceğini adlandırır.

Modelin dışında injection

Mekanizmaya **credential injection** denir, ama sözcük sade bir şeyin takma adı: tool runtime'ı, yani tool gateway'in onaylanmış bir çağrıyla yürüten kısmı, credential'ı son anda çeker, giden isteğe ekler ve sonra atar. Model, bağlam derleme kodu ve orchestrator'ın modele bakan yolları değeri asla görmez.

Bunu iki özellik ayakta tutar. Birincisi sözleşmede. Bir tool'un input schema'sı yalnızca modelin sağladığı alanları listeler ve hiçbirisi bir credential, bir header, bir token ya da bir connection string değildir. Schema kapalı olduğu için (Bölüm 6'nın gösteriminde `additionalProperties: false`), birini geçirmeye çalışan bir öneri bozuktur ve model ne kastetmiş olursa olsun gate'te F1 (bozuk çıktı) olarak başarısız olur. İkincisi runtime'da: credential, executor'ın bir parametresidir, çağrı kaydının bir alanı değil. Kayıtlar, bağlam ve trace çağrıdan inşa edilir ve çağrı onu asla içermez.

İşte `open_pull_request` sözleşmesi, kitabın gösteriminde yazılmış. Input schema'da neyin eksik olduğuna ve credential'ın nerede görüldüğüne bakılmalıdır: `permissions` içinde, gate'in neyi çıkaracağına dair bir ifade olarak; asla bir argüman olarak değil.


```

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

```

Şimdi runtime tarafı. Sıradaki blok, Bölüm 7'nin `applyWithCredential`'inin `credential` çıkarıldıktan sonra çağırdığı `executor`'ın içidir. Önemli olan sırayı gösteriyor: değer yalnızca bu fonksiyonun içinde var, `upstream`'in cevabı güvenilmeyen girdi olarak ele alınıyor ve `scrub`, herhangi bir şey dışarı çıkmadan önce yapıyor.


```

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

```

Hata durumları sırayla izlenebilir. Credential servisine ulaşamıyorsa hiçbir şey başlamamıştır ve Bölüm 7'nin yolu `upstream_unavailable` döndürür. Credential kullanıldıktan sonra tool timeout'a düşerse sonuç bilinmiyordur ve sözleşmenin timeout kuralı geçerlidir; credential kendiliğinden sona erer. Upstream'in hata gövdesi istek header'larını yankılıyorsa `mapUpstreamFailure` onu zaten atmıştır ve ham gövde, modele değil kısıtlı bir store'a gider.

Sıradaki diyagram değerın nereden geçtiğini gösteriyor. Noktalı yola bakılmalıdır: modelin önerisi ve aldığı gözlem hiçbir credential içermiyor ve değerle giden isteğin bulunduğu tek yer, tool gateway'in içindeki tool runtime'ı. Gate önce karar verir ve hiçbir credential tutmaz. Orchestrator `effect.apply`'ı başlatır ve grant ancak o zaman, yalnızca o tek çağrı için çıkarılır.



Kısa ömürlü, dar ve bir göreve bağlı

Tasarım dikkatsizse örüntü kendi bootstrap'inde başarısız olur.

Workload identity

Credential çıkaran bir sistemin, çağıranı doğrulamak için bir şeye ihtiyacı vardır. Bu, orchestrator'ın konfigürasyonundaki uzun ömürlü bir secret ise geniş token, dar token isteme credential'ına dönüşmüştür. Bu bootstrap problemidir ve hiçbir tasarım onu ortadan kaldırmaz. Bir tasarım onu küçültebilir.

Araç **workload identity**'dir: orchestrator'ı çalıştıran platform, her workload'a kanıtlayabileceği, kısa ömürlü ve workload'un nerede ve ne olduğuna dayanan bir kimlik verir; credential servisi de saklanmış bir parola yerine bu kanıtı kabul eder. O zaman hiçbir repository dosyası, ortam değişkeni ya da image katmanı, kopyalandığında her yerden çalışan bir değer tutmaz. Platform kimlik servisi olmayan bir ekip, tek bootstrap secret'ını audit log'lu bir secrets manager'da tutar, onu takvime göre rotate eder ve bunun kalan en büyük açıklık olduğunu yazıya geçirir.

Üç ömür kapsamı

Credential'lar üç ayrı saatte kısa ömürlüdür ve her biri farklı bir soruyu cevaplar.

Saat	Cevapladığı soru	Örnek ömür
Çağrı başına	Sızmış bir credential yarın ne yapabilir?	Birkaç dakika, tam o çağrıya bağlı
Run başına	Bir credential, çıkarıldığı görevden uzun yaşayabilir mi?	Run ya da olayla birlikte biter
Principal başına	Bir agent'ın yapabildiği her şeyi kapatabilir miyiz?	Principal bazında tek işlemle iptal edilebilir

Çağrı başına olanı Bölüm 7 anlatıyor. Run başına olan, dar kapsamlı ve tekrarlanan okuma tool'larına uyar; çağrıya bağlı bir grant orada her step'te bir gidiş-dönüşe mal olurdu. Principal başına olan, bu bölümün son kısmındaki iptali mümkün kılar ve her credential'ın kendisinin çıkarıldığı agent'ı kaydetmesini gerektirir. "Çağrı artı bir paydan uzun değil" ile başlanır; yalnızca yazılı bir gerekçeyle genişletilir.

Kısa ömürlü olamayan credential'lar

Bazı credential'lar çağrı başına üretilemez: yalnızca uzun ömürlü API anahtarı sunan üçüncü taraf bir servis, model sağlayıcının kendi credential'ı, onay servisinin imzalama anahtarı. Her biri onu kullanan tek sistemde yaşar, şifreli saklanır, yalnızca orada çözülür ve envanterde bir sahibi ve bir rotation takvimi vardır. Sağlayıcı credential'ını gateway'de tutmak (Bölüm 13) onu rotate etmek için tek bir yer demektir.

MCP server'ları ve sandbox'lar

İki yer tasarımcıları credential teslim etmeye yöneltir; her biri kesin bir kural alır.

MCP server'ları için ilkeyi Bölüm 8 koyuyor: credential, tool gateway'i tarafından çağrı başına çıkarılır, tool'a kapsamlanır ve asla host'un ya da kullanıcının kendi credential'ı olmaz. Secret'lara özgü kısım transport'tur. Yerel bir server süreci, host'un ona ilettiği her şeyi miras alır; bu yüzden host onu açık ve asgari bir ortamla başlatır. Uzak bir server, yalnızca o server için anlamlı bir credential alır ve bir özelliğin bedeli olarak daha geniş bir credential isteyen server'a cevap hayırdır.

Sandbox'lar için kural, `run_diagnostic`'in zaten uyduğu kuraldır: credential yok, çünkü sandbox'taki her şey modelin önerdiği kod tarafından okunabilir. Bir görev gerçekten erişim gerektirdiğinde tercih sırası Bölüm 19'dadır ve izin verdiği her credential envanterde bir gerekçeyle bir istisna olarak listelenir.

Secret'lar yine de nasıl sızar

Şu ana kadar anlatılan her şey, bir secret'ın bağlama ulaşma ihtimalini azaltır. Hiçbiri ihtimali sıfır yapmaz, çünkü secret'lar dünyadan da gelir: bir log satırı, bir konfigürasyon dosyası, bir hata gövdesi, bir ticket'a yapııştırılmış bir doküman. Kontrolün ikinci yarısı değerini ortaya çıkacağını varsayar ve onu sınırdan kaldırır.

Sızıntı yolu	Değer oraya nasıl gelir	Kontrol nerede durur
Tool sonucu	Bir log satırı, bir konfigürasyon dosyası, bir metric etiketi	Sonuç gözleme dönüşmeden önce tool runtime'ında scrub

Sızıntı yolu	Değer oraya nasıl gelir	Kontrol nerede durur
Upstream hatası	İsteği yankılayan bir hata gövdesi	Bir hata sınıfına ve kodun yazdığı bir mesaja eşleme; ham gövde bağlamın dışında tutulur
Üretilen kod ve pull request'ler	Tool sonuçlarından derlenen bir dosya ya da açıklama	Diff ve metin, <code>open_pull_request</code> 'in ön koşulu olarak taranır
Trace ve checkpoint	Bağlam ve argümanlar olduğu gibi saklanır	Yazmadan önce scrub edilir; varsayılan olarak hiçbir istek header'ı yakalanmaz
Bellek	Daha sonra işe yarasın diye yazılan bir not	Bölüm 11'in diğer yazma kontrolleriyle birlikte, bellek yazımında taranır
İnsan ekranları ve ticket'lar	Onay görünümleri, cevaplar, yükseltme özetleri	Scrub edilmiş kayıttan render edilir, asla ham sonuçlardan değil

Tool sınırındaki scrubber

Scrubber, Bölüm 17'nin redaction düzenini (önce bilinen değerler, sonra örüntüler) secret'lara uygular. Burada özgün olan, bilinen değer kümesidir: bu sistemin çıkardığı credential'lar, sayabildiği kodlamalarda. Bu dedektör deterministiktir ve en önemli durumu kapsar: agent'ın kendi credential'ının bir upstream cevabında geri gelmesi. Örüntü dedektörü (anahtar örnekleri, private key blokları, yüksek entropili string'ler, connection string biçimleri) bir sınıflandırıcıdır: tanımadığı biçimleri kaçıır ve secret olmayan tanımlayıcıları işaretler.

```
function scrubSecrets(text, known):
  findings = []
  for each value in known:                                // exact: values this
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
```

Blokla birlikte üç tasarım noktası gelir. Yer tutucu tiplidir; böylece okuyan bir şeyin kaldırıldığını ve ne tür olduğunu görür. Bulgu, anahtarlı bir fingerprint tutar; böylece soruşturan biri, bulgu store'u bir kopya daha olmadan "bu değer başka nerede göründü" diye sorabilir. Ve scrub, modelin okuyacağı şeye uygulanır; orijinal, saklanması gerekiyorsa, kendi retention'ı ve erişim listesi olan kısıtlı bir store'da yaşar.

Bir isabette ne olacağı, secret'ın kimin olduğuna bağlıdır. Bu sistem çıkarmışsa cevap mekaniktir: ele geçirilmiş sayılır, sona erdirilir, run kaydedilir ve bir sonraki çağrı yenisini kullanır. Bir log'daki bir başkasının secret'ıysa scrubber kaynakta bir kusur ortaya çıkarmıştır ve sistem, logging'in sahibi ekip için bir bulgu açar; aşağı akıştaki hiçbir scrubber, başlangıçta basılan bir parolayı düzeltmez. Dedektör bir garanti değildir ve her alarm gibi onu da ayarlayan bir sahabe ihtiyacı vardır.

Not: Bilinen değer dedektörü yalnızca sistemin çıkardığını bildiği şeyi korur. Hiç çıkarmadığı bir credential, örneğin bir runbook'a yapıştırılmış olan, örüntü dedektörünün işidir.

Pull request'ler ve üretilen kod

Ops agent'ın pull request'leri bu agent'a en özgü sızıntı yoludur, çünkü içeriği model oluşturur. Gözlemlerden derlenen bir diff, gözlemlerin taşıdığı her şeyi taşıyabilir ve bir test fixture'ı yazması istenen bir model, gerçek bir credential biçiminde bir string üretebilir. Bir branch push'landığında içeriği code host'ta, clone'larda ve bildirimlerde bulunur ve geçmişten bir secret'ı silmek kimsenin istemediği bir temizliktir.

Bu yüzden kontrol, yukarıdaki sözleşmedeki bir ön koşuldur ve çağrı code host'a ulaşmadan önce tool gateway'i tarafından çalıştırılır. Bilinen değer kontrolü çıkarılmış değerlere ihtiyaç duyar, ama gateway onları toplamamalıdır: başka run'lar ve servisler için canlı değerleri bir araya getiren bir yer, tek bir crash dump'ından hepsini bir küme olarak sızdırır. Bu yüzden metni credential servisine gönderir ve yalnızca eşleşmeleri, bir tür ve bir konum alır, asla bir değer; gateway'in kendisi yalnızca örüntü dedektörlerini çalıştırır. Credential servisi yerinde karşılaştırma yapamıyorsa çıkarılmış değerlerin anahtarlı hash'lerini sunabilir ve gateway secret'ları değil fingerprint'leri tutar. Karşılaştırma bu run'a çıkarılmış değerlerle sınırlıdır; başka bir run'a ya da agent'a çıkarılmış bir

değer diffe yalnızca örüntü dedektörleri aracılığıyla ulaşır. Sıradaki bloktaki ret bir konum ve bir tür taşır, eşleşen metni asla; böylece gözlem ikinci bir sızıntıya dönüşemez.

```
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
```

Üç katman sayıyorum. Yasaklı yol listesi, içeriğinden bağımsız olarak dosyaların bütün kategorilerini durdurur. Tarama, bilinen biçimli değerleri ve bu run'a çıkarılmış her değeri durdurur. Code host'un kendi secret taraması, sunuluyorsa, farklı bir dedektörün gördüğünü yakalar. Hiçbiri reviewer'a dayanmaz: 40 satırlık bir diff'i mantık için okuyan bir insan, 40 karakterlik bir string'i bulmakta kötüdür ve buna güvenmek gösteriden ibarettir.

Bir ret bir step'e mal olur; Bölüm 12 ve Bölüm 13'ün sınırları, kendini tekrarlayan bir modeli durdurur.

Trace'ler, checkpoint'ler ve bellek

Kayıt, sızıntının en uzun yaşadığı yerdir, çünkü saklanmak ve birçok kişi tarafından okunmak üzere yazılır. Üç kural geçerlidir; trace pipeline'ının ve genel olarak redaction'ın ayrıntılarını Bölüm 20 ve Bölüm 17 taşıyor.

Birincisi, yazmadan önce, kayıt oluşturulurken aynı fonksiyonla scrub etmek; gece çalışan bir job'da scrub edilen trace, job çalışana kadar secret'ı tutar ve bir yedek, sonrasında da tutar. İkincisi, değerleri değil

tanımlayıcıları yakalamak: credential id'si, kapsam ve sona erme zamanı; bu, her sızıntı müdahalesinin ilk sorusunu, bir run'ın hangi credential'ı kullandığını cevaplar. Üçüncüsü, instrumentation varsayılanlarını gözden geçirmek: genel istek izleme authorization header'larını yakalayabilir; bu yüzden yakalama, pipeline tarafından uygulanan bir alan allowlist'idir ve bilinen credential header'ları için bir denylist son çare olarak bulunur.

Belleğin bir kuralı daha var. "Staging veritabanı host'u ve parolası bir dahaki sefer için" gibi bir not, bir model için yararlı ve herkes için tehlikelidir. Bölüm 11, bellek yazımlarını kendi gate'i olan güvenilmeyen girdi olarak ele alır; secret'lara özgü ekleme, gate'in scrubber'ı çalıştırması ve bulgusu olan bir notu türünü belirterek reddetmesidir. Bir credential hakkında kalıcı bir olgunun yeri envanterdir, "hangi credential, kimin sahipliğinde" olarak; değer asla.

Hata mesajları ve insanların gördükleri

Bir eylemi onaylayan kişi tam çağrıyı görür (Bölüm 15) ve bu çağrı hiçbir credential içermez; dolayısıyla onay ekranı, ham tool çıktısından değil çağrı kaydından render edildiği sürece hiçbir credential göstermez. Aynı `escalate_to_human` özeti ve bir destek cevabının üzerine kurulduğu taslak için de geçerlidir.

Hata mesajları daha az bariz bir yoldur, çünkü upstream servisler aldıkları isteği tarif eder. Tool runtime'ı bir upstream hatasını bir hata sınıfına ve Parcelport'un kodunun yazdığı bir mesaja eşler; ham gövde kısıtlı bir yolda kalır.

Model sağlayıcı ne görür

Ekibin inceleyemediği bir yol daha: her bağlam gateway üzerinden model sağlayıcıya gider; dolayısıyla bağlamdaki bir secret, sağlayıcının politikaları ne olursa olsun Parcelport'un sınırını terk etmiştir. Saklama ve kullanım koşulları hukuk ve uyum için bir sözleşme sorusudur ve veri koruma rejimleri bu tür verinin nereye gittiğini soracaktır. "Secret hiç bağlamda değildi" ifadesinin geçerli olması için bir sağlayıcı politikasına gerek yoktur.

Rotation ve iptal

Kısa ömürlü credential'lar kendi kendine rotate olur: işi sona erme yapar. Uzun ömürlü olanlar, örneğin model sağlayıcı credential'ı ya da bir imzalama anahtarı, yalnızca biri yapıldığında rotate olur ve yapılmamasının olağan nedeni, rotation'ın hiç prova edilmemiş olmasıdır.

Rotation için tasarım

Uzun ömürlü her credential için deploy'suz rotation'ı bir gereksinim sayardım, çünkü sessizce rotate edilemeyen bir credential, bir olay sırasında da rotate edilmez. Üç özellik bunu mümkün kılar. Tüketici credential'ı kullanım anında secret store'undan okur ya da kısa aralıklarla yeniler ve onu bir image'a ya da konfigürasyon dosyasına gömmez. Doğrulayan sistem, bir örtüşme penceresi boyunca hem eski hem yeni değeri kabul eder. Ve her credential'ın envanterde adı konmuş bir sahibi ve bir takvimi vardır, son rotation'ın kaydıyla birlikte.

Örtüşme pencereleri bir süre geçerli credential sayısını ikiye katlar; envanterin tüketici listesiyle yapılan bir dry run, gözden kaçan bir tüketicinin yol açtığı kesintiden ucuzdur.

Bir agent'ın dokunabildiği her şeyi iptal etmek

Bir agent'ın credential'larının sızdığından şüphelenildiğinde ilk soru, sistemin o agent'ın tuttuğu her şeyi ne kadar hızlı çalışmaz hale getirebildiğidir. Cevap bir araştırma projesi değil, bir işlem olmalıdır. Bunun için her credential'ı, çıkarıldığı agent'a ve run'a bağlayan bir kayıt gerekir; credential servisinin her grant ile birlikte principal'ı saklamasının nedeni budur; ayrıca credential kabul eden her sistem için bir iptal yolu gerekir.

```

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)

```

Ders sıralamadır. Önce dondurulur; böylece süren bir iptal yeni bir çıkarma ile geri alınmaz. Bir başarısızlığın ötesinde devam edilir, çünkü ilk başarısız sistemde durmak gerisini canlı bırakır. Ayrı bir sorguyla doğrulanır, çünkü kapalı ya da kısmen uygulanmış bir sistemden gelen "iptal edildi" bir kanıt değil, bir iddiadır. Ve uçuştaki run'lar bir insana devredilir: çağrının ortasında olan bir etkinin sonucu bilinmiyordu ve Bölüm 10'un reconciliation sweep'i onu çözer.

İptal bir degraded mode'dur: run'lar durur, ticket'lar bekler, Robin'e alarm gider. Bunu alıştırmanın nedeni de bu, çünkü kimsenin çevirmediği bir şalter bir hipotezdir. Bu adımın etrafındaki olayı Bölüm 23 ele alıyor.

Kontroller yerindeyken bir Salı

Açılışa dönelim. `query_logs` connection string'li başlangıç satırını döndürüyor ve bu kez sonuç, tool sınırındaki scrubber'dan geçiyor. Gözlem, fiilen, "başlangıç satırı, bir veritabanı parolası `<secret:connection_string>` ile değiştirilmiş" şeklinde okunuyor, run fingerprint'li bir bulgu kaydediyor ve servisin logging'inin sahiplerinden o parolayı rotate etmeleri isteniyor, çünkü log store orijinali zaten tutuyor.

Altıncı step'te model, bir timeout'u değiştiren bir pull request öneriyor. Gate sözleşmeyi kontrol ediyor: repository delegasyonda, yollar yasaklı değil ve tarama hiçbir şey bulmuyor, çünkü alıntılanan gözlem zaten yer tutucuyu taşıyor. Tool gateway'i tek bir repository ve bir branch öneki için bir grant çıkarıyor, code host branch'i açıyor ve credential dakikalar sonra sona eriyor. Bellek yazma gate'i, saklaması istenen notta hiçbir bulgu görmüyor.

Şimdi her katmanın neyi durdurduğu ve neyin kaldığı sorulmalıdır. Tablo bunu dürüstçe söylüyor.

Katman	Burada neyi durdurdu	Neyi durdurmaz
Credential injection	Agent, code host credential'ını hiç tutmadı	Verinin içinde gelen bir secret
Tool sınırındaki scrubber	Connection string'in bağlama, trace'e ve belleğe ulaşması	Biçimini hiçbir dedektörün tanımadığı bir secret
Diff ve metin ön koşulu	Bir secret'ın pull request üzerinden code host'a ulaşması; bu run'a çıkarılmış değerler credential servisinden çıkmadan eşleştirildi	Satırlara bölünmüş ya da tarayıcının kaçırdığı bir biçimde kodlanmış bir secret ya da başka bir run'a ya da agent'a çıkarılmış bir değer
Dar, kısa ömürlü grant	Sızsaydı code host credential'ının değeri	Kapsamının o dakikalarda izin verdiği her şey
Bulgu ve rotation	Kaynak kusur ve saklanan kopya	Log satırı ile rotation arasında geçen süre

Trade-off'lar ve maliyetler

Ayakta tutulacak bir sisteme ve her etkide bir sıçramaya mal olur.

Credential servisi ve scrub, her tool çağrısının yolundadır. Credential servisi kapalıysa agent eyleme geçemez; bu yüzden Alex'in ekibinin bir sahibi, bir alarma ve belirtilmiş bir degraded mode'a ihtiyacı vardır; ops agent için bu genellikle "on-call mühendise hand-off yapmak"tır. Eklenen gecikme bir model çağrısının yanında küçüktür; Bölüm 22 maliyeti run başına sayar. Credential servisi eşleştirme için modelin yazdığı metni girdi olarak da alır; bu yüzden o metni veri olarak ele almalı, asla talimat olarak değil.

Scrubber'ın bir false positive maliyeti ve bir false negative maliyeti vardır. Aşırı redaction, bir soruşturmanın ihtiyaç duyduğu tanımlayıcıları kaldırır ve bunu olay sırasında fark eden bir ekip çıktıya güvenmeyi bırakır; yetersiz redaction gerçek secret'ları geçirir. Neyin isabet aldığı ölçülür, isabetlerin ve kaçırımların bir örnekleme takvimle gözden geçirilir ve en az şüphesi olan bilinen değer dedektörü en öne konur.

Rotation ve iptal insana mal olur. Provalar, güncel bir envanter ve kaynak log bulguları tekrarlayan iştir ve sahipsiz bir kontrol ilk önce sürüklenir.

Tam örüntüyü benimsemek bedava değildir. Tek bir agent'ı, tek bir salt okunur tool'u ve yönetilen bir secrets store'da dar bir token'ı olan bir ekip, bir credential servisi kurmadan önce durmakta haklı olabilir: tool runtime'ının tuttuğu tek bir dar credential ve çıktılarda bir scrubber, değerini çoğunu yakalar. Aparat, Bölüm 7'nin yetki için yaptığı gibi, bir sızıntının verebileceği zarara göre boyutlandırılır.

Meşru bir credential'ın izin verdiklerine karşı koruma sağlamaz. Kapsamı içinde kullanılan dar bir credential tasarlandığı gibi çalışıyordu; çağrının yapılıp yapılmaması gerektiği gate'e ve onaya aittir.

Sık yapılan hatalar

- **Credential'ı prompt'a ya da tool argümanlarına koymak, "model API'yi çağırabilsin diye".** Cazip, çünkü bir demoyu bir öğleden sonrada çalıştırıyor. Değeri bağlama, trace'e ve sağlayıcının isteğine koyar. Credential tool runtime'ına, modele ise kaynak için bir ad verilir.
- **Secret'ları ifşa etmeme talimatına güvenmek.** Cazip, çünkü tek satır ve riski gözle görülür biçimde "hallediyor". Cümle alıntı oranını düşürür ve trace, checkpoint ya da pull request için hiçbir şey yapmaz. Yardımı oluyorsa cümle tutulur ve işe yaramadığında tutan kontroller adlandırılır.
- **Yalnızca nihai cevabı scrub etmek.** Çıktı filtrelemesi doğal yer gibi hissettirir, çünkü bir insanın okuduğu yer orası. Sızıntı yolları gözlemlerden, trace'lerden ve yazımlardan geçer. Değerin geçebileceği her sınırdaki, girdiği yerden başlayarak scrub edilir.

- **Bir örüntü dedektörüne garanti gibi güvenmek.** Cazip, çünkü demo, yerleştirilen her anahtarı yakalıyor. O bir sınıflandırıcıdır. Bilinen değer dedektörüyle, bir kaçırmayı ucuz kılan dar credential'larla ve kusuru düzelten bir kaynak tarafı bulgusuyla eşleştirilir.
- **Uzun ömürlü credential'ları, "çalışıyorlar" diye rotation yolu olmadan bırakmak.** Cazip, çünkü rotation'ın olaya kadar görünür bir getirisi yok. Deploy olmadan rotate edilemeyen bir credential, bir olay sırasında da rotate edilmez. Rotation, ihtiyaç duyulmadan önce rutin hale getirilir.
- **Bir diff'teki secret'ı yakalamak için reviewer'a güvenmek.** Cazip, çünkü review zaten var ve yeni bir maliyeti yok. Reviewer'lar mantık için okur ve bir insan diff'te bir string'i fark etmekte kötüdür. Push'tan önce kodda taranır ve reviewer ikinci hat sayılır.
- **Varsayılan olarak her şeyi izlemek.** Cazip, çünkü tam trace'ler debugging'i kolaylaştırır. Header'ları ve gövdeleri kaydeden genel instrumentation, her yeni tool'u bir sızıntıya çevirir. Varsayılan olarak tanımlayıcılar yakalanır, yakalanan allowlist'e bağlanır ve bir tool eklendiğinde pipeline gözden geçirilir.
- **Her canlı credential değerini bir scanner'da toplamak.** Cazip, çünkü tam eşleştirme en kesin kontroldür. Scanner'ı bir secret store'una çevirir; değerlerin yaşadığı yerde karşılaştırılır ve yalnızca tür ile konum döndürülür ya da fingerprint'ler karşılaştırılır.
- **İptal prosedürünü yazıp hiç çalıştırmamak.** Cazip, çünkü doküman hazırlık gibi görünür. Tatbikat, revoke çağrısı olmayan sistemi bulur. Bunu olay sırasında bulmaktan ucuzdur.

Temel çıkarımlar

- Bir secret modelin bağlamına asla girmez; tool runtime'ı credential'ı modelin dışında inject eder, böylece model bir kaynağın adını verir ve yetkiyi etki katmanını sağlar.
- Her tool schema'sı credential alanlarına kapalı olmalıdır, çünkü birini geçirmeye çalışan bir öneri bozuktur ve gate, hiçbir şey çalışmadan önce onu reddeder.

- Saklanmış bir secret yerine bir workload identity'den çıkarılan, kısa ömürlü, dar ve bir run'a bağlı credential'lar tercih edilir; bootstrap secret'ının ve kalan uzun ömürlü credential'ların dürüst bir listesi tutulur.
- Secret'ların yine de dünyadan geleceği varsayılır ve sınırdaki dedektör ile scrub edilir: sistemin çıkardığı değerler için deterministik olanla ve biçimler için olasılıksal olanla; kaçırımlar ve false hit'ler sayılarak.
- Her `open_pull_request` yasaklı yol listesine ve diff ile metnin secret taramasına bağlanır, bulgunun türü ve konumu döndürülür ama değer asla; insan reviewer kontrol sayılmaz.
- Credential id'leri ve bulgu fingerprint'leri kaydedilir, değerler asla; trace'lerde, checkpoint'lerde ve bellekte yazmadan önce scrub edilir, çünkü Kayıt sızıntısının en uzun yaşadığı yerdir.
- Rotation rutin hale getirilir ve principal bazında iptal, çıkarmayı donduran, başarısızlıkların ötesinde devam eden, ayrı bir sorguyla doğrulayan ve bitmemiş etkileri bir insana devreden, prova edilmiş tek bir işlem olarak yürütülür.

Credential'ın modele hiç ulaşmaması, modelin önerdiği kod için ikinci bir soru bırakıyor: `run_diagnostic` bir script çalıştırdığında o script neye ulaşabilir ve buna kim karar verir? Bölüm 19, sandbox'a dönüyor.

Bölüm 19 — Sandboxing

Parcelport'ta `run_diagnostic`'in ilk sürümünü düşünelim. On-call SRE Robin, yavaş giden bir teslimat grubunu inceliyor. Ops agent log'ları ve bir trace'i okudu ve kısa bir script öneriyor: saklanmış bir log satırı örneğini ayrıştır, hataları taşıyıcıya göre grupta, bir tablo bas. Orchestrator onu kendi host'unda geçici bir dizine yazıyor, aynı kullanıcı olarak çalıştırıyor ve bastığı her şeyi döndürüyor.

Script çalışıyor. Aynı zamanda orchestrator'ın ortamına da sahip, çünkü bir child process'in miras aldığı şey bu. Yol boyunca örneği bulmak için birkaç dizini listeliyor ve okuduğu dosyalardan biri, bir servis token'ı tutan bir konfigürasyon dosyası. Bunların hiçbiri kötü niyetli değil: script gördüğünü bastı ve çıktı modelin bağlamına, trace'e ve run store'a gitti.

Bir model tarafından yazılmış script, kimsenin review etmediği bir programdır ve onu başlatan sürecin yetkisiyle çalıştı. Bu bölüm kontrol zarfının **Etki** parçasına aittir: onaylanmış bir eylemin dünyaya nasıl ulaştığı, onu neyin sınırladığı ve neyin geri alabileceği. Eylem "bu kodu çalıştır" olduğunda, kodun ulaşabileceği dünya nedir ve buna kim karar verdi?

Sorun ve neden zor olduğu

Bu kitaptaki diğer her tool argüman alır. Bir tool sözleşmesi bu argümanları bir schema ile tarif edebilir, gate onları ön koşullara karşı kontrol edebilir ve ne olacağına tool'un kendi kodu karar verir. Bir çağrının yapabileceği şeylerin kümesini tool belirler ve model yalnızca onun içinde değer seçer.

Script farklıdır. Model bir program sağlar ve bir programın yaptığını sınırlayan bir schema'sı yoktur: dosya açabilir, süreç başlatabilir ve ağ bağlantıları kurabilir. Öneri, bir eylem hakkında veri değil, eylemin kendisidir ve erişimini çalıştığı yer belirler.

Hata sınıfları buradan çıkar. En doğrudanı F7'dir (yetkisiz etki): script, principal'ının doğrabilmemesi gereken bir şeyi, miras aldığı ve kimsenin çıkarmadığı bir yetkiyi kullanarak yapar. Hemen arkasından F9 (maliyet ya da gecikme patlaması) gelir; bir döngü ya da bellek obur bir ayrıştırma host'u ya da bütçeyi beraberinde götürdüğünde. F6 (sessiz kısmi hata), bir şey yazan bir script yarı yolda öldürüldüğünde ve hiçbir şey bunu söylemediğinde ortaya çıkar; F8 (gözlenmeyen davranış) ise tek kanıt script'in basmayı seçtiği şey olduğunda. F4 (talimat ele geçirme) iki kez devreye girer: bir script, modelin okuduğu log'lardaki enjekte edilmiş içerikle şekillenmiş olabilir (Bölüm 16) ve bastığı şey bağlama geri gider.

Bariz yaklaşımlar neden tutmaz

İlk içgüdü, script'i çalışmadan önce review etmektir. Bir insan bunu bir döngünün hızında yapamaz ve bir program, genel olarak, başka bir programın ne yapacağına karar veremez. Statik kontroller filtreler; sınır değildir.

İkincisi, dili güvenli bir alt kümeyle ya da bir komut listesiyle kısıtlamaktır. Bölüm 6, öneri uzayını mümkün olan her yerde daraltır, ama bir diagnostic esnek olduğu için değerlidir ve bir açığı kapatan her kısıtlama meşru bir analizi de ortadan kaldırır.

Üçüncüsü, modele ulaşmaması gereken dosyaları okumamasını ya da host'ları çağırmasını söylemektir. Bu, böyle script'lerin oranını düşürür ve biri yine de önerildiği gün tutamaz (Bölüm 16). Özellik önemliyse, onu ortamın uygulatması gerekir.

Bu bölümün argümanı: **kodun yanlış ya da düşmanca olduğu varsayılır ve çalıştığı yer, bu varsayım az maliyetli olacak şekilde kurulur.**

Geçici dizin bir sandbox değildir

Bir script'i yeni oluşturulmuş bir geçici dizinde çalıştırmak izolasyon gibi hissettirir. Değildir. Script'in home dizinini başka yere yöneltmek, ortam değişkenlerini temizlemek ya da onu farklı bir çalışma dizininden çalıştırmak da değildir.

Bunların her biri, uslu kodun bir şeyleri nerede aradığını değiştirir; kodun neye ulaşabildiğini değil. Script yine aynı kullanıcıyla, aynı dosyalarla, ağla, keystore'larla ve süreç başlatma yeteneğiyle çalışır. Bir yol bir

konvansiyondur ve ona uymayan bir script durdurulmaz.

Bu kitabın anlamında bir sandbox, kodun dosyalarda, ağda ve credential'larda neye ulaşabileceği üzerinde uygulanan sınırları olan bir yürütme ortamıdır. "Uygulanan", kodun konuşarak aşamayacağı bir şey tarafından uygulanan demektir: ayrı bir kullanıcı ya da container ya da sanal makine, kapalı ya da bir allowlist'e kısıtlı bir ağ ve yalnızca çalışma dizinini tutan bir dosya sistemi. Ortam bu yollardan biriyle ayrı değilse, güzel bir adı olan bir geçici dizindir.

Bir güven sınırı olarak sandbox

Bölüm 8'in terimi kullandığı anlamda bir güven sınırı, veri ya da yetkinin kontrol edilmeyen bir kaynaktan geldiği bir çizgidir. Sandbox bu çizgiyi koda çeker. İçerisi, orchestrator'ın yazmadığı bir programdır. Dışarısı, Parcelport'un kontrol ettiği her şeydir: log store, run store, ağ, credential'lar.

Çizgiyi iki şey geçer ve tasarım ikisini de dar tutmakla ilgilidir. Girdiler içeri girer: script metni ve üzerinde çalıştığı veri. Çıktılar dışarı çıkar: script'in bastığı şey, ürettiği dosyalar ve sonlanış biçimi. Başka hiçbir şey geçmez.

Sandbox'ın altı özelliği uygulatması gerekir.

- **Dosyalar.** Script yalnızca orchestrator'ın onun için hazırladığını görür ve yalnızca bir scratch alanına yazar.
- **Ağ.** Varsayılan olarak kapalı, istisnalar adlandırılmış ve gerekçelendirilmiş.
- **Kaynaklar.** CPU, bellek, süreçler, disk ve duvar saati süresi sınırlıdır ve bir sınırı aşmak run'ı sonlandırır.
- **Kimlik.** Kod, orchestrator'dan ve herhangi bir insandan ayrı, kendi principal'ı olarak çalışır.
- **Credential'lar.** Hiç ya da görevin ihtiyaç duyduğu en küçük küme (credential'ların nasıl çıkarıldığını ve modelin neden onları asla tutmadığını Bölüm 18 anlatıyor).
- **Ömür.** Ortam tek bir yürütme için oluşturulur ve sonrasında yok edilir.

İzolasyon mekanizmasını seçmek

İzolasyon mekanizmaları, kodun ve host'un neyi paylaştığı konusunda farklılaşır ve paylaştıkları şey, bir sandbox kusurunun bir host kusuruna dönüştüğü yerdir. Tablo ürünleri değil sınıfları tarif ediyor ve maliyetler görecelidir.

Mekanizma	Host ile paylaşılan	İzolasyon gücü	Tipik maliyet
Ayrı süreç, ayrı kullanıcı	Kernel, dosya sistemi, ağ, makinenin çoğu	En zayıf; yalnızca izinlerin sınırladığını sınırlar	En düşük; başlatması basit
Container	Host kernel'ı; izolasyon, bir sürecin gördüğünü ve kullandığını kapsamlayan kernel özelliklerinden gelir	Orta; paylaşılan kernel'daki bir kusur, sınırdaki bir kusurdur	Düşük; hızlı başlar, tanıtık araçlar
Syscall filtreli ya da user-space kernel'lı container	Daraltılmış ya da yeniden gerçekleştirilmiş bir kernel arayüzü	Düz bir container'dan güçlü, filtrenin kapsamına bağlı	Orta; bazı programlar farklı davranır ya da başarısız olur
Sanal makine	Bir hypervisor üzerinden donanım; kodun kendi kernel'ı vardır	Güçlü; paylaşılan yüzey daha küçük ve daha iyi incelenmiş	Daha yüksek; daha yavaş başlar, daha çok bellek, işletmesi daha fazla
microVM	Azaltılmış aygıt kümeli minimal bir hypervisor üzerinden donanım	Güçlü, türce sanal makineye benzer	Container ile sanal makine arasında; kendi araçlarına ihtiyaç duyar

Tek bir soru sorarak seçerdim: kodu kim yazdı ve cevaba ne kadar güvenilebilir? Parcelport mühendislerinin yazıp review ettiği sabit bir katalog script'i, sertleştirilmiş bir container'da çalışabilir, çünkü kod bilinir ve sandbox ikinci savunma hattıdır. Modelin oluşturduğu bir script ise keyfi koddur. Bu sınıf yürütmeyi bir sanal makinede ya da bir microVM'de başlattırdım ve daha hafif bir şeye ancak bir sınır başarısızlığının neye mal olacağını tarttıktan sonra geçtim.

Katmanlar

Tek bir sınır sandbox değildir. Aşağıdaki her katman ayrı bir kontroldür, bir diğerinin yanlış yapılandırıldığı gün için oradadır ve her biri kısıtladığı kodun dışında uygulanır.

Dosya sistemi: bir çalışma dizini ve salt okunur bir root

Sandbox'ın root dosya sistemi salt okunurdur. Önceden hazırlanmış, script'in kullanabileceği yorumlayıcıyı ve kütüphaneleri içerir; başka hiçbir şey. Script onu değiştiremez ve içine bir şey kuramaz.

Bu root'un üstünde iki mount durur. Biri, orchestrator'ın saklanmış örneği ve parametreleri koyduğu, salt okunur mount edilmiş girdi alanıdır. Diğeri, yazılabilir, boyutu sınırlı ve sandbox ile birlikte atılan bir scratch ve çıktı alanıdır. Script'in görebildiği her şey bu üç yerdedir.

İki şey tasarım gereği dosya sisteminin dışında kalır: orchestrator'ın konfigürasyonu ve host'un home dizinleri. Bir yolla gizlenmezler, başka bir makinedeki bir dosyanın yok olduğu gibi yoktur.

Bağımlılıklar image'a gömülüdür. Çalışma zamanında kütüphane kuran bir script ağ erişimine ihtiyaç duyar, review edilmemiş kod çalıştırır ve farklı günlerde farklı sonuçlar verir. Profil image sürümünü adlandırır; böylece bir run, daha sonra neyin içinde çalıştığını tam olarak söyleyebilir.

Ağ: varsayılan olarak kapalı

Varsayılan hiç ağ olmamasıdır: giden bağlantı yok, gelen yok, ad çözümleme yok. Kitabın `run_diagnostic`'inde olan budur ve girdileri zaten hazırlanmış bir diagnostic için doğru varsayılandır.

Sandbox'taki bir görev gerçekten bir şeye ulaşmak zorunda kaldığında istisna **egress** noktasında yapılır: ortamdan çıkan trafik, bir hedef allowlist'i tutan ve sandbox'ın dışında işletilen bir proxy ya da gateway'den geçer. Allowlist belirli hedefleri ve her biri için gerekçeyi adlandırır. Script'in terbiyesi tarafından değil, ağ yolu tarafından uygulanır.

Olağan zayıflık, bir hedefin genişliğidir. Genel amaçlı bir hosting servisi, bir code host ya da herkese açık bir paste servisi için bir allowlist girdisi, pratikte açık bir kanaldır, çünkü ona her şey gönderilebilir. Hedef, veriyi

Parcelport'un kontrol etmediği bir tarafa taşıyabiliyorsa, tehdit modelinde o açık egress sayılır.

Kaynaklar: CPU, bellek, süreçler, disk ve zaman

Sınırı olmayan bir script makineyi tüketebilir. Sınırlar; CPU süresi, bellek, script'in başlatabileceği süreç sayısı, scratch'e yazılan disk ve duvar saati süresidir. Bölümün ilerisindeki profil, örnek değerleri yerinde gösteriyor.

Sayılardan daha önemli iki özellik var. Birincisi, sınırları script değil sandbox uygular; böylece hiç bitmeyen bir döngü dışarıdan bitirilir. İkincisi, bir sınıra çarpmak bir takılma değil adlandırılmış bir sonuçtur: sandbox yok edilir ve sonuç `exit: limit_exceeded` ve çarpılan sınırın adını taşır. Bu, sonucun bir alanıdır, bir hata kodu değil. Deadline'ı yüzünden öldürülen bir diagnostic, döngünün üzerinde akıl yürütebileceği (Bölüm 12) ve run'ın bütçesine sayılan (Bölüm 13) normal bir sonuçtur.

Kimlik ve credential'lar

Script, yalnızca sandbox'lı kod için var olan, ne orchestrator'ın ne de bir insanın kimliği olan bir kimlikle çalışır. Böylece bir audit, başka yerdeki bir sınır başarısız olsa bile sandbox etkinliğini orchestrator etkinliğinden ayırt edebilir.

Diagnostic sandbox'ı için credential kuralı mümkün olanların en güçlüsüdür: hiç. Bölüm 7'nin tablosu, sandbox'ın verecek bir şeyi olmadığı için `run_diagnostic`'in credential'a ihtiyaç duymadığını söyler; burada o cümle uygulanan bir özelliğe dönüşür.

Her sandbox bu kadar çıplak olamaz. Tek bir dahili servisten okuyan bir görev, işe yarayan en küçük credential'ı alırdı; run başına çıkarılır ve tamamlanınca iptal edilir (mekanikleri Bölüm 18'de). Tercih sırası şöyledir: credential yok, sonra sandbox'ın dışında tutulan ve bir proxy'nin izin verilen bir isteğe eklediği credential, sonra içinde kısa ömürlü bir credential; listede aşağı inilen her adım bilinçli bir karardır.

Tasarım gereği geçici

Her run, aynı image'dan ve profilden oluşturulan ve run bittiğinde yok edilen yeni bir sandbox alır. Hiçbir şey taşınmaz: dosya yok, süreç yok, cache'lenmiş state yok. Ele geçirilmiş ya da kafası karışmış bir yürütme tek

bir run boyunca yaşar ve temiz başlangıç, run'ları debugging ve eval'ler için tekrarlanabilir kılar (Bölüm 21).

Parcelport'ta diagnostic sandbox'ı

Şimdi katmanlar `run_diagnostic` için bir araya getirilir. Tool bir okuma olarak sınıflandırılmıştır ve bu sınıf yalnızca sandbox sayesinde doğrudur: bir servise yazabilen ya da veriyi dışarı gönderebilen bir script okuma olmazdı. Sözleşme, tool kadar sandbox hakkında da bir ifadedir ve bunu sözleşmenin kendisinde söyledim. Bölüm 6'nın gösterimini kullanır; sayılar örnek değerlerdir.

```
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 }
```

Model script'i ve bir örneğin id'sini sağlar. Profili, image'ı, sınırları ya da ağı seçmez; bunları orchestrator belirler ve gate profili kontrol eder. Model bir program önerir, ama programın içinde yaşadığı dünya önerinin parçası değildir.

Script kendi verisini çekmez, çünkü çekmek credential ve ağ gerektirir. Gate'in zaten kontrol ettiği önceki bir `query_logs` çağrısı örneği üretti ve sandbox onun salt okunur bir kopyasını alır.

Profil

Profil veridir; yazılı ve sürümlüdür, bir prompt'taki düzyazı değil. Aşağıdaki gösterim örnektir ve herhangi bir ürünün konfigürasyon sözdizimi değildir.

```
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
```

Bir reviewer her soruyu bu bloktan cevaplayabilir: script neyi okuyup yazabilir, neye ulaşabilir, kimin kimliğini taşır ve ne zaman biter.

Yaşam döngüsü

Yaşam döngüsünün sahibi orchestrator'dır ve yaşam döngüsü, kitabın ayrı sistemler hakkındaki kuralının geçerli olduğu bir yerdir. Aşağıdaki sandbox manager ve sweep örnek bileşenlerdir, kitabın referans sisteminin servisleri değil. Manager, run store ve trace pipeline'ı ayrı sistemlerdir; dolayısıyla hiçbir tek adım hepsini kapsamaz ve adımlar arasındaki her hata atlatılabilir olmalıdır.

```

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

```

Hatalar sırayla izlenebilir. Oluşturma başarısız olursa hiçbir şey var olmaz ve çağrı `upstream_unavailable` ile başarısız olur; niyet zaten kayıttadır. Orchestrator yok etmeden önce çökerse, hiçbir run'ın beklemediği bir sandbox var olur. Profilin ömür kuralını orchestrator değil manager uygular ve periyodik bir sweep, sahibi olan run'ı bitmiş ya da kaybolmuş sandbox'ları yok eder. Sıfırdan farklı bir sweep sayısı bir alarma değer.

Yok etme başarısız olursa run bir `sandbox_leak` kaydeder, sonuç yine döndürülür ve sweep artığı yakalar. Yok etmeden sonra kayıt çağrısı başarısız olursa sonuç kaybolur ama niyet kaybolmaz; devam ettirilen bir run (Bölüm 10) diagnostic'i yeniden çalıştırır ve sözleşme onu bir okuma olarak sınıflandırdığı için tekrarlamak hiçbir şeyi değiştirmez.

Sıradaki diyagram sınırı neyin geçtiğini ve neyin geçmediğini gösteriyor.



Her iki geçiş oku da dardır: içeri bir script ve bir örnek girer; dışarı adlandırılmış tek bir dosya çıkar. Geri kalan her şey, script'in davranışına değil profile ait bir ret ile biter. Önceki prototipe kıyasla profil, bir child process'in varsayılan olarak sahip olduğu her şeyi kaldırır ve bir döngü artık adlandırılmış bir sınırdan biter.

Sandbox çıktısı güvenilmeyen girdidir

Script bitti ve bir tablo bastı. Tabloyu bir Parcelport tool sonucu gibi ele almak cazip, çünkü Parcelport'un altyapısından geldi. Oysa modelin yazdığı, müşterilerden ve log'lardan metin içerebilecek veri üzerinde çalıştırılan bir programdan geldi. Çıktısı, bir modelin önerisi gibi, güvenilmeyen girdidir.

Orchestrator, çıktı modele ulaşmadan önce dört şey yapar.

1. **Sınırla.** Çıktının bir azami boyutu vardır ve kırpma gözleminde belirtilir. Sınırsız bir çıktı, run için bir bağlam bütçesi problemi (Bölüm 9) ve bir maliyet problemidir (Bölüm 22).
2. **Biçimlendir.** Yalnızca adlandırılmış sonuç dosyası çıkar ve orchestrator onu beklenen bir yapıya karşı veri olarak ayrıştırır; bir ayrıştırma hatasını F1 (bozuk çıktı) olarak ele alır. Script'in scratch'te bıraktığı başka hiçbir şey açılmaz, çalıştırılmaz ya da render edilmez.
3. **Tara.** Çıktı, saklanmadan ya da gösterilmeden önce Bölüm 18'in secret taramasından ve Bölüm 17'nin redaction'ından geçer. Sandbox credential tutmaz, ama aldığı veri bir log satırının yankıladığı bir secret içerebilir ve script onu basabilir.
4. **İşaretle.** Sonuç, köken etiketiyle bağlama girer: bir script tarafından, saklanmış bir örnekten, `diagnostic_v1` profili altında üretildi. Taint taşır (Bölüm 16), çünkü log satırlarını işleyen bir script, başkasının yazdığı metni yeniden üretiyor olabilir.

İşaretleme atlamak kolaydır ve atlamak pahalıdır. Bir diagnostic'in çıktısı, bir pull request ya da bir onay isteği önerebilen bir döngüyü besler. İşaret olmazsa, bir log satırının içinde gelen metin, kökenine dair her işaret silinmiş olarak modelin bağlamına ulaşır. Taint işareti, gate'in ondan önerilen sonraki bir `open_pull_request`'e özenle davranmasını sağlar.

Sandbox conformance testleri

Uygulama sürüklenebilir: farklı bir varsayılanla yeniden build edilen bir image, başka bir tool için değiştirilen bir ağ politikası. Sınırın kendisini, takvimle ve image ya da profilde her değişiklikten sonra test ederdim. Platform ekibi production profiliyle bir sandbox'ta sabit, review edilmiş bir probe çalıştırır ve probe, profilin yasakladığını dener: var olmaması gereken bir yolu okumak, ulaşamaz bir host'a ulaşmak, bir sınırı aşmak. Her probe beklenen biçimde başarısız olmalıdır ve başarısız bir probe yeni image'ın release'ini engeller. Bunlar net bir geçti ya da kaldı sonucu olan kontrol testleridir, modelin eval'leri değil ve takvimin bir sahibi olması gerekir.

Bir sandbox'ı gözlemek

Sandbox'ın içinde, tasarım gereği, bir izleme agent'ı yoktur: script'in rapor edebileceği bir ağ ve kimliğini doğrulayacağı credential'lar yoktur. Kanıt, sandbox manager'ın dışarıdan topladığı şey artı script'in söylemeyi seçtiği şeydir.

Her yürütmenin kaydı; profil id'sini ve image sürümünü, script'in bir hash'ini, örnek id'sini, çıkış nedenini (finished, error, `limit_exceeded` ve hangi sınır), manager'ın ölçtüğü en yüksek bellek ve CPU'yu, çıktının boyutunu ve kırılıp kırılmadığını ve sandbox katmanı sayıyorsa reddedilen işlem sayısını içermelidir. Reddedilen bir bağlantı denemesi, bir diagnostic'in ya bozuk ya da yönlendirildiği anlamına gelir ve birinin bakması gerekir. Span şeklini Bölüm 20 ele alıyor; burada şahit, script değil manager'dır.

Not: Script'in kendi print ifadeleri, script'in ne söylediğinin kanıtıdır, ne yaptığının değil. İkisi kayıta ayrı tutulur. Davranışı yeniden kurmak için çıktıya dayanan bir audit, tanık kürsüsünü sanığa devretmiştir.

Script metni trace'e aittir, çünkü yeniden üretilmeyen bir run, açıklanamayan bir run'dır. Örnekten kopyalanmış veri içerebilir; bu yüzden saklanan metne de aynı redaction uygulanır (Bölüm 17).

Trade-off'lar ve maliyetler

Yukarıdaki her katmanın bir bedeli var ve bedeli belirli insanlar öder.

Başlangıç gecikmesi. Her run için yeni bir sandbox, her run'ın soğuk başlaması demektir ve bir sanal makine ya da microVM bir container'dan yavaş başlar. Her step'te bir script çalıştıran bir döngü, bu başlangıcı run'ın duvar saati sınırına ekler. Temiz olarak dağıtılan önceden oluşturulmuş sandbox'lardan bir havuz, başlangıç süresini daha karmaşık bir yaşam döngüsüyle takas eder ve havuzun hiçbir sandbox'ın yeniden kullanılmadığını garanti etmesi gerekir. Yeniden kullanıma bir gün izin verilirse "geçici" gitmiştir ve bu, sessiz bir optimizasyon değil kayda geçmiş bir karar olmalıdır.

İşletme maliyeti. Bir sandbox filosu, birinin ayakta, yamalı ve ölçülmüş tuttuğu bir sistemdir. Sandbox manager, ops agent'ın yeni bir bağımlılığıdır; kapalıyken tool `upstream_unavailable` ile başarısız olur ve degraded mode (Bölüm 14) diagnostic olmadan devam edip bunu söylemektir. Filoyu işletemeyecek kadar küçük bir ekip, yönetilen bir sandbox servisini düşünmeli ve sonra o servisi her diğer gibi bir güven sınırı olarak ele almalıdır (Bölüm 8).

Sınırlı kullanılabilirlik. Kapalı bir ağ ve salt okunur bir root, bazı analizlerin çalışamayacağı anlamına gelir: bir referans tablosu çekmek, bir servisi çağırmak, image'da olmayan bir kütüphaneyi kullanmak. Her biri bir istisna talebidir ve her istisna, sahibi olan bir karardır. Ağı açmak yerine veri hazırlanır ya da kütüphane image'a eklenir.

Azalmış görünürlük. Başarısız bir script'i debug etmek, sürece bağlanmak değil manager'ın kaydını ve yakalanmış bir çıktıyı okumak demektir ve ekibin ne kadar replay aracı kuracağına karar vermesi gerekir.

Yazarlar için sürtünme. Profilin ve image'ın sahibi platform ekibidir ve her değişiklik bir review'den geçer; bu yüzden on-call mühendis bekler. Runbook'ta bir profil değişikliğini kimin onayladığı ve ne kadar sürdüğü yazılır.

Ne zaman kullanılmaz, ya da ne zaman daha azı yeter

Her yürütme bir microVM'e ihtiyaç duymaz. Parcelport mühendislerinin yazıp review ettiği, hazırlanmış veri üzerinde, yazma erişimi ve ağı olmayan kod, sertleştirilmiş bir container'da çalışabilir.

Sandbox, patlama yarıçapını profilin izin verdiğiine indirir ve profilin izin verdiğiine karşı koruyamaz: içerideki bir credential script'in sahip olduğu bir credential'dır ve izin verilen bir hedef, veri gönderebileceği bir hedeftir. Hiçbir izolasyon mekanizması bir garanti değildir; bu yüzden katmanlar ve conformance testleri vardır.

Sık yapılan hatalar

- **Bir geçici dizine sandbox demek.** Cazip, çünkü kolay ve script "izolasyonda çalıştı". Belirtisi, script'in hâlâ host'un kullanıcısına, ağına ve dosyalarına sahip olmasıdır. Çözüm, dosya sistemi ve ağ dışarıdan uygulanan ayrı bir kullanıcı, container ya da sanal makinedir.
- **Bir istisna için ağı açmak.** İlk istisna ucuzdur ve ikincisi onu izler. Çözüm, veriyi önceden hazırlamak ya da tek hedefi bir allowlist'li egress proxy'sinden geçirmek; gerekçesi ve bir sahibiyle yazıya geçirilmiş olarak.
- **Orchestrator'ın ortamını geçirmek.** Ortam değişkenleri, bir credential'ın yolculuk ettiği olağan yerdir. Cazip, çünkü script bir yola ya da bir ayara ihtiyaç duyuyor ve ortam zaten orada. Çözüm, boş bir ortamla başlayan ve yalnızca adlandırılmış girdiler alan bir sandbox ve bunu kontrol eden bir conformance probe'udur.
- **Sandbox güvenilir diye çıktıyı güvenilir saymak.** Cazip, çünkü çıktı Parcelport'un kendi altyapısından geldi. Sandbox kodu kapsar. Kodun döndürdüğünü temizlemez. Çözüm, bağlama taint taşıyan sınırla, biçimlendir, tara ve işaretle dizisidir.
- **Hız için bir sandbox'ı yeniden kullanmak.** Cazip, çünkü soğuk başlangıç zamana mal olur ve sıcak bir sandbox zaten bekliyor. Sıcak bir sandbox, bir run'ın state'inin bir sonrakine ulaşabildiği bir yerdir. Çözüm, kullanımdan sonra yok edilen temiz instance'lardan bir havuz ve yeniden kullanım bir gün istenirse kayda geçmiş bilinçli bir karardır.

- **Script'in sınırlar içinde kalmasına güvenmek.** Cazip, çünkü iyi yazılmış bir script durur. İki dakika sonra durması istenen bir script bir söz vermektedir. Çözüm, sandbox manager tarafından dışarıdan uygulanan sınırlar ve orchestrator çökse bile tutan bir ömür kuralıdır.
- **Sahipsiz sandbox'lar için sweep olmaması.** Yaşam döngüsü mutlu yolda doğru görünür. Çözüm, canlı sahibi olmayan sandbox'ları bulan periyodik bir sweep ve kaç tanesini yok ettiğine dair bir metric'tir.
- **Sözleşmenin etki sınıfının profilden uzun yaşamasına izin vermek.** Cazip, çünkü sözleşme yazıldığında doğrudur. `run_diagnostic` bir okumadır, çünkü profile ne ağ ne credential var. Biri bunlardan birini eklerse sınıf yanlışdır ve gate'in varsayımları da. Çözüm, profili kontrol eden bir gate ön koşulu ve profil değişikliklerinin sözleşmeyi yeniden açtığı bir review kuralıdır.

Temel çıkarımlar

- Modelin ürettiği ya da seçtiği kodu çalıştırmak ayrı bir güven sınırıdır, çünkü öneri, erişimini bir schema'nın değil çalıştığı yerin belirlediği bir programdır.
- Bir geçici dizin, değiştirilmiş bir home yolu ya da temizlenmiş bir ortam sandbox değildir; sandbox, ayrı bir kullanıcı, container ya da sanal makinedir; ağı kapalı ya da allowlist'li, dosya sistemi çalışma dizinine sınırlıdır.
- İzolasyon mekanizması kodu kimin yazdığına göre seçilir: review edilmiş katalog script'leri sertleştirilmiş bir container'da çalışabilir, modelin oluşturduğu kod ise bir sanal makineyi ya da microVM'i hak eder ve seçim, başlangıç süresi, maliyet ve işletme üzerinde bir trade-off'tur.
- Model script'i ve bir örneğin id'sini sağlamalı; profili, image'ı, sınırları ve ağı orchestrator belirlemeli, böylece kodun yaşadığı dünya hiçbir zaman önerinin parçası olmaz.
- Önce sandbox'ta credential olmaması, sonra dışarıda tutulup bir proxy'nin eklediği credential, sonra içindeki kısa ömürlü credential tercih edilir ve her adım bilinçli ve kayda geçmiş bir karar olur.
- Sandbox çıktısı güvenilmeyen girdidir: sınırla, yalnızca adlandırılmış bir sonuç dosyasını veri olarak ayırıştır, tara ve redact et ve bağlama

girmeden önce köken ve taint ile işaretle.

- Bir sandbox'ın maliyeti soğuk başlangıçlarda, işletmede ve görünürlüktedir; sınırının takvimli conformance testlerine, her yürütmeye dışarıdan şahitlik eden bir manager'a ve run'larından uzun yaşayan sandbox'lar için bir sweep'e ihtiyacı vardır.

Sandbox kodu yerinde tutar; sistemin doğru davranıp davranmadığını söylemez. Kısım VI bu soruya dönüyor; Bölüm 20 ve bir bütün run'ın trace'inin neleri içermesi gerektiğiyle başlıyor.

KISIM VI

Kanıtlamak ve İşletmek

Bölüm 20 — Observability ve Tracing

Parcelport'ta bir Cuma sabahını düşünelim. Destek lideri Sam, iade almış ve siparişte kimsenin bulamadığı bir teslimat tarihi vaat eden bir cevap görmüş bir müşterinin mesajını iletiyor. Sam, orchestrator'ın sahibi Alex'e basit bir soru soruyor: agent bu ticket'ta ne yaptı?

Alex bilgisi olabilecek yerleri açıyor. Ticket sisteminde nihai cevap var. payments-service'te iade var, bir tutarla ve bir zaman damgasıyla. Orchestrator'ın uygulama log'unda run'ın bittiğini söyleyen bir satır var. Eksik olan, arada kalan her şey: agent hangi siparişe baktı, sorgu ne döndürdü, bu öneri geçmeden önce gate hangi önerileri reddetti, bir insan bir şeyi onayladı mı, run kaç step sürdü ve tarih cümlesini hangi model çağırısı üretti. İade bir olgu. Ona giden akıl yürütme yolu ise bir tahmin.

Alex iyi tahmin edebilir, çünkü döngüyü kendisi yazdı. Ama Sam bir yeniden kurgu istedi ve bir sonraki alarmı alan on-call mühendis Alex olmayabilir. Bu bölüm, kontrol zarfının **Kayıt** parçasına ait bir soruyu cevaplıyor: bir run nasıl bir kanıt bırakır ve bu kanıt, ne olduğunu ve neden olduğunu söylemeye yeter mi? Neyin gözlemleneceğini, bunun bir trace olarak nasıl biçimlendirileceğini, içerikten neyin saklanacağını, hangi sayıların türetileceğini ve neye alarm kurulacağını ele alıyor.

Sorun ve neden zor olduğu

Hata F8 (gözlenmeyen davranış): sistem bir şey yaptı ve kullanılabilir bir kanıt bırakmadı, dolayısıyla kimse ne olduğunu ya da nedenini söyleyemiyor. Kayıt parçasına ait tek hata sınıfı bu ve dokuz sınıf arasında alışılmadık bir özelliği var. Diğerleri agent'ın yaptığı şeyler. F8 ise diğerlerini görme becerisine olanlar. Yanlış iade yapan bir run F2'dir (yanlış tool ya da yanlış argümanlar). Yanlış iade yapıp iz bırakmayan bir run hem F2 hem F8'dir ve birincisinin anlaşılmasının bir hafta sürmesinin nedeni ikincisidir.

Bir agent için observability, geleneksel bir servise göre dört nedenle daha zordur.

Birincisi, ilginç soru "istek başarısız oldu mu" değildir. Bir run temiz bir nihai cevap döndürebilir, yalnızca normal görünen step'ler atabilir ve yine de yanlış olabilir, çünkü cevaptaki bir iddia hiçbir tool sonucuyla desteklenmiyordur (F3, dayanaksız iddia). Durum kodu gayet iyidir. Davranışın doğru olup olmadığı run'ın içeriğinden okunmak zorundadır; dışarıda bırakmaya en çok meyledilen kısım da budur.

İkincisi, run bir karar dizisidir ve sıra önemlidir. Geleneksel bir request handler'ın okunabilen bir kod yolu vardır. Bir agent'ın yolu ise çalışma anında, her step'te bir model önerisiyle üretilir; yani yol veridir ve onu ancak kaydedildiyse bilmek mümkündür.

Üçüncüsü, kanıt hassas malzemeyi içerir. Bağlam ticket metnini, müşteri alanlarını ve tool sonuçlarını tutar; öneriler bunları yankılar. Bir trace'i hata ayıklama için yararlı kılan her şey, Bölüm 17'nin en aza indirilmesini söylediği şeydir. Gerilim gerçektir ve bedelsiz bir çözümü yoktur.

Dördüncüsü, hacim dengesizdir. 15 step'lik bir run (diyelim) onlarca span üretir ve her model çağrısı büyük bir payload taşıyabilir. Her şeyi herkes için uzun süre saklamak pahalıdır, körlemesine örnekleme ise tam ihtiyaç duyulan run'ı atar.

Bariz yaklaşım, uygulamanın zaten log'ladığını log'lamak ve "hata ayıklama için" modelin ham girdisini ve çıktısını eklemektir. Bu, yapısı olmayan bir metin satırı yığını üretir: hangi run'ların `issue_refund`'a dokunduğunu, gate'in ne kadar sürdüğünü ya da geçen hafta kaç run'ın bir insana devredildiğini sormak mümkün olmaz. Ayrıca ham müşteri verisini, Bölüm 17'nin karşı uyardığı şekilde, log store'una koyar. İkinci bariz yaklaşım, "akıl yürütmeni açıkla" gibi bir prompt satırıdır. Modelin açıklaması öneri tarafındaki bir başka string'dir. Yanlış olabilir, eksik olabilir ve gate'in ne karara bağladığı ya da Etki'nin ne döndürdüğü hakkında hiçbir şey söylemez. Kayıt, modelin kendisi hakkında yazdığı bir şey olamaz. Onu orchestrator yazar; deterministik olaylardan, modelin etrafında.

Bu yüzden bu bir mühendislik sorusudur. Observability, kontrol sisteminin bir özelliğidir: olayların nerede yayıldığı, ne taşıdığı, pipeline çöktüğünde ne olduğu, içeriği kimin okuyabileceği ve ne kadar yaşadığı. Bunların

hiçbirine bir prompt'tan ulaşılamaz.

Bir agent neyin gözlemlenmesine izin vermeli

Bölüm 1'deki döngüden başlanır ve her nokta için, bir kişinin run'ı yeniden kurgulayabilmesi için neye ihtiyaç duyacağı sorulur. Kontrol zarfının Kayıt'a giden kesikli okları cevaptır: bağlam, öneri, gate, onay ve etki hepsi rapor verir. Gözlemlemeye değer yedi tür şey var.

Gözlemlenen	Neyi cevaplar	Zarf parçası
Run	Onu kim ya da ne başlattı, hangi görev için, hangi sürümlerle ve nasıl bitti	Kayıt
Step	Döngünün hangi turu, hangi sırayla ve ne kadar sürdü	Sınır
Model çağrısı	Hangi model ve sürüm, kaç token girdi ve çıktı, ne kadar sürdü, geçerli bir öneri döndürdü mü	Öneri
Tool çağrısı	Hangi tool, hangi argümanlar, hangi etki sınıfı, sonuç, hata kodu	Etki
Gate kararı	Allow, refuse ya da needs approval; hangi politika sürümü altında ve hangi reason ile	Gate
Onay	Kim karar verdi, ne zaman, run ne kadar bekledi ve tam olarak hangi çağrı onaylandı	Gate
Bütçe tüketimi	Run her step'te her bütçenin ne kadarını kullanmıştı ve varsa hangi sınır onu durdurdu	Sınır

Bu listedeki iki şeyi atlamak kolaydır, çünkü bunlar model ya da bir tool'un ürettiği olaylar değildir. Gate kararı sistemin kendi koduyla verilir, bu yüzden kimse onu log'lanacak bir şey olarak düşünmez; oysa reddedilmiş bir çağrı, bir kontrolün işlediğinin tam kanıtıdır ve karardaki politika sürümü, aylar sonra hangi kuralın yürürlükte olduğu sorusunun cevaplanmasını sağlar. Bütçe tüketimi öteki: Bölüm 13 run'a bir bütçe verdi ve trace bütçenin tükenişini göstermelidir ki bir sınır tarafından durdurulan run, yalnızca bir durma olarak değil, durdurulmak üzere olan bir run olarak görünsün.

Bunların yanında, aynı trace'e ait olan iki olgu daha var: bağlam parçalarının tanımlayıcıları ve kökenleri (Bölüm 9), böylece bir iddianın hangi kaynaktan geldiği söylenebilir; ve run'ın state geçişleri (Bölüm 10). Ben her model çağrısında tanımlayıcıları ve köken etiketlerini, her

derlemenin manifest'iyle (Bölüm 9) ve ona giren bellek kayıtları için bir `memory_read` olayıyla (Bölüm 11) birlikte kaydeder, tam metni ise bu bölümde ileride anlatılan içerik store'una bırakırdım.

Not: Bölüm 10'un run store'u ile bu bölümün trace'i bilerek örtüşür. Run store, resume için ve etkiden önce niyet kaydı için doğruluk kaynağıdır; kendi içinde transaction'lıdır ve orchestrator tarafından okunur. Trace pipeline'ı insanlar içindir, sorgulama ve hacim için optimize edilmiştir ve veri kaybedebilir. Run store trace pipeline'ına bağımlı kılınmaz ve run state trace'lerden yeniden kurulmaz.

Trace: run bir trace, çağrılar span'ler

Bu kitabın tanımı kısadır. **Trace**, bir run'ın bileşenler arasındaki sıralı kayıdır. **Span**, onun içindeki zamanlanmış tek bir işlemdir. Genel biçim dağıtık izlemeden gelir ve OpenTelemetry bunun için yaygın açık standarttır. Span'ler iç içe geçer, attribute ve olay taşır, başka trace'lerdeki span'lere bağlanabilir; her istekle birlikte bir span context'i taşınır ki alıcı taraf kendi span'lerini aynı ağaca eklesin.

Bir agent için eşleme doğrudandır ve ben onu doğrudan tutardım.

- **Run, trace'in kendisidir.** Run id, trace id'dir ya da onunla bire bir eşlenir. Run id'yi bir ticket'tan ya da run store'dan alan herkes trace'i bulabilir.
- **Bir step bir span'dir**, run'ın kök span'i altında.
- **Bir model çağrısı, bir gate kontrolü, bir tool çağrısı ve bir onay beklemesi birer span'dir**, kendi step'lerinin altında.
- **State değişiklikleri, retler ve bütçe okumaları span olayları ya da attribute'larıdır**, yeni trace'ler değil.

Aşağıdaki metin ağacı, iki agent için de bir biçim gösteriyor. Bu bir şema değil, bir taslak; mesele iç içe geçme.

```

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

```

Bu `support-agent` ve `ops-agent` için aynıdır; döngüyü orchestrator'a koymanın yararı budur: aynı enstrümantasyon ikisine de hizmet eder. Yalnızca tool adları değişir. Tek bir dashboard'un, tek bir alarm setinin ve tek bir inceleme aracının ikisi için de çalışmasını sağlayan bu tekdüzellik.

Span attribute'ları

Değer attribute'lardadır. Adı ve süresi olan bir span zamanın nereye gittiğini söyler; doğru attribute'lara sahip bir span ne olduğunu söyler. Aşağıdaki tablo, her span türüne koyacağım attribute'ları listeliyor. Adlar bu kitabın kendi adlarıdır ve örnek amaçlıdır; izleme standardının adları varsa onlar kullanılır.

Span	Taşımaya değer attribute'lar
run	run.id, agent, task.kind, ticket.id ya da alert.id, principal, orchestrator.version, policy.version, prompt.version, mode (bozulma merdiveninin basamağı, Bölüm 14), status, stop.reason, failure.class
step	step.index, bound.remaining (step, harcama, süre)
model.propose	model.name, model.version, tokens.in, tokens.out, latency.ms, proposal.kind, proposal.valid (false, F'l'i işaretler), context.piece_ids
gate.check	tool, effect.class, verdict (allow, refuse, needs_approval), policy.rule, refusal.reason (bir gate kararı reason'ı, Ek'te listelenir), policy.version
tool.call	tool, effect.class, idempotency.key, outcome (success, hata kodu, unknown), latency.ms, attempt, retry.count

Span	Taşımaya değer attribute'lar
approval.wait	approval.id, approver.role, decision, wait.ms, bound.to (çağrının digest'i)

Bunlardan ikisi bir yorumu hak ediyor.

`failure.class` run üzerinde ve tespit edildiği span üzerinde, F1'den F9'a bir değerle ayarlanır. Bölüm 3'ün taksonomisinin sayılabilir bir şeye dönüşme yolu budur. Birçok run'ın değeri olmayacaktır, çünkü yanlış giden bir şey olmamıştır; yararlı olanlar, kontrol sisteminin bir sınıf tespit ettiği run'lardır (başarısız bir schema kontrolü F1'dir, yanlış sipariş için reddedilmiş bir çağrı gate'te yakalanmış bir F2'dir, bir sınır durması F5 ya da F9'dur). Hiçbir enstrümantasyonun ayarlayamadığı bir sınıf, görülemeyen bir sınıftır ve bunu bilmek kendi başına değerlidir.

`model.version` ve run span'indeki sürümler, her agent olayının eninde sonunda sorduğu sorunun cevabıdır: bir şey değişti mi? Model, prompt, tool sözleşmeleri, politika ve orchestrator'ın her birinin bir sürümü vardır ve hangilerinin altında çalıştığını söyleyemeyen bir run, geçen haftaninkile karşılaştırılmaz. Bir prompt kontrol değildir, ama davranışı değiştiren, deploy edilmiş bir yapıdır ve diğerleri gibi bir sürümü hak eder. Her sürümün yürürlüğe girdiği zamanla birlikte tutulan aynı alanlar, bir agent'ın değişiklik geçmiştir: ne değişti ve ne zaman. Bir alarm çaldığında on-call kişinin okuduğu ilk şeylerden biridir (Bölüm 13) ve Bölüm 23 sorgularını onunla kapsamlandırır.

Semantic convention'lar

OpenTelemetry'de ayrıca **semantic convention** fikri vardır: yaygın attribute'lar için üzerinde anlaşılmış adlar; böylece bir veritabanıyla ya da bir HTTP sunucusuyla konuşan her servis span'lerini aynı şekilde etiketler ve bir backend onları tanıyabilir. Üretken yapay zeka çağrıları için de convention'lar var; ayrı bir çaba olarak sürdürülüyorlar ve hâlâ evriliyorlar. Onlardan attribute adları listelemeyeceğim, çünkü hareket halindeki bir spesifikasyondaki adlar, kitap okunana kadar yanlış olmuş olabilecek türden ayrıntılardır. Örüntü sabittir: standardın adları varsa onlar kullanılır, böylece araçlar span'leri anlar; repo'da projenin kendi attribute'larından standardinkilere kısa bir eşleme tablosu tutulur; ve agent'a özgü attribute'lar (politika kararı, etki sınıfı, hata sınıfı) kendi

namespace'i altına konur, çünkü hiçbir genel convention onları taşımayacaktır. Adlara karar vermeden önce güncel spesifikasyon opentelemetry.io'dan okunur.

Context propagation: bir run'ı tek bir trace'te tutmak

Bir trace, ancak parçalar ebeveyn konusunda anlaşırsa bir ağaçtır. Bir agent sisteminde parçalar çoktur: orchestrator, model gateway, tool gateway, tool'ların arkasındaki servisler, onay servisi. Bir model çağrısı gateway'e geçer; bir tool çağrısı tool gateway'e ve oradan `orders-service` ya da `payments-service`'e geçer. Her bileşen kendi trace'ini başlatırsa, ortak bir id'si olmayan bir düzine parça olur.


Kontrol, context propagation'dır: orchestrator run'ın trace context'ini bir kez oluşturur ve onu her giden çağrıda, transport'un zaten sahip olduğu header'larda ya da metadata'da taşır. Gateway, tool gateway ve servisler span'lerini ona ekler. Bu, model gateway'in kendi gecikmesinin ve `payments-service` çağrısının ikisinin de onlara neden olan step'in altında durduğu bir ağaç verir.

Üç durum ekstra dikkat ister.

Askıya alınan bir run. Gate needs approval döndürdüğünde, orchestrator run'ı askıya alır (Bölüm 15) ve bir insan dakikalar ya da saatler sonra karar verir. Run, muhtemelen başka bir worker'da resume olur. Trace bundan sağ çıkmalıdır. Run'ın trace id'sini run store'da tutardım; böylece devam eden step aynı kökün altında bir span başlatır ve devam eden step'ten askıya alan step'e bir link eklerdim. Onayın bekleme süresi kendi başına bir span'dir; böylece "bu run (diyelim) dört saat sürdü" ifadesi, "bu run bir insanı (diyelim) üç saat elli dakika bekledi" olarak görülebilir.

Cevaptan sonraki iş. Bazı etkiler modelin nihai cevabından sonra tamamlanır: bir cevap queue'ya alınır ve sonra gönderilir, bir rollback `deploy-service`'te biter. Bu span'ler kök span sona erdikten sonra gelebilir. Bir link ya da geç gelen bir child span onları bağlı tutar. Bu F6 (sessiz kısmi hata) için önemlidir: cevabın hiç çıkmadığı durum, yalnızca gönderim aynı hikâyenin parçasıysa görünür.

Kontrol edilmeyen sınırlar. Bir model sağlayıcısı, üçüncü taraf bir MCP server (Bölüm 8) ya da harici bir taşıyıcı trace'e katılmayacaktır. Her biri bir yaprak olarak ele alınır: çağrının etrafındaki span ne gönderildiğini, ne geri geldiğini ve ne kadar sürdüğünü kaydeder. İçini görüyormuş gibi yapılmaz ve trace id'leri, onları almak için hiçbir nedeni olmayan taraflara giden isteklere konmaz.



İki ok türüne bakalım. Düz olanlar trace context'ini işle birlikte ileri taşır, böylece her bileşen ebeveynini bilir. Kesikli olanlar bitmiş span'leri, trace store'u dolduran trace pipeline'ına taşır. Pipeline hepsinden ayrı bir sistemdir ve bu, bir sonraki başlıkta önem kazanır.

Döngüyü enstrümante etmek

Bölüm 1'deki döngü, doğru yerlerde zaten `record(run, event, detail)` çağırıyor. Observability katmanı, `record`'un her çağrıyla ne yaptığı ve pipeline kullanılmadığında çevresindeki kodun ne yaptığıdır. Tasarım sorusu şu: run trace'i bekler mi?

Benim cevabım trace pipeline'ı için hayır, run store için evet. Orchestrator niyeti ve etki kaydını run store'a yazar, çünkü run'ın doğruluğu ve resume'u onlara bağlıdır (Bölüm 10). Span'leri trace pipeline'ına yerel bir buffer ile asenkron yayar, çünkü bir span kalıcı olarak yazılana kadar step'i bloke etmek, agent'ın erişilebilirliğini kaydın bütünlüğüyle takas etmek olurdu ve yavaş ya da erişilemeyen bir pipeline bir müşterinin iadesini durdurmamalıdır; geri alınamaz bir yazma için run store'daki niyet kaydı kalıcı kısmı zaten sağlar. Bu, bedeli olan bir seçimdir ve bedel yan kapıdan gelen F8'dir: span'ler kaybolursa run olmuştur ve kanıt olmamıştır. Bu yüzden tasarım kaybı görmenin bir yolunu ekler.

```

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

```

Üç ayrıntı yükü taşıyor. Sıra numarası orchestrator tarafından, run başına atanır; böylece span'ler sıralanabilir ve sayılan kayıplar eksik olan numaralarla karşılaştırılabilir. Buffer sınırlıdır ve önce düşük öncelikli span'leri atar. Ve `reconcileRun`, etkilerin yetkili listesi olan run store'a bakar: her niyetin anahtarıyla bir `tool.call` span'i olmalıdır ve her sonucun anahtarı ve eşleşen outcome'uyla bir tane olmalıdır; böylece kaydedilmiş outcome'u taşıyan span'in kaybı, daha önceki başarısız bir deneme tarafından gizlenmez ve bir boşluk, işaretlenmiş bir run'a ve alarm kurulabilecek bir orana dönüşür. Eksiksiz olduğuna güvenilemeyen bir trace yine de yararlıdır, ama yalnızca ne zaman eksik olduğu biliniyorsa.

Run store, trace pipeline'ı ve payments servisi, aralarında transaction olmayan ayrı sistemlerdir; bu yüzden trace, geri alınamaz bir yazmanın tek tanığı asla olmamalıdır (Bölüm 10).

Düzyazı değil, olay yayınlamak

Bölümün geri kalanını işleten bir disiplin var: cümle değil, yapılandırılmış attribute yayınlamak. `refused: "the amount was too high"` diyen bir span bir insan tarafından okunabilir ve kimse tarafından sayılamaz. `verdict: refuse, refusal.reason: precondition_failed` ve `field: amount_minor` içeren bir span sayılabilir, grafiğe dökülebilir ve alarm kurulabilir. Reason'lar, gate ile orchestrator'ın ortak kullandığı kapalı bir listeden gelmelidir; tıpkı bir sözleşmedeki hata kodları gibi. Açık bir metin alanı insan notları için uygundur; bir metric onun üzerine kurulmaz.

İçerikten neyi saklamalı

Yukarıdaki her şey metadata'dır: yapı, tanımlayıcılar, sürümler, boyutlar, zamanlamalar. Ucuzdur ve riski düşüktür. Zor soru içeriktir: render edilmiş bağlam, modelin öneri metni, tool argümanları ve tool sonuçları.

İçerik, "agent bunu neden önerdi" sorusunu cevaplamak için ihtiyaç duyulan şeydir. Bir step'in yanlış sipariş için `issue_refund` önerdiği görülebilir; nedeni ancak o step'teki bağlam, iki siparişi listeleyen tool sonucu dahil, görülebiliyorsa görülür. İçerik olmadan ne olduğu bilinir ve nedeni söylenemez. İçerikle birlikte, müşterinin verisinin bir kopyası bir yerde daha tutulur.

Bunu bir evet ya da hayır meselesi yapmazdım. Alan başına karara bağlanan ve kararı yazılı olan bir katmanlar kümesi yapardım.

Katman	Neyi tutar	Kim okuyabilir	Saklama süresi
Metadata	Span yapısı, attribute'lar, sürümler, boyutlar, zamanlamalar, kararlar, reason kodları	Mühendislik ve destek operasyonları ekiplerindeki herkes	En uzun; ucuzdur ve içerik taşımaz
Redacted içerik	PII ve secret'ların yazma anında çıkarıldığı bağlam parçaları, öneriler ve tool sonuçları (Bölüm 17)	Agent davranışı üzerinde çalışan mühendisler	Daha kısa

Katman	Neyi tutar	Kim okuyabilir	Saklama süresi
Ham içerik	İçerik olduğu gibi ya da ona giden reveal yolu	Küçük, adı konmuş bir grup; denetlenen ve süresi dolan bir reveal ile	En kısa, ya da hiç

Katmanlarla birlikte giden kurallar:

1. **Okurken değil, yazarken redact edilir.** Trace pipeline'ına ulaşan span, Bölüm 17'deki redaction fonksiyonundan zaten geçmiştir. Redaction başarısız olursa içerik alanı atlanır ve span bunu söyler; ham yazılmaz. Bir boşluk görünür; bir sızıntı görünmez.
2. **İçerik ayrı, erişimi denetlenen bir store'da tutulur.** Span içeriği değil, içeriğe bir referans tutar. Bu, metadata katmanının geniş çapta okunabilir olmasına, içerik katmanının olmamasına izin verir ve saklama ile silmenin span ağacına dokunmadan içerik store'unda çalışmasını sağlar. Bölüm 17'nin silme yolunun ona ulaşması gerekir; run id ve ticket hash'i ile bir referans bunu mümkün kılar.
3. **Secret'lar hiçbir katmana girmez.** Secret, ifşa edilirse erişim sağlayan bir değerdir. Tool gateway çağrı başına credential'lar verir (Bölüm 18) ve orchestrator onları asla açık halde görmez; trace de görmemelidir. Bir token tutan trace store'u, bütün ekip için sorgu erişimi olan bir credential store'dur.
4. **İçerik örneklenir, metadata değil.** Metadata ucuzdur; her run için saklanır. İçerik pahalı ve risklidir; bir örneklem için ve önemli olan her run için saklanır.

İhtiyaç duyulan run'ları tutan örnekleme

İçeriğin tekdüze rastgele örneklenmesi olağan varsayılandır ve önemli olan şekilde başarısız olur: araştırılması gereken run nadirdir, dolayısıyla yirmide bir örneklemin (diyelim) onu tutmama olasılığı yirmide on dokuzdur. Alternatif, run bittikten sonra, nasıl gittiği bilindiğinde karar vermektir. Buna sıklıkla tail-based sampling denir: run'ın span'leri toplanır ve run tamamlandığında neyin saklanacağına karar veren bir kural uygulanır.

Başlangıç olarak alacağım bir kural seti:

- reddedilmiş, yükseltilmiş, bir sınır tarafından durdurulmuş, bir insana devredilmiş ya da onaylanmış her run için redacted içeriğin tamamı saklanır;
- `failure.class` ayarlanmış her run için ve `trace_incomplete` işaretlenmiş her run için saklanır;
- bir müşteri şikâyetinin, bir iptalin ya da bir olayın sonradan run id'ye atıfta bulunduğu her run için saklanır (içerik store'u hâlâ tutuyorsa, bir job bir run'ın içeriğini geriye dönük terfi ettirebilir);
- olağan başarılı run'lardan küçük bir tekdüze örneklem saklanır, çünkü onlar olmadan normalin neye benzediğine dair bir baseline ve Bölüm 21 için vaka kaynağı olmaz.

Bedel bellektir: sonda karar vermek için run'ın içeriği sona kadar tutulur. 15 step'lik bir run (diyelim) için bu küçüktür; saatler boyunca resume olan ops agent'ın uzun bir araştırması için daha büyüktür ve tutma işi orchestrator'ın belleğinde değil, içerik store'unun staging alanında olur. Staging'e konan bir zaman sınırı onu sınırlı tutar.

Uyarı: Para hareket ettiren bir run'da ne olduğu söylenemiyorsa, kanıtı saklamanın maliyeti ne olursa olsun tasarım başarısız olmuştur. Geri alınamaz yazmalar ve dış yan etkiler için, örneklemmeden bağımsız olarak, çağrının ve sonucunun metadata'sı ve redacted içeriği her zaman saklanır. Kitabın "her zaman" dediği az sayıdaki yerden biri budur, çünkü alternatif, ne olduğunu söyleme yeteneğini kaybetmektir.

Metric'ler: trace'in toplamda dönüştüğü şey

Bir trace tek bir run hakkındaki soruları cevaplar. Metric'ler hepsi hakkındaki soruları cevaplar: agent iyileşiyor mu kötüleşiyor mu, bir şey kayıyor mu ve bu kötü bir run mu yoksa kötü bir gün mü? Bir agent için metric'ler, trace'in attribute'larından, metrics store'da türetilir ve türetme, attribute'ların yapılandırılmış olması gerektiğinin nedenidir.

İlk kuracaklarım:

Metric	Nasıl türetilir	Ne söyler
Run başarı oranı	Durumu done olan ve hand-off'u olmayan run'lar, görev türü başına tüm run'lara bölünür	Agent başladığı işi tamamlıyor mu. Başarı dikkatle tanımlanmalıdır: "done", "doğru" demek değildir
Ret oranı	Refuse gate kararları, tool başına ve reason başına tüm gate kontrollerine bölünür	Önerilerin gate'in görebileceği biçimlerde ne sıklıkla yanlış olduğu; artış bir F2 ya da F4 sinyalidir
Hand-off oranı	<code>escalate_to_human</code> ya da bir sınırla biten run'lar, tüm run'lara bölünür	İşin ne kadarı hâlâ insanlara düşüyor; düşüş iyi de olabilir, bir boşluk da
Onay oranı	Onaylananlar, karara bağlananlara bölünür; tool başına ve onaylayan rolü başına	%100'e yakınsa ve kararlar saniyeler sürüyorsa onay bir tiyatrodur (Bölüm 15)
Onay bekleme süresi	<code>approval.wait</code> süreleri	Kontrolün insani maliyeti; queue'nun nerede biriktiği
Run başına step	Step span'lerinin sayısı, bir dağılım olarak	Döngüler ortalamada değil kuyrukta görünür (F5)
Run başına token ve maliyet	Run başına <code>tokens.in</code> ve <code>tokens.out</code> toplamı ve harcama	Bölüm 22'nin girdisi
Hata sınıfı dağılımı	<code>failure.class</code> başına sayı	F1'den F9'a hareket var mı; kontrol sistemi neyi yakalıyor
Geçersiz öneri oranı	<code>proposal.valid</code> false olan, model çağrılarına bölünür	F1 baskısı ve bir model ya da prompt değişikliğinin onu kötüleştirip kötüleştirmedeği
Trace bütünlüğü	<code>trace_incomplete</code> işaretli run'lar, tüm run'lara bölünür	Yukarıdakilerin hepsine ne kadar güvenilebileceği

Bunları okurken birkaç uyarı.

Oranların anlamlı paydaları olmalıdır. Tüm gate kontrolleri üzerinden hesaplanan bir ret oranı, agent daha fazla başarılı step attığında düşer, daha az attığında yükselir; ona tool'a ve reason'a göre bakılır ve sayı oranın yanında tutulur, çünkü dört çağrıda %50'lik bir oran bir bulgu değildir.

Bir ret bir hata değildir. Müşteriye ait olmayan bir sipariş için iadeyi `not_permitted` ile reddeden ya da tavanın üzerindeki bir iadeyi onaya gönderen bir gate, sistemin çalışmasıdır. Ret ve hand-off oranları, modelin önerileriyle politikanın nerede anlaşılmadığının sinyali olarak ele alınır ve en aza indirilecek bir skor olarak değil, bir soru olarak okunur.

Cardinality bir maliyettir. Run id'si ya da ticket id'si ile etiketlenmiş bir metric, run başına yeni bir zaman serisidir ve metrics store'lar bundan hoşlanmaz. Etiketler sınırlı olanlar olmalıdır: agent, tool, görev türü, karar, reason kodu, hata sınıfı, sürüm. Sınırsız tanımlayıcılar trace'e aittir; bir metric'te bir şey ters görüldüğünde gidilen yer orasıdır.

Son olarak, sürüme göre dilimlenir. Yukarıdaki her metric model sürümüne, prompt sürümüne, politika sürümüne ve orchestrator sürümüne göre dilimlenebilir olmalıdır, çünkü bunlardan herhangi birindeki bir değişiklik, bir hareketin en olası açıklamasıdır. Bölüm 21 aynı dilimleri bir değişiklik yayına çıkmadan önce kullanır; burada onlar, bir eval olmadan yayına çıkmış bir değişikliği fark etme yoludur.

Alarmlar ve service level objective'ler

Bir alarm, birinin uyandırılması ya da bölünmesi gerektiğine dair bir karardır ve bunun maliyeti gerçektir. Agent alarmları alarm kurmanın olağan kuralını izler: şimdi eylem gerektirene alarm gönderilir; bekleyebilecek olan ticket'a bağlanır. Farklı olan, neyin izlendiğidir.

Geleneksel bir servis hatalara ve gecikmeye alarm kurar. Bir agent ikisine de sahip olmadan yine de yanlış davranıyor olabilir, bu yüzden kontrol sisteminin kendi ürettiği sinyalleri eklerdim.

Sinyal	Neden önemli	Olası sınıf
Tek bir tool için ret oranının kendi baseline'ına göre yükselmesi	Öneriler biçim değiştiriyor: bir model, prompt ya da bağlam değişikliği ya da çağrılarını yönlendiren içerik	F2, F4
Agent'ın ihtiyaç duymaması gereken bir tool'da <code>not_permitted</code> gate retleri	Bir yetki sorusu, muhtemelen bir injection	F7, F4
Run başına step, 99. yüzdeler, step sınırına yakın	Döngüler oluşuyor	F5

Sinyal	Neden önemli	Olası sınıf
Run maliyeti ya da token'ları, kuyruk yükseliyor; saat başına harcama hızı baseline'ın üzerinde	Retry fırtınası, bağlam büyümesi, kontrolden çıkma	F9
Bir iadeden sonra <code>unknown tool outcome</code> 'u ya da cevap gönderme hataları	Onayı olmayan kısmi etkiler	F6
Bir deploy'dan sonra geçersiz öneri oranının yükselmesi	Bir sürüm değişikliği yapıyı bozdu	F1
Hand-off oranı ya da onay bekleme süresi yükseliyor	İnsanlar darboğaz ya da agent daha çok başarısız oluyor	hepsi
<code>trace_incomplete</code> oranı küçük bir eşiğin üzerinde	Kanıt kaybediliyor	F8
Eşleşen niyet kaydı olmayan herhangi bir geri alınamaz yazma	En ciddi uyumsuzluk	F6, F8

Oran sinyalleri için bir baseline'a göre değişime, invariant'lar için sabit bir koşula alarm kurulur. "Niyet kaydı olmayan herhangi bir geri alınamaz yazma" bir invariant'tır ve tek bir oluşumda tetiklenmelidir; "`issue_refund` için ret oranı bir önceki haftanın iki katı" bir orandır ve değişim sürdüğünde tetiklenmelidir.

Son satır gerekçesini hak ediyor. Bir mutabakat job'ı gerektirir (örnek amaçlı bir job): iadenin olup olmadığı konusunda yetkili olan `payments-service` iade kayıtlarını, run store'un niyet kayıtlarıyla karşılaştırır. `payments-service`'te var olan ama eşleşen niyeti olmayan bir iade, gate'ten geçmemiş bir etkidir ve bu, bir alarmin var olma nedeni olan türden bir olgudur. Bölüm 23 buradan devam ediyor.

Bir agent için service level objective

Bir service level objective (SLO), bir süre boyunca ölçülen bir davranış için, tolere edilen bir kaçırma miktarıyla birlikte bir hedeftir. Fikir agent'lara taşınır; yalnız neyin vaat edildiğine dikkat edilmelidir.

"Cevap doğru" için bir SLO yazmazdım, çünkü bu, her run için online ölçülemez ve ölçülemeyen bir hedef bir temenniden ibarettir. Kontrol sisteminin ve pipeline'ın ölçebildiği şeyler için SLO'lar yazardım:

- bir terminal duruma (done, devredilmiş, durdurulmuş) bir süre sınırı içinde ulaşan run'ların payı; diyelim, kayan bir dönem boyunca görevin süre sınırı içinde %99;
- tam bir trace'i ve eşleşen bir niyet kaydı olan geri alınamaz yazmaların payı; hedefi hepsine yakın ve açıklanamayan tek bir tanesi için tolerans yok;
- belirtilen bir süre içinde karara bağlanan onay isteklerinin payı; bu, sistemin insan tarafı için bir SLO'dur ve yalnızca platforma değil, destek lideri ile on-call ekibine de aittir;
- tam bir trace'i olan run'ların payı, kanıtın kendisi üzerindeki SLO olarak.

Yukarıdaki yüzdeler örnektir. Doğru değerler görevlere, onaylar için kadroya ve kaçırılan bir hedefin neye mal olduğuna bağlıdır. Agent'ın cevaplarının iyi olup olmadığı bir eval sorusudur (Bölüm 21) ve örneklenmiş bir grader skoru üzerinde bir SLO var olabilir, ama onu bir tahmin olarak etiketler ve örneklem boyutunu yanına koyardım.

Her alarm kimin harekete geçtiğini, önce neyi açtığını ve neler yapabileceğini söyler; "ne yapabilir" sorusunun cevabı "hiçbir şey" ise bu bir alarm değil, bir dashboard'dur (kural Bölüm 13'ündür ve Bölüm 23'ün runbook'u onun yaşadığı yerdir).

Replay ve inceleme

Bir trace kanıttır. Onu kullanılabilir kılan araç bir inceleme görünümüdür ve bunun en yararlı biçimi bir replay'dir.

Replay ile dar bir şey kastediyorum: kaydedilmiş bir run'ı sırayla adım adım gezmek; her step'te bağlamı derlendiği haliyle (görüntüleyenin izin verildiği katmanda redacted), öneriyi, gate'in kararını politika kuralı ve sürümüyle, varsa onayı ve ardından gelen etkiyi ya da reddi görmek. Olanın salt okunur bir görünümüdür. Bölümün başındaki Sam'in sorusunun cevabıdır.

Bu anlamdaki replay modeli yeniden çalıştırmaz ve hiçbir tool'u çağırmmamalıdır. Kaydedilmiş bir run'ı canlı tool'lara karşı yeniden yürütmek, bir teşhisin ikinci bir olaya dönüşme yoludur: iade yeniden

yapılır ya da cevap iki kez gönderilir. Bir görüntüleyici kaydı gösterir; onun üzerinde eylemde bulunmaz.

İkinci bir replay türü yararlı ve farklıdır ve ikisini adlandırmada ve izinlerde ayrı tutardım: **yeniden değerlendirme**. Bir step'in kaydedilmiş bağlamı ve yeni bir model, prompt ya da politika sürümü verildiğinde, öneriyi ya da gate kontrolünü etkisiz bir sandbox'ta yeniden çalıştırıp karşılaştırmaktır. Bu bir eval tekniğidir ve Bölüm 21 onu kullanır; burada trace vakaların kaynağıdır. İki sınır geçerlidir. Modelin çıktısı genel olarak yeniden üretilebilir değildir, bu yüzden yeniden değerlendirmede farklı bir öneri kendi başına bir regresyon değildir; bir örnektir. Ve gate deterministiktir, bu yüzden kaydedilmiş önerileri yeni bir politika sürümünden geçirmek kesindir ve bir politika değişikliğinin neyi reddedeceğini görmenin ucuz bir yoludur.

```
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
```

Görüntüleyici müşteri verisine açılan bir yoldur, bu yüzden okuma denetlenir.

Ops agent'ın `get_trace` tool'u aynı store'dur, bir tool üzerinden okunur. Bu iyi bir kullanımdır ve açıkça söylemeye değer bir sınırı vardır. Tool, trace'leri id ile, ops agent'ın devredilmiş yetkisinin erişimiyle okur (Bölüm 7); araştırmayı başlatan mühendisin okuyabileceği gibi metadata'yı ve redacted katmanı okumalı, fazlasını okumamalıdır. Trace içeriği, ticket'lardan ve tool sonuçlarından gelen metin içerir, dolayısıyla Bölüm 16'nın kuralları geçerlidir: bu, kökeni olan veridir ve bağlama girerken güvenilir olarak işaretlenir.

Parcelport üzerinden bir trace

Açılış senaryosundaki ticket'ı, enstrümantasyon yerindeyken ele alalım. tkt-5521 ticket'ı hasarlı bir koliyi soruyor; sipariş ord-7f3k2m91 ve tutar refund_ceiling'in üzerinde varsayımsal bir değer. Aşağıdaki ağaç run'ı gösteriyor.

```
run run-3b9d agent: support-agent ticket: tkt-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
```

Bütün sayılar örnek için uydurulmuştur. gate.check satırları, Bölüm 5'teki gate'in kısmi bir görünümüdür: rule tetiklenen politika kuralını adlandırır ve bir ret aynı sözlükten refusal.reason ekler; step 1'deki okuma, her çağrı gibi gate'ten geçer. Ağaç, Alex'in okuyacağı gibi okunur. İade onaydan geçti ve bekleme dokuz dakikaydı; onay tek bir çağrı digest'ine bağlıydı ve iade, tekrarı yakalayacak idempotency key'i taşıyor. Cevap, mesaj kabul edilmeden önce açık bir hatayla bir kez başarısız oldu; Bölüm 14'ün sınıflandırması bunu yeniden denenebilir sayar ve retry, step 4'ün içinde ikinci bir deneme olarak kaldı: gate'in kararını ve aynı anahtarı yeniden kullandı ve bir retry gate'i yeniden açmadığı için run'ın bütçesine ilk deneme gibi yazıldı (Bölüm 14). Burada hiçbir şey teslimat tarihi cümlesini göstermiyor, çünkü tarih yapıda değil, içerikte. Katmanların

karşılığını verdiği yer burası. Alex, step 4 için redacted içeriği açıyor ve bağlam parçalarını id ve köken ile görüyor: sipariş sorgusu sonucu bir durum listeliyor ve tarih içermiyor; cevaptaki tarihin kaynağı yok. Bu F3 (dayanaksız iddia), trace'te görünür ve Bölüm 21'deki bir grader'ın, örneklenmiş bir run üzerinde sonradan ayarlayabileceği bir `failure.class` ile.

Bir varyasyon Kayıt'ı iş başında gösteriyor. Step 3'teki `issue_refund` için `tool.call` span'inin dolu bir buffer yüzünden kaybolduğunu varsayalım. Her step span'i mevcut, bu yüzden bir step sayımı yanlış bir şey görmez. Ama run store `key-0007` için niyet ve sonuç kayıtlarını tutuyor, `reconcileRun` o anahtar için bir `tool.call` span'i bulamıyor ve `trace_incomplete` işaretliyor. İade, yani geri alınamaz bir yazma, bu kayıtlar sayesinde hâlâ görünür. Boşluk, üzerinde sayı olan bir olgudur, bir gizem değil.

Ops agent'in run'ları aynı ağaca sahiptir; bunun yerine `query_logs`, `get_metrics`, `get_trace` ve `run_diagnostic` span'leri vardır. Bir `run_diagnostic` span'i sandbox'ın outcome'unu, süresini ve bir sınıra çarpıp çarpmadığını kaydeder; script'in yazdırdığı şey içeriktir ve katman kurallarını izler, çünkü diagnostic çıktısı, script'in sandbox'ta okuyabildiği veriyi içerebilir. Bir `request_rollback` span'i Robin'in rolü ve kararıyla onayı ve `deploy-service`'in döndürdüğü deployment tanımlayıcısını taşır; böylece "agent production'da ne değiştirdi" bir arkeoloji çalışması değil, `effect.class` ve `tool` üzerinde bir sorgu olur.

Trade-off'lar ve maliyetler

Hacim ve para. Trace pipeline'ı ve içerik store'u, agent'ın bütçelendiği gibi bütçelenir ve Bölüm 22'nin onları ticket başına maliyette saymasına izin verilir.

Gizlilik ve hata ayıklanabilirlik. Redaction, mühendise bir run'ı açıklamak için gereken bilginin bir kısmına mal olur ve reveal yolları bir onaya ve bir denetime mal olur. Bu, ham değere zaman zaman uygunsuz bir saatte ihtiyaç duyacak olan on-call'a bir maliyettir. Bir gün süren bir reveal kimsenin kullanmadığı bir kontroldür ve herkesin tetikleyebildiği bir reveal kontrol değildir. Nereye ayarlanacağı veriye ve rejime bağlıdır;

bu türden rejimler kişisel verinin nerede saklandığını, kimin okuyabildiğini ve ne kadar süreyle okunabildiğini sorma eğilimindedir ve bu yorum hukuk ve uyum ekiplerine aittir.

Enstrümantasyon bakımı. Her yeni tool, span türü ya da hata sınıfı attribute'lar ister ve bir sözleşme testi ya da schema kontrolü onu tutmadıkça attribute listesi koddan kayar. Kimsenin doğrulamadığı bir trace şeması bir çeyrek içinde serbest metne dönüşür.

Hepsini ne zaman kullanmamalı. Bir ekip için günde birkaç run işleyen bir prototipin tail-based sampling'e, katmanlı bir içerik store'una ya da bir SLO'ya ihtiyacı yoktur. İlk günden üç şeye ihtiyacı vardır: her şeyin üzerinde bir run id, gate kararı ve sonucuyla birlikte tool çağrısının yapılandırılmış olaylar olarak kaydı ve yazma anında redaction. Gerisi hacim, risk ya da kaydı okuması gereken kişi sayısı büyüdüğünde eklenir. Hiçbir ölçekte yapılmaması gereken, para hareket ettirebilen ya da müşterilerle iletişime geçebilen bir agent'ı, ne yaptığına dair hiçbir kayıt olmadan çalıştırmaktır.

Observability'nin yapmadıkları. Bir trace ne olduğunu söyler. Onu durdurmaz.

Sık yapılan hatalar

Modelden kendini açıklamasını istemek ve bunu trace olarak saklamak. Cazip, çünkü açıklama bir kayıt gibi okunur. Bir açıklama string'i öneri tarafındaki bir başka çıktıdır; yanlış olabilir ve eksik olabilir. Bir insan için, içerik olarak tutulan yararlı bir bağlam olabilir. Kayıt değildir. Çözüm: orchestrator kaydı gözlemlediği olaylardan yazar; modelin metni kaydın içindeki içeriktir.

Ham prompt'lar ve tool sonuçları genel log store'unda. Cazip, çünkü hata ayıklamanın en hızlı yolu bu. Saklama ve silmenin bilmediği bir kopya yaratır (Bölüm 17). Çözüm: yazma anında redact edilir, içerik kendi store'unda tutulur, reveal'a bir denetim izi ve bir son kullanma süresi verilir.

İçeriğin tekdüze rastgele örneklenmesi. Maliyeti düşük tutar ve olayı atar. Cazip, çünkü basittir ve hacim temsili görünür. Çözüm: run bittikten sonra karar verilir ve reddedilmiş, yükseltilmiş, onaylanmış, durdurulmuş

ya da başarısız olmuş her run, baseline için küçük bir tekdüze örneklemele birlikte saklanır.

Saklanmış trace'lerin güvenilir metin olarak bağlama geri girmesine izin vermek. Cazip, çünkü trace bizim kendi verimiz. Bir trace, ticket'lardan ve tool sonuçlarından gelen metin tutar. Çözüm: bir trace bir agent'ın bağlamına, örneğin `get_trace` ile girdiğinde, kökeni olan veri olarak girer ve güvenilmez olarak işaretlenir (Bölüm 16).

Temel çıkarımlar

- Bir run'ın kaydı, orchestrator tarafından deterministik olaylardan yazılır ve modelin ne yaptığına dair kendi anlatımı o kaydın içindeki içeriktir, asla yerine geçen bir şey değil.
- Run bir trace olarak; her step, model çağrısı, gate kontrolü, tool çağrısı ve onay beklemesi ise sürümler, token'lar, gecikme, etki sınıfı, politika kararı ve hata sınıfı için attribute'ları olan birer span olarak ele alınır.
- Trace pipeline'ı kritik yolun dışında tutulur, her span'e bir sıra numarası verilir ve run store'daki her etki kaydı bir `tool.call` span'iyle mutabık kılınır; böylece kaybolan kanıt sessiz bir F8 değil, ölçülmüş bir boşluk olur.
- Metadata ucuz ve geniş çapta okunabilir; içerik risklidir ve katmanlıdır, yazma anında redact edilir, ayrı, erişimi denetlenen bir store'da tutulur ve şansa göre değil sonuca göre saklanır; böylece reddedilmiş, yükseltilmiş, onaylanmış, durdurulmuş ya da başarısız her run incelemeye hazır olur.
- Metric'ler yapılandırılmış attribute'lardan türetilir, kuyrukları ve paydaları okunur ve sürüme göre dilimlenir, çünkü davranıştaki bir kaymanın olağan açıklaması, model, prompt, politika ya da tool'daki ve kimsenin bir eval'e bağlamadığı bir değişikliktir.
- Ret oranı, kuyruktaki step'ler, maliyet hızı, bilinmeyen outcome'lar ve niyet kaydı olmayan geri alınamaz yazmalar gibi agent'a özgü sinyallere alarm kurulur ve her alarma bir sahip ve bir ilk eylem verilir, yoksa o bir dashboard'a çevrilir.
- Replay, olanın salt okunur bir görünümüdür, yeniden değerlendirme sandbox'ta bir karşılaştırmadır ve ikisinin de bir tool çağırmasına izin

verilmez.

Kayıt, agent'ın ne yaptığını ve bunu yapmanın neye mal olduğunu söyler. Bölüm 21, bir değişiklik yayına çıkmadan önce agent'ın bunu yapmaya devam etmesine izin verilip verilmeyeceğine karar vermek için o kaydı kullanır.

Bölüm 21 — Değerlendirme

Parcelport'ta platform ve AI enablement ekibinde çalışan Alex'in, destek agent'ının system prompt'unun politika metnindeki tek bir cümleyi değiştirdiğini düşünelim. Cümle beceriksizdi ve yeni ifade bir insan okuyucuya daha net geliyor. Orchestrator'ın unit test'leri geçiyor. Gate test'leri geçiyor. `issue_refund` için sözleşme test'leri geçiyor. Pipeline'da hiçbir şey kırmızı değil, dolayısıyla değişiklik o öğleden sonra yayına çıkıyor.

Perşembeye gelindiğinde destek lideri Sam, yükseltme queue'sunun büyüdüğünü fark ediyor. Destek agent'ı, eskiden kendi çözdüğü hasarlı koli ticket'larını devretmeye başlamış ve ayrıca müşterinin istemediği birkaç vakada jest olarak iade teklif etmeye de başlamış. Hiçbir şey tavanı aşmadı ve hiçbir kural çiğnenmedi, bu yüzden gate sessiz kaldı. Davranış yine de değişti ve pipeline'daki hiçbir test bunu fark etmek için kurulmamıştı. Alex'in elinde beceriksiz bir cümle, daha net bir cümle ve ikisinden hangisinin daha iyi bir agent ürettiğini söyleyebilecek hiçbir yol yok.

Bu bölüm kontrol zarfının Kayıt parçasına ait. Bölüm 20 "bu run'da ne oldu" sorusunu cevaplıyor; bu bölüm aynı parçanın farklı bir sorusunu cevaplıyor: olasılıksal bir bileşenin davranışını, bir değişiklik yayına çıkmadan önce ve çalışırken nasıl ölçülür ki bir prompt'ta, bir modelde, bir tool'da ya da bir politikadaki değişiklik bir umut değil, ölçülmüş bir karar olsun?

Sorun ve neden zor olduğu

Bu kitaptaki kontrol sisteminin çoğu deterministiktir ve deterministik kodun test edildiği gibi test edilir. Gate aynı öneri için aynı kararı döndürür. Sözleşme doğrulayıcı aynı argümanları her seferinde kabul eder ya da reddeder. İkisi için de bir unit test ucuz, hızlı ve kesindir ve yazılmalıdır. Bu bölümdeki hiçbir şey onun yerini almaz.

Bu şekilde davranmayan parça modelidir. Aynı bağlam iki kez verildiğinde iki farklı öneri döndürebilir. Biraz farklı bir bağlam verildiğinde çok farklı bir öneri döndürebilir. "Bu ticket için öneri tam olarak şu tool çağrısına eşittir" diye iddia eden bir test, iyi bir günde zararsız nedenlerle başarısız olur ve kötü bir günde şans eseri geçer. Modelin neden böyle davrandığını Bölüm 2 açıklıyor; bu bölüm için sonucu bilmek yeter. Tek bir run bir oran hakkında neredeyse hiçbir şey söylemez ve bilinmesi gereken şey bir orandır.

Bu üç sorun doğurur. Birincisi, davranışın bir dağılım olarak ölçülmesi gerektiğidir: birçok vakada birçok run içinden, hangi payı doğru olanı yaptı? İkincisi, "doğru olan"ın çoğu zaman karşılaştırılabilecek bir string olmamasıdır. Bir cevap taslağı yüz farklı ifadeyle doğru olabilir ve tek bir ince biçimde yanlış olabilir. Üçüncüsü, ölçümün kendisinin yanlış olabilmesidir, çünkü notlandırmayı yapan şey bir model, yorgun bir insan ya da fazla katı bir kural olabilir.

Taksonomideki her hata sınıfı burada ortaya çıkar; eval'lerin bir Öneri değil, bir Kayıt meselesi olmasının nedeni budur; bölümün ilerisindeki bir tablo her sınıfı bir vakaya ve bir grader'a eşliyor. F8 (gözlenmeyen davranış) bir eval'i imkânsız kılan sınıftır, çünkü kaydı olmayan bir run notlandırılamaz.

Bu bir prompt sorusu değil, bir mühendislik sorusudur, çünkü alternatif bir avuç çıktıyı okumak, iyi göründüklerine karar vermek ve yayına almaktır. Bu bir review'dur ve bir review'un değeri vardır, ama bir ekibin yaptığı değişiklik sayısına ölçeklenmez, geçen ayın hatalarını hatırlamaz ve karşılaştırılabilecek bir sayı veremez. Bir eval verebilir.

Eval, test'lerin yerini almaz

İkisini baştan ayrı tutardım, çünkü karıştırmak hem yanlış güven hem de boşa çaba üretir.

Bir **test**, deterministik kodun spesifikasyonunun söylediğini yaptığını iddia eder. Girdi sabittir, çıktı sabittir ve bir başarısızlık bir kusur demektir. Test'ler bir öneriyi tipli bir çağrıya çeviren parser'ı, gate'in tavanın üzerindeki bir iadeyi reddetmesini, bir idempotency key türeten

fonksiyonu, redaction filtresini, bir onayı pending'den decided'a taşıyan state machine'i kapsar. Bunlar her commit'te çalışır ve kesin olmaları gerekir. Bir test flaky ise düzeltme testte ya da kodda yapılır.

Bir **eval**, davranışın beklenen sonuçlara karşı tekrarlanabilir bir ölçümüdür. Girdi bir vakadır, ölçülen şey olasılıksal bir öneri ya da birkaçından kurulu bir run'dır ve sonuç bir skor ya da orandır. Bir eval'de tek bir vakanın başarısız olması mutlaka bir kusur değildir; bir dağılımdaki bir veri noktasıdır ve önemli olan dağılımın kayıp kaymadığıdır.

İkisi arasındaki sınır, Bölüm 4'teki determinizm sınırıdır. Onun deterministik tarafındaki her şey test alır. Olasılıksal tarafındaki her şey eval alır. Bir ekip bir eval'in "iade tutarı hiçbir zaman tavanı aşmaz" gibi deterministik bir şeyi kontrol ettiğini fark ettiğinde, bu kontrolün her run'da geçerli olduğu gate'e ait olduğunun ve eval'in yalnızca gate'in devreye bağlı olduğunu doğrulaması gerektiğinin işaretidir. Bir eval, bir sınırı uygulayan şey olmamalıdır.

İkisi birbirini de tamamlar. Gate'in bir test'i gate'in kötü bir öneriyi reddettiğini söyler. Bir eval modelin gate'in reddedeceği kötü önerileri ne sıklıkla ürettiğini söyler ve yüksek bir ret oranı prompt'a, tool açıklamalarına ya da retrieval'a işaret eder. Gate kontroldür; eval, kontrolün ne kadar iş yaptığını görme yoludur.

Eval seviyeleri

Bir eval ancak neyi ölçtüğü açık olduğunda yararlıdır. Dört seviyeyi ayırmaya değer buluyorum, çünkü farklı maliyetleri, farklı grader'ları ve farklı sahipleri var.

Tek step

Tek step'lik bir eval bir bağlam alır ve tek bir öneriyi kontrol eder. Bu ticket ve bu tool sonuçları verildiğinde, model doğru sipariş id'siyle `lookup_order` öneriyor mu? Bu sipariş ve bu müşteri mesajı verildiğinde, duruma uyan bir tutar ve para birimiyle `issue_refund` mı öneriyor, yoksa `escalate_to_human` mı?

Bu eval'ler ucuz ve keskindir. Bağlam sabittir, dolayısıyla elle ya da run store'dan saklanmış bir step replay edilerek kurulabilir. Beklenen sonuç çoğu zaman bir kontrol olarak ifade edilebilir: tool izin verilen bir kümededir, argümanlar sözleşmeye göre doğrulanır, sipariş id'si ticket'taki ile aynıdır. F1 ve F2'yi yakalamak ve bir tool açıklamasındaki değişikliğin argüman kalitesini nasıl hareket ettirdiğini ölçmek için doğru seviyedir. Zayıf yanı, tek bir step'in hataların bir run boyunca nasıl birikeceğini göstermemesidir.

Uçtan uca

Uçtan uca bir eval, tüm döngüyü bir vaka üzerinde stub'lanmış ya da sandbox'lanmış tool'lara karşı çalıştırır ve sonucu notlandırır. Run doğru state'te mi bitti? İade bir kez, doğru tutarda yapıldı ve cevap gönderildi mi? Gerekliğinde hand-off'a geçti mi? Tool'lar, kaydedilmiş sonuçları döndüren deterministik fake'lerle değiştirilir; böylece tekrarlar arasında değişen tek şey model olur.

Bu seviye F5 ve F6'yı yakalar: yakınsamayan döngüler, kaydedilmiş bir iade ve hiç gönderilmemiş bir cevap. Daha yavaş ve daha pahalıdır, çünkü her vaka tam bir run'a mal olur ve hata ayıklaması daha zordur: başarısız bir vakanın birçok step'i vardır. Tam çağrı sırasını eşleştirmeye çalışmak yerine son state'i ve kısa bir invariant listesini (niyet başına birden fazla iade yok, ret sonrasında etki yok) notlandırırdım. Müşterinin umursadığı şey sıra değildir.

Güvenlik ve sınır

Bir güvenlik eval'i, girdi düşmanca olduğunda ya da durum bir uça olduğunda kontrollerin tutup tutmadığını sorar. Gövdesi agent'a yönelik talimatlar içeren bir ticket bir sonraki tool çağrısını değiştiriyor mu? Devredilenden daha fazla yetki gerektiren bir istek, reddedilmiş bir öneri mi yoksa onaylanmış bir etki mi üretiyor? Nihai cevap, içermemesi gereken PII içeriyor mu?

Bu eval'ler önemlidir, çünkü gate'in yolda olup olmadığını doğrularlar. Modelin tavan dışı bir iade önermeye zorlandığı ve beklenen sonucun `needs_approval` olduğu bir vaka, modelden çok devre bağlantısını test eder.

Kitabın savunan tarafını izleyerek, buradaki vakalar durumu ve beklenen kontrol davranışını anlatır; çalışan saldırı metni taşımaları gerekmez. Bir vaka "ticket gövdesi agent'a yönelik bir talimat içeriyor, güvenilir olarak işaretli" diyebilir ve fixture zararsız bir yer tutucu kullanabilir. Injection kontrolleri Bölüm 16'ya aittir; bu seviye, bir değişiklikten sonra hâlâ tutup tutmadıklarını kontrol etme yoludur.

Maliyet ve gecikme

Son seviye, bir run'ın neye mal olduğunu ve ne kadar sürdüğünü ölçer: step'ler, token'lar, model çağrıları, tool çağrıları, duvar saati süresi. Bunlar bir run'ın özellikleridir ve Bölüm 13'teki bir bütçeye ve Bölüm 22'deki maliyet hedeflerine karşı notlandırılır. Cevap kalitesini koruyup step sayısını ikiye katlayan bir değişiklik, F9 (maliyet ya da gecikme patlaması) için bir regresyondur ve hiçbir doğruluk eval'inde görünmez.

Bunları, seviye ne olursa olsun, her eval run'ında kaydederdim ve ayrı bir proje olarak ele almazdım. Bir vakanın maliyeti onu çalıştırmanın yan ürünüdür ve saklaması neredeyse bedavadır.

Seviye	Neyi kontrol eder	Tipik grader	Ana hata sınıfları	Çalıştırma maliyeti
Tek step	Sabit bir bağlam için tek öneri	Deterministik kontrol	F1, F2, F3	Düşük
Uçtan uca	Bir run'ın son state'i ve invariant'ları	Deterministik artı model grader	F5, F6, F2	Orta ila yüksek
Güvenlik ve sınır	Düşmanca ya da uç girdide kontroller tutuyor	Deterministik kontrol	F4, F7	Orta
Maliyet ve gecikme	Sınırlara karşı step'ler, token'lar, süre	Deterministik kontrol	F9, F5	Diğerleriyle bedava

Golden set'i kurmak

Golden set, bir eval'in karşısında ölçüldüğü sabit vaka koleksiyonudur. Kalitesi aşağı akıştaki her şeyi sınırlar ve herhangi bir eval programının ilk çabasını harcayacağım yer orasıdır.

Vakalar nereden gelir

Üç kaynak var ve sağlıklı bir sette hepsi bulunur.

Örneklenmiş gerçek trafik. En temsili vakalar gerçek ticket'lardır. Onları ticket sisteminden tekdüze değil, kategoriye ve zorluğa göre örneklemek gerekir, çünkü tekdüze bir örnekleme kolay çoğunluk baskındır ve önemli vakalar hakkında az şey söyler. Gerçek ticket'lar PII içerir; bu yüzden sete girmeden önce Bölüm 17'deki redaction yolundan geçerler ve set, bir production veri store'unun erişim kontrolleriyle bir store'da yaşar. İçinde gerçek bir isim bulunan bir fixture, gecikmeli bir sızıntıdır. Redaction'ın belirtmeye değer bir yan etkisi vardır: vakayı değiştirebilir. Özgün ticket bir ismi önemli olacak şekilde anmışsa, redact edilmiş sürüm rolü korumalı ve değeri düşürmelidir.

Zor vakalar. Bazı durumlar trafikte nadirdir ve ters gittiğinde pahalıdır: iki kısmi iadesi olan bir sipariş için iade talebi, taşıyıcıya hand-off'tan bir dakika sonra adres değişikliği, destek ekibinin başka bir kanaldan ele aldığı bir dilde yazan müşteri, aynı anda iki şey isteyen bir ticket. Bunlar, zor ticket'ların neye benzediğini bilen Sam ya da bir destek lideriyle elle yazılır. Sayıca azdırlar ve çok ağırlık taşırlar.

Olaylardan gelen vakalar. Bir agent'ın dahil olduğu her olay geride en az bir vaka bırakmalıdır. Bir olayı vakaya çeviren prosedür Bölüm 23'e aittir. Zamanın geçmesiyle iyileşen tek kaynak budur.

Bir vaka neyi içerir

Bir vakanın, bir grader'ın kullanabileceği ve bir insanın bir yıl sonra okuyabileceği kadar yapıya ihtiyacı vardır.

```
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"
```

Buradaki iki alanı atlamak kolaydır ve onlarsız kalmak pahalıdır. Hedeflenen hata sınıfı, sonuçları taksonomiye göre dilimlemeye izin verir (ilerideki bir başlık). Kaynak ve tarihler, artık Parcelport'un çalışma biçimini yansıtmayan vakaları emekliye ayırmaya izin verir.

Boyut ve denge

Golden set için doğru boyutu bilmiyorum ve trafik bilinmeden kimse söyleyemez. Agent'ın kaç farklı durumla karşılaştığına, her birinde yanlış bir cevabın neye mal olduğuna ve bir run'ı çalıştırmanın maliyetine bağlıdır. Durumları iyi kapsayan, diyelim 150 vakalık bir set, hepsi "kolim nerede"nin varyasyonları olan 2.000 vakalık bir setten daha yararlıdır. Elle review edilebilecek kadarıyla başlanır, olaylardan büyütülür ve denge seviyeye ve hata sınıfına göre izlenir.

Denge hakkında bir uyarı daha. Çoğunlukla kolay vakalardan oluşan bir set yüksek skor alır ve hiçbir şey söylemez. Geçme oranı ilk günde yüzde 98 ise, set muhtemelen bir regresyonu görecektir kadar zor değildir ve regresyon o yüzde ikinin içinde saklanır.

Grader'lar

Bir grader, bir çıktının beklentileri karşılayıp karşılamadığına karar verir. Dört tür var ve onlara bu sırayla başvururdum.

Deterministik kontroller

Bir özellik kodla kontrol edilebiliyorsa, kodla kontrol edilir. Tool adı izin verilen kümededir. Argümanlar sözleşmeye göre doğrulanır. İade tutarı iade edilebilir bakiyeyi aşmaz. Cevap redaction listesinden hiçbir değer içermez. Run izin verilen kümeden bir state'te bitti. Step sayısı sınırın altındadır. Deterministik grader'lar ucuz, kesin, tekrarlanabilir ve bir insanla uyuşmadıklarında açıklaması kolaydır. Kalibrasyon olmadan güvenilebilecek tek grader'lar da bunlardır.

Sınırları ifade gücüdür. Bir cevabın kibar olup olmadığını ya da müşterinin sorduğu soruyu cevaplayıp cevaplamadığını söyleyemezler.

Referans karşılaştırması

Bilinen iyi bir cevap olduğunda, onunla karşılaştırılır: beklenen tool çağrısı, beklenen son state, beklenen yükseltme. Yapılandırılmış çıktılar için bu iyi işler; yalnızca daha önceki uyarıyla: önemli olan (sipariş id'si, tutar, para birimi) karşılaştırılır, tesadüfi kısımlar (serbest metin alanının ifadesi) değil. Bir cevap taslağında tam string karşılaştırması, her zararsız yeniden ifadeyi cezalandıracak ve ekibe başarısızlıkları yok saymayı öğretecek bir grader'dır.

Model grader'lar

Kodun kontrol edemediği özellikler için bir **model grader** çıktıyı ve bir rubric'i okur ve bir yargı döndürür. Cevap taslağı, tool sonuçlarının desteklemediği bir iddiada bulunuyor mu? Müşterinin sorusuna değiniyor mu? Ton, destek yönergeleri altında kabul edilebilir mi? Bu yararlıdır ve aynı zamanda bir modeldir, Bölüm 2'nin anlattığı belirsizlikle birlikte. Bir model grader, ölçüm sisteminin içinde olasılıksal bir bileşendir ve onun da bir bileşen gibi değerlendirilmesi gerekir.

Üç alışkanlık bir model grader'ı dürüst tutar. Ona genel bir kalite puanlama isteği değil, az sayıda açık sorudan oluşan dar bir rubric verilir. Çıktıdaki kanıta bağlı bir yargı istenir; böylece sonucu okuyan bir kişi nedenini görebilsin. Ve çıktıyı üreten aynı model ve yapılandırma onun tek grader'ı olarak kullanılmaz, çünkü ikisi kör noktaları paylaşır. Hangi modelin kullanılacağını söylemeyeceğim; tasarım model değiştirildiğinde de tutmak zorunda ve grader'daki bir değişiklik kendisi aşağıdaki kalibrasyondan geçmelidir.

Kalibrasyon. Bir model grader'ın skoru bir anlam taşımadan önce, insanlarla ne kadar uyduğu ölçülür. Bir çıktı örnekleme alınır, diyelim 100, ve iki ya da daha fazla insana aynı rubric'e göre notlandırılır. Grader insanlarla karşılaştırılır ve insanlar birbirleriyle karşılaştırılır. Çoğu çıktı geçtiğinde ham uyum bir grader'ı pohpohlar, çünkü iki grader yaygın etikette rastlantıyla uyuyor; Cohen'in kappa'sı gibi şansa göre düzeltilmiş bir ölçü kullanılır ya da en azından fail sınıfındaki uyum ayrıca raporlanır. İnsanlar arasındaki uyum tavadır: bir insanla, insanların birbiriyle uyduğu sıklıkta uyuyan bir grader, rubric'in izin verdiği kadar iyidir ve düşük bir insan uyumu rubric'in belirsiz olduğunu söyler. Grader'ın nerede uyumadığına bakılır. Cevap taslaklarında en çok önem taşıyan hata olan dayanaksız iddialara (F3) karşı müsamahakârsa, geçme oranı tam olarak doğru olmasına ihtiyaç duyulan yerde kaliteyi olduğundan yüksek gösterir.

Grader'da herhangi bir şey değiştiğinde yeniden kalibre edilir: model, rubric, talimatlar. İnsan etiketli seti kendi başına küçük bir golden set olarak tutulur. Değerlendiricinin değerlendirmesidir.

İnsan değerlendirme

İnsanlar referans olmaya devam eder. Kalibrasyon setini notlandırırlar, production run'larının örneklerini review ederler ve hiçbir grader'ın ele almadığı vakalar hakkında, örneğin üzgün bir müşteriye verilen cevabın iyi ele alınıp alınmadığına, hüküm verirler. İnsan değerlendirme yavaş ve pahalıdır ve yorgunluğa ve review edenler arasındaki kaymaya tabidir. Onu idareli ve bilinçli kullanırdım: kalibrasyon için, hiçbir grader'ın henüz kapsamadığı yeni hata modları için ve otomatik grader'ları dürüst tutan periyodik spot kontroller için. Bölüm 15'teki onaylarda olduğu gibi, kimin yaptığı ve ne kadar zaman aldığı adlandırılır. Planlanmış ama kadrolanmamış bir insan review'u bir tiyatrodur.

Olasılıksal sonuçlar: tekrarlar, oranlar ve aralıklar

Model deterministik değildir, dolayısıyla bir vaka pass ya da fail değildir; tekrarlar üzerinde bir geçme oranı vardır. Bu, bir eval'in nasıl çalıştırıldığını ve okunduğunu değiştirir.

Tekrarlar

Her vaka birkaç kez, diyelim beş, çalıştırılır ve sonuçlar kaydedilir. Deterministik bir grader için maliyet, run'ların maliyetidir. Beşte beş geçen bir vaka ile beşte iki geçen bir vaka farklıdır, ikisinden birinin tek bir run'ı iki yöne de gidebilecek olsa bile. İkinci vaka agent'ın o durumda güvenilmez olduğunu söylüyor; tam olarak görülmesi gereken şey bu ve tek atımlık bir eval onu yarı yarıya gösterirdi.

Doğru tekrar sayısı agent'ın varyansına, bir run'ın maliyetine ve ne kadar ince bir değişikliğin saptanması gerektiğine bağlıdır. Düşükten başladım, hangi vakaların tekrarlar arasında kendileriyle çeliştiğine bakardım ve tekrarları varyansın olduğu yere harcardım.

Oranlar ve aralık fikri

Toplam sonuç bir orandır: geçen vaka-run'ların payı. Bir oran sonlu bir örneklemeden gelir, dolayısıyla belirsizlik taşır. Bir sette 150 vaka ve her birinde beş tekrar varsa, geçme oranı agent'ta hiçbir değişiklik olmadan bir run'da yüzde 91, bir diğerinde yüzde 89 okunabilir. Sayıyı 91'den 89'a hareket ettiren bir değişiklik hiçbir şey göstermemiştir.

Gereken fikir **güven aralığı**dır (confidence interval): ölçülen oranın etrafında, gerçek oranın makul biçimde içinde olduğu bir aralık; daha çok vakayla daralır, daha azıyla genişler. Onu kullanmak için bir istatistik dersine ihtiyaç yok. Aday ile baseline arasındaki fark için bir aralık hesaplanır: sıfırı dışarıda bırakıyorsa kanıt budur; iki ayrı aralığı gözle karşılaştırmak ise gerçek bir farkı gizleyebilecek, muhafazakâr bir kestirmedir. Set için doğru yöntem veri ya da platform meslektaşlarına sorulur; ben prensibi anlatıyorum, bir formül dayatmıyorum.

Vakalar bağımsız örnekler değildir, çünkü bir vakanın tekrarları ilişkilidir ve benzer vakalar kümelenir. Bu, saf aralıkları fazla dar yapar. Pratik bir önlem, karşılaştırırken birim olarak tekrarı değil vakayı saymak ve yön değiştiren vakaların listesine bakıp onları okumaktır.

Flaky eval'ler

Aynı agent üzerinde farklı sonuçlar veren bir eval flaky'dir. Bunun bir kısmı modelin doğasıdır ve belirli vakalarda yüksek varyans olarak görünür; bu bir bulgudur, bir rahatsızlık değil. Diğer kaynaklar

harness'tadır ve düzeltilmesi gerekir: zamana bağlı tool fake'leri, kendi rastgeleliği olan grader'lar, vakalar arasında state sızdıran fixture'lar, yük altında değişen bir gateway.

Flakiness, flaky bir test'in yönetildiği gibi, bir ek adımla yönetilir. Varyansı agent'tan gelen vakalar (onlar tutulur ve geçme oranları raporlanır), varyansı harness'tan gelen vakalardan (onlar düzeltilir) ayrılır. Flaky bir vaka sessiz bir atlamayla değil, bir sahip ve bir son kullanma tarihiyle karantinaya alınır. Son kullanma tarihi olmayan bir karantina, bir setin, kurulduğu şeyi ölçmeyi sessizce bırakma yoludur.

Deploy gate olarak eval

Yayına çıkmadan önce kimsenin bakmak zorunda olmadığı bir eval bir rapordur. Bir değişiklik ile production arasında duran bir eval bir kontroldür.

Neyin değişiklik sayıldığı

Bir agent'ta davranışı değiştiren yalnızca kod değildir. Aşağıdakilerin hepsi agent'ın ne yaptığını değiştirir ve her biri bir eval run'ını tetiklemelidir:

- System prompt'un politika metninde ya da başka herhangi bir prompt metninde bir değişiklik.
- Modelin ya da proje için model gateway'in yapılandırmasının değişmesi.
- Bir tool açıklamasında, bir tool sözleşmesinde ya da agent'ın gördüğü tool kümesinde bir değişiklik.
- Hangi önerilerin geçtiğini değiştiren, gate'teki bir politikada değişiklik.
- Retrieval'da, bağlam derlemede ya da bellek davranışında bir değişiklik.
- Sınırlarda bir değişiklik: step limitleri, bütçeler, retry ve fallback kuralları.

Bu bölümün açılışındaki olay ilk maddeye aittir. Değişiklik bir yeniden ifadeydi ve review süreci onu dokümantasyon olarak ele aldı. Pipeline'daki hiçbir şey bir prompt düzenlemesini bir yorum düzenlemesinden ayırt etmedi. Prompt ve politika metnini, aynı pipeline'dan aynı gate ile yayına çıkan kod olarak ele alırdım.

Eşikler

Bir deploy gate'in bir kurala ihtiyacı vardır. En basit kural, baseline'a karşı bir regresyon eşigidir: aday, gate'lenen herhangi bir metric'te mevcut production yapılandırmasından belirtilmiş bir marjdan fazla kötü olamaz. Marj, ölçümdeki gürültüyü yansıtmalıdır; yukarıdaki aralıkların işe yaradığı yer burasıdır.

```
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" }
```

Buradaki **inconclusive**, gate'in tek başına karar veremeyeceği anlamına gelir. Bir maliyet artışı otomatik bir bloğa değil, bir insana gider, çünkü daha pahalı bir agent daha iyi kalite için doğru bir trade-off olabilir ve bu, bütçenin sahibi için bir ürün karardır.

Eşikleri bir şablondan belirlemezdim. Gevşek bir marjla başlanır, birkaç hafta yanlış bloklar ve kaçırılan regresyonlar izlenir ve sıkılaştırılır. İyi bir değişikliği haftada iki kez bloklayan bir gate, üçüncü haftaya kadar bypass edilir.

Gate'in sahibi kim

Eval suite'inin sahibi Alex'in ekibidir, ama vakalar durumları bilen insanlara aittir. Sam'in ekibi, kod değişikliği olmadan bir vaka ekleyebilmelidir. Override yolu, yani bir kişinin başarısız bir gate'e rağmen yayına alması, var olmalıdır, çünkü gerekli olacağı bir gün olacak ve bunu kimin ve neden yaptığına dair bir kayıt bırakmalıdır. Kayıt bırakmayan bir override, sürecin içindeki F8'dir.

Online değerlendirme

Bir offline eval, akla gelen vakaları ölçer. Production, gelmeyenleri getirir; dolayısıyla offline eval gerekli ama yetersiz bir kontroldür. Online değerlendirme, agent'ın davranışını gerçek trafik üzerinde, müşteriye zarar vermeyecek biçimde ölçer.

Production run'larının örneklenmiş notlandırması

Bölüm 20'deki trace pipeline'ı zaten her run'ı kaydediyor. Biten run'ların bir payı örneklenir, referans olmadan çalışabilen grader'lardan (deterministik invariant'lar ve dayandırma ile ton için model grader'lar) geçirilir ve oranlar zaman içinde izlenir. Kayma burada görünür: sağlayıcıda bir model güncellemesi, müşterilerin yazdığı şeyde bir değişiklik, sonuçlarının biçimi değişmiş bir tool. Bunlar bir deploy ile gelmez, dolayısıyla hiçbir deploy gate onları yakalamaz. Örneklenmiş online notlandırma onları gören kontroldür.

Örnekleme production verisine dokunur, bu yüzden trace'lerin herhangi bir kullanımındaki kurallar geçerlidir: redaction, erişim kontrolü ve bir saklama süresi (Bölüm 17 ve Bölüm 20). Online notlandırmanın çıktısı golden set için de bir kaynaktır. Bir grader'ın işaretlediği ve bir insanın doğruladığı bir production run'ı, aday bir vakadır.

Shadow run'lar


Bir shadow run'da aday yapılandırma gerçek girdilerin bir kopyasını alır ve kaydedilen ve notlandırılan ama asla uygulanmayan öneriler üretir. Çağırdığı tool'lar salt okunur sürümler ya da kaydedilmiş fake'lerdir; bir shadow agent'ın `issue_refund` ya da `send_customer_reply`'ı gerçekten çağırabilmesi mümkün olmamalıdır. Bu kısıt bir tasarım gereksinimidir ve ben onu gate'te uygulardım; shadow agent'ın yazma tool'ları için hiçbir credential'ı olmaz, çünkü "etkileri uygulama" diyen bir prompt bir kontrol değildir.

Shadow run'lar, golden set'in kapsamadığı trafikte bir adayın nasıl davrandığını, agent'ı iki kez çalıştırma bedeliyle gösterir. Müşterilerin nasıl tepki verdiğini gösteremezler ve önceki eylemlerin etkilerine bağlı davranışı gösteremezler, çünkü bunlar hiç gerçekleşmez.

Canary

Bir canary, gerçek trafiğin küçük bir payını adaya yönlendirir ve etkilerini uygular. Adayın eylemlerinin gerçek olduğu ilk noktadır, dolayısıyla offline eval'den ve riskli bir değişiklik için bir shadow run'dan sonra gelir. Ticket başına ya da müşteri başına kararlı bir atama kullanılır; böylece bir ticket yarı yarıya bir yapılandırma, yarı yarıya bir diğeri tarafından ele alınmaz. Canary'nin oranları ve yükseltme ile onay oranları baseline ile karşılaştırılır ve bir rollback kuralı önceden belirlenir: adlandırılmış bir metric adlandırılmış bir çizgiyi aşarsa, trafik bir toplantı olmadan baseline'a döner.

Paraya ilişkin olağan uyarı geçerlidir. İade yapan bir destek agent'ı için bir canary kohortu, kanıtlanmamış bir yapılandırma üzerinde gerçek para harcıyor demektir. Canary payı küçük tutulur, gate ve onay eşikleri production değerlerinde yürürlükte tutulur ve etkilerin geri alınabilir olduğu ticket kategorileriyle başlanması tercih edilir. Canary, bir insan onay adımını yolda, kararlı durumun gerektirdiğinden daha uzun tutacağı yerlerden biridir.



Diyagram soldan okunur ve tam rollout'tan önceki üç çıkış bulunur. Her aşama bir öncekinden daha pahalıdır ve farklı türden bir sorunu yakalar; alttaki döngü ise ekiplerin atladığı kısımdır: online notlandırmanın bulduğu şey golden set'e geri döner, böylece bir sonraki değişiklik o vakayla karşılaşır.

Eval'leri hata taksonomisiyle hizalamak

Tek bir geçme oranı en çok ihtiyaç duyulan bilgiyi gizler. "Yüzde doksan", eksik yüzde onun biraz beceriksiz ifadeler mi yoksa yanlış iadeler mi olduğunu hiçbir şekilde söylemez. Bölüm 3'teki hata taksonomisi çaredir ve her vakada bir alana mal olur.

Her vaka hedeflediği hata sınıfıyla etiketlenir ve başarısız olan her sonuç, hatanın düştüğü sınıfla etiketlenir. Sonra sonuçlar, genel oranla birlikte, sınıfa göre bir tablo olarak raporlanır.

Sınıf	Tipik eval vakası	Grader	Bir regresyon ne anlama gelir
F1 bozuk çıktı	Alışılmadık bir alanla bir tool çağrısının gerektiği bağlam	Deterministik: sözleşmeye göre doğrula	Modelin önerileri parser'ı daha sık geçemiyor; tool açıklamalarına bakılır
F2 yanlış tool ya da yanlış argümanlar	İki siparişli, yalnızca biri iade edilebilir ticket	Deterministik ve referans	Öneriler yanlış siparişi ya da tutarı seçiyor; gate daha fazlasını yakalıyor
F3 dayanaksız iddia	Tool sonucunda istenen olgu yokken taslaklanan cevap	Model grader, kalibre edilmiş, artı alıntılanan alanlar üzerinde deterministik bir kontrol	Cevaplar bağlamın desteklemediği şeyleri söylüyor
F4 talimat ele geçirme	Agent'a hitap eden metinli, güvenilirmez olarak işaretli ticket	Deterministik: sonraki çağrı değişmemiş, etki yok	Bölüm 16'daki yapısal kontroller zayıflamış ya da bypass edilmiş
F5 kontrolden çıkan döngü ya da bayat bağlam	Bir tool'un aynı boş sonucu döndürdüğü vaka	Deterministik: step'ler sınırın altında, durma sebebi kaydedilmiş	Döngüler daha uzun; Bölüm 12'deki ilerleme kontrollerine bakılır
F6 sessiz kısmi hata	İade başarılı olduktan sonra cevap tool'unun başarısız olması	Deterministik: run tamamlandı olarak işaretlenmez, boşluk tespit edilir	Run store ve etki sıralamasında bir boşluk var
F7 yetkisiz etki	Devredilmiş yetkinin üzerindeki istek	Deterministik: gate kararı refuse ya da needs approval	Gate yolda değil; sürüm durdurulur
F8 gözlenmeyen davranış	Herhangi bir run, tam bir trace için kontrol edilir	Deterministik: her etkinin bir span'i ve bir kaydı var	Kayıtta boşluklar var ve sonraki olaylar review edilemeyecek
F9 maliyet ya da gecikme patlaması	Tarihsel olarak çok sayıda step tetikleyen vaka	Deterministik: sınırlara karşı step'ler, token'lar, süre	Değişiklik daha pahalıya mal oluyor; maliyet hedefleriyle karşılaştırılır

Tablo nereye yatırım yapılacağını da söyler. F7 ya da F4'teki bir regresyon, genel orandan bağımsız olarak hattı durdurma olayıdır, çünkü bu vakalar kontrolleri denetler. F3'teki bir regresyon, cevap gönderilmeden önce bir insandan geçiyorsa başka bir yerdeki bir kazanç karşılığında kabul

edilebilir olabilir, doğrudan gönderiliyorsa kabul edilemez. Taksonomi "skor düştü"yü "bu hata sınıfı daha sık oldu"ya çevirir ve bu, bir ekibin harekete geçebileceği bir şeydir.

`ops-agent` için aynı hizalama farklı vakalarla geçerlidir. Bir runbook eval'i agent'a kaydedilmiş bir alarm ve bir dizi kaydedilmiş tool sonucu (log'lar, metric'ler, bir trace) verir ve araştırmayı kontrol eder: `search_docs` ile doğru runbook'a başvurdu mu, önerdiği teşhis aldığı kanıtı alınıldı mı (F3), sınırı içinde durdu mu (F5) ve `request_rollback` önerisi gate'e `needs_approval` kararıyla ulaştı mı, kayıtlı bir onaydan önce hiçbir etki uygulanmadan (F7). Son madde için grader deterministiktir ve vaka güvenlik seviyesinde olmalıdır.

Seti sürdürmek ve ona aşırı uyum

Bir golden set bitmiş bir yapıt değildir. Sistemin, diğer her parçanın ihtiyaç duyduğu özeni isteyen bir parçasıdır.

Bayatlama

Parcelport'un politikaları değişir, tool'lar değişir, ürünler değişir. Artık var olmayan bir politika altında bir iadenin yapılmasını bekleyen bir vaka, yeni ve doğru davranışı başarısız sayar. Her vaka bir review tarihi taşır ve periyodik bir review vakaları emekliye ayırır, günceller ya da doğrular. Bir vaka kasıtlı bir politika değişikliğinden sonra başarısız olduğunda, yanlış olan vakadır; set ile sistem birbirinden kopmasın diye vaka, politikayla aynı pull request'te güncellenir.

Aşırı uyum

Bu, bir eval programının en ince hatasıdır. Bir ekip golden set geçene kadar bir prompt'u iyileştirdiğinde, prompt'u o vakalar için optimize ediyordur. Set bir hedef olarak ne kadar çok kullanılırsa, geçme oranı setin içermediği vakalar hakkında o kadar az şey söyler. Agent iadeleri ele almayı öğrenmemiştir; prompt bu 150 ticket'a göre ayarlanmıştır.

Pratik karşı önlemler var, hiçbiri eksiksiz değil. Setin bir kısmı, gate'leme için kullanılan ve ayarlama için kullanılmayan, saklı tutulan (held-out) bir bölüm olarak ayrılır ve yeni trafikten ve olaylardan yenilenir ki bilinen bir set olarak kalmasın. Bağlamı, tool açıklamasını ya da bir kontrolü

değiştiren düzeltmeler, tek bir ticket'ın ifadesine yama yapan düzeltmelere tercih edilir. Genel bir düzeltme birçok vakayı hareket ettirir, bir yama tek birini. Başarısız her vaka için bir istisna biriktiren bir prompt bir tasarım kokusudur, çünkü her istisna, kodda olması gereken eksik bir kontrolün yerini tutar. Golden set'in geçme oranı ile online geçme oranı arasındaki fark izlenir. Offline sayı yükselip online sayı yükselmiyorsa, set öğrenilmiştir.

Suite'in maliyeti

Eval suite'inin işletme maliyetleri vardır: her vakanın her tekrarı için model çağrıları, model grader çağrıları, fixture bakımı, insan notlandırma süresi. Setin tam bir çalıştırmasının, diyelim, 40 dakika sürdüğünü varsayalım. Geliştiriciler onu daha seyrek çalıştırır ve istisna ister. Çare katmanlı bir suite'tir: prompt ya da politikadaki her değişiklikte küçük ve hızlı bir set, bir sürümden önce tam set ve pahalı insan notlandırmalı kontroller bir takvimle. Çalıştırması çok pahalı bir kontrol daha seyrek çalıştırılır ve daha seyrek çalıştırılan bir kontrol pratikte kaldırılmıştır.

Uyarı: Haftalardır kırmızı olan ve her seferinde muaf tutulan bir eval suite'i, hiç suite'in olmamasıyla aynıdır ve daha kötüdür, çünkü sürüm süreci hâlâ birini içerdiğini iddia eder. Suite değişiklikleri bloklamıyorsa, ya raporladığı şey düzeltilir ya da yetkisi açıkça kaldırılır; böylece kimse onu bir kontrol sanmasın.

Trade-off'lar ve maliyetler

Eval'ler gerçek çaba gerektirir ve onları bedava gibi sunmak dürüst olmazdı.

Seti kurmak insana mal olur. Birinin ticket'ları örneklemesi, redact etmesi, beklenen sonuçları yazması ve zor vakaları Sam'in ekibiyle review etmesi gerekir. Bu uzman zamanıdır ve özellik işiyle yarışır. Getirisi yavaş gelir, doğası gereği görünmez olan, bir Perşembe queue'suna yol açmayan değişikliklerde.

Bir model grader, yanlış olabilecek bir bileşen ekler. Küçük ekipler için bu ek yük sorundan büyük olabilir. Deterministik grader'lar önemli olanın çoğunu kapsıyorsa, mümkün olduğu için kalan kısım adına bir model

grader eklemesdim.

Eşikler sürtünme yaratır. Değişiklikleri bloklayan bir gate ekibi yavaşlatır; işi budur ve marj ayarlanana kadar bedel yanlış bloklarla ödenir.

Bunların hepsini ne zaman kurmamalı. Yalnızca bir insanın review etmesi için, düşük hacimde cevap taslakları hazırlayan bir agent'ın canary sistemine ihtiyacı yoktur. Kullanıcısı olmayan bir prototipin bir avuç elle yazılmış vakaya ve onları çalıştırma alışkanlığına ihtiyacı vardır. Sahibi olan bir set, kalibre edilmiş grader'lar, bir deploy gate ve online örnekleme içeren tam program, bir agent paraya mal olan ya da müşterilere dokunan etkiler uyguladığında, onu birkaç kişi değiştirdiğinde ve sık değiştiğinde haklı çıkar. Kuracağım sıra şudur: küçük, elle yapılmış bir sette deterministik grader'lar, sonra olay vakaları, sonra deploy gate, sonra online örnekleme ve ancak ondan sonra, trafik ve riskler gerektiriyorsa, model grader'lar, shadow run'lar ve canary'ler.

Eval'ler güvenliği kanıtlamaz. Geçen bir suite, agent'ın settaki vakalarda iyi yaptığını söyler. Sette olmayan vakalar hakkında hiçbir şey söylemez ve agent'ı güvenli kılmaz.

Sık yapılan hatalar

- **Eval'e unit test gibi davranmak.** Tek bir run'da tam bir öneri iddia etmek zararsız nedenlerle başarısız olur ve şans eseri geçer. Cazip, çünkü ekibin zaten bildiği test biçimi bu. Tekrarlar üzerinden bir oran ölçülür, önemli olan notlandırılır ve tam iddialar deterministik tarafa saklanır.
- **Tek bir genel skor kullanmak.** Tek bir sayı hangi hata sınıfının hareket ettiğini gizler. Cazip, çünkü bir dashboard'a sığar. Hata sınıfına ve seviyeye göre raporlanır ve F4 ile F7 regresyonları ortalama bağımsız olarak bloklayıcı sayılır.
- **Kalibre edilmemiş bir model grader'a güvenmek.** Grader'ın geçme oranı kalite sayısı olur ve kimse onun insanların düşündüğüyle nasıl ilişkili olduğunu bilmez. Cazip, çünkü insan etiketleme işini ortadan kaldırır. İnsan etiketlerine karşı kalibre edilir, nerede müsamahakâr olduğu bulunur ve değiştiğinde yeniden kalibre edilir.

- **Gürültünün içindeki farkları okumak.** Bir run'da skor 89'dan 91'e gitti diye bir değişikliği daha iyi ilan etmek. Cazip, çünkü bir sayı hareket etti. Vakalar tekrarlanır, bir aralıkla karşılaştırılır ve yön değiştiren vakalar okunur.
- **Setin tamamına karşı ayarlama yapmak.** Her vaka geçene kadar prompt üzerinde iterasyon yapıp aynı seti gate olarak kullanmak. Cazip, çünkü set mevcut tek ölçü. Bir bölüm gate'leme için ayrılır, trafikten ve olaylardan yenilenir ve offline ile online oranlar arasındaki fark izlenir.
- **Sette gerçek PII bırakmak.** Ticket'ları olduğu gibi kopyalamak. Cazip, çünkü gerçek bir ticket en sadık vakadır. Girerken redact edilir, rol korunup değer düşürülür ve set production düzeyinde erişim kontrolüyle saklanır.

Temel çıkarımlar

- Bir eval sistemin olasılıksal parçalarını ölçer ve bir test deterministik parçaları kontrol eder; dolayısıyla ikisine de ihtiyaç var ve her zaman geçerli olması gereken herhangi bir sınır gate'e aittir, bir eval'e değil.
- Eval'in dört seviyesi ayrı tutulur: tek step, uçtan uca, güvenlik ve sınır, maliyet ve gecikme; çünkü farklı grader'ları, maliyetleri ve sahipleri var.
- Golden set örneklenmiş ve redact edilmiş gerçek trafikten, elle yazılmış zor vakalardan ve olaylardan gelen vakalardan kurulur ve geride vaka bırakmayan bir olay review'u bitmemiş sayılır.
- Deterministik grader'lar tercih edilir, model grader'lar yalnızca kodun kontrol edemediği şeyler için kullanılır ve her model grader, skoruna inanılmadan önce insan etiketlerine karşı kalibre edilir.
- Sonuçlar, bir miktar belirsizlik kavramıyla, tekrarlar üzerinden oranlar olarak ve hata sınıfına göre dilimlenerek raporlanır; böylece bir regresyon, hareket eden bir sayı olarak değil, "bu hata sınıfı daha sık oldu" olarak okunur.
- Bir prompt'taki, modeldeki, tool'daki, politikadaki ya da sınırdaki her değişiklik, regresyon eşiği olan bir eval run'ından geçirilir, güvenlik vakaları bloklayıcı sayılır ve deploy gate, riskler gerektirdiği yerlerde online örnekleme, shadow run'lar ve bir canary ile tamamlanır.

- Set sistemin parçası olarak sürdürölür; bayat vakalar emekliye ayrılır, aşırı uyuma karşı vakalar saklı tutulur ve suite çalıştırılacak kadar ucuz tutulur, çünkü atlanan bir kontrol, gitmiş bir kontroldür.

Eval, agent'ın hâlâ doğru olanı yapıp yapmadığını söyler; doğru olanın neye mal olduđu hakkında hiçbir şey söylemez. Bölüm 22, eval'in yan tarafta ölçmekte olduđu Sınır'ı, yani her run'ın harcamasını ve gecikmesini ele alıyor ve kaliteyi tasarrufun bedelini sessizce ödemeye bırakmadan bunun nasıl atfedileceğini, sınırlanacağını ve azaltılacağını gösteriyor.

Bölüm 22 — Maliyet Kontrolü

Parcelport'ta operasyon başkanının çeyrek sonunda Alex'e basit bir soru sorduğunu düşünelim: destek agent'ı ilk değerlendirmeyi yaptığına göre bir destek ticket'ı artık ne kadara mal oluyor? Alex model sağlayıcısının faturasını açıyor ve tek bir satır buluyor. Satır büyük, çeyrek boyunca büyümüş ve hangi agent'ın, hangi müşterinin, hangi özelliğin ya da hangi tür ticket'ın buna yol açtığı hakkında hiçbir şey söylemiyor. Ops agent'ı aynı gateway'i paylaşıyor, dolayısıyla onun incelemeleri de bu satırın içinde.

İkinci ayda yapılan bir prompt değişikliğinin her model çağrısına uzun bir politika alıntısı eklediğini varsayalım. Tipik bir run'ın girdisini ikiye katlamaya kimse karar vermedi; alıntı makuldü, cevaplar biraz iyileşti ve değişiklik yayına çıktı. Yavaş bir sağlayıcıya karşı uygulanan bir retry politikasının da kötü geçen bir hafta boyunca çağrıları sessizce katladığını varsayalım. Bunların her biri makul bir yerel karardı ve hiçbirisi tek bir fatura satırında görünmüyor.

Sam'in sorusunun farklı bir versiyonu var. Agent bazı ticket'ları hand-off'a geçiriyor ve her hand-off bir insan queue'suna düşüyor. Agent eskisinden ucuz mu, yoksa maliyet faturadan Sam'in ekibine mi kaydı; orada da kimse onu bir dashboard'a koymuyor? Bu bölümün cevapladığı soru şu: bir run'ın neye mal olduğu nasıl görülür, işi sessizce bozmayan kontrollerle nasıl aşağıda tutulur ve maliyet değiştiğinde bu nasıl fark edilir.

Bu bölüm kontrol zarfının **Sınır** parçasına ait. Sınır, döngünün nerede durduğunu ve çalıştırmanın neye mal olduğunu sorar. Bölüm 13 sert tavanları verdi; bu bölüm her limitin içinde kalan ve yine de yanlış olan gündelik harcamayla ilgili: onu nasıl ölçeriz, nasıl atfederiz, nasıl azaltırız ve nasıl izleriz.

Sorun ve neden zor olduđu

Hata sınıfı **F9 (maliyet ya da gecikme patlaması)**: run doğru ve çok pahalıya mal oluyor. Can sıkıcı bir sınıf, çünkü hiçbir şey bozuk değil. Her çağrı başarılı, her cevap kabul edilebilir, gate her öneriye izin verdi. Belirtiler bir fatura ve bir queue ve ikisi de geç geliyor.

Maliyet başka sınıfları da besler. Döngüye giren bir run, **F5 (kontrolden çıkan döngü ya da bayat bağlam)** yan etkisi olarak para harcar. Kendi harcamasını göremeyen bir run'ın o harcamayla sınırlandığı söylenemez. Kimsenin atfedemediği bir maliyet de **F8 (gözlenmeyen davranış)** örneğidir: sistem pahalı bir şey yaptı ve neyi, neden yaptığına dair kullanılabilir hiçbir kanıt bırakmadı. Atıf olmadan bir maliyet sıçraması baştan başlayan bir soruşturmadır.

Akla gelen ilk yaklaşım en büyük sayıyı kırmaktır. Daha küçük bir model kullanmak, prompt'u kısaltmak, cevapları cache'lemek. Bunların her biri doğru olabilir ve her biri cevapları kabul edilebilir kılan şeyi de ortadan kaldırabilir. Bir model çağrısının maliyeti daha uzun bir toplamın tek satırıdır ve diğerleri hareket ederken tek bir satırı optimize etmek, maliyet kontrolünün haftalar sonra daha uzun bir insan queue'su olarak ortaya çıkan bir kalite gerilemesine dönüşmesinin yoludur.

Akla gelen ikinci yaklaşım modelden tutumlu olmasını istemektir. Prompt, olabildiğince az step kullanmasını ve kendini tekrar etmemesini söyler. Savurgan step oranını düşürebilir, ama bu bir kontrol değildir. Model günün toplamını ya da fiyat tablosunu göremez ve sınırlanan şeye bağlı bir limit limit değildir. Tavan kodda yaşar (Bölüm 13); gündelik maliyet ise kodun yaptığı tasarım seçimlerinde yaşar: bağlama ne girer, hangi model tier'ına sorulur, hangi istekler agent'a hiç ulaşmaz.

Para nereye gidiyor

Herhangi bir şeyi ölçmeden önce, bir run'ın nerelerde harcama yaptığı listelenir. Çoğu liste token'larda durur. Bir agent için token'lar görünür en büyük kalemdir ve nadiren tek kalemdir.

Kaynak	Neyin belirlediği	Nerede saklandığı
Girdi token'ları	Derlenen bağlamın boyutu, her step'te yeniden gönderilir	Bağlam büyümesi: her step önceki step'lerin eklediklerini taşır

Kaynak	Neyin belirlediği	Nerede saklandığı
Çıktı token'ları	Önerilerin ve taslakların uzunluğu	Ayrıntılı taslaklar, tekrarlanan planlar, kimsenin okumadığı açıklamalar
Döngü step'leri	Nihai cevaba ya da bir durmaya kadar geçen tur sayısı	İlerleme sağlamayan step'ler (Bölüm 12)
Retry'lar ve fallback'ler	Tekrarlanan model çağrıları, daha pahalı bir fallback tier'i	Bozuk geçen bir hafta normal trafik gibi görünür, yalnızca daha pahalıdır (Bölüm 14)
Tool çağrıları	Tool'un arkasındaki servisin dış maliyeti	Geniş bir aralıkta log sorgusu, uzun süren bir tanılama
Sandbox	run_diagnostic için başlatma ve hesaplama saniyeleri	Başlatmanın ağır bastığı kısa betikler
İnsan zamanı	Onaylar, hand-off'lar, örneklenen run'ların review'u	Bir ekibin takviminde görünür, faturada hiç görünmez
Kayıt	Trace'lerin, prompt'ların ve çıktıların saklanması (Bölüm 20)	Her step için tam bağlamın saklama süresi
Eval'ler	Golden set run'ları, grader'lar, shadow trafik (Bölüm 21)	Her değişiklik ücretli bir run tetikler

Bağlam büyümesi bir sayıyı hak ediyor, çünkü insanları şaşırtan maliyet o. Bir run'ın 2.000 token'lık bağlamla başladığını ve her step'in 1.000 token'lık tool sonucu ve öneri eklediğini varsayalım. k. step'te model çağrısı 2.000 artı 1.000 çarpı k token girdi taşır. On step boyunca bu toplam 75.000 girdi token'ı eder; büyümeyen bir bağlam 20.000 göndermiş olurdu. On beş step'te toplam 150.000. Step sayısı yarı yarıya fazla, girdi iki katı. Sayılar varsayımsal ve asıl mesele biçim: girdi maliyeti step sayısından daha hızlı büyür, step limiti ve bağlam diyeti bu yüzden güvenilirlik kontrolleri olduğu kadar maliyet kontrolleridir. Sağlayıcı tekrarlanan örnekleri farklı fiyatlandırıyorsa bu oranı değiştirir, biçimi değiştirmez.

İnsan zamanı en sık dışarıda bırakılan maliyettir. Sam'in ekibi bir hand-off özetini okuyor ve cevaplıyor, her onay da bir kişinin dikkatine mal oluyor (Bölüm 15). Bu bölüm "bir run'ın maliyeti" dediğinde, run'ın yol açtığı insan dakikaları da buna dahildir.

Maliyeti ölçmek ve atfetmek

Nereye ait olduğu bulunamayan bir maliyet kısılamaz. Atıf, her harcama birimi hakkında dört soruyu cevaplar: hangi run, hangi agent ve versiyon, hangi özellik ve hangi müşteri ya da tenant. Bunları cevaplamamanın yeri trace'tir (Bölüm 20), çünkü trace zaten run ve step tanımlayıcılarını taşıyor ve bir maliyet olayı bir span hakkında bir olgu daha.

Para değil, ham kullanımı kaydederdim. Giren token'lar, çıkan token'lar, çağrılar, sandbox saniyeleri. Para, kendi versiyonu olan bir fiyat tablosundan rapor zamanında hesaplanır. Sağlayıcı bir fiyatı değiştirirse ya da bir route'un tier'ı değiştirilirse geçmişin yeniden yazılması gerekmez ve geçen ayın bugünün fiyatlarıyla neye mal olacağı sorulabilir.

```
function recordCost(run, step, call, kind, usage):
  event = {
    run_id: run.id, step_id: step.id,
    kind: kind,                                // "model", "tool", "sandbox"
    usage: usage,                              // raw: tokens in/out, calls,
    seconds
    route: step.route,                        // "short_path", "small",
    "primary", "fallback"
    retry_of: call.attempt > 1 ? call.id : null, // attempt number
    from the retry loop (Chapter 14)
    agent: run.agent, agent_version: run.agent_version,
    feature: run.feature,                    // e.g. "delayed_parcel"
    tenant: run.tenant_id,                  // opaque ids only, never names
    subject: run.ticket_id,
    price_version: prices.version,          // money is computed later
    estimated: usage.is_estimate            // true after a timeout
  }
  record(run, "cost", event)                // trace pipeline: may lag, may be
  lost
```

Üç alan, kolayca hafife alınan işler yapıyor. `route`, ucuz yolun maliyetini `primary` ve `fallback`'inkinden ayırmayı sağlar. `retry_of`, tekrarlanan çağrıların maliyetini işin maliyetinden ayrılabilir kılar. `estimated`, kullanımı hiç raporlanmamış çağrıları işaretler; bir timeout'un geride bıraktığı da budur: orchestrator bir tahmin tutar, gateway başka bir şey faturalamış olabilir ve olay hangisi olduğunu söyler.

Trace pipeline'ı model gateway'inden ayrı bir sistemdir, dolayısıyla ikisi bazen aynı fikirde olmaz. Token'lar için gateway'in kullanımını doğruluk kaynağı sayar ve her gün ona karşı mutabakat yapardım: agent ve gün bazında maliyet olaylarının toplamı, gateway'in toplamına karşı. Bir fark muhasebe sıkıntısı değil, bir sinyaldir. Gateway lehine pozitif bir fark, bazı

çağrılarının maliyet olayı bırakmadığını söyler; bu, maliyet sisteminin içindeki bir F8'dir: modele orchestrator olmadan ulaşan bir kod yolu. Negatif bir fark olayların çift sayıldığını söyler. İkisi de bir sahibi hak ediyor.

Tanımlayıcılar başka bir nedenle de önemli. Müşteri başına maliyet yararlı bir sorudur ve olaya isim ya da e-posta koymadan, yalnızca opak tenant ve subject tanımlayıcılarıyla sorulmalıdır (Bölüm 17). Maliyet kaydı uzun ömürlü ve geniş kitlece okunabilir, çünkü hem finans hem mühendislik ona bakıyor ve PII'nin orada yeri yok.

Önemli olan birim

Model çağrısı başına maliyet yararlı bir mühendislik sayısı ve kötü bir iş sayısıdır. Yönetmek istediğim birim, destek agent'ı için **çözülen ticket başına maliyet** ve ops agent'ı için **inceleme başına maliyet**; maliyet, run'ın yol açtığı her şeyi içerir: model, tool'lar, sandbox ve hand-off'ların ve onayların insan dakikaları.

Paydada "çözülen" önemli. Hand-off ile biten bir run agent tarafından çözülmemiştir ve onun insan maliyeti run'a aittir. Fatura maliyeti yalnızca agent'ın çözdüğü ticket'lara bölünürse, pahalı ticket'ları erken hand-off'a geçirerek sayı düşürülebilir; bu, onların token'larını faturadan düşürürken insan maliyetini başka yere indirir. Faturada tasarruf gibi görünür ve başka bir bütçede bir maliyettir.

Birim ekonomisi, uydurma sayılarla

Varsayımsal sayılar yapıyı gösterir ve aşağıdakilerin hiçbirisi bir ölçüm değildir. Kendi sayıları kullanılmalıdır. Parcelport'un destek queue'suna günde 200 ticket geldiğini varsayalım. Birimin soyut bir maliyet birimi olduğunu ve bir insanın bir ticket'ı sıfırdan ele almasının 50 birime mal olduğunu varsayalım. Agent'ın model, tool ve sandbox harcamasının run başına ortalama 3 birim, yani günde 600 birim olduğunu söyleyelim.

Tipik bir günde 200 ticket'ın 130'unun agent tarafından hiç insan işi olmadan çözüldüğünü, 70'inin bir özetle hand-off'a geçtiğini ve özet okuma süresinden kazandırdığı için her birinin bir insana 35 birime mal olduğunu varsayalım. 200'ün 20'sinin her biri Sam'in dikkatinden 5 birim tutan bir onay içerdiğini söyleyelim. Günlük toplam:

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


Bu uydurma örnekte fatura benzeri satır, 600 birim, toplamın beşte birinden az ve hand-offların insan maliyeti en büyük satır. En büyük görünen kaldıraç, en büyük olan kaldıraç değil.

Sınayalım. Daha ucuz bir model tier'ının model harcamasını üçte bir oranında düşürdüğünü, yani günde 200 birim tasarruf ettirdiğini varsayalım. Çözüm oranını da düşürdüğünü ve günde on ticket daha fazlasının hand-off'la bittiğini varsayalım. Bu on ticket'ın her biri artık daha önce mal olmayan 35 birimlik insan zamanına mal oluyor, yani 350 birim. Değişiklik 200 tasarruf ettiriyor ve 350'ye mal oluyor, günde net 150 birim artış; fatura iyi bir sonuç gösterirken insan queue'su uzuyor. Tersisi de geçerli: run başına daha pahalıya mal olan ve on ticket daha fazla çözen bir değişiklik toplamı düşürebilir. Bir maliyet değişikliğinin her zaman kaliteye karşı değerlendirilmesinin nedeni budur ve bölümün geri kalanı buna dönüyor.

Maliyeti azaltan kontroller

Beş kontrol var ve riske ne kadar az soktuklarına göre sıralandılar. İlki modeli hiç ilgilendirmiyor.

Mermaid diyagramı her kontrolün bir ticket'ın yolunda nerede durduğunu gösteriyor. Bir isteğin modele ulaşmadan yoldan çıktığı yerlere ve her çıkışta dinleyen maliyet kaydına bakılır.



Deterministik kısa yollar

En ucuz model çağrısı hiç yapılmayandır. Hacmin çoğunu oluşturan birkaç ticket türü için kodlanmış bir yol, örneğin bir `lookup_order` çağrısı ve biçimlendirilmiş bir durum olarak "siparişim nerede", model çağrısı olmadan cevap verir (Bölüm 14 aynı yolu bir fallback basamağı olarak anlatır). Bir maliyet kontrolü olarak, normal bir günde yerini hak eder.

Aynı fikir ops agent'ı için de geçerli. Tek bir nedenden kırk alert tetiklendiğini varsayalım. Kırk inceleme açmak kırk kat harcama ve tek bir cevaptır. Agent'tan önce gelen, alert'in kaynağına ve zaman penceresine göre anahtarlanan bir grupta adımları tek bir run başlatır ve diğer otuz dokuzunu ona ekler. Bölüm 13'ün subject seviyesi subject başına run'ları sayar; grupta, bu sayıya anlam kazandıran adımdır.

Kısa yol deterministiktir, dolayısıyla eval'ler değil klasik testler alır (Bölüm 21). Kısa yolları, tool verisinde net bir cevabı olan en üstteki bir avuç ticket türü için kurardım ve orada dururdum.

Model routing

Bir router, bir run ya da bir step için model tier'ını seçer: kolay iş için daha küçük, daha ucuz bir tier, geri kalanı için primary tier. İlke, bu kitaptaki her kontrole hükmeden ilkedir: routing kararı yapılandırılmış sinyallerden kodla verilir ve kanıtla doğrulanır. Modelden kendi zorluğunu derecelendirmesini isteyen bir router bir öneri daha demektir ve bir öneri olarak değerlendirilmelidir.

Bağlı kalacağım kural, bir eval buna izin verdiğini söyleyene kadar hiçbir route'un ucuz olmamasıdır. Route tablosu her ticket türü için tier'ı ve onu haklı çıkaran eval run'ını adlandırır.

```
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)
```

Tier yükseltme kolayca unutulmuş kısım. Küçük tier bozuk çıktı (F1) ya da gate'in iki kez reddettiği tool çağrıları (F2, yanlış tool ya da yanlış argümanlar) üretirse bir tier yukarı çıkmak makuldür ve aynı zamanda ilkinin üstüne ödenen ikinci bir çağrıdır. Bu yüzden tier yükseltmeleri sayılır ve sınırlandırılır, kayıttadırlar: yükseltme oranı tırmanan bir route, küçük tier'ı işi yapmayan bir route'tur ve tablo bunu söylemelidir.

Örnek bir politika, bir reviewer'ın bir route'un neden ucuz olduğunu okuyabilmesi için kanıtı route'un yanında tutar. Aşağıdaki notasyon örnek amaçlıdır ve hiçbir gerçek ürünün sözdizimi değildir.

```
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 // illustrative margin
      f3_rate <= baseline // no more ungrounded claims
      refused_proposal_rate <= baseline
    review_every: 30 days
    default: primary
```

Bir route kalıcı değildir. Prompt'ta, modelde, bir tool'da ya da bir politikada yapılan bir değişiklik bir eval run'ıdır (Bölüm 21) ve kanıtı eskimiş bir route, inançla ucuz kalmak yerine varsayılan tier'a döner. Bedel eval run'larında ve tabloyu tutma disiplininde ödenir: tasarruflar yalnızca tablo güncelse gerçektir.

Bağlam diyeti

Girdi token'ları her step'te tekrarlanır, dolayısıyla bağlam en büyük çarpanlı kaldıraçtır. Bağlamın nasıl derlendiği Bölüm 9'un konusu; maliyet merceği bir soru ekliyor: bağlamdaki hangi kaynak kendi yerini hak ediyor?

Bölüm 9'un önerdiği context manifest her ögenin kaynağını ve boyutunu kaydeder. Maliyet olayına bağlandığında girdi token'larının kaynağa göre dökümünü verir: sistem politikası, ticket metni, tool sonuçları, getirilen pasajlar, bellek notları, geçmiş. Döküm genellikle öğreticidir. Step'in iki alana ihtiyaç duyduğu yerde bir sipariş kaydının tamamını döndüren bir tool sonucu yaygın durumdur ve bir sonucu bir sonraki step'in ihtiyaç duyduğu alanlara kırpma aynı zamanda bir PII azaltımıdır (Bölüm 17). Tekrarlanan tool sonuçları, hiçbir şeyin atıf yapmadığı getirilen pasajlar ve artık kararı bilgilendirmeyen eski geçmiş diğerleridir.

Diyetin bir kalite maliyeti var. Çıkarılan her öge, modelin artık bir iddiayı dayandıramayacağı bir şeydir ve çok fazla çıkarmak F3 (dayanaksız iddia) ya da eksik veya bayat bağlam yoluyla F5 üretir. Dolayısıyla diyet, diğerleri gibi eval destekli bir değişikliktir: çıkarılır, golden set çalıştırılır, hata sınıfı dağılımı okunur ve değişiklik yalnızca sayılar tutuyorsa

korunur. Geçmişin özetlenmesi özel bir kuşkuyu hak eder, çünkü bir özet, bunun ima ettiği F3 riskini taşıyan bir model çıktısıdır (Bölüm 9 her kırpmının neyi kaybettiğini anlatır).

Cache'leme ve riski

Bir cache, yeniden hesaplamak yerine daha önceki bir sonucu döndürür ve bunun bedeli, daha önceki sonucun artık doğru olmama riskidir. Cache'leme diye anılan üç farklı şey var ve riskleri farklı.

Okuma verisini cache'lemek, örneğin bir sipariş durumunu ya da bir doküman arama sonucunu, en güvenliisidir. Her ögeye politikada bir azami yaş verilir, yaş trace'e kaydedilir ve önemli olduğunda okuyana söylenir, Bölüm 14'ün şablon cevaplar için yaptığı gibi. Cache'lenmiş bir değeri asla bir yazmanın temeli olarak kullanılmaz: bir iade ya da adres değişikliği, gate'te taze bir okumaya karşı denetlenir. Bayat okumalar F5'tir ve bir cache pencereyi uzatır.

Model cevaplarını isteğe göre anahtarlayarak cache'lemek daha risklidir, çünkü anahtar durum değildir. Bir müşterinin geciken kargosuna verilen cevap, metin benzer görünse bile bir başkasının için yanlıştır. Hiç cache'lenecekse anahtar principal'ı, tenant'ı, cevabın bağlı olduğu tool sonuçlarını ve prompt ile politikanın versiyonunu içerir. Müşteriler arasında geçen bir cache bir PII ifşasıdır (Bölüm 17) ve bir prompt değişikliğinden uzun yaşayan bir cache, düzeltilmiş bir davranışın çalışmaya devam etmesinin bir yoludur. Müşteriye ulaşan nihai cevapları cache'lemezdin ve bir etkiye yol açan hiçbir şeyi cache'lemezdin.

Retrieval sonuçlarının doküman versiyonuna göre anahtarlanarak cache'lenmesi orta durumdur: doküman değişmediyse pasajlar da değişmemiştir ve anahtar bunu söyler. Bir aramayı ve yeniden embedding'i kurtarır, versiyon anahtarın parçası değilse başarısız olur. Ne cache'lenirse cache'lensin, bir cache hit trace'te yaşıyla birlikte bir olaydır, böylece yanlış bir cevap cache'lenmiş bir girdiye kadar izlenebilir.

```
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 }
```

Maliyet kontrolü olarak limitler

Step, tool çağrısı ve token limitleri Bölüm 12 ve 13'ün konusudur ve her biri bir run'ın kötü davrandığı günlerde bir maliyet kontrolüdür. Maliyete özgü nokta, bu limitlerin meşru run'ların dağılımından belirlenmesi ve o dağılımın maliyet kaydından gelmesidir.

Maliyet anomalileri ve kill switch

Bölüm 13'teki tavanlar en kötü durumu durdurur. Maliyet kaydındaki alarmlar normal bir gün ile bir tavan arasındaki durumları yakalar ve harekete geçirilebilir olmaları için atfedilmeleri gerekir.

Sinyal	Neyle karşılaştırıldığı	İlk soru
Saatlik harcama, agent başına	Son haftalardaki aynı saat	Bir deploy, bir route değişikliği ya da bir trafik değişikliği oldu mu?
Run başına maliyet, üst kuyruk	O ticket türünün dağılımı	Hangi özellik ya da tenant kuyrukta?
Step başına girdi token'ları	Agent versiyonu için yakın zamanın ortalaması	Bağlam büyüdü mü ve hangi kaynak?
Çağrılar içinde retry ve fallback payı	Normal pay	Bir sağlayıcı ya da bağımlılık bozuldu mu (Bölüm 14)?
Çözülen ticket başına maliyet	Geriye dönük pencere	Çözüm oranı değişti mi?
Normalin çok altında harcama	Son haftalardaki aynı saat	Run'lar durdu mu, bir breaker açıldı mı ya da bir kısa yol ticket'ları yuttu mu?

Son satır insanların kurmadığı satır. Keskin biçimde düşen bir maliyet de bir anomalidir, çünkü daha az iş yapan bir agent daha az harcar. Açılan bir breaker, fazla şeyle eşleşen bir kısa yol ya da run başlatmayan bir orchestrator, hepsi faturada tasarruf gibi görünür. Her maliyet alarmı bir hacim ya da sonuç sinyaliyle eşlenir ki ikisi birlikte okunabilsin.

Alarmlar yalnızca küresel bir ortalamaya değil, agent versiyonuna ve route'a karşı karşılaştırılmalıdır, çünkü maliyeti oynatan bir değişiklik neredeyse her zaman bunlardan birinde bir değişikliktir. Deploy işaretçisi, prompt versiyonu ve route tablosu versiyonu dashboard'da maliyet çizgisinin yanında durmalıdır. Kayıt parçasının ne işe yaradığı budur.

Bir alarmin gerçek olduğu ortaya çıktığında, önce atfın işaret ettiği yer sınırlanır: onun subject ya da tenant bütçesi düşürülür ya da o route varsayılan tier'a gönderilir. Maliyet geniş yayılmış ve büyüyorsa Bölüm 13'teki agent seviyesi breaker ve kill switch kullanılır; runbook bu trade-off'u önceden söyler (Bölüm 23).

Not: Her maliyet alarminın adı konmuş bir sahibi ve bir ilk eylemi olmalıdır; Bölüm 13 bunu bir kural olarak koyar, Bölüm 23 runbook'ta tutar.

Ucuza görünür kılmak

Yukarıdaki her kontrol agent'ı daha kötü yapabilir ve bunun başarısız oluş biçimi sessizdir. Maliyet her gün ölçülür, kalite biri baktığında ölçülür; bu yüzden bir maliyet azaltımı haftalarca net bir kazanç gibi görünebilir. İkisini bir arada tutmanın yolu, her maliyet değişikliğine kalite kanıtını taşıtmaktır.

Offline çalıştırılabilecek bir değişiklik için, örneğin bir route değişikliği, bir bağlam diyeti ya da farklı bir step limiti, golden set (Bölüm 21) mevcut versiyonla ve adayla çalıştırılır ve çözülen vaka başına maliyet, çözüm oranı ve hata sınıfı dağılımı karşılaştırılır. F3 ya da F2 oranları tırmanırken düşen maliyet, faturadan review edenlere ve yanlış cevap alan müşterilere bir aktarımdır. Kabul kuralı, iyi bir maliyet sayısının kötü bir kalite sayısını geçecek şekilde tartışamaması için, run'dan önce bir kalite eşiği olarak belirtilir.

Offline kanıt, yeniden açılan bir ticket ya da geri çevrilen bir karar gibi gecikmeli sinyaller için yeterli değildir. Müşteriye dönük cevaplara dokunan değişiklikler için trafiğin küçük bir payı adaya yönlendirilir ve hand-off, yeniden açılma ve reddedilen öneri oranları tam bir haftalık ritim boyunca baseline ile karşılaştırılır (Bölüm 21 shadow ve canary'yi anlatır).

Golden set bir değişikliğin etkilediği türden ticket içermiyorsa kanıt yok demektir ve bir tasarruf iddia edilmemelidir.

Parcelport: iki run, kalem kalem

Parcelport'ta geciken bir kargo ticket'ını düşünelim. Orchestrator önce ticket için açık bir run olup olmadığına bakar; yok. Kısa yol eşleştiricisi eşleşmez, çünkü müşteri geç bir teslimatı ve olası bir iadeyi soruyor ve bu bir durum sorusu değil. Route tablosu bu ticket türünü, bir eval run'ı kayıtlı olan küçük tier'a gönderir ve run bütçeleri altında başlar.

Run dört step atar: `lookup_order`, gecikme politikası için `search_docs`, taslak metinle `send_customer_reply` ve nihai cevap. Her model çağrısı ve her tool çağrısı, `small` route'u, agent versiyonu, `delayed_parcel` özelliği ve opak tenant ile kendi maliyet olayını yazar. İlk step'in bağlamı küçük; dördüncüye gelindiğinde tool sonuçları ve getirilen bir pasaj eklenmiştir. Manifest, girdi token'larının en büyük payını sipariş kaydının, taslağın hiç kullanmadığı alanlarla birlikte sağladığını gösterir ve `lookup_order`'ın sonuç biçimindeki bir sonraki değişiklik onları kırpar. Run'ın maliyeti yedi olayın toplamıdır: dört step'in her biri için bir model olayı ve ilk üçünün her biri için bir tool olayı; bunun hiçbirisi bir insanın takviminde değildir.

Şimdi bir ops vakası. Bir alert fırtınası tek bir nedenden kırk alert üretir. Gruplama adımı tek bir inceleme başlatır ve gerisini ona ekler. Ops agent'ı birkaç step `query_logs` ve `get_metrics` çalıştırır ve sandbox saniyelerini kaydeden maliyet olayıyla bir `run_diagnostic` yapar. `query_logs` çağrılarının ikisi geniş zaman aralıklarını taradı; bu yalnızca tool maliyeti olayın içinde olduğu için görünür ve sözleşmenin sınırlı aralığı (Bölüm 7) bunun sonucunda sıkılaştırılır. Run bir pull request'e ve önerilen bir rollback'e ulaşır, sonra Robin'i bekleyerek askıya alınır.

Askıdayken bir worker da bir sandbox da tutmaz, çünkü state'i run store'dadır (Bölüm 10). İnceleme başına maliyet, Robin'in onay dakikalarını içerir.

Haftanın sonunda maliyet kaydı operasyon başkanının sorusunu Alex'in savunabileceği bir biçimde cevaplar: özelliğe göre çözölen ticket başına maliyet, modelin, tool'un ve insanın payı ve bir önceki haftadan beri neyin neden değıştiğı. Mükemmel biçimde cevaplayamaz. İnsan dakikaları destek lideriyle üzerinde anlaşılmış tahminlerdir ve sayı bu belirsizliğı taşıır; bu, nereden geldiğini söylemeyen bir sayıdan iyidir.

Trade-off'lar ve maliyetler

Atıf bir maliyettir. Yalnızca run ve agent bazında daha kaba bir kayıt daha ucuzdur ve daha az soruyu cevaplar. Run, agent versiyonu, özellik ve route ile başlar, tenant'lı birinin ona göre ücretlendirmesi ya da limitlemesi gerektiğinde eklerdim.

Routing ve kısa yollar, agent ile uyumlu tutulması gereken bileşenler ekler. Hacim küçükse, diyelim günde birkaç düzine ticket, iyi limitli tek bir tier daha iyi seçimdir; üzerinde route edecek bir dağılım olmadan bir router kurulmaz.

Cache'leme doğruluğı maliyetle takas eder. Bir cache'in azami yaşı ve anahtar kapsamı söylenemiyorsa cache eklenmez.

Sıkı maliyet alarmları page üretir, bu yüzden eşikler için Bölüm 13'ün önerdiği gibi önce observe modunda ayarlama yapılır.

Son olarak, maliyet amaç değildir. İşin yüksek riskli olduğu yerlerde, örneğin tavanın üstündeki iadeler ya da production değışiklikleri, daha güçlü tier'a ve onaya ödeme yapmayı tercih ederim ve bunu politikada söylerim.

Sık yapılan hatalar

- **İnsan maliyetini ölçmeden model maliyetini kısmak.** Cazip, çünkü fatura görönen satır. Hand-off ve onay dakikaları dahil çözölen ticket başına maliyet hesaplanır ve her değışiklik buna göre yargılanır.

- **Daha ucuz bir tier'ı bir ayar saymak.** Cazip, çünkü bir konfigürasyon dosyasında tek satır, ama bu bir davranış değişikliği. Her ucuz route bir eval run'ına bağlanır ve kanıt eskidiğinde varsayılan tier'a döndürülür.
- **Principal'lar arasında cache'lemek.** Cazip, çünkü paylaşılan bir anahtar isabet oranını ikiye katlar. Müşteriyi ya da tenant'ı dışarıda bırakan bir anahtar bir optimizasyonu PII ifşasına çevirir. Anahtar kapsamlanır, yaş kaydedilir ve bir yazma asla cache'lenmiş bir okumaya dayandırılmaz.
- **Tier yükseltmenin serbestçe harcamasına izin vermek.** Cazip, çünkü daha güçlü bir tier sigorta gibi hissettirir. Her şüphede daha güçlü bir tier'a düşmek çağırışı ikiye katlar. Tier yükseltmeleri harcama olarak sayılır ve sınırlandırılır.
- **Yalnızca artışlarda alarm vermek.** Cazip, çünkü maliyet sıçramaları tanıdık hatadır. Maliyetteki keskin bir düşüş agent'ın çalışmayı bıraktığı anlamına gelebilir. Her maliyet sinyali bir hacim ya da sonuç sinyaliyle eşlenir.

Temel çıkarımlar

- Maliyet, Sınır parçasının gündelik sorusudur: Bölüm 13'ün bütçeleri en kötü durumu durdurur, maliyet kontrolü ise her limitin altında kalan ve yine de yanlış olan harcamayla ilgilidir.
- Ham kullanım her span'e run, agent versiyonu, özellik, route ve opak bir tenant ile kaydedilir ve para rapor zamanında versiyonlu bir fiyat tablosundan hesaplanır.
- Çözülen ticket başına ya da inceleme başına maliyete göre yönetilir; hand-off'ların ve onayların yol açtığı insan dakikaları dahil edilir, çünkü fatura çoğu zaman küçük kısımdır.
- Kontroller, risk sırasına göre: modeli atlayan kısa yollar, eval'e bağlı routing, bağlam diyeti, kapsamlı cache'leme ve gerçek dağılımlardan ayarlanan limitler; her biri kalitenin tuttuğuna dair kanıt ister.
- Bağlam maliyeti step sayısından daha hızlı büyür, dolayısıyla bağlam boyutu ve step limitleri maliyet kontrolleridir ve cache'lenen her değer bir yaş, bir kapsamı olmalı ve bir yazmada hiçbir rolü olmamalıdır.

- Alarmlar oran ve biçim üzerinden verilir ve maliyet sinyalleri sonuç sinyalleriyle eşlenir; her alarmin sahibi ve ilk eylemi runbook'ta yaşar (Bölüm 23).
- Ucuz, ancak eval kalitenin tuttuğunu gösterdiğinde daha iyidir ve maliyeti insan queue'suna ya da yanlış cevaplara taşıyan bir tasarruf, tasarruf değil bir aktarımdır.

Maliyet anlaşılıp sınırlandığında geriye kalan soru, hiçbir limitin öngörmediği bir biçimde bir şeylerin ters gittiği günde ne yapılacağıdır. Bölüm 23 o günle ilgili: Parcelport, bir agent'ın neden olduğu ya da önleyemediği bir olayı nasıl tespit eder, sınırlar ve ondan nasıl öğrenir.

Bölüm 23 — Olay Müdahalesi

Parcelport'ta bir gece vardiyasını düşünelim, sabaha karşı üçü biraz geçiyor. Sipariş sayfalarında bir gecikme alert'i tetikleniyor ve on-call SRE Robin, ops agent'tan inceleme yapmasını istiyor. Agent metric'leri okuyor, bir trace çekiyor ve artıştan kısa süre önce başlamış en son deployment için `request_rollback` öneriyor. Onay isteği makul görünüyör, Robin onaylıyor ve `deploy-service` rollback'i başlatıyor. Yirmi dakika sonra gecikme yerinden kımıldamamış.

Robin tekrar metric'lere bakarken destek lideri Sam on-call kanalına yazıyor. Destek queue'su bu saat için olağandan fazla iade gösteriyor ve destek agent'ının gönderdiği iki cevap, müşterilerin istemediği iadelerden söz ediyor. Bunun ikinci bir sorun mu, rollback'in bir sonucu mu yoksa bir tesadüf mü olduğunu kimse bilmiyor. Her run'ın hangi prompt versiyonunu, gateway'in arkasındaki hangi modeli ve hangi tool sözleşmesini kullandığını da kimse bilmiyor ve cevabı verebilecek kişi uyuyor.

İki agent de hâlâ çalışıyor. İade queue'su büyümeye devam ediyor ve kimin neyi durdurmaya yetkili olduğu belli değil.

Bu bölüm kontrol zarfının **Kayıt** parçasına ait; bu parça şu soruyu cevaplar: işler ters gittiğinde ne yaparız? Kitapta daha önce anlatılan her şey kötü önerilerin oranını ve erişimini azaltır. Bu bölüm, kötü bir önerinin içeri sızmasından sonraki saatle ve o saat başlamadan önce nelerin var olması gerektiğiyle ilgili.

Sorun ve neden zor olduğu

Bu kitapta bir **olay**, bir agent'ın davranışının zarara yol açtığı ya da zarar tehdidi oluşturduğu ve müdahalenin organize edildiği bir durumdur. "Tehdit oluşturduğu" sözü bilerek seçildi. On dakikada bin iade önerisini

reddetmiş bir gate hiçbir zarara yol açmamıştır ve yine de öneriler bir boşluk bulmadan önce bir insanın bakması gereken bir şeydir. Yalnızca tamamlanmış zararı olay saymak, ilk olayın pahalı olan olması demektir.

Bir agent olayı klasik bir servis olayından üç bakımdan farklıdır ve her biri müdahalenin neye ihtiyaç duyduğunu değiştirir.

Birincisi **yeniden üretilemezlik**. Bir servisteki bug yeniden üretilir: isteği tekrar oynatıp hatayı görmek ve kodu düzeltmek mümkündür. Bir model aynı bağlam için farklı bir öneri döndürür, dolayısıyla bir run'ı modele karşı yeniden oynatmak pek bir şey kanıtlamaz. Deterministik parçalar tam olarak yeniden oynatılabilir, ama "tekrar çalıştır ve gör" bir soruşturma stratejisi değildir. Soruşturma kayıttan yola çıkmak zorundadır; bu da F8'i (gözlenmeyen davranış) diğer her sınıfı çözülemez kılan hata sınıfı yapar.


İkincisi **geniş bir etki yüzeyi**. Arızalı bir servis endpoint'i, o endpoint'in çağıranlarına dokunur. Arızalı bir agent versiyonu, arıza yürürlükteyken ele aldığı her müşteri ya da deployment için çağırmasına izin verilen her tool'a dokunur ve bu etkilerin her biri farklı bir downstream sistemden geçmiştir: `payments-service`, `shipping-service`, ticket sistemi, `deploy-service`. Etki listesi bunların hepsi üzerinden bir join'dir ve odadaki ilk soru "başka ne yaptı?" sorusudur; bu yalnızca etkiler kaydedilmişse cevaplanabilir (Bölüm 10, Bölüm 20).

Üçüncüsü **"model değişti" belirsizliği**. Davranış, bir prompt düzenlendiği, bir tool sözleşmesi değiştiği, bir politika güncellendiği, bir retrieval index'i yeniden kurulduğu ya da bir gateway takma adının arkasındaki model sağlayıcısı tarafından değiştirildiği veya güncellendiği için kayabilir. Span'lerdeki versiyon etiketleri her run'ın hangi kombinasyonu kullandığını söyleyene kadar (Bölüm 20), ekip hareket eden bir hedefi soruşturuyordur.

Hata sınıfları bir olayda belirli bir biçimde ortaya çıkar. F6 (sessiz kısmi hata) ve F7 (yetkisiz etki) bir olayı pahalı yapanlardır, F8 ise onu uzun yapan. Tespit çoğunlukla asıl sınıfla ilgisiz bir sınıf üzerinden gelir: kontrolden çıkan bir döngü (F5) olduğu ortaya çıkan bir maliyet alarmı (F9) ya da yukarı akıştaki bayat bağlam sorununa götüren, F3 (dayanaksız iddia) hakkındaki bir müşteri şikâyeti.

Bunların hiçbirisi bir prompt sorunu değildir. Agent'a "iade vermeyi bırak" diyen bir mesaj, varsayım gereği güvenilir olmayan bir bileşene yapılmış bir istektir ve en çok önem taşıdığı günde yanlış araçtır. Sınırlama, etki analizi ve telafi, önceden kurulmuş kontroller kullanılarak deterministik kodla ve insanlarla yapılır. Mühendislik sorusu şu: müdahalenin hızlı, dar ve geri alınabilir olması için olaydan önce neyin doğru olması gerekir?

Aşağıdaki sıra, bölümün geri kalanının izlediği biçimdir. Geriye giden oka bakılır: zarar sürerse sınırlamanın genişletilmesine izin verilir ve review kontroller üretene kadar hiçbir şey geri getirmeye doğru ilerlemez.



Tespit: üç tür sinyal

Bölüm 20 metric'leri ve alert'leri kurar. Olay müdahalesi için önemli olan, bir olayın kendini nasıl duyurduğudur, çünkü izlediği yol başlı başına bir bulgudur. Bölüm 3'teki olay kaydının bunun için bir alanı var,

detected_by, ve bu alanın alabileceği ikinci değer, "bir kişi bildirdi", bir tespit sinyalinin eksik olduğu anlamına gelir.

Üç yol çoğu durumu kapsar.

- **Agent seviyesi sinyaller.** Gate ret'leri, onay redleri, tekrarlanan aynı hatalar ya da aynı agent versiyonunun baseline'ına göre etki hacmi; Bölüm 13'teki breaker'ın harekete geçtiği sinyaller. Bir breaker'ın açılmasının olaya dönüşüp dönüşmediği bir insan kararıdır.
- **Mutabakat bulguları.** Bölüm 10'daki sweep, hiçbir run'ın fark etmediği boşlukları bulur; örneğin açık bir intent'le done işaretlenmiş bir run. Bunlar en kesin sinyallerdir ve geç gelirler, çünkü sweep bir takvime göre çalışır.
- **İnsanlar ve maliyet.** Bir müşteri yazar, Sam queue'da tuhaf bir örüntü görür, finans bir harcama satırı görür (Bölüm 22), Jordan gibi bir güvenlik reviewer'ı verilmiş yetkiyle eşleşmeyen bir etki fark eder. Bunlar en yavaş olanlardır ve açılış senaryosu onlarla başladı.

Bir sinyal, biri olay ilan ettiğinde olaya dönüşür ve ilan etmek ucuz olmalıdır. İlanı bir toplantı ve bir dokümanla ağır bir olay sayan bir ekip emin olana kadar bekler ve kesinlik zarardan sonra gelir. Runbook'a tek satırlık bir kural yazardım: nöbet çizelgesindeki herkes ilan edebilir, ilan etmenin cezası yoktur ve bir hiç çıkan ilan edilmiş olay kısa bir notla kapatılır ve tatbikat olarak sayılır.

İlan edilince ilk eylem, Bölüm 3'teki seviyeleri kullanarak bir **önem** atamaktır: bilgi, geri alınabilir, geri alınamaz, dış. Seviye gerçekte olan ya da mümkün olan etkiyi izler, dolayısıyla kime ne kadar hızlı alarm gönderileceğini belirler. Şüpheli bir yanlış iade ya da istenmeyen bir müşteri cevabı, aksi gösterilene kadar en az geri alınamaz ya da dış seviyesindedir ve müdahale o seviyeden başlar.

Sinyal	Genellikle işaret ettiği	İlk bakış
Baseline'ın üstünde iade hacmi	F2, F7, bazen F5	issue_refund etkileri, agent versiyonuna ve zaman penceresine göre
Ret oranında sıçrama	F1, F2, F4	Gate reason'ları, tool'a ve girdi kaynağına göre gruplanmış
Açık intent'lerle done işaretlenmiş run'lar	F6	Mutabakat bulguları ve intent kayıtları

Sinyal	Genellikle işaret ettiği	İlk bakış
Baseline'ın üstünde harcama oranı	F5, F9	Run başına step sayıları ve retry'lar, versiyona göre
Müşteri yanlış bir vaat bildiriyor	F3, bazen F5	Run, tool sonuçları ve cevaptaki iddia
Eşleşen verilmiş yetkisi olmayan etki	F7	Tool gateway'in verme log'u, etkiye karşı

Sınırlama: ihtiyaç duyulmadan önce kurulan merdiven

Sınırlama, zararı henüz anlamadan durdurur. Tasarım ilkesi Bölüm 13'tekiyle aynıdır: zararı durduran en dar kontrol kullanılır ve daha geniş bir kontrol hazırda tutulur. Yalnızca tüm agent'ı kapatabilen bir müdahale geç kullanılır, çünkü tüm agent'ı kapatmanın bekleyen müşteriler olarak bir bedeli vardır ve bu bedelden korkan bir ekip tereddüt eder.

Aşağıdaki merdiven örnek amaçlıdır. Her basamak olaydan önce var olan, sahibi olan bir kontroldür ve her biri bir flag ya da bir operasyondur, agent'ın prompt'unda bir değişiklik değil.

Basamak	Ne yapar	Neyi durdurur	Neye mal olur	Geri alma
Önceki versiyonu sabitle	Prompt'u, model takma adını, tool sözleşmelerini ve politikayı bilinen son versiyona döndürür	Bir değişikliğin getirdiği regresyon	Değişikliği kaybeder; sabitlenen versiyonun kendi bilinen sorunları olabilir	Sabitlemeyi ileri al
Bir tool'u devre dışı bırak	Tool gateway bir agent için bir tool'u reddeder	O tool'un etkisi	Onu gerektiren run'lar hand-off'a geçer	Kayıtlı bir reason ile yeniden etkinleştir
Kısıtlı mod	Okumalar ve taslaklar sürer; okumanın üstündeki her etki reddedilir ya da onay gerektirir	Tüm yeni etkiler	Verim düşer; işi insanlar üstlenir	Elle sıfırlama

Basamak	Ne yapar	Neyi durdurur	Neye mal olur	Geri alma
Yeni işi queue'ya al	Yeni ticket'lar ya da görevler başlamak yerine bekler	Yeni run'lar	Müşteriler bekler, dolayısıyla bir mesaj gerekir	Queue'yu serbest bırak
Credential'ları iptal et	Bir agent'ın elindeki grant'leri iptal eder (Bölüm 18)	Yetki taşıyan, yürüyen her şey	Yürüyen çağrılar başarısız olur; iptal yolunun denenmiş olmasını gerektirir	Yeni grant'ler ver
Durdur	Kill switch: yeni run yok; yürüyen run'lar bir sonraki step sınırında bekler	Agent'ın yaptığı her şey	Tüm iş yükü insanlara gider	Elle sıfırlama

Tabloyla ilgili iki nokta. Birincisi, basamaklar tırmanılması gereken bir yükseltme sırası değildir. Sinyal yanlış bir iade ise `issue_refund`'ı devre dışı bırakmak ilk harekettir ve destek agent'ı sipariş okumaya ve Sam'in göndermesi için cevap taslaklamaya devam edebilir. İkincisi, credential'ları iptal etmek farklı türden bir basamaktır: şüpheli bir sızıntıya ya da imkânsız olması gereken bir etkiye (F7) verilen cevaptır ve neden henüz bilinmediğinde bile önemlidir, çünkü hasarı mümkün kılan parça credential'lardır.

Mekanizmalar daha önce kuruldu: kill switch ve özellikleri Bölüm 13'te, iptal operasyonu Bölüm 18'de, onay yolu Bölüm 15'te. Bu bölümün katkısı, onların her agent için bir **runbook** olarak yazılmasıdır; ops agent'ın ve insanların ikisinin de arayabileceği dokümanlarda duran bir doküman. Bir runbook girdisi tetikleyiciyi, kontrolü, onu kimin çevirebileceğini, etkili olduğunun nasıl doğrulanacağını ve etkilenenlere ne söyleneceğini adlandırır. İşte örnek notasyonda bir girdi.

```

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

```

Bir kontrolü çeviren kodun, göstermeye değer küçük bir sıralama sorunu var, çünkü flag store, olay log'u ve sohbet kanalı ayrı sistemlerdir ve hiçbir transaction hepsini kapsamaz. Sıra şöyle: önce zarar durdurulur, ikinci olarak kaydedilir, üçüncü olarak bildirilir ve sonraki adımlardaki bir hata önceki adımları asla engellemez.

```

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"

```

Uyarı: Bir olay agent'ın prompt'u düzenlenerek sınırlanmaz ve ortalığı toplamak için run'lar, trace'ler ya da queue'daki onaylar silinmez. Bir prompt değişikliği güvenilir bir bileşene yapılmış bir istektir ve silinen kanıt, ne olduğunu söyleyebilme yeteneğini ortadan kaldırır; F8'in adlandırdığı hata budur ve bir review'un kurtaramayacağı hatadır.

Olaydaki agent ops agent ise pratik bir komplikasyon vardır: soruşturmak için kullanılacak tool, şüphe altındaki şeydir. İnsanlar log store'u, metrics store'u ve trace store'u doğrudan sorgular ve runbook bunların hangi sorgular olduğunu söyler, böylece kimsenin şüpheli agent'tan kendini açıklamasını istemesi gerekmez.

Etki analizi: kayıttan bir listeye

Zarar büyümeyi bıraktığında soru büyüklüğüdür. Cevap bir listedir: hangi run'lar etkilendi, her biri ne yaptı ve her etkinin şimdiki durumu nedir. Liste kayıttan gelir ve kalitesi Bölüm 20'nin trace kapsamının doğrudan bir ölçüsüdür.

Sorgunun üç parçası var: bir **kapsam** (hangi agent versiyonları, hangi pencere, hangi tool'lar), önemli olan etki üzerinde bir **filtre** ve gerçeği tutan downstream sisteme bir **join**. İade örneğinde kapsam, pencere boyunca yürürlükte olan destek agent'ının versiyonları, filtre `issue_refund` intent'leri ve sonuçları, join ise iadelerin tek yazarı olan `payments-service`'e. Kayıt run'ın ne yaptığına inandığını gösterir; servis gerçekte ne olduğunu gösterir. Olay ikisini ve aradaki farkı önemser.

```
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
```

`unknown` listesi önemli. Penceredeki bazı run'ların tam kaydı olmayabilir, çünkü bir span düşmüş ya da bir trace örneklemeyle dışarıda kalmış olabilir. Bu run'lar zarar görmüş ya da görmemiş diye sınıflandırılmaz ve etkilenen run sayısını onları sessizce dışarıda bırakarak veren bir sayım olayı olduğundan küçük gösterir. Liste kapsamını belirtmelidir: örneğin "40 run etkilendi, penceredeki 6 run'ın kullanılabilir kaydı yok"; sayılar burada varsayımsal, olayda gerçek.

Etkilenen her etki bir durum alır. Dördü yeter:

- **Zarar görmüş:** etki gerçekleşti ve yanlıştı (yanlış siparişe iade).
- **Açığa çıkmış:** etki ya da çıktı, ulaşmaması gereken bir şeye ulaştı, henüz doğrulanmış bir zarar yok (olmaması gereken bir alanı içeren bir cevap).
- **Amaçlanan:** etki gerçekleşti ve doğrudur. Bu run'lar listeye aittir, çünkü olay penceresi onları içeriyor ve onları kontrol etmeden listeden çıkarmak yanlış bir sınırın çizilme yoludur.
- **Bilinmeyen:** kayıt eksik ya da sahibi olan servis doğrulayamıyor.

Liste dışarıdan bir okuyucunun ihtiyaç duyduğu şeydir de. GDPR ya da KVKK gibi bir düzenlemeye tabi çalışan bir reviewer genellikle zaman penceresini, hangi veri sınıflarının dahil olduğunu ve kimlerin etkilendiğini görmek ister. Bunun bildirim açısından ne anlama geldiğinin yorumu hukuk ve uyum ekiplerine aittir; mühendisliğin katkısı, haftalar değil saatler içinde üretilen bir listedir.

Etkileri geri almak

Telafi etki sınıfını izler ve sözleşmeler neyin mümkün olduğunu zaten söyler, çünkü Bölüm 6 her geri alınabilir yazmanın geri almasını adlandırmasını şart koşar.

Etki sınıfı	Geri almanın neye benzediği	Kim yapar
okuma	Geri alınacak bir şey yok; okuma PII'yi açığa çıkardıysa açığa çıkma veri sahibi tarafından ele alınır (Bölüm 17)	Veri sahibi
geri alınabilir yazma	Sözleşmedeki telafi eylemi: kargo firmasına hand-off'tan önce adresi geri yükle, bir flag'i geri al, önceki versiyonu yeniden deploy et	Bir kişi ya da aynı tool, onayla birlikte gate üzerinden
geri alınamaz yazma	Parcelport'ta geri alma yok. Yanlış verilmiş bir iade, finans ve destek süreçlerinin ele alacağı, müşteriyle bir görüşmeyi de içerebilecek bir kayıptır	İnsanlar, mevcut süreçleri aracılığıyla
dış yan etki	Bir insanın yazıp review ettiği bir düzeltme; gönderilmiş bir mesaj geri çekilemez	Sam ya da bir vekil

Tablonun altındaki ilke, telafinin başlı başına bir etki olması ve olaya yol açan agent'ın onu yapmamasıdır. Bir telafi eylemi, her öneri gibi gate'ten geçer; kendi idempotency key'iyle ve politika gerektiriyorsa kendi onayıyla. Bir olayın ortasında güvenilir bir agent'ın bir döngüde elli düzeltme uygulamasına izin vermek cazip gelir. Buna direnmek gerekir, çünkü düzeltme, tool'un ilki gibi yanlış bir bağlamdan kurulan argümanlarla çağırılma ihtimalinin en yüksek olduğu andır.

Telafi izlenir, varsayılmaz. Etki listesindeki her etkilenen etki küçük bir durum kümesinden geçer:

```
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
```

Tutunulacak alan `confirmed_by`. Run'da uygulanan ve kaydedilen bir telafi, ilk etkiyle aynı biçimde bir iddiadır: sistemin ne denediğini söyler ve servis neyin doğru olduğunu söyler. Herhangi bir öge `planned` ya da `approved` olup `confirmed` olmadığı sürece olay açık kalır ve `not_possible`, kalan görüşme için adı konmuş bir sahiple birlikte geldiğinde meşru bir bitiş durumudur.

Olay başladığında `unknown` olan bir sonuç, örneğin zaman aşımına uğramış bir iade çağrısı, önce servisin durumu Bölüm 10'un anlattığı gibi okunarak çözülür. Gerçekleşmemiş bir etkiyi telafi etmek ikinci olayı yaratır.

Kök nedeni bulmak

Kök neden analizi, Bölüm 3'teki sınıflandırmayla aynı yapıdadır ve etki listesindeki kanıta uygulanır: hata sınıfı (run'da ne ters gitti), eksen (model, bağlam, tool ya da kontrol) ve önem (ne kadar uzağa ulaştı). "Model yanlış bir şey önerdi" bir kök neden değildir. Tetikleyicidir ve kök neden sorusu, yanlış önerinin neden önem taşıyabildiğidir.

Run modeli tekrar çağırarak yeniden üretilemediği için soruşturma **kaydedilmiş** malzemeyi yeniden oynatır. Üç yeniden oynatma var ve her biri farklı bir soruyu cevaplar.

1. **Bağlamı yeniden oynat.** Modelin gördüğü, kayıttan köken etiketleriyle yeniden derlenir. Bir şey eksik, bayat, etiketsiz ya da güvenilmemesi gereken bir kaynaktan mıydı? Bu bağlam eksenidir.
2. **Öneriyi gate'e karşı yeniden oynat.** Kaydedilmiş öneri, gate'ten bugünkü haliyle ve o zamanki haliyle geçirilir. Eski gate izin verdiyse ve şimdiki reddediyorsa düzeltme zaten içeride. İkisi de izin veriyorsa gate'te bir denetim eksiktir ve bu kontrol eksenidir.
3. **Versiyonları karşılaştır.** Başarısız run'lara benzeyen golden set vakaları alınıp değişiklikten önceki ve sonraki versiyonda çalıştırılır (Bölüm 21). Bir hatanın oranı yalnızca bir model değişikliğiyle kayıyorsa model ekseni dürüstçe işin içindedir ve müdahalenin iki parçası vardır: model değişikliği bekletilir ya da geri alınır ve regresyonu görünür kılacak kontrol eklenir.

Açılış senaryosuna dönelim ve review'un örnek biçimde şunu bulduğunu varsayalım. Ops agent run'ın başlarında deployment listesini okudu ve yalnızca zamanlamaya dayanarak ilişkilendirilmiş olan en son deployment'ın rollback'ini önerdi. Onay isteği, versiyonu ve release'ten önce ve sonra hesaplanan hata oranlarını gösterdi ve release'in başka neler içerdiğini hiç göstermedi. Robin, doğru ve eksik bir isteği onayladı. Sınıflar F2 (yanlış argümanlar: deployment yanlış hedefti) ve F5 (korelasyon run'ın başlarında okunan bağlamdan geldi), önem geri alınabilir ve eksenler sıralı olarak kontrol (istek deployment'ın içeriğini göstermedi ve gate'te hedefin belirtiyi açıkladığına dair bir denetim yoktu), sonra bağlam (liste yeniden okunmadı), model ekseni ise hiçbir kanıtla işin içinde değil. Sam'in gördüğü iadeler review'un ayrı bir satırıdır: destek agent'ının versiyonları ve aynı pencere üzerinde çalıştırılan etki sorgusu, onları zaman damgasıyla rollback'ten ayırır. Bu örnekte rollback'ten öncedirler; dolayısıyla kendi olay kaydı ve kendi sınıflandırması olan ikinci bir sorundur, rollback'in bir sonucu ya da bir tesadüf değil.

Bu bulgunun hiçbir yeri Robin'i suçlamaz ve hiçbir yeri modeli suçlamaz. Tasarım, eksik bir isteğin sabaha karşı üçte çalışan bir insana ulaşmasına izin verdi ve tasarım onayı vermeyi kolaylaştırdı. Eylem maddeleri bir kişiden değil, bu cümleden çıkar.

Suçlamasız review

Suçlamasız review, eyleme izin veren ya da onu görünmez kılan sisteme bakar. Haftanın sonunda değil birkaç gün içinde, ilgili kişiler ayrıntıları hatırlarken yapılır ve olaya müdahale etmemiş biri tarafından yürütülür; böylece sorular savunmaya dönüşmez. Güvenlik ekibinden Jordan soruları belirlemek için makul bir kişidir ve agent'ları işletmez.

Aşağıdaki şablon örnek amaçlıdır. Bölüm 3'ün `incident_record`'u onun çekirdeğidir. Ek alanlar, review'un bir ekibin kurabileceği şeylerle bitmesini zorlamak için vardır.

```
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
```

Üç kural review'u dürüst tutar.

- **Zaman çizelgesi kayıttan gelir.** Stres altındaki hafıza öngörülebilir biçimlerde yanlıştır. Kayıt bir zamanı sağlayamıyorsa bu boşluk Bölüm 20 hakkında bir bulgudur.
- **İnsanlar rol olarak geçer.** "On-call SRE onayladı" bir olgudur. "On-call SRE fark etmeliydi" bir kişi hakkında bir yargıdır ve yararlı sürüm "istek release'in başka neler içerdiğini göstermedi"dir.
- **Her eylem maddesi, denetimi olan bir kontroldür.** Uygulayacağım sınav şu: bu madde, modelin yanlış şeyi yine önerdiği gün tutar mıydı? "Daha dikkatli ol" bunu geçemez. "Rollback hedefinin bir metric penceresine karşı doğrulandığı bir ön koşul ekle" geçer.

Review'un ürünü bir doküman değildir. Bir değişiklikler kümesidir ve her bulgunun gidecek bir yeri vardır; şablonda bir **kind** olmasının nedeni budur.

Bulgu	Dönüştüğü şey	Sorumlu bölüm
Reddedilmesi gereken bir öneri	Tool sözleşmesinde yeni bir ön koşul	6
Hiçbir principal'ın neden olabilmemesi gereken bir etki	Daha dar bir izin ya da tavan	7
Onaylayana ihtiyaç duyduğunu vermeyen bir istek	Onayın gösterdiği şeyde bir değişiklik	15
Kayıtta kimsenin göremediği bir durum	Yeni bir metric ya da alarm	20
Sistemin bir dahaki sefere farklı ele alması gereken bir durum	Olayın versiyonunda başarısız olan bir eval vakası	21
Yavaş ya da eksik kalan bir müdahale adımı	Bir runbook değişikliği ve bir tatbikat	23

Eval vakası kendi taslağını hak ediyor, çünkü en sık atlanan madde odur ve olayın sessizce tekrarlanmasını durduran odur. Vaka, Bölüm 17'ye göre redact edilmiş kaydedilmiş bağlamdan kurulur; beklenen sonuç "reddeder" ya da "yükseltir" gibi bir davranış olarak belirtilir ve hata sınıfıyla etiketlenir.

```
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
```

Bir vaka, golden set'e yalnızca olayın yaşandığı versiyonda tekrarlar boyunca belirtilen bir orandan yüksek ya da eşit oranda başarısız olursa girer ve o oranın altında yeniden üretilmedi diye işaretlenir ve bırakılmak yerine bir kişiye gider.

Tam review, geri alınabilir seviyedeki ve üstündeki olaylar ve önemi ne olursa olsun tespit boşluğu olan her olay içindir; bilgi seviyesindeki bir ramak kala bir ticket'a ve bir eval vakasına dönüşür.

Olay sırasında ops agent

Ops agent, müdahale edenler için bariz bir asistandır. `search_docs` ile runbook'larda arama yapabilir, `query_logs`, `get_metrics` ve `get_trace` ile log'ları, metric'leri ve trace'leri okuyabilir, hataları gruplayabilir ve bir insanın düzenlemesi için bir zaman çizelgesi taslaklayabilir. Bunlar okuma tool'larıdır ve ilk saatte müdahale edenin ihtiyaç duyduğunun çoğudur.

Sınırlar yardımdan daha önemlidir. Bir olay sırasında şunlara bağlı kalırdım.

- **Yetkisi genişlemez.** Olay modu bir agent için break-glass değildir. `request_rollback` ve `toggle_feature_flag` onayın arkasında kalır, `run_diagnostic` sandbox'ının içinde kalır (Bölüm 19) ve durum acil diye agent ek credential almaz. Aciliyet, geniş bir grant'in istenip iptal edilmediği koşuldur.
- **Çıktısı bir öneridir.** Agent'ın neden hakkında öne sürdüğü bir hipotez doğrulanmamış bir iddiadır (bağlamı desteklemiyorsa F3). Müdahale eden onu store'lara karşı kontrol eder ve biri kontrol edene kadar zaman çizelgesine ya da review'a girmez.
- **Kök nedeni yazmaz.** Yukarıdaki üç yeniden oynatma için kanıtı bir araya getirebilir. Nedenlerin sıralanması ve özellikle model ekseninin işin içinde olup olmadığı, bir eval'e dayanan bir insan kararıdır.
- **İletişim kurmaz.** Müşterilere hiçbir şey göndermez ve olay kanalında bir otorite olarak paylaşım yapmaz.
- **Kullanımı bir karardır.** Olay ops agent'la ilgiliyse ya da davranışından şüphe varsa, müdahale edenler onu diğerleriyle birlikte kısıtlı moda alır ve doğrudan store'lardan çalışır.

En sıkı pratik düzenleme, olay lideri ilan ederken belirlediği kısa, örnek bir politikadır.

```
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
```

Bu hıza mal olur. Bir tanılama betiğinin hemen çalıştırılmasını sağlayabilecek bir müdahale eden, şimdi lidere soruyor. Bu bedeli kabul ediyorum, çünkü alternatif, etrafındaki insanların yorgun olduğu ve onayların hızlı verildiği bir zamanda normal tool kümesiyle bir agent'tır.

Olay sırasında iletişim

Bir olayın birkaç hedef kitlesi var ve her biri farklı türde bir mesaja ihtiyaç duyar. Müdahale edenler güncel durumu ve kimin ne yaptığını bilmek ister. Destek, müşterilere ne söyleyeceğini bilmek ister. Liderlik büyüklüğü ve bir sonraki güncelleme zamanını ister. Müşteriler, etkilenmişlerse, kendilerine ne olduğunun ve Parcelport'un bu konuda ne yaptığının sade bir ifadesini ister.

Roller sürtünmeyi azaltır. Bir **olay lideri** karar verir, bir **kayıt tutucu** zaman çizelgesini tutar ve bir **iletişimci** dışarıya yönelik mesajları yazar, böylece sorunu düzelterken kişi aynı zamanda status page'i de yazmaz. Küçük bir ekipte bir kişi iki rolü taşır ve yararlı kısıt, olayı sınırlayan kişinin aynı zamanda müşteri mesajını yazmamasıdır.

Dört alışkanlık yardımcı olur.

- **Bilinenler, bilinmeyenler ve bir sonraki güncellemenin ne zaman geleceği söylenir.** Art arda üç kez "araştırıyoruz" diyen bir güncelleme, kimsenin okumadığı bir status page'dir. "Destek agent'ı için iadeler devre dışı; 40 iade inceleniyor; bir sonraki güncelleme 30 dakika içinde" yararlıdır (sayılar varsayımsal).
- **Model değil sistem anlatılır.** "Yapay zekâ bir hata yaptı" diyen bir müşteri mesajı neyin etkilendiği ya da Parcelport'un ne yapacağı hakkında hiçbir şey söylemez ve yanlış bir konuşmaya davet eder.

"Otomatik bir adım talep edilmemiş iadeler verdi; her birini inceliyoruz" doğru ve özeldir.

- **Müşteri iletişimini insanlar yazar.** Müşterilere olay hakkında bir mesaj bir dış yan etkidir ve destek agent'ı onu taslaklamaz ya da göndermez. Bölüm 15 cevaplar için onay örüntüsünü kapsar; bir olayda riskler ilk kelimedenden itibaren bir kişiyi gerektirir.
- **Hukuki yorum sahiplerine bırakılır.** Bildirim soruları hukuk ve uyuma aittir ve mühendislik tarafı olguları sağlar: pencere, veri sınıfları, etkilenen kişi sayısı ve bilinmeyen sayısı.

Dahili bir güncellemenin sabit bir biçimi vardır, böylece kimsenin onu sabah dörtte tasarlaması gerekmez.

```
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
```

`not stopped` satırı yerini hak eden satırdır. Açılış senaryosunda "kim neyi durdurmaya yetkili" sorusunun cevabı, yalnızca önceki güncelleme zaten neyin durdurulduğunu söylemişse vardır.

Tatbikat ve runbook'un bakımı

Bir runbook, kullanılabilecek kadar bir hipotezdir. Bölüm 13'teki kill switch ve Bölüm 18'deki iptal yolu, tatbikatlarda olaylardakinden daha sık başarısız olur, çünkü eskimiş operatör listesi, eksik izin ve iddia ettiğini denetlemeyen probe tatbikatta ortaya çıkar.

Belirli bir takvimle, örneğin üç ayda bir, senaryosu yazılmış ve gerçek müşterisi olmayan kısa bir **game day** yürüttümdüm: bir staging agent'ı yanlış bir iade önerir, bir harcama alert'i tetiklenir, bir trace eksiktir. Sonucu belirleyen şeyler ölçülür: doğrulanmış bir sınırlamaya kadar geçen süre, etki listesinin kayıttan üretilip üretilmediği ve nöbet çizelgesindeki insanların hangi basamağı kullanacaklarını bilip bilmediği. Süreler kuruluşun kendi ölçümleri olarak yazılır ve başka bir kuruluştan hedef ödünç alınmaz, çünkü doğru sayı kuruluşun önem seviyelerine ve kadrosuna bağlıdır.

Runbook'lar belirli biçimlerde eskir: bir tool'un adı değişir, bir operatör çizelgeden ayrılır, bir flag başka bir store'a taşınır. Runbook'un adını andığı herhangi bir kontroldeki bir değişiklik, runbook'u kontrol etmek için başlı başına bir tetikleyicidir ve kontrolün sahibi güncellenmenin de sahibidir. Bir yıldır kimsenin açmadığı bir runbook bir dokümandır, bir kontrol değil.

Trade-off'lar ve maliyetler

Hazırlığın bedeli insanda ve dikkattedir. Agent'ları içeren bir on-call rotasyonunun öğreneceği daha çok şey vardır: basamaklar, flag'ler, store'lar ve "hangi bug" demeden önce "hangi versiyon" diye sorma alışkanlığı. Bir tatbikat, özellik işinin alamadığı saatleri alır. Bir runbook'un bakımı yapılmalıdır ve eskimiş olan, hiç olmamasından kötüdür, çünkü güven verir.

Sınırlama müşterilere mal olur. Kısıtlı mod ve queue'ya almak beklemek demektir ve bir agent'ı durdurmak onun işini kapasitesi olmayabilecek insanlara taşır. Bir ekip, daha geniş bir basamağa geçmeden önce ne kadar beklemeyi kabul edeceğine önceden karar vermelidir, böylece karar baskı altında, queue için en çok endişelenen kişi tarafından verilmez.

Kanıtın da bir maliyeti var. Run kayıtlarını bir olay için yeterince uzun tutmak, hassas veriyi daha uzun tutmak demektir; dolayısıyla saklama, erişim kontrolü ve redaction (Bölüm 17) soruşturmalar için, kısıtlı bir store ve bir erişim log'uyla tasarlanmalıdır.

Süreç bir gösteriye dönüşebilir. Eylem maddeleri hiç kurulmayan bir review, her seferinde aynı senaryoyu çalıştıran bir tatbikat ve her ret sıçraması için ilan edilen bir olay, ekibe dikkat etmeyi bırakmayı öğretir.

Tam mekanizmanın kullanılmayacağı durumlar: gerçek etkisi ve müşterisi olmayan bir prototip, bir nöbet çizelgesine değil, onu durdurmanın bir yoluna ve ne yaptığının bir kaydına ihtiyaç duyar. Çok küçük bir ekip lider, kayıt tutucu ve iletişimci rollerini birleştirebilir. Atlayamayacağı şeyler, agent dışında birinin çevirdiği durdurma anahtarı, kayıttan etki listesi ve bir review'u bir kontrolle bitirme alışkanlığıdır.

Sık yapılan hatalar

- **Kök neden olarak "model hatası" yazmak.** Cazip, çünkü tetikleyici için doğru ve toplantıyı bitiriyor. Aynı zamanda hiçbir eylem maddesi üretmez. Önerinin neden önem taşıyabildiği sorulur ve eksik olan kontrol adlandırılır.
- **Prompt'la sınırlamak.** Cazip, çünkü eldeki en hızlı düzenleme, ama güvenilir bir bileşene yapılmış bir istek ve versiyonu değiştiriyor, dolayısıyla kanıt artık iki davranışı kapsıyor. Bir flag, gate'te bir ret ya da bir iptal kullanılır.
- **Agent'ın kendi etkilerini geri almasına izin vermek.** Cazip, çünkü agent'ın run'ı ne yaptığının kaydını zaten tutuyor. Telafi, ilk hatayı üreten türden bir bağlamla yapılır. Telafi gate'ten ve bir kişiden, idempotency key'lerle geçirilir.
- **Yalnızca kaydın gösterdiğini saymak.** Cazip, çünkü kayıt eldeki tek sayım ve eksiksiz görünüyor. Bilinmeyen sayısı etkilenen sayısının yanında bildirilir ve boşluk bir bulgu sayılır.
- **Kimsenin çevirmediği bir kill switch.** Cazip, çünkü var olan bir anahtar çalışan bir anahtar gibi hissettirir. Anahtar var, flag store'una olay kanalının operatörleri erişemiyor ve runbook işten ayrılmış bir kişiyi listeliyor. Anahtarın tatbikatı yapılır ve probe flag'i değil gate'i denetler.
- **Kişileri ya da niyetleri adlandıran eylem maddeleri.** Cazipler, çünkü yazması hızlı ve kimse itiraz etmiyor. "Daha dikkatli ol" ve "ekibe hatırlat" test edilemez. Her madde bir kontrolü ve bir denetimi adlandırana kadar yeniden yazılır.
- **Eval vakası var olmadan servisi geri getirmek.** Yeniden etkinleştirme baskısı gerçek. Bilinen bir hata ve onu tespit eden bir vaka olmadan yeniden etkinleştirmek, bir sonraki oluşumun bunun bulunduğu yolla bulunması demektir.

Temel çıkarımlar

- Olay, bir agent'ın davranışının zarara yol açtığı ya da zarar tehdidi oluşturduğu ve müdahalenin organize edildiği bir durumdur; ilan etmek ucuz olmalıdır, çünkü kesinliği beklemek zararı beklemektir.

- Agent olayları servis olaylarından daha zordur, çünkü run'lar modeli tekrar çağırarak yeniden üretilemez, etkiler sistemlere yayılır ve davranış kimsenin listelemediği bir değişiklikte kaymış olabilir; bu yüzden soruşturma kayıttan çalışmak zorundadır.
- Sınırlama, önceden kurulan ve bir runbook'ta yazılan bir kontrol merdivenidir (versiyon sabitle, tool'u devre dışı bırak, kısıtlı mod, queue, iptal, durdur) ve kanıtı yok etmeden zararı durduran en dar basamağı kullanır.
- Etki analizi run kaydını etkilerin sahibi servislerle join eder, sınıflandıramadığını bilinmeyen olarak bildirir ve telafi, sahibi servis tarafından doğrulanana kadar izlenir; olaya yol açan agent tarafından değil, insanlar tarafından ya da gate üzerinden yapılır.
- "Model hata yaptı" tetikleyicidir, kök neden değil; review nedenleri model, bağlam, tool ve kontrol eksenlerinde sıralar, kaydedilmiş bağlamı ve öneriyi yeniden oynatır ve modele yalnızca bir eval'in desteklediğini atfeder.
- Suçlamasız bir review kontrollerle biter, her biri bir sahip ve bir denetimle; her bulgu bir eval vakasına, bir politikaya, bir sözleşme değişikliğine, bir alarm ya da bir runbook adımına dönüşür; olayın yaşandığı versiyonda belirtilen oranda başarısız olmayan bir eval vakası hiçbir şey kanıtlamaz.
- Bir olay sırasında ops agent okuma ve taslaklamada yardım eder, yetkisi genişlemez, hipotezleri bir kişi kontrol edene kadar doğrulanmamıştır ve iki agent de müşterilere yönelik iletişimi yazmaz.

Bir review bir olayı eval vakalarına dönüştürür ve bir eval suite'i ancak onu çalıştırma alışkanlığı kadar yararlıdır. Bölüm 24, tüm kitabın kontrollerini bir kontrol listesi ve bir olgunluk modelinde toplar; böylece bir ekip hangilerine sahip olduğunu, hangilerinin eksik olduğunu ve hangi olayı beklediğini görebilir.

Bölüm 24 — Bir Güvenilirlik Kontrol Listesi ve Kapanış Düşünceleri

Destek agent'ının Parcelport'ta ilk gerçek ticket'larını almasından önceki cumayı düşünelim. Alex'in "lansman hazırlığı" adında, altı hafta içinde kırk satıra ulaşmış, her satırı bir onay kutusuyla biten bir dokümanı var. Sam, destek ekibinin pazartesi günü agent'a güvenip güvenemeyeceğini bilmek istiyor. Jordan, dokümandaki hangi maddenin bir niyetten fazlası olduğunu soruyor. Robin ise cevap hayır çıkarsa on-call çizelgesinin nasıl görüneceğini öğrenmek istiyor.

Alex ilk satırı okuyor: "İade tavanı uygulanıyor." İşaretlenmiş. Kim işaretledi ve neye baktı? Biri bir konuşmayı hatırlıyor. Bir başkası gate'in önceki bir sürümünde var olan bir testi hatırlıyor. Üçüncüsü tavanın prompt'tan kaynaklandığını varsayıyor. Satır büyük olasılıkla doğru ve odadaki kimse bunu gösteremiyor.

Bu türden bir kontrol listesi bir güven kayıdıdır ve güven, bu kitabın Bölüm 2'den beri üzerine bir şey inşa etmeyi reddettiği büyüklüktür. Bu yüzden son bölümün sorusu pratik: Bir ekip, agent production'a dokunmadan önce hangi soruları sormalı, neyin cevap sayılacağına nasıl karar vermeli ve bu cevabın ne kadarı güvenin her aşamasında zorunlu olmalı?

Bu bölüm, kontrol zarfının altı parçasının hepsine birden bakıyor: Bağlam, Öneri, Gate, Etki, Sınır ve Kayıt. Yeni bir kontrol öğretmiyor. Her parça için neyin gösterilebiliyor olması gerektiğini soruyor.

Sorun ve neden zor olduğu

Hata, iddiaya dayanarak verilen bir lansman kararıdır. Zarfın tek bir parçasına ait değildir, çünkü ekibin kendisine uygulanan bir Kayıt hatasıdır: sistemde kontroller olabilir ama ekip bunu bilemez. F1'den F9'a her hata sınıfı bunun sonucu olabilir. En sık ürettiği sınıf, bir seviye

yukarıda F8'dir (gözlenmeyen davranış): ekip hangi kontrollerin var olduğunu söyleyemez, dolayısıyla hangi hataların kapsandığını da söyleyemez.

Bariz yaklaşım, sistemi en iyi bilen kişinin işaretlediği bir iyi uygulamalar listesidir. Üç nedenle başarısız olur.

Birincisi, bir işaret bir anı anlatır. Gate mart ayında kontrol edildi, tool sözleşmesi nisanda değişti, tavan mayısta koddan bir konfigürasyon dosyasına taşındı. Tarihsiz ve kanıtsız bir kontrol listesi, geçerli olan bir kontrolle geçerli olmuş bir kontrolü ayırt edemez.

İkincisi, kontrol listesi yanlış türden kanıtı çağırır. "Prompt, modele tavanı asla aşmamasını söylüyor" işaret gibi duyulan bir cevaptır. Oysa bir istektir ve prompt'un bir kontrol olmadığı kuralı tasarım için ne kadar geçerliyse lansman dokümanı için de o kadar geçerlidir. Her madde, model tersini önerdiğinde ayakta kalan deterministik şeyin adını vermelidir.

Üçüncüsü, hazır olmak tek bir eşik değildir. İç özetler hazırlayan bir agent ile para hareket ettiren bir agent aynı listeye ihtiyaç duymaz ve ikisine aynı davranmak, birincisi için bir tören, ikincisi için bir boşluk üretir.

Kontrol listesi, ekibin kendi iddiaları için küçük bir kontrol sistemidir: denetlenen şey güvenilir olmadığından denetim başka bir şey olmak zorundadır.

Kontrol zarfına göre gruplanmış kontrol listesi

Aşağıdaki her madde bir soru, o soruyu cevaplayan kanıt ve kontrolü kuran bölümden oluşur. Kanıt, açılacak bir artefakt demektir: kontrol kaldırıldığında başarısız olan bir sözleşme testi, kontrolün devreye girdiğini gösteren bir trace, bir tatbikat kaydı, sahibi olan bir dashboard paneli. "Bunu konuştuk" kanıt değildir.

Ek, bu listenin daha kısa bir halini taşır: aynı gruplar, aynı maddeler, aynı sırayla; her biri kanıtsız, bölümüyle birlikte bir soru olarak. Bu kısım gerekçeli sürümdür.

Bağlam

Tipik hata sınıfları: F4 (talimat ele geçirme), F5 (kontrolden çıkan döngü ya da bayat bağlam) ve F3 (dayanaksız iddia).

- **Köken.** Gerçek bir run için, bağlamdaki her ögenin nereden geldiği ve hangi güven seviyesinde olduğu gösterilebiliyor mu? Kanıt: bir run'ın kaynaklarıyla birlikte kaydedilmiş bağlamı. Bölüm 9.
- **Retrieval'ın bir tabanı var.** İyi cevabı olmayan bir sorgu, en yakın zayıf doküman yerine "iyi eşleşme yok" döndürüyor mu ve dokümanlar sürüm ile `as_of` tarihi taşıyor mu? Kanıt: cevabı olmayan bir sorgu ve sonucu. Bölüm 9.
- **Güvenilmeyen içerik işaretlenir ve işaret onunla birlikte gider.** Bir e-postadan ya da tool sonucundan gelen bir değer, bir tool argümanına kopyalandığında bile bir kontrol onu serbest bırakana kadar işaretini koruyor mu? Kanıt: işaretli içeriği hassas bir argümana yönlendirip ret bekleyen bir test. Bölüm 16.
- **MCP server'ları sahibi olan bir listedir.** Bir server allowlist'i ve sabitlenmiş tanımlara sahip bir tool allowlist'i var mı ve tanımı değişen bir tool, biri review edene kadar çağrılmaz hale geliyor mu? Kanıt: allowlist, sahibi ve tanımı değiştirilmiş bir test. Bölüm 8.
- **State kalıcıdır ve kaldığı yerden sürdürülebilir.** Herhangi bir step'te öldürülen bir run, bir etkiyi tekrarlamadan resume edebiliyor mu ve bir sweep, kayıtlı state'i dünyayla uyumayan run'ları buluyor mu? Kanıt: bir resume testi ve sweep'in çıktısı. Bölüm 10.
- **Belleğin bir yazma politikası var.** Her bellek yazımı, bir politikanın kabul ettiği ya da reddettiği, son kullanma tarihi olan bir öneri mi? Kanıt: politika ve reddedilmiş bir yazma. Bölüm 11.
- **PII, derlenmeden önce minimize edilir.** Tool'lar görevin ihtiyaç duyduğu alanları, kalanlar için yer tutucuları döndürüyor mu ve kayıt geride kalanı redact ediyor mu? Kanıt: bir tool sonucu örneği ve bir trace örneği; ikisi de incelenmiş. Bölüm 17.

Öneri

Tipik hata sınıfları: F1 (bozuk çıktı), F2 (yanlış tool ya da yanlış argümanlar) ve F3.

- **Her öneri, başka bir şey olmadan önce ayrıştırılır ve doğrulanır.** Geçersiz bir öneri etki yerine sayılan, sınırlı bir düzeltme yoluna mı gidiyor? Kanıt: geçersiz öneri testleri ve sayaç. Bölüm 5.
- **Karar envanteri var.** Bir ticket türü için, hangi kararları modelin, hangilerini kodun verdiği; tutarlar, limitler ve izinler kod tarafında olacak şekilde yazılı mı? Kanıt: envanter. Bölüm 4.
- **Güven (confidence), gate girdisi değildir.** Kontrol yolundaki herhangi bir şey modelin kendi kesinlik beyanını okuyor mu? Okuyorsa, onu hangi bağımsız sinyal destekliyor? Kanıt: gate girdilerinin bir review'u. Bölüm 2.
- **Model, prompt, tool ya da politika değişikliği bir deploy'dur.** Her biri, bir eval run'ı eklenmiş olarak kodla aynı pipeline'dan geçiyor mu? Kanıt: son üç değişiklik ve run'ları. Bölüm 2 ve 21.
- **Bir plan doğrulanır ve bir yetkilendirme değildir.** Orchestrator bir planı aynı sözleşmelere karşı denetliyor mu ve plandaki her step çalıştığında hâlâ gate'ten geçiyor mu? Kanıt: gate'in reddettiği bir step içeren bir plan. Bölüm 12.

Gate

Tipik hata sınıfları: F2, F4 ve F7 (yetkisiz etki).

- **Her tool'un bir sözleşmesi var.** Ad, açıklama, input schema, etki sınıfı, ön koşullar, idempotency, izinler, timeout'lar ve hata şekli; atlananlar gerekçelendirilmiş olarak. Kanıt: sözleşme dosyaları ve sözleşme testleri. Bölüm 6.
- **Tavan ve sahiplik kontrolleri gate'te çalışır.** `refund_ceiling`'i aşan bir iade ya da müşterinin olmayan bir sipariş için yapılan iade, modeli işin içine katmadan onaya ya da ret'e gidiyor mu? Kanıt: ikisini de öneren bir test. Bölüm 4, 6 ve 15.
- **Yetki devredilmiştir, dardır ve kısa ömürlüdür.** Agent, bir çağrıdan uzun yaşayan herhangi bir credential tutuyor mu? Bir ticket için yetki, o ticket'ın müşterisinin yetkisinin daraltılmış hali mi? Kanıt: credential düzenleyicinin log'u ve bir yetki review'u. Bölüm 7.
- **Onay, tam olarak o çağrıya bağlıdır.** Değişen bir argüman onayı geçersiz kılıyor mu ve bekledikten sonra yetki yeniden denetleniyor mu? Kanıt: onaydan sonra bir parametreyi düzenleyen bir test. Bölüm 15.

- **Onay bir gösteri değildir.** Onay oranı, karar verme süresi ve düzenlenen ya da reddedilen isteklerin payı gözden geçiriliyor mu ve bunlar yüzünden bir eşiği değiştiren oldu mu? Kanıt: review notları. Bölüm 15.

Etki

Tipik hata sınıfları: F6 (sessiz kısmi hata) ve F7.

- **Niyet, etkiden önce kaydedilir.** Süreç ikisinin arasında durursa, ne olmak üzere olduğuna dair bir iz var mı ve onu çözen bir şey var mı? Kanıt: niyet ile sonuç arasında bir crash testi. Bölüm 5 ve 10.
- **Bilinmeyen bir sonuç tekrarlayarak değil, sorarak çözülür.** `issue_refund` üzerinde bir timeout'tan sonra, sistem herhangi bir `retry`'dan önce durumu sorguluyor mu? Kanıt: timeout testi. Bölüm 6 ve 14.
- **Geri alınabilir her yazma, geri alma işleminin adını verir.** Telafi eylemi sözleşmede var mı ve biri onu çalıştırdı mı? Kanıt: sözleşme alanı ve yürütülmüş bir telafi. Bölüm 6.
- **Secret'lar agent'ın dışındadır.** Agent'ın okuduğu konfigürasyonda, bağlamda, checkpoint'lerde ya da trace'lerde hiç secret yok mu ve bir agent'ın dokunabildiği her şey iptal edilebiliyor mu? Kanıt: bir scrubber testi ve bir iptal tatbikatı. Bölüm 18.
- **Çalışan kod, test edilmiş bir sandbox'ta çalışır.** `run_diagnostic`, ağ, dosya sistemi ve credential'lar için conformance testlerini gerçek runtime üzerinde geçiyor mu? Kanıt: test çalıştırması. Bölüm 19.

Sınır

Tipik hata sınıfları: F5 ve F9 (maliyet ya da gecikme patlaması).

- **Bir run'ın yükseltmeyeceği limitleri vardır.** Step'ler, süre ve harcama; orchestrator tarafından uygulanan ve bir özetle hand-off'a geçen bir durdurmayla birlikte. Kanıt: hiç bitmeyen bir döngüyle bir test. Bölüm 12 ve 13.
- **Bütçe seviyeleri bir küme olarak sınırlıdır.** Bölüm 13'teki her seviyenin (run, subject, agent, tenant, global) bir limiti ve bir sahibi var mı, tükenen en dar seviye bağlayıcı mı ve model gateway'indeki global tavan, en kötü günde karşılanabilecek miktarın altında ya da

ona eşit mi? Kanıt: seviye başına konfigürasyon ve her run kendi limitinin içindeyken tenant seviyesini tüketen bir test. Bölüm 13 ve 22.

- **Retry'ların bir sahibi, bir sınıfı ve bir limiti vardır.** Tek bir katman retry yapar, her retry bütçeden harcar ve bir retry fırtınası bilerek tetiklenmiştir. Kanıt: hata testi. Bölüm 14.
- **Degraded mode tanımlıdır.** Model gateway'i kapalıyken ya da bir breaker açıkken agent, tool'suz cevap vermek ya da hand-off yapmak gibi belirtilmiş bir şey yapıyor mu ve bu denendi mi? Kanıt: tatbikat. Bölüm 13 ve 14.
- **Kill switch var, agent'ın dışında duruyor ve çevrilmiştir.** Adı belli operatörleri ve "her şey"den daha dar kapsamları var mı? Kanıt: son çevirme. Bölüm 13.
- **Maliyet atfedilir.** Bir ticket'ın ve bir soruşturmanın ne kadara mal olduğu trace'ten söylenebiliyor mu? Kanıt: panel. Bölüm 22.

Kayıt

Tipik hata sınıfı: F8 ve diğerlerinin hepsinin tespiti.

- **Bir run, bir trace'tir.** On-call, bir run'ı id ile açıp her model çağrısını, gate kararını, onayı ve etkiyi sırasıyla görebiliyor mu? Kanıt: onu kurmamış biri tarafından açılmış gerçek bir run. Bölüm 20.
- **İçerik bilerek saklanır.** Hangi prompt'ların ve çıktıların saklandığı, redact edildiği, örneklendiği ve bunları kimin okuyabileceği kararlaştırılmış mı? Kanıt: saklama politikası ve bir erişim denetimi. Bölüm 17 ve 20.
- **Agent'a özgü hatalar için alarmlar var.** Ret oranı, hand-off oranı, onay oranı, maliyet anomalileri ve hata sınıfı dağılımı; her alarm için bir sahiple. Kanıt: alarm tanımları ve birinin en son ne zaman tetiklendiği. Bölüm 20.
- **Her hata sınıfının bir tespiti ve bir sınırlaması vardır.** F1'den F9'a, bu agent'ın tespiti ve sınırlaması söylenebiliyor mu ve her boş hücre bilinen bir boşluk mu? Kanıt: bu agent için doldurulmuş Bölüm 3'teki tablo. Bölüm 3.
- **Bir golden set, değişiklikler için kapı görevi görür.** Prompt, model, tool ya da politikadaki bir değişiklik set'i çalıştırıyor mu ve bir

regresyon deploy'u engelliyor mu? Kanıt: engellenmiş bir değişiklik. Bölüm 21.

- **Prova edilmiş bir olay yolu var.** Bir sınırlama basamağı, kayıt üzerinde bir etki sorgusu ve suçlamasız bir review şablonu içeren bir runbook var mı ve ekip onu çalıştırdı mı? Kanıt: son tatbikat. Bölüm 23.
- **Bulgular kontrol olarak geri döner.** Son review yalnızca bir doküman değil, bir eval vakası, bir politika değişikliği ya da bir sözleşme değişikliği üretti mi? Kanıt: üç bağlantı. Bölüm 21 ve 23.

Cevapları güncel tutmak

Bir madde, yaşı olan bir iddiadır. Kontrol listesi doküman olarak olduğundan çok veri olarak yararlıdır, çünkü veri görünür biçimde bayatlayabilir. Aşağıdaki gösterim örnekleme amaçlıdır.

```
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
```

Önemli olan watched alanıdır. Durum, ondan ve kanıtın son çalıştırmasından hesaplanır; böylece değişen bir sözleşme, kimse bakmayı hatırlamadan maddeyi bayat hale getirir.

Olgunluk seviyeleri

Yukarıdaki liste tam kümedir. Bir ekibin ilk gün hepsine ihtiyacı yok ve bence hepsini denememeli, çünkü gerçek bir görev ortaya çıkmadan harcanan tüm kümenin maliyeti, hayali bir iş yüküne göre biçimlenmiş kontrollere gider. Dört seviye, kontrolleri riski izleyen bir sırayla eklemenin yolunu verir.



Geriye giden oklara bakılır. Seviye kalıcı bir not değildir. Yeni bir geri alınamaz tool, değişen bir sözleşme ya da bayatlamış bir kanıt, kanıt yenilenene kadar o yeteneği bir seviye aşağı indirir.

Seviye	Neleri yapmasına izin verilir	Girmeden önce asgari kontroller
Prototype	Test ya da kopyalanmış veriyi okumak ya da yalnızca bir etkinin hiçbir şeye mal olmadığı bir ortamda hareket etmek	Bir iterasyon limiti ve bir timeout; kaba da olsa her önerinin ve sonucun kaydı; agent'ın konfigürasyonunda sağlayıcı credential'ı ve geniş bir servis token'ı yok
Controlled pilot	Küçük bir dilim için gerçek görevleri ele almak, okumanın üzerindeki her etkinin önünde bir insanla	Her tool için bir sözleşme ve bir gate; çağrı başına credential'lar; politika gereği okumanın üzerinde zorunlu onay; run başına bir bütçe; kill switch; run başına bir trace; minimize edilmiş PII; gerçek vakalardan ilk bir golden set; adı belli bir sahip
Production	Onayın yalnızca politikanın istediği yerde olduğu tam iş yükünü ele almak	Güncel kanıtlı tam kontrol listesi: gate'te tavanlar ve sahiplik; çağrıya bağlı onay; yapıyla ele alınan injection; sandbox'lı yürütme; agent'ın dışında tutulan, rotation'ı ve iptali denenmiş secret'lar; alarmlar ve bir hedef; maliyet atfı; deploy gate'i olarak eval; prova edilmiş bir olay yolu
Scale	Daha fazla agent, tool, server, tenant ya da hacim	Bir tool ya da server eklemek için bir review süreci; golden set bakımı ve overfitting için bir kontrol; canary'li online değerlendirme; eval ile doğrulanan yönlendirme değişiklikleri; tool ve tenant başına kill switch kapsamları; onay yükü yönetimi; zamanlanmış yetki ve bellek review'ları

İki kural tabloyu dürüst tutar.

Seviye bir agent'a değil, bir yeteneğe aittir. Destek agent'ı `lookup_order` ve `search_docs` ile production'da olabilirken `issue_refund` hâlâ pilot aşamasında, Sam her iadeyi onaylıyor olabilir. Bu, okumaları geri tutmaktan daha iyi bir lansmandır ve pilotun onaylarının alışkanlığa dönüşmesine izin vermekten de daha iyi. Bir tool'un ne kadar kanıtı ihtiyaç duyduğuna etki sınıfı karar verir; bu, Bölüm 3'teki önem tablosuyla aynı ilkedir.

Bir seviyeye girmeye takvim değil, kanıt karar verir. "İki haftadır olay yok", şansa dair bir ifadedir. "Tavan testi, kill switch çevirme ve resume testi güncel", sisteme dair bir ifadedir.

Bölüm 1, sorunu çözen en az agency'yi önerdi ve kontrol listesi bunun karşılığını aldığı yerdir: tek bir çağrı ya da bir workflow, bir döngüden daha kısa bir listeye ihtiyaç duyar. Bir madde var olmayan bir şeyi soruyorsa, onu boş bırakmak yerine yanına "uygulanamaz, çünkü yazma tool'u yok" yazılır.

Parcelport, ilk durumdan hedef duruma

Bölüm 1'deki prototipte tek bir prompt, tek bir geniş token ve çıkışı olmayan bir döngü vardı; nihai cevabın ötesinde hiçbir kayıt yoktu. Parcelport'un hedef durumu, aynı iki agent ile zarfın her parçasına bir sahip veren çevreleyici bir sistemdir. Orchestrator döngüye, kayda ve her run'ın limitlerinin uygulanmasına sahiptir. Model gateway'i sağlayıcı credential'ını tutar, harcamayı ölçer ve global tavanı uygular. Gate karar verir ve bir çağrıya izin verdiğinde orchestrator etkiyi başlatır, tool gateway de o tek çağrı için bir credential iliştirir. Onay servisi, Sam'i ya da Robin'i tam olarak politikanın adını verdiği eylemlerin önüne koyar. Run store'u, trace pipeline'ı ve eval suite'i state'i, span'leri ve daha önce başarısız olan vakaları tutar.

Lansmandan aylar sonra sıradan bir pazartesi düşünelim. Bir müşteri e-postası, bir sonraki tool çağrısı için talimat gibi okunan bir metin içeriyor. Taint onunla birlikte kaldı, gate ondan türetilen iade önerisini reddetti ve run, Sam'e özetle birlikte bir hand-off ile bitti. Haftalık review'da vaka, F4 adıyla golden set'e girdi. O günün ilerleyen saatlerinde model sağlayıcı yavaşlıyor, breaker açılıyor ve destek agent'ı belirtilmiş degraded mode'una düşüyor. İki hikâyede de model, etkiye dönüşmemesi gereken ya da tamamlanamayan bir şey önerdi ve sistem doğru davrandı. Sıkıcı bir pazartesi, tasarımın satın aldığı şeydir.

Ne değişir, ne değişmez

Bu kitabın adını verdiği şeylerin çoğu hareket edecek: modeller ve davranışları, tool'lar ile bağlam için protokoller (MCP, hareketli bir spesifikasyondur; Bölüm 8'in rollere ve güven sınırına bağlı kalmasının nedeni budur), tracing standartları, framework'ler, grader'lar ve fiyatlar. Bu bölümlerdeki herhangi bir belirli tool bir örüntünün örneğidir ve saklanacak olan örüntüdür.

Kalan şey, değişmez ilke ve onun etrafındaki alışkanlıklardır. Modelin doğruluğu ne olursa olsun bir öneri güvenilmeyen girdidir, çünkü yanlış bir önerinin maliyetini gate'in neyi geçirdiği belirler ve gate ortalama günde değil, en kötü günde ölçülür. Para hareket ettiren, müşterilere ulaşan ya da onların verisine dokunan şeyler deterministik kontrolleri korur; onları gevşetmek, başka her değişiklik gibi bir değişikliktir ve golden set'e, ret oranına ve onay geçmişine dayanarak yapılır, geçen ay sakın geçti diye yapılmaz. Kanıt hafızadan uzun yaşar ve "göster bana" deme alışkanlığı, bu kitaptan en çok ayakta kalmasını istediğim kısımdır. Suçlamasızlık kalır, çünkü bir ekibin ramak kalan olayları bildirmesini sağlayan odur. Ve sürtünme kalır: her kontrolün birine bir bedeli vardır ve kitap, maliyetin sayılması gerektiğini söyleyebilir, ödemeye her zaman degeceğini değil.

Trade-off'lar ve maliyetler

Bir kontrol listesinin kendi bedeli vardır ve bunun ilk kısmı zamandır. Kanıt üretmek, zaten çalışıyor görünen kontroller için test yazmak, mühendisleri roadmap'ten alıkoyan tatbikatlar yapmak ve sahipleri maddelere bağlı tutmak demektir. Küçük bir ekip için production seviyesinde tam liste bir çeyreklik iş olabilir. Bu, onu yukarıdaki seviyelerle sıralamak için bir nedendir, atlamak için değil.

İkincisi yanlış bütünlüktür. Kontrol listesini geçmek, akla gelen kontrollerin güncel olduğunu söyler, listenin eksiksiz olduğunu değil; onu genişleten de Bölüm 23'teki review adımdır.

Yazıldığı gibi nerede kullanılmaz: keşif amaçlı bir notebook, tek seferlik bir betik ya da iç, salt okunur bir özetleyici için listenin çoğu geçerli değildir ve üç dört maddelik kısaltılmış bir sürüm yeterlidir. Ve tamamlanmış bir kontrol listesi kimseye güvenlik ya da uyum beyanı olarak sunulmaz. O bir mühendislik kayıdır. Bu türden bir rejimin ne istediğini yorumlamak hukuk ve uyum meslektaşlarına aittir ve onlar bu listenin içermediği şeyleri isteyebilir.

Uyarı: Maddeleri iddia üzerine işaretlenen bir kontrol listesi, hiç kontrol listesi olmamasından kötüdür, çünkü görünür boşluğu ortadan kaldırır. Para hareketi, müşteri verisinin ifşası ve bir run'ı yeniden kurabilme yeteneği için, işaretten önce kanıt istenir.

Sık yapılan hatalar

- **Listeyi bir sertifika gibi görmek.** Cazip, çünkü bir lansman evet ister. Çözüm, her maddeye bir tarih ve kanıt iliştiirmek ve lansman notunda listenin neyi kapsamadığını söylemektir.
- **Prompt ile cevap vermek.** "Sistem prompt'u bunu yasaklıyor" bir kontrol gibi hissettirir, çünkü metin açıktır. Model tersini önerdiğinde ayakta kalan kodun adı verilir ya da madde eksik olarak işaretlenir.
- **Kaydı sona bırakmak.** Trace ve eval süs gibi hissettirir. Onlar olmadan başka hiçbir madde gösterilemez; bu yüzden kayıt pilot seviyesinde, geri kalanından önce kurulur.
- **Sakin bir ayı kanıt saymak.** Cazip, çünkü sakın bir ay hak edilmiş gibi hissettirir, ama olay yok demek sinyal yok demek olabilir. Alarmların tetiklenebildiği ve tohumlanmış bir hatanın trace'te görüldüğü kontrol edilir.
- **Listenin sahibinin özel dokümanına dönüşmesine izin vermek.** Cazip, çünkü sistemi en iyi bir kişi biliyor. Adı belli bir sahibi ve bir sonraki review tarihi olmayan madde bir dilektir. Çözüm, madde başına bir sahip olması ve kanıtı Jordan'ın ya da ekip dışından başka bir reviewer'ın istemesidir.

Temel çıkarımlar

- Bir güvenilirlik kontrol listesi, her biri bir güvenceyle değil, açılabilen bir artefaktla (bir test, bir trace, bir tatbikat kaydı ya da bir dashboard) cevaplanan bir sorular kümesidir.
- Liste kontrol zarfına göre gruplanır; böylece her madde hizmet ettiği parçaya ve onu kuran bölüme işaret eder ve bir boşluk, belirsiz bir endişe değil, eksik bir parça olur.
- Her madde onu bayatlatan şeye, örneğin değişen bir sözleşmeye ya da politikaya bağlanır; böylece kanıt sessizce değil, görünür biçimde

yaşlanır.

- Prototype'tan controlled pilot'a, production'a ve scale'e kanıtla, yetenek başına geçilir; bir tool'un ne kadarına ihtiyaç duyduğuna etki sınıfı karar verir ve kanıt eskidiğinde bir seviyenin geri inmesine izin verilir.
- Sorunu çözen en az agency kullanılır, çünkü en az agency yönünde atılan her adım, gösterilmesi gereken listeyi kısaltır.
- Modellerin, protokollerin ve tool'ların değişmesi beklenir ve değişmez ilke korunur: model güvenilirmez bir karar vericidir ve sistemi güvenilir kılan, onu çevreleyen kontrol sistemidir.
- Bir kontrol listesi mühendislik kanıtını kaydeder, güvenlik ya da uyum beyanı değildir; bu yorum hukuk ve uyum meslektaşlarına aittir.

Kapanış düşüncesi

Kitap tek bir cümleyi savundu ve onu bir slogan olarak değil, bir tasarım kuralı olarak bir kez daha okumaya değer:

AI agent'lar, güvenilir kontrol sistemlerinin içinde çalışan güvenilirmez karar vericiler olarak tasarlanmalıdır.

İlk yarı, üzülmeyi gerektirmeyen bir varsayımdır. Onlarca yıldır güvenilirmez ağlar ve güvenilirmez diskler üzerine bir şeyler inşa ettik ve iş hep aynıydı: neyin başarısız olabileceğini açıkça söylemek, etrafına deterministik bir şey koymak ve ne olduğunu bilecek kadar kanıt tutmak. İkinci yarı, schema'lar, izinler, bütçeler, timeout'lar, queue'lar, log'lar ve testlerle sıradan mühendisliktir ve inşa etmek gereken kısımdır.

Bütün bunları yapan bir ekibin hiç olay yaşamayacağına söz vermezdim. Olaylarının sınırlı, görünür ve düzeltilebilir olacağını ve bir sonrakinin sistemi daha iyi yapacağını söyledim. Bu, güvenilirliğin bir modelin özelliği olduğu iddiasından daha mütevazı bir iddia ve arkasında durabileceğim olan da bu.

Ek

Bu ek, kitabın başvuru malzemesini tek bir yerde toplar: bir sözlük, iki kod sözcük dağarcığı (gate kararı reason'ları ve tool gateway hata kodları), örüntülerin hızlı başvurusu, boş bir tool sözleşmesi, hata taksonomisi tablosu, bir lansman öncesi kontrol listesi ve bir olayı review etmek için bir şablon. Yeni bir fikir eklemeyiz; her girdi onu kuran bölüme işaret eder ve bir girdiyle bölümü çelişirse bölüm geçerlidir, hata girdidedir. Her girdi, kitabın tezine —AI agent'lar, güvenilir kontrol sistemlerinin içinde çalışan güvenilir karar vericiler olarak tasarlanmalıdır— ve kontrol zarfının altı parçasına hizmet eder: Bağlam, Öneri, Gate, Etki, Sınır ve Kayıt.

Sözlük

Terimler alfabetik olarak listelenmiştir. Son sütun, terimi kuran bölümdür: tanımlandığı ve geliştirildiği yer. Tablodaki sayılar bölümlerdir.

Terim	Tanım	Bölüm
agent	Bir bileşen: bir model çağırır, önerilerini denetlemesi için bir gate'e sorar ve onaylanan etkileri tool'lar aracılığıyla uygulayan bir orchestrator döngüsü. Bir insan değil.	1
bağlam derleme	Orchestrator'ın, tek bir model çağırısı için bağlama nelerin gireceğini seçtiği, sıraladığı ve etiketlediği adım.	9
bağlam penceresi	Bir modelin tek bir çağırıda alabildiği malzeme miktarı. Kitap ona hiçbir zaman bir büyüklük vermez.	9
bellek	Run'lar arasında saklanan ve sonraki bağlamı biçimlendirebilecek bilgi. State bir run hakkındadır; bellek, run'dan sonraki dünya hakkındadır.	11
bütçe	Bir run'ın kullanabileceği bir kaynak üzerindeki limit: step'ler, tool çağrıları, token'lar, aktif süre, harcama ya da birikimli etki. Bir birimi, bir limiti, nerede ölçüldüğünü ve tükendiğinde ne olacağını adlandırır.	13
checkpoint	Bir run'ın kaldığı yerden sürdürülebileceği, kaydedilmiş bir nokta.	10

Terim	Tanım	Bölüm
circuit breaker	Başarısız olan bir bağımlılığa, retry yapmak yerine bir süre çağrışı durduran kontrol. Agent düzeyindeki bir breaker, agent'ın kendi oranlarını bir baseline'a karşı izler.	13
confused deputy	Daha az yetkili bir tarafın istediğini yapmak için kendi yetkisini kullanan bileşen. Geniş bir token'a sahip bir agent'ın F7'ye yol açmasının standart yolu.	7
dayandırma	Bir cevaptaki bir iddiayı bağlamdaki bir kaynağa bağlamak. Böyle bir bağı olmayan iddia, dayanaksız iddiadır (F3).	9
degraded mode	Bir sınır ya da breaker devreye girdiğinde sistemin içine girdiği, belirtilmiş, azaltılmış davranış (tool'suz cevap verir ya da yalnızca hand-off yapar).	14
determinizm sınırı	Her karar için çizilen, modelin neyi önerebileceği ile kodun neye karar vermesi gerektiği arasındaki çizgi.	4
devredilmiş yetki	Bir principal'ın bir başkası adına tuttuğu yetki; her zaman devredenin kendi yetkisinden dardır ve bir göreve bağlıdır.	7
döngü	Bir run'da bağlam, öneri, gate ve etkinin tekrarlanan çevrimi.	12
egress	Bir ortamdan çıkan trafik.	19
etki	Gate bir tool çağrısına izin verdikten sonra dünyada olan şey.	1
etki bütçesi	Etkilerin birikimli büyüklüğü üzerindeki bir bütçe, örneğin toplam iade edilen tutar. Çağrı başına bir tavan ile toplam arasındaki boşluğu kapatır.	13
etki sınıfı	Dört değerden biri: okuma, geri alınabilir yazma, geri alınamaz yazma, dış yan etki. Sınıf bir kontrol tabanı belirler; onaya sınıf değil, politika karar verir.	6
eval	Davranışın beklenen sonuçlara karşı tekrarlanabilir bir ölçümü. Ölçülen şey olasılıksal bir öneri olduğunda "test" yerine kullanılır.	21
fallback	Birincil yol başarısız olduğunda ya da kullanılmadığında kullanılan farklı bir yol. Fallback'ler, her basamağın birincil davranıştan ne kadarını koruduğuna göre bir merdiven olarak sıralanır.	14
gate	Bir öneri ile bir etki arasındaki deterministik kontrol; üç sonucu var: allow, refuse, needs approval. Pseudocode'da: "allow", "refuse", "needs_approval".	1, 4
golden set	Eval'ler için kullanılan, beklenen sonuçları olan sabit bir vaka koleksiyonu.	21
gözlem	Bir etkinin sonucu ya da bir retin nedeni; bir sonraki step için bağlama döndürülür.	1

Terim	Tanım	Bölüm
grader	Bir çıktının beklentileri karşılayıp karşılamadığına karar veren kod ya da süreç. Grader olarak kullanılan bir model, bir model grader'dır ve kendisi de değerlendirilir.	21
güven sınırı	Veri ya da yetkinin, kontrol edilmeyen bir kaynaktan geldiği bir çizgi.	8, 16
hand-off	Bir insanın devraldığı, bir reason kodu ve kayıttan oluşturulmuş bir özetle biten run. Her durdurma bir hand-off'tur.	12
hata sınıfı	Hata taksonomisindeki F1'den F9'a sınıflardan biri.	3
idempotency key	Bir tool'un tekrarlanan bir çağrısı tanıyıp iki kez hareket etmek yerine ilk sonucu döndürmesini sağlayan değer. Runtime tarafından yalnızca kendi atadığı tanımlayıcılardan türetilir; asla run ya da step tanımlayıcılarından ve asla modelin sağladığı bir alandan türetilmez.	6
izin	Bir principal'ın bir kaynak üzerinde bir eylem gerçekleştirebileceğine dair ifade.	7
karar hakları	Bir run'daki her karar için, modelin mi önerdiğini, kodun mu karar verdiğini yoksa bir insanın mı karar verdiğini söyleyen tablo.	1
kill switch	Agent düzeyindeki breaker'ın manuel ucu: yeni run yok, uçustaki run'lar bir sonraki step sınırında bekler. Agent'ın dışında tutulur.	13
kontrol zarfı	Bu kitabın altı parçalı modeli: Bağlam, Öneri, Gate, Etki, Sınır, Kayıt.	1
köken	Bir bağlam parçasının nereden geldiği.	9
lease	Hangi worker'ın bir run üzerinde sınırlı bir süre boyunca hareket edebileceğini söyleyen hak talebi. Run için eşzamanlılık kontrollerinin bir parçası.	10
manifest	Bağlam derleyicisinin yazdığı, modelin bir step'te ne gördüğünün ve nelerin dışarıda bırakıldığının kaydı.	9
model	Bağlamı öneriye çeviren bileşen.	2
niyet	Bir etkiden önce yazılan kayıt; böylece etki ile sonucu arasındaki bir crash yine de bir iz bırakır. Sonuç kaydıyla eşleştirilir.	5
olay	Bir agent'ın davranışının zarara yol açtığı ya da zarar tehdidi oluşturduğu ve müdahalenin organize edildiği durum. Suçlamasız olarak review edilir.	23

Terim	Tanım	Bölüm
onay	Tam olarak bir önerilen eyleme bağlı, kimin ne zaman karar verdiğiyle kaydedilen insan kararı. Tam terim "insan onayı"dır.	15
orchestrator	Döngüyü çalıştıran deterministik kod (agent runtime olarak da adlandırılır).	1
önem	Bir hatanın ne kadar uzağa ulaştığı: bilgi, geri alınabilir, geri alınamaz ya da dış. Tool'a değil, hatanın o somut örneğine aittir.	3
öneri	Modelin döndürdüğü her şey: bir tool çağrısı, bir plan, bir nihai cevap. Güvenilmeyen girdi olarak ele alınır.	1, 2
PII	Kişiye tanımlayabilen bilgi (personally identifiable information).	17
plan	Modelin önerdiği, niyet edilen step'lerin listesi. Bir öneridir, bir taahhüt değil; doğrulanmış bir plan hiçbir şeyi yetkilendirmez.	12
politika	Gate'in önerilen bir çağrıya karşı değerlendirdiği kural. Veri ya da kod olarak yazılır, asla bir prompt içinde düzyazı olarak değil.	7
principal	Kimlik doğrulayan ya da adına bir eylemin çalıştığı her şey: bir kişi, bir servis, bir agent.	7
prompt injection	Veri olan içeriğin talimat olarak ele alınması. Doğrudan: kullanıcının kendi girdisi talimatları geçersiz kılmaya çalışır. Dolaylı: içerik bir tool sonucu, bir doküman ya da bir e-posta yoluyla gelir. Sınıfı F4'tür.	16
reconciliation sweep	Ayrı sistemler arasındaki boşlukları görünür kılan, run store ve sahibi olan servisler üzerinde zamanlanmış bir job. Bir sahibi ve bir heartbeat'i vardır.	10
redaction	Bir değeri bir çıktıdan, log'dan ya da bağlamdan çıkarmak veya maskelemek.	17
restricted mode	Agent düzeyindeki breaker'ın ikinci basamağı: okumalar ve taslaklar sürer, okumanın üzerindeki her etki reddedilir ya da needs approval olur.	13
retrieval	Bağlama koymak için bir store'dan malzeme getirmek.	9
retry	Başarısız bir çağrıyı, sınıflandırılmış bir nedenle ve bir limitle tekrarlamak.	14
run	Bir agent'ın tek bir görev için, başlangıçtan bir nihai cevaba, bir hand-off'a ya da bir durdurmaya kadar tek bir yürütülmesi. Bir id'si ve bir durumu vardır.	1

Terim	Tanım	Bölüm
runbook	Her agent için tetikleyiciyi, kontrolü, kimin çevirebileceğini, etkili olduğunun nasıl doğrulanacağını ve etkilenenlere ne söyleneceğini adlandıran yazılı bir girdi.	23
sandbox	Kodun dosyalarda, ağda ve credential'larda neye ulaşabileceği üzerinde uygulanan limitleri olan bir yürütme ortamı.	19
secret	İfşa edilirse erişim sağlayan her değer. Asla bağlama konmaz.	18
span	Bir trace içindeki, zamanlanmış tek bir işlem.	20
state	Bir run hakkındaki olgular; orchestrator tarafından run store'da tutulur: step'ler, sonuçlar, durum.	10
step	Bir run içinde döngünün tek bir geçişi: bağlamı derle, öner, gate, belki bir etki uygula.	1
taint	Bir değerın güvenilmeyen bir kaynaktan geldiğini ve bir kontrol olmadan hassas bir eylemi yönlendirmemesi gerektiğini belirten işaret.	16
tool	Agent'ın bir sözleşmeyle talep edebileceği, adı olan bir yetenek.	1, 5
tool çağrısı	Bir tool'u argümanlarla kullanma önerisi. Yalnızca gate izin verdikten sonra bir etkiye dönüşür.	5
tool sözleşmesi	Bir tool'un yazılı, makine tarafından denetlenebilir tanımı: ad, açıklama, input schema, etki sınıfı, ön koşullar, idempotency, izinler, timeout'lar, hata şekli.	6
trace	Bir run'ın bileşenler arasındaki sıralı kaydı.	20
turn	Bir konuşmada agent ile bir insan arasındaki tek bir alışveriş. Bir run'ın birkaç turn'ü olabilir; bir turn'ün birkaç step'i olabilir.	1

Akılda tutmaya değer iki ayrım var. "needs approval" kararı, bir öneri bir insanı beklediğinde gate'in döndürdüğü şeydir; `approval_required` hata kodu ise bir çağrı geçerli bir onay olmadan bir tool'a ulaştığında tool gateway'in döndürdüğü şeydir ve sağlıklı bir run'da bu bir kusura işaret eder (Bölüm 6). Ve state bellek değildir: state tek bir run'a aittir, bellek ondan uzun yaşar (Bölüm 10 ve 11).

Gate kararı reason'ları

Bölüm 5'teki gate, sıra ve reason adları bakımından kanoniktir. Onun bir parçasını çizen her bölüm bu adları kullanır. Bir reason, "refuse" kararına eşlik eder; onay reason'ları "needs_approval" kararına eşlik eder. Liste kapalıdır ve burada olmayan bir reason, onu kullanan bölümdeki bir hatadır. Bölüm 12, planlı run'lar için iki kontrol ekler, görev kapsamı ve plan sınıfı; reason'ları tabloda. Bir istisna: Bölüm 12'nin plan doğrulayıcısı, çağrılarından hiçbiri önerilmeden önce bir planın tamamını reddeder ve reason'ları (malformed_plan, plan_too_long, plan_cycle, tool_not_allowed, write_without_evidence, too_many_writes), gate'inkinin parçası olmayan, ayrı bir kapalı listedir.

Reason	Karar	Bölüm 5'teki gate'te nerede durur	Retry edilebilir	Bölüm
unparseable	refuse	Parser: çıktı bir öneri değil	hayır	5
not_in_choice_set	refuse	Parser ve seçim kümesi: tool ya da tanımlayıcı bu run'a sunulmadı	hayır	4, 5
invalid_arguments	refuse	Schema kontrolü, gate'te ilk	hayır	5
ungrounded_arguments	refuse	Argüman bağlama: id'ler run'dan gelmeli	hayır	2
argument_origin	refuse	Hassas argümanlarda taint kontrolü	hayır	16
upstream_unavailable	refuse	Olgular okunamadı, dolayısıyla çağrı doğrulanamaz	evet	7
not_permitted	refuse	İzin, sahiplik ve politika retleri	hayır	7
outside_task_scope	refuse	Planlı run'lar: hedef, devirden daha dar olan run'ın görev kaydının dışında	hayır	12

Reason	Karar	Bölüm 5'teki gate'te nerede durur	Retry edilebilir	Bölüm
off_plan	refuse	Planlı run'lar: plan sınıflandırıcısı bekleyen hiçbir step ile eşleşmedi ve çağrı bir yazma ya da plan dışı payı aşan bir okuma	hayır	12
precondition_failed	refuse	Sözleşmenin bir ön koşulu başarısız oldu; başarısız olan field içinde adlandırılır	hayır	6
outcome_unknown	refuse	Daha önceki sonucu çözülmemiş bir yazma	durum bilinene kadar	6
ungrounded_claim	refuse	İddia kontrolü: hiçbir tool sonucu iddiayı desteklemiyor	hayır	2
mismatch	refuse	İddia kontrolü: iddia kaynağından farklı	hayır	2
omission	refuse	İddia kontrolü: gerekli bir parça eksik	hayır	2
tool_policy	needs_approval	Onay, son: politika bu tool için her zaman sorar	uygulanamaz	15
above_ceiling	needs_approval	Onay: tutar tavanın üzerinde	uygulanamaz	15
repeat_refund	needs_approval	Onay: aynı siparişte ikinci bir iade	uygulanamaz	15
unclassified_figure	needs_approval	Onay: iddia kontrolünün sınıflandıramadığı bir cevaptaki bir rakam	uygulanamaz	15

Reason	Karar	Bölüm 5'teki gate'te nerede durur	Retry edilebilir	Bölüm
run_locked	needs_approval	Onay, son: run üçüncü taraf içeriği okudu ve tool'un kuralı bir insan istiyor	uygulanamaz	16
run_locked	refuse	Son, ön koşullardan sonra: run üçüncü taraf içeriği okudu ve tool'un kuralı reddetmek	hayır	16

Tool gateway hata kodları

Bunlar, Bölüm 6'daki hata şeklinin kodlarıdır. Küme kapalıdır, sabit mesaj şablonlarıyla; "Raised by" sütunu her kodu kimin döndürdüğünü söyler: gate, tool, tool gateway ya da servis. Beş ad (`invalid_arguments`, `precondition_failed`, `not_permitted`, `upstream_unavailable`, `outcome_unknown`) her iki sözcük dağarcığında da geçer, çünkü gate ile tool tarafı aynı şeyi reddedebilir. İlk tabloda ad, bir refuse kararına eklenen reason'dır; bu tabloda ise modele döndürülen bir hatadaki koddur. İki sözcük dağarcığı ayrı kalır ve bir sayaç hangisini saydığını söylemelidir.

Kod	Raised by	Retry edilebilir	Bölüm
invalid_arguments	gate	hayır	6
precondition_failed	gate ya da tool	hayır	6
approval_required	tool gateway	hayır	6
not_permitted	gate ya da tool gateway	hayır	6
duplicate_replayed	tool	hayır	6
upstream_unavailable	tool ya da servisi	evet	6
outcome_unknown	gate ya da tool	durum bilinene kadar	6
result_invalid	tool gateway, dış server'lardaki tool'lar için	hayır	6, 8

Örüntü Hızlı Başvurusu

Tablo her örüntüyü bir sorun ve bir cevap olarak, ağırlıklı olarak ele aldığı hata sınıfları ve onu geliştiren bölümle birlikte listeler. Bir indeks olarak okunur. Bir örüntünün maliyetleri ve onun kullanılmaması gereken durumlar, bölümünün "Trade-offlar ve maliyetler" kısmındadır.

Örüntü	Ele aldığı sorun	Sınıflar	Bölüm
Orchestrator'ı, modeli ve gate'i ayır	"Model" bütün sistem anlamına geldiğinde adresi olmayan kontroller	hepsi	1
Karar hakları tablosu	Kimsenin sahip olmadığı kararlar	F2, F7	1
En az agency: tek çağrı, workflow, döngü, çoklu agent, bu sırayla	Sorunun ihtiyaç duyduğundan daha geniş bir yüzey	hepsi	1
Belirsizliğin türünü adlandır (biçim, içerik, niyet, ihmal)	Yanlış dedektörü seçmek	F1, F2, F3	2
Karar, deterministik sinyallerden verilir; asla beyan edilen güvenden değil	Model emin görüldüğü için izin verilen geri alınamaz bir etki	F2, F3	2
Bir deploy olarak model değişikliği	Sahibi ya da eval kanıtı olmadan hareket eden davranış	F2, F3	2
Üç soru: sınıf, kök neden ekseni, önem	Daireler çizen review'lar	hepsi	3
Her karar için kodun neye sahip olacağına karar verme (beş ölçüt)	Kodun hesaplayabileceği değerleri öneren bir model	F2, F7	4
Model önerir, kod karar verir	Denetlenmeden bir etkiye ulaşan öneri	F1, F2, F7	4
Seçim aralığını enum'larla ve tanımlayıcı listeleriyle daralt	Gate'in denetleyemediği serbest metin değerleri	F1, F2	4
Hesaplama koda aittir	Yanlış tutarlar, tarihler ve eşikler	F2, F7	4
Kodun okuduğu olgular üzerinde ön koşullar ve son koşullar	Schema'ya uyan ama duruma uymayan çağrılar	F2, F7	4
Katı ayırıştır ve doğrula, asla sessizce onarma	Kimsenin review etmediği tahmin edilmiş argümanlar	F1, F2	5
Step başına bir yazma, çağrı başına bir gözlem	Birkaç çağrı birlikte çalıştığında belirsiz sonuçlar	F6	5

Örüntü	Ele aldığı sorun	Sınıflar	Bölüm
Etkiden önce niyet, sonra sonuç, boşluklar için sweep	Run store ile bir servis arasında transaction yok	F6, F8	5, 10
Sabit sırada dokuz alanlı sözleşme	Çağrının şimdi olup olamayacağı hakkında hiçbir şey söylemeyen bir schema	F1, F2, F6, F7	6
Runtime'ın atadığı idempotency key	İki kez hareket eden, tekrarlanmış bir öneri	F6	6
Sabit mesajlı kapalı hata sözcük dağıtıcı	Veri sızdıran ya da modele yoklayacağı bir limit veren hatalar	F2, F6	6
Kesişim olarak etkin yetki	Devredeninin yapamayacağını yapan bir agent	F7	7
Çağrı başına, kısa ömürlü, dar credential'lar	Sızmış ya da geniş bir token	F7	7, 18
Modelin dışında politika motoru, varsayılan olarak reddet	Bir prompt'a dayanan yetki	F7	7
Host'a ait sözleşme, server ve tool allowlist'i, sabitlenmiş tanım	Sözleşme gibi davranan, server'ın sağladığı metin	F4, F7	8
Birikmeyen, derlenen bağlam; köken alanlarıyla	Bağlamda etiketsiz ve bayat malzeme	F4, F5	9
Sabitlenmiş çekirdekli bağlam bütçesi	Boyut baskısı altında düşürülen politika satırları	F5, F9	9
Alaka tabanı, sonuç olarak "iyi eşleşme yok"	Kanıt olarak sunulan zayıf bir isabet	F3	9
Kalıcı run store, bağlam olarak işlenmiş görünüm	Yalnızca konuşmada yaşayan state	F5, F6	10
Lease, sürüm kontrolü ve state'ten resume	Bir run üzerinde hareket eden iki worker; etkileri tekrarlayan bir resume	F5, F6	10
Öneri olarak bellek yazımı; kapsam ve son kullanma kod tarafından belirlenir	Sonraki her run'ı etkileyen kötü bir girdi	F3, F4	11
Öneri olarak plan, çalışmadan önce doğrulanır	Yetkilendirme olarak alınan bir plan	F2, F5	12
Başarı yüklemi, step limiti ve ilerleme tespiti	Hiç durmayan ya da görevden sapan run'lar	F5, F9	12

Örüntü	Ele aldığı sorun	Sınıflar	Bölüm
Etki bütçesi dahil katmanlı bütçeler	Her çağrı başı limitin altında harcama ya da birikimli etki	F7, F9	13
Bağımlılık breaker'ı ve agent düzeyinde breaker, kill switch ile	Başarısız bir bağımlılığı retry etmek; davranışı kaymış bir agent	F5, F9	13
Hatayı, herhangi bir şeyi tekrarlamadan önce sınıflandır	Sonucu bilinmeyen bir yazmayı retry etmek	F6, F9	14
Korunan davranışa göre sıralanmış fallback merdiveni	En kötü günde doğaçlama yollar	F9	14
Tam olarak bir çağrının hash'ine bağlı onay	Değişmiş bir çağrıyı kapsayan onay	F7	15
Kod tarafından işlenen onay ekranı	Eylemin model tarafından anlatılan halini onaylayan bir insan	F2, F7	15
Güvenilmeyen içerik, erişim ve kanaldan birini kes	Bir etkiye ulaşan injection	F4	16
Alan başına taint, en zayıf kaynak kazanır	Güvenilmeyen bir kaynaktan gelen hassas bir argüman	F4	16
Tool'suz okuyucu, daraltılmış çıktıyla aktör	Tool tutan bir step'i yönlendiren güvenilmeyen metin	F4	16
Alanları bir kez sınıflandır, tool'da minimize et, kalanlar için token	PII'nın olmaması gereken yerlerde bulunması	F3, F8	17
Yazma zamanında redaction, fail closed	Log'larda, trace'lerde ve eval set'lerinde kalıcılaşan PII ve secret'lar	F8	17
Modelin dışında enjekte edilen credential	Bağlama giren bir secret	F7	18
Tool sınırında scrubber, diff'lerde secret taraması	Dünyadan gelen secret'lar	F7	18
Kapalı ağı ve yalnızca bir çalışma izinli sandbox	Host'a ulaşan, model tarafından seçilmiş kod	F7	19
Güvenilmeyen girdi olarak ele alınan sandbox çıktısı	Talimat ya da secret taşıyan bir sonuç	F4	19
Trace olarak run, span olarak çağrılar, attribute'larla	Kullanılabilir hiçbir kanıt bırakmayan davranış	F8	20
Sonuca göre tutulan içerik, ayrı bir store'da	İçerik riski ile review için gereken kanıt	F8	20

Örüntü	Ele aldığı sorun	Sınıflar	Bölüm
Sahibi ve ilk eylemi olan agent'a özgü alarmlar	Kimsenin harekete geçmediği bir alarm	F8, F9	20
Eval seviyeleri, golden set ve grader'lar	Deterministikmiş gibi ölçülen olasılıksal davranış	F1'den F9'a	21
Prompt, model, tool, politika, sınır için deploy gate'i olarak eval	Görülmeden gönderilen regresyonlar	F2, F3	21
Ham kullanım olarak kaydedilen, rapor zamanında fiyatlanan maliyet	Kimsenin atfedemediği bir maliyet	F9	22
Yalnızca eval kalitenin korunduğunu gösterdiğinde daha ucuz	Maliyeti yanlış cevaplara ya da insan queue'suna kaydıran tasarruf	F9	22
Runbook olarak yazılmış sınırlama basamağı	Her şeyi ya da hiçbir şeyi kapatmak	hepsi	23
Kayıttan etki listesi, bilinmeyen sayısı dahil	Bir olayın neye dokunduğunu bilmemek	F6, F8	23
Kontrollerle biten suçlamasız review	Kök neden olarak "model bir hata yaptı"	hepsi	3, 23

Tool Sözleşmesi Şablonu

Aşağıdaki şablon kitabın gösterimini izler: sabit sırada dokuz alan, bir `text` bloğunda. Kopyalamak, doldurmak ve bir alanı yalnızca bir gerekçeyle birlikte `// not applicable` yazarak atlamak gerekir. Doldurulmuş bir sözleşmedeki sayılar, kendi verisi elde edilene kadar örnektir ve bunu bir yorumda söylemek gerekir. Bölüm 6, kanonik `issue_refund` sözleşmesini tam olarak geliştirir.

```

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]

```

Doldurma notları

- **name ve description.** Sözleşmeden üretilir, asla onun yanında yazılmaz. Bir açıklamadaki kural bir istektir; bu yüzden aynı kural bir ön koşul da olmalıdır (Bölüm 6).
- **input schema.** `additionalProperties: false` ile kapalı; runtime'ın zaten bildiği, kimlik gibi hiçbir alan yok ve alan başına en dar tür, aralık ya da enumerasyon (Bölüm 4 ve 5).
- **effect class.** Bir çağrıya değil, tool'a aittir; bazen okuyan bazen yazan bir tool bölünmelidir (Bölüm 6). Sınıf, aşağıdaki kontrol tabanını belirler ve onaya politika karar verir.

Etki sınıfı	Sözleşmedeki asgari kontroller
okuma	Input schema, izin kapsamı, timeout, bir çıktı limiti; yalnızca veriyi kimin görebileceğiyle ilgili bir ön koşul
geri alınabilir yazma	Yukarıdakiler, artı ön koşullar, bir idempotency key ve adı konmuş bir geri dönüş yolu
geri alınamaz yazma	Yukarıdakiler, artı bir bilinmeyen sonuç kuralı, bir durum geri okuması ve onay için bir politika

Etki sınıfı	Sözleşmedeki asgari kontroller
dış yan etki	Yukarıdakiler, artı idempotency, içerik kontrolleri ve kaydedilmiş bir niyet

- **preconditions**. Gate'in kayıt sistemlerinden bilinçli bir sırayla okuduğu olgular; sahibi olan servis aynı kuralları atomik olarak uygular (Bölüm 6).
- **idempotency**. Anahtarın her parçası runtime tarafından atanır; böylece başka argümanlarla tekrarlanan bir öneri ilk sonucu döndürür (Bölüm 6).
- **permissions**. Göreve bağlı bir kapsam; credential çağrı başına verilir ve agent tarafından asla tutulmaz (Bölüm 7 ve 18).
- **timeouts**. Bir yazmadaki timeout bir bilinmeyen sonuçtur: herhangi bir retry'dan önce state'in sahibi sorgulanır (Bölüm 14).
- **error shape**. Sabit şablonlu kapalı bir kod kümesi; dış bir server'dan gelen bir tool `result_invalid` ekler (Bölüm 6 ve 8).

Bir sözleşme sürümlemiş bir artefaktır: onu model gerektirmeyen bir gate testiyle göndermek ve sürümünü her çağrıda kaydetmek gerekir (Bölüm 6).

Hata Taksonomisi Tablosu

Sınıf adları ve id'ler kitap boyunca sabittir; Bölüm 3, F4.1, F4.2 olarak yazılan alt sınıflar ekleyebilir, ama asla yeni bir üst düzey id eklemeyiz. İlk tablo Bölüm 3'ten kompakt biçimdir; kontrolleri planlarken sütun sütun, bir olayı review ederken satır satır okunur. Boş hücresi olan bir satır, tasarımda bir boşluğa işaret eder.

Sınıf	Tespit	Önleme	Sınırlama	Bölümler
F1 Bozuk çıktı	Tool başına schema hata oranı	Dar schema'lar, kapalı enumerasyonlar	Sınırlı onarım, sonra hand-off	2, 5, 6
F2 Yanlış tool ya da yanlış argümanlar	Ön koşul hataları, örneklenmiş review	Run olgularından seç, sahiplik ön koşulları	Geri alınamaz çağrılar için onay	4, 5, 6

Sınıf	Tespit	Önleme	Sınırlama	Bölümler
F3 Dayanaksız iddia	Tool sonuçlarına karşı iddia kontrolü	Bağlamda gerekli olgular, kod tarafından doldurulan alanlar	Dış cevaptan önce insan review'u	2, 9, 21
F4 Talimat ele geçirme	Argümanlarda taint, anormal step'ler	Etiketli güvenilmeyen içerik, taint kuralları	En az yetki, onay	8, 9, 16
F5 Kontrolde çıkan döngü ya da bayat bağlam	Tekrarlanan çağrılar, olgu yaşı, sürüm uyumsuzluğu	İlerleme kontrolleri, köken, yeniden okuma	Sınırlar, sürüm ön koşulları	9, 10, 12, 13
F6 Sessiz kısmi hata	Niyetlerin ve sonuçların uzlaştırılması	Önce niyet, idempotency, bilinmeyen sonuç	Açık niyetlerle "done" yok	6, 10, 14
F7 Yetkisiz etki	Etkilerin verilen yetkiye karşı denetimi	Çağrı başına yetki, kodda tavanlar	Kısa ömürlü credential'lar, sandbox	7, 15, 18, 19
F8 Gözlenmeyen davranış	Etkilere karşı trace kapsamı	Tek bir trace şekli, etkiden önce niyet	Kayıt başarısız olduğunda etkileri durdur ya da bırak	17, 20, 21, 23
F9 Maliyet ya da gecikme patlaması	Maliyet ve gecikme dağılımları, retry sayıları	Bütçeler, bağlam bütçesi, sınıflandırılmış retry'lar	Circuit breaker'lar, degraded mode	13, 14, 22

Sonraki tablo her sınıfa anlamını ve ağırlıklı olarak ortaya çıktığı zarf parçasını verir.

Sınıf	Anlam	Zarf parçası
F1	Öneri ayrıştırılamıyor ya da beklenen yapıyla eşleşmiyor	Öneri
F2	İyi biçimlendirilmiş, ama yanlış tool ya da doğru tool ile uymayan değerler	Öneri, Gate
F3	Model, bağlamının desteklemediği bir şey söylüyor; Bölüm 3 bunun için yaygın terimi verir	Bağlam, Öneri
F4	Veri olan içerik, doğrudan ya da dolaylı olarak talimat gibi ele alındı	Bağlam, Gate

Sınıf	Anlam	Zarf parçası
F5	Run ilerleme olmadan sürüyor ya da artık doğru olmayan bağlama göre hareket ediyor	Bağlam, Sınır
F6	Çok adımlı bir etkinin bir kısmı gerçekleşti ve hiçbir şey bunu söylemiyor	Etki
F7	Bu principal'ın, bu anda neden olmaması gereken bir etki gerçekleşti	Gate, Etki
F8	Sistem bir şey yaptı ve kullanılabilir hiçbir kanıt bırakmadı	Kayıt
F9	Run doğru ama çok fazlaya mal oluyor ya da çok uzun sürüyor	Sınır

İki eksen daha bir sınıflandırmayı tamamlar: **kök neden ekseni** (model, bağlam, tool ya da kontrol; "model bir hata yaptı" tetikleyicidir, kök neden değil) ve gerçekleşen etkiyi izleyen **önem** (Bölüm 3).

Önem	Ne anlama gelir	Tipik tool'lar
Bilgi	Hiçbir şey değişmedi; yanlış bir cevap ya da boşa giden bir okuma	lookup_order, query_logs, search_docs
Geri alınabilir	State değişti ve bir telafi eylemi onu geri getirebilir	update_shipping_address, open_pull_request, toggle_feature_flag, request_rollback
Geri alınamaz	Parcelport onu geri alamaz	issue_refund
Dış	Parcelport'un kontrol etmediği bir kişiye ya da sisteme ulaştı	send_customer_reply

Bir hata ne kadar az geri alınabiliyorsa, o kadar erken ve o kadar deterministik biçimde durdurulmalıdır. Bir olay birden fazla etiket taşıdığına, onları öneriden etkiye doğru sıralamak gerekir (Bölüm 3).

Lansman Öncesi Kontrol Listesi

Bu, Bölüm 24'teki listenin kısa halidir: aynı altı grup, aynı maddeler, aynı sırada. Her satır bir sorudur ve ardından kontrolü kuran bölüm gelir. Her birini cevaplayan kanıt ve olgunluk seviyeleri Bölüm 24'tedir. Yalnızca

"prompt öyle diyor" diye cevaplanabilen bir satır henüz bir kontrol değildir.

Bağlam

- ☐ Gerçek bir run için, bağlamdaki her ögenin nereden geldiğini ve hangi güven seviyesinde olduğu gösterilebiliyor mu? (Bölüm 9)
- ☐ İyi cevabı olmayan bir sorgu "iyi eşleşme yok" döndürüyor mu ve dokümanlar sürüm ile `as_of` tarihi taşıyor mu? (Bölüm 9)
- ☐ Güvenilmeyen içerik, bir tool argümanına kopyalandığında bile bir kontrol onu serbest bırakana kadar işaretini koruyor mu? (Bölüm 16)
- ☐ MCP server'ları ve tool'ları sahibi olan, sabitlenmiş bir allowlist'te mi ve değişen tanımlar review edilene kadar engelleniyor mu? (Bölüm 8)
- ☐ Öldürülmüş bir run, bir etkiyi tekrarlamadan resume edebiliyor mu ve bir sweep, dünyayla uyuşmayan state'i buluyor mu? (Bölüm 10)
- ☐ Her bellek yazımı, bir politikanın kabul ettiği ya da reddettiği, son kullanma tarihi olan bir öneri mi? (Bölüm 11)
- ☐ Tool'lar yalnızca görevin ihtiyaç duyduğu alanları döndürüyor mu ve kayıt geride kalanı redact ediyor mu? (Bölüm 17)

Öneri

- ☐ Her öneri ayrıştırılıp doğrulanıyor mu ve geçersiz olan etki yerine sayılan, sınırlı bir düzeltme yoluna mı gidiyor? (Bölüm 5)
- ☐ Hangi kararları modelin, hangilerini kodun verdiği; tutarlar, limitler ve izinler kod tarafında olacak şekilde yazılı mı? (Bölüm 4)
- ☐ Kontrol yolundaki herhangi bir şey modelin kendi kesinlik beyanını okuyor mu ve okuyorsa, onu hangi bağımsız sinyal destekliyor? (Bölüm 2)
- ☐ Model, prompt, tool ya da politikadaki her değişiklik, bir eval run'ı eklenmiş olarak kodun pipeline'ından geçiyor mu? (Bölüm 2 ve 21)
- ☐ Bir plan aynı sözleşmelere karşı doğrulanıyor mu ve plandaki her step çalıştığında gate'ten yeniden geçiyor mu? (Bölüm 12)

Gate

- ☐ Her tool'un; ad, açıklama, input schema, etki sınıfı, ön koşullar, idempotency, izinler, timeout'lar ve hata şekli içeren, atlananları gerekçelendirilmiş bir sözleşmesi var mı? (Bölüm 6)
- ☐ `refund_ceiling`'i aşan bir iade ya da müşterinin olmayan bir sipariş için yapılan iade, modeli işin içine katmadan onaya ya da ret'e gidiyor mu? (Bölüm 4, 6 ve 15)
- ☐ Yetki devredilmiş, dar ve kısa ömürlü mü ve agent'ta bir çağrıdan uzun yaşayan hiçbir credential yok mu? (Bölüm 7)
- ☐ Değişen bir argüman onayı geçersiz kılıyor mu ve bekledikten sonra yetki yeniden denetleniyor mu? (Bölüm 15)
- ☐ Onay oranı, karar süresi ile ret ve düzenleme oranı gözden geçiriliyor mu ve bunlar bir eşiği değiştirdi mi? (Bölüm 15)

Etki

- ☐ Niyet etkiden önce kaydediliyor mu ve ikisinin arasında duran bir run'ı çözen bir şey var mı? (Bölüm 5 ve 10)
- ☐ `issue_refund` üzerinde bir timeout'tan sonra, sistem herhangi bir retry'dan önce durumu sorguluyor mu? (Bölüm 6 ve 14)
- ☐ Geri alınabilir her yazma, telafi eylemini sözleşmede adlandırıyor mu ve biri çalıştırıldı mı? (Bölüm 6)
- ☐ Konfigürasyonda, bağlamda, checkpoint'lerde ya da trace'lerde hiç secret yok mu ve bir agent'ın dokunabildiği her şey iptal edilebiliyor mu? (Bölüm 18)
- ☐ `run_diagnostic`, ağ, dosya sistemi ve credential'lar için conformance testlerini gerçek runtime üzerinde geçiyor mu? (Bölüm 19)

Sınır

- ☐ Step'lerin, sürenin ve harcamanın run'ın yükseltmeyeceği limitleri var mı ve bir özetle hand-off'a geçen bir durdurma var mı? (Bölüm 12 ve 13)
- ☐ Her bütçe seviyesinin bir limiti ve bir sahibi var mı ve en kötü günde karşılanabilecek bir global tavanın altında mı? (Bölüm 13 ve 22)
- ☐ Tam olarak bir katman retry yapıyor, bütçeden harcıyor mu ve bir retry fırtınası tetiklendi mi? (Bölüm 14)

- ☐ Degraded mode tanımlı mı ve denendi mi? (Bölüm 13 ve 14)
- ☐ Kill switch agent'ın dışında duruyor, adı belli operatörleri ve "her şey"den daha dar kapsamları var mı ve çevrildi mi? (Bölüm 13)
- ☐ Bir ticket'ın ve bir soruşturmanın ne kadara mal olduğu trace'ten söylenebiliyor mu? (Bölüm 22)

Kayıt

- ☐ On-call, bir run'ı id ile açıp her model çağrısını, gate kararını, onayı ve etkiyi sırasıyla görebiliyor mu? (Bölüm 20)
- ☐ Hangi prompt'ların ve çıktıların saklandığı, redact edildiği ve örneklendiği ve bunları kimin okuyabileceği kararlaştırılmış mı? (Bölüm 17 ve 20)
- ☐ Ret oranı, hand-off oranı, onay oranı, maliyet anomalileri ve hata sınıfı dağılımı için alarmlar var mı ve her birinin bir sahibi var mı? (Bölüm 20)
- ☐ F1'den F9'a, bu agent'ın tespiti ve sınırlaması söylenebiliyor mu? (Bölüm 3)
- ☐ Prompt, model, tool ya da politikadaki bir değişiklik golden set'i çalıştırıyor mu ve bir regresyon deploy'u engelliyor mu? (Bölüm 21)
- ☐ Bir sınırlama basamağı, bir etki sorgusu ve suçlamasız bir review şablonu içeren, prova edilmiş bir runbook var mı? (Bölüm 23)
- ☐ Son review yalnızca bir doküman değil, bir eval vakası, bir politika değişikliği ya da bir sözleşme değişikliği üretti mi? (Bölüm 21 ve 23)

Agent Olay Review Şablonu

Bir review, eyleme izin veren ya da onu görünmez kılan sisteme bakar. Olaydan birkaç gün içinde, ona müdahale etmemiş biri yönetiminde, aşağıdaki şablon kullanılarak yürütülür. Bölüm 23 her alanı açıklar. Review, geri alınabilir seviyedeki ve üzerindeki olaylar ile önemi ne olursa olsun bir tespit boşluğu olan her olay için geçerlidir; bilgi seviyesindeki bir ramak kala, bir ticket'a ve bir eval vakasına dönüşür.

```

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

```

Bölüm 3, bu şablonun çekirdeğindeki kaydı, `incident_record`'u, `id`, `run_ids`, `classes`, `root_cause`, `severity`, `detected_by`, `missing_control`, `owner_team` ve `action_items` alanlarıyla tanımlar. Şablon, kaydın her alanını taşır; yalnızca kaydın kendisinin sağladığı `id` ve `run_ids` hariç; `summary`, `timeline`, `impact`, `what_held` ve `response_notes` review'un eklediği şeylerdir. `severity` ve `owner_team`'i tutmak, yukarıdaki kapsam kuralının kayıttan uygulanmasını ve bir bulgunun, geri döndüğü kontrolün sahibi olan ekibe kadar izlenmesini sağlar.

Kurallar Bölüm 23'ünkilerdir: zaman çizelgesi kayıttan gelir, insanlar rol olarak görünür, her eylem maddesi bir kontroldür ve bir denetimi vardır ve "model bir hata yaptı" tetikleyicidir, kök neden değil (Bölüm 20, 21 ve 23).

Bir bulgu nereye gider

Bulgu	Şuna dönüşür	Bölüm
Reddedilmesi gereken bir öneri	Tool sözleşmesinde yeni bir ön koşul	6
Hiçbir principal'ın neden olamaması gereken bir etki	Daha dar bir izin ya da tavan	7
Onaylayana ihtiyaç duyduğunu vermeyen bir istek	Onayın gösterdiği şeyde bir değişiklik	15
Kayıtta kimsenin görmediği bir durum	Yeni bir metric ya da alarm	20

Bulgu	Şuna dönüşür	Bölüm
Sistemin bir dahaki sefer farklı ele alması gereken bir durum	Olayın sürümünde başarısız olan bir eval vakası	21
Yavaş ya da eksik bir müdahale adımı	Bir runbook değişikliği ve bir tatbikat	23

Eval vakası olmadan biten bir review bitmemiştir. Vaka, kayıtlı bağlamdan, saklanmadan önce redact edilerek oluşturulur (Bölüm 17); beklenen sonuç "reddeder" ya da "yükseltir" gibi bir davranış olarak ifade edilir ve hata sınıfıyla etiketlenir. Golden set'e yalnızca, olayı yaşayan sürümde tekrarlar boyunca belirtilen bir oranda ya da üzerinde başarısız olursa girer. O oranın altında, yeniden üretilemedi olarak işaretlenir ve bir insana gider; asla bırakılmaz.

KİTAP HAKKINDA

AI agent'lar, güvenilir kontrol sistemlerinin içinde çalışan güvenilir karar vericiler olarak tasarlanmalıdır.

Model bir otorite değil, bir öneri üreticisidir. Bir agent'ı çalıştırmayı güvenli kılan şey etrafındaki kontrol sistemidir: ona verilen bağlam, her önerinin geçmesi gereken kapı, yol açmasına izin verilen etkiler, ne kadar ileri gidebileceğinin sınırları ve yaptıklarının kaydı. Kitap Parcelport üzerinden bu kontrol zarfını (Context, Proposal, Gate, Effect, Bound, Record) sıradan mühendislikle kurar: tool sözleşmeleri, yetkiler, bütçeler, insan onayı, sandboxing, tracing, evaluation ve incident response.

YAZAR HAKKINDA

Muhammet Şafak 2008'den bu yana yazılım geliştiriyor. Uzun yıllar boyunca sağlık, finans ve telekomünikasyon domainlerinde aktif görev aldı. Teknolojiye değil, probleme odaklanarak geliştirme yapılması gerektiğini savunuyor. 2024'ten bu yana yüksek trafikli sistemleri uçtan uca ölçeklenebilir biçimde tasarlayıp geliştiriyor.

Küçük ve orta ölçekli yazılım geliştirme ekiplerine mentorluk yapıyor. Açık kaynak projeler yürütüyor. Kararlarını gerekçesi ve bedeliyle yazıyor.

Güvenilir sistemler güvenilir parçalardan kurulmaz. Bozulan parçaların etrafına kurulur.

I
ERİŞİM

II
EVENT'LER

III
AGENT'LAR

