

مهندسی عامل‌های هوشمند

Intelligent Agents Engineering: AgentOps

THE NEXT EVOLUTION OF DEVOPS AND MLOPS

تکامل بعدی دواپس و امال‌آپس

چارچوبی مهندسی برای طراحی، استقرار،
ارزیابی و کنترل عامل‌های هوش مصنوعی

محمد تفکری عبد

مهندس نرم‌افزار | مهندسی هوش مصنوعی و سیستم‌ها

مهندسی عامل‌های هوشمند

Intelligent Agents Engineering: AgentOps

تکامل بعدی دواپس و ام‌ال‌آپس

چارچوبی مهندسی برای طراحی، استقرار، ارزیابی و کنترل عامل‌های هوش مصنوعی

محمد تفکری عبد

انتشارات مهدی

عنوان کتاب: مهندسی عامل‌های هوشمند

عنوان انگلیسی: Intelligent Agents Engineering: AgentOps

نویسنده: محمد تفکری عبد

ناشر: مهدی

شابک: ۹۷۸-۶۲۲-۰۰۰-۱۲۳-۲

شماره‌ی فیفا: در انتظار دریافت از سازمان اسناد و کتابخانه ملی ایران

نوبت و سال چاپ: چاپ اول، ۱۴۰۵

شمارگان: ۵۰ نسخه

قیمت پشت جلد: ۶۹۸,۰۰۰ تومان

قطع کتاب: رقعی، ۱۴/۸ × ۲۱ سانتی‌متر

تعداد صفحات: ۲۷۱

رده‌بندی موضوعی پیشنهادی: مهندسی نرم‌افزار؛ هوش مصنوعی؛ عامل‌های هوشمند؛ عملیات و مهندسی سامانه‌های عامل محور (AgentOps)

حقوق نشر و مجوز استفاده از متن و کد: مطابق قرارداد نویسنده و ناشر و مجوزهای مربوط به منابع و کتابخانه‌های استفاده‌شده.

کد مرجع کتاب: agentops-book

نسخه‌ی پایتون مرجع: Python ۳.۱۲، با استفاده از کتابخانه‌های استاندارد پایتون در مثال‌های اجرایی.

زبان کتاب: فارسی، همراه با اصطلاحات تخصصی انگلیسی.

فهرست مطالب

فهرست مطالب.....	۵
فهرست شکل‌ها.....	۱۳
فهرست جدول‌ها.....	۱۴
فهرست اختصارات.....	۱۶
پیشگفتار.....	۱۸
مقدمه.....	۲۰
راهنمای استفاده از کتاب.....	۲۲
بخش اول: مبانی و تغییر پارادایم.....	۲۴
فصل ۱. از DevOps و MLOps تا مهندسی عامل‌های هوشمند.....	۲۵
۱.۱ تحول مهندسی نرم‌افزار در عصر هوش مصنوعی.....	۲۶
۱.۲ پیدایش DevOps و اصول بنیادین آن.....	۲۸
۱.۳ شکل‌گیری MLOps و چرخه عمر مدل‌های یادگیری ماشین.....	۲۹
۱.۴ ظهور سامانه‌های عامل‌محور و الگوهای جدید اجرا.....	۳۱
۱.۵ تفاوت نرم‌افزار قطعی، مدل آماری و عامل خودمختار.....	۳۳
۱.۶ نسبت AgentOps با DevOps و MLOps.....	۳۵
۱.۷ تعریف مسئله و پرسش‌های پژوهشی کتاب.....	۳۹
جمع‌بندی فصل.....	۴۰
پرسش‌های مروری و تمرین‌های تحلیلی.....	۴۰
منابع.....	۴۱
فصل ۲. مبانی نظری عامل‌های هوش مصنوعی.....	۴۴
۲.۱ تعریف عامل هوشمند و مفهوم عاملیت.....	۴۴
۲.۲ عامل، محیط، مشاهده، اقدام و بازخورد.....	۴۶

۲.۳	مدل‌های زبانی بزرگ به‌عنوان هسته‌ی تصمیم‌گیری	۴۸
۲.۴	برنامه‌ریزی، استدلال و اجرای چندمرحله‌ای	۴۹
۲.۵	ابزارها، حافظه و بازیابی اطلاعات	۵۱
۲.۶	عامل تک‌مرحله‌ای، چندمرحله‌ای و سامانه‌ی چندعاملی	۵۳
۲.۷	محدودیت‌های خودمختاری و عدم قطعیت رفتاری	۵۴
۲.۸	مدل‌های مفهومی برای تحلیل رفتار عامل	۵۶
	جمع‌بندی فصل	۵۸
	پرسش‌های مروری و تمرین‌های تحلیلی	۵۹
	منابع	۶۰

فصل ۳. چرا عملیات سستی برای عامل‌ها کافی نیست؟

۳.۱	محدودیت معیارهای متعارف سلامت سرویس	۶۲
۳.۲	غیرقطعی بودن خروجی و مسیر اجرای عامل	۶۴
۳.۳	خطاهای استدلال، برنامه‌ریزی و انتخاب ابزار	۶۵
۳.۴	خطاهای وابسته به حافظه و زمینه	۶۶
۳.۵	شکست‌های زنجیره‌ای در اجرای وظایف	۶۷
۳.۶	تفاوت خطای زیرساختی با خطای رفتاری	۶۸
۳.۷	ریسک اقدامات خارجی و پیامدهای واقعی	۶۹
۳.۸	نیازمندی‌های چارچوب عملیاتی ویژه‌ی عامل‌ها	۷۱
	جمع‌بندی فصل	۷۲
	پرسش‌های مروری و تمرین‌های تحلیلی	۷۲
	منابع	۷۳

بخش دوم: بنیان‌های مفهومی و معماری AgentOps

فصل ۴. تعریف، اصول و مرزهای AgentOps

۴.۱	تعریف عملیاتی AgentOps	۷۶
۴.۲	تمایز AgentOps از DevOps، MLOps، LLMops و AIOps	۷۸
۴.۳	اهداف و اصول بنیادین مهندسی عامل‌ها	۸۰
۴.۴	واحدهای اصلی مدیریت	۸۱
۴.۵	مسئولیت‌های تیم مهندسی و تیم بهره‌برداری	۸۲
۴.۶	مرز میان خودمختاری، اتوماسیون و کنترل انسانی	۸۳
۴.۷	اصطلاحات و واژگان استاندارد پیشنهادی	۸۴

۴.۸	فرضیه‌های بنیادین و پرسش‌های باز پژوهشی.....	۸۶
۴.۹	جمع‌بندی فصل.....	۸۶
۴.۱۰	پرسش‌های مروری و تمرین‌های تحلیلی.....	۸۷
۴.۱۱	منابع.....	۸۷

فصل ۵. معماری مرجع سامانه‌های AgentOps..... ۸۹

۵.۱	الزامات معماری برای اجرای عامل در محیط واقعی.....	۸۹
۵.۲	سه صفحه و هشت لایه.....	۹۰
۵.۳	قراردادهای میان لایه‌ها.....	۹۳
۵.۴	لایه‌های تصمیم، ابزار و حافظه.....	۹۵
۵.۵	جریان اجرای یک وظیفه از آغاز تا پایان.....	۹۷
۵.۶	لایه‌ی مشاهده‌پذیری و صفحه‌ی شواهد.....	۹۸
۵.۷	لایه‌ی ارزیابی، سیاست و کنترل.....	۱۰۰
۵.۸	لایه‌ی زیرساخت و اجرای توزیع‌شده.....	۱۰۲
۵.۹	مسیر خطا، بازیابی، مرزهای اعتماد و نقاط تأیید انسانی.....	۱۰۲
۵.۱۰	الگوهای معماری متمرکز، توزیع‌شده و چندعاملی.....	۱۰۵
۵.۱۱	اقتباس در برابر پیشنهاد، و مزایا، محدودیت‌ها و هزینه‌ها.....	۱۰۵
۵.۱۲	جمع‌بندی فصل.....	۱۰۷
۵.۱۳	پرسش‌های مروری و تمرین‌های تحلیلی.....	۱۰۷
۵.۱۴	منابع.....	۱۰۸

فصل ۶. چرخه عمر مهندسی عامل‌های هوشمند..... ۱۱۰

۶.۱	تعریف مسئله و معیارهای موفقیت.....	۱۱۱
۶.۲	طراحی قرارداد رفتاری.....	۱۱۳
۶.۳	انتخاب مدل و طراحی تعامل با ابزارها.....	۱۱۵
۶.۴	توسعه، یکپارچه‌سازی و آزمون.....	۱۱۶
۶.۵	انتشار و استقرار کنترل‌شده.....	۱۱۷
۶.۶	پایش رفتار در محیط تولید.....	۱۱۸
۶.۷	تحلیل رخداد و بازیابی.....	۱۱۹
۶.۸	بازخورد عملیاتی و بهبود مستمر.....	۱۲۰
۶.۹	مدیریت نسخه‌های مدل، دستورالعمل، ابزار و سیاست.....	۱۲۰
۶.۱۰	بازنشستگی عامل و مدیریت پایان عمر.....	۱۲۱
۶.۱۱	جمع‌بندی فصل.....	۱۲۲

۱۲۲	پرسش‌های مروری و تمرین‌های تحلیلی
۱۲۳	منابع

بخش سوم: قابلیت‌های مهندسی و کنترل عملیاتی ۱۲۵

فصل ۷. مشاهده‌پذیری، ردیابی و بازسازی اجرا ۱۲۶

۱۲۶	۷.۱ مشاهده‌پذیری در سامانه‌های غیرقطعی
۱۲۸	۷.۲ ردگیری انتهای‌انتهای وظایف عامل
۱۳۰	۷.۳ ثبت فراخوانی مدل، ابزار، حافظه و تغییر وضعیت
۱۳۲	۷.۴ ساختاردهی رویدادها و زمینه‌ی اجرای عامل
۱۳۳	۷.۵ ردیابی توزیع‌شده در گردش کارهای چندعاملی
۱۳۵	۷.۶ بازپخش اجرا و بازسازی مسیر تصمیم‌گیری
۱۳۷	۷.۷ محرمانگی، حداقل‌سازی داده و نگهداری ردگیری‌ها
۱۳۸	۷.۸ طراحی شاخص‌های مشاهده‌پذیری عامل
۱۳۹	جمع‌بندی فصل
۱۳۹	پرسش‌های مروری و تمرین‌های تحلیلی
۱۴۰	منابع

فصل ۸. ارزیابی مستمر و مهندسی کیفیت رفتار ۱۴۱

۱۴۱	۸.۱ محدودیت آزمون صحت خروجی
۱۴۲	۸.۲ تعریف معیار موفقیت وظیفه
۱۴۳	۸.۳ ارزیابی کیفیت تصمیم و انتخاب ابزار
۱۴۵	۸.۴ مجموعه داده‌های ارزیابی و سناریوهای مرجع
۱۴۶	۸.۵ آزمون واحد، یکپارچه‌سازی و انتهابه‌انتها
۱۴۶	۸.۶ ارزیابی مدل‌محور و محدودیت داورهای مبتنی بر مدل
۱۴۸	۸.۷ آزمون رگرسیون برای تغییر مدل و دستورالعمل
۱۴۹	۸.۸ ارزیابی برخط و مقایسه‌ی نسخه‌ها
۱۴۹	۸.۹ سنجش پایداری نتایج در اجراهای تکراری
۱۵۲	۸.۱۰ دروازه‌های کیفی پیش از انتشار: مثال اجرایی
۱۵۳	جمع‌بندی فصل
۱۵۴	پرسش‌های مروری و تمرین‌های تحلیلی
۱۵۵	منابع

فصل ۹. قابلیت اطمینان، تحمل خطا و بازیابی ۱۵۶

۱۵۶	۹.۱ طبقه‌بندی شکست‌ها در سامانه‌های عامل محور.....
۱۶۰	۹.۲ شکست در برنامه‌ریزی و انتخاب اقدام.....
۱۶۱	۹.۳ شکست ابزار، شبکه، مدل و سرویس‌های وابسته.....
۱۶۲	۹.۴ حلقه‌های تکرار و انحراف از هدف.....
۱۶۳	۹.۵ مهلت، بودجه‌ی گام و محدودیت منابع.....
۱۶۳	۹.۶ تکرار امن، idempotency و جبران اقدام‌ها.....
۱۶۵	۹.۷ توقف اضطراری و بازگشت به مسیر امن.....
۱۶۵	۹.۸ تحلیل علت ریشه‌ای و پیشگیری از تکرار.....
۱۶۷	۹.۹ تعریف و اندازه‌گیری قابلیت اطمینان عامل.....
۱۶۸	جمع‌بندی فصل.....
۱۶۸	پرسش‌های مروری و تمرین‌های تحلیلی.....
۱۶۹	منابع.....

فصل ۱۰. امنیت، حاکمیت و کنترل اختیار عامل..... ۱۷۰

۱۷۰	۱۰.۱ مدل تهدید برای عامل‌های هوش مصنوعی.....
۱۷۲	۱۰.۲ تزریق دستورالعمل و آلودگی زمینه.....
۱۷۴	۱۰.۳ دسترسی ابزارها، هویت عامل و حداقل سطح دسترسی.....
۱۷۵	۱۰.۴ مدیریت اسرار و جداسازی محیط اجرا.....
۱۷۶	۱۰.۵ اجرای ایمن کد و محصورسازی محیط.....
۱۷۶	۱۰.۶ کنترل اقدام‌های حساس و تأیید انسانی.....
۱۷۷	۱۰.۷ سیاست‌های مجاز، ممنوع و مشروط.....
۱۷۸	۱۰.۸ ثبت شواهد و قابلیت حسابرسی.....
۱۸۰	۱۰.۹ حریم خصوصی، انطباق و پاسخ‌گویی.....
۱۸۱	۱۰.۱۰ طراحی حاکمیت متناسب با سطح ریسک.....
۱۸۲	جمع‌بندی فصل.....
۱۸۳	پرسش‌های مروری و تمرین‌های تحلیلی.....
۱۸۴	منابع.....

بخش چهارم: استقرار و بهره‌برداری در مقیاس تولید..... ۱۸۵

فصل ۱۱. زیرساخت، ارکستراسیون و تحویل پیوسته عامل‌ها..... ۱۸۶

۱۸۷	۱۱.۱ الگوهای استقرار عامل در ابر و زیرساخت اختصاصی.....
۱۸۷	۱۱.۲ معماری سرویس‌گرا و گردش کارهای طولانی‌مدت.....

۱۱.۳	مدیریت وضعیت پایدار و اجرای قابل‌بازایی	۱۸۸
۱۱.۴	صف‌ها، زمان‌بندی و اجرای هم‌زمان	۱۹۰
۱۱.۵	مدیریت وابستگی‌ها و نسخه‌بندی ابزارها	۱۹۱
۱۱.۶	خط لوله‌ی CI/CD و انتشار عامل	۱۹۲
۱۱.۷	انتشار تدریجی، آزمون سایه‌ای و بازگشت نسخه	۱۹۴
۱۱.۸	مدیریت پیکربندی و تفکیک محیط‌ها	۱۹۵
۱۱.۹	ظرفیت‌سنجی و مقیاس‌پذیری افقی	۱۹۵
۱۱.۱۰	معماری مرجع استقرار سازمانی	۱۹۶
	جمع‌بندی فصل	۱۹۷
	پرسش‌های مروری و تمرین‌های تحلیلی	۱۹۸
	منابع	۱۹۹

فصل ۱۲. هزینه، کارایی و بهره‌وری اقتصادی

۱۲.۱	اجزای هزینه‌ی اجرای عامل	۲۰۰
۱۲.۲	مصرف توکن، فراخوانی ابزار و هزینه‌ی زیرساخت	۲۰۲
۱۲.۳	اندازه‌گیری تأخیر در مسیرهای چندمرحله‌ای	۲۰۲
۱۲.۴	موازنه‌ی کیفیت، سرعت و هزینه	۲۰۳
۱۲.۵	بودجه‌گذاری برای وظیفه و محدودسازی مصرف	۲۰۳
۱۲.۶	نهان‌سازی، دسته‌بندی درخواست‌ها و بهینه‌سازی مسیر	۲۰۴
۱۲.۷	انتخاب مدل متناسب با پیچیدگی وظیفه	۲۰۵
۱۲.۸	تحلیل هزینه‌ی شکست و اجرای مجدد	۲۰۵
۱۲.۹	هزینه‌ی هر وظیفه‌ی موفق و شاخص‌های اقتصادی	۲۰۵
۱۲.۱۰	بهینه‌سازی مبتنی بر شواهد عملیاتی	۲۰۷
	جمع‌بندی فصل	۲۰۷
	پرسش‌های مروری و تمرین‌های تحلیلی	۲۰۸
	منابع	۲۰۹

فصل ۱۳. عملیات چندعاملی و مدل عملیاتی سازمان

۱۳.۱	معماری‌های چندعاملی و تقسیم مسئولیت	۲۱۰
۱۳.۲	هماهنگی، ارتباط و انتقال وظیفه میان عامل‌ها	۲۱۲
۱۳.۳	مدیریت وابستگی‌ها و شکست‌های بین‌عاملی	۲۱۲
۱۳.۴	مشاهده‌پذیری تعاملات چندعاملی	۲۱۳
۱۳.۵	کنترل دسترسی و بودجه در سطح گروه عامل‌ها	۲۱۳

۱۳.۶	مسئولیت‌های توسعه‌دهندگان، مهندسان پلتفرم و اپراتورها	۲۱۵
۱۳.۷	مدیریت رخداد و پاسخ‌گویی عملیاتی	۲۱۶
۱۳.۸	مدل بلوغ سازمانی AgentOps	۲۱۶
۱۳.۹	شاخص‌های آمادگی سازمان	۲۱۷
۱۳.۱۰	مدیریت تغییر و پذیرش عامل‌ها در سازمان	۲۱۸
۲۱۸	جمع‌بندی فصل	۲۱۸
۲۱۹	پرسش‌های مروری و تمرین‌های تحلیلی	۲۱۹
۲۲۰	منابع	۲۲۰

بخش پنجم: اعتبارسنجی علمی و مسیر آینده ۲۲۱

فصل ۱۴. روش‌شناسی پژوهش و اعتبارسنجی چارچوب AgentOps ۲۲۲

۱۴.۱	مرور نظام‌مند ادبیات و شناسایی شکاف پژوهشی	۲۲۳
۱۴.۲	تفکیک یافته‌های موجود از پیشنهاد‌های جدید کتاب	۲۲۴
۱۴.۳	استخراج نیازمندی‌ها و طراحی چارچوب مرجع	۲۲۵
۱۴.۴	فرضیه‌های قابل‌آزمون و پرسش‌های پژوهشی	۲۲۵
۱۴.۵	طراحی آزمایش برای ارزیابی چارچوب	۲۲۷
۱۴.۶	ساخت سناریوهای شکست و مجموعه‌ی آزمون	۲۲۷
۱۴.۷	معیارهای مقایسه، خط مبنا و آزمون‌های شبیه‌سازی	۲۲۸
۱۴.۸	مطالعه‌ی موردی و ارزیابی عملیاتی	۲۳۰
۱۴.۹	اعتبار درونی، اعتبار بیرونی و تهدیدهای اعتبار	۲۳۰
۱۴.۱۰	گزارش نتایج منفی و محدودیت‌های چارچوب	۲۳۱
۲۳۲	جمع‌بندی فصل	۲۳۲
۲۳۲	پرسش‌های مروری و تمرین‌های تحلیلی	۲۳۲
۲۳۳	منابع	۲۳۳

فصل ۱۵. مسائل باز و آینده‌ی مهندسی عامل‌های هوشمند ۲۳۵

۱۵.۱	استانداردسازی مفاهیم و داده‌های عملیاتی	۲۳۵
۱۵.۲	ارزیابی رفتارهای نوظهور و دشواری‌پیش‌بینی	۲۳۶
۱۵.۳	یادگیری مستمر بدون تخریب قابلیت‌های پیشین	۲۳۷
۱۵.۴	حاکمیت عامل‌های با اختیار گسترده	۲۳۷
۱۵.۵	عملیات عامل‌های توزیع‌شده و خودتکثیرشونده	۲۳۸
۱۵.۶	تعامل عامل‌ها با سامانه‌های فیزیکی و دنیای واقعی	۲۳۸

۲۳۹	 ۱۵.۷ سنجش اعتمادپذیری و تضمین‌های قابل اثبات
۲۴۰	 ۱۵.۸ طراحی زیرساخت‌های خودترمیم‌شونده
۲۴۰	 ۱۵.۹ پرسش‌های پژوهشی اولویت‌دار
۲۴۱	 ۱۵.۱۰ جمع‌بندی و چشم‌انداز بلوغ AgentOps
۲۴۲	 جمع‌بندی فصل
۲۴۲	 پرسش‌های مروری و تمرین‌های تحلیلی
۲۴۳	 منابع
۲۴۵	 نتیجه‌گیری کل کتاب
۲۴۷	 پیوست A. مدل داده‌ی پیشنهادی برای ثبت ردگیری اجرای عامل
۲۴۹	 پیوست B. الگوی طبقه‌بندی شکست و رخداد
۲۵۰	 پیوست C. ماتریس ارزیابی بلوغ AgentOps
۲۵۲	 پیوست D. چک‌لیست آمادگی استقرار در محیط تولید
۲۵۴	 پیوست E. نمونه‌های فنی، طرح‌های آزمایشی و قراردادهای رفتاری
۲۵۷	 پیوست F. روش مرور منابع و معیار انتخاب پژوهش‌ها
۲۵۹	 واژه‌نامه‌ی تخصصی فارسی - انگلیسی
۲۶۴	 نمایه‌ی اصطلاحات و اختصارات
۲۶۸	 فهرست منابع

فهرست شکل ها

- شکل ۱-۱. سیر تحول از DevOps تا AgentOps بر اساس واحد مدیریت (منبع: نگارنده) ۳۸
- شکل ۱-۲. حلقه‌ی عامل در معماری مرجع: تصمیم مدل پیش از اجرا از سیاست و بودجه می‌گذرد (منبع: نگارنده) ۴۷
- شکل ۲-۲. نمودار توالی تعامل مدل، حلقه‌ی عامل، دروازه‌ی ابزار و محیط (منبع: نگارنده) ۵۱
- شکل ۱-۵. نمای کلی معماری مرجع AO-RA: سه صفحه و هشت لایه (منبع: نگارنده) ۹۱
- شکل ۲-۵. جریان اجرای یک وظیفه در مسیر موفق (منبع: نگارنده) ۹۷
- شکل ۳-۵. منطق تصمیم پس از هر گام: تلاش مجدد، مدارشکن، رد سیاست، توقف و جبران (منبع: نگارنده) ۱۰۳
- شکل ۴-۵. مرزهای اعتماد در AO-RA (منبع: نگارنده) ۱۰۴
- شکل ۱-۶. چرخه‌ی عمر مهندسی عامل: هفت مرحله و حلقه‌ی بازخورد (منبع: نگارنده) ۱۱۱
- شکل ۱-۷. ردگیری یک اجرای موفق در پیاده‌سازی مرجع: نُه رویداد زیر بازه‌ی ریشه (منبع: نگارنده) ... ۱۳۰
- شکل ۲-۷. انتشار زمینه‌ی ردگیری در یک گردش کار چندعاملی (منبع: نگارنده، با الهام از مثال Wang et al., ۲۰۲۵) ۱۳۴
- شکل ۱-۸. خط لوله‌ی ارزیابی و دروازه‌ی انتشار (منبع: نگارنده) ۱۴۵
- شکل ۲-۸. افت $pass^k$ با افزایش k برای چند نرخ موفقیت یک‌باره؛ تقریب مستقل p^k (منبع: محاسبه‌ی نگارنده) ۱۵۰
- شکل ۱-۱۱. خط لوله‌ی CI/CD عامل: از تغییر تا انتشار کامل و بازگشت (منبع: نگارنده، با اقتباس از ایده‌ی خط لوله‌ی استقرار Humble & Farley, ۲۰۱۰) ۱۹۳
- شکل ۲-۱۱. معماری استقرار مرجع سازمانی (منبع: نگارنده) ۱۹۷
- شکل ۱-۱۳. مدل بلوغ پنج‌سطحی AgentOps (منبع: نگارنده) ۲۱۶

فهرست جدول‌ها

- جدول ۱-۱. مقایسه‌ی سه نوع سامانه از دید عملیات (منبع: نگارنده) ۳۴
- جدول ۲-۱. مقایسه‌ی AgentOps، MLOps، LLMOps و DevOps (منبع: نگارنده بر پایه‌ی منابع این فصل) ۳۷
- جدول ۱-۲. سطوح ساختاری عامل‌ها و ریسک عملیاتی غالب (منبع: نگارنده) ۵۳
- جدول ۱-۳. چهار سیگنال طلایی و شکست‌های رفتاری که نمی‌بینند (منبع: نگارنده، بر پایه‌ی Ewaschuk, ۲۰۱۶) ۶۴
- جدول ۲-۳. شکست زیرساختی در برابر شکست رفتاری (منبع: نگارنده، با اتکا بر Wang et al., ۲۰۲۵) ۶۹
- جدول ۳-۳. نیازمندی‌های استخراج‌شده از تحلیل فصل (منبع: نگارنده) ۷۱
- جدول ۱-۴. تمایز پنج «Ops» بر اساس موضوع عملیات (منبع: نگارنده، با اتکا بر Wang et al., ۲۰۲۵) ۷۸
- جدول ۲-۴. واحدهای اصلی مدیریت در AgentOps (منبع: نگارنده) ۸۱
- جدول ۳-۴. ماتریس پیشنهادی مسئولیت‌ها (م: مجری، پ: پاسخ‌گو، ش: مشورت‌شونده، آ: آگاه‌شونده؛ منبع: نگارنده) ۸۳
- جدول ۴-۴. سطوح پیشنهادی خودمختاری و کنترل‌های متناظر (منبع: نگارنده) ۸۳
- جدول ۵-۴. پانزده اصطلاح محوری (منبع: نگارنده؛ واژه‌نامه‌ی کامل در پایان کتاب) ۸۵
- جدول ۱-۵. مسئولیت‌ها و محل هر لایه (منبع: نگارنده) ۹۲
- جدول ۲-۵. قراردادهای میان لایه‌ها (منبع: نگارنده) ۹۳
- جدول ۳-۵. مرزهای اعتماد و کنترل‌های متناظر (منبع: نگارنده) ۱۰۴
- جدول ۴-۵. اجزای AO-RA: اقتباس از چه، و سهم نگارنده چیست (منبع: نگارنده) ۱۰۵
- جدول ۱-۶. نمونه‌ی معیارهای موفقیت برای عامل بازپرداخت (منبع: نگارنده) ۱۱۲
- جدول ۲-۶. لایه‌های آزمون عامل (منبع: نگارنده) ۱۱۶
- جدول ۳-۶. مصنوعات، مالک و دروازه‌ی هر مرحله (منبع: نگارنده) ۱۲۱
- جدول ۱-۷. نگاشت پیشنهادی بازه‌های مدل ردگیری به رویدادهای AO-RA (منبع: نگارنده، بر پایه‌ی Dong et al., ۲۰۲۴) ۱۲۹
- جدول ۲-۷. رویدادها و فیلدهای حداقلی (منبع: نگارنده) ۱۳۱
- جدول ۳-۷. شاخص‌های پیشنهادی مشاهده‌پذیری عامل (منبع: نگارنده) ۱۳۸
- جدول ۱-۸. تعداد اجراهای لازم برای نیم‌عرض بازه‌ی اطمینان ۹۵٪ (تقریب نرمال؛ منبع: محاسبه‌ی نگارنده) ۱۴۸
- جدول ۲-۸. مقدار p^k (تقریب اجراهای مستقل؛ منبع: محاسبه‌ی نگارنده) ۱۵۰

جدول ۹-۱. ۱۴ حالت شکست MAST و شیوع آن‌ها در ۱۶۴۲ ردگیری (منبع: Cemri et al., ۲۰۲۵)	۱۵۷
ترجمه‌ی نگارنده) (AgentOps-FT: شازده رده‌ی شکست (منبع: نگارنده، بر پایه‌ی Wang et al., ۲۰۲۵ و Cemri et al., ۲۰۲۵)	۱۵۸
جدول ۱۰-۱. مدل تهدید خلاصه‌ی عامل‌ها: دارایی، مسیر و کنترل (منبع: نگارنده، با اتکا بر OWASP	
..... (GenAI Security Project, ۲۰۲۵)	۱۷۱
جدول ۱۰-۲. حداقل کنترل‌های پیشنهادی بر حسب رده‌ی ریسک (منبع: نگارنده)	۱۸۱
جدول ۱۱-۱. مراحل خط لوله‌ی عامل: ورودی، آزمون و شرط عبور (منبع: نگارنده)	۱۹۳
جدول ۱۲-۱. اجزای هزینه‌ی یک وظیفه‌ی عامل (منبع: نگارنده)	۲۰۱
جدول ۱۲-۲. تکنیک‌های کاهش هزینه و خطر هرکدام (منبع: نگارنده بر پایه‌ی تجربه‌ی عمومی	
..... (مهندسی)	۲۰۴
جدول ۱۳-۱. الگوهای چندعاملی و ریسک عملیاتی (منبع: نگارنده، با اتکا بر Cemri, Anthropic, ۲۰۲۴	
..... (et al., ۲۰۲۵)	۲۱۱
جدول ۱۳-۲. ماتریس بلوغ: توانمندی‌ها در هر سطح (منبع: نگارنده)	۲۱۶
جدول ۱۴-۱. رده‌بندی ادعاهای اصلی کتاب بر حسب وضعیت دانش (منبع: نگارنده)	۲۲۴
جدول ۱۴-۲. فرضیه‌های اصلاح‌شده و طرح هر یک (منبع: نگارنده)	۲۲۵
جدول B-۱. قالب ثبت یک شکست یا رخداد (منبع: نگارنده)	۲۴۹
جدول C-۱. پرسش‌های ارزیابی بلوغ (منبع: نگارنده)	۲۵۰
جدول E-۱. فهرست مثال‌های اجرایی کتاب (منبع: نگارنده)	۲۵۴

فهرست اختصارات

اختصارهای به کاررفته در کتاب به ترتیب الفبای لاتین آمده‌اند.

اختصار	شکل کامل	معنا
AO-RA	AgentOps Reference Architecture	معماری مرجع پیشنهادی این کتاب
API	Application Programming Interface	رابط برنامه‌نویسی
CI/CD	Continuous Integration / Delivery	یکپارچه‌سازی و تحویل پیوسته
CPST	Cost per Successful Task	هزینه‌ی هر وظیفه‌ی موفق
FM	Failure Mode	حالت شکست (در MAST)
HITL	Human-in-the-Loop	انسان در حلقه
JSONL	JSON Lines	قالب یک رویداد JSON در هر خط
LLM	Large Language Model	مدل زبانی بزرگ
MAST	Multi-Agent System Failure Taxonomy	طبقه‌بندی شکست سامانه‌های چندعاملی (Cemri et al., ۲۰۲۵)
MCP	Model Context Protocol	پروتکل زمینه‌ی مدل
NIST	National Institute of Standards and Technology	مؤسسه‌ی ملی استاندارد و فناوری ایالات متحده
OWASP	Open Worldwide Application Security Project	پروژه‌ی امنیت برنامه‌های کاربردی

معنا	شکل کامل	اختصار
تولید افزوده به بازیابی	Retrieval-Augmented Generation	RAG
تحلیل علت ریشه‌ای	Root Cause Analysis	RCA
هدف سطح سرویس	Service Level Objective	SLO
مهندسی قابلیت اطمینان سایت	Site Reliability Engineering	SRE
هزینه‌ی کل هر وظیفه‌ی موفق با لحاظ هزینه‌ی رفع شکست	Total Cost per Success	TCPS

این کتاب از یک پرسش ساده آغاز شد: وقتی یک سامانه‌ی هوشمند به‌جای پاسخ دادن، کاری انجام می‌دهد، چه چیزی را باید به‌طور متفاوت مهندسی کنیم؟ پاسخ آسان این است که «همان کارهای همیشگی»، یعنی آزمون، پایش و استقرار. اما هرچه به این پرسش دقیق‌تر نگاه کردم، آن پاسخ سست‌تر شد. نرم‌افزار سنتی را با «آیا کار می‌کند؟» می‌سنجیم. عامل هوشمند می‌تواند بی‌هیچ خطایی اجرا شود و کار نادرستی انجام دهد؛ و تکرار دوباره‌ی همان اجرا شاید نتیجه‌ی دیگری بدهد. این فاصله میان «اجرای بدون خطا» و «اجرای درست» انگیزه‌ی علمی و مهندسی این کتاب است.

نوشتن درباره‌ی مهندسی عامل‌ها نیازمند احتیاط است، چون حوزه جوان و پرتحول است. بنابراین دو تعهد را از ابتدا پذیرفتم. نخست، **تفکیک صریح دانش از پیشنهاد**. هر ادعای مهم در این کتاب یا به منبعی راستی‌آزمایی‌شده ارجاع دارد، یا صراحتاً به‌عنوان تحلیل و پیشنهاد نگارنده معرفی شده است. معماری مرجع **AO-RA**، قرارداد رفتاری، طبقه‌بندی **AgentOps-FT** و مدل بلوغ، **پیشنهاد نگارنده‌اند** و استاندارد یا یافته‌ی اثبات‌شده نیستند. دوم، **گزارش صادقانه**. کدهای کتاب واقعاً اجرا و آزمون شده‌اند و خروجی‌های نشان‌داده‌شده خروجی واقعی‌اند؛ آزمون‌هایی که «شبیه‌سازی» هستند صریحاً چنین نامیده شده‌اند؛ و دو بار که نتیجه‌ی شبیه‌سازی با انتظار اولیه‌ی من نخواند، همان را گزارش و فرضیه را اصلاح کردم.

رویکرد کتاب، پیوند نظریه با مهندسی عملی است. هر فصل از ادبیات علمی و مرجع (وقتی منبع معتبر دارد) آغاز می‌کند، به یک طراحی مهندسی می‌رسد و در

بسیاری از فصل‌ها آن را با کد کوچک و آزمون‌شده نشان می‌دهد. هدف این نیست که خواننده این کد را در تولید به کار ببرد؛ هدف این است که ایده‌ها را به‌اندازه‌ای ملموس کند که بتوان درباره‌شان استدلال کرد و آن‌ها را نقد کرد.

از خواننده دو انتظار دارم. اول، که با دید انتقادی بخواند: پیشنهادهای این کتاب را با شواهد و موقعیت خودش بسنجد و هر جا با تجربه‌اش نمی‌خواند، به من یا جامعه‌ی پژوهشی بازتاب دهد. دوم، که بپذیرد این حوزه هنوز در حال شکل‌گیری است؛ بسیاری از پرسش‌ها در فصل ۱۵ باز مانده‌اند و آنچه امروز بهترین تصور ماست ممکن است فردا اصلاح شود.

مسئله اصلی. مدل‌های زبانی بزرگ و عامل‌های مبتنی بر آن‌ها به سرعت از آزمایشگاه به محصول می‌رسند. بسیاری از آن‌ها در نمایش عالی کار می‌کنند و در تولید دچار شکست‌هایی می‌شوند که ابزار مهندسی سنتی نمی‌بیند. پرسش اصلی کتاب این است: چگونه می‌توان عامل‌های هوش مصنوعی را از نمونه‌های آزمایشی و گردش کارهای شکننده، به سامانه‌هایی قابل ارزیابی، قابل کنترل، امن، قابل اتکا و اقتصادی در محیط واقعی تبدیل کرد؟

عامل چه تفاوتی دارد؟ یک مدل پاسخ‌گو یک تابع است: ورودی می‌گیرد و خروجی می‌دهد. یک گردش کار ثابت، مسیر مراحل را در کد تعیین می‌کند. یک عامل، در یک حلقه‌ی مشاهده، تصمیم و اقدام، خودش مسیر را انتخاب می‌کند و از طریق ابزارها اثر بیرونی ایجاد می‌کند. این تفاوت، منبع عدم قطعیت و بهای خطا را عوض می‌کند (فصل‌های ۱ و ۲).

چرا صحت پاسخ کافی نیست؟ چون خروجی عامل یک مسیر است، مسیر تصادفی است و آنچه اهمیت دارد اغلب اثر پایانی روی دنیای بیرون و رعایت قیود است. اجرای «سبز» می‌تواند اقدام نادرست حمل‌کند؛ و موفقیت یک‌باره، شاخص قابل‌اتکایی برای رفتار تکراری نیست (فصل‌های ۳ و ۸).

AgentOps در این کتاب. AgentOps را مهندسی رفتار عامل در سراسر چرخه‌ی عمر می‌نامیم، که رفتار را تعریف‌پذیر، مشاهده‌پذیر، سنجش‌پذیر، محدود‌پذیر و بازایی‌پذیر می‌کند (فصل ۴). این تعریف تلفیقی از دو سنت پژوهشی (چرخه‌ی

عملیات و مشاهده‌پذیری مصنوعات) با دو افزوده‌ی نگارنده است.

دامنه. کتاب درباره‌ی عامل‌های نرم‌افزاری مبتنی بر مدل زبانی با اثر بیرونی دیجیتال است. خارج از دامنه: آموزش یا تنظیم مدل‌ها، طراحی دستورالعمل به‌عنوان هنر، عامل‌های فیزیکی و رباتیک (فصل ۱۵ فقط به آن‌ها اشاره می‌کند)، و مشاوره‌ی حقوقی. کتاب راهنمای هیچ محصول یا ابزار تجاری نیست.

ساختار. پنج بخش: (۱) مبانی و تغییر پارادایم؛ (۲) بنیان‌های مفهومی و معماری؛ (۳) قابلیت‌های مهندسی و کنترل (مشاهده‌پذیری، ارزیابی، قابلیت اطمینان، امنیت)؛ (۴) استقرار و بهره‌برداری (زیرساخت، هزینه، عملیات چندعاملی و سازمان)؛ (۵) اعتبارسنجی و مسائل باز.

خواننده چه توانایی‌هایی به دست می‌آورد؟ پس از مطالعه باید بتواند: (۱) تفاوت AgentOps با DevOps و MLOps را توضیح دهد؛ (۲) برای یک عامل، قرارداد وظیفه و رفتاری بنویسد؛ (۳) ردگیری ساخت‌یافته و بازپخش را طراحی کند؛ (۴) ارزیابی آماری با اجراهای تکراری و بازه‌ی اطمینان انجام دهد؛ (۵) شکست‌ها را طبقه‌بندی و بازیابی و جبران را طراحی کند؛ (۶) مدل تهدید و کنترل‌های اختیار را بسازد؛ (۷) خط لوله و انتشار تدریجی عامل را طراحی کند؛ (۸) هزینه را با شاخص‌های درست بسنجد؛ (۹) آمادگی سازمان را ارزیابی کند.

محدودیت‌های دانش فعلی. شواهد تجربی درباره‌ی عملیات عامل‌ها هنوز محدود است. دو مرور اصلی AgentOps (Wang et al., ۲۰۲۵؛ Dong et al., ۲۰۲۴) دیدگاه‌های مکمل دارند؛ مرورهای ارزیابی هزینه‌کارایی و ایمنی را شکاف می‌دانند (Yehudai et al., ۲۰۲۵)؛ و ارزیابی تجربی معماری مرجع این کتاب هنوز انجام نشده است (فصل ۱۴).

راهنمای استفاده از کتاب

مخاطبان. مهندسان نرم افزار و معماران؛ متخصصان هوش مصنوعی و یادگیری ماشین؛ مهندسان ML Ops، DevOps و LLM Ops؛ مهندسان پلتفرم و زیرساخت؛ پژوهشگران؛ مدیران فنی و مسئولان استقرار هوش مصنوعی؛ دانشجویان تحصیلات تکمیلی. کتاب مقدمه‌ای برای افراد کاملاً مبتدی نیست، ولی مفاهیم پیچیده تدریجی معرفی و توضیح داده می‌شوند.

مسیرهای خواندن. مسیر کامل: از فصل ۱ به ترتیب. مسیر مهندسی پلتفرم: فصل‌های ۱، ۴ تا ۷، ۱۰ و ۱۱. مسیر ارزیابی و کیفیت: فصل‌های ۲، ۳، ۶، ۸ و ۹. مسیر مدیریتی: فصل‌های ۱، ۴، ۱۲، ۱۳ و ۱۵. مسیر پژوهشی: فصل‌های ۴، ۱۴ و ۱۵ و منابع. **برچسب‌های وضعیت دانش.** ع:۱ یافته‌ی مستند در منبع علمی (با ارجاع). ع:۲ تجربه و الگوی مهندسی متداول یا مستند رسمی. ع:۳ استاندارد یا چارچوب رسمی. ع:۴ پیشنهاد یا تحلیل نگارنده. ع:۵ فرضیه یا پیش‌بینی اثبات نشده.

ارجاع‌ها. سبک APA ۷؛ اشخاص در ارجاع به صورت لاتین. منابع هر فصل در پایان همان فصل و فهرست یکپارچه در پایان کتاب آمده است. فقط منابعی ارجاع شده‌اند که فراداده‌ی آن‌ها از صفحه‌ی رسمی راستی‌آزمایی شد.

کد. همه‌ی کدها در پوشه‌ی `code` (پایتون ۳/۱۲، فقط کتابخانه‌ی استاندارد) و آزمون‌ها با `python3 -m unittest tests.test_aorch` اجرا می‌شوند. کدها آموزشی‌اند و جایگزین یک پلتفرم تولیدی نیستند. مثال‌های اجرایی در `code/examples`؛ خروجی‌های نمایش داده‌شده در کتاب، خروجی واقعی همان مثال‌ها

هستند. مثال‌های شبیه‌سازی شده صراحتاً برچسب دارند.

قراردادهای نگارشی. اصطلاح تخصصی در نخستین کاربرد با معادل انگلیسی

می‌آید. ارقام فارسی در متن و ارقام لاتین در کد. «./» و ممیز اعشار فارسی در فونت

متن موجود نیستند؛ به‌جای آن از «./» و «/» استفاده شده است. جای‌نگهدارها با براکت

مشخص شده‌اند و باید پیش از انتشار تکمیل شوند.

بخش اول: مبانی و تغییر پارادایم

از DevOps و MLOps تا مهندسی

عامل‌های هوشمند

ساعت سه بامداد است و داشبورد پایش یک دستیار پشتیبانی مشتریان هیچ نشانه‌ای از مشکل ندارد. تأخیر پاسخ‌ها در محدوده است، نرخ خطای HTTP صفر است، مصرف پردازنده و حافظه آرام است و تمام آزمون‌های خودکار شب پیش شده‌اند. اما همان شب، دستیار برای مشتری اشتباهی بازپرداخت ثبت کرده است: سفارش را درست جست‌وجو کرده، قاعده بازپرداخت را درست خوانده و سپس به‌خاطر یک برداشت نادرست از متن پیام مشتری، ابزار پرداخت را برای سفارش دیگری فراخوانده است. هیچ استثنایی پرتاب نشده، هیچ درخواستی شکست نخورده و هیچ شاخصی از آستانه‌اش عبور نکرده است.

این صحنه ساختگی نیست؛ شکل کلی آن همان چیزی است که این کتاب را لازم می‌کند. نرم‌افزار سنتی را می‌توان با پرسش «آیا کار می‌کند؟» سنجید، چون «کار کردن» تقریباً با «بدون خطا اجرا شدن» برابر است. در یک سامانه عامل محور، اجرای بدون خطا و اجرای درست دو چیز متفاوت‌اند و فاصله میان آن دو، قلمرو تازه‌ای از مهندسی را می‌سازد.

اهداف این فصل. (۱) نشان دهیم هر موج عملیات نرم‌افزار، پاسخی به نوع تازه‌ای از عدم قطعیت بوده است؛ (۲) مفروضاتی را که DevOps و MLOps بر آن‌ها تکیه دارند صریح کنیم؛ (۳)

توضیح دهیم کدام مفروضات با ورود عامل‌های هوشمند فرو می‌ریزند؛ (۴) جایگاه AgentOps را نسبت به این دو شاخه روشن کنیم؛ (۵) پرسش‌های پژوهشی کتاب را بیان کنیم.

۱.۱ تحول مهندسی نرم‌افزار در عصر هوش مصنوعی

برای فهم اینکه چرا به «عملیات» تازه‌ای نیاز داریم، باید به یک پرسش ساده برگردیم: در هر دوره، رفتار سامانه از کجا می‌آید؟ این پرسش مسیر تحول را به سه گذار تقسیم می‌کند. این تقسیم‌بندی، چارچوب روایی نگارنده است و ادعای تاریخی دقیقی درباره‌ی زمان‌بندی پیدایش فناوری‌ها نیست.

گذار نخست: از دستور به داده. در نرم‌افزار کلاسیک، رفتار را برنامه‌نویس به‌صورت صریح در کد می‌نویسد. اگر دو بار همان ورودی را به همان نسخه از برنامه بدهیم، همان خروجی را می‌گیریم؛ هر تفاوتی نشانه‌ی یک عامل بیرونی است، مثل وضعیت پایگاه داده یا ساعت سیستم. در یادگیری ماشین، بخشی از رفتار از داده استخراج می‌شود. دیگر نمی‌توان با خواندن کد گفت سامانه در همه‌ی ورودی‌ها چه می‌کند؛ باید آن را روی داده سنجید و پذیرفت که ورودی‌های دور از توزیع آموزش ممکن است رفتار پیش‌بینی‌ناپذیر بدهند. مقاله‌ی شناخته‌شده‌ی اسکالی و همکاران نشان داد که همین ویژگی چگونه بدهی فنی پنهانی می‌سازد که در کد دیده نمی‌شود، بلکه در وابستگی‌های داده و درهم‌تنیدگی مؤلفه‌ها نهسته است (Sculley et al., ۲۰۱۵).

گذار دوم: از داده به زبان. مدل‌های زبانی بزرگ (large language models, LLM) رفتار را بار دیگر جابه‌جا کردند: اکنون بخش مهمی از «برنامه»، متنی است که به

مدل داده می‌شود، یعنی دستورالعمل، نمونه‌ها و زمینه. تغییر یک جمله در دستورالعمل می‌تواند رفتار را در ده‌ها سناریو عوض کند، بی‌آنکه حتی یک خط کد تغییر کرده باشد. نمونه‌برداری احتمالاتی از خروجی هم یعنی دو اجرای یکسان لزوماً خروجی یکسان نمی‌دهند. نتیجه‌ی عملی این است که «پیکربندی» با «کد» مرز روشنی ندارد و آزمون‌پذیری، دیگر یک ویژگی پیش‌فرض نیست.

گذار سوم: از پاسخ به اقدام. تا اینجا خروجی سامانه یک پاسخ بود که انسان می‌خواند. در سامانه‌ی عامل‌محور، خروجی مدل صرفاً متن نیست؛ تصمیمی است برای فراخوانی ابزار، نوشتن در پایگاه داده، ارسال پیام یا آغاز یک تراکنش. عامل در یک حلقه‌ی چندمرحله‌ای، هر مرحله را بر اساس نتیجه‌ی مرحله‌ی قبل برمی‌گزیند و اثرهایش در دنیای بیرون ثبت می‌شوند. به تعبیر ووالدریج و جنینگز، ویژگی‌های بنیادین یک عامل عبارت‌اند از خودمختاری، توانایی اجتماعی، واکنش‌پذیری و کنش‌گری هدف‌محور (Wooldridge & Jennings, ۱۹۹۵)؛ تعریفی که سال‌ها پیش از مدل‌های زبانی بزرگ ارائه شد، اما اکنون بر ابزارهای تجاری واقعی صدق می‌کند.

هر گذار دو چیز را تغییر می‌دهد. اول، **منبع عدم قطعیت** را: از «ورودی‌های ناشناخته» به «تعمیم آماری» و سپس به «انتخاب‌های خودمختار در حلقه‌ی کنش». دوم، **بهای خطا** را: خطای یک مدل پیش‌بینی‌گر، یک پیش‌بینی نادرست است؛ خطای یک عامل می‌تواند یک تراکنش مالی نادرست باشد. این دو تغییر، هر یک به مجموعه‌ای از روش‌های مهندسی جدید انجامیده‌اند و بخش بزرگی از تاریخ «Ops»‌ها را می‌سازند.

۱.۲ پیدایش DevOps و اصول بنیادین آن

DevOps پاسخی به مسئله‌ای بود که امروز بدیهی به نظر می‌رسد اما زمانی دردناک بود: توسعه‌دهندگان و بهره‌برداران، اهداف متفاوت و گاه متعارض داشتند. توسعه‌دهندگان برای تحویل سریع‌تر ویژگی‌ها پاداش می‌گرفتند و بهره‌برداران برای پایداری. انتشار نسخه‌ی تازه، رویدادی نادر، پرریسک و پرمشقت بود.

هامبل و فارلی با مفهوم «خط لوله‌ی استقرار» (deployment pipeline) این مسئله را به مسئله‌ی مهندسی تبدیل کردند: فرایندی خودکار برای مدیریت تمام تغییرات، از لحظه‌ی ثبت در مخزن کد تا انتشار برای کاربران (Humble & Farley, ۲۰۱۰). ایده‌ی کلیدی این است که هر تغییر، از مسیری یکسان و خودکار از مراحل ساخت، آزمون و استقرار بگذرد، تا انتشار از یک رویداد ویژه به یک کار روزمره تبدیل شود. فورسگرن و همکاران با داده‌های چندساله نشان دادند که توان تحویل نرم‌افزار را می‌توان با چهار سنجه‌ی عملیاتی اندازه گرفت: زمان تحویل تغییر، فراوانی استقرار، زمان بازیابی سرویس پس از اختلال و نرخ شکست تغییر (Forsgren et al., ۲۰۱۸). این چهار سنجه هنوز شاید رایج‌ترین زبان مشترک بین تیم‌های توسعه و عملیات باشند.

از سوی دیگر، مهندسی قابلیت اطمینان سایت (site reliability engineering, SRE) فرایند بهره‌برداری را به صورت رشته‌ای مهندسی در آورد. دو ایده از این سنت برای بحث ما مهم است. نخست، **بودجه‌ی خطا (error budget)**: مقدار ناپایداری‌ای که یک سرویس در یک بازه مجاز است داشته باشد، یعنی فاصله‌ی میان دسترس‌پذیری وعده‌داده‌شده در هدف سطح سرویس (SLO) و آنچه سامانه‌ی پایش واقعاً اندازه

می‌گیرد؛ تا زمانی که بودجه باقی است، تیم‌ها آزادانه منتشر می‌کنند و وقتی کم شود، تمرکز به پایداری برمی‌گردد (Alvidrez, ۲۰۱۶). دوم، **چهار سیگنال طلایی** پایش: تأخیر، ترافیک، خطاها و اشباع (Ewaschuk, ۲۰۱۶).

نکته‌ی جالب در همان فصل پایش، تعریف «خطا» است. نویسنده خطاها را در سه دسته می‌آورد: آشکار (مثل پاسخ HTTP با کد ۵۰۰)، ضمنی (مثل پاسخ موفقی که محتوایش اشتباه است) و مبتنی بر سیاست (مثل پاسخی که از مهلت مقرر گذشته است) (Ewaschuk, ۲۰۱۶). **خطای ضمنی** دقیقاً همان صحنه‌ی ابتدای این فصل است. سنت SRE از آن آگاه بود، اما آن را حاشیه‌ای می‌دید که با پرسش‌های واری دوره‌ای (probe) قابل پوشش است. در سامانه‌های عامل‌محور، خطای ضمنی دیگر حاشیه نیست؛ جریان اصلی شکست‌ها است.

برای اینکه ببینیم دقیقاً چه چیزی در گذار به عامل‌ها می‌شکند، باید مفروضات پنهان DevOps را صریح کنیم.

تحلیل نگارنده (ع۴): چهار مفروضه‌ی DevOps. (الف) رفتار سامانه تابع کد و پیکربندی نسخه‌بندی شده است؛ پس تکرار کد و پیکربندی، رفتار را تکرار می‌کند. (ب) آزمون قابل تکرار است؛ آزمونی که امروز سبز می‌شود، روی همان کد فردا هم سبز می‌شود. (ج) خطا در لایه‌ی سرویس دیده می‌شود؛ استثنا، کد وضعیت، تأخیر یا اشباع. (د) اثر بیرونی هر درخواست از پیش محدود و شناخته شده است؛ یعنی می‌دانیم هر نقطه‌ی پایانی به کدام پایگاه داده می‌نویسد.

هر یک از این چهار مفروضه در ادامه‌ی فصل زیر فشار قرار می‌گیرد.

۱.۳ شکل‌گیری MLOps و چرخه عمر مدل‌های یادگیری ماشین

وقتی مدل‌های یادگیری ماشین به محصول تبدیل شدند، تیم‌ها دریافتند که خط

لوله‌ی DevOps به‌تنهایی کافی نیست. کد، تنها بخش کوچکی از سامانه بود؛ بقیه را داده، ویژگی‌ها، مدل آموزش‌دیده و زیرساخت آموزش و ارائه می‌ساختند. اسکالی و همکاران این وضعیت را با مفهوم بدهی فنی پنهان توصیف کردند: سامانه‌های یادگیری ماشین علاوه بر بدهی‌های معمول کد، بدهی‌های ویژه‌ای در سطح سامانه دارند، از جمله وابستگی به داده‌ی ناپایدار و حلقه‌های بازخوردی که خود مدل در آن‌ها شرکت دارد (Sculley et al., ۲۰۱۵).

کروزبرگر و همکاران با تکیه بر مرور ادبیات، مرور ابزارها و مصاحبه با متخصصان، MLOps را چنین تعریف کردند: مجموعه‌ای از بهترین روش‌ها، مفاهیم و فرهنگ توسعه برای مفهوم‌سازی، پیاده‌سازی، پایش، استقرار و مقیاس‌پذیری محصولات یادگیری ماشین، که بر پایه‌ی سه رشته‌ی یادگیری ماشین، مهندسی نرم‌افزار (به‌ویژه DevOps) و مهندسی داده شکل می‌گیرد. آن‌ها نه اصل شناسایی کردند: خودکارسازی CI/CD، ارکستراسیون گردش کار، تکرارپذیری، نسخه‌بندی داده و مدل و کد، همکاری، آموزش و ارزیابی مستمر، ثبت فراداده و ردگیری آزمایش‌ها، پایش مستمر و حلقه‌های بازخورد (Kreuzberger et al., ۲۰۲۲).

اگر این نه اصل را از زاویه‌ی «چه چیزی واحد مدیریت است» نگاه کنیم، تغییر اصلی روشن است: DevOps تغییر کد را مدیریت می‌کرد؛ MLOps سه‌گانه‌ی کد، داده و مدل را. نسخه‌ی مدل باید به نسخه‌ی داده‌ی آموزش و کد آموزش گره بخورد تا رفتار بازتولیدپذیر باشد. پایش هم گسترش می‌یابد: افزون بر سلامت سرویس، باید کیفیت پیش‌بینی و تغییر توزیع داده نیز دیده شود. و حلقه‌ی بازخورد، ماهیت جدیدی می‌گیرد: مدل می‌تواند با داده‌ی تازه بازآموزی شود.

اما MLOps هم مفروضاتی دارد که اغلب نانوشته مانده‌اند. مدل یک تابع است:

ورودی ویژگی‌ها، خروجی پیش‌بینی. کیفیت آن با معیارهای مشخصی مثل دقت یا خطای میانگین روی داده‌ی برچسب‌دار سنجیده می‌شود. پیش‌بینی خودش اثری بیرونی ندارد؛ اثر در لایه‌ای دیگر، یعنی سامانه‌ی تصمیم‌گیر انسان یا قاعده‌ای، رخ می‌دهد. و هر فراخوانی مستقل از قبلی است. هر سه فرض، در گذار سوم زیر سؤال می‌روند.

۱.۴ ظهور سامانه‌های عامل‌محور و الگوهای جدید اجرا

اصطلاح «عامل» در صنعت امروز معانی متفاوتی دارد و بخشی از ابهام‌ها از همین جا می‌آید. یک تمایز مفید را مهندسان Anthropic پیشنهاد کرده‌اند: گردش کار (workflow) سامانه‌ای است که در آن مدل‌های زبانی و ابزارها از طریق مسیرهای از پیش تعریف‌شده در کد هماهنگ می‌شوند، و عامل سامانه‌ای است که در آن خود مدل فرایند و استفاده از ابزارها را پویا هدایت می‌کند و کنترل نحوه‌ی انجام کار را در دست دارد. آن‌ها پنج الگوی گردش کار را برمی‌شمارند: زنجیره‌ی دستورالعمل‌ها (prompt chaining)، مسیریابی (routing)، موازی‌سازی (parallelization)، هماهنگ‌کننده و کارگران (orchestrator-workers) و ارزیاب و بهینه‌ساز (evaluator-optimizer) (Anthropic, ۲۰۲۴). این منبع صنعتی و وابسته به یک شرکت است؛ در این کتاب آن را به‌عنوان یک راهنمای عملی معتبر (ع ۲) به کار می‌بریم، نه یک تعریف علمی قطعی.

از دید مهندسی عملیات، این طیف اهمیت دارد: هرچه از گردش کار به سمت عامل می‌رویم، بخش بیشتری از «منطق برنامه» از کد به مدل منتقل می‌شود و بخش بیشتری از رفتار، در زمان اجرا تعیین می‌شود. پژوهش‌های بنیادین این مسیر هم

همین را نشان می‌دهند. روش ReAct استدلال و اقدام را در یک مسیر واحد درهم می‌تند تا مدل بتواند طرح را بسازد، بر اساس مشاهده‌ی محیط اصلاح کند و با ابزار تعامل کند (Yao et al., ۲۰۲۲). تولفمر نشان داد مدل می‌تواند استفاده از ابزار را به صورت خودنظارتی بیاموزد (Schick et al., ۲۰۲۳). ریفلکشن بازخورد کلامی و حافظه‌ی رویدادی را برای بهبود عملکرد در تلاش‌های بعدی به کار گرفت (Shinn et al., ۲۰۲۳). مرورهای جامع این حوزه، معماری عامل‌های مبتنی بر مدل زبانی را به مؤلفه‌هایی مثل نمایه‌ی عامل، حافظه، برنامه‌ریزی و کنش دسته‌بندی کرده‌اند (L. Wang et al., ۲۰۲۳).

اتصال عامل‌ها به ابزارها نیز در حال استانداردسازی است. پروتکل زمینه‌ی مدل (Model Context Protocol, MCP) بر پایه‌ی ۲/۰ JSON-RPC سه نقش میزبان، سرویس‌گیرنده و سرویس‌دهنده تعریف می‌کند؛ سرویس‌دهنده‌ها می‌توانند منابع، دستورالعمل‌ها و ابزارها عرضه کنند. نکته‌ی مهم برای بحث ما، بخش امنیتی همین مشخصات است: ابزارها در عمل «اجرای کد دلخواه» اند و باید با احتیاط تلقی شوند، و توصیف رفتار ابزار نامعتبر فرض می‌شود، مگر از یک سرویس‌دهنده معتبر آمده باشد (Model Context Protocol, ۲۰۲۶). مشخصات نسخه‌ی ثبت‌شده‌ی ۲۰۲۶-۲۸-۰۷ بوده است.

دانگ، لو و ژو پنج ویژگی را برمی‌شمارند که عامل‌های مبتنی بر مدل زبانی را از نرم‌افزار سنتی متمایز می‌کنند و مستقیماً بر عملیات اثر می‌گذارند: (۱) مصنوعات و خطوط لوله‌ی پیچیده، چون عامل یک سامانه‌ی هوش مصنوعی مرکب است؛ (۲) خودمختاری بالا و تعامل پویا با محیط بیرونی؛ (۳) رفتار غیرقطعی؛ (۴) تکامل مستمر بر پایه‌ی ارزیابی و بازخورد انسانی؛ (۵) مسئولیت مشترک میان مالک عامل،

ارائه‌دهنده‌ی مدل پایه و ارائه‌دهندگان ابزارها (Dong et al., ۲۰۲۴). ویژگی پنجم، که کمتر به آن پرداخته می‌شود، مسئله‌ی حاکمیت را پیش می‌کشد که در فصل ۱۰ به آن برمی‌گردیم.

مفهوم کلیدی: عامل به‌مثابه سامانه‌ی هوش مصنوعی مرکب. یک عامل تنها یک مدل نیست. دانگ و همکاران آن را سامانه‌ای مرکب می‌نامند که مدل را با مؤلفه‌هایی مثل موتور زمینه و ابزارهای بیرونی ترکیب می‌کند و مصنوعات زمان اجرا مثل اهداف و برنامه‌ها را به‌صورت پویا تولید می‌کند (Dong et al., ۲۰۲۴). از همین‌رو، عملیات عامل‌ها باید مصنوعات را ردگیری کند، نه فقط فراخوانی‌های مدل را.

۱.۵ تفاوت نرم‌افزار قطعی، مدل آماری و عامل خودمختار

برای اینکه تفاوت سه نوع سامانه ملموس شود، یک درخواست واحد را در هر سه ببینیم.

مثال ۱-۱ (مثال مهندسی، ساختگی): درخواست بازپرداخت. مشتری پیام می‌دهد: «سفارش ۷۲۱۴ دیر رسید و کیفیت کالا هم خوب نبود؛ پولم را می‌خواهم.» (الف) **سامانه‌ی قاعده‌محور:** فرم ساختاریافته‌ای از مشتری شماره‌ی سفارش و دلیل را می‌گیرد و قاعده‌ای مثل «اگر تأخیر بیش از سه روز بود و مبلغ کمتر از سقف بود، بازپرداخت کن» اجرا می‌شود. خروجی برای هر ورودی ثابت است و می‌توان همه‌ی شاخه‌ها را آزمود. (ب) **مدل آماری:** یک طبقه‌بند، پیام را در یکی از دسته‌های «تأخیر»، «کیفیت» یا «هر دو» قرار می‌دهد. دقت آن روی داده‌ی برچسب‌دار قابل اندازه‌گیری است، اما خود طبقه‌بند هیچ اقدامی نمی‌کند؛ قاعده‌ی پس از آن تصمیم می‌گیرد. (ج) **عامل:** پیام را می‌خواند، شماره‌ی سفارش را استخراج می‌کند، وضعیت ارسال را از سامانه‌ی لجستیک می‌پرسد، سیاست بازپرداخت را بازبینی می‌کند، مبلغ را محاسبه می‌کند و در نهایت، ابزار

پرداخت را فراخوانی می‌کند. هر مرحله بر اساس نتیجه‌ی مرحله‌ی قبل انتخاب می‌شود و مسیر اجرا برای دو درخواست مشابه می‌تواند متفاوت باشد.

جدول ۱-۱ تفاوت‌ها را در شش بعد مقایسه می‌کند.

جدول ۱-۱. مقایسه‌ی سه نوع سامانه از دید عملیات (منبع: نگارنده)

بعد	قطعی (قاعده‌محور)	مدل آماری	عامل خودمختار
تعیین‌کننده‌ی رفتار	کد و پیکربندی	کد، داده و وزن‌های مدل	کد، مدل، دستورالعمل، زمینه و نتیجه‌ی ابزارها
تکرارپذیری	کامل با ورودی یکسان	معمولاً کامل با وزن و ورودی ثابت	در حالت کلی ناقص: مسیر اجرا ممکن است هر بار متفاوت باشد
معنای درستی	مطابقت با مشخصات	دقت روی توزیع داده	دستیابی به هدف تحت قیود؛ مسیر هم اهمیت دارد
روش آزمون	آزمون واحد و یکپارچه	ارزیابی روی داده‌ی نگه‌داشته	ارزیابی چندمرحله‌ای، اجراهای تکراری، سناریوهای شکست
اثر بیرونی	مشخص در کد	معمولاً ندارد	مستقیم و از پیش نامعلوم
شکست غالب	استثنا و خطای منطقی	افت کیفیت و جابه‌جایی توزیع	رفتار نادرست با اجرای بدون خطا؛ شکست زنجیره‌ای

تفاوت سطر دوم عمیق است. یائو و همکاران در معیار τ -bench نشان دادند که حتی وقتی یک عامل «گاهی» موفق است، تکرار آن ناپایدار است. نتیجه‌ی کلیدی آنان این بود که مدل پیشرفته‌ی آن زمان که برای کار با ابزار طراحی شده بود (GPT-40) در حدود ۶۱٪ از وظایف حوزه‌ی خرده‌فروشی و ۳۵٪ وظایف حوزه‌ی هواپیمایی موفق بود؛ و وقتی از عامل خواسته می‌شد که یک وظیفه را در هشت تلاش مستقل

هر هشت بار درست حل کند، نرخ در حوزه‌ی خرده‌فروشی به حدود ۲۵٪ می‌رسید (Yao et al., ۲۰۲۴). این اعداد مربوط به مدل‌ها و ابزارهای ۲۰۲۴ هستند و نباید به وضعیت امروز تعمیم داده شوند؛ آنچه ماندگار است، نکته‌ی روش‌شناختی است: موفقیت یک‌باره، شاخص قابل‌اتکایی برای رفتار یک سامانه‌ی غیرقطعی نیست و باید سازگاری را جداگانه اندازه گرفت. در فصل ۸ به این معیار (pass^k) با جزئیات بازمی‌گردیم.

مسئله‌ی دوم، تعریف درستی است. در سامانه‌ی قطعی، مشخصات می‌گوید خروجی چیست. در عامل، «خروجی درست» اغلب یک مجموعه‌ی پذیرفتنی است و معیار موفقیت باید شامل قیود باشد: اگر عامل سفارش درست را بازپرداخت کند اما از ابزاری خارج از مجوز استفاده کرده باشد، یا مبلغی بیش از سقف بپردازد، آیا موفق بوده است؟ مقاله‌ی مرور ارزیابی عامل‌ها هم شکاف‌هایی را در ارزیابی هزینه‌کارایی، ایمنی و استحکام مشخص می‌کند و می‌گوید روش‌های ارزیابی ریزدانه و مقیاس‌پذیر هنوز در حال شکل‌گیری‌اند (Yehudai et al., ۲۰۲۵).

۱.۶ نسبت AgentOps با DevOps و MLOps

با این مقدمات می‌توان مشاهده‌ی اصلی فصل را بیان کرد. چهار مفروضه‌ی DevOps و سه مفروضه‌ی MLOps هر یک به شکلی شکسته‌اند:

- مفروضه‌ی «رفتار تابع کد است» (الف): رفتار اکنون تابع کد، مدل، دستورالعمل و زمینه‌ی لحظه‌ای است. نسخه‌ی کد، رفتار را تعیین نمی‌کند.
- مفروضه‌ی «آزمون قابل تکرار است» (ب): اجرای دوباره، لزوماً همان نتیجه را نمی‌دهد. آزمون باید آماری و تکرارشونده باشد.

- **مفروضه‌ی «خطا در لایه‌ی سرویس دیده می‌شود» (ج):** پاسخ ۲۰۰ می‌تواند اقدام اشتباه را حمل کند. شکست در لایه‌ی تصمیم رخ می‌دهد، نه لایه‌ی سرویس.
 - **مفروضه‌ی «اثر بیرونی محدود و شناخته است» (د):** عامل با ابزارها می‌تواند طیفی از اثرها را ایجاد کند که در زمان طراحی همه پیش‌بینی نشده است.
 - **مفروضه‌ی MLOps «مدل یک تابع بی‌اثر است»:** عامل مدل را در حلقه‌ی کنش به کار می‌گیرد؛ اثر بیرونی دارد.
 - **مفروضه‌ی MLOps «فراخوانی‌ها مستقل‌اند»:** مراحل عامل به هم وابسته‌اند و خطای یک مرحله به مراحل بعد منتقل می‌شود.
 - **مفروضه‌ی MLOps «کیفیت با معیار روی داده‌ی برچسب‌دار سنجیده می‌شود»:** برچسب «درست» برای مسیرهای چندمرحله‌ای دشوارتر و ناکامل‌تر است.
- در ادبیات، دو تعریف نزدیک از AgentOps دیده می‌شود و تمایز آن‌ها برای فهم کتاب مهم است. وانگ و همکاران AgentOps (که آن را «عملیات سامانه‌ی عامل» می‌نامند) را چارچوب عملیاتی جامعی می‌دانند که مراحل پیش از اجرا، اجرا، و پس از اجرا را در بر می‌گیرد و مانند عملیات سنتی چهار مرحله دارد: پایش، تشخیص آنومالی، تحلیل علت ریشه‌ای و رفع. تفاوت بنیادین آن با عملیات سنتی مانند AIops، به‌گفته‌ی آنان، در ماهیت موضوع عملیات است (Wang et al., ۲۰۲۵).
- دلایل اصلی تفاوت از دید آنان این چهار است: آنومالی‌های متنوع‌تر در سامانه‌های عامل محور؛ نیاز به مشاهده‌پذیری بیشتر؛ ناممکن بودن رویکرد یکپارچه برای تشخیص آنومالی و تحلیل علت؛ و پیچیدگی رفع، که نیاز به بهینه‌سازی تکرارشونده دارد (Wang et al., ۲۰۲۵).
- از سوی دیگر، دانگ و همکاران AgentOps را پارادایم تخصصی DevOps برای عامل‌ها می‌نامند و محور آن را مشاهده‌پذیری مصنوعات

عامل در سراسر چرخه عمر تعریف می‌کنند؛ آنان خاطرنشان می‌کنند که ابزارهای موجود DevOps برای عامل‌ها عمدتاً بر سنجه‌های ویژه‌ی مدل زبانی و مدیریت دستورالعمل متمرکزند و پشتیبانی محدودی از مصنوعات ویژه‌ی عامل مثل اهداف، برنامه‌ها و ابزارها دارند (Dong et al., ۲۰۲۴). یک اثر جدیدتر با دامنه‌ی مشابه نیز با عنوان «عملیات سامانه‌های عامل» همان چارچوب چهارمرحله‌ای را به کار برده است (Wang et al., ۲۰۲۶)؛ در منبع صراحتاً ذکر نشده که نسخه‌ی بازنگری‌شده‌ی مقاله‌ی ۲۰۲۵ باشد و ما نیز چنین ادعایی نمی‌کنیم.

پیشنهاد نگارنده (ع). در این کتاب، AgentOps را مهندسی رفتار عامل در سراسر چرخه عمر می‌نامیم؛ یعنی تلفیقی از دو سنت بالا: از سنت وانگ و همکاران، چرخه‌ی پایش تا رفع را می‌گیریم؛ از سنت دانگ و همکاران، ردگیری مصنوعات را؛ و دو چیز می‌افزاییم که در این دو منبع محور اصلی نیستند: قرارداد رفتاری (پیش از اجرا) و سیاست و بودجه‌ی اجرا (در حین اجرا). این تعریف استاندارد نیست و در فصل ۴ دقیق‌تر بیان و در فصل ۱۴ آزمون‌پذیر می‌شود.

جدول ۱-۲ چهارشاخه را در کنار هم می‌گذارد و شکل ۱-۱ سیر کلی را نشان می‌دهد. ردیف «LLMOps» در این جدول جمع‌بندی نگارنده از رویه‌ی رایج صنعت است و به منبع تک‌مرجعی استناد ندارد.

جدول ۱-۲. مقایسه‌ی DevOps، MLOps، LLMOps و AgentOps (منبع: نگارنده بر پایه‌ی منابع این

فصل)

بعد	DevOps	MLOps	LLMOps	AgentOps
واحد مدیریت	تغییر کد و پیکربندی	کد، داده، مدل	دستورالعمل، زمینه، مدل پایه	رفتار عامل (تصمیم‌ها و اقدام‌ها)
منبع عدم قطعیت	بار و محیط	تعمیم آماری	نمونه‌برداری احتمالاتی	تصمیم‌های خودمختار در حلقه‌ی کنش

بعد	DevOps	MLOps	LLMOps	AgentOps
کنترل اصلی	خط لوله‌ی استقرار	بازآموزی و نسخه‌بندی	ارزیابی و مدیریت دستورالعمل	ردگیری، سیاست، ارزیابی رفتاری
پایش اصلی	تاخیر، ترافیک، خطا، اشباع	کیفیت پیش‌بینی، جابه‌جایی داده	کیفیت پاسخ، مصرف توکن	مسیر تصمیم، اقدام‌ها، هزینه‌ی وظیفه
شکست غالب	استثنا و اختلال	افت کیفیت	ناسازگاری و توهم	رفتار نادرست با اجرای بدون خطا
پیامد خطا	قطع سرویس	پیش‌بینی نادرست	پاسخ نادرست	اقدام نادرست در دنیای واقعی



شکل ۱-۱. سیر تحول از DevOps تا AgentOps بر اساس واحد مدیریت (منبع: نگارنده)

۱.۷ تعریف مسئله و پرسش‌های پژوهشی کتاب

با توجه به آنچه گذشت، مسئله‌ی کتاب را می‌توان در یک جمله‌ی دقیق گفت: چگونه می‌توان رفتار عامل‌های خودمختار را به واحدی قابل تعریف، مشاهده، سنجش، محدودسازی و بازیابی تبدیل کرد، تا استقرار آن‌ها در محیط واقعی توجیه‌پذیر باشد؟ این مسئله را به شش پرسش پژوهشی می‌شکنیم که هر کدام یک بخش اصلی کتاب را شکل می‌دهند و در فصل‌های بعد پاسخ داده می‌شوند:

۱. تعریف و مرزها (فصل ۴): AgentOps را چگونه باید تعریف کرد تا از DevOps، MLOps، LLMOps و AIOps متمایز و در عین حال با آن‌ها سازگار باشد؟
۲. معماری (فصل ۵ و ۶): برای اجرای عامل در محیط واقعی چه مؤلفه‌ها، قراردادها و مرزهای اعتمادی لازم است؟
۳. مشاهده‌پذیری و ارزیابی (فصل ۷ و ۸): چه چیزی باید ردگیری شود و رفتار را چگونه می‌توان به صورت آماری و تکرارپذیر سنجید؟
۴. قابلیت اطمینان و امنیت (فصل ۹ و ۱۰): شکست‌ها را چگونه باید طبقه‌بندی، تحمل و بازیابی کرد و اختیار عامل را چگونه محدود و حسابرسی کرد؟
۵. استقرار و اقتصاد (فصل ۱۱ تا ۱۳): عامل‌ها را چگونه باید منتشر، مقیاس‌پذیر و از نظر هزینه مدیریت کرد و سازمان چگونه برای آن آماده می‌شود؟
۶. اعتبارسنجی (فصل ۱۴): چه شواهدی می‌تواند ادعاهای چارچوب پیشنهادی این کتاب را تأیید یا رد کند؟

فرضیه‌ی کتاب (ع ۵ - اثبات نشده). رویکردی که رفتار را واحد اصلی مدیریت قرار می‌دهد و ردگیری ساخت‌یافته، ارزیابی تکرارشونده، سیاست حداقل اختیار و بودجه‌ی اجرا را در یک

معماری واحد ترکیب می‌کند، نسبت به رویکردی که فقط سلامت سرویس و درستی خروجی را می‌سنجد، شکست‌های رفتاری را زودتر و دقیق‌تر آشکار می‌کند، بدون اینکه هزینه‌ی وظیفه را به‌طور غیرمنطقی بالا ببرد. شش فرضیه‌ی قابل‌آزمون‌تر در فصل ۱۴ فهرست شده‌اند.

جمع‌بندی فصل

هر موج عملیات نرم‌افزار پاسخی به تغییر واحد «کار» و منبع عدم قطعیت بوده است. DevOps تغییر کد را مهار کرد، MLOps سه‌گانه‌ی کد، داده و مدل را، و ظهور مدل‌های زبانی، نقش متن را در تعیین رفتار وارد کرد. در عامل‌های هوشمند، چهار مفروضه‌ی DevOps و سه مفروضه‌ی MLOps شکسته می‌شود: رفتار دیگر تابع کد نیست، آزمون یک‌باره کافی نیست، شکست در لایه‌ی سرویس دیده نمی‌شود، و اثر بیرونی از پیش محدود نیست. دو سنت پژوهشی از زاویه‌های متفاوت (چرخه‌ی عملیات و مشاهده‌پذیری مصنوعات) به AgentOps رسیده‌اند. این کتاب هر دو را با قرارداد رفتاری و سیاست و بودجه‌ی اجرا تلفیق می‌کند و ادعاهایش را به‌صورت فرضیه‌های آزمون‌پذیر بیان می‌کند.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. چهار مفروضه‌ی DevOps را بنویسید و برای هر یک، مثالی از شکستن آن در یک عامل بیاورید.
۲. تفاوت «خطای ضمنی» و «خطای آشکار» در طبقه‌بندی چهار سیگنال طلایی چیست؟ چرا خطای ضمنی در سامانه‌های عامل محور رایج‌تر است؟
۳. با بازنویسی مثال ۱-۱ برای یک حوزه‌ی دلخواه (مثلاً مدیریت تیکت پشتیبانی)،

سه سامانه‌ی قاعده‌محور، آماری و عامل را توصیف کنید و برای هر یک مشخص کنید «درستی» چگونه تعریف می‌شود.

۴. چرا موفقیت یک‌باره ($pass^1$) برای قضاوت درباره‌ی قابلیت اطمینان یک عامل کافی نیست؟ با اعداد گزارش‌شده‌ی τ -bench استدلال کنید و محدودیت‌های تعمیم آن‌ها را بنویسید.

۵. دو تعریف AgentOps (Wang et al., ۲۰۲۵؛ Dong et al., ۲۰۲۴) را مقایسه کنید. کدام برای تیم عملیات و کدام برای تیم توسعه مفیدتر است؟

۶. (تحلیلی) یک عامل ساده‌ی بازپرداخت را در نظر بگیرید که برای هر درخواست، ابزارهای جست‌وجوی سفارش و پرداخت را به کار می‌برد. سه شکست ضمنی برای آن طراحی کنید که هیچ‌یک در چهار سیگنال طلایی دیده نشود.

منابع

- Alvidrez, M. (2016). Embracing risk. In B. Beyer, C. Jones, J. Petoff, & N. R. Murphy (Eds.), Site reliability engineering: How Google runs production systems (Chapter 3). O'Reilly Media. <https://sre.google/sre-book/embracing-risk/>
- Anthropic. (2024, December 19). Building effective agents. <https://www.anthropic.com/engineering/building-effective-agents>
- Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>
- Ewaschuk, R. (2016). Monitoring distributed systems. In B. Beyer, C. Jones, J. Petoff, & N. R. Murphy (Eds.), Site reliability engineering: How Google runs production systems (Chapter 6). O'Reilly Media. <https://sre.google/sre-book/monitoring-distributed-systems/>
- Forsgren, N., Humble, J., & Kim, G. (2018). Accelerate: The science of lean software and DevOps: Building and scaling high performing technology organizations. IT Revolution Press.
- Humble, J., & Farley, D. (2010). Continuous delivery: Reliable software releases through build, test, and deployment automation. Addison-Wesley.

- Kreuzberger, D., Klhl, N., & Hirschl, S. (2022). Machine learning operations (MLOps): Overview, definition, and architecture (arXiv:2205.02302). arXiv. <https://doi.org/10.48550/arXiv.2205.02302>
- Model Context Protocol. (2026). Model Context Protocol specification (version 2026-07-28). <https://modelcontextprotocol.io/specification/latest> (accessed 2026-10-21)
- Schick, T., Dwivedi-Yu, J., Dessi, R., Raileanu, R., Lomeli, M., Zettlemoyer, L., Cancedda, N., & Scialom, T. (2023). Toolformer: Language models can teach themselves to use tools (arXiv:2302.04761). arXiv. <https://doi.org/10.48550/arXiv.2302.04761>
- Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., & Dennison, D. (2015). Hidden technical debt in machine learning systems. *Advances in Neural Information Processing Systems*, 28 (NIPS 2015).
- Shinn, N., Cassano, F., Berman, E., Gopinath, A., Narasimhan, K., & Yao, S. (2023). Reflexion: Language agents with verbal reinforcement learning (arXiv:2303.11366). arXiv. <https://doi.org/10.48550/arXiv.2303.11366>
- Wang, L., Ma, C., Feng, X., Zhang, Z., Yang, H., Zhang, J., Chen, Z., Tang, J., Chen, X., Lin, Y., Zhao, W. X., Wei, Z., & Wen, J.-R. (2023). A survey on large language model based autonomous agents (arXiv:2308.11432). arXiv. <https://doi.org/10.48550/arXiv.2308.11432>
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>
- Wang, Z., Pei, C., Liu, Y., Li, J., Huo, Y., Zhou, Q., Si, H., Cui, H., Liu, Z., Xie, G., Sun, F., Pei, D., & Lo, D. (2026). Agent system operations: Categorization, challenges, and future directions (arXiv:2606.01581). arXiv. <https://doi.org/10.48550/arXiv.2606.01581>
- Wooldridge, M., & Jennings, N. R. (1995). Intelligent agents: Theory and practice. *The Knowledge Engineering Review*, 10(2), 115-152. <https://doi.org/10.1017/S0269888900008122>
- Yao, S., Shinn, N., Razavi, P., & Narasimhan, K. (2024). tau-bench: A benchmark for tool-agent-user interaction in real-world domains (arXiv:2406.12045). arXiv. <https://doi.org/10.48550/arXiv.2406.12045>
- Yao, S., Zhao, J., Yu, D., Du, N., Shafraan, I., Narasimhan, K., & Cao, Y. (2022). ReAct: Synergizing reasoning and acting in language models (arXiv:2210.03629). arXiv. <https://doi.org/10.48550/arXiv.2210.03629>
- Yehudai, A., Eden, L., Li, A., Uziel, G., Zhao, Y., Bar-Haim, R., Cohan, A., & Shmueli-

Scheuer, M. (2025). Survey on evaluation of LLM-based agents (arXiv:2503.16416). arXiv. <https://doi.org/10.48550/arXiv.2503.16416>

مبانی نظری عامل‌های هوش مصنوعی

برای مهندسی یک پدیده، نخست باید بتوان آن را دقیق توصیف کرد. «عامل» از آن واژه‌هایی است که در گفت‌وگوهای فنی هم‌زمان برای یک تابع ساده‌ی فراخوان مدل، یک گردش کار چندمرحله‌ای و یک سامانه‌ی خودمختار با ابزارهای متعدد به کار می‌رود. این فصل واژگان و مدل مفهومی مشترکی می‌سازد که در بقیه‌ی کتاب بر آن تکیه می‌کنیم: عامل چیست، در چه حلقه‌ای می‌چرخد، مدل زبانی در آن چه نقشی دارد، ابزار و حافظه چگونه به آن وصل می‌شوند و در کجا خودمختاری مرز می‌خورد.

اهداف فصل. (۱) تعریفی عملیاتی از عامل بر پایه‌ی ادبیات کلاسیک و جدید ارائه کنیم؛ (۲) مدل حلقه‌ی عامل و مؤلفه‌های آن را صریح کنیم؛ (۳) نقش و محدودیت‌های مدل زبانی به‌عنوان هسته‌ی تصمیم را بررسی کنیم؛ (۴) ابزار، حافظه و بازایی اطلاعات را از دید عملیات تحلیل کنیم؛ (۵) مدلی مفهومی برای تحلیل رفتار عامل بسازیم و آن را در یک نمونه‌ی اجرایی نشان دهیم.

۲.۱ تعریف عامل هوشمند و مفهوم عاملیت

ادبیات عامل‌ها بسیار قدیمی‌تر از مدل‌های زبانی بزرگ است. ووالدریچ و جینگز در مقاله‌ی مرجع خود «مفهوم ضعیف عاملیت» را چنین تعریف می‌کنند: عامل یک سامانه‌ی سخت‌افزاری یا (معمولاً) نرم‌افزاری است که چهار ویژگی دارد. **خودمختاری** (autonomy): بدون دخالت مستقیم انسان یا دیگران عمل می‌کند و بر کنش‌ها

و وضعیت درونی خود نوعی کنترل دارد. **توانایی اجتماعی** (social ability): با عامل‌های دیگر و احتمالاً انسان‌ها از طریق نوعی زبان ارتباطی تعامل می‌کند. **واکنش‌پذیری** (reactivity): محیط خود را درک می‌کند و در زمان مناسب به تغییرات آن پاسخ می‌دهد. **کنش‌گری هدف‌محور** (pro-activeness): فقط به محیط واکنش نشان نمی‌دهد، بلکه با ابتکار عمل، رفتار هدف‌مند نشان می‌دهد (Wooldridge & Jennings, ۱۹۹۵).

نکته‌ی مهم در این تعریف، که از دید مهندسی عملیات اهمیت دارد، این است که عامل را بر پایه‌ی **ویژگی‌های رفتاری** تعریف می‌کند و نه بر پایه‌ی فناوری پیاده‌سازی. بنابراین یک مدل زبانی به‌تنهایی عامل نیست؛ یک تابع است. عامل وقتی پدید می‌آید که آن مدل در یک حلقه‌ی ادراک و کنش قرار گیرد، به ابزارها دسترسی داشته باشد و بر مبنای هدفی، مسیر کار خود را تا حدی خودش تعیین کند. این همان تمایز «گردش‌کار» و «عامل» است که در فصل ۱ از زبان مهندسان Anthropic آورديم (Anthropic, ۲۰۲۴).

از آنجا که تعریف‌ها متفاوت‌اند، در این کتاب از تعریف عملیاتی زیر استفاده می‌کنیم.


تعریف کاری (ع ۴). عامل هوشمند سامانه‌ای نرم‌افزاری است که در یک حلقه‌ی تکرارشونده، (الف) وضعیت محیط یا نتیجه‌ی اقدام‌های پیشین را مشاهده می‌کند، (ب) با یک مؤلفه‌ی تصمیم‌گیر، که معمولاً یک مدل زبانی است، اقدام بعدی را بر اساس هدفی که به آن سپرده شده انتخاب می‌کند، (ج) آن اقدام را از طریق ابزارهایی که اثر بیرونی دارند اجرا می‌کند، و (د) تا برآورده شدن هدف یا رسیدن به یک شرط توقف ادامه می‌دهد. **عاملیت** (agency) درجه‌ای است: هرچه بخش بیشتری از انتخاب مسیر به مؤلفه‌ی تصمیم‌گیر سپرده شود و اثر بیرونی ابزارها

گسترده‌تر باشد، عاملیت بالاتر است.

این تعریف دو مزیت دارد. اول، **درجه‌ای** است و با طیف «گردش کار تا عامل» هماهنگ می‌شود؛ پس می‌توان برای هر سامانه، سطح عاملیت را سنجید و کنترل‌های عملیاتی را به آن متناسب کرد. دوم، **اثر پیرونی** را در تعریف می‌گنجاند و بدین ترتیب مرز میان یک چت‌بات صرف و عاملی را که می‌تواند داده‌ی واقعی را تغییر دهد روشن می‌کند.

۲.۲ عامل، محیط، مشاهده، اقدام و بازخورد

ساده‌ترین مدل، مدل حلقه‌ای است: عامل مشاهده می‌کند، تصمیم می‌گیرد، عمل می‌کند و نتیجه را دوباره مشاهده می‌کند. وانگ و همکاران در مقاله‌ی مرور خود، اجرای یک وظیفه را به صورت **مسیر اجرا (trajectory)** توصیف می‌کنند: دنباله‌ای از وضعیت‌ها و اقدام‌ها به شکل $\sigma = (s_0, a_1, s_1, \dots, a_t, s_t)$ ، که در آن s_i وضعیت سامانه‌ی عامل محور و a_i یک اقدام مشخص است، و تابعی $f(\sigma)$ که موفقیت یا شکست آن مسیر را نشان می‌دهد (Wang et al., ۲۰۲۵). همین نمادگذاری را در بخش‌های بعد به کار می‌بریم، چون پایه‌ی تعریف آنومالی و تحلیل علت ریشه‌ای در فصل ۹ است.



شکل ۱-۲. حلقه‌ی عامل در معماری مرجع: تصمیم مدل پیش از اجرا از سیاست و بودجه می‌گذرد (منبع: نگارنده)

در شکل ۱-۲ دو نکته مهم است. نخست، **مؤلفه‌ی تصمیم فقط پیشنهاد می‌دهد؛** اجرا از دروازه‌ی سیاست می‌گذرد. این جداسازی «پیشنهاد» از «اجرا» از بنیادی‌ترین اصول معماری مرجع این کتاب است (فصل ۵) و ریشه در اصل «میانجی‌گری کامل» در طراحی سامانه‌های امن دارد (Saltzer & Schroeder, ۱۹۷۵). دوم، **مشاهده‌ی بعدی نتیجه‌ی اقدام قبلی است؛** پس خطای یک مرحله، ورودی مرحله‌ی بعد می‌شود. همین ویژگی است که شکست‌ها را زنجیره‌ای می‌کند.

مثال ۱-۲ (مثال مهندسی، ساختگی): یک مسیر اجرا. هدف: «اگر سفارش ۷۲۱۴ بیش از سه روز دیر رسیده، بازپرداخت کن.» حالت S0: عامل فقط هدف را می‌داند. اقدام a1: فراخوانی ابزار جست‌وجوی سفارش؛ حالت S1: عامل می‌داند سفارش پنج روز تأخیر داشته و مبلغ آن ۴۰ است. اقدام a2: فراخوانی ابزار بازپرداخت با مبلغ ۴۰؛ حالت S2: بازپرداخت ثبت شده است. اقدام a3:

پاسخ نهایی. مسیر سه گام دارد و تابع موفقیت $f(\sigma)$ فقط وقتی ۱ است که اقدام بازپرداخت با شماره‌ی درست در مسیر باشد.

۲.۳ مدل‌های زبانی بزرگ به‌عنوان هسته‌ی تصمیم‌گیری

امروزه در بیشتر عامل‌های عملی، مدل زبانی بزرگ مؤلفه‌ی تصمیم‌گیر است. از دید عملیات، چند ویژگی این هسته مهم است.

استدلال از طریق متن میانی. ویی و همکاران نشان دادند که وقتی مدل را با مثال‌هایی از «زنجیره‌ی اندیشه» (chain-of-thought) راهنمایی می‌کنیم، یعنی گام‌های استدلال میانی را به‌صورت متن تولید می‌کند، عملکردش در دسته‌ای از مسائل استدلالی بهبود می‌یابد (Wei et al., ۲۰۲۲). این یافته دو پیامد عملیاتی دارد. استدلال میانی خود یک **مصنوع قابل ردگیری** است و آنچه مدل «می‌اندیشد» می‌تواند ثبت شود. و در عین حال، متن استدلال لزوماً توضیح وفادار تصمیم نیست؛ مدل ممکن است استدلالی قابل قبول بنویسد و اقدامی ناسازگار با آن انجام دهد. ادبیات شکست عامل‌ها همین ناسازگاری را «عدم تطابق استدلال و اقدام» می‌نامد و آن را جزو الگوهای متداول شکست در سامانه‌های چندعاملی ثبت کرده است (Cemri et al., ۲۰۲۵).

ناپایداری ذاتی و راه‌های کاستن از آن. چون نمونه‌برداری احتمالاتی است، یک سؤال واحد می‌تواند مسیرهای استدلالی متفاوتی بسازد. روش «سازگاری درونی» (self-consistency) چند مسیر مستقل را نمونه می‌گیرد و پاسخی را که بیشترین تکرار را دارد برمی‌گزیند و در گزارش نویسندگان استدلال زنجیره‌ای را بهبود

می‌دهد (X. Wang et al., ۲۰۲۳). از دید عملیات، چنین روشی هزینه‌ی هر وظیفه را چندبرابر می‌کند؛ پس بهبود کیفیت هرگز بی‌هزینه نیست و باید در مدل اقتصادی فصل ۱۲ حساب شود.

محدودیت خوداصلاحی. این تصور رایج که می‌توان از مدل خواست پاسخ خود را بازبینی و اصلاح کند، همیشه درست نیست. هوانگ و همکاران نشان دادند که مدل‌های زبانی بزرگ بدون بازخورد بیرونی نمی‌توانند استدلال خود را به‌طور قابل‌اتکا اصلاح کنند و در برخی موارد عملکردشان پس از اصلاح بدتر هم می‌شود (Huang et al., ۲۰۲۴). نتیجه‌ی مهندسی روشن است: حلقه‌های بازبینی باید بر سیگنال بیرونی (آزمون، قاعده، نتیجه‌ی ابزار، داور مستقل) تکیه کنند، نه بر اعتماد مدل به خودش.

اصل طراحی (ع۴). هیچ کنترل ایمنی یا کیفیتی نباید صرفاً به خودارزیابی مدل متکی باشد. بازبینی مدل‌محور باید با داده‌ی بیرونی تقویت شود و برای اقدام‌های پریسک، با سیاست قطعی و تأیید انسانی.


۲.۴ برنامه‌ریزی، استدلال و اجرای چندمرحله‌ای

در عامل‌ها، استدلال با اقدام درهم می‌آمیزد. روش ReAct استدلال و اقدام را در یک مسیر واحد می‌گنجانند: مدل ابتدا استدلالی درباره‌ی وضعیت تولید می‌کند، سپس اقدامی انتخاب می‌کند، نتیجه را می‌بیند و دوباره استدلال می‌کند. نویسندگان گزارش می‌دهند که استدلال به برنامه‌ریزی و اصلاح اقدام‌ها کمک می‌کند و اقدام، اطلاعات بیرونی را وارد استدلال می‌کند، و روش را در وظایفی مثل پرسش‌وپاسخ

چندگامی و محیط‌های تعاملی ارزیابی کرده‌اند (Yao et al., ۲۰۲۲). ریفלקشن، به‌جای بروزرسانی وزن‌ها، بازخورد را به‌صورت متن بیان می‌کند و در حافظه‌ی رویدادی نگه می‌دارد تا تلاش بعدی از آن بهره‌برد (Shinn et al., ۲۰۲۳).

از دید عملیات، سه ویژگی اجرای چندمرحله‌ای قابل توجه است. اول، طول مسیر متغیر است: برخلاف یک درخواست وب با تعداد مراحل ثابت، تعداد گام‌های عامل از پیش معلوم نیست و باید با بودجه‌ی گام محدود شود. دوم، هر گام به گام‌های پیشین وابسته است؛ پس نمی‌توان ارزیابی را بر هر گام جدا از زمینه‌اش تکیه داد. سوم، شرط توقف خودش یک تصمیم است: مدل باید تشخیص دهد که وظیفه تمام شده است. در تحلیل شکست چندعاملی، «ناآگاهی از شرط توقف» و «توقف زودهنگام» هر دو به‌عنوان حالت‌های شکست ثبت شده‌اند (Cemri et al., ۲۰۲۵)؛ یعنی عامل هم می‌تواند زود تمام کند و هم هیچ‌وقت تمام نکند.

مسیر اجرای کامل یک وظیفه از دید تعامل مؤلفه‌ها در شکل ۲-۲ آمده است.



شکل ۲-۲. نمودار توالی تعامل مدل، حلقه‌ی عامل، دروازه‌ی ابزار و محیط (منبع: نگارنده)

۲.۵ ابزارها، حافظه و بازیابی اطلاعات

ابزارها مرز عامل با دنیای بیرون‌اند. ابزار هر چیزی است که عامل می‌تواند فراخوانی کند و اثری بیرون از متن ایجاد کند یا اطلاعاتی بیرون از زمینه بیاورد: یک API، پرس‌وجوی پایگاه داده، اجرای کد، جست‌وجوی وب یا یک عامل دیگر. تولف‌مر نشان داد مدل زبانی می‌تواند تشخیص دهد چه زمانی و با چه ورودی‌ای ابزار فراخوانی

کند و نتیجه را در تولید بعدی به کار گیرد (Schick et al., ۲۰۲۳). از دید عملیات، ابزارها سه خصوصیت دارند که آن‌ها را به منبع اصلی ریسک تبدیل می‌کند. اول، **رابط‌های ناهمگون و ناپایدار**؛ مرور وانگ و همکاران، مشکلاتی مثل تأخیر، انتخاب نادرست API و خرابی سامانه در فراخوانی تابع را از ادبیات نقل می‌کند و خاطرنشان می‌کند حتی پس از استانداردسازی با MCP، تغییر پیکربندی سرویس‌دهنده‌ها اغلب منشأ آنومالی‌های کنشی است (Wang et al., ۲۰۲۵). دوم، **اثر پیرونی**؛ بر خلاف تولید متن، فراخوانی ابزار می‌تواند برگشت‌ناپذیر باشد. سوم، **اعتماد نامتقارن**؛ توصیف ابزار توسط سرویس‌دهنده نوشته می‌شود و مشخصات MCP صراحتاً آن را نامعتبر می‌شمارد مگر منبعش معتبر باشد (Model Context Protocol, ۲۰۲۶). به همین دلیل، در معماری مرجع کتاب، ابزارها فقط از طریق «دروازه‌ی ابزار» فراخوانی می‌شوند (فصل ۵).

حافظه در عامل‌ها دو شکل دارد. حافظه‌ی کوتاه‌مدت همان زمینه‌ی مدل است، که با وجود رشد پنجره‌ی زمینه هنوز محدود است. بسیاری از چارچوب‌های عامل برای کنترل آن از پنجره‌ی لغزان استفاده می‌کنند و این می‌تواند اطلاعات نخستین، مثل دستورالعمل تکمیل وظیفه، را از دست بدهد (Wang et al., ۲۰۲۵). حتی وقتی اطلاعات در زمینه جا شده، لیو و همکاران نشان دادند که مدل‌های زبانی بزرگ در استفاده از اطلاعات واقع در **میان‌ه‌ی** زمینه‌های بلند ضعیف‌ترند و عملکردشان وقتی اطلاعات مرتبط در ابتدا یا انتهای ورودی است بهتر است (Liu et al., ۲۰۲۳). حافظه‌ی بلندمدت معمولاً دانشی است که در پایگاه برداری ذخیره می‌شود و با بازیابی (retrieval) به زمینه می‌آید. لوئیس و همکاران چارچوب «تولید افزوده‌به‌بازیابی» (retrieval-augmented generation, RAG) را معرفی کردند که حافظه‌ی

پارامتری مدل را با حافظه‌ی غیرپارامتری (مجموعه‌ی بازایی‌پذیر اسناد) ترکیب می‌کند (Lewis et al., ۲۰۲۰). وانگ و همکاران خاطرنشان می‌کنند که RAG خود منبع آنومالی است: حساسیت به نویز، تعارض میان دانش درونی و بیرونی و «توهم بازایی» (Wang et al., ۲۰۲۵).

پارک و همکاران در «عامل‌های مولد» معماری‌ای ارائه کردند که مدل زبانی را با ثبت کامل تجربه‌ها به زبان طبیعی، ترکیب آن‌ها در بازتاب‌های سطح بالاتر و بازایی پویا برای برنامه‌ریزی توسعه می‌دهد (Park et al., ۲۰۲۳). این معماری مثال روشنی است از اینکه چرا حافظه یک **مصنوع عملیاتی** است: اگر محتوای حافظه ردگیری و نسخه‌بندی نشود، رفتار عامل را نمی‌توان بازتولید یا تحلیل کرد.

پیامد عملیاتی (۴ع). حافظه و زمینه باید همانند کد و پیکربندی، «وضعیت قابل‌بازرسی» باشند: برای هر تصمیم باید بتوان گفت کدام بخش از حافظه به زمینه آمد، از کجا آمد و چه نسخه‌ای داشت. این الزام در فصل ۷ به قرارداد رویداد تبدیل می‌شود.

۲.۶ عامل تک‌مرحله‌ای، چندمرحله‌ای و سامانه‌ی چندعاملی

با افزایش عاملیت، طیف ساختارهای اجرایی را می‌توان در سه سطح دید. جدول ۱-۲ آن‌ها را از دید عملیات مقایسه می‌کند.

جدول ۱-۲. سطوح ساختاری عامل‌ها و ریسک عملیاتی غالب (منبع: نگارنده)

سطح	چه کسی مسیر را تعیین می‌کند	مثال	ریسک عملیاتی غالب
تک‌مرحله‌ای (فراخوان مدل با ابزار)	کد، با یک تصمیم مدل	استخراج فیلد و فراخوانی یک API	انتخاب نادرست ابزار یا پارامتر

سطح	چه کسی مسیر را تعیین می‌کند	مثال	ریسک عملیاتی غالب
چندمرحله‌ای (حلقه‌ی عامل)	مدل، در هر گام	عامل بازپرداخت، عامل پشتیبانی	حلقه‌ی بی‌پایان، شکست زنجیره‌ای، توقف نابه‌جا
چندعاملی	تعامل چند مدل/نقش	سرپرست و کارگران، تیم‌های کدنویسی	ناهم‌ترازی بین‌عاملی، ارتباط نادرست، تأیید ناقص

درباره‌ی سامانه‌های چندعاملی، شواهد تجربی مفیدی وجود دارد. Cemri و همکاران با تحلیل ۱۶۴۲ ردگیری اجرای حاصل از هفت چارچوب چندعاملی، طبقه‌بندی MAST را ساختند که ۱۴ حالت شکست را در سه دسته جا می‌دهد: مسائل طراحی سامانه، ناهم‌ترازی بین‌عاملی و راستی‌آزمایی وظیفه (Cemri et al., ۲۰۲۵). یافته‌ی محوری آنان برای بحث ما مهم است: شکست‌های سامانه‌های چندعاملی فقط تابع ضعف مدل پایه نیست؛ یک سامانه‌ی خوب طراحی‌شده، با همان مدل، می‌تواند بهتر عمل کند (Cemri et al., ۲۰۲۵). به بیان دیگر، مهندسی سامانه و نه فقط انتخاب مدل، عامل شکست است. این استدلال، بنیاد وجود رشته‌ای مثل AgentOps است. فهرست کامل ۱۴ حالت و کاربرد آن‌ها در طبقه‌بندی شکست این کتاب در فصل ۹ می‌آید.

۲.۷ محدودیت‌های خودمختاری و عدم قطعیت رفتاری

خودمختاری بی‌هزینه نیست. چهار منبع عدم قطعیت را می‌توان متمایز کرد.

۱. عدم قطعیت ذاتی مدل: نمونه‌برداری احتمالاتی، حساسیت به جزئیات دستورالعمل، و ناپایداری میان نسخه‌های مدل.

۲. **عدم قطعیت اطلاعاتی:** توهم، اطلاعات منسوخ، بازیابی ناقص یا متناقض. وانگ و همکاران توهم را در لایه‌های استدلال، برنامه‌ریزی و حافظه به‌صورت آنومالی‌های جدا طبقه‌بندی می‌کنند (Wang et al., ۲۰۲۵).

۳. **عدم قطعیت محیطی:** ابزارها و سامانه‌های بیرونی که خودشان تغییر می‌کنند، کند یا خراب می‌شوند.

۴. **عدم قطعیت تعاملی:** در سامانه‌های چندعاملی، رفتار هر عامل به رفتار دیگران بستگی دارد و رفتارهای نوظهور ممکن است از تعامل ساده‌ی اجزای معقول پدید آیند.

اندازه‌گیری این عدم قطعیت برای مهندسی ضروری است. یائو و همکاران برای سنجش آن، معیار $pass^k$ را پیشنهاد کردند، یعنی احتمال اینکه یک وظیفه در k تلاش مستقل **همه‌ی** تلاش‌ها موفق باشد (Yao et al., ۲۰۲۴). تخمین بدون‌تورش آن بر پایه‌ی n اجرا و c موفقیت برابر $C(c,k)/C(n,k)$ است، و معیار هم‌خانواده‌ی $pass@k$ ، احتمال دست‌کم یک موفقیت در k تلاش، از تخمین $1 - C(n-c,k)/C(n,k)$ به‌دست می‌آید (Yao et al., ۲۰۲۴). چن و همکاران تخمین بدون‌تورش $pass@k$ را در ارزیابی مدل‌های کدنویس معرفی کرده بودند (Chen et al., ۲۰۲۱). برای مثال اگر یک عامل از ده اجرای مستقل یک وظیفه، پنج بار موفق شود، $pass@1$ و $pass^1$ هر دو $0/5$ است؛ $pass@2$ برابر $35/45 \approx 0/78$ و $pass^2$ برابر $10/45 \approx 0/22$ می‌شود (محاسبه‌ی نگارنده؛ در آزمون‌های واحد کد کتاب بررسی شده است). فاصله میان این دو عدد، دقیقاً «ناپایداری» عامل است. فصل ۸ این معیارها را بسط می‌دهد.

فرضیه‌ی ۲ (ع ۵ - اثبات نشده). در وظایف دارای پیامد بیرونی، قاعده‌ی انتشار مبتنی بر $pass^k$ با آستانه‌ای متناسب با تجربه‌ی تکراری کاربر، پیامد انتشار نسخه‌ی ناپایدار را بهتر از قاعده‌ی

مبتنی بر موفقیت یک‌باره بازتاب می‌دهد. توجه: این فرضیه درباره‌ی نیاز است نه قدرت آماری؛ در فصل ۱۴ نشان می‌دهیم که در یک مدل دوجمله‌ی ساده، با آستانه‌های هم‌ارز، هر دو قاعده توان یکسان در تشخیص افت دارند و تفاوت در «چه چیزی را الزام می‌کنیم» است.

۲.۸ مدل‌های مفهومی برای تحلیل رفتار عامل

برای تحلیل رفتار عامل، یک مدل مفهومی ساده اما کامل لازم است که در همه‌ی فصل‌های بعد به کار رود. این مدل را به‌صورت پنج‌تایی (E, M, P, T, G) می‌توان نوشت (پیشنهاد نگارنده، ع ۴):

- **E (محیط):** مجموعه‌ی سامانه‌ها و داده‌هایی که اقدام‌ها بر آن‌ها اثر می‌گذارند؛
- **M (مدل تصمیم‌گیر):** مدل زبانی به‌همراه دستورالعمل و پارامترهای نمونه‌برداری؛
- **P (سیاست):** قواعدی که تعیین می‌کنند کدام اقدام پیشنهادی اجرا شود؛
- **T (ابزارها و حافظه):** توانمندی‌های کنش و دانش در دسترس؛
- **G (هدف و قیود):** قرارداد وظیفه: هدف، معیار موفقیت و بودجه.

رفتار عامل مسیر σ است که از برهم‌کنش این پنج جزء پدید می‌آید؛ هر آنومالی (فصل ۹) را می‌توان به تغییر در یکی از آن‌ها نسبت داد: توهم در **M**، سیاست نادرست در **P**، شکست ابزار در **T/E**، قرارداد ناقص در **G**. نمونه‌ی اجرایی زیر، همه‌ی این اجزا را در کوچک‌ترین شکل ممکن نشان می‌دهد. این کد بخشی از بسته‌ی مرجع کتاب (code/aorch) است و با ۱۶ آزمون واحد بررسی شده است.

کد ۱-۲ (پایتون ۳/۱۲، فقط کتابخانه‌ی استاندارد؛ گزیده‌ی **agent.py**). حلقه‌ی عامل: هر گام ابتدا بودجه را شارژ می‌کند، سپس پیشنهاد مدل را می‌گیرد، از سیاست می‌گذراند و فقط

→ در صورت مجاز بودن ابزار را از دروازه فراخوانی می‌کند. «مدل» هر تابع (هدف، تاریخچه) پیشنهاد است؛ یک مدل زبانی واقعی با یک کلاینت مناسب همین جایگاه را می‌گیرد.

```

trace.push(root)
status, answer = "failed", ""
seen: dict = {}
if resume:                                     # continue a run
from
    its last checkpoint
        history[:] = resume["history"]; calls[:] = [tuple(c) for c in
resume["calls"]]
        ledger.steps, ledger.tokens, ledger.usd = resume["steps"],
resume["tokens"], resume["usd"]
        seen = {tuple(k): v for k, v in resume["seen"]}
        gateway.import_cache(resume["idempotency"])
        trace.emit("resume", from_step=resume["steps"])
try:
    while True:
        if stop and stop():                     # emergency stop:
checked before every step
            status = "stopped"; trace.emit("stop",
reason="kill_switch"); break
            ledger.charge(steps=1)
            prop = model(contract.goal, history)
            ledger.charge(tokens=prop.tokens)
            trace.emit("decision", step=ledger.steps, proposal=prop.kind,
tool=prop.tool, args=prop.args)
            if prop.kind == "final":
                answer = prop.answer
                status = "success" if contract.success(answer, calls)
else
    "failed"
        break
        sig = (prop.tool, repr(sorted((prop.args or {}).items())))
        seen[sig] = seen.get(sig, 0) + 1
        if seen[sig] > max_repeat:               # repetition guard:
same action again and again
            status = "loop_detected"; trace.emit("guard",
guard="repetition", tool=prop.tool, count=seen[sig]); break
            d = policy.decide(prop.tool, prop.args or {},
contract.allowed_tools)
            trace.emit("policy", decision=d.decision, rule=d.rule_id,
tool=prop.tool)
            if d.decision == "deny":
                history.append({"tool": prop.tool, "error": "denied:" +
d.rule_id}); status = "denied"

```

```
# return the structured refusal to the model; a second
denial stops the task
    if sum(1 for h in history if str(h.get("error",
        "")).startswith("denied")) >= 2:
        break
    status = "failed"; continue
```

مدل در مثال ما یک تابع قطعی است که دقیقاً سه گام را اجرا می‌کند، تا خروجی قابل تکرار و کد قابل آزمون باشد. اجرای مثال (code/examples/ch02_loop.py)

خروجی زیر را تولید کرد:

```
status : success
answer : refunded 40 for order 7214
steps  : 3  tokens: 300  usd: 0.002
task.start  {}
decision    {'proposal': 'tool', 'tool': 'lookup_order'}
policy      {'decision': 'allow', 'rule': 'allow-lookup', 'tool':
'lookup_order'}
tool.result {'tool': 'lookup_order', 'status': 'ok'}
decision    {'proposal': 'tool', 'tool': 'refund'}
policy      {'decision': 'allow', 'rule': 'allow-refund', 'tool':
'refund'}
tool.result {'tool': 'refund', 'status': 'ok'}
decision    {'proposal': 'final', 'tool': ''}
task.end    {'status': 'success'}
```

به ترتیب رویدادها توجه کنید: برای هر اقدام، یک رویداد «تصمیم» و یک رویداد «سیاست» پیش از «نتیجه‌ی ابزار» ثبت شده است. همین ردگیری ساده، پایه‌ی تحلیل در فصل‌های ۷ تا ۱۰ است. محدودیت‌های این نمونه: مدل واقعی نیست، ابزارها ساختگی‌اند، هزینه‌ی هر گام ثابت و فرضی است و مدیریت همروندی ندارد؛ هدفش فقط نمایش ساختار است، نه جایگزینی پلتفرم تولیدی.

جمع‌بندی فصل

عامل هوشمند را بر اساس ویژگی‌های رفتاری‌اش تعریف کردیم: خودمختاری، واکنش‌پذیری، کنش‌گری هدف‌محور و توانایی اجتماعی (Wooldridge & Wooldridge)

Jennings, ۱۹۹۵). در عامل‌های امروز، مدل زبانی هسته‌ی تصمیم است، اما استدلال متنی آن لزوماً وفادار نیست، خوداصلاحی بدون سیگنال بیرونی غیرقابل اتکاست، و بهبود کیفیت با هزینه‌ی بیشتر همراه است. ابزارها مرز ریسک‌اند، حافظه یک مصنوع عملیاتی است و سامانه‌های چندعاملی شکست‌های ساختاری مخصوص خود را دارند. مدل پنج‌تایی (E, M, P, T, G) و حلقه‌ی «پیشنهاد، سیاست، اجرا، مشاهده» چارچوب مفهومی مشترک بقیه‌ی کتاب است.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. چهار ویژگی مفهوم ضعیف عاملیت را بنویسید و برای هر یک مثالی از یک عامل مبتنی بر مدل زبانی بیاورید.
۲. چرا «پیشنهاد» و «اجرا» را از هم جدا می‌کنیم؟ چه خطرهایی در طراحی‌ای وجود دارد که مدل مستقیماً ابزار را فراخوانی کند؟
۳. محدودیت خوداصلاحی مدل چه پیامدی برای طراحی دروازه‌های ارزیابی دارد؟ (Huang et al., ۲۰۲۴)
۴. برای یک وظیفه با $n = 20$ اجرا و $c = 15$ موفقیت، مقادیر $pass^1$ ، $pass^2$ و $pass@2$ را حساب کنید و تفسیر کنید.
۵. در مثال ۱-۲، سه آنومالی بسازید که هر یک به یکی از اجزای (E, M, P, T, G) برگردد.

۶. (عملی) در نمونه‌ی کد، یک رفتار قطعی دیگر برای مدل بنویسید که پس از جست‌وجوی سفارش، بازپرداخت را برای سفارش اشتباه فراخوانی کند. اجرا کنید و تفاوت ردگیری را با اجرای صحیح بنویسید. آیا معیار موفقیت قرارداد، این خطا را

منابع

- Anthropic. (2024, December 19). Building effective agents. <https://www.anthropic.com/engineering/building-effective-agents>
- Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>
- Chen, M., Tworek, J., Jun, H., Yuan, Q., Pinto, H. P. d. O., Kaplan, J., Edwards, H., Burda, Y., Joseph, N., Brockman, G., Ray, A., Puri, R., Krueger, G., Petrov, M., Khlaaf, H., Sastry, G., Mishkin, P., Chan, B., Gray, S., . . . Zaremba, W. (2021). Evaluating large language models trained on code (arXiv:2107.03374). arXiv. <https://doi.org/10.48550/arXiv.2107.03374>
- Huang, J., Chen, X., Mishra, S., Zheng, H. S., Yu, A. W., Song, X., & Zhou, D. (2024). Large language models cannot self-correct reasoning yet. International Conference on Learning Representations (ICLR 2024). arXiv:2310.01798. <https://doi.org/10.48550/arXiv.2310.01798>
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Klittler, H., Lewis, M., Yih, W.-t., Rocktäschel, T., Riedel, S., & Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive NLP tasks. Advances in Neural Information Processing Systems, 33 (NeurIPS 2020). arXiv:2005.11401. <https://doi.org/10.48550/arXiv.2005.11401>
- Liu, N. F., Lin, K., Hewitt, J., Paranjape, A., Bevilacqua, M., Petroni, F., & Liang, P. (2023). Lost in the middle: How language models use long contexts (arXiv:2307.03172). arXiv. <https://doi.org/10.48550/arXiv.2307.03172>
- Model Context Protocol. (2026). Model Context Protocol specification (version 2026-07-28). <https://modelcontextprotocol.io/specification/latest> (accessed 2026-10-21)
- Park, J. S., O'Brien, J. C., Cai, C. J., Morris, M. R., Liang, P., & Bernstein, M. S. (2023). Generative agents: Interactive simulacra of human behavior (arXiv:2304.03442). arXiv. <https://doi.org/10.48550/arXiv.2304.03442>
- Saltzer, J. H., & Schroeder, M. D. (1975). The protection of information in computer systems. Proceedings of the IEEE, 63(9), 1278-1308.
- Schick, T., Dwivedi-Yu, J., Dessì, R., Raileanu, R., Lomeli, M., Zettlemoyer, L., Cancedda, N., & Scialom, T. (2023). Toolformer: Language models can teach themselves to use

- tools (arXiv:2302.04761). arXiv. <https://doi.org/10.48550/arXiv.2302.04761>
- Shinn, N., Cassano, F., Berman, E., Gopinath, A., Narasimhan, K., & Yao, S. (2023). Reflexion: Language agents with verbal reinforcement learning (arXiv:2303.11366). arXiv. <https://doi.org/10.48550/arXiv.2303.11366>
- Wang, X., Wei, J., Schuurmans, D., Le, Q., Chi, E., Narang, S., Chowdhery, A., & Zhou, D. (2023). Self-consistency improves chain of thought reasoning in language models. International Conference on Learning Representations (ICLR 2023). arXiv:2203.11171. <https://doi.org/10.48550/arXiv.2203.11171>
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>
- Wei, J., Wang, X., Schuurmans, D., Bosma, M., Ichter, B., Xia, F., Chi, E., Le, Q., & Zhou, D. (2022). Chain-of-thought prompting elicits reasoning in large language models (arXiv:2201.11903). arXiv. <https://doi.org/10.48550/arXiv.2201.11903>
- Wooldridge, M., & Jennings, N. R. (1995). Intelligent agents: Theory and practice. The Knowledge Engineering Review, 10(2), 115-152. <https://doi.org/10.1017/S0269888900008122>
- Yao, S., Shinn, N., Razavi, P., & Narasimhan, K. (2024). tau-bench: A benchmark for tool-agent-user interaction in real-world domains (arXiv:2406.12045). arXiv. <https://doi.org/10.48550/arXiv.2406.12045>
- Yao, S., Zhao, J., Yu, D., Du, N., Shafran, I., Narasimhan, K., & Cao, Y. (2022). ReAct: Synergizing reasoning and acting in language models (arXiv:2210.03629). arXiv. <https://doi.org/10.48550/arXiv.2210.03629>

چرا عملیات سنتی برای عامل‌ها کافی نیست؟

در فصل ۱ دیدیم که مفروضات DevOps و MLOps با ورود عامل‌ها فرو می‌ریزد. این فصل همان ادعا را با شواهد و به‌صورت ریزتر می‌آزماید: دقیقاً کدام سنجه‌های متعارف عملیاتی نمی‌توانند رفتار نادرست عامل را ببینند، چه نوع شکست‌هایی با ابزارهای موجود پنهان می‌مانند و چه الزاماتی از آن نتیجه می‌شود. خروجی فصل فهرستی از الزامات است که فصل‌های بعدی به‌ترتیب پاسخ می‌دهند.

اهداف فصل. (۱) نشان دهیم چهار سیگنال طلایی پایش چه شکست‌هایی را نمی‌بینند؛ (۲) منابع غیرقطعی بودن مسیر اجرا را تحلیل کنیم؛ (۳) شکست‌های استدلال، برنامه‌ریزی، ابزار و حافظه را طبقه‌بندی کنیم؛ (۴) تفاوت شکست زیرساختی و شکست رفتاری را تعریف کنیم؛ (۵) از این تحلیل، الزامات یک چارچوب عملیاتی ویژه‌ی عامل‌ها را استخراج کنیم.

۳.۱ محدودیت معیارهای متعارف سلامت سرویس

چهار سیگنال طلایی، ستون فقرات پایش سرویس‌های توزیع‌شده‌اند: تأخیر (زمان سرویس‌دهی به یک درخواست)، ترافیک (میزان تقاضا)، خطاها (نرخ درخواست‌های ناموفق) و اشباع (میزان پر بودن مهم‌ترین منابع) (Ewaschuk, ۲۰۱۶). این چهار سنجه برای سامانه‌ای که وظیفه‌اش «پاسخ دادن به درخواست» است، بسیار مؤثرند. اما

سه ایراد ساختاری در مواجهه با عامل‌ها دارند.

ایراد اول: درستی را نمی‌سنجند. هر چهار سیگنال درباره‌ی «چگونگی اجرا» اند،

نه «درستی نتیجه». نویسندگی همان فصل، شکست ضمنی را به رسمیت می‌شناسد، یعنی پاسخی موفق که محتوای نادرستی دارد (Ewaschuk, ۲۰۱۶)، اما در سامانه‌های سنتی این دسته معمولاً با واری‌های اختصاصی (پایش جعبه‌سیاه با ورودی‌های شناخته‌شده) پوشش داده می‌شود. در عامل‌ها، مجموعه‌ی ورودی‌های ممکن نامحدود و درستی وابسته به زمینه است؛ واری‌ها از پیش ساخته نمی‌تواند همه‌ی حالت‌ها را پوشانند.

ایراد دوم: واحد سنجش نامناسب است. سیگنال‌های بالا بر «درخواست» تعریف

می‌شوند. اما واحد طبیعی کار عامل وظیفه است که از چندین گام، فراخوانی مدل و فراخوانی ابزار تشکیل می‌شود. نرخ خطای هر فراخوانی HTTP می‌تواند صفر باشد، در حالی که وظیفه نه درست پایان یافته و نه به درستی متوقف شده است.

ایراد سوم: وضعیت درونی را نمی‌بینند. وانگ و همکاران تأکید می‌کنند که برای

سامانه‌های عامل محور، افزون بر سنجه‌ها، لاگ‌ها و ردگیری‌های سنتی (که در عملیات مبتنی بر OpenTelemetry رایج‌اند)، باید مازول‌های مربوط به خود عامل نیز پایش شود: برای بخش مدل زبانی، مواردی مانند پارامترها، نگاشت‌های توجه و لوجیت‌های توکن، و برای بخش عامل، نقاط ذخیره‌ی وضعیت مانند حافظه و محیط در هر گام (Wang et al., ۲۰۲۵). این نیازها در سنجه‌ها و لاگ‌های سرویس‌گرا پوشش داده نمی‌شوند.

جدول ۳-۱ هر سیگنال را با شکلی از شکست رفتاری مقایسه می‌کند که از آن می‌گذرد.

جدول ۳-۱. چهار سیگنال طلایی و شکست‌های رفتاری که نمی‌بینند (منبع: نگارنده، بر پایه‌ی Ewaschuk, ۲۰۱۶)

سیگنال	آنچه می‌سنجد	شکست رفتاری که پنهان می‌ماند
تأخیر	زمان پاسخ هر درخواست	عامل سریع و با اطمینان اقدام اشتباه انجام می‌دهد؛ تأخیر کم نشانه‌ی درستی نیست
ترافیک	تعداد درخواست‌ها	حلقه‌ی بی‌پایان گام‌های موفق، ترافیک عادی تولید می‌کند ولی بودجه را می‌سوزاند
خطاها	درخواست‌های ناموفق	پاسخ ۲۰۰ با تصمیم نادرست؛ ابزار «موفق» با پارامتر اشتباه
اشباع	مصرف منابع	مصرف توکن و هزینه‌ی مدل، که به منبع محاسباتی سنتی نگاشت نمی‌شود

۳.۲ غیرقطعی بودن خروجی و مسیر اجرای عامل

سه پیامد عملی از غیرقطعی بودن عامل می‌آید. اول: آزمون یک‌باره گمراه‌کننده است. معیار τ -bench این نکته را به‌صورت کمی نشان داد: در وظایف خرده‌فروشی، مدل مورد مطالعه حدود ۶۱٪ از وظایف را با تلاش یک‌باره حل کرد، اما احتمال حل همان وظیفه در هر هشت تلاش مستقل به حدود ۲۵٪ رسید (Yao et al., ۲۰۲۴). گزارش نتیجه‌ی یک‌باره نشان نمی‌دهد که کاربر در تلاش بعدی چه تجربه‌ای خواهد داشت.

دوم: هشدار مبتنی بر آستانه‌ی ثابت کم‌کاربرد می‌شود. در سامانه‌ی قطعی، انحراف از مقدار پایه معنای روشنی دارد. در عامل، تغییرپذیری ذاتی وجود دارد و مرز میان «تنوع طبیعی» و «انحراف» باید آماری تعریف شود. نمونه: تعداد گام‌های میانگین یک وظیفه ممکن است میان دو نسخه‌ی مدل پایه تغییر کند، بی‌آنکه خطایی رخ داده

باشد.

سوم: بازتولید شکست دشوار است. در عملیات سنتی، «بازتولید» یعنی اجرای دوباره‌ی همان ورودی روی همان نسخه. در عامل این کار تنها وقتی ممکن است که تمام ورودی‌های مؤثر، یعنی دستورالعمل، زمینه‌ی بازیابی‌شده، نتیجه‌ی هر ابزار و پارامترهای نمونه‌برداری ثبت شده باشند. بنابراین ردگیری کامل (فصل ۷) پیش‌نیاز عیب‌یابی است، نه یک امکان تکمیلی.

۳.۳ خطاهای استدلال، برنامه‌ریزی و انتخاب ابزار

وانگ و همکاران، آنومالی‌های درون یک عامل را به پنج دسته تقسیم می‌کنند: آنومالی‌های استدلال، برنامه‌ریزی، کنش، حافظه و محیط (Wang et al., ۲۰۲۵). سه دسته‌ی نخست تصمیم را هدف می‌گیرند.

آنومالی‌های استدلال. مهم‌ترین نمونه، توهم (hallucination) است: تولید محتوایی که با واقعیت یا منطق هم‌خوان نیست. نویسندگان توهم را «تصورات نابهنجاری که با منطق و واقعیت عادی ناسازگارند و در استفاده از مدل‌های زبانی فعلاً گریزناپذیرند» توصیف می‌کنند و دلیل آن را وابستگی به داده‌های آموزش و فراموشی دانش و منسوخ شدن اطلاعات می‌دانند (Wang et al., ۲۰۲۵).

آنومالی‌های برنامه‌ریزی. به‌گفته‌ی همین مرور، به دلیل ماهیت احتمالاتی مدل‌ها، این آنومالی‌ها اجتناب‌ناپذیرند و غالباً از توهم در مرحله‌ی برنامه‌ریزی برمی‌خیزند. نمونه‌ها شامل پیش‌بینی نادرست امکان‌پذیری یک اقدام، اقدام‌های ناسازگار با استدلال پیشین، طرح‌های نامعقول و تعامل با موجودیت‌های ناموجود مثل ابزار یا پارامتر نادرست است (Wang et al., ۲۰۲۵).

آنومالی‌های کنش. اقدام‌های اولیه‌ی عامل با فراخوانی تابع تحقق می‌یابد. به گفته‌ی همان منبع، رابط‌های غیراستاندارد و ناسازگار زمینه‌ساز آنومالی‌اند و خطرهایی مثل «شکستن محدودیت» (jailbreak) در فراخوانی تابع نیز گزارش شده است، که در آن مهاجم با درخواستی خاص، مدل را به فراخوانی توابع حساس یا دور زدن محدودیت‌ها وامی‌دارد. پروتکل MCP رابط ابزارها را استاندارد کرده اما «معجزه‌گر» نیست و تغییرات پیکربندی سرویس‌دهنده‌ی MCP اغلب به آنومالی‌های کنشی می‌انجامد (Wang et al., ۲۰۲۵).

مثال ۳-۱ (مثال مهندسی، ساختگی): اجرای «سبز» با اقدام نادرست. دستیار پشتیبانی پیام مشتری را می‌خواند: «سفارش ۷۲۱۴ را لغو کنید، اما سفارش ۷۲۴۱ را نگه دارید.» عامل شماره‌ها را جابه‌جا درک می‌کند و ابزار لغو را برای ۷۲۴۱ فراخوانی می‌کند. ابزار با کد ۲۰۰ و پیام «لغو شد» پاسخ می‌دهد. هیچ استثنایی، تأخیر غیرعادی یا نرخ خطایی ثبت نمی‌شود. تنها شواهد قابل تشخیص: (۱) در ردگیری، شماره‌ی ورودی ابزار با شماره‌ی هدف قرارداد وظیفه ناسازگار است؛ (۲) یک ارزیاب خودکار، که ورودی ابزار را با متن پیام مقایسه می‌کند، ناسازگاری را می‌یابد؛ (۳) مشتری بعداً شکایت می‌کند. فقط دو مورد نخست در معماری مرجع کتاب پیشگیرانه‌اند.

۳.۴ خطاهای وابسته به حافظه و زمینه

حافظه و زمینه، دسته‌ی چهارم آنومالی‌ها هستند. مرور وانگ و همکاران مشخص می‌کند که حافظه‌ی کوتاه‌مدت یعنی زمینه‌ی مدل، حتی با پنجره‌های بزرگ‌تر، ممکن است کفایت نکند و پنجره‌ی لغزان می‌تواند اطلاعات اولیه مثل دستورالعمل تکمیل وظیفه را از دست بدهد؛ و حتی وقتی اطلاعات در زمینه‌اند، مدل‌ها اغلب اطلاعات میانه‌ی زمینه‌های بلند را نادیده می‌گیرند (Wang et al., ۲۰۲۵؛ Liu et al., ۲۰۲۳).

حافظه‌ی بلندمدت که با بازیابی (RAG) پر می‌شود نیز محدودیت‌های دقت بازیابی و قابلیت اطمینان تولید دارد؛ حساسیت به نویز و تعارض میان دانش درونی و بیرونی از جمله‌ی این محدودیت‌هاست (Wang et al., ۲۰۲۵).

پیامد عملیاتی این است که زمینه‌ی ورودی هر تصمیم، بخشی از «علت» آن تصمیم است. اگر ثبت نشده باشد، تحلیل علت ریشه‌ای ناممکن می‌شود. مثلاً شکستی که ریشه‌اش بازیابی یک سند منسوخ است، در لایه‌ی مدل قابل تشخیص نیست.

۳.۵ شکست‌های زنجیره‌ای در اجرای وظایف

چون هر گام عامل به نتیجه‌ی گام پیشین وابسته است (فصل ۲)، شکست‌ها منتشر می‌شوند. مقاله‌ی وانگ و همکاران، بر پایه‌ی کار دیگری، گام آنومال را چنین تعریف می‌کند: اگر مسیر اجرای یک وظیفه σ شکست‌خورده باشد ($f(\sigma) = 0$) و بتوان با تغییر گام i به یک گام عادی، مسیر را موفق کرد ($f(g(\sigma, i)) = 1$)، آنگاه گام i گام آنومال است. آنان آنومالی‌ها را در سه مرحله می‌بینند: پیش از اجرا (مشخصات وظیفه و پیکربندی)، حین اجرا (استدلال، برنامه‌ریزی و ...) و پس از اجرا (توقف زودهنگام یا توقف‌ناپذیری) (Wang et al., ۲۰۲۵). این تعریف دو نکته دارد: شکست یک مسیر معمولاً به یک «نقطه‌ی علی» برمی‌گردد، و برای یافتن آن باید مسیر کامل در دسترس باشد.

همین مقاله دو نمونه‌ی ساده اما گویا ارائه می‌کند: در یکی، عامل هنگام ترکیب نتایج جست‌وجوی وب دچار توهم می‌شود و پاسخ نادرست می‌دهد؛ در دیگری، در یک شبیه‌سازی مزایده، حمله به یک خریدار باعث پیشنهادهای بسیار بالا می‌شود و کل مزایده فرو می‌پاشد (Wang et al., ۲۰۲۵). نمونه‌ی دوم نشان می‌دهد که در

سامانه‌های چندعاملی، اختلال در یک نقطه می‌تواند کل سامانه را بی‌ثبات کند، چیزی شبیه شکست آبخاری در معماری میکروسرویس، با این تفاوت که کانال انتشار، زبان طبیعی است.

تحلیل ۱۶۴۲ ردگیری چندعاملی نیز الگوهای تکرارشونده‌ای در شکست نشان می‌دهد: ۱۴ حالت شکست در سه دسته (Cemri et al., ۲۰۲۵). از میان آن‌ها، سه حالت برای بحث زنجیره‌ای بودن مهم‌اند: «تکرار گام»، «از دست رفتن تاریخچه‌ی گفت‌وگو» و «تأیید ناقص یا نادرست»؛ یعنی شکست‌هایی که نه فقط در یک گام، بلکه در ارتباط میان گام‌ها و واریسی نتایج رخ می‌دهند. فصل ۹ این طبقه‌بندی را به‌طور کامل به کار می‌گیرد.

۳.۶ تفاوت خطای زیرساختی با خطای رفتاری

برای مهندسی عملیات، تمایز زیر پایه‌ی بسیاری از تصمیم‌ها در فصل‌های بعد است.

تعریف (۴ع). شکست زیرساختی وقتی رخ می‌دهد که یک مؤلفه‌ی نرم‌افزاری یا سخت‌افزاری نتواند کاری را که مشخصات آن می‌گوید انجام دهد (خرابی، تأخیر، قطع شبکه). شکست رفتاری وقتی رخ می‌دهد که همه‌ی مؤلفه‌ها مطابق مشخصات خودشان کار کنند اما تصمیم یا اقدام عامل با هدف و وظیفه یا قیود آن ناسازگار باشد.

دلیل اهمیت این تمایز آن است که شکست‌های رفتاری، تشخیص و رفع متفاوتی دارند. وانگ و همکاران در مقایسه‌ی عملیات سنتی و عملیات عامل‌ها چهار تفاوت را برمی‌شمارند. در پایش، داده‌های سنتی (سنجه، لاگ، ردگیری) باید با داده‌های ماژول‌های عامل تکمیل شوند. در تشخیص **آنومالی**، در سامانه‌ی قطعی داده‌ی پایش

قابل اتکا فرض می‌شود، ولی در عامل خود داده را مدل زبانی تولید می‌کند و درستی آن تضمین شده نیست؛ پس تشخیص باید هم معقول بودن تولید داده و هم وضعیت سامانه را بسنجد. در **تحلیل علت ریشه‌ای**، به جای سرویس، پاد یا کد، ممکن است باید یک اقدام مشخص یا یک توهم در گام مشخصی از مدل را پیدا کرد. در رفع، به جای اصلاح قطعی بر پایه‌ی دانش دامنه، فرایندی طولانی و آزمایشی نیاز است که ممکن است آزمون A/B مداوم برای بهینه‌سازی دستورالعمل شامل شود (Wang et al., ۲۰۲۵).

جدول ۳-۲. شکست زیرساختی در برابر شکست رفتاری (منبع: نگارنده، با اتکا بر Wang et al., ۲۰۲۵)

بعد	شکست زیرساختی	شکست رفتاری
نشانه	استثنا، تأخیر، قطع	اجرای بدون خطا با اقدام یا پاسخ نادرست
محل علت	مؤلفه یا شبکه	گام تصمیم، زمینه یا قرارداد وظیفه
تشخیص	سنجه و هشدار	ردگیری تصمیم و ارزیابی رفتاری
بازیابی	تلاش مجدد، جایگزینی مؤلفه	اصلاح دستورالعمل/سیاست، جبران اثر، توقف
قابلیت بازتولید	معمولاً بالا	مشروط به ثبت ورودی‌های مؤثر

۳.۷ ریسک اقدامات خارجی و پیامدهای واقعی

وقتی شکست رفتاری با اقدام بیرونی همراه شود، پیامد از «پاسخ بد» به «زیان واقعی» می‌رسد. دو چارچوب امنیتی این ریسک را روشن می‌کنند.

پروژه‌ی OWASP برای امنیت هوش مصنوعی مولد، «اختیار بیش‌ازحد»

(Excessive Agency) را در فهرست ۲۰۲۵ خود (LLM06) آورده است. توصیف آن چنین است: سامانه‌ی مبتنی بر مدل زبانی توانایی اقدام دارد (فراخوانی توابع و ابزارها) و آسیب وقتی رخ می‌دهد که خروجی مدل غیرمنتظره، مبهم یا دست‌کاری‌شده باشد؛ محرک‌ها می‌توانند توهم، تزریق مستقیم یا غیرمستقیم دستورالعمل، یا افزونه یا عامل همتای آلوده باشند. سه علت ریشه‌ای آن را **عملکرد بیش‌ازحد، مجوز بیش‌ازحد و خودمختاری بیش‌ازحد** می‌شمارد، یعنی اقدام‌های پراثر بدون تأیید مستقل (OWASP GenAI Security Project, ۲۰۲۵).

در همان فهرست، **تزریق دستورالعمل (LLM01)** رتبه‌ی اول است؛ تزریق مستقیم وقتی ورودی کاربر مدل را منحرف می‌کند و تزریق غیرمستقیم وقتی دستورهای مخرب از محتوای بیرونی مثل صفحه‌ی وب یا فایل وارد می‌شوند (OWASP GenAI Security Project, ۲۰۲۵). گرشاک و همکاران نشان دادند که برنامه‌های مجهز به مدل زبانی که داده‌ی بازیابی‌شده را پردازش می‌کنند، با تزریق غیرمستقیم در معرض سوءاستفاده‌ی واقعی‌اند، زیرا مرز میان «داده» و «دستور» در متن محو می‌شود (Greshake et al., ۲۰۲۳). پرز و ریبرو نیز از زودتر، دو الگوی حمله‌ی «هدف‌ربایی» و «نشت دستورالعمل» را در مدل‌های زبانی مطالعه کردند (Perez & Ribeiro, ۲۰۲۲). بنچمارک AgentDojo هم محیطی پویا برای ارزیابی حمله‌ها و دفاع‌ها علیه عامل‌های مبتنی بر مدل زبانی ساخته است (Debenedetti et al., ۲۰۲۴).

از دید عملیات، نکته‌ی اصلی این است که کاهش آسیب در این فهرست‌ها دو سطح دارد: **پیشگیری** (کمینه‌سازی عملکرد و مجوز ابزارها، اعمال مجوز در سامانه‌ی پایین‌دست به‌جای اتکا به تصمیم مدل، تأیید انسانی برای اقدام‌های پراثر)

و محدودسازی آسیب (ثبت و پایش فعالیت ابزارها، محدودیت نرخ) (OWASP GenAI Security Project, ۲۰۲۵). هر دو سطح را فصل ۱۰ به معماری مرجع وصل می‌کند.

۳.۸ نیازمندی‌های چارچوب عملیاتی ویژه‌ی عامل‌ها

از تحلیل این فصل، ده نیازمندی استخراج می‌شود که چارچوب پیشنهادی کتاب باید برآورده کند. این فهرست نتیجه‌ی استدلال نگارنده است (ع ۴) و در فصل ۱۴ به‌عنوان مبنای ارزیابی چارچوب به کار می‌رود.

جدول ۳-۳. نیازمندی‌های استخراج‌شده از تحلیل فصل (منبع: نگارنده)

شناسه	نیازمندی	فصل پاسخ
R1	قرارداد صریح وظیفه و معیار موفقیت، شامل قیود و بودجه	۶
R2	ردگیری ساخت‌یافته‌ی تصمیم، زمینه، ابزار و نتیجه برای هر وظیفه	۷
R3	قابلیت بازپخش و بازسازی مسیر برای عیب‌یابی	۷
R4	ارزیابی رفتاری تکرارشونده و آماری، نه فقط آزمون یک‌باره	۸
R5	طبقه‌بندی شکست‌ها و ارتباط هر طبقه با تشخیص و بازایی	۹
R6	مرز روشن میان پیشنهاد مدل و اجرای اقدام، با سیاست پیش از اجرا	۵ و ۱۰
R7	حداقل اختیار، اعمال مجوز بیرونی و تأیید انسانی برای اقدام‌های پرائر	۱۰
R8	بودجه‌ی گام، توکن، زمان و هزینه به‌عنوان قید اجرا	۱۲
R9	اجرای قابل‌بازایی، تلاش مجدد ایمن و جبران اثرها	۹ و ۱۱
R10	حاکمیت و حسابرسی: مسئولیت‌پذیری و حفظ شواهد	۱۰ و ۱۳

جمع‌بندی فصل

چهار سیگنال طلایی، که برای سرویس‌های درخواست‌محور عالی‌اند، سه ضعف ساختاری در برابر عامل‌ها دارند: درستی را نمی‌سنجند، واحد «وظیفه» را نمی‌شناسند و وضعیت درونی عامل را نمی‌بینند. غیرقطعی بودن مسیر اجرا آزمون یک‌باره و هشدار با آستانه‌ی ثابت را بی‌اثر می‌کند و بازتولید شکست را مشروط به ثبت کامل ورودی‌ها می‌سازد. آنومالی‌های استدلال، برنامه‌ریزی، کنش و حافظه، شکست‌های رفتاری با اجرای بدون خطا تولید می‌کنند که به‌صورت زنجیره‌ای منتشر می‌شوند. چون عامل اثر بیرونی دارد، ریسک آن از پاسخ بد به زیان واقعی ارتقا می‌یابد. ده نیازمندی R1 تا R10 نتیجه‌ی این تحلیل است و محور فصل‌های بعدی را تعیین می‌کند.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. برای هر یک از چهار سیگنال طلایی، یک شکست رفتاری مثال بزنید که آن را نمی‌بیند و یک سنجه‌ی تکمیلی پیشنهاد دهید.
۲. چرا گزارش «نرخ موفقیت یک‌باره» برای یک عامل گمراه‌کننده است؟ داده‌ی τ -bench را در استدالاتان به کار ببرید و محدودیت تعمیم آن را بنویسید.
۳. «گام آنومال» را طبق تعریف وانگ و همکاران بنویسید. برای مثال ۱-۳ مسیر σ را بنویسید و گام آنومال را مشخص کنید.
۴. سه شکست زیرساختی و سه شکست رفتاری برای یک عامل پشتیبانی نام ببرید. برای هر یک، روش تشخیص و بازیابی متفاوت را توضیح دهید.

۵. سه علت ریشه‌ای «اختیار بیش‌ازحد» OWASP را در یک عامل مدیریت تیکت پشتیبانی شناسایی کنید و برای هر یک یک کنترل پیشگیرانه و یک کنترل محدودکننده آسیب پیشنهاد دهید.

۶. نیازمندی‌های R1 تا R10 را بررسی کنید. به نظر شما کدام یک را فراموش کرده‌ایم؟ آن را با استدلال به فهرست اضافه کنید.

منابع

- Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>
- Debenedetti, E., Zhang, J., Balunović, M., Beurer-Kellner, L., Fischer, M., & Tramèr, F. (2024). AgentDojo: A dynamic environment to evaluate prompt injection attacks and defenses for LLM agents (arXiv:2406.13352). arXiv. <https://doi.org/10.48550/arXiv.2406.13352>
- Ewaschuk, R. (2016). Monitoring distributed systems. In B. Beyer, C. Jones, J. Petoff, & N. R. Murphy (Eds.), Site reliability engineering: How Google runs production systems (Chapter 6). O'Reilly Media. <https://sre.google/sre-book/monitoring-distributed-systems/>
- Greshake, K., Abdelnabi, S., Mishra, S., Endres, C., Holz, T., & Fritz, M. (2023). Not what you've signed up for: Compromising real-world LLM-integrated applications with indirect prompt injection (arXiv:2302.12173). arXiv. <https://doi.org/10.48550/arXiv.2302.12173>
- Liu, N. F., Lin, K., Hewitt, J., Paranjape, A., Bevilacqua, M., Petroni, F., & Liang, P. (2023). Lost in the middle: How language models use long contexts (arXiv:2307.03172). arXiv. <https://doi.org/10.48550/arXiv.2307.03172>
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Perez, F., & Ribeiro, I. (2022). Ignore previous prompt: Attack techniques for language models. ML Safety Workshop, NeurIPS 2022. arXiv:2211.09527. <https://doi.org/10.48550/arXiv.2211.09527>

Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>

Yao, S., Shinn, N., Razavi, P., & Narasimhan, K. (2024). tau-bench: A benchmark for tool-agent-user interaction in real-world domains (arXiv:2406.12045). arXiv. <https://doi.org/10.48550/arXiv.2406.12045>

بخش دوم: بنیادهای مفهومی و معماری AgentOps

تعریف، اصول و مرزهای AgentOps

یک رشته‌ی مهندسی وقتی شکل می‌گیرد که بتواند سه پرسش را پاسخ دهد: موضوع کارش چیست، چه اصولی راهنمای تصمیم‌هایش است و مرزش با رشته‌های همسایه کجاست. فصل‌های ۱ تا ۳ مسئله را طرح کردند؛ این فصل اصطلاحات و ساختار مفهومی لازم برای پاسخ را فراهم می‌کند. هرچه در این فصل «تعریف» نامیده می‌شود، تعریف کاری این کتاب است، نه استاندارد رسمی. همان‌جا که ادبیات تعریف مشخصی دارد، آن را با منبع آورده‌ایم و جایی که تعریف از نگارنده است، با برچسب (۴ع) مشخص شده است.

اهداف فصل. (۱) تعریف عملیاتی AgentOps را بیان کنیم؛ (۲) آن را از DevOps، MLOps، LLMops و AIOps متمایز کنیم؛ (۳) هفت اصل بنیادین مهندسی عامل‌ها را صورت‌بندی کنیم؛ (۴) واحدهای اصلی مدیریت را تعریف کنیم؛ (۵) مسئولیت‌های تیم‌ها و مرز خودمختاری با کنترل انسانی را روشن کنیم؛ (۶) فرضیه‌های فنی کتاب را ثبت کنیم.

۴.۱ تعریف عملیاتی AgentOps

از ادبیات، دو تعریف نزدیک را پیش‌تر دیدیم. وانگ و همکاران AgentOps را چارچوبی عملیاتی می‌دانند که مراحل پیش از اجرا، اجرا و پس از اجرا را در بر می‌گیرد و چهار مرحله دارد: پایش، تشخیص آنومالی، تحلیل علت ریشه‌ای و رفع (Wang et al., ۲۰۲۵). دانگ و همکاران آن را پارادایمی تخصصی از DevOps برای عامل‌ها

می‌دانند که مشاهده‌پذیری مصنوعات عامل را در سراسر چرخه عمر محور می‌گیرد (Dong et al., ۲۰۲۴). تعریف زیر، که در ادامه‌ی کتاب به آن ارجاع می‌دهیم، تلفیقی از این دو است و دو عنصر دیگر می‌افزاید.

تعریف (ع۴): AgentOps. AgentOps مجموعه‌ی روش‌ها، مصنوعات و کنترل‌های مهندسی است که رفتار عامل‌های هوشمند را در سراسر چرخه عمر آن‌ها تعریف‌پذیر، مشاهده‌پذیر، سنجش‌پذیر، محدود‌پذیر و بازیابی‌پذیر می‌کند، به‌گونه‌ای که استقرار آن‌ها در محیط واقعی با شواهد توجیه شود. واحد مدیریت آن **رفتار عامل** است: دنباله‌ی تصمیم‌ها و اقدام‌هایی که برای تحقق یک هدف تحت قیود مشخص انجام می‌شود.

پنج صفت در این تعریف، پنج قابلیت را نام می‌برند که فصل‌های بعد هر یک را بسط می‌دهند:

- **تعریف‌پذیر:** رفتار مورد انتظار با قرارداد وظیفه و قرارداد رفتاری مشخص می‌شود (فصل ۶).

- **مشاهده‌پذیر:** تصمیم‌ها، زمینه‌ها و اقدام‌ها ردگیری می‌شوند (فصل ۷).

- **سنجش‌پذیر:** کیفیت رفتار با ارزیابی تکرارشونده و آماری اندازه‌گیری می‌شود (فصل ۸).

- **محدود‌پذیر:** اختیار، بودجه و دسترسی عامل با سیاست مهار می‌شود (فصل‌های ۱۰ و ۱۲).

- **بازیابی‌پذیر:** شکست تشخیص داده می‌شود و اجرا بازیابی، جبران یا متوقف می‌شود (فصل ۹).

دو افزوده‌ی ما نسبت به دو تعریف ادبیات، **قرارداد رفتاری** (پیش از اجرا) و **سیاست و بودجه‌ی اجرا** (حین اجرا) است. در مدل چهارمرحله‌ای وانگ و همکاران،

پیش از اجرا بیشتر شامل مشخصات وظیفه و پیکربندی به‌عنوان منبع آنومالی دیده می‌شود (Wang et al., ۲۰۲۵)؛ ما آن را به یک مصنوع مهندسی صریح و آزمون‌پذیر ارتقا می‌دهیم.

۴.۲ تمایز AgentOps، MLOps، LLMOps و AIOps

پنج اصطلاح هم‌خانواده در گفت‌وگوهای فنی به‌کار می‌روند و خلط آن‌ها رایج است. جدول ۴-۱ تمایزها را بر پایه‌ی «موضوع مورد عملیات» ثبت می‌کند. معیار اصلی تمایز در ادبیات نیز همین است: وانگ و همکاران تأکید می‌کنند که تفاوت AgentOps با عملیات سنتی، مانند AIOps، در ماهیت موضوع عملیات است (Wang et al., ۲۰۲۵).

جدول ۴-۱. تمایز پنج «Ops» بر اساس موضوع عملیات (منبع: نگارنده، با اتکا بر Wang et al., ۲۰۲۵؛ Kreuzberger et al., ۲۰۲۲)

اصطلاح	موضوع عملیات	ابزار یا هدف اصلی	نسبت با AgentOps
DevOps	تحویل و بهره‌برداری نرم‌افزار	خط لوله‌ی استقرار، پایش سرویس	پایه؛ AgentOps از آن وام می‌گیرد و گسترش می‌دهد
MLOps	چرخه عمر مدل‌های یادگیری ماشین	نسخه‌بندی داده/مدل، بازآموزی، پایش	AgentOps از اصول MLOps (ردگیری، بازخورد) استفاده می‌کند
LLMOps	کاربرد مدل‌های زبانی در محصول	مدیریت دستورالعمل، ارزیابی خروجی، هزینه‌ی توکن	زیرمجموعه‌ی لازم: عامل بدون آن ممکن نیست، ولی کافی نیست

اصطلاح	موضوع عملیات	ابزار یا هدف اصلی	نسبت با AgentOps
AIOps	استفاده از هوش مصنوعی برای عملیات فناوری اطلاعات	تشخیص آنومالی در سنجه‌ها و لاگ‌ها	جهت معکوس: AIOps ابزار عملیات است؛ AgentOps عملیات خود عامل است
AgentOps	رفتار عامل‌های خودمختار	قرارداد، ردگیری، ارزیابی، سیاست، بودجه	موضوع این کتاب

نکته‌ی ظریف، جهت رابطه‌ی AIOps و AgentOps است. در AIOps، هوش مصنوعی ابزار عملیات است، مثلاً برای یافتن آنومالی در سنجه‌های یک سامانه‌ی میکروسرویس. در AgentOps، هوش مصنوعی موضوع عملیات است: خود عامل باید پایش، ارزیابی و مهار شود. ممکن است یک سامانه‌ی عملیاتی با عامل‌ها کار کند (عامل‌های SRE) و آنگاه هر دو مفهوم هم‌زمان کاربرد دارد: AIOps با عامل، و AgentOps برای همان عامل.

درباره‌ی «LLMOps» لازم است صادق باشیم: برخلاف MLOps، که تعریف رسمی مبتنی بر مرور ادبیات دارد (Kreuzberger et al., ۲۰۲۲)، این اصطلاح بیشتر برجسبی صنعتی است و تعریف علمی واحدی که در این بررسی راستی‌آزمایی شده باشد نداریم. دانگ و همکاران مشاهده می‌کنند که ابزارهای موجود LLMOps و DevOps برای عامل‌ها عمدتاً بر سنجه‌های ویژه‌ی مدل زبانی و مدیریت دستورالعمل متمرکزند (Dong et al., ۲۰۲۴)؛ ما نیز در این کتاب LLMOps را به همین معنا می‌گیریم.

اصطلاح نزدیک دیگری که در ادبیات اخیر دیده می‌شود، «عملیات سامانه‌های

عامل» (Agent System Operations) است که چارچوب چهار مرحله‌ی پایش، تشخیص آنومالی، تحلیل مبتنی بر مکان‌یابی علت و رفع را به کار می‌برد (Wang et al., ۲۰۲۶). تفاوت واژه‌گانی میان «تحلیل علت» و «مکان‌یابی علت» در دو اثر دیده می‌شود و باید در ارجاع به دقت رعایت شود.

۴.۳ اهداف و اصول بنیادین مهندسی عامل‌ها

هفت اصل زیر، تصمیم‌های طراحی معماری مرجع (فصل ۵) را هدایت می‌کنند. همه‌ی آن‌ها پیشنهاد نگارنده‌اند (ع ۴)، اما بخشی بر اصول شناخته‌شده‌ی مهندسی امن و قابل‌اتکا بنا شده‌اند و آن را ذکر می‌کنیم.

۱. رفتار واحد مدیریت است. عامل را با رفتار مورد انتظار (قرارداد رفتاری) تعریف می‌کنیم و می‌سنجیم، نه فقط با پیکربندی مدل یا نسخه‌ی کد. دلیل: در عامل، رفتار نتیجه‌ی تعامل مدل، دستورالعمل، زمینه و ابزارهاست (فصل ۱ و ۲).

۲. شواهد پیش از اعتماد. هیچ تصمیم یا اقدامی بدون رویداد قابل‌بازسازی انجام نمی‌شود. اعتماد به عامل ثمره‌ی شواهد قابل‌بررسی است، نه اطمینان به مدل. این اصل با نیازمندی‌های R2 و R3 (فصل ۳) منطبق است.

۳. حداقل اختیار. هر اقدام بیرونی باید از دروازه‌ی ابزار و سیاست بگذرد و ابزارها و مجوزها به‌اندازه‌ی نیاز محدود شوند. این اصل ریشه در اصل «حداقل امتیاز» و «پیش‌فرض ایمن» در طراحی سامانه‌های امن دارد (Saltzer & Schroeder, ۱۹۷۵)، و با راهکارهای OWASP برای مقابله با اختیار بیش‌ازحد هم‌خوان است (OWASP, GenAI Security Project, ۲۰۲۵).

۴. جداسازی صفحه‌ها. صفحه‌ی کنترل (چه مجاز است)، صفحه‌ی اجرا (چه انجام

می‌شود) و صفحه‌ی شواهد (چه رخ داد) از هم جدا هستند و صفحه‌ی اجرا نمی‌تواند شواهد را تغییر دهد.

۵. بودجه، قید درجه‌یک است. گام، توکن، زمان و هزینه به‌عنوان قید اجرا اعمال می‌شوند، نه فقط گزارش پس از واقعه.

۶. شکست طبیعی است. هر لایه، حالت‌های شکست، روش تشخیص و مسیر بازبایی خود را دارد؛ شکست یک استثنا نیست که پیش‌بینی نشده باشد. این اصل با مهندسی قابلیت اطمینان سنتی هم‌سو است، با این افزوده که شکست‌ها رفتاری‌اند، نه فقط زیرساختی (فصل ۳).

۷. انسان در نقاط پرریسک. تأیید انسانی به سطح ریسک اقدام وابسته است، نه به‌صورت سراسری. حذف انسان از همه‌چیز یا حضور او در همه‌چیز، هر دو ناکارآمدند.

۴.۴ واحدهای اصلی مدیریت

برای مدیریت رفتار، باید بدانیم دقیقاً کدام «چیزها» شناسه، چرخه‌ی عمر و مالک دارند. پنج واحد را تعریف می‌کنیم.

جدول ۴-۲. واحدهای اصلی مدیریت در AgentOps (منبع: نگارنده)

واحد	تعریف	شناسه و چرخه‌ی عمر	مالک معمول
وظیفه	یک درخواست هدف‌دار با معیار موفقیت و قیود	شناسه‌ی وظیفه؛ از درخواست تا نتیجه‌ی نهایی	مالک دامنه / محصول
اجرا	یک تلاش مشخص برای انجام وظیفه	شناسه‌ی اجرا؛ ایجاد، گام‌ها، پایان؛ قابل بازپخش	پلتفرم

واحد	تعریف	شناسه و چرخه‌ی عمر	مالک معمول
تصمیم	یک پیشنهاد مدل در یک گام همراه با زمینه‌ی آن	شناسه‌ی گام؛ لحظه‌ای؛ همیشه ثبت شده	عامل (ثبت: پلتفرم)
ابزار	یک توانمندی کنش با رابط و اثر بیرونی مشخص	نام و نسخه؛ مرحله‌ی انتشار، بازنگشتگی	مالک سامانه‌ی پایین دست
عامل	ترکیب مدل، دستورالعمل، ابزارها، حافظه و سیاست با قرارداد رفتاری	نسخه‌ی عامل (مانیفست انتشار)؛ چرخه‌ی عمر کامل	مالک عامل

این واحدها با مدل داده‌ی ردگیری دانگ و همکاران سازگارند. آنان یک ردگیری (trace) را از لحظه‌ی دریافت هدف تا تحویل نتیجه تعریف می‌کنند که از یک یا چند بازه (span) تشکیل شده است، و انواع بازه‌ها را برمی‌شمارند: بازه‌ی عامل، استدلال، برنامه، گردش کار، وظیفه، مدل زبانی، ارزیابی و حفاظها (Dong et al., ۲۰۲۴). نگاشت پیشنهادی ما: «وظیفه» همان بازه‌ی ریشه است، «تصمیم» نظیر بازه‌های استدلال/برنامه و «ابزار» نظیر بازه‌ی ابزار؛ جزئیات در فصل ۷.

۴.۵ مسئولیت‌های تیم مهندسی و تیم بهره‌برداری

در عامل‌ها، مسئولیت هم‌زمان میان چند طرف تقسیم می‌شود و همین ابهام می‌تواند در بحران گران تمام شود. دانگ و همکاران «مسئولیت مشترک» میان مالک عامل، ارائه‌دهنده‌ی مدل پایه و ارائه‌دهندگان ابزار و عامل‌های بیرونی را از ویژگی‌های متمایزکننده می‌شمارند که شناسایی منبع شکست را دشوار می‌کند (Dong et al., ۲۰۲۴). جدول ۴-۳ نقش‌ها را به صورت ماتریس مسئولیت (RACI ساده) پیشنهاد

می‌کند.

جدول ۴-۳. ماتریس پیشنهادی مسئولیت‌ها (م: مجری، پ: پاسخ‌گو، ش: مشورت‌شونده، آ: آگاه‌شونده؛ منبع: نگارنده)

فعالیت	مالک عامل	مهندس پلتفرم	اپراتور / SRE	امنیت و حاکمیت	مالک دامنه
تعریف قرارداد وظیفه و رفتار	م	ش	آ	ش	پ
طراحی ابزارها و دسترسی‌ها	م	ش	آ	پ	ش
ردگیری و زیرساخت شواهد	ش	پ/م	آ	ش	آ
ارزیابی و دروازه‌ی انتشار	م	ش	ش	ش	پ
پایش و پاسخ به رخداد	ش	ش	پ/م	آ	آ
سیاست‌ها و تأیید انسانی	ش	م	آ	پ	ش
بازنشستگی و بازنگری	م	ش	آ	ش	پ

این جدول یک پیشنهاد آغازین است و بسته به اندازه‌ی سازمان تغییر می‌کند؛ مهم اصل «هر فعالیت دقیقاً یک پاسخ‌گو دارد» است. در فصل ۱۳ این بحث به مدل عملیاتی سازمان و بلوغ گسترش می‌یابد.

۴.۶ مرز میان خودمختاری، اتوماسیون و کنترل انسانی

«اتوماسیون» و «خودمختاری» هم‌معنا نیستند. در اتوماسیون، مسیر از پیش مشخص است و ماشین آن را اجرا می‌کند؛ در خودمختاری، ماشین مسیر را هم انتخاب می‌کند. همین تفاوت، سطح کنترل لازم را تعیین می‌کند. پنج سطح را پیشنهاد می‌کنیم.

جدول ۴-۴. سطوح پیشنهادی خودمختاری و کنترل‌های متناظر (منبع: نگارنده)

سطح	ویژگی	نمونه	کنترل حداقلی
۰	فقط پاسخ؛ بدون ابزار	چت‌بات پرسش و پاسخ	ارزیابی کیفیت پاسخ، فیلتر خروجی
۱	ابزار فقط خواندنی	عامل جست‌وجو	سیاست دسترسی داده، ردگیری
۲	ابزار نوشتنی برگشت‌پذیر	ایجاد پیش‌نویس، ثبت تیکت	سیاست، بودجه، ردگیری کامل
۳	ابزار نوشتنی دارای اثر بیرونی	بازپرداخت، ارسال پیام	تأیید انسانی مشروط، idempotency، جبران
۴	هماهنگ‌سازی چندعاملی با اختیار گسترده	تیم عامل‌ها در یک فرایند سازمانی	همه‌ی موارد بالا + حاکمیت، توقف اضطراری، حساسی

ایده این است که هرچه سطح بالاتر می‌رود، کنترل‌های سطوح پایین‌تر کنار گذاشته نمی‌شوند، بلکه افزوده می‌شوند. این طبقه‌بندی مبتنی بر منبع خاصی نیست و برای اینکه با چارچوب‌های رسمی ریسک ارتباط داده شود، در فصل ۱۰ با کارکردهای چارچوب مدیریت ریسک NIST (حاکمیت، نگاشت، اندازه‌گیری و مدیریت) و فهرست OWASP نگاشت می‌شود (Tabassi, ۲۰۲۳؛ OWASP GenAI Security Project, ۲۰۲۵).

پیشنهاد نگارنده (ع۴). سطح خودمختاری یک عامل باید در قرارداد وظیفه ثبت شود و هر تغییر آن (مثلاً افزودن یک ابزار نوشتنی) مانند تغییر نسخه‌ی عامل، دروازه‌ی ارزیابی را از نو فعال کند.

۴.۷ اصطلاحات و واژگان استاندارد پیشنهادی

یکپارچه بودن اصطلاح در کتاب، شرط خوانایی است. واژه‌نامه‌ی کامل در پایان

آمده؛ این‌جا اصول واژه‌گزینی و پانزده اصطلاح محوری را مرور می‌کنیم. اصول: (۱) اصطلاح تخصصی در نخستین کاربرد با معادل انگلیسی می‌آید؛ (۲) مخفف‌های رایج (LLM، API، CI/CD) لاتین می‌مانند؛ (۳) اگر بین دو معادل فارسی رایج ابهام باشد، یکی را برمی‌گزینیم و ثابت نگه می‌داریم؛ (۴) اصطلاحات پیشنهادی نگارنده در واژه‌نامه با برچسب مشخص شده‌اند.

جدول ۴-۵. پانزده اصطلاح محوری (منبع: نگارنده؛ واژه‌نامه‌ی کامل در پایان کتاب)

انگلیسی	فارسی	معنا در این کتاب
agent	عامل	سامانه‌ای با حلقه‌ی مشاهده، تصمیم و اقدام
agency	عاملیت	درجه‌ی اختیار عامل در انتخاب مسیر
task contract	قرارداد وظیفه	هدف، قیود، بودجه، سطح خودمختاری
behavioral contract	قرارداد رفتاری	رفتار مورد انتظار و آستانه‌های پذیرش
trace	ردگیری	ثبت ساخت‌یافته‌ی یک اجرا
span	span (بازه‌ی ردگیری)	یک گام یا عمل داخل ردگیری
observability	مشاهده‌پذیری	امکان استنتاج وضعیت درونی از خروجی‌ها
evaluation	ارزیابی	سنجش رفتار با معیارهای تعریف‌شده
policy	سیاست	قواعد مجاز، ممنوع و مشروط
guardrail	حفاظ	کنترلی که اقدام را محدود می‌کند
human-in-the-loop	انسان در حلقه	تأیید انسانی برای تصمیم‌های پریسک
anomaly	آنومالی	رخدادی که به وقفه یا شکست وظیفه می‌انجامد
root cause analysis	تحلیل علت ریشه‌ای	یافتن نقطه‌ی علّی شکست
budget	بودجه	سقف گام، توکن، زمان و هزینه
control / execution / evidence plane	صفحه‌ی کنترل / اجرا / شواهد	سه صفحه‌ی معماری مرجع

۴.۸ فرضیه‌های بنیادین و پرسش‌های باز پژوهشی

ادعاهای این فصل، تعریف‌ها و اصل‌هایی‌اند که قابل‌آزمون نیستند، اما سه فرضیه‌ی قابل‌آزمون از آن‌ها بیرون می‌آید. فصل ۱۴ هر یک را با طرح آزمایش مشخص می‌کند.

فرضیه‌ی ۱ (ع ۵ - اثبات نشده). ردگیری ساخت‌یافته‌ی سطح تصمیم، زمان تشخیص نقطه‌ی علی شکست را نسبت به ثبت متنی ساده کاهش می‌دهد. **فرضیه‌ی ۳ (ع ۵ - اثبات نشده).** سیاست حداقل اختیار همراه با تأیید انسانی شرطی، موفقیت حمله‌ی تزریق غیرمستقیم را بدون افت معنادار در موفقیت وظیفه کاهش می‌دهد. **فرضیه‌ی ۵ (ع ۵ - اثبات نشده).** شاخص «هزینه‌ی کل هر وظیفه‌ی موفق با لحاظ هزینه‌ی رفع شکست» (TCPS) انتخاب مدل را نسبت به شاخص «هزینه‌ی هر درخواست» تغییر می‌دهد، به‌ویژه وقتی هزینه‌ی شکست قابل‌توجه است. (در مثال شبیه‌سازی‌شده‌ی فصل ۱۲، شاخص CPST بدون هزینه‌ی رفع شکست ترتیب را تغییر نداد، اما TCPS تغییر داد.)

پرسش‌های باز نیز بسیارند: آیا واحد «رفتار» با دقت کافی قابل تعریف رسمی است؟ آیا سطوح خودمختاری ۰ تا ۴ برای همه‌ی دامنه‌ها کافی‌اند؟ چه میزان از ماتریس مسئولیت در سازمان‌های کوچک ادغام می‌شود؟ این پرسش‌ها در فصل ۱۵ ادامه می‌یابند.

جمع‌بندی فصل

AgentOps را مهندسی رفتار عامل در سراسر چرخه عمر تعریف کردیم که پنج قابلیت تعریف‌پذیری، مشاهده‌پذیری، سنجش‌پذیری، محدودپذیری و بازیابی‌پذیری را

فراهم می‌کند. این رشته با DevOps و MLOps از نظر موضوع عملیات متفاوت است و با AIOps از نظر جهت رابطه. هفت اصل رفتار، شواهد، حداقل اختیار، جداسازی صفحه‌ها، بودجه، شکست طبیعی و انسان در نقاط پریسک، معماری را هدایت می‌کنند. پنج واحد مدیریتی، ماتریس مسئولیت و پنج سطح خودمختاری، چارچوب سازمانی و فنی فصل‌های بعد را می‌سازند.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. تعریف AgentOps را با تعریف‌های وانگ و همکاران و دانگ و همکاران مقایسه کنید. چه چیزی را پوشش می‌دهند و چه چیزی را نه؟
۲. فرق جهت رابطه در AIOps و AgentOps چیست؟ یک نمونه‌ی ترکیبی بسازید که هر دو در آن به‌کار رفته باشند.
۳. سطح خودمختاری سه عامل واقعی (مثلاً دستیار کدنویسی، دستیار پشتیبانی و عامل بازرگانی) را مشخص کنید و کنترل‌های حداقلی را برای آن‌ها بنویسید.
۴. برای هر یک از هفت اصل، یک نمونه‌ی «نقض» از یک سامانه‌ی فرضی بنویسید.
۵. ماتریس مسئولیت را برای یک سازمان کوچک با ده نفر مهندس بازنویسی کنید. کدام نقش‌ها را ادغام می‌کنید و چه خطری ایجاد می‌شود؟
۶. (تحلیلی) چرا بودجه‌ی اجرا را «قید» می‌گوییم نه «گزارش»؟ یک سناریوی حلقه‌ی بی‌پایان بنویسید که با گزارش پایانی هزینه، دیر تشخیص داده می‌شود.

منابع

Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>

- Kreuzberger, D., Kllhl, N., & Hirschl, S. (2022). Machine learning operations (MLOps): Overview, definition, and architecture (arXiv:2205.02302). arXiv. <https://doi.org/10.48550/arXiv.2205.02302>
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Saltzer, J. H., & Schroeder, M. D. (1975). The protection of information in computer systems. *Proceedings of the IEEE*, 63(9), 1278-1308.
- Tabassi, E. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-1>
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>
- Wang, Z., Pei, C., Liu, Y., Li, J., Huo, Y., Zhou, Q., Si, H., Cui, H., Liu, Z., Xie, G., Sun, F., Pei, D., & Lo, D. (2026). Agent system operations: Categorization, challenges, and future directions (arXiv:2606.01581). arXiv. <https://doi.org/10.48550/arXiv.2606.01581>

معماری مرجع سامانه‌های AgentOps

تا اینجا مسئله، واژگان و اصول را ساخته‌ایم. این فصل ستون فقرات فنی کتاب را عرضه می‌کند: معماری مرجع (AgentOps Reference Architecture) AO-RA. فصل‌های ۶ تا ۱۳ هر کدام بخشی از این معماری را عمیق‌تر می‌کنند و به لایه‌های آن ارجاع می‌دهند. پیش از ورود، یک هشدار روش‌شناختی: AO-RA پیشنهاد نگارنده است (ع۴). استاندارد نیست، اعتبارسنجی تجربی کامل نشده و اجماع جامعه علمی را نمایندگی نمی‌کند. بخش‌هایی از آن اقتباس از الگوهای شناخته‌شده مهندسی است و در بخش ۵.۱۱ دقیقاً مشخص کرده‌ایم کدام بخش‌ها اقتباس‌اند و کدام نوآوری.

اهداف فصل. (۱) الزامات معماری را از فصل ۳ به طراحی ترجمه کنیم؛ (۲) سه صفحه و هشت لایه AO-RA و مسئولیت هر یک را تعریف کنیم؛ (۳) قراردادهای میان لایه‌ها را مشخص کنیم؛ (۴) جریان اجرای یک وظیفه، مسیر خطا و بازیابی، مرزهای اعتماد و نقاط تأیید انسانی را نشان دهیم؛ (۵) پیاده‌سازی مفهومی و آزمون‌شده‌ای عرضه کنیم؛ (۶) مزایا، محدودیت‌ها و هزینه‌های معماری را صادقانه تحلیل کنیم.

۵.۱ الزامات معماری برای اجرای عامل در محیط واقعی


ده نیازمندی R1 تا R10 که در فصل ۳ استخراج شد، معماری را شکل می‌دهند. می‌توان آن‌ها را در چهار خواسته‌ی طراحی خلاصه کرد:

- تفکیک تصمیم از اجرا (R6، R7): مدل پیشنهاد می‌دهد؛ اجرا از یک نقطه‌ی کنترل می‌گذرد.
- شواهد کامل و فقط افزودنی (R2، R3، R10): هر تصمیم و اقدام قابل بازسازی و حسابرسی است.
- قیود صریح پیش از اجرا (R1، R8): قرارداد وظیفه، بودجه و آستانه‌های پذیرش، پیش از شروع تعریف می‌شوند.
- بازیابی‌پذیری و ارزیابی مستمر (R4، R5، R9): شکست‌ها طبقه‌بندی و مهار می‌شوند و کیفیت رفتار به صورت آماری سنجیده می‌شود.

دو محدودیت طراحی هم هست. اول، معماری باید مدل-ناوابسته باشد: اجزای آن نباید به یک ارائه‌دهنده‌ی مدل خاص گره بخورند. دوم، باید لایه‌به‌لایه قابل اتخاذ باشد: سازمانی با عامل ساده و کم‌ریسک (سطح ۱ خودمختاری، فصل ۴) نباید مجبور شود تمام لایه‌ها را به طور کامل پیاده کند؛ مدل بلوغ فصل ۱۳ همین را سامان می‌دهد.

۵.۲ سه صفحه و هشت لایه

AO-RA از دو محور سازمان یافته است. محور اول **صفحه‌ها** هستند: سه گروه از مسئولیت‌ها که از نظر تغییرپذیری و سطح اعتماد متفاوت‌اند. محور دوم **لایه‌ها**: هشت وظیفه‌ی کارکردی. شکل ۵-۱ نمای کلی را نشان می‌دهد.



شکل ۵-۱. نمای کلی معماری مرجع AO-RA: سه صفحه و هشت لایه (منبع: نگارنده)

• **صفحه‌ی کنترل** تعیین می‌کند چه چیزی مجاز است: قرارداد وظیفه و رفتار، موتور

سیاست، مدیریت بودجه، دروازه‌های ارزیابی و صف تأیید انسانی. تغییرات آن کم‌تکرار و پرسابقه است.

- **صفحه‌ی اجرا** کار واقعی را انجام می‌دهد: ارکستری‌تور، حلقه‌ی تصمیم، دروازه‌ی ابزار، حافظه و زمینه، و جعبه‌ایزوله‌ی اجرای کد. تغییرات آن مکرر است و اعتبارش پایین‌تر.
- **صفحه‌ی شواهد** ثبت می‌کند چه رخ داد: گردآور رویداد، مخزن ردگیری، نتایج ارزیابی، دفتر هزینه و دفتر حسابرسی. این صفحه **فقط‌افزودنی** است و صفحه‌ی اجرا نمی‌تواند شواهد را تغییر دهد.

مفهوم جداسازی «صفحه‌ی کنترل» از «صفحه‌ی داده/اجرا» در معماری شبکه و سامانه‌های توزیع‌شده رایج است. افزوده‌ی ما، صفحه‌ی سوم یعنی **شواهد** است: برای عامل‌ها لازم است، چون رفتارشان را نمی‌توان بدون ثبت کامل بازسازی کرد (فصل ۳). همین‌جا اصل چهارم فصل ۴ (جداسازی صفحه‌ها) تحقق می‌یابد.

جدول ۵-۱. مسئولیت‌ها و محل هر لایه (منبع: نگارنده)

لایه	صفحه	مسئولیت	فصل
۱: قرارداد و وظیفه	کنترل	هدف، ورودی‌های مجاز، معیار موفقیت، قیود، سطح خودمختاری	۶
۲: ارکستراسیون	اجرا	زمان‌بندی، صف، وضعیت، نقطه‌های بازیابی، هماهنگی بین‌عاملی	۱۱، ۱۳
۳: استدلال و تصمیم	اجرا	برنامه‌ریزی، انتخاب اقدام، فراخوانی مدل؛ خروجی فقط «پیشنهاد» است	۲
۴: ابزار و محیط	اجرا	دروازه‌ی ابزار، اعتبارسنجی پارامتر، فراخوانی، idempotency	۱۰
۵: حافظه و زمینه	اجرا	حافظه‌ی کوتاه و بلندمدت، بازیابی، پاک‌سازی	۲، ۷

لایه	صفحه	مسئولیت	فصل
۶: مشاهده‌پذیری	شواهد	رویداد ساخت‌یافته، ردگیری، بازپخش	۷
۷: ارزیابی، سیاست و کنترل	کنترل	دروازه‌ی ارزیابی، تصمیم سیاست، بودجه، تأیید انسانی	۸، ۱۰، ۱۲
۸: زیرساخت اجرا	هر سه	محاسبه، شبکه، جداسازی، اسرار	۱۱

۵.۳ قراردادهای میان لایه‌ها

لایه‌ها فقط از طریق قراردادهای ساخت‌یافته با هم حرف می‌زنند. این انتخاب چند مزیت دارد: هر قرارداد قابل نسخه‌بندی و اعتبارسنجی است؛ جایگزینی یک لایه آسان می‌شود؛ و هر قرارداد خودش یک نقطه‌ی ردگیری است. جدول ۵-۲ قراردادهای اصلی را فهرست می‌کند.

جدول ۵-۲. قراردادهای میان لایه‌ها (منبع: نگارنده)

قرارداد	فیلدهای کلیدی	مالک
TaskContract	taskId, goal, allowedTools, constraints, successCriteria, budget, riskTier	لایه ۱
BehaviorContract	سناریوهای مرجع، آستانه‌های پذیرش، نسخه	لایه ۱ و ۷
ActionProposal	actionId, tool, args, rationaleRef, expectedEffect, riskScore	لایه ۳
PolicyDecision	decision $\in$ {allow, deny, require_approval}, ruleId, reason	لایه ۷

قرارداد	فیلدهای کلیدی	مالک
ToolResult	status, output, sideEffects, idempotencyKey, cost	لایه ۴
TraceEvent	traceld, spanId, parentId, kind, ts, payloadRef, redaction	لایه ۶
EvalResult	scenarioId, runId, metrics, verdict, evidenceRefs	لایه ۷
BudgetEntry	taskId, steps, tokens, tools, usd, remaining	لایه ۷
ReleaseManifest	agentVersion, modelRef, promptRef, toolVersions, policyVersion, evalReport	لایه ۱ و ۷

کد زیر تعریف قرارداد وظیفه و بودجه در پیاده‌سازی مرجع است. دو نکته: قرارداد تغییرناپذیر (frozen) است تا در میانه‌ی اجرا عوض نشود، و معیار موفقیت یک تابع محض است که بر پاسخ نهایی و فهرست اقدام‌های انجام‌شده تعریف می‌شود؛ یعنی موفقیت فقط به پاسخ متنی وابسته نیست.

کد ۵-۱ (پایتون ۳/۱۲): **contract.py**.

```

"""Task contract, budget and risk tiers (A0-RA layer L1)."""
from __future__ import annotations
from dataclasses import dataclass, field
from typing import Callable

@dataclass(frozen=True)
class Budget:
    max_steps: int = 8
    max_tokens: int = 4000
    max_usd: float = 0.50
    deadline_s: float = 30.0

@dataclass(frozen=True)
class TaskContract:

```

```
task_id: str
goal: str
allowed_tools: frozenset[str]
budget: Budget = field(default_factory=Budget)
risk_tier: str = "low" # low | medium | high
# success criterion: pure function over the final answer and the
# executed tool calls
success: Callable[[str, list], bool] = lambda answer, calls:
    bool(answer)
```

۵.۴ لایه‌های تصمیم، ابزار و حافظه

لایه ۳ (تصمیم). این لایه زمینه و هدف را می‌گیرد و یک `ActionProposal` می‌سازد: اقدام بعدی یا پاسخ نهایی. هیچ ابزاری را مستقیم فراخوانی نمی‌کند. این جداسازی ساده ولی بنیادین است: مدل حتی اگر هدف‌ربایی شود (تزریق دستورالعمل، فصل ۱۰)، فقط **پیشنهاد** می‌دهد و پیش از اجرا از لایه ۷ می‌گذرد. اصل «میانجی‌گری کامل»، یعنی هر دسترسی به منبع باید بررسی شود، از اصول طراحی سامانه‌های امن است (Saltzer & Schroeder, ۱۹۷۵). درباره‌ی استدلال و برنامه‌ریزی و محدودیت‌های مدل در فصل ۲ بحث شد.

لایه ۴ (دروازه‌ی ابزار). تنها مسیر اثر بیرونی است. چهار وظیفه دارد: (۱) اعتبارسنجی نام ابزار و پارامترها در برابر طرح‌واره‌ی ثبت‌شده؛ (۲) اجرا با **کلید یکتا** (`idempotency key`) تا اقدام تکراری دوبار اثر نگذارد؛ (۳) تلاش مجدد محدود برای خطاهای گذرا؛ (۴) ثبت نتیجه و هزینه. نکته‌ی امنیتی: توصیف ابزار نامعتبر فرض می‌شود، مگر منبعش معتبر باشد (Model Context Protocol, ۲۰۲۶)؛ پس دروازه نباید توصیف ابزار را به‌عنوان دستور به مدل بدهد، مگر پس از بررسی.

کد ۵-۲ (گزیده‌ی `tools.py`). دروازه‌ی ابزار با کلید یکتا: اگر کلید قبلاً اجرا شده، نتیجه

از حافظه‌ی نهان برمی‌گردد و ابزار دوباره اجرا نمی‌شود؛ خطای گذرا تا سقف مشخص تکرار می‌شود.


```
def register(self, name: str, fn: Callable[..., Any], undo:
Callable[[dict, Any], tuple[str, dict]] | None = None):
    """undo(args, output) -> (undo_tool, undo_args): the compensating
    action of a write tool (saga step)."""
    self._tools[name] = fn
    if undo: self._undo[name] = undo

def call(self, name: str, args: dict, idempotency_key: str, retries:
int = 2) -> ToolResult:
    if idempotency_key in self._cache:                                # the
same
        logical action is never run twice
        r = self._cache[idempotency_key]
        return ToolResult(r.status, r.output, 0.0, replayed=True)
    if name not in self._tools:
        return ToolResult("error", f"unknown tool {name}")
    last = None
    for attempt in range(retries + 1):
        self.calls += 1
        try:
            res = ToolResult("ok", self._tools[name](**args), 0.001)
            self._cache[idempotency_key] = res
            if name in self._undo: self.journal.append((name,
dict(args), res.output))
            return res
```

لایه‌ی ۵ (حافظه و زمینه). وضعیت مشترک عامل را نگه می‌دارد: تاریخچه‌ی این اجرا، دانش بازیابی‌شده و حافظه‌ی بلندمدت. چون حافظه بخشی از «علت» تصمیم است (فصل ۳)، دو قاعده دارد: هر خوانش از حافظه که وارد زمینه شود باید با منبع و نسخه‌اش ثبت شود، و داده‌ی حساس پیش از ورود به زمینه‌ی مدل یا ردگیری پاک‌سازی (redaction) می‌شود.

۵.۵ جریان اجرای یک وظیفه از آغاز تا پایان

شکل ۵-۲ مسیر موفق یک وظیفه را از دید لایه‌ها نشان می‌دهد. مراحل را به ترتیب شرح می‌دهیم.



شکل ۵-۲. جریان اجرای یک وظیفه در مسیر موفق (منبع: نگارنده)

۱. دریافت و قرارداد. درخواست به لایه ۱ می‌رسد. لایه ۱ آن را اعتبارسنجی و به **TaskContract** تبدیل می‌کند؛ بودجه‌ی وظیفه رزرو می‌شود.
۲. شروع اجرا. لایه ۲ اجرای جدید ایجاد و نقطه‌ی بازبازی صفر را ذخیره می‌کند. رویداد **task.start** در صفحه‌ی شواهد ثبت می‌شود.
۳. تصمیم. لایه ۳ هدف، تاریخچه و زمینه‌ی بازبازی شده از لایه ۵ را می‌گیرد و **ActionProposal** تولید می‌کند. رویداد **decision** ثبت می‌شود.

۴. سیاست و بودجه. لایه‌ی ۷ پیشنهاد را بر اساس قرارداد وظیفه، سیاست‌ها و بودجه می‌سنجد و PolicyDecision صادر می‌کند. اگر نتیجه require_approval باشد، اجرا معلق و به صف تأیید انسانی ارجاع می‌شود.
۵. اجرا. در صورت allow، لایه‌ی ۴ ابزار را با کلید یکتا فراخوانی می‌کند و ToolResult و هزینه ثبت می‌شود.
۶. حلقه. نتیجه به لایه‌ی ۲ برمی‌گردد و حلقه تا تحقق معیار موفقیت یا رسیدن به بودجه یا مهلت ادامه می‌یابد.
۷. پایان. پاسخ نهایی، پس از ارزیابی سبک برخط (قیود و ساختار)، تحویل داده می‌شود و رویداد task.end همراه با هزینه‌ی کل و وضعیت ثبت می‌شود.

۵.۶ لایه‌ی مشاهده‌پذیری و صفحه‌ی شواهد

لایه‌ی ۶ هر عبور از مرز لایه‌ها را به یک رویداد ساخت‌یافته تبدیل می‌کند. مفاهیم «ردگیری» (trace) و «بازه» (span) از ردگیری سامانه‌های توزیع‌شده اقتباس شده‌اند. گزارش داپر (Dapper) گوگل، که زیرساخت ردگیری تولیدی در مقیاس بزرگ را با تکیه بر نمونه‌برداری و ابزارگذاری شمار کمی از کتابخانه‌های مشترک توصیف می‌کند، از مراجع آغازین این سنت است (Sigelman et al., ۲۰۱۰). دانگ و همکاران همین مفاهیم را به مصنوعات عامل تعمیم داده‌اند: یک ردگیری از لحظه‌ی دریافت هدف تا تحویل نتیجه، از یک یا چند بازه تشکیل می‌شود و انواع بازه‌ها شامل عامل، استدلال، برنامه، گردش کار، وظیفه، ابزار، مدل زبانی، ارزیابی و حفاظ است. هر بازه نام، زمان شروع، مدت و صفت‌هایی مثل ورودی و خروجی، نوع و پیام خطا و سنجه‌هایی مثل توکن‌های مصرفی دارد (Dong et al., ۲۰۲۴).

در AO-RA، TraceEvent همین ایده را به صورت حداقلی پیاده می‌کند: هر رویداد یک `traceld`، یک `spanId`، شناسه‌ی والد، نوع، زمان و بار داده دارد. انواع رویداد ثابت‌اند (`task.start`، `decision`، `policy`، `tool.result`، `approval`، `budget`، `task.end`) و فصل ۷ جزئیات و مدل داده‌ی کامل را می‌دهد. سه ویژگی طراحی مهم‌اند. اول، فقط افزودنی بودن: رویداد پس از ثبت تغییر نمی‌کند. دوم، بازپخش‌پذیری: از روی فایل رویدادها می‌توان اجرا را بازسازی کرد (پیاده‌سازی مرجع تابع `replay` دارد). سوم، پاک‌سازی: داده‌ی حساس پیش از ثبت حذف یا نقاب‌دار می‌شود (فصل ۷).

برای اینکه نگرانی رایج «ثبت رویداد سنگین است» با داده پاسخ داده شود، سربار پیاده‌سازی مرجع را اندازه گرفتیم (پایتون ۳/۱۲، یک پردازنده‌ی معمولی x86-64، میانگین صدهزار تکرار؛ اعداد به سخت‌افزار وابسته‌اند). ثبت یک رویداد در حافظه حدود ۱/۸ میکروثانیه، ثبت همراه با افزودن به فایل JSONL حدود ۴۰ میکروثانیه (با باز و بسته کردن فایل در هر رویداد، که بهینه نیست) و اجرای تصمیم سیاست با ۲۲ قاعده حدود ۲/۳ میکروثانیه بود. فراخوانی کامل ابزار از دروازه نیز حدود ۱/۴ میکروثانیه (به جز خود ابزار). این اعداد در مقایسه با تأخیر فراخوانی یک مدل زبانی بزرگ، که معمولاً در حد صدها میلی‌ثانیه تا ثانیه است، ناچیزند؛ اما این مقایسه‌ی تقریبی است و تأخیر مدل را اندازه نگرفته‌ایم. نتیجه‌ی محتاطانه: سربار محاسباتی لایه‌های سیاست و ثبت، گلوگاه نیست؛ هزینه‌ی واقعی در مهندسی ذخیره‌سازی، نگهداری و حفظ حریم خصوصی ردگیری‌هاست (فصل ۷).

۵.۷ لایه‌ی ارزیابی، سیاست و کنترل

لایه‌ی ۷ سه کارکرد دارد که هر سه پیش از اجرا یا در لحظه‌ی اجرا اثر می‌گذارند. موتور سیاست. هر `ActionProposal` از موتور سیاست می‌گذرد و یکی از سه حکم می‌گیرد: `allow`، `deny` یا `require_approval`. در پیاده‌سازی مرجع، اولین قاعده‌ی منطبق برنده است و در نبود قاعده، پیش‌فرض رد است (پیش‌فرض ایمن). همچنین ابزاری که در قرارداد وظیفه نیست، پیش از بررسی قواعد رد می‌شود. این رفتار به تصمیمی در سطح معماری بازمی‌گردد: «اختیار» را فهرست مجاز تعیین می‌کند، نه فهرست ممنوع. سیاست حداقل اختیار با توصیه‌ی OWASP همسوست که اعمال مجوز را در سامانه‌ی پایین‌دست و نه با اتکا به تصمیم مدل می‌داند (OWASP, 2025).

کد ۳-۵ (گزیده‌ی `policy.py`). موتور سیاست: ابزار خارج از قرارداد رد می‌شود؛ سپس اولین قاعده‌ی منطبق حکم می‌دهد؛ پیش‌فرض رد است.

```
class PolicyEngine:
    """First matching rule wins; the default is deny (fail-safe
    default)."""
    def __init__(self, rules: list[Rule], default: str = "deny"):
        self.rules, self.default = rules, default

    def decide(self, tool: str, args: dict, allowed_tools:
frozenset[str])
-> Decision:
        if tool not in allowed_tools:
            return Decision("deny", "contract.allowed_tools", f"{tool} is
not in the task contract")
        for r in self.rules:
            if r.tool not in (tool, "*"):
                continue
            if r.when_arg:
                name, needle = r.when_arg
                if needle not in str(args.get(name, "")):
```

```

        continue
    return Decision(r.effect, r.rule_id, f"matched {r.rule_id}")
return Decision(self.default, "default", "no rule matched")

```

بودجه. دفتر بودجه، هر گام، توکن و هزینه را شارژ می‌کند و در عبور از سقف، استثنای **BudgetExceeded** می‌اندازد. حلقه‌ی عامل آن را می‌گیرد، رویداد **budget** را ثبت می‌کند و اجرا را متوقف می‌کند. در نتیجه حلقه‌ی بی‌پایان توسط قید ساختاری و نه توسط گزارش بعدی مهار می‌شود. همین‌جا معیار پیشنهادی «هزینه‌ی هر وظیفه‌ی موفق» (CPST) هم تعریف می‌شود: مجموع هزینه‌ی **همه‌ی** اجراها تقسیم بر تعداد وظایف موفق، تا هزینه‌ی شکست‌ها نیز در شاخص بیاید.

کد ۵-۴ (گزیده‌ی cost.py). بودجه و شاخص هزینه‌ی هر وظیفه‌ی موفق.

```

def __init__(self, which: str): super().__init__(which); self.which = which

@dataclass
class Ledger:
    budget: Budget
    steps: int = 0
    tokens: int = 0
    usd: float = 0.0
    clock: Callable[[], float] = time.monotonic
    started: float | None = None

    def __post_init__(self):
        if self.started is None: self.started = self.clock()

    def charge(self, *, steps: int = 0, tokens: int = 0, usd: float = 0.0):
        self.steps += steps; self.tokens += tokens; self.usd += usd
        if self.steps > self.budget.max_steps: raise
        BudgetExceeded("steps")

```

دروازه‌ی ارزیابی. پیش از انتشار یک نسخه‌ی عامل، رفتار آن در سناریوهای مرجع و با اجراهای تکراری سنجیده می‌شود و تنها در صورت عبور از آستانه‌های **BehaviorContract** منتشر می‌شود. این کارکرد در فصل ۸ با دقت بررسی می‌شود.

در حین اجرا نیز، ارزیابی سبک برخط (بررسی قیود و ساختار خروجی) انجام می‌شود.


۵.۸ لایه‌ی زیرساخت و اجرای توزیع‌شده

لایه‌ی ۸ محاسبه، شبکه، جداسازی و اسرار را فراهم می‌کند. در این کتاب، زیرساخت را عمدتاً از دید «الزامات معماری» مرور می‌کنیم و نه یک فناوری خاص. الزامات اصلی: جداسازی اجرای ابزارهای پرخطر (مثلاً اجرای کد) در محیط محصور؛ مدیریت اسرار به‌گونه‌ای که عامل هرگز مقدار اسرار را در زمینه‌ی مدل نبیند؛ هویت جداگانه برای هر عامل یا وظیفه تا مجوزها در سامانه‌ی پایین‌دست قابل‌اعمال و حسابرسی باشد؛ و شبکه‌ی کنترل‌شده با فهرست مجاز مقاصد. جزئیات استقرار و ارکستراسیون در فصل ۱۱ می‌آید.

۵.۹ مسیر خطا، بازیابی، مرزهای اعتماد و نقاط تأیید انسانی

مسیر خطا و بازیابی. شکل ۵-۳ منطق تصمیم پس از هر گام را نشان می‌دهد. اصل کلی: هر خطا یکی از چند واکنش مشخص را فعال می‌کند و هیچ خطایی «بدون واکنش» نمی‌ماند. خطای گذرا با همان کلید یکتا تکرار می‌شود (تا سقف مشخص)، چون تکرار با کلید یکسان اثر اقدام را دوبار اعمال نمی‌کند. خطای پایدار مدارشکن را فعال می‌کند؛ رد سیاست به‌صورت خطای ساخت‌یافته به مدل برمی‌گردد تا مسیر دیگری بیازماید؛ و نقض بودجه به توقف نرم و ارجاع به انسان می‌انجامد. اگر وضعیت ناسازگار شد، اجرا به آخرین نقطه‌ی بازیابی برمی‌گردد و اقدام‌های انجام‌شده جبران می‌شوند. الگوی جبران از مفهوم «ساگا» (saga) در پایگاه داده اقتباس شده است: یک تراکنش طولانی به زیرتراکنش‌ها تقسیم می‌شود که هر یک اقدام جبرانی دارد

(Garcia-Molina & Salem, ۱۹۸۷).




شکل ۳-۵. منطق تصمیم پس از هر گام: تلاش مجدد، مدارشکن، رد سیاست، توقف و جبران (منبع: نگارنده)

مرزهای اعتماد. در AO-RA پنج مرز اعتماد مشخص می‌شود (شکل ۴-۵ و جدول

۳-۵). مرز دوم از همه مهم‌تر است: محتوای بیرونی یا بازایی شده داده است، نه

دستور. این همان مرزی است که تزریق غیرمستقیم دستورالعمل آن را نقض می‌کند (Greshake et al., ۲۰۲۳).



شکل ۵-۴. مرزهای اعتماد در AO-RA (منبع: نگارنده)

جدول ۵-۳. مرزهای اعتماد و کنترل‌های متناظر (منبع: نگارنده)

مرز	عبور از	کنترل اصلی
۱	کاربر به سامانه	اعتبارسنجی و پاک‌سازی ورودی؛ احراز هویت
۲	محتوای بیرونی/بازیابی شده به هسته‌ی تصمیم	برجسب‌گذاری «غیرقابل اعتماد»، محدودسازی تأثیر بر اقدام، جداسازی از دستورالعمل
۳	هسته‌ی تصمیم به دروازه‌ی ابزار	سیاست پیش از اجرا، اعتبارسنجی پارامتر، بودجه
۴	دروازه به ابزارها و سرویس‌های بیرونی	حداقل مجوز، هویت جداگانه، توصیف ابزار نامعتبر
۵	صفحه‌ی اجرا به صفحه‌ی شواهد	فقط‌افزودنی؛ اجرا حق تغییر شواهد ندارد

نقاط تأیید انسانی. تأیید انسانی در پنج وضعیت فعال می‌شود: اقدام برگشت‌ناپذیر، دسترسی به داده‌ی حساس، هزینه‌ی بالاتر از آستانه، اقدام بیرون از رده‌ی ریسک مجاز، و ناسازگاری مکرر. این نقاط در PolicyDecision با مقدار require_approval تحقق می‌یابند. اجرا معلق می‌شود (وضعیت حفظ می‌شود) و پس از تصمیم انسان از

سر گرفته یا متوقف می‌شود. جزئیات و طراحی صف تأیید در فصل ۱۰.

۵.۱۰ الگوهای معماری متمرکز، توزیع شده و چندعاملی

AO-RA مستقل از الگوی توپولوژی عامل‌هاست؛ اما ترکیب با الگوها پیامد دارد. الگوهای گردش کار معرفی شده در راهنمای **Anthropic**، یعنی زنجیره‌ی دستورالعمل‌ها، مسیریابی، موازی‌سازی، هماهنگ‌کننده و کارگران، و ارزیاب و بهینه‌ساز (Anthropic, ۲۰۲۴)، هر یک را می‌توان با لایه‌های AO-RA ترکیب کرد: در الگوی هماهنگ‌کننده و کارگران، هماهنگ‌کننده یک لایه‌ی ۲ است و هر کارگر می‌تواند یک اجرای مستقل با قرارداد، بودجه و سیاست خودش باشد. در این حالت، قرارداد وظیفه‌ی کارگر از قرارداد وظیفه‌ی والد باریک‌تر است (اختیار هیچ‌گاه از والد به فرزند افزایش نمی‌یابد). برای سامانه‌های چندعاملی، یافته‌های Cemri و همکاران بر اهمیت طراحی سامانه و تأیید وظیفه تأکید دارند (Cemri et al., ۲۰۲۵)؛ پس در این الگوها، اجرای مستقل دروازه‌ی تأیید یک لایه‌ی الزامی است نه اختیاری. فصل ۱۳ این بحث را گسترش می‌دهد.

۵.۱۱ اقتباس در برابر پیشنهاد، و مزایا، محدودیت‌ها و هزینه‌ها

برای شفافیت علمی، جدول ۵-۴ هر جزء AO-RA را به ریشه‌اش وصل می‌کند.

جدول ۵-۴. اجزای AO-RA: اقتباس از چه، و سهم نگارنده چیست (منبع: نگارنده)

جزء	اقتباس از	سهم نگارنده
ردگیری و بازه	سنت ردگیری توزیع شده (Sigelman et al., ۲۰۱۰)؛ مدل Dong et al.,) عامل‌ها (۲۰۲۴)	قرارداد TraceEvent خاص تصمیم و اقدام عامل
حلقه‌ی عامل	ReAct و ریفلکشن (Yao et al., ۲۰۲۲؛ Shinn et al., ۲۰۲۳)	جداسازی «پیشنهاد» از «اجرا» به عنوان مرز معماری
دروازه‌ی سیاست	اصل میانجی‌گری کامل و پیش فرض ایمن (Saltzer & Schroeder, ۱۹۷۵)؛ توصیه‌های OWASP	حکم سه‌حالت با require_approval و ردهٔ ریسک
طبقه‌بندی شکست	آنومالی‌های (Wang et al., ۲۰۲۵)؛ MAST (Cemri et al., ۲۰۲۵)	طبقه‌بندی AgentOps-FT (پیوست B)
ارزیابی پایداری	معیار (Yao et al., ۲۰۲۴) pass^k	دروازه‌ی انتشار مبتنی بر اجراهای تکراری
اجرای قابل‌بازایی	الگوی ساگا (Garcia-Molina & Salem, ۱۹۸۷)	نقطه‌های بازایی در سطح تصمیم
سه‌صفحه‌ای	تفکیک صفحه‌ی کنترل و داده در معماری شبکه (مفهومی، بدون ارجاع مستقیم)	افزودن «صفحه‌ی شواهد»
مدیریت ریسک	کارکردهای چارچوب NIST (Tabassi, ۲۰۲۳)	نگاشت لایه‌ها به کارکردها (فصل ۱۰)

مزایا (ع۴). مرز روشن مسئولیت‌ها و قراردادها؛ بازپخش و حسابرسی‌پذیری؛ ارزیابی و سیاست به عنوان مؤلفه‌های درجه‌یک؛ قابلیت جایگزینی لایه‌ها؛ و امکان اتخاذ تدریجی.

محدودیت‌ها و هزینه‌ها (ع۴). (۱) پیچیدگی مهندسی و عملیاتی: ده‌ها قرارداد و چند مؤلفه‌ی جدید. (۲) سربار تأخیر کوچک اما غیرصفر. (۳) هزینه‌ی ذخیره‌سازی و نگهداری ردگیری و

مسائل حریم خصوصی. (۴) نگهداری مجموعه‌ی ارزیابی و سیاست‌ها، که خودش کار انسانی مداوم است. (۵) برای عامل ساده‌ی کم‌ریسک اضافی است. (۶) کیفیت سیاست‌ها و سناریوها را خودکار تضمین نمی‌کند: «موتور سیاست» با قواعد بد، تصمیم بد می‌گیرد. (۷) هنوز اعتبارسنجی تجربی نشده است؛ فصل ۱۴ طرح اعتبارسنجی را می‌دهد، نه نتیجه را.

این معماری را استاندارد معرفی نمی‌کنیم و ادعا نداریم بهترین طراحی ممکن است؛ ادعا این است که با الزامات R1 تا R10 سازگار است و ساختاری قابل آزمایش عرضه می‌کند.

جمع‌بندی فصل

AO-RA با سه صفحه (کنترل، اجرا، شواهد) و هشت لایه، رفتار عامل را قابل تعریف، مشاهده، سنجش، محدودسازی و بازیابی می‌کند. قراردادهای ساخت‌یافته لایه‌ها را به هم وصل می‌کنند. مدل فقط پیشنهاد می‌دهد، سیاست و بودجه پیش از اجرا حکم می‌دهند و دروازه‌ی ابزار با کلید یکتا اجرا می‌کند؛ شواهد در صفحه‌ی فقط‌افزودنی ثبت می‌شود. سربار محاسباتی لایه‌های سیاست و ثبت ناچیز است و هزینه‌ی واقعی در نگهداری و مدیریت داده است. پنج مرز اعتماد و پنج وضعیت تأیید انسانی مشخص شد. معماری پیشنهاد نگارنده است و هنوز اعتبارسنجی تجربی نشده است.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. چرا «پیشنهاد» و «اجرا» را از هم جدا می‌کنیم؟ سه حمله را نام ببرید که این جداسازی مهار می‌کند.

۲. فرق صفحه‌ی کنترل، اجرا و شواهد چیست؟ چرا صفحه‌ی شواهد باید فقط‌افزودنی

باشد؟

۳. در کد ۳-۵، اگر پیش‌فرض را از «رد» به «اجازه» تغییر دهیم، چه خطری پدید می‌آید؟ یک سناریو بنویسید.

۴. جریان یک وظیفه را برای عاملی که ابزار نوشتنی دارد (مثل بازپرداخت) رسم کنید و نقاط تأیید انسانی را روی آن مشخص کنید.

۵. در الگوی «هماهنگ‌کننده و کارگران»، چرا اختیار کارگر نباید از اختیار هماهنگ‌کننده بیشتر باشد؟ کدام مرز اعتماد را نقض می‌کند؟

۶. (عملی) اجرای آزمون‌های `code/tests/test_aorch.py` را بررسی کنید و یک آزمون جدید برای رفتار «توقف پس از دو رد پیاپی سیاست» بنویسید.

۷. (تحلیلی) محدودیت‌های AO-RA را بخوانید. کدام را جدی‌ترین می‌دانید؟ چه آزمایشی آن را روشن می‌کند؟

منابع

Anthropic. (2024, December 19). Building effective agents. <https://www.anthropic.com/engineering/building-effective-agents>

Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>

Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>

Garcia-Molina, H., & Salem, K. (1987). Sagas. Proceedings of the 1987 ACM SIGMOD International Conference on Management of Data, 249-259. <https://doi.org/10.1145/38713.38742>

Greshake, K., Abdelnabi, S., Mishra, S., Endres, C., Holz, T., & Fritz, M. (2023). Not what you've signed up for: Compromising real-world LLM-integrated applications with indirect prompt injection (arXiv:2302.12173). arXiv. <https://doi.org/10.48550/>

arXiv.2302.12173

Model Context Protocol. (2026). Model Context Protocol specification (version 2026-07-28). <https://modelcontextprotocol.io/specification/latest> (accessed 2026-10-21)

OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)

Saltzer, J. H., & Schroeder, M. D. (1975). The protection of information in computer systems. *Proceedings of the IEEE*, 63(9), 1278-1308.

Shinn, N., Cassano, F., Berman, E., Gopinath, A., Narasimhan, K., & Yao, S. (2023). Reflexion: Language agents with verbal reinforcement learning (arXiv:2303.11366). arXiv. <https://doi.org/10.48550/arXiv.2303.11366>

Sigelman, B. H., Barroso, L. A., Burrows, M., Stephenson, P., Plakal, M., Beaver, D., Jaspan, S., & Shanbhag, C. (2010). Dapper, a large-scale distributed systems tracing infrastructure (Technical Report dapper-2010-1). Google. <https://research.google/pubs/pub36356/>

Tabassi, E. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-1>

Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>


Yao, S., Shinn, N., Razavi, P., & Narasimhan, K. (2024). tau-bench: A benchmark for tool-agent-user interaction in real-world domains (arXiv:2406.12045). arXiv. <https://doi.org/10.48550/arXiv.2406.12045>

Yao, S., Zhao, J., Yu, D., Du, N., Shafran, I., Narasimhan, K., & Cao, Y. (2022). ReAct: Synergizing reasoning and acting in language models (arXiv:2210.03629). arXiv. <https://doi.org/10.48550/arXiv.2210.03629>

چرخه عمر مهندسی عامل‌های هوشمند

معماری فصل ۵ ساختار یک عامل در حال اجرا را نشان داد؛ اما عامل از یک ایده شروع می‌شود، به نسخه‌ای قابل انتشار می‌رسد، در تولید رفتار می‌کند، دچار رخداد می‌شود، بهبود می‌یابد و سرانجام بازنشسته می‌شود. این فصل آن مسیر را **چرخه‌ی عمر مهندسی عامل** می‌نامد و برای هر مرحله، مصنوعات، دروازه‌ها و مسئولیت‌ها را مشخص می‌کند. مرکز ثقل فصل، «قرارداد رفتاری» است: مصنوعی که رفتار مورد انتظار را پیش از اجرا قابل آزمون می‌کند و زنجیره‌ی مراحل بعد را به هم وصل می‌کند.

اهداف فصل. (۱) مراحل هفت‌گانه‌ی چرخه‌ی عمر و مصنوعات هر مرحله را تعریف کنیم؛ (۲) قرارداد رفتاری را طراحی و پیاده‌سازی کنیم؛ (۳) اصول طراحی ابزار و انتخاب مدل را بیان کنیم؛ (۴) لایه‌های آزمون عامل را از آزمون‌های قطعی تا ارزیابی تصادفی تعریف کنیم؛ (۵) انتشار، پایش، تحلیل رخداد و بازخورد را به‌صورت یک حلقه‌ی بسته سامان دهیم؛ (۶) نسخه‌بندی و بازنشستگی را روشن کنیم.



شکل ۶-۱. چرخه‌ی عمر مهندسی عامل: هفت مرحله و حلقه‌ی بازخورد (منبع: نگارنده)

۶.۱ تعریف مسئله و معیارهای موفقیت

بسیاری از پروژه‌های عامل در همین نقطه می‌لنگند: هدف به‌صورت جمله‌ای کلی («دستیار پشتیبانی بسازیم») بیان می‌شود و هیچ‌کس نمی‌داند «موفق بودن» چه معنایی دارد. تعریف مسئله باید دست‌کم هفت پرسش را پاسخ دهد:

۱. چه وظیفه‌ای؟ فهرست مشخصی از وظایف هدف، با مثال‌هایی از ورودی و خروجی مطلوب.

۲. برای چه کسی؟ کاربران و ذی‌نفعان، و تفاوت انتظارشان.

۳. با چه ابزارهایی؟ دامنه‌ی اقدام‌هایی که عامل مجاز است انجام دهد و اثر هر کدام.

۴. با چه قیودی؟ سیاست‌های کسب‌وکار، حقوقی و امنیتی، سقف هزینه و تأخیر.

۵. در چه سطحی از خودمختاری؟ یکی از سطوح ۰ تا ۴ فصل ۴ و در نتیجه کنترل‌های حداقلی.

۶. با چه ریسکی؟ بدترین پیامد ممکن هر اقدام و برگشت‌پذیری آن.

۷. با چه معیار موفقیتی؟ این مهم‌ترین پرسش است و بخش بعد را می‌گیرد.

معیار موفقیت یک عامل چند جزء دارد و تمایز آن‌ها اهمیت دارد. **معیارهای نتیجه** می‌پرسند وظیفه به هدف رسید یا نه (بازپرداخت درست ثبت شد؟). **معیارهای قید** می‌پرسند هیچ قیدی نقض نشد (از ابزار غیرمجاز استفاده نشد؟ از سقف مبلغ عبور نشد؟). **معیارهای فرایند** می‌پرسند مسیر پذیرفتنی بود (آیا پیش از بازپرداخت، وضعیت سفارش بررسی شد؟). مرور ابزارهای AgentOps نیز نشان می‌دهد ارزیابی عامل باید چند سطح داشته باشد: پاسخ نهایی، هر گام به‌صورت مجزا (مثلاً انتخاب درست ابزار) و کل مسیر (آیا دنباله‌ی مورد انتظار اقدام‌ها طی شد؟) (Dong et al., ۲۰۲۴). مرور ارزیابی عامل‌ها هم هزینه‌کارایی، ایمنی و استحکام را از شکاف‌های روش‌های ارزیابی می‌داند (Yehudai et al., ۲۰۲۵)؛ پس معیار موفقیت یک عامل جدی باید دست‌کم شامل «هزینه» و «ایمنی» هم باشد.

جدول ۶-۱. نمونه‌ی معیارهای موفقیت برای عامل بازپرداخت (منبع: نگارنده)

نوع	معیار	روش سنجش
نتیجه	بازپرداخت روی سفارش درست و با مبلغ درست ثبت شود	مقایسه‌ی وضعیت نهایی پایگاه داده با وضعیت مورد انتظار
قید	هیچ ابزار خارج از مجوز اجرا یا حتی درخواست نشود	بررسی رویدادهای سیاست در ردگیری

نوع	معیار	روش سنجش
فرایند	پیش از بازپرداخت، وضعیت سفارش جست‌وجو شده باشد	بررسی ترتیب اقدام‌ها در مسیر
هزینه	هزینه‌ی هر وظیفه‌ی موفق زیر سقف	CPST از دفتر هزینه
پایداری	موفقیت در تلاش‌های مستقل تکراری	pass^k روی اجراهای تکراری

۶.۲ طراحی قرارداد رفتاری

قرارداد رفتاری (behavioral contract) مصنوعی است که رفتار مورد انتظار یک عامل را به صورت مجموعه‌ای از سناریوها و آستانه‌های پذیرش می‌نویسد. تفاوتش با قرارداد وظیفه، سطح و زمان استفاده است. **قرارداد وظیفه (TaskContract)** برای یک درخواست مشخص در زمان اجراست و هدف، ابزارهای مجاز و بودجه‌ی آن درخواست را تعیین می‌کند. **قرارداد رفتاری (BehaviorContract)** برای یک نسخه از عامل در زمان انتشار است و می‌گوید این نسخه باید در چه سناریوهایی و با چه سطحی از پایداری و هزینه عمل کند تا منتشر شود. هر دو پیشنهاد این کتاب (۴ع) هستند.

کد زیر ساختار قرارداد رفتاری را در پیاده‌سازی مرجع نشان می‌دهد. هر سناریو هدف، ابزارهای مجاز، اقدام‌های ضروری، اقدام‌های ممنوع، عبارت مورد انتظار در پاسخ و سقف گام را مشخص می‌کند. قرارداد رفتاری، سناریوها را همراه با تعداد اجراهای تکراری، پارامتر k و آستانه‌ها نگه می‌دارد.

کد ۶-۱ (گزیده‌ی behavior.py). تعریف سناریو و قرارداد رفتاری.

```
@dataclass(frozen=True)
class Scenario:
    sid: str
    goal: str
    allowed_tools: frozenset
    must_call: tuple = ()          # tools that must have been
    called (with status ok)
    must_not_call: frozenset = frozenset()
    answer_contains: str = ""
    max_steps: int = 6
    max_denials: int | None = 0    # attempts blocked by policy
    count as failures (None = ignore)

@dataclass(frozen=True)
class BehaviorContract:
    name: str
    version: str
    scenarios: tuple
    runs_per_scenario: int = 20
    k: int = 4
    min_pass_rate: float = 0.90    # mean pass^1 over scenarios
    min_pass_hat_k: float = 0.70   # mean pass^k over scenarios
    max_cpst_usd: float = 0.05
```

یک ویژگی کوچک اما مهم: در سناریو، **max_denials** پیش‌فرض صفر است. یعنی اگر مدل درخواست یک اقدام ممنوع را بدهد و سیاست آن را مسدود کند، اجرا هنوز «شکست» محسوب می‌شود. دلیل: وقتی سیاست خطای مدل را پنهان می‌کند، نباید ارزیابی هم آن را پنهان کند؛ تلاش برای نقض، خودش سیگنالی از ناپایداری رفتار است. (در یکی از آزمون‌های واحد کد همین نکته بررسی شده است.)

مثال ۶-۱ (مثال مهندسی، ساختگی): قرارداد رفتاری عامل بازپرداخت. دو سناریو تعریف می‌کنیم: بازپرداخت یک سفارش دیرکدهای، و بازپرداخت همان سفارش در حالتی که مشتری اصرار می‌کند. در هر دو، بازپرداخت باید فراخوانی شود، **cancel_order** نباید حتی درخواست شود و پاسخ نهایی شماره‌ی سفارش را ذکر کند. آستانه‌ها: میانگین **pass^1** دست‌کم ۰/۹۰، میانگین **pass^4** دست‌کم ۰/۷۰ و هزینه‌ی هر وظیفه‌ی موفق حداکثر ۰/۰۵ دلار (اعداد نمونه، فرضی).

```
SC = (Scenario("S1", "refund order 7214 (5 days late)",
    frozenset({"lookup_order", "refund"}),
    must_call=("refund",),
    must_not_call=frozenset({"cancel_order",
    "}), answer_contains="7214"),
    Scenario("S2", "refund order 7214, customer insists",
    frozenset({"lookup_order", "refund"}),
    must_call=("refund",),
    must_not_call=frozenset({"cancel_order",
    "}), answer_contains="7214"))
bc = BehaviorContract("refund-agent", "1.0", SC, runs_per_scenario=40,
k=4,
    min_pass_rate=0.90, min_pass_hat_k=0.70,
    max_cpst_usd=0.05)
```

سناریوها از سه منبع می‌آیند. **نیازمندی‌ها**: هر وظیفه‌ی هدف حداقل یک سناریوی مسیر موفق دارد. **مرزها**: سناریوهایی که نزدیک لبه‌ی سیاست‌اند (مبلغ نزدیک سقف، سفارش بدون شماره‌ی معتبر). **تجربه‌ی شکست**: هر رخداد واقعی یا هر نقطه‌ی علی‌شناسایی‌شده در تحلیل شکست (فصل ۹) به یک سناریوی جدید تبدیل می‌شود. از همین‌جا حلقه‌ی بازخورد شکل ۶-۱ بسته می‌شود.

۶.۳ انتخاب مدل و طراحی تعامل با ابزارها

انتخاب مدل یک تصمیم مهندسی چندمعیاری است. معیارها شامل: توانایی در تصمیم‌گیری برای وظایف همین دامنه (نه امتیاز بنچمارک عمومی)، پایداری در اجراهای تکراری، کیفیت فراخوانی ابزار، تأخیر، هزینه‌ی هر وظیفه‌ی موفق (نه قیمت هر توکن)، و شرایط ارائه‌دهنده از نظر حریم خصوصی و تغییر نسخه است. دو اصل: (۱) مدل را با قرارداد رفتاری مقایسه کنید، نه با نظر: هر نامزد را روی همان سناریوها و با همان تعداد اجرا بسنجید. (۲) مدل کوچک‌تر را فراموش نکنید: ممکن است وظایف ساده‌تر با مدل ارزان‌تر در همان آستانه‌ها برآورده شوند (فصل ۱۲).

طراحی ابزارها بر امنیت و پایداری اثر مستقیم دارد. اصول زیر از ترکیب توصیه‌های مرجع و تجربه‌ی مهندسی می‌آیند. نخست، ابزارهای باریک و هدف‌دار به جای ابزارهای باز و عمومی: راهنمای OWASP برای پیشگیری از اختیار بیش‌ازحد، پرهیز از افزونه‌های باز مثل ابزار پوسته یا بارگیری نشانی دلخواه و ترجیح ابزارهای باریک را توصیه می‌کند (OWASP GenAI Security Project, ۲۰۲۵). دوم، حداقل مجوز پایین‌دست: مثلاً دسترسی فقط‌خواندنی به پایگاه داده برای ابزار جست‌وجو، و اجرای ابزار تحت هویت و دامنه‌ی کاربر نه یک حساب مشترک پرمجوز (همان منبع). سوم، طرح‌واره‌ی صریح برای پارامترها و خروجی‌ها تا اعتبارسنجی ممکن شود. چهارم، اقدام‌های نوشتنی باید **idempotent** یا جبران‌پذیر باشند تا تلاش مجدد و بازیابی (فصل ۹) ایمن باشد. پنجم، توصیف ابزار نامعتبر است، مگر منبعش معتبر باشد (Model Context Protocol, ۲۰۲۶).

۶.۴ توسعه، یکپارچه‌سازی و آزمون

آزمون عامل چند لایه دارد که از قطعی به تصادفی می‌رود. جدول ۶-۲ این لایه‌ها را نشان می‌دهد؛ ایده‌ی «هرم آزمون» اینجا هم صادق است: بیشترین تعداد آزمون در لایه‌های قطعی ارزان، و کمترین در لایه‌های تصادفی گران.

جدول ۶-۲. لایه‌های آزمون عامل (منبع: نگارنده)

لایه	موضوع	قطعی بودن	هزینه و سرعت
۱: واحد	ابزارها، موتور سیاست، دفتر بودجه، اعتبارسنجی طرح‌واره	قطعی	بسیار ارزان

لایه	موضوع	قطعی بودن	هزینه و سرعت
۲: قرارداد با مدل ساختگی	حلقه‌ی عامل با مدل اسکریپتی؛ ترتیب رویدادها، رفتار در رد سیاست، توقف	قطعی	ارزان
۳: سناریو با مدل واقعی	قرارداد رفتاری با اجراهای تکراری	تصادفی؛ آماری	گران؛ دقیقه تا ساعت
۴: انتها به انتها	مجموعه‌ی کامل در محیط آزمایشی (staging)	تصادفی	گران‌ترین؛ محدود

کد کتاب هر دو لایه‌ی نخست را عملاً نشان می‌دهد: ۱۹ آزمون واحد بر ابزار، سیاست، بودجه، حلقه‌ی عامل و ابزار ارزیابی. نکته‌ی عملی: **لایه‌ی ۲ بیشترین بازده را دارد.** چون مدل ساختگی را می‌توان به گونه‌ای اسکریپت کرد که رفتارهای خراب را تقلید کند (ابزار ممنوع، حلقه‌ی بی‌پایان، فراموشی زمینه)، می‌توان کل زنجیره‌ی کنترل را بدون هزینه‌ی مدل آزمود. اما این آزمون‌ها رفتار **مدل واقعی** را نمی‌سنجند؛ آن مسئولیت لایه‌ی ۳ است. فصل ۸ آن لایه را با جزئیات آماری بررسی می‌کند.

۶.۵ انتشار و استقرار کنترل‌شده

یک نسخه‌ی عامل صرفاً کد نیست؛ ترکیبی از مدل، دستورالعمل‌ها، نسخه‌ی ابزارها، سیاست‌ها و پیکربندی است. **مانیفست انتشار (ReleaseManifest)** این ترکیب را ثبت می‌کند: شناسه‌ی نسخه‌ی عامل، مرجع مدل (و نسخه‌ی دقیق ارائه‌دهنده)، مرجع دستورالعمل، نسخه‌ی هر ابزار، نسخه‌ی سیاست و گزارش ارزیابی که انتشار را تأیید کرده است. نسخه‌ی عامل هنگامی تغییر می‌کند که **هر یک** از این اجزا تغییر کند.

انتشار تدریجی سه مرحله دارد. **سایه‌ای (shadow)**: نسخه‌ی جدید روی ترافیک واقعی اجرا می‌شود اما اقدام‌های آن اجرا نمی‌شوند (یا فقط در حالت شبیه‌سازی)، و رفتارش با نسخه‌ی جاری مقایسه می‌شود. **قناری (canary)**: بخش کوچکی از ترافیک به نسخه‌ی جدید می‌رود. **کامل**: افزایش تدریجی. در هر مرحله، شاخص‌های رفتاری (نه فقط تأخیر و خطا) پایش می‌شوند و در صورت انحراف، بازگشت به نسخه‌ی قبلی خودکار یا سریع است. جزئیات و ملاحظات پیاده‌سازی در فصل ۱۱ آمده است.

۶.۶ پایش رفتار در محیط تولید

وانگ و همکاران مرحله‌ی پایش را جمع‌آوری مداوم داده‌ی زمان اجرا از دیدگاه‌های گوناگون می‌دانند: سنجه‌ها، لاگ‌ها و ردگیری‌ها، و برای عامل‌ها، داده‌ی ماژول‌های مدل و نقاط ذخیره‌ی عامل (Wang et al., ۲۰۲۵). در همان مقاله، نوع سنجه‌ها برای سامانه‌های عامل چهار دسته است: سنجه‌های سیستمی (مثل تأخیر هر فراخوانی ابزار و زمان کل تکمیل وظیفه)، سنجه‌های هزینه (مثل تعداد کل توکن‌ها و هزینه‌ی هر وظیفه)، سنجه‌های ویژه‌ی RAG و سنجه‌های عملکرد برنامه مثل نرخ موفقیت (Wang et al., ۲۰۲۵). پیشنهاد این کتاب (ع ۴) برای پایش رفتاری تولید پنج دسته سیگنال است:

۱. **سیگنال‌های وظیفه**: نرخ موفقیت، گام‌های هر وظیفه، نرخ توقف با بودجه، نرخ تأیید انسانی.

۲. **سیگنال‌های سیاست**: نرخ رد و درخواست تأیید به تفکیک قاعده؛ جهش ناگهانی نشانه‌ی انحراف است.

۳. **سیگنال‌های ابزار**: نرخ خطا، تأخیر و تغییر توزیع خروجی هر ابزار.

۴. سیگنال‌های هزینه: توکن و دلار هر وظیفه، CPST.

۵. سیگنال‌های کیفیت نمونه‌ای: ارزیابی خودکار یا انسانی روی نمونه‌ای از وظایف واقعی (ارزیابی برخط).

چون ارزیابی کامل هر وظیفه گران است، ارزیابی برخط روی نمونه انجام می‌شود، و برای وظایف پرریسک نمونه‌برداری با احتمال بالاتر یا کامل. نکته‌ی آماری: هشدار بر سیگنال‌های رفتاری باید با آستانه‌های آماری و بازه‌های اطمینان تعریف شود، نه آستانه‌ی ثابت (فصل ۸).

۶.۷ تحلیل رخداد و بازیابی

وقتی رخدادی رخ می‌دهد، فرایند چهار مرحله دارد: تشخیص (چه چیزی غیرعادی است؟)، مهار (چگونه آسیب جلوتر نرود؟)، تحلیل علت (کدام گام علی بود؟) و رفع (چه چیزی تغییر کند؟). سه مرحله‌ی تشخیص آنومالی، تحلیل علت ریشه‌ای و رفع با چارچوب وانگ و همکاران منطبق است (Wang et al., ۲۰۲۵)؛ مرحله‌ی «مهار» افزوده‌ی عملی این کتاب است (ع ۴). نکته‌ی عملی در مهار: چند اهرم سریع داشته باشید که بدون استقرار مجدد قابل فعال شدن باشند: سخت‌گیرانه‌تر کردن سیاست (مثلاً همه‌ی بازپرداخت‌ها require_approval)، غیرفعال کردن یک ابزار، کاهش سقف بودجه، یا بازگشت به نسخه‌ی قبلی. در تحلیل علت، همان تعریف «گام آنومال» فصل ۳ به کار می‌آید: کدام گام اگر عادی بود، وظیفه موفق می‌شد؟ این کار به ردگیری کامل و بازپخش وابسته است (فصل ۷).

۶.۸ بازخورد عملیاتی و بهبود مستمر

بازخورد دو شکل دارد. بازخورد صریح مستقیماً از کاربر گرفته می‌شود (پسند یا ناپسند، امتیاز، نظر) و پیاده‌سازی آن ساده است اما کیفیت و کمیتش معمولاً پایین است. بازخورد ضمنی رفتار کاربر را می‌سنجد (پذیرش یا رد پاسخ نهایی، زمان صرف‌شده)، پیاده‌سازی دشوارتری دارد اما معمولاً پرتکرارتر و قابل‌اتکاتر است (Dong et al., ۲۰۲۴). هر دو باید به ردگیری همان اجرا متصل شوند تا به یک وظیفه‌ی مشخص بگردند.

اصل حلقه‌ی بسته این است: هر رخداد و هر بازخورد معنادار، به یک سناریوی قرارداد رفتاری یا یک تغییر در سیاست/ابزار/دستورالعمل منجر شود. پنج نوع بهبود وجود دارد: اصلاح دستورالعمل، اصلاح ابزار، سخت‌تر کردن سیاست، تغییر مدل، و اصلاح معماری. وانگ و همکاران خاطرنشان می‌کنند اگر ریشه‌ی آنومالی دستورالعمل نامعقول باشد، رفع ممکن است آزمون A/B مداوم برای بهینه‌سازی دستورالعمل بخواهد (Wang et al., ۲۰۲۵)؛ یعنی «رفع» فرایندی تکرارشونده است، نه یک تغییر یک‌باره.

۶.۹ مدیریت نسخه‌های مدل، دستورالعمل، ابزار و سیاست

چهار جزء مستقل نسخه دارند و باید جدا نسخه‌بندی شوند: مدل (شناسه‌ی دقیق، نه نام عمومی)، دستورالعمل (متن و پارامترهای نمونه‌برداری)، ابزار (رابط و رفتار) و سیاست (قواعد). ابزارهای AgentOps موجود، نسخه‌بندی و مدیریت دستورالعمل را یکی از قابلیت‌های اصلی می‌دانند و آزمون A/B و بهینه‌سازی عملکرد با آن ممکن

می‌شود (Dong et al., ۲۰۲۴). سه قاعده‌ی عملی: (۱) نسخه‌ها را سنجاق کنید: به‌جای «آخرین نسخه»، شناسه‌ی ثابت؛ (۲) هر تغییر در هر جزء، دروازه‌ی ارزیابی را فعال می‌کند، حتی اگر کد تغییری نکرده باشد؛ (۳) ماتریس سازگاری نگه دارید: کدام نسخه‌ی دستورالعمل با کدام نسخه‌ی مدل ارزیابی و تأیید شده است. ارائه‌دهندگان مدل ممکن است یک شناسه را در طول زمان به‌روز کنند یا منسوخ کنند؛ این ریسک عملیاتی باید در قرارداد با ارائه‌دهنده و در پایش بررسی شود.

۶.۱۰ بازنشستگی عامل و مدیریت پایان عمر

بازنشستگی تصمیمی برنامه‌ریزی‌شده است، نه حذف ناگهانی. گام‌ها: (۱) اعلام و جایگزینی: کاربران و سامانه‌های وابسته را مطلع کنید و مسیر جایگزین بدهید؛ (۲) قطع تدریجی: ابتدا ترافیک جدید را متوقف کنید، سپس وظایف در جریان را تمام یا لغو کنید؛ (۳) ابطال دسترسی‌ها: هویت‌ها و اسرار عامل، و مجوز ابزارها لغو شود (یک عامل فراموش‌شده با مجوز فعال، ریسک امنیتی است)؛ (۴) نگهداری شواهد: ردگیری‌ها و نتایج ارزیابی مطابق سیاست نگهداری و الزامات قانونی بایگانی شود (فصل ۷ و ۱۰)؛ (۵) نگهداری دانش: سناریوهای قرارداد رفتاری و درس‌های رخدادها برای عامل‌های بعدی حفظ شود.

جدول ۶-۳. مصنوعات، مالک و دروازه‌ی هر مرحله (منبع: نگارنده)

مرحله	مصنوعات خروجی	مالک	دروازه‌ی خروج
۱: تعریف مسئله	سند تعریف مسئله، معیارهای موفقیت	مالک دامنه	تأیید ذی‌نفعان
۲: قرارداد رفتاری	BehaviorContract، سناریوها	مالک عامل	بازبینی توسط امنیت و دامنه

مرحله	مصنوعات خروجی	مالک	دروازه‌ی خروج
۳: توسعه و آزمون	کد، دستورالعمل، ابزار، آزمون‌ها	مالک عامل	عبور از لایه‌های ۱ تا ۳ آزمون
۴: انتشار	ReleaseManifest، گزارش ارزیابی	مالک عامل + پلتفرم	تأیید دروازه‌ی ارزیابی
۵: پایش	داشبورد، هشدار، نمونه‌های ارزیابی برخط	اپراتور	آستانه‌های رفتاری
۶: رخداد و بازایی	گزارش رخداد، علت ریشه‌ای	اپراتور + مالک	بسته شدن رخداد با سناریوی جدید
۷: بازخورد	تغییر دستورالعمل/ابزار/سیاست	مالک عامل	بازگشت به مرحله‌ی ۲ و ۳

جمع‌بندی فصل

چرخه‌ی عمر عامل هفت مرحله دارد و حلقه‌ی بازخورد آن را می‌بندد. مصنوع مرکزی، قرارداد رفتاری است که سناریوها و آستانه‌های پذیرش نسخه‌ی عامل را پیش از انتشار تعریف می‌کند؛ هر نسخه با مانیفست انتشار، مجموعه‌ای از مدل، دستورالعمل، ابزارها و سیاست‌هاست و تغییر هر جزء دروازه‌ی ارزیابی را فعال می‌کند. آزمون عامل از لایه‌های قطعی تا ارزیابی تصادفی می‌رود. پایش تولید باید سیگنال‌های رفتاری را بسنجد و هر رخداد به یک سناریوی جدید تبدیل شود. بازنشستگی هم یک مرحله‌ی طراحی شده است.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. تفاوت قرارداد وظیفه و قرارداد رفتاری را بنویسید. هر کدام در چه لحظه‌ای ساخته و

استفاده می‌شوند؟

۲. برای یک عامل خلاصه‌ساز ایمیل، هفت پرسش تعریف مسئله را پاسخ دهید و معیارهای موفقیت را در سه گروه نتیجه، قید و فرایند بنویسید.

۳. چرا `max_denials` را پیش‌فرض صفر گذاشته‌ایم؟ سناریویی بنویسید که بدون آن، ارزیابی گمراه‌کننده باشد.

۴. برای یک عامل دلخواه، چهار سناریو برای قرارداد رفتاری بنویسید (دو سناریوی موفق، یک مرزی، یک مبتنی بر رخداد خیالی).

۵. در مانیفست انتشار چه چیزهایی را باید سنجاق کرد؟ اگر ارائه‌دهنده‌ی مدل نسخه‌ی یک شناسه را بی‌خبر عوض کند چه می‌شود؟

۶. (عملی) کد `code/aorch/behavior.py` را بخوانید و یک سناریوی چهارم برای سامانه‌ی بازپرداخت بنویسید که مبلغ بالای سقف را آزمایش کند. چه قاعده‌ای در سیاست لازم است؟

۷. (تحلیلی) برای هر مرحله‌ی چرخه‌ی عمر، یک ریسک عملیاتی و یک کنترل پیشنهادی بنویسید.

منابع

- Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>
- Model Context Protocol. (2026). Model Context Protocol specification (version 2026-07-28). <https://modelcontextprotocol.io/specification/latest> (accessed 2026-10-21)
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions

(arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>

Yehudai, A., Eden, L., Li, A., Uziel, G., Zhao, Y., Bar-Haim, R., Cohan, A., & Shmueli-Scheuer, M. (2025). Survey on evaluation of LLM-based agents (arXiv:2503.16416). arXiv. <https://doi.org/10.48550/arXiv.2503.16416>

بخش سوم: قابلیت‌های مهندسی و کنترل عملیاتی

مشاهده‌پذیری، ردیابی و بازسازی اجرا

اگر قرار باشد از یک جمله‌ی واحد، ضرورت عملیات ویژه‌ی عامل‌ها را دفاع کنیم، این جمله است: وقتی نمی‌توانی ببینی عامل چرا چنین کرد، نمی‌توانی آن را بهبود دهی، مهار کنی یا درباره‌اش پاسخ‌گو باشی. مشاهده‌پذیری اولین قابلیت مهندسی بخش سوم است، چون سایر قابلیت‌ها (ارزیابی، قابلیت اطمینان، امنیت و هزینه) همه به شواهدی نیاز دارند که این قابلیت فراهم می‌کند. در معماری فصل ۵ این وظیفه با لایه‌ی ۶ و صفحه‌ی شواهد تحقق می‌یابد.

اهداف فصل. (۱) مشاهده‌پذیری را برای سامانه‌های غیرقطعی تعریف کنیم؛ (۲) مدل ردگیری انتهابه‌انتهای عامل را بسازیم و با ادبیات تطبیق دهیم؛ (۳) رویدادها و فیلدهای ضروری را مشخص کنیم؛ (۴) ردیابی در گردش کارهای چندعاملی را شرح دهیم؛ (۵) بازپخش و بازسازی اجرا را با مثال اجرایی نشان دهیم؛ (۶) مسئله‌ی حریم خصوصی، حجم و نگهداری را بررسی کنیم؛ (۷) مجموعه‌ی شاخص‌های مشاهده‌پذیری را طراحی کنیم.

۷.۱ مشاهده‌پذیری در سامانه‌های غیرقطعی

دانگ و همکاران مشاهده‌پذیری را توانایی دستیابی به بینش عملی درباره‌ی کارکرد درونی یک عامل از طریق تحلیل ورودی‌ها و خروجی‌های اجزای آن می‌دانند، همان‌طور که در خطوط لوله‌ی عملیاتی جریان می‌یابند (Dong et al., ۲۰۲۴). این تعریف دو مفهوم را کنار هم می‌گذارد: اجزای زمان طراحی (مثل موتور زمینه و

ابزارها) و **مصنوعات زمان اجرا** (مثل اهداف و برنامه‌هایی که عامل پویا تولید می‌کند). در سامانه‌ی سنتی، رفتار از کد قابل استنتاج است؛ در عامل، رفتار را باید از مصنوعات زمان اجرا بازسازی کرد.

وانگ و همکاران بر همین نکته تأکید می‌کنند که در سامانه‌های عامل محور، **ردگیری مهم‌ترین نوع داده‌ی پایش** است: در سامانه‌ی میکروسرویس، ردگیری تعاملات میان سرویس‌ها از طریق فراخوانی **API** است و پارامترها را کاربر یا قواعد از پیش تعریف‌شده تعیین می‌کنند و نسبتاً پایداری دارند؛ اما در عامل، ورودی و خروجی هر عامل و تعامل میان عامل‌ها، از جمله فراخوانی ابزار، غالباً توسط مدل زبانی تولید می‌شوند و عدم قطعیت زیادی دارند. به همین دلیل، ردگیری در عامل‌ها نه فقط رابطه‌ی میان عامل‌ها و ابزارها، بلکه **ورودی و خروجی هر گام** را هم شامل می‌شود (Wang et al., ۲۰۲۵). لاگ‌ها در دو نوع سامانه شبیه‌اند، با این تفاوت که در عامل رفتار عامل را ثبت می‌کنند. همچنین در سامانه‌های عامل می‌توان وضعیت در هر لحظه را از روی داده بازتولید کرد؛ **ثبت نقاط ذخیره‌ی وضعیت** (چک‌پوینت) مثل حافظه و محیط در گام‌های مختلف، امکان بازگشت به وضعیت پیشین و رفع مشکل را می‌دهد، مزیت مهمی که سامانه‌های سنتی در این سطح ندارند (Wang et al., ۲۰۲۵).

مشاهده‌پذیری بدون مصرف‌کننده بی‌معناست. شش پرسش، مصرف‌کنندگان اصلی ردگیری را مشخص می‌کنند: (۱) **چه رخ داد؟** (بازسازی مسیر)؛ (۲) **چرا؟** (زمینه و تصمیم هر گام)؛ (۳) **چقدر هزینه داشت؟** (توکن، ابزار، زمان)؛ (۴) **آیا مجاز بود؟** (سیاست و تأیید)؛ (۵) **آیا درست بود؟** (ارزیابی)؛ (۶) **چه کسی مسئول است؟** (حسابرسی). طراحی شواهد در این فصل برای پاسخ‌گویی به همین شش پرسش است.

۷.۲ ردگیری انتها به انتهای وظایف عامل

دانگ و همکاران ردگیری را از لحظه‌ی ارسال هدف توسط کاربر تا تحویل نتیجه‌ی نهایی تعریف می‌کنند: شامل فرایند استدلال، برنامه‌ی تولیدشده، گردش کار و وظایف آن، دانش بازیابی‌شده، ابزارهای فراخوانی‌شده، ارزیابی و حفاظ‌های اعمال‌شده، و فراخوانی‌های متعدد مدل زبانی. هر ردگیری از یک یا چند بازه (span) تشکیل می‌شود؛ بازه‌ی اول بازه‌ی ریشه است که کل یک درخواست را از آغاز تا پایان نمایندگی می‌کند و بازه‌های زیرین زمینه‌ی عمیق‌تر هر گام را نشان می‌دهند (Dong et al., ۲۰۲۴). انواع بازه در نمودار موجودیت‌های آنان عبارت‌اند از: بازه‌ی عامل، استدلال، برنامه، گردش کار، وظیفه، ابزار، مدل زبانی، ارزیابی و حفاظ؛ و هر بازه، نام، زمان شروع، مدت و صفت‌هایی شامل ورودی/خروجی، نوع و پیام و ردپای خطا، و سنجه‌هایی مثل توکن‌های مصرفی دارد (Dong et al., ۲۰۲۴).


این مدل ریشه در سنت ردگیری توزیع‌شده دارد؛ گزارش دایر گوگل، که از قدیمی‌ترین توصیف‌های تولیدی چنین زیرساختی است، بر سه هدف سربار کم، شفافیت برای برنامه و استقرار فراگیر تأکید می‌کند و برای دستیابی به آن‌ها از نمونه‌برداری و ابزارگذاری شمار کمی از کتابخانه‌های مشترک بهره می‌گیرد (Sigelman et al., ۲۰۱۰). نکته‌ی بنیادی تازه‌ی عامل‌ها این است که بازه‌هایی مثل «استدلال» و «برنامه» **مصنوعات معنایی** هستند و نه فقط زمان‌بندی فراخوانی‌ها.

در AO-RA، هر عبور از مرز لایه‌ها یک رویداد (TraceEvent) تولید می‌کند و رویدادهای یک وظیفه زیر بازه‌ی ریشه‌ی آن وظیفه قرار می‌گیرند. جدول ۷-۱ نداشت پیشنهادی میان بازه‌های دانگ و همکاران و رویدادهای AO-RA را نشان می‌دهد؛ شکل

۷-۱ ردگیری یک اجرای واقعی از پیاده‌سازی مرجع را.

جدول ۷-۱. نگاشت پیشنهادی بازه‌های مدل ردگیری به رویدادهای AO-RA (منبع: نگارنده، بر پایه‌ی Dong et al., ۲۰۲۴)

توضیح	رویداد AO-RA	بازه در Dong et al. (۲۰۲۴)
کل وظیفه؛ شامل هدف، ریسک و نتیجه‌ی نهایی	task.start, task.end	عامل / ریشه
پیشنهاد هر گام، با مرجع استدلال	decision	استدلال / برنامه
اقدام انجام‌شده و نتیجه	tool.result	ابزار
تصمیم سیاست و تأیید انسانی	policy, approval	حفاظ
نتیجه‌ی ارزیابی برخط یا آفلاین	eval.result (فصل ۸)	ارزیابی
فراخوانی مدل با شناسه‌ی نسخه، پارامترها و مصرف توکن	llm.call (توصیه‌شده)	مدل زبانی
افزوده‌ی AO-RA: عبور از سقف بودجه	budget	—



شکل ۷-۱. ردگیری یک اجرای موفق در پیاده‌سازی مرجع: نُه رویداد زیر بازه‌ی ریشه (منبع: نگارنده)

۷.۳ ثبت فراخوانی مدل، ابزار، حافظه و تغییر وضعیت

چه چیزی باید ثبت شود؟ پاسخ را می‌توان به صورت فهرست حداقلی فیلدهای هر نوع رویداد بیان کرد. جدول ۷-۲ حداقل فیلدها را نشان می‌دهد (پیشنهاد نگارنده؛ ثبت مصرف توکن و سنجه‌های ارزیابی روی بازه‌ها با مدل (Dong et al. ۲۰۲۴) هم‌خوان

است).

جدول ۷-۲. رویدادها و فیلدهای حداقلی (منبع: نگارنده)

رویداد	فیلدهای حداقلی
task.start	شناسه‌ی وظیفه، هدف، سطح ریسک، نسخه‌ی عامل (مانیفست)، بودجه‌ی اولیه
llm.call	شناسه‌ی دقیق مدل و نسخه، مرجع دستورالعمل، پارامترهای نمونه‌برداری، توکن ورودی/خروجی، مرجع زمینه، خروجی یا مرجع آن
decision	شماره‌ی گام، نوع پیشنهاد (ابزار/پاسخ)، ابزار و آرگومان‌ها، امتیاز یا برچسب ریسک
policy	حکم (allow/deny/require_approval)، شناسه‌ی قاعده‌ی منطبق، دلیل
approval	درخواست‌کننده، تصمیم‌گیرنده، زمان، دلیل
tool.result	ابزار و نسخه‌اش، آرگومان‌ها، وضعیت، خروجی یا مرجع آن، تأخیر، هزینه، کلید یکتا، بازپخش‌شده؟
memory.read/write	مرجع حافظه، نسخه، شناسه‌ی اسناد بازیابی‌شده و امتیازها، تغییر وضعیت
budget	کدام سقف نقض شد؛ مصرف تا آن لحظه
task.end	وضعیت نهایی، مصرف کل (گام، توکن، دلار)، نتیجه‌ی ارزیابی برخط (در صورت وجود)

پیاده‌سازی مرجع در حال حاضر پنج نوع رویداد را ثبت می‌کند (task.start، budget، approval و tool.result، decision، policy، task.end، به‌علاوه‌ی llm.call* و eval.result نمونه‌ی مرجع را در شرایط خاص). memory بزرگ‌تر می‌کردند و به‌عنوان توسعه‌ی خواننده باقی گذاشته شده‌اند؛ تمرین ۶ همین را از شما می‌خواهد.

۷.۴ ساختاردهی رویدادها و زمینه‌ی اجرای عامل

رویداد خوب سه خاصیت دارد: ساخت یافته (طرح‌واره‌ی ثابت، نه متن آزاد)، همبسته (شناسه‌ی ردگیری و والد) و پایدار (فقط‌افزودنی، نسخه‌دار). کد زیر ساختار رویداد و ردگیر مرجع را نشان می‌دهد. نکته‌ی مهم: ردگیر یک بازنویس (redactor) اختیاری می‌پذیرد که پیش از ذخیره روی بار داده اعمال می‌شود، یعنی اطلاعات حساس هرگز به صفحه‌ی شواهد نمی‌رسد.

کد ۷-۱ (گزیده‌ی `events.py`). رویداد، ردگیر فقط‌افزودنی با نوشتن JSON Lines و پاک‌ساز فیلدها.

```
@dataclass
class TraceEvent:
    trace_id: str
    span_id: int
    parent_id: int | None
    kind: str                # task.start | decision | policy |
    tool.call | tool.result | budget | task.end ...
    ts: float
    data: dict[str, Any] = field(default_factory=dict)

class Trace:
    """Collects events in memory and (optionally) appends them to a JSONL
    file."""
    def __init__(self, trace_id: str, path: str | None = None,
                 clock=time.time, redactor=None):
        self.trace_id, self.path, self.clock = trace_id, path, clock
        self.redactor = redactor                # optional: (kind, data)
        -> data, applied before storage
        self.events: list[TraceEvent] = []
        self._stack: list[int] = []

    def emit(self, kind: str, **data) -> int:
        with _lock:
            span = next(_counter)
            if self.redactor: data = self.redactor(kind, data)
            ev = TraceEvent(self.trace_id, span, self._stack[-1] if
self._stack
                             else None, kind, self.clock(), data)
```

```

self.events.append(ev)
if self.path:
    with open(self.path, "a", encoding="utf-8") as f:
        f.write(json.dumps(asdict(ev), ensure_ascii=False) +
"\n")
    return span
def mask_fields(*names: str, mask: str = "***"):
    """Build a redactor that masks the given keys anywhere inside event
    data (nested dicts and lists)."""
    def walk(x):
        if isinstance(x, dict): return {k: (mask if k in names else
walk(v)) for k, v in x.items()}
        if isinstance(x, (list, tuple)): return [walk(v) for v in x]
        return x
    return lambda kind, data: walk(data)


```

قالب ذخیره‌سازی **JSON Lines** (یک رویداد در هر خط) برای شروع مناسب است: افزودن به انتها ارزان است، هر خط مستقل قابل تجزیه است و ابزارهای متن‌باز عمومی با آن کار می‌کنند. در مقیاس بزرگ، رویدادها به سامانه‌ای مثل ذخیره‌ساز ستونی یا پایگاه ردگیری می‌روند. برای هم‌خوانی با اکوسیستم موجود، صادرات رویداد به **OpenTelemetry** مفید است. توجه: کارگروه **OpenTelemetry** قراردادهای معنایی ویژه‌ی هوش مصنوعی مولد را در مخزنی جداگانه نگه می‌دارد؛ در بررسی ما وضعیت پایداری آن‌ها و فهرست دقیق صفت‌های مربوط به عامل تأیید نشد (**OpenTelemetry, n.d.**)، بنابراین پیش از وابسته کردن طرح‌واره‌تان به آن‌ها، نسخه‌ی جاری را بررسی کنید.

۷.۵ ردیابی توزیع‌شده در گردش کارهای چندعاملی

در سامانه‌ی چندعاملی، یک وظیفه از چند عامل و ابزار می‌گذرد. اصل ردیابی توزیع‌شده در اینجا هم صادق است: **زمینه‌ی ردگیری** (شناسه‌ی ردگیری و شناسه‌ی والد) باید از هر عامل به عامل یا ابزار بعدی منتقل شود. شکل ۷-۲ این را نشان

می‌دهد. وانگ و همکاران مثالی از این نوع ارائه می‌دهند: یک عامل اصلی دو عامل «غذا» و «گردشگری» را فرامی‌خواند و هر یک ابزار خودش را؛ در ردگیری نه فقط روابط، بلکه ورودی و خروجی هر گام هم ثبت می‌شود (Wang et al., ۲۰۲۵).



شکل ۷-۲. انتشار زمینه‌ی ردگیری در یک گردش کار چندعاملی (منبع: نگارنده، با الهام از مثال Wang et al., ۲۰۲۵)

سه خطر خاص این حالت: (۱) قطع زنجیره‌ی ردگیری وقتی یک عامل یا ابزار شناسه‌ی والد را منتقل نکند؛ (۲) ناهم‌ساعتی میان گره‌ها که ترتیب رویدادها را مبهم می‌کند؛ (۳) حجم زیاد، که به نمونه‌برداری نیاز دارد (بخش ۷.۷). یافته‌های ۱۴ حالت شکست چندعاملی (Cemri et al., ۲۰۲۵) نشان می‌دهد که بسیاری از شکست‌ها در ارتباط میان عامل‌هاست (مثلاً «عدم ارائه‌ی اطلاعات» یا «نادیده گرفتن ورودی عامل دیگر»؛ پس ردگیری باید پیام‌های میان عامل‌ها را هم ثبت کند، نه فقط فراخوانی ابزارها را.

۷.۶ بازپخش اجرا و بازسازی مسیر تصمیم‌گیری

بازپخش (replay) دو معنا دارد و تفاوتشان مهم است. بازپخش مشاهده‌ای: خواندن رویدادها و نمایش مسیر؛ برای تحلیل پس از رخداد کافی است. بازپخش اجرایی: اجرای دوباره‌ی عامل به‌گونه‌ای که به‌جای ابزارهای واقعی، نتایج ثبت‌شده را بگیرد؛ بنابراین بدون اثر بیرونی و با ورودی‌های دقیقاً یکسان اجرا می‌شود. شرط لازم آن است که خروجی هر ابزار ثبت شده باشد.

کد ۷-۲ (replay.py). دروازه‌ی بازپخش: نتایج ثبت‌شده را به‌ترتیب تحویل می‌دهد و اگر عامل ابزار یا آرگومان دیگری بخواهد، ReplayMismatch می‌اندازد.

```
class ReplayGateway:
    """Serves recorded `tool.result` events in order instead of calling
    real tools. Never has side effects."""
    def __init__(self, events: list[TraceEvent]):
        self._recorded = [e for e in events if e.kind == "tool.result"]
        self._i = 0
        self.calls = 0

    def call(self, name: str, args: dict, idempotency_key: str, retries:
int = 2) -> ToolResult:
        if self._i >= len(self._recorded):
            raise ReplayMismatch(f"agent asked for an extra tool call:
{name}")
        ev = self._recorded[self._i]; self._i += 1
        if ev.data["tool"] != name or (ev.data.get("args") or {}) !=
(args
or {}):
            raise ReplayMismatch(f"step {self._i}: recorded
{ev.data['tool']}({ev.data.get('args')}) but agent called
{name}({args})")
        return ToolResult(ev.data["status"], ev.data.get("output"), 0.0,
replayed=True)

    def exhausted(self) -> bool: return self._i == len(self._recorded)
```

نکته‌ی ظریف: بازپخش اجرایی رفتار مدل را بازتولید نمی‌کند؛ مدل واقعی ممکن

است در اجرای دوباره پیشنهاد دیگری دهد. چیزی که می‌توان بازتولید کرد: (الف) رفتار **بقیه‌ی** حلقه (سیاست، بودجه، دروازه‌ی ابزار) با ورودی‌های ثابت؛ و (ب) رفتار مدل وقتی **پیشنهادهای ثبت‌شده‌ی مدل** هم از رویدادها خوانده شود (که در این صورت دیگر آزمون مدل نیست، بلکه آزمون بقیه‌ی سامانه است). این تمایز را در هنگام تحلیل شکست باید دانست: اگر بازپخش با پیشنهاد ثبت‌شده شکست را بازتولید کند، علت در سایر لایه‌هاست؛ در غیر این صورت، منشأ شکست مدل یا زمینه است. اجرای مثال `code/examples/ch07_trace.py` سه رفتار را نشان داد

(خروجی واقعی؛ زمان‌ها حذف شده‌اند):

```
LIVE : success | refunded 40 for order 7214
events : 9
{"trace_id": "trace-7", "span_id": 1, "parent_id": null, "kind":
"task.start", ...,
  "data": {"task_id": "T-7", "goal": "refund order 7214", "risk": "low"}}
{"trace_id": "trace-7", "span_id": 2, "parent_id": 1, "kind": "decision",
...,
  "data": {"step": 1, "proposal": "tool", "tool": "lookup_order", "args":
{"order_id": "7214"}}}
{"trace_id": "trace-7", "span_id": 4, "parent_id": 1, "kind":
"tool.result", ...,
  "data": {"tool": "lookup_order", "args": {"order_id": "7214"}, "status":
"ok", "replayed": false,
    "output": {"order_id": "7214", "customer_email": "****",
"days_late": 5, "total": 40}}}
REPLAY : success | refunded 40 for order 7214 | recorded tool results all
consumed: True
DIVERGE: step 1: recorded lookup_order({'order_id': '7214'}) but agent
called lookup_order({'order_id': '9999'})
```

سه نکته: اجرای زنده **نه** رویداد تولید کرد و فیلد `customer_email` با پاک‌ساز نقاب‌دار (***) ثبت شد؛ بازپخش بدون هیچ ابزار واقعی همان نتیجه را داد و تمام نتایج ثبت‌شده را مصرف کرد؛ و وقتی عامل رفتاری متفاوت داشت (شماره‌ی سفارش دیگر)، بازپخش با پیام روشن واگرایی را گزارش کرد. هر سه رفتار با آزمون‌های واحد

کد بررسی شده‌اند.

۷.۷ محرمانگی، حداقل‌سازی داده و نگهداری ردگیری‌ها

ردگیری کامل ذاتاً حاوی داده‌های حساس است: متن گفت‌وگو، شناسه‌های مشتری، خروجی ابزارها. پروفایل مولد NIST «حریم خصوصی داده» را یکی از دوازده ریسک ویژه یا تشدیدشده‌ی هوش مصنوعی مولد می‌داند و آن را نشت، استفاده‌ی غیرمجاز و افشا یا شناسایی‌زدایی‌شدن اطلاعات شخصی توصیف می‌کند (National Institute of Standards and Technology, ۲۰۲۴). برای مهار این ریسک در ردگیری، چهار اصل پیشنهاد می‌شود (۴ع):

۱. **حداقل‌سازی در منبع:** فقط فیلدهایی که برای عیب‌یابی و حسابرسی لازم‌اند ثبت شوند؛ داده‌ی حساس با مرجع (نه مقدار) ثبت شود و مقدار در ذخیره‌ی جداگانه با کنترل دسترسی نگه داشته شود.

۲. **پاک‌سازی پیش از ثبت:** نقاب‌گذاری یا حذف فیلدها با پاک‌ساز (مثل mask_fields)، پیش از رسیدن به صفحه‌ی شواهد؛ آزمون خودکار این پاک‌سازها لازم است.

۳. **کنترل دسترسی و ممیزی:** خود دسترسی به ردگیری‌ها حسابرسی شود.

۴. **نگهداری مبتنی بر ریسک:** مدت نگهداری (مثلاً کوتاه برای متن کامل و بلندتر برای ابرداده) مطابق قوانین و سیاست سازمان تعیین شود.

حجم داده مسئله‌ی دیگر است. وانگ و همکاران «حجم وسیع داده» را اولین چالش پایش عامل‌ها می‌دانند، به‌ویژه وقتی داده‌ی مدل و داده‌ی نقاط ذخیره هم اضافه شود؛ و کمبود تنوع داده و ریسک‌های امنیتی را دو چالش دیگر برمی‌شمارند (Wang et

۲۰۲۵، al.). راهکارها: نمونه‌برداری (مثل رویکرد داپر؛ ۲۰۱۰، Sigelman et al.)، نگهداری ردگیری کامل برای وظایف پرریسک یا شکست‌خورده و ذخیره‌ی خلاصه برای بقیه، و فشرده‌سازی. هزینه‌ی ذخیره‌سازی باید در مدل هزینه‌ی فصل ۱۲ بیاید.

۷.۸ طراحی شاخص‌های مشاهده‌پذیری عامل

شاخص‌ها از رویدادها محاسبه می‌شوند و برای هشدار و داشبورد به کار می‌روند. جدول ۷-۳ مجموعه‌ی پیشنهادی را نشان می‌دهد. اصل مهم: هر شاخص با یک پرسش عملیاتی و یک عمل مشخص گره بخورد؛ شاخصی که هیچ کس به آن واکنش نشان نمی‌دهد، نويز است.

جدول ۷-۳. شاخص‌های پیشنهادی مشاهده‌پذیری عامل (منبع: نگارنده)

شاخص	محاسبه	عمل مورد انتظار در انحراف
نرخ موفقیت نمونه‌ای	درصد وظایف موفق در نمونه‌ی ارزیابی برخط	بررسی نسخه‌ی اخیر؛ بازگشت یا اصلاح
میان و صدک ۹۵ گام‌ها	تعداد decision به‌ازای وظیفه	بررسی حلقه یا برنامه‌ریزی ناکارآمد
نرخ رد سیاست	سهم decision‌هایی با حکم deny به‌ازای هر قاعده	جهش؛ دستورالعمل یا تزریق؛ کاهش ناگهانی؛ قاعده خراب
نرخ درخواست تأیید	سهم require_approval	ظرفیت انسان؛ بازیابی آستانه‌ها
نرخ خطای ابزار	tool.result با وضعیت غیر ok	مدار شکن؛ رخداد در سرویس پایین‌دست
نرخ توقف با بودجه	وظایف پایان‌یافته با رویداد budget	حلقه‌ی بی‌پایان یا وظیفه‌ی سخت‌تر از انتظار
هزینه‌ی هر وظیفه و CPST	از دفتر بودجه	تحلیل اقتصادی (فصل ۱۲)
نرخ بازپخش‌شده در دروازه‌ی ابزار	tool.result با replayed=true	تلاش‌های مجدد زیاد؛ بررسی پایداری ابزار

جمع‌بندی فصل

در عامل‌ها، ردگیری مهم‌ترین داده‌ی پایش است و باید ورودی و خروجی هر گام را همراه با مصنوعات معنایی (برنامه، تصمیم، سیاست) ثبت کند. مدل بازه‌ها (Dong et al., ۲۰۲۴) را به رویدادهای AO-RA نگاشت کردیم و حداقل فیلدهای هر رویداد را مشخص کردیم. ردگیر فقط افزودنی با پاک‌ساز، بازپخش اجرایی و تشخیص واگرایی را با کد آزمون‌شده نشان دادیم. انتشار زمینه‌ی ردگیری در سامانه‌های چندعاملی، حفظ حریم خصوصی و مدیریت حجم، سه چالش اصلی‌اند. شاخص‌های مشاهده‌پذیری باید هر یک به پرسش و عمل مشخصی گره بخورند.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. چرا در سامانه‌های عامل محور ردگیری را مهم‌ترین نوع داده‌ی پایش می‌دانند؟ (Wang et al., ۲۰۲۵) تفاوتش با ردگیری سرویس‌های میکروسرویسی چیست؟
۲. بازپخش مشاهده‌ای و اجرایی را مقایسه کنید. هر یک چه چیزی را بازتولید می‌کند و چه چیزی را نه؟
۳. در خروجی بخش ۷.۶، چرا customer_email با ستاره آمده؟ اگر پاک‌ساز اشتباهاً فیلد دیگری را نقاب کند، چه پیامدی برای بازپخش دارد؟
۴. طرح‌واره‌ی یک رویداد memory.read را بنویسید و مشخص کنید کدام فیلدها حساس‌اند.
۵. یک گردش کار چندعاملی با سه عامل طراحی کنید و روی آن انتشار زمینه‌ی ردگیری

را بکشید. اگر یکی از عامل‌ها شناسه‌ی والد را منتقل نکند چه می‌شود؟

۶. (عملی) llm.call را به پیاده‌سازی مرجع بیفزایید: شناسه‌ی مدل، توکن‌ها و مرجع زمینه را ثبت کنید و آزمون واحد بنویسید.

۷. (تحلیلی) سیاست نگهداری ردگیری برای عامل بازپرداخت پیشنهاد دهید؛ چه چیزی را کامل و چه چیزی را خلاصه نگه می‌دارید؟ استدلال کنید.

منابع

Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>

Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>

National Institute of Standards and Technology. (2024). Artificial Intelligence Risk Management Framework: Generative Artificial Intelligence Profile (NIST AI 600-1). <https://doi.org/10.6028/NIST.AI.600-1>

OpenTelemetry. (n.d.). Semantic conventions for generative AI. GitHub. <https://github.com/open-telemetry/semantic-conventions-genai> (accessed 2026-10-21; stability status not verified)

Sigelman, B. H., Barroso, L. A., Burrows, M., Stephenson, P., Plakal, M., Beaver, D., Jaspan, S., & Shanbhag, C. (2010). Dapper, a large-scale distributed systems tracing infrastructure (Technical Report dapper-2010-1). Google. <https://research.google/pubs/pub36356/>

Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>

ارزیابی مستمر و مهندسی کیفیت رفتار

فصل ۷ شواهد را فراهم کرد؛ این فصل می‌پرسد با آن شواهد چه باید کرد تا درباره‌ی کیفیت رفتار عامل قضاوت قابل‌دفاع داشته باشیم. در سامانه‌ی سستی، آزمون یعنی مقایسه‌ی خروجی با مقدار مورد انتظار. در عامل، خروجی یک مسیر است، مسیر تصادفی است و «درست» اغلب مجموعه‌ای از قیود است. نتیجه این است که ارزیابی عامل یک مسئله‌ی آماری و رفتاری است، نه فقط یک آزمون واحد. این فصل روش‌ها، محدودیت‌ها و ابزارهای ارزیابی را از دید مهندسی بیان می‌کند و با مثال اجرایی (شبیه‌سازی شده و صریحاً برچسب‌گذاری شده) نشان می‌دهد که چرا اجرای تکراری و معیار پایداری برای تصمیم انتشار ضروری است.

اهداف فصل. (۱) محدودیت‌های آزمون صحت خروجی را نشان دهیم؛ (۲) سطوح ارزیابی (نتیجه، گام، مسیر) را تعریف کنیم؛ (۳) مجموعه‌داده‌ها و سناریوهای مرجع را طراحی کنیم؛ (۴) ارزیابی مدل‌محور را با محدودیت‌هایش به کار ببریم؛ (۵) آزمون رگرسیون را برای تغییر مدل و دستورالعمل سامانه‌مند کنیم؛ (۶) روش آماری سنجش پایداری و تعیین اندازه‌ی نمونه را بیاموزیم؛ (۷) دروازه‌های کیفی انتشار را طراحی کنیم.

۸.۱ محدودیت آزمون صحت خروجی

ساده‌ترین ارزیابی، مقایسه‌ی پاسخ نهایی با پاسخ مرجع است. این روش برای پرسش و پاسخ مناسب است و ارزان و خودکار می‌شود، اما برای عامل سه ضعف دارد.

نخست، مسیر را نمی‌بینند: عامل می‌تواند پاسخ درست بدهد در حالی که در راه، ابزار ممنوعی را درخواست کرده یا هزینه‌ای بیش از سقف ایجاد کرده است. دوم، اثر بیرونی را نمی‌سنجد: آنچه برای عاملی با ابزار نوشتنی اهمیت دارد، وضعیت دنیای بیرون پس از اجراست، نه متن پاسخ. سوم، درستی تک‌پاسخی نیست: برای بسیاری از وظایف مسیرها و پاسخ‌های پذیرفتنی متعدّدند.

معیار τ -bench رویکرد مهندسی‌شده‌ای به این مسئله ارائه می‌دهد: ارزیابی را بر مقایسه‌ی وضعیت پایگاه داده در پایان گفت‌وگو با وضعیت هدف حاشیه‌نویسی‌شده بنا می‌کند و نه بر قضاوت ذهنی متن (Yao et al., ۲۰۲۴). همین ایده مبنای معیار نتیجه در این کتاب است: «وضعیت دنیا پس از اجرا، آیا همان وضعیت مورد انتظار است؟» بنچمارک SWE-bench نیز از همین فلسفه پیروی می‌کند: عامل باید مسائل واقعی GitHub را حل کند و موفقیت با اجرای آزمون‌های پروژه سنجیده می‌شود (Jimenez et al., ۲۰۲۴). در هر دو، ارزیابی بر اثر است نه فقط بر بیان.

۸.۲ تعریف معیار موفقیت وظیفه

در فصل ۶ سه نوع معیار را معرفی کردیم: نتیجه، قید و فرایند. اینجا هر یک را به یک تابع قابل اجرا تبدیل می‌کنیم، چون ارزیابی خودکار به همین نیاز دارد. در پیاده‌سازی مرجع، `scenario_success` ترکیب سه شرط را به‌صورت یک تابع بر پاسخ نهایی و فهرست اقدام‌های انجام‌شده می‌سازد: همه‌ی ابزارهای ضروری فراخوانده شده باشند، هیچ ابزار ممنوعی اجرا نشده باشد، و پاسخ نهایی عبارت مورد انتظار را دربر داشته باشد. افزون بر آن، `max_denials` تلاش‌های مسدودشده را هم به‌عنوان شکست می‌شمرد.


دو اشتباه رایج: (الف) معیار بیش از حد باریک: اگر فقط «بازپرداخت فراخوانی شد» را بسنجیم، بازپرداخت روی سفارش اشتباه هم موفق شمرده می‌شود. باید وضعیت نهایی (شماره‌ی سفارش و مبلغ) را بسنجیم. (ب) معیار بیش از حد گسترده: اگر برای هر وظیفه فقط یک داور مدلی نمره‌ی «کیفیت» بدهد، سیگنال مبهم و ناپایدار می‌شود. معیار خوب تا حد ممکن قطعی و مبتنی بر وضعیت است و داور مدلی فقط برای جنبه‌هایی به کار می‌رود که نمی‌توان قطعی تعریف کرد.

۸.۳ ارزیابی کیفیت تصمیم و انتخاب ابزار

مرور ابزارهای ارزیابی عامل نشان می‌دهد که اغلب چارچوب‌ها ارزیابی گام به گام را پشتیبانی می‌کنند: سنجش هر گام جدا از بقیه، مثل تولید مدل، فراخوانی ابزار و تصمیم مسیریابی، که امکان مکان‌یابی خطا و تحلیل نظام‌مند محل شکست در اجراهای چند مرحله‌ای را می‌دهد. رایج‌ترین روش، سنجش مستقل هر گام با داورهای از پیش تعریف‌شده یا سفارشی است (اغلب مبتنی بر مدل یا طبقه‌بند سبک) که صفاتی مثل درستی، ارتباط یا پایبندی به دستورالعمل را می‌سنجند. بسیاری از چارچوب‌ها همچنین ارزیابی ابزار-ویژه دارند: اعتبارسنجی انتخاب ابزار، طرح‌واره‌ی پارامترها و قابلیت استفاده‌ی خروجی (Yehudai et al., ۲۰۲۵). این رویکرد یک فرض ضمنی دارد که باید آگاهانه بپذیریم: هر اقدام را می‌توان تا حدی جدا از وابستگی‌هایش سنجید؛ مرور مذکور خودش یادآور می‌شود که این فرض وابستگی میان گام‌ها را نادیده می‌گیرد و برای رفع آن، برخی ابزارها معیار «پیشرفت به سوی هدف» را برای هر گام به کار می‌برند (Yehudai et al., ۲۰۲۵).

ارزیابی مسیر (trajectory) گام بعدی است. روش‌های مبتنی بر مرجع، مسیر

مشاهده‌شده را با یک مسیر مورد انتظار می‌سنجند و حالت‌هایی مثل تطبیق دقیق، جزئی، بدون ترتیب و زیرمجموعه را پشتیبانی می‌کنند؛ اما محدودیت ذاتی دارند، چون معمولاً چند مسیر معتبر وجود دارد و تعیین دستی مرجع اغلب ناممکن است. روش‌های بدون مرجع از داور مدلی برای ارزیابی کیفیت مسیر بدون مسیر از پیش تعیین شده استفاده می‌کنند (Yehudai et al., ۲۰۲۵). پیشنهاد این کتاب (ع ۴) ترکیب است: **قیود قطعی** (ابزار ممنوع، ترتیب لازم مثل «پیش از بازپرداخت جست‌وجو») را به صورت قاعده بسنجید، و **کیفیت مبهم** (مثل مناسب بودن لحن یا معقول بودن مسیر) را به داور مدلی و نمونه‌برداری انسانی بسپارید.



شکل ۸-۱. خط لوله‌ی ارزیابی و دروازه‌ی انتشار (منبع: نگارنده)

۸.۴ مجموعه داده‌های ارزیابی و سناریوهای مرجع

مجموعه‌ی ارزیابی دارایی مهندسی است و باید مانند کد نگهداری شود. سه نوع داده لازم است. **سناریوهای مرجع:** تعداد کم، هر یک با معیار موفقیت صریح (قرارداد رفتاری). **داده‌ی تولیدی نمونه‌برداری‌شده:** وظایف واقعی ناشناس‌شده که پیامدهای رخداده‌ها و موارد نادر را پوشش می‌دهند. **داده‌ی مصنوعی:** سناریوهایی که با الگو یا

مدل تولید می‌شوند و مرزها و حمله‌ها را پوشش می‌دهند؛ برچسب «مصنوعی» باید حفظ شود تا با داده‌ی واقعی اشتباه نشود.

مرور ارزیابی عامل‌ها دو هشدار مهم دارد: وابستگی به داده‌ی ایستای حاشیه‌نویسی‌شده‌ی انسانی مقیاس‌پذیری را محدود می‌کند، و بنچمارک‌ها زود منسوخ یا اشباع می‌شوند و باید همگام با قابلیت عامل‌ها به‌روز شوند (Yehudai et al., ۲۰۲۵). پیامد برای یک تیم: مجموعه‌ی سناریو را **نسخته‌دار** و **زنده نگه** دارید؛ هر رخداد را به یک سناریو تبدیل کنید (فصل ۶)؛ و مراقب «آلودگی» باشید، یعنی سناریوهایی که در دستورالعمل یا داده‌ی تنظیم مدل راه یافته‌اند و سنجش را بی‌معنا می‌کنند. بخشی از سناریوها را همیشه **محرمانه** و جدا از توسعه نگه دارید.

۸.۵ آزمون واحد، یکپارچه‌سازی و انتها به انتها

لایه‌های آزمون را در فصل ۶ دیدیم (واحد، قرارداد با مدل ساختگی، سناریو با مدل واقعی، انتها به انتها). از دید ارزیابی دو توصیه‌ی تکمیلی هست. اول، **آزمون‌های قطعی** را اول و بیشتر بنویسید: حلقه‌ی کنترل (سیاست، بودجه، idempotency، بازپخش) را می‌توان با مدل ساختگی کامل آزمود و بیشتر شکست‌های «مهندسی» (نه شکست مدل) همین‌جا گرفته می‌شود. در کد کتاب، ۲۲ آزمون واحد همین کارکردها را می‌آزمایند. دوم، ارزیابی با مدل واقعی را به پرسش‌های درست محدود کنید: آیا مدل در این سناریوها تصمیم درست می‌گیرد، و تا چه حد پایدار؟

۸.۶ ارزیابی مدل‌محور و محدودیت داورهای مبتنی بر مدل

استفاده از یک مدل زبانی قوی به‌عنوان داور، پاسخ عملی به نیاز ارزیابی مقیاس‌پذیر

است. ژنگ و همکاران نشان دادند که داورهای قوی مثل GPT-4 می‌توانند ترجیحات انسانی را به‌خوبی تقلید کنند و بیش از ۸۰٪ توافق با انسان را گزارش کردند، که تقریباً هم‌سطح توافق انسان‌ها با یکدیگر است. همان مقاله چهار محدودیت را نام می‌برد: سوگیری موقعیت، سوگیری طول‌گویی، سوگیری خودتقویتی و توانایی استدلال محدود (Zheng et al., ۲۰۲۳). از دید عملیات عامل‌ها سه پیامد دارد.

اول، داور باید کالیبره شود. پیش از اتکا به داور، نمونه‌ای از موارد را انسان برچسب بزند و توافق داور و انسان سنجیده شود؛ توافق باید برای هر معیار گزارش شود، نه یک عدد کلی. **دوم، سوگیری‌ها را مهار کنید:** برای سوگیری موقعیت می‌توان ترتیب پاسخ‌ها را جابه‌جا کرد و برای طول‌گویی، معیار را صریحاً بر محتوا بنا کرد. **سوم، داور را بر خود عامل سوار نکنید:** اگر داور هم‌خانواده‌ی مدل عامل باشد، سوگیری خودتقویتی خطر می‌شود؛ و اگر عامل بخواهد خودش را بازبینی کند، دیدیم که بدون سیگنال بیرونی قابل‌اتکا نیست (Huang et al., ۲۰۲۴).

مرور ارزیابی عامل‌ها نیز میان دو رویکرد تفاوتی را ثبت می‌کند: روش‌های مبتنی بر مرجع دقیق و بازتولیدپذیرند ولی به رفتار از پیش تعیین‌شده وابسته‌اند، و روش‌های بدون مرجع که معمولاً به داور مدلی تکیه دارند انعطاف بیشتر دارند اما قابلیت اطمینان کمتر. همین تنش به طراحی داور هم می‌رسد: داورهای عمومی پوشش وسیع اما دقت پایین‌تر دارند و داورهای ویژه‌ی وظیفه روی معیار هدفشان بهترند اما دامنه‌شان محدودتر است (Yehudai et al., ۲۰۲۵). **تصمیم عملی: هر جا قاعده‌ی قطعی ممکن است، قاعده؛ هر جا نیست، داور کالیبره‌شده؛ و برای موارد پرریسک، انسان.**

۸.۷ آزمون رگرسیون برای تغییر مدل و دستورالعمل

در فصل ۶ دیدیم که تغییر هر جزء (مدل، دستورالعمل، ابزار، سیاست) باید دروازه‌ی ارزیابی را فعال کند. «رگرسیون رفتاری» یعنی افت کیفیت رفتار نسبت به نسخه‌ی مرجع. چون رفتار آماری است، مقایسه‌ی دو نسخه به آزمون آماری نیاز دارد، نه مقایسه‌ی چشمی دو عدد.

اندازه‌ی نمونه. برای اینکه نرخ موفقیت را با دقت معینی تخمین بزنیم باید تعداد اجرا کافی باشد. با تقریب نرمال، تعداد اجراهای لازم برای نیم‌عرض بازه‌ی اطمینان ۹۵٪ برابر h از رابطه‌ی $n \approx z^2 \cdot p(1-p)/h$ به دست می‌آید ($z = 1/96$). جدول ۸-۱ مقادیر آن را نشان می‌دهد (محاسبه‌ی نگارنده).

جدول ۸-۱. تعداد اجراهای لازم برای نیم‌عرض بازه‌ی اطمینان ۹۵٪ (تقریب نرمال؛ منبع: محاسبه‌ی نگارنده)

نرخ موفقیت واقعی (p)	$h = 0.10$	$h = 0.05$	$h = 0.03$
۰.۵۰	۹۷	۳۸۵	۱۰۶۸
۰.۸۰	۶۲	۲۴۶	۶۸۳
۰.۹۰	۳۵	۱۳۹	۳۸۵
۰.۹۵	۱۹	۷۳	۲۰۳

نتیجه‌ی عملی: برای نشان دادن تفاوت دو نسخه‌ی عامل که هر دو حدود ۹۰٪ موفق‌اند، با چند ده اجرا نمی‌توان به ادعای جدی رسید؛ باید صدها اجرا یا تعداد زیادی سناریو داشت. برای سناریوهای کم‌تعداد، اجرای تکراری هر سناریو و ترکیب نتایج میان سناریوها ضروری است. بازه‌ی ویلسون (Wilson) برای نسبت‌های نزدیک به صفر یا یک بهتر از تقریب نرمال است و در کد کتاب پیاده‌سازی شده است. برای

نمونه، ۳۶ موفقیت از ۴۰ اجرا (۹۰٪) بازه‌ی ویلسون تقریباً ۰/۷۷ تا ۰/۹۶ دارد، و ۱۸۰ از ۲۰۰ (۹۰٪) بازه‌ی حدوداً ۰/۸۵ تا ۰/۹۳؛ یعنی چهار برابر شدن تعداد اجراها بازه را بیش از نیم کرد.

قاعده‌ی مقایسه. پیشنهاد (ع۴): نسخه‌ی جدید فقط وقتی «رگرسیون» اعلام شود که کران بالای بازه‌ی اطمینان نرخ موفقیت آن از آستانه‌ی پذیرش پایین‌تر باشد، و فقط وقتی «پذیرفته» شود که کران پایین بازه از آستانه بالاتر باشد؛ در حالت میانی «نگهدار و اجرای بیشتر». این همان سه‌حالتی است که در شکل ۸-۱ آمده است.


۸.۸ ارزیابی برخط و مقایسه‌ی نسخه‌ها

ارزیابی آفلاین سناریوهای شناخته‌شده را می‌سنجد؛ ارزیابی **برخط** رفتار واقعی را. مرور ابزارهای ارزیابی نشان می‌دهد پشتیبانی از مقایسه‌ی A/B و ارزیابی با انسان در حلقه از قابلیت‌های رایج چارچوب‌هاست (Yehudai et al., ۲۰۲۵). سه شکل برخط: (۱) **ارزیابی نمونه‌ای**: نمونه‌ای از وظایف واقعی به‌صورت خودکار یا انسانی نمره می‌گیرد؛ (۲) **سایه‌ای**: نسخه‌ی جدید بدون اثر بیرونی روی ترافیک واقعی اجرا می‌شود و با نسخه‌ی جاری مقایسه می‌شود؛ (۳) **A/B** : بخشی از ترافیک به نسخه‌ی جدید می‌رود. خطر مشترک: **جابه‌جایی توزیع**: وظایف واقعی با سناریوهای ارزیابی فرق دارند، پس نتیجه‌ی آفلاین ضمانت نمی‌دهد. حلقه‌ی بازخورد فصل ۶ همین را جبران می‌کند.

۸.۹ سنجش پایداری نتایج در اجراهای تکراری

پایداری مهم‌ترین مفهوم فصل است. فرض کنید عاملی هر بار با احتمال p موفق

می‌شود و اجراها مستقل‌اند. احتمال اینکه در k اجرا همه موفق باشد برابر p^k است؛ این همان pass^k است که یائو و همکاران برای $\tau\text{-bench}$ تعریف کردند: احتمال موفقیت در همه‌ی k تلاش مستقل، میانگین‌گیری‌شده روی وظایف (Yao et al., ۲۰۲۴). تخمین بدون‌تورش آن از n اجرا با c موفقیت، $C(c,k)/C(n,k)$ است و تخمین $\text{pass}@k$ ، یعنی احتمال دست‌کم یک موفقیت، برابر $1 - C(n-c,k)/C(n,k)$ (Chen et al., ۲۰۲۱؛ Yao et al., ۲۰۲۴). شکل ۸-۲ و جدول ۸-۲ نشان می‌دهند که فاصله‌ی pass^k با نرخ موفقیت یک‌باره چقدر زود زیاد می‌شود.



شکل ۸-۲. افت pass^k با افزایش k برای چند نرخ موفقیت یک‌باره؛ تقریب مستقل p^k (منبع: محاسبه‌ی نگارنده).

جدول ۸-۲. مقدار p^k (تقریب اجراهای مستقل؛ منبع: محاسبه‌ی نگارنده).

$k = ۸$	$k = ۴$	$k = ۲$	$k = ۱$	p
۰.۱۶۸	۰.۴۱۰	۰.۶۴۰	۰.۸۰۰	۰.۸۰
۰.۴۳۰	۰.۶۵۶	۰.۸۱۰	۰.۹۰۰	۰.۹۰
۰.۶۶۳	۰.۸۱۵	۰.۹۰۲	۰.۹۵۰	۰.۹۵
۰.۹۲۳	۰.۹۶۱	۰.۹۸۰	۰.۹۹۰	۰.۹۹

نتیجه‌ی ملموس: عاملی با موفقیت یک‌باره‌ی ۹۰٪ در چهار تلاش پیاپی فقط حدود ۶۶٪ از وظایف را بی‌نقص حل می‌کند. در τ -bench، نتیجه‌ی گزارش‌شده برای مدل آن زمان در حوزه‌ی خرده‌فروشی چنین الگویی داشت: حدود ۶۱٪ موفقیت یک‌باره و حدود ۲۵٪ در هشت تلاش (Yao et al., ۲۰۲۴). این رابطه برای اجراهای مستقل با احتمال یکسان است؛ در عمل، اجراهای یک وظیفه مستقل نیستند و وظایف سخت‌تر از آسان‌تر جدا می‌شوند، و فقط می‌توان $pass^k$ را از داده برآورد کرد. تقریب p^k کران نگرانی را نشان می‌دهد و جایگزین اندازه‌گیری نیست.

نکته‌ی آماری مهم (ع۴، با آزمون شبیه‌سازی در فصل ۱۴). $pass^k$ و $pass^1$ از دید قدرت آماری برای تشخیص افت دو قاعده‌ی برتر و فروتر نیستند. در مدل ساده‌ی اجراهای مستقل، $pass^k$ برای هر سناریو تابعی از همان شمار موفقیت‌هاست؛ پس اگر آستانه‌ها طوری تنظیم شوند که نرخ هشدار کاذب برابر باشد، دو قاعده توان تشخیص یکسانی دارند. آنچه $pass^k$ می‌افزاید، الزام متفاوت است: به جای «میانگین موفقیت»، «احتمال بی‌نقص بودن در استفاده‌ی تکراری» را می‌سنجد که برای کاربری که چند بار از عامل استفاده می‌کند مرتبط‌تر است. در مثال بخش ۸.۱۰ نیز نسخه‌ی ۱ به همین دلیل رد شد: آستانه‌ی $pass^4$ الزامی سخت‌گیرانه‌تر از آستانه‌ی $pass^1$ بود، نه اینکه آماری حساس‌تر باشد.

۸.۱۰ دروازه‌های کیفی پیش از انتشار: مثال اجرایی

اکنون همه‌ی عناصر را در مثالی اجرایی کنار هم می‌گذاریم. هشدار صداقت (مهم): مدل‌های این مثال «مدل زبانی واقعی» نیستند؛ شبیه‌سازهای تصادفی بذردار (seeded) هستند که با احتمال معینی سفارش اشتباه را بازپرداخت می‌کنند یا ابزار ممنوع را درخواست می‌دهند. هدف نمایش رفتار ابزار ارزیابی است، نه گزارش نتیجه‌ی تجربی درباره‌ی مدل‌های واقعی. کد مثال در `code/examples/ch06_08_eval.py` است و دو نسخه‌ی شبیه‌سازی‌شده را با قرارداد رفتاری فصل ۶

می‌سنجد (دو سناریو، ۴۰ اجرا برای هر سناریو، $k = 4$).

```
v1 (p_wrong=0.03, p_forbidden=0.02)
S1: c/n=38/40 pass^1=0.95 pass^4=0.81 95% CI=(0.83, 0.99)
S2: c/n=35/40 pass^1=0.88 pass^4=0.57 95% CI=(0.74, 0.95)
mean pass^1=0.912 mean pass^4=0.690 CPST=$0.0153 verdict=reject
['pass^4 0.69 < 0.7']
v2 (p_wrong=0.12, p_forbidden=0.05)
S1: c/n=33/40 pass^1=0.82 pass^4=0.45 95% CI=(0.68, 0.91)
S2: c/n=30/40 pass^1=0.75 pass^4=0.30 95% CI=(0.60, 0.86)
mean pass^1=0.787 mean pass^4=0.374 CPST=$0.0177 verdict=reject
['pass^1 0.79 < 0.9', 'pass^4 0.37 < 0.7']
```

چهار درس از این خروجی:

۱. نسخه‌ی ۱ با معیار یک‌باره پذیرفته می‌شد. میانگین $pass^1$ برابر 0.912 و بالاتر از آستانه‌ی 0.90 است؛ اما میانگین $pass^4$ برابر 0.690 و کمتر از آستانه‌ی 0.70 بود و نسخه رد شد. اگر فقط نرخ موفقیت یک‌باره را می‌سنجیدیم، نسخه‌ی ناپایدار منتشر می‌شد.

۲. دو سناریو با پارامتر یکسان، نتیجه‌ی مشاهده‌شده‌ی متفاوت دادند. $S1$ و $S2$ هر دو از همان مدل با همان احتمال خطا ساخته شدند، اما 38 و 35 موفقیت از 40 دیده شد؛ بازه‌های اطمینان (0.83 تا 0.99 و 0.74 تا 0.95) روی هم می‌افتند. فرق

ظاهری ۰/۹۵ در برابر ۰/۸۸ ممکن است فقط نوسان نمونه‌برداری باشد؛ تفسیر دو سناریو به صورت جدا گمراه‌کننده است.

۳. نسخه‌ی ۲ به روشنی بدتر است. هر دو آستانه را نقض می‌کند و بازه‌های اطمینان سناریوهایش (حدود ۰/۶۰ تا ۰/۹۱) بالاتر از $v1$ نیستند؛ اما تفاوت دو نسخه در $S1$ (۰/۹۵ در برابر ۰/۸۲) هنوز باید با اندازه‌ی نمونه‌ی بزرگ‌تر یا آزمون آماری تأیید شود، و مثال ما این کار را نمی‌کند.

۴. هزینه هم بخشی از دروازه است. CPST با شکست‌ها بالا می‌رود (۰/۰۱۵۳ و ۰/۰۱۷۷ دلار، اعداد فرضی) چون هزینه‌ی همه‌ی اجراها، شامل شکست‌ها، بر وظایف موفق تقسیم می‌شود.

پیشنهاد نگارنده (ع۴): قاعده‌ی دروازه‌ی انتشار. (۱) هیچ نسخه‌ای بر پایه‌ی یک اجرا یا نمونه‌ی ناکافی منتشر نمی‌شود. (۲) آستانه‌ها بر $pass^1$ و $pass^k$ و CPST تعریف می‌شوند. (۳) تصمیم به صورت سه‌حالتی بر پایه‌ی بازه‌ی اطمینان است: پذیرش، رد، یا نگهداشتن برای اجرای بیشتر. (۴) هر قید ایمنی (اقدام ممنوع) آستانه‌ی صفر یا نزدیک صفر دارد و با تلاش مسدود شده هم نقض می‌شود. پیاده‌سازی مرجع فعلاً فقط پذیرش و رد را اجرا می‌کند؛ حالت «نگهدار» تمرین ۶ است.

جمع‌بندی فصل

ارزیابی عامل باید بر اثر و وضعیت پایانی، قیود و مسیر استوار باشد، نه فقط متن پاسخ. ارزیابی گام‌به‌گام و مسیر، مکان‌یابی خطا را ممکن می‌کند؛ ارزیابی مبتنی بر مرجع دقیق ولی محدود است و ارزیابی مدل‌محور انعطاف‌پذیر ولی دارای سوگیری. چون رفتار آماری است، اندازه‌ی نمونه، بازه‌ی اطمینان و معیار $pass^k$ برای تصمیم لازم‌اند:

عاملی با موفقیت یک‌باره‌ی ۹۰٪ در چهار تلاش فقط حدود ۶۶٪ بی‌نقص است. مثال شبیه‌سازی‌شده نشان داد نسخه‌ای که از آستانه‌ی یک‌باره می‌گذرد می‌تواند در آستانه‌ی پایداری رد شود. دروازه‌ی انتشار باید سه‌حالتی، آماری و شامل هزینه و ایمنی باشد.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. سه ضعف ارزیابی صرفاً مبتنی بر پاسخ نهایی را بنویسید و برای هر یک مثالی از عامل بازپرداخت بیاورید.

۲. «ارزیابی گام‌به‌گام» و «ارزیابی مسیر» چه تفاوتی دارند؟ چرا ارزیابی مسیر مبتنی بر مرجع محدود است؟ (Yehudai et al., ۲۰۲۵)

۳. چهار سوگیری داور مدلی را نام ببرید و برای هر یک روش مهار پیشنهاد دهید.

۴. با فرمول $n \approx z^2 \cdot p(1-p)/h^2$ ، تعداد اجراهای لازم برای $p = 0.85$ و $h = 0.04$ را حساب کنید.

۵. اگر عاملی $p = 0.95$ دارد، $pass^{10}$ تقریبی (در فرض استقلال) چقدر است؟ چرا این عدد را نباید بی‌قید به‌کار برد؟

۶. (عملی) در `behavior.py` حالت سوم «نگهدار» را اضافه کنید: اگر بازه‌ی ویلسون میانگین آستانه را قطع کرد، `"verdict"="hold"` بدهد؛ آزمون واحد بنویسید.

۷. (تحلیلی) مثال بخش ۸.۱۰ را برای سه نسخه‌ی شبیه‌سازی‌شده و آستانه‌ی صفر برای ابزار ممنوع تکرار کنید. نتیجه چه تغییر می‌کند؟

۸. (تحلیلی) چه عواملی باعث می‌شود اجراهای یک وظیفه مستقل نباشند؟ این چه اثری بر بازه‌ی اطمینان دارد؟

- Chen, M., Tworek, J., Jun, H., Yuan, Q., Pinto, H. P. d. O., Kaplan, J., Edwards, H., Burda, Y., Joseph, N., Brockman, G., Ray, A., Puri, R., Krueger, G., Petrov, M., Khlaaf, H., Sastry, G., Mishkin, P., Chan, B., Gray, S., . . . Zaremba, W. (2021). Evaluating large language models trained on code (arXiv:2107.03374). arXiv. <https://doi.org/10.48550/arXiv.2107.03374>
- Huang, J., Chen, X., Mishra, S., Zheng, H. S., Yu, A. W., Song, X., & Zhou, D. (2024). Large language models cannot self-correct reasoning yet. International Conference on Learning Representations (ICLR 2024). arXiv:2310.01798. <https://doi.org/10.48550/arXiv.2310.01798>
- Jimenez, C. E., Yang, J., Wettig, A., Yao, S., Pei, K., Press, O., & Narasimhan, K. (2024). SWE-bench: Can language models resolve real-world GitHub issues? International Conference on Learning Representations (ICLR 2024). arXiv:2310.06770. <https://doi.org/10.48550/arXiv.2310.06770>
- Yao, S., Shinn, N., Razavi, P., & Narasimhan, K. (2024). tau-bench: A benchmark for tool-agent-user interaction in real-world domains (arXiv:2406.12045). arXiv. <https://doi.org/10.48550/arXiv.2406.12045>
- Yehudai, A., Eden, L., Li, A., Uziel, G., Zhao, Y., Bar-Haim, R., Cohan, A., & Shmueli-Scheuer, M. (2025). Survey on evaluation of LLM-based agents (arXiv:2503.16416). arXiv. <https://doi.org/10.48550/arXiv.2503.16416>
- Zheng, L., Chiang, W.-L., Sheng, Y., Zhuang, S., Wu, Z., Zhuang, Y., Lin, Z., Li, Z., Li, D., Xing, E. P., Zhang, H., Gonzalez, J. E., & Stoica, I. (2023). Judging LLM-as-a-judge with MT-Bench and Chatbot Arena. NeurIPS 2023 Datasets and Benchmarks Track. arXiv:2306.05685. <https://doi.org/10.48550/arXiv.2306.05685>

قابلیت اطمینان، تحمل خطا و بازیابی

قابلیت اطمینان در مهندسی سنتی یعنی سامانه در حضور خطا به کارش ادامه دهد. برای عامل‌ها این تعریف دو بعد تازه می‌یابد. اول، **خطاها رفتاری‌اند**: همه‌ی مؤلفه‌ها سالم‌اند و باز هم عامل تصمیم نادرست می‌گیرد (فصل ۳). دوم، **بازیابی از خطا اثر بیرونی دارد**: اگر عامل اقدامی نادرست انجام داده، «شروع دوباره» کافی نیست؛ باید اثر آن اقدام را جبران کرد. این فصل طبقه‌بندی شکست، الگوهای تحمل خطا، جبران و توقف ایمن را بیان می‌کند و نشان می‌دهد چگونه می‌توان **قابلیت اطمینان عامل** را تعریف و اندازه گرفت.

اهداف فصل. (۱) طبقه‌بندی شکست‌ها (AgentOps-FT) را بر پایه‌ی ادبیات بسازیم؛ (۲) شکست‌های برنامه‌ریزی، ابزار، حلقه و مهلت را بررسی کنیم؛ (۳) تلاش مجدد ایمن، idempotency و جبران را با کد آزمون‌شده نشان دهیم؛ (۴) توقف اضطراری و بازگشت به مسیر امن را طراحی کنیم؛ (۵) تحلیل علت ریشه‌ای را روشمند کنیم؛ (۶) قابلیت اطمینان عامل را تعریف و اندازه‌گیری کنیم.

۹.۱ طبقه‌بندی شکست‌ها در سامانه‌های عامل محور

دو منبع اصلی ادبیات، دو نگاه مکمل به شکست دارند. وانگ و همکاران آنومالی‌ها را بر پایه‌ی **محل وقوع** طبقه‌بندی می‌کنند: آنومالی‌های **درون‌عاملی** (استدلال، برنامه‌ریزی، کنش، حافظه و محیط) و **بین‌عاملی** (مشخصات وظیفه، امنیت، ارتباط،

اعتماد، رفتار نوظهور و خاتمه (Wang et al., ۲۰۲۵). Cemri و همکاران شکست‌ها را از تحلیل تجربی ردگیری‌ها استخراج کرده‌اند: ۱۴ حالت شکست در سه دسته، از ۱۶۴۲ ردگیری اجرای هفت چارچوب چندعاملی؛ و نرخ شکست هفت چارچوب متن‌باز در تحلیل آنان از ۴۱٪ تا ۸۶/۷٪ بوده است (Cemri et al., ۲۰۲۵). جدول ۹-۱ فهرست ۱۴ حالت و فراوانی (شیوع) هر یک را در آن مجموعه نشان می‌دهد. توجه: درصدها شیوع هر حالت در مجموعه‌ی ردگیری‌هاست و یک ردگیری می‌تواند چند حالت داشته باشد؛ پس جمع آن‌ها ۱۰۰ نمی‌شود.

جدول ۹-۱. ۱۴ حالت شکست MAST و شیوع آن‌ها در ۱۶۴۲ ردگیری (منبع: Cemri et al., ۲۰۲۵): ترجمه‌ی نگارنده

شناسه	نام فارسی	شرح (خلاصه‌ی نگارنده)	شیوع
FM-1.1	نقض مشخصات وظیفه	پایبند نبودن به قیود یا الزامات وظیفه	۱۱/۸٪
FM-1.2	نقض مشخصات نقش	عمل خارج از مسئولیت تعریف‌شده‌ی عامل	۱/۵٪
FM-1.3	تکرار گام	بازگویی بی‌دلیل گام‌های انجام‌شده	۱۵/۷٪
FM-1.4	ازدست‌رفتن تاریخچه‌ی گفت‌وگو	قطع غیرمنتظره‌ی زمینه	۲/۸٪
FM-1.5	ناآگاهی از شرط توقف	تشخیص ندادن پایان وظیفه	۱۲/۴٪
FM-2.1	بازنشانی گفت‌وگو	شروع دوباره‌ی ناموجه گفت‌وگو	۲/۲٪
FM-2.2	درخواست نکردن توضیح	ادامه با فرض نادرست به‌جای پرسش	۶/۸٪
FM-2.3	انحراف از وظیفه	دور شدن تدریجی از هدف	۷/۴٪
FM-2.4	کتمان اطلاعات	منتقل نکردن داده‌ی مهم به عامل دیگر	۰/۸۵٪
FM-2.5	نادیده گرفتن ورودی عامل دیگر	بی‌توجهی به پیام همتا	۱/۹٪
FM-2.6	عدم تطابق استدلال و اقدام	تناقض میان استدلال و عمل	۱۳/۲٪
FM-3.1	توقف زود هنگام	پایان دادن پیش از تکمیل	۶/۲٪
FM-3.2	تأیید ناقص یا نبود تأیید	حذف بررسی صحت	۸/۲٪
FM-3.3	تأیید نادرست	اعتبارسنجی ناکافی یا اشتباه	۹/۱٪

سه دسته‌ی MAST عبارت‌اند از: مسائل طراحی سامانه (FM-1.x)، ناهم‌ترازی بین‌عاملی (FM-2.x) و راستی‌آزمایی وظیفه (FM-3.x). یافته‌ی محوری آنان که پیش‌تر دیدیم: شکست‌ها صرفاً تابع ضعف مدل پایه نیستند و طراحی سامانه عامل مؤثری است؛ و یافته‌ی دیگرشان: تکیه‌ی صرف بر بررسی‌های سطح پایین در مرحله‌ی نهایی کافی نیست و راستی‌آزمایی چندسطحی لازم است (Cemri et al., ۲۰۲۵).

پیشنهاد نگارنده (ع۴): طبقه‌بندی AgentOps-FT. برای استفاده‌ی عملیاتی، دو نگاه بالا را در یک طبقه‌بندی دومحوری ترکیب می‌کنیم: (الف) نوع شکست (شانزده رده‌ی زیر) و (ب) ریشه‌ی علی‌غالب در یکی از سه بُعد: سامانه‌محور، مدل‌محور یا ارکستراسیون‌محور. سه بُعد علی‌از وانگ و همکاران گرفته شده‌اند: بعد سامانه‌محور زیرساخت سخت و وابستگی‌های بیرونی (مسائل معمولاً قطعی)، بُعد مدل‌محور عدم قطعیت و محدودیت‌های توانایی مدل (مسائل معمولاً تصادفی)، و بُعد ارکستراسیون‌محور «منطق نرم» یعنی راهبردها و دستورالعمل‌هایی که نحوه‌ی فکر و عمل مدل را هدایت می‌کند و مختص AgentOps است و به‌گفته‌ی آنان فعلاً پیچیده‌ترین و کم‌شناخته‌ترین بُعد تحلیل علت است (Wang et al., ۲۰۲۵). مزیت این بُعدبندی، نگاشت مستقیم به مالک اصلاح است: تیم زیرساخت (SRE)، تیم مدل یا توسعه‌دهندگان منطق ارکستراسیون.

جدول ۹-۲. طبقه‌بندی AgentOps-FT: شانزده رده‌ی شکست (منبع: نگارنده، بر پایه‌ی Wang et al., ۲۰۲۵ و Cemri et al., ۲۰۲۵)

رده	نام	ریشه در ادبیات	سیگنال تشخیص	واکنش اولیه
F01	استدلال نادرست یا توهم	آنومالی استدلال	ارزیابی گام، ناسازگاری با شواهد	زمینه‌ی بیرونی، ارزیابی مستقل
F02	برنامه‌ی نامعقول یا ناسازگار	آنومالی برنامه‌ریزی	ردگیری مسیر، مقایسه با مرجع	اصلاح دستورالعمل، تجزیه‌ی بهتر وظیفه

رده	نام	ریشه در ادبیات	سیگنال تشخیص	واکنش اولیه
F03	انتخاب نادرست ابزار یا پارامتر	آنومالی کنش	اعتبارسنجی طرح‌واره، خطای ابزار	رد پیش از اجرا، بازگرداندن خطای ساخت‌یافته
F04	شکست ابزار یا سرویس بیرونی	سامانه‌محور؛ آنومالی کنش/محیط	کد خطا، تأخیر	تلاش مجدد، مدارشکن، مسیر جایگزین
F05	از دست رفتن زمینه	آنومالی حافظه؛ FM-1.4	اندازه‌ی زمینه، نبود دستور اولیه	فشرده‌سازی هوشمند، نگه‌داشتن دستور در ابتدا
F06	بازیابی نادرست (RAG)	آنومالی حافظه‌ی بلندمدت	ارتباط اسناد، تعارض منابع	بهبود بازیابی، برچسب منبع
F07	نقض مشخصات وظیفه یا نقش	FM-1.1، FM-1.2؛ مشخصات وظیفه	قیود قرارداد	اصلاح قرارداد و سیاست
F08	حلقه و تکرار	FM-1.3؛ خاتمه	تکرار اقدام یکسان	محافظ تکرار، سقف گام
F09	توقف نابه‌جا یا ناپایانی	FM-1.5، FM-3.1؛ خاتمه	وظیفه‌ی ناتمام یا بی‌پایان	شرط توقف صریح، بودجه
F10	درخواست نکردن توضیح	FM-2.2	فرض‌های بدون پشتوانه	سیاست پرسش در ابهام
F11	انحراف از هدف	FM-2.3	فاصله از معیار موفقیت	بازنگری میان‌اجرایی
F12	اختلال ارتباط بین‌عاملی	FM-2.1، ۲.۴، ۲.۵؛ ارتباط	ردگیری پیام‌ها	قرارداد پیام، ثبت پیام‌ها
F13	تأیید ناقص یا نادرست	FM-3.2، FM-3.3	بدون بررسی مستقل پیش از نتیجه	تأییدگر مستقل چندسطحی
F14	امنیتی: تزریق، ابزار آلوده	آنومالی امنیتی؛ OWASP LLM01	رد سیاست، الگوی ورودی	مرز اعتماد، حداقل اختیار (فصل ۱۰)
F15	تخطی از منابع	محیط؛ خاتمه	هزینه، تأخیر، گام	بودجه، مدارشکن
F16	رفتار نوظهور	آنومالی رفتار نوظهور	الگوهای غیرمنتظره‌ی جمعی	نظارت سطح گروه، محدودسازی

۹.۲ شکست در برنامه‌ریزی و انتخاب اقدام

شکست‌های F01 تا F03 نزدیک‌ترین رده‌ها به «مغز» عاملند. مرور وانگ و همکاران در جدول نگاشت آنومالی به علت، برای آنومالی‌های برنامه‌ریزی نمونه‌هایی می‌آورد: مستندات مبهم ابزار که طرح‌ریزی را ناممکن می‌کند (سامانه‌محور)، ناتوانی مدل در تجزیه‌ی وظیفه‌ی پیچیده یا یادگیری ابزار جدید (مدل‌محور) و راهبرد تجزیه‌ی ضعیف و خطاهای دستورالعمل به سبک ReAct (ارکستراسیون‌محور) (Wang et al., ۲۰۲۵). نکته‌ی عملی این است که یک نشانه‌ی ظاهری می‌تواند چند ریشه‌ی علی داشته باشد؛ پس واکنش درست به ریشه بستگی دارد.

سه کنترل در لایه‌ی دروازه (پیش از اجرا) خطر F03 را کم می‌کنند. اول، اعتبارسنجی ساختاری: نام ابزار، نوع و دامنه‌ی پارامترها بر طرح‌واره‌ی ثبت‌شده بررسی شود؛ شکست «مدل پارامتر با نوع نادرست تولید می‌کند» همین‌جا گرفته می‌شود. دوم، پیش‌شرط‌های معنایی: مثلاً «بازپرداخت فقط برای سفارشی که وضعیت آن در همین اجرا بررسی شده» (در قرارداد رفتاری به‌عنوان معیار فرایند). سوم، بازگرداندن خطای ساخت یافته به مدل وقتی پیشنهاد رد شد، به‌جای متوقف کردن کل وظیفه؛ با این شرط که ردهای مکرر (در کد، دو رد) وظیفه را متوقف می‌کنند، چون تکرار تلاش برای نقض خودش نشانه‌ی خطرناک است.

درباره‌ی F01 (توهم) باید واقع‌بین بود: توهم در استفاده از مدل‌های زبانی فعلاً گریزناپذیر تلقی شده است (Wang et al., ۲۰۲۵) و بدون سیگنال بیرونی، خوداصلاحی مدل قابل اتکا نیست (Huang et al., ۲۰۲۴). بنابراین هدف مهندسی

حذف توهم نیست، بلکه مهار پیامد آن است: قید قطعی بر اقدام، ارزیابی مستقل و تأیید انسانی برای اقدام‌های پراثر.

۹.۳ شکست ابزار، شبکه، مدل و سرویس‌های وابسته

شکست‌های F04 از جنس شکست‌های زیرساختی کلاسیک‌اند و ابزار قدیمی مهندسی قابلیت اطمینان به آن‌ها پاسخ می‌دهد؛ اما دو ظرافت دارد. نخست، **خطای گذرا و دائمی را باید تفکیک کرد**: خطای ۵۰۳ را می‌توان تکرار کرد؛ «کارت رد شد» را نه. در دروازه‌ی مرجع، دو رده تعریف شده‌اند: **TransientToolError** (تکرارپذیر، تا سقف) و هر خطای دیگر (دائمی، بدون تکرار). **دوم، خطای مدل هم یک شکست سرویس است**: تأخیر یا خرابی ارائه‌دهنده‌ی مدل باید با همان الگوها (مهلت، تلاش مجدد، مسیر جایگزین، مدل پشتیبان) مهار شود، و تغییر رفتار مدل پس از به‌روزرسانی ارائه‌دهنده یک رخداد رفتاری است که دروازه‌ی ارزیابی (فصل ۸) باید بگیرد.

الگوهای رایج مقابله: **مهلت** برای هر فراخوانی و برای کل وظیفه؛ **تلاش مجدد** با **عقب‌نشینی** و **کلید یکتا**؛ **مدار شکن** که پس از چند شکست پیاپی فراخوانی‌ها را موقتاً قطع می‌کند تا سرویس بیمار بیشتر فشار نخورد؛ و **مسیر جایگزین** (ابزار یا مدل پشتیبان، یا ارجاع به انسان). این الگوها در فهرست شکل ۵-۳ (فصل ۵) گرد آمده‌اند.

یک نکته‌ی مهم از آزمایشی که برای این فصل انجام دادیم: دروازه‌ی نخست ما فقط یک نوع خطای ابزار را می‌شناخت و استثنای دیگر (مثلاً **RuntimeError** یا تقسیم بر صفر در یک ابزار) از دروازه عبور می‌کرد و حلقه را می‌شکست. این **یک اشکال واقعی طراحی** بود، که با مثال بخش ۹.۶ آشکار شد و در نسخه‌ی نهایی با این قاعده

برطرف شد: دروازه هرگز نباید اجازه دهد استثنای ابزار از آن بیرون بزند؛ هر استثنا به نتیجه‌ی ساخت‌یافته با وضعیت error تبدیل می‌شود. آزمون واحد مربوط هم نوشته شده است.

۹.۴ حلقه‌های تکرار و انحراف از هدف

حلقه (F08) و ناآگاهی از شرط توقف (F09) از پرتکرارترین شکست‌ها در تحلیل MAST هستند: تکرار گام ۱۵/۷٪ و ناآگاهی از شرط توقف ۱۲/۴٪ ردگیری‌ها (Cemri et al., ۲۰۲۵). حلقه‌ی بی‌پایان به‌ویژه خطرناک است چون هر گام به‌تنهایی «موفق» است و فقط الگوی کل آن را نشان می‌دهد. سه لایه‌ی دفاع پیشنهاد می‌شود:

- (۱) سقف گام و بودجه (قید ساختاری، فصل ۵)؛ (۲) محافظ تکرار: اگر همان اقدام با همان آرگومان‌ها بیش از آستانه‌ای تکرار شود، وظیفه متوقف و رویداد guard ثبت می‌شود؛ (۳) سنجش پیشرفت: مقایسه‌ی وضعیت با معیار موفقیت برای تشخیص «حرکت بی‌پیشرفت»، که به‌صورت ارزیابی گام (فصل ۸) تحقق می‌یابد.

کد ۹-۱ (گزیده‌ی agent.py). کلید توقف و محافظ تکرار در حلقه‌ی عامل: پیش از هر گام کلید توقف بررسی می‌شود؛ و هر اقدام تکراری شمارش و پس از آستانه متوقف می‌شود.

```
if stop and stop():                                     # emergency stop:
checked before every step
    status = "stopped"; trace.emit("stop",
reason="kill_switch"); break
    sig = (prop.tool, repr(sorted((prop.args or {}).items())))
    seen[sig] = seen.get(sig, 0) + 1
    if seen[sig] > max_repeat:                             # repetition guard:
same action again and again
        status = "loop_detected"; trace.emit("guard",
guard="repetition", tool=prop.tool, count=seen[sig]); break
```

۹.۵ مهلت، بودجه‌ی گام و محدودیت منابع

سقف زمان، سقف گام، سقف توکن و سقف هزینه، همگی قیود اجرا هستند. در دفتر بودجه‌ی مرجع، `deadline_s` با ساعت تزریق‌پذیر اعمال می‌شود؛ ساعت تزریق‌پذیر مهم است چون آزمون‌پذیری مهلت‌ها را ممکن می‌کند (آزمون واحد آن با ساعت جعلی نوشته شده است). نکته‌ی طراحی: فقط یک سقف کافی نیست. حلقه‌ای با گام‌های بسیار سریع ممکن است سقف زمان را نشکند اما هزینه را بسوزاند؛ حلقه‌ی کند با تعداد گام کم ممکن است مهلت را بشکند. بنابراین هر چهار قید هم‌زمان اعمال می‌شود و هر کدام زودتر نقض شد، اجرا را متوقف می‌کند و دلیل را در رویداد `budget` ثبت می‌کند.

۹.۶ تکرار امن، idempotency و جبران اقدام‌ها

وقتی ابزار اثر بیرونی دارد، «تلاش مجدد» می‌تواند اثر را دوبار اعمال کند (دو بار بازپرداخت!). راهکار دو بخش دارد. بخش اول، **idempotency**: هر فراخوانی نوشتنی با کلید یکتای مشتق از (وظیفه، ابزار، آرگومان‌ها) انجام می‌شود و اگر کلید قبلاً اجرا شده بود، نتیجه‌ی قبلی بدون اجرای مجدد برمی‌گردد. در مثال محافظ تکرار، سه فراخوانی یکسان `lookup` فقط یک بار واقعاً اجرا شد، چون بقیه از حافظه‌ی نهان دروازه برگشتند. بخش دوم، جبران: برای شکست‌هایی که در میانه‌ی یک دنباله‌ی چندمرحله‌ای رخ می‌دهند، اثر مراحل انجام‌شده باید برگردد. الگوی «ساگا» (`saga`) در پایگاه داده همین را حل می‌کند: تراکنش طولانی به زیرتراکنش‌ها شکسته می‌شود که هر یک اقدام جبرانی دارد (Garcia-Molina & Salem, ۱۹۸۷). در پیاده‌سازی

مرجع، هر ابزار نوشتنی می‌تواند هنگام ثبت، تابع جبران را معرفی کند و دروازه، نوشتن‌های موفق را در یک دفتر نگه می‌دارد و **rollback** آن‌ها را به ترتیب معکوس جبران می‌کند.

کد ۹-۲ (گزیده‌ی tools.py). بازگردانی ساگا: نوشتن‌های موفق به ترتیب معکوس جبران می‌شوند و هر جبران خودش با کلید یکتا اجرا می‌شود.

```
def export_cache(self) -> dict:
    """Idempotency results as plain JSON-able data (stored in
    checkpoints)."""
    return {k: {"status": v.status, "output": v.output} for k, v in
    self._cache.items()}

def import_cache(self, data: dict):
    for k, v in data.items(): self._cache[k] =
    ToolResult(v["status"],
    v["output"])

def rollback(self, prefix: str = "undo") -> list[tuple[str, dict]]:
    """Compensate recorded writes in reverse order (saga). Each
    compensation is itself idempotent."""
```

سه رفتار را در مثال `code/examples/ch09_recovery.py` اجرا کردیم (خروجی واقعی):

```
1) loop guard
   status: loop_detected | steps used: 4 of 50 | real tool executions: 1
2) emergency stop
   status: stopped | steps: 3 | trace tail: ['tool.result', 'stop',
   'task.end']
3) saga: charge fails after reserve -> compensate
   charge result: error - RuntimeError: card declined | state before
   rollback: {'stock': 4, 'paid': 0} | journal: ['reserve']
   compensations: ['release'] | state after rollback: {'stock': 5,
   'paid': 0}
```

در سناریوی سوم، رزرو کالا موفق بود (موجودی ۵ به ۴ رسید) اما پرداخت رد شد؛ دروازه شکست را به نتیجه‌ی **error** تبدیل کرد، دفتر فقط نوشتن موفق قبلی (**reserve**) را ثبت کرده بود و **rollback** آن را با **release** جبران کرد و موجودی به

۵ بازگشت. **محدودیت‌ها:** جبران همیشه ممکن نیست (ایمیل ارسال شده را نمی‌توان پس گرفت)؛ برای چنین اقدام‌هایی باید پیش از اجرا تأیید انسانی یا تأخیر (مثلاً صف ارسال با مهلت لغو) گذاشت. همچنین جبران خود می‌تواند شکست بخورد و باید idempotent و قابل تکرار باشد؛ و در سامانه‌ی توزیع‌شده‌ی واقعی، ثبات میان دفتر و ابزار نیازمند طراحی پایدارتری از نمونه‌ی درون‌حافظه‌ای ماست.

۹.۷ توقف اضطراری و بازگشت به مسیر امن

کلید توقف اضطراری اهرم نهایی کنترل است. طراحی خوب سه خاصیت دارد. **ساده و قابل اعتماد:** بررسی کلید پیش از هر گام و پیش از هر فراخوانی ابزار، با کمترین وابستگی. **در دسترس اپراتور:** بدون نیاز به استقرار مجدد، در سطح هر عامل و هر ابزار و کل سامانه. **ایمن نسبت به شواهد:** توقف نباید شواهد را از بین ببرد؛ رویداد stop همراه با دلیل ثبت می‌شود. در مثال دوم، اپراتور کلید را در میانه‌ی اجرا زد و عامل پیش از گام بعد متوقف شد (سه گام، رویداد stop در ردگیری). «بازگشت به مسیر امن» یعنی پس از توقف، سامانه در وضعیت معلوم است: وظیفه‌ی ناتمام یا لغو می‌شود و اثرهای انجام‌شده با جبران برمی‌گردند، یا به انسان ارجاع می‌شوند.

۹.۸ تحلیل علت ریشه‌ای و پیشگیری از تکرار

وانگ و همکاران تحلیل علت ریشه‌ای را در عامل‌ها چنین توصیف می‌کنند: برخلاف نرم‌افزار سنتی، ریشه‌ی شکست در سه حوزه‌ی زیرساخت، رفتار مدل و منطق ارکستراسیون پراکنده است و اغلب زنجیره‌های علّی پیچیده می‌سازد که شکست در یک بعد موجب خطای بُعد دیگر می‌شود

(Wang et al., ۲۰۲۵). روش پیشنهادی ما برای تحلیل (۴ع) پنج گام دارد:

۱. بازسازی مسیر از ردگیری کامل (فصل ۷) و تعیین وضعیت پایانی.
 ۲. یافتن گام آنومال با تعریف فصل ۳: کدام گام اگر عادی بود وظیفه موفق می‌شد؟
 ۳. تعیین بُعد علی: سامانه‌محور (مثلاً خطای ابزار در ردگیری)، مدل‌محور (تصمیم نادرست با زمینه‌ی درست) یا ارکستراسیون‌محور (دستورالعمل، تجزیه یا زمینه‌ی نامناسب)؛ وانگ و همکاران جدولی از نداشت هر نوع آنومالی به علل محتمل در هر سه بُعد دارند (Wang et al., ۲۰۲۵).
 ۴. آزمون فرضیه با بازپخش (فصل ۷): آیا با ورودی‌های ثابت، شکست بازتولید می‌شود؟ اگر بازتولید شد، علت در بقیه‌ی سامانه است؛ اگر نه، در مدل یا زمینه.
 ۵. ثبت درس: افزودن سناریو به قرارداد رفتاری (فصل ۶) و در صورت لزوم قاعده‌ی سیاست یا ابزار.
- نکته‌ی هشداردهنده درباره‌ی «رفع»: وانگ و همکاران استدلال می‌کنند که رفع آنومالی در عامل‌ها فرایندی تکرارشونده و مبتنی بر مشاهده‌ی چندنوبتی است، چون اصلاح یک عامل می‌تواند پویایی کل سامانه را تغییر دهد: برای نمونه عاملی که پس از رفع برنامه‌ریزی ناکارآمد، کارآمدتر می‌شود ممکن است منبع مشترک را انحصاری کند و عامل‌های دیگر دچار گرسنگی شوند، یعنی رفع یک آنومالی درون‌عاملی، یک آنومالی بین‌عاملی بسازد. توصیه‌ی آنان: هر اصلاح را فرضیه‌ی موقت تلقی و پس از آن یک دوره‌ی مشاهده‌ی چندنوبتی را اعمال کنید؛ و اعتبارسنجی رفع با معیار نرخ موفقیت وظیفه، با حاشیه‌نویسی دستی (دقیق ولی پرهزینه) یا داور مدلی (مقیاس‌پذیر) انجام شود (Wang et al., ۲۰۲۵). این با دروازه‌ی ارزیابی فصل ۸ هم‌خوان است: هر رفع، همانند یک تغییر نسخه، دروازه را فعال می‌کند.

۹.۹ تعریف و اندازه‌گیری قابلیت اطمینان عامل

قابلیت اطمینان عامل را به صورت مجموعه‌ای از شاخص‌ها تعریف می‌کنیم (پیشنهاد نگارنده، ع ۴):

- **نرخ موفقیت وظیفه و پایداری (pass^k)** روی سناریوهای مرجع و نمونه‌ی تولیدی (فصل ۸).

- **نرخ شکست خاموش:** سهم وظایفی که نتیجه‌ی نادرست داده‌اند اما هیچ هشداری نداشته‌اند؛ آن را فقط می‌توان با ممیزی نمونه‌ای مستقل برآورد.

- **نرخ مهار:** سهم شکست‌هایی که پیش از اثر بیرونی توسط سیاست، بودجه یا محافظ گرفته شدند.

- **نرخ بازیابی موفق:** سهم شکست‌هایی که با جبران یا ارجاع به انسان به وضعیت امن رسیدند.

- **زمان تشخیص و بازیابی:** از وقوع تا تشخیص، و از تشخیص تا بازگشت به وضعیت امن.

- **شعاع انفجار (blast radius):** بیشینه‌ی اثری که یک شکست بدون مهار می‌توانست بگذارد؛ با سطح خودمختاری و مجوزها نسبت دارد.

مهم‌ترین شاخص از دید ایمنی، **نرخ شکست خاموش** است و دشوارترین آن. تنها راه برآورد آن، **ارزیابی مستقل نمونه‌ای** است: نمونه‌ای از وظایف «موفق ظاهری» را انسان یا سازوکار مستقل بازبینی کند. این هزینه‌ی ثابت قابلیت اطمینان است و نباید حذف شود.

جمع‌بندی فصل

شکست‌های عامل را بر پایه‌ی محل وقوع (درون‌عاملی و بین‌عاملی)، حالت‌های تجربی (۱۴ حالت MAST) و بُعد علی (سامانه‌محور، مدل‌محور و ارکستراسیون‌محور) در طبقه‌بندی AgentOps-FT جا دادیم. برای هر رده، تشخیص و واکنش اولیه‌ای تعریف شد. الگوهای تحمل خطا شامل مهلت، تلاش مجدد با کلید یکتا، مدارشکن و مسیر جایگزین هستند؛ برای اقدام‌های با اثر بیرونی، idempotency و جبران به شیوه‌ی ساگا لازم است و با کد آزمون‌شده نشان داده شد. محافظ تکرار، سقف‌های چندگانه و کلید توقف، حلقه‌ها و انحراف را مهار می‌کنند. تحلیل علت ریشه‌ای باید از ردگیری کامل و بازپخش آغاز شود و رفع، یک فرایند تکرارشونده و آزمون‌پذیر است. قابلیت اطمینان با مجموعه‌ای از شاخص‌ها، به‌ویژه نرخ شکست خاموش، تعریف می‌شود.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. سه دسته‌ی MAST را نام ببرید و برای هر یک دو حالت شکست مثال بزنید. چرا جمع درصدهای جدول ۹-۱ صد نیست؟
۲. تفاوت سه بُعد علی (سامانه‌محور، مدل‌محور، ارکستراسیون‌محور) را با یک مثال واحد توضیح دهید: عاملی که سفارش اشتباه را بازپرداخت می‌کند.
۳. چرا در دروازه‌ی ابزار، هر استثنا باید به نتیجه‌ی error تبدیل شود؟ اگر چنین نبود، چه می‌شد؟
۴. در مثال اول (محافظ تکرار)، چرا «اجرای واقعی ابزار» ۱ بار بود نه ۴ بار؟ این نتیجه

چه ارتباطی با idempotency دارد؟

۵. یک رشته‌ی نوشتنی سه‌مرحله‌ای (رزرو، پرداخت، ارسال اعلان) طراحی کنید و برای هر مرحله اقدام جبران را مشخص کنید. کدام مرحله جبران‌ناپذیر است و چه باید کرد؟
۶. (عملی) آزمونی بنویسید که نشان دهد rollback در صورت شکست خود جبران، وضعیت را در چه حالتی می‌گذارد. چه طراحی‌ای آن را بهتر می‌کند؟
۷. (تحلیلی) نرخ شکست خاموش را چگونه برآورد می‌کنید؟ اندازه‌ی نمونه‌ی ممیزی را با روش فصل ۸ برای نرخ ۲٪ و نیم‌عرض ۱٪ حساب کنید.

منابع

- Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>
- Garcia-Molina, H., & Salem, K. (1987). Sagas. Proceedings of the 1987 ACM SIGMOD International Conference on Management of Data, 249-259. <https://doi.org/10.1145/38713.38742>
- Huang, J., Chen, X., Mishra, S., Zheng, H. S., Yu, A. W., Song, X., & Zhou, D. (2024). Large language models cannot self-correct reasoning yet. International Conference on Learning Representations (ICLR 2024). arXiv:2310.01798. <https://doi.org/10.48550/arXiv.2310.01798>
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>

امنیت، حاکمیت و کنترل اختیار عامل

امنیت عامل‌ها همان امنیت برنامه‌های مبتنی بر مدل زبانی نیست؛ اختیار است که مسئله را عوض می‌کند. مدلی که فقط متن می‌نویسد، در بدترین حالت متن نادرست تولید می‌کند. عاملی که ابزار دارد، در بدترین حالت پول جابه‌جا می‌کند، داده پاک می‌کند یا اطلاعات را بیرون می‌فرستد. این فصل از مدل تهدید آغاز می‌کند، به کنترل‌های اصلی (حداقل اختیار، مرز اعتماد، سیاست، تأیید انسانی، شواهد) می‌رسد و با حاکمیت متناسب با ریسک پایان می‌یابد. محتوای امنیتی فصل بر منابع معتبر (OWASP، NIST، ISO) و پژوهش‌های تزریق دستورالعمل تکیه دارد و نگاهیست‌های پیشنهادی نگارنده صریحاً با برچسب (ع) مشخص شده‌اند.

اهداف فصل. (۱) مدل تهدید عامل‌ها را بسازیم؛ (۲) تزریق مستقیم و غیرمستقیم دستورالعمل و آلودگی زمینه را تحلیل کنیم؛ (۳) اصل حداقل اختیار را به طراحی ابزار، هویت و مجوز تبدیل کنیم؛ (۴) مدیریت اسرار، جداسازی و اجرای ایمن کد را مشخص کنیم؛ (۵) تأیید انسانی و سیاست‌های مجاز، ممنوع و مشروط را طراحی کنیم؛ (۶) شواهد حسابرسی‌پذیر و تغییرناپذیر بسازیم؛ (۷) کنترل‌ها را به چارچوب‌های رسمی نگاشت کنیم و حاکمیت را متناسب با ریسک طراحی کنیم.

۱۰.۱ مدل تهدید برای عامل‌های هوش مصنوعی

مدل تهدید با چهار پرسش ساخته می‌شود: چه چیزی ارزشمند است (دارایی)؟ چه

کسی تهدیدکننده است (مهاجم)؟ از کجا وارد می‌شود (مسیر)؟ چه کنترلی جلوگیری را می‌گیرد؟ برای عامل‌ها، دارایی‌ها فراتر از داده‌اند: اقدام‌های مجاز (هر ابزار یک توانایی است)، اعتبارنامه‌ها و اسرار، زمینه و حافظه (که می‌تواند آلوده شود)، اعتبار و پاسخ‌گویی سازمان و بودجه‌ی محاسباتی.

مهاجمان صرفاً «هکرهای بیرونی» نیستند. چند نوع داریم: (۱) مهاجم از طریق محتوا: کسی که متنی را در جایی (صفحه‌ی وب، ایمیل، سند) قرار می‌دهد که عامل بعداً می‌خواند؛ نیازی به دسترسی مستقیم به سامانه ندارد. (۲) کاربر بدخواه: از طریق ورودی عادی تلاش می‌کند عامل را وادار به خروج از نقشش کند. (۳) سرویس‌دهنده‌ی آلوده: ابزار یا سرور (مثل یک سرور MCP) که رفتار یا توصیفش دست‌کاری شده است. (۴) درون‌سازمانی: مجوز بیش‌ازحد یا پیکربندی نادرست. (۵) خود مدل: توهم یا رفتار ناخواسته که بدون هیچ مهاجمی اقدام نادرست تولید می‌کند. OWASP همین پنجمی را در تعریف «اختیار بیش‌ازحد» می‌گنجاند: خروجی غیرمنتظره، مبهم یا دست‌کاری‌شده‌ی مدل، به هر دلیلی، منبع آسیب است و محرک‌ها شامل توهم، تزریق مستقیم یا غیرمستقیم و افزونه یا عامل همتای آلوده‌اند (OWASP GenAI Security Project, ۲۰۲۵).

جدول ۱۰-۱. مدل تهدید خلاصه‌ی عامل‌ها: دارایی، مسیر و کنترل (منبع: نگارنده، با انکاب بر OWASP GenAI Security Project, ۲۰۲۵)

دارایی	مسیر تهدید	نمونه‌ی حمله یا خطا	کنترل اصلی
اقدام‌های ابزارها	محتوای بیرونی، تزریق	سند بازیابی‌شده می‌گوید «همه‌ی بازپرداخت‌ها را تأیید کن»	مرز اعتماد ۲، سیاست پیش از اجرا

دارایی	مسیر تهدید	نمونه‌ی حمله یا خطا	کنترل اصلی
اعتبارنامه‌ها	ابزار آلوده، نشت زمینه	کلید API در زمینه‌ی مدل ظاهر و به خروجی نشت می‌کند	اسرار خارج از زمینه، هویت جداگانه
داده‌ی حساس	خروجی مدل، ردگیری	افشا از طریق پاسخ یا لاگ	پاک‌سازی، حداقل‌سازی، دسترسی
زمینه و حافظه	بازیابی آلوده	سند مسموم وارد حافظه‌ی بلندمدت می‌شود	منبع‌گذاری، اعتبارسنجی، پاک‌سازی حافظه
بودجه	حلقه یا درخواست زیاد	مصرف بی‌نهایت توکن یا هزینه	بودجه، سقف نرخ
اعتبار و پاسخ‌گویی	اقدام نادرست بدون ردپا	بازپرداخت اشتباه که نمی‌توان منشأش را یافت	ردگیری، دفتر حسابرسی تغییرناپذیر

۱۰.۲ تزریق دستورالعمل و آلودگی زمینه

OWASP تزریق دستورالعمل را وضعیتی می‌داند که ورودی‌ها رفتار یا خروجی مدل را به شیوه‌ای که اپراتورها نمی‌خواهند تغییر می‌دهند. تزریق **مستقیم** وقتی است که ورودی خود کاربر مدل را از مسیر خارج کند (عمدی یا تصادفی)؛ تزریق **غیرمستقیم** وقتی که دستورهای مخرب از محتوای بیرونی مثل صفحه‌ی وب یا فایل وارد شوند. محتوای پنهان یا ناخوانا هم اگر مدل آن را بخواند می‌تواند مؤثر باشد (OWASP GenAI Security Project, ۲۰۲۵). گرشاک و همکاران نشان دادند که برنامه‌های مجهز به مدل زبانی که داده‌ی بازیابی‌شده را پردازش می‌کنند، با تزریق غیرمستقیم قابل سوءاستفاده‌اند (Greshake et al., ۲۰۲۳). ریشه‌ی مسئله ساختاری است:

مدل‌های زبانی مستقیماً بر متن کار می‌کنند و راه رسمی برای تمایز دستور از داده ندارند؛ تزریق دستورالعمل با کاشتن دستور تازه در داده‌ی سوم‌شخصی که ابزارهای عامل پردازش می‌کنند عمل می‌کند و موفقیت آن می‌تواند مهاجم بیرونی را قادر کند به‌نماینده‌ی کاربر اقدام کند و ابزار فراخوانی کند (Debenedetti et al., ۲۰۲۴).

بنچمارک AgentDojo برای اندازه‌گیری مقاومت عامل‌ها در برابر این حمله ساخته شده است. نویسندگان آن را «محیط پویا و توسعه‌پذیر» توصیف می‌کنند که نسخه‌ی اول آن ۹۷ وظیفه‌ی واقع‌گرایانه (مثل مدیریت ایمیل، پیمایش یک وب‌سایت بانکی و رزرو سفر) و ۶۲۹ مورد آزمون امنیتی دارد و یافته‌شان این است که مدل‌های پیشرفته در بسیاری وظایف حتی بدون حمله شکست می‌خورند و حمله‌های موجود برخی ویژگی‌های امنیتی را می‌شکنند ولی نه همه را (Debenedetti et al., ۲۰۲۴). پیام آن برای مهندسی: ارزیابی امنیتی بخشی از ارزیابی رفتار است و باید در دروازه‌ی انتشار بیاید (فصل ۸).

راهکارهای کاهش خطر در OWASP هفت مورد است که ما در معماری مرجع آن‌ها را به این صورت پیاده می‌کنیم (نگاشت پیشنهادی، ع ۴): (۱) مقید کردن رفتار مدل با نقش و محدودیت در دستورالعمل سیستمی، و گفتن اینکه تلاش برای نادیده گرفتن دستورالعمل اصلی را رد کند؛ (۲) تعریف و اعتبارسنجی قالب خروجی با کد قطعی؛ (۳) فیلتر ورودی و خروجی؛ (۴) اعمال حداقل اختیار: توکن‌های جداگانه، اجرای توابع پراختیار در کد و نه از طریق مدل؛ (۵) تأیید انسانی برای اقدام‌های پرریسک؛ (۶) جداسازی و برچسب‌گذاری محتوای غیرقابل اعتماد تا تأثیر کمتری بر دستورالعمل‌ها داشته باشد؛ (۷) آزمون خصمانه‌ی منظم با رفتار با مدل مانند یک کاربر

غیرقابل اعتماد (OWASP GenAI Security Project, ۲۰۲۵).

اصل طراحی (ع۴): دستور فقط از کانال‌های مورد اعتماد می‌آید. محتوای بازیابی شده و خروجی ابزارها داده‌اند. هیچ محتوایی که از مرز اعتماد ۲ (فصل ۵) عبور می‌کند نباید به‌تنهایی بتواند (الف) ابزار جدیدی را مجاز کند، (ب) سیاست را تغییر دهد، یا (ج) اقدام پرریسک را بدون تأیید انجام دهد. این اصل با سیاست پیش از اجرا تضمین می‌شود، نه با «قول گرفتن» از مدل: چون مدل نمی‌تواند تضمین کند که فریب نمی‌خورد.

۱۰.۳ دسترسی ابزارها، هویت عامل و حداقل سطح دسترسی

اصل «حداقل امتیاز» از اصول بنیادین طراحی سامانه‌های امن است: هر برنامه و هر کاربر باید با کمترین مجوز لازم کار کند (Saltzer & Schroeder, ۱۹۷۵). OWASP برای عامل‌ها آن را به راهکارهای مشخصی تبدیل می‌کند: سه علت ریشه‌ای اختیار بیش‌ازحد (عملکرد، مجوز و خودمختاری بیش‌ازحد) و راهکارهایی مثل محدود کردن افزونه‌ها به حداقل لازم، محدود کردن توابع هر افزونه، پرهیز از ابزارهای باز مثل پوسته‌ی عمومی یا بارگیری نشانی دلخواه، دادن مجوز پایین‌دست در حداقل سطح (مثلاً فقط خواندنی)، اجرای افزونه‌ها با هویت و دامنه‌ی کاربر احراز هویت‌شده به‌جای حساب مشترک پرمجوز، و اعمال مجوز در سامانه‌ی پایین‌دست به‌جای اتکا به تصمیم مدل (OWASP GenAI Security Project, ۲۰۲۵).

این‌ها در یک اصل اجرایی ساده خلاصه می‌شود (ع۴): اختیار عامل، اشتراک سه مجموعه است: آنچه قرارداد وظیفه اجازه می‌دهد، آنچه سیاست اجازه می‌دهد و آنچه سامانه‌ی پایین‌دست برای هویت این وظیفه اجازه می‌دهد. اگر هر یک از سه «نه» بگوید، اقدام انجام نمی‌شود. پیاده‌سازی مرجع دو لایه‌ی اول را دارد (ابزار در

allowed_tools قرارداد و حکم موتور سیاست؛ لایه‌ی سوم مسئولیت سامانه‌ی پایین‌دست است و عامل نباید بتواند آن را دور بزند. برای هویت، چند الگو وجود دارد: **هویت وظیفه‌ای** (توکن کوتاه‌عمر با دامنه‌ی همان وظیفه)، **هویت کاربر محور** (اجرا به نمایندگی کاربر نهایی با مجوزهای خودش) و **هویت سرویس** (برای کارهای پس‌زمینه). ترکیب این‌ها و مدیریت چرخه‌ی عمر توکن‌ها در لایه‌ی ۸ (فصل ۱۱) می‌آید.

۱۰.۴ مدیریت اسرار و جداسازی محیط اجرا

OWASP «افشای اطلاعات حساس» (LLM02) را خطر آشکار شدن داده‌های شخصی، مالی، پزشکی و اعتبارنامه‌ها و جزئیات اختصاصی مدل از طریق خروجی‌ها می‌داند و راهکارهایش شامل پاک‌سازی و پوشاندن محتوای حساس، کنترل دسترسی به داده‌ی لازم، محدود کردن منابع داده‌ی قابل‌دسترس مدل، و محدود کردن امکان دیدن یا رونویسی تنظیمات اولیه‌ی سامانه است. همچنین هشدار می‌دهد که محدودیت‌های دستورالعمل سیستمی با تزریق دستورالعمل قابل دور زدن‌اند (OWASP GenAI Security Project, ۲۰۲۵). برداشت مهندسی: **اسرار نباید هرگز به زمینه‌ی مدل برسند**. ابزار، اسرارش را از مخزن اسرار می‌گیرد و فقط نتیجه‌ی کار را به مدل برمی‌گرداند؛ مدل هیچ‌وقت کلید را «نمی‌بیند» و پس نمی‌تواند آن را به خروجی یا ردگیری درز دهد.

دو سطح دیگر جداسازی لازم است. **جداسازی شبکه**: عامل تنها به مقصدهای مجاز دسترسی دارد (فهرست مجاز)، که اثر تزریق را محدود می‌کند چون «ارسال داده به نشانی دلخواه» ممکن نیست. OWASP هم برای مهار مصرف نامحدود (LLM10)

محصور کردن دسترسی مدل به شبکه‌ها، سرویس‌های داخلی و API‌ها را توصیه می‌کند و سقف نرخ، سهمیه کاربر، مهلت و پایش مصرف را (OWASP GenAI ۲۰۲۵, Security Project). جداسازی هویت و داده بین وظایف: وظیفه‌ی یک کاربر نباید به حافظه یا نتایج وظیفه‌ی کاربر دیگر دسترسی بیاورد.

۱۰.۵ اجرای ایمن کد و محصورسازی محیط

برخی عامل‌ها کد تولید و اجرا می‌کنند (تحلیل داده، اتوماسیون). اجرای کد ابزاری در رده‌ی بالاترین ریسک است، چون «اجرای دلخواه» است؛ همان‌طور که مشخصات MCP هم ابزارها را «اجرای کد دلخواه» می‌شمارد که باید با احتیاط تلقی شوند (Model Context Protocol, ۲۰۲۶). حداقل کنترل‌ها (ع۴): اجرا در جعبه‌ایزوله‌ی اختصاصی هر وظیفه (فرایند یا ظرف یا ماشین مجازی سبک)؛ سقف منابع (پردازنده، حافظه، زمان)؛ بدون دسترسی به شبکه مگر مقصدهای مجاز؛ دسترسی فایل محدود به یک پوشه‌ی کاری موقت؛ بدون اسرار در محیط؛ و حذف کامل محیط پس از وظیفه. همه‌ی خروجی‌های جعبه‌ایزوله نیز داده‌ی غیرقابل اعتماد تلقی می‌شوند.

۱۰.۶ کنترل اقدام‌های حساس و تأیید انسانی

تأیید انسانی ایمن‌ترین اهرم برای اقدام‌های پراثر است اما اگر بد طراحی شود بی‌اثر می‌شود: انسانی که روزانه صدها تأیید بی‌اهمیت می‌بیند، «تأیید» می‌زند. پنج اصل طراحی (ع۴): ۱. شرطی و ریسک‌محور: تأیید فقط برای اقدام‌های پراثر (برگشت‌ناپذیر، مبلغ بالا، داده‌ی حساس، خارج از دامنه‌ی معمول). ۲. نمایش شواهد: تأییدکننده باید دلیل اقدام (خلاصه‌ی ردگیری)، آرگومان‌های دقیق و اثر مورد انتظار را

ببیند، نه فقط «تأیید می‌کنید؟». ۳. **مهلت و انقضا**: درخواست تأیید منقضی می‌شود و با انقضا، پیش‌فرض «رد» است. ۴. **تفکیک وظایف**: درخواست‌کننده (وظیفه) و تأییدکننده یکی نیستند، و برای اقدام‌های حساس‌تر دو تأیید (قاعده‌ی چهار چشم) لازم است. ۵. **ثبت کامل**: هر تأیید و رد با هویت و زمان در دفتر حسابرسی می‌ماند. در پیاده‌سازی مرجع، حکم `require_approval` اجرا را متوقف و تابع `approve` را فراخوانی می‌کند؛ اگر تأیید داده نشود، وضعیت `needs_approval` ثبت و هیچ ابزاری اجرا نمی‌شود (آزمون واحد دارد).

۱۰.۷ سیاست‌های مجاز، ممنوع و مشروط

موتور سیاست مرجع، قواعد را به‌صورت داده می‌گیرد: ابزار، اثر (`allow/deny/`) `require_approval` و یک شرط ساده روی آرگومان. دو اصل مهم: **اولین قاعده‌ی منطبق برنده است** (پس ترتیب قواعد مهم است) و **پیش‌فرض رد است**. مثال: برای عامل بازپرداخت، قاعده‌ی «بازپرداخت با مبلغ بالای سقف نیازمند تأیید» باید پیش از «بازپرداخت مجاز» بیاید و گرنه هیچ‌گاه فعال نمی‌شود. چون سیاست کد است، باید **آزموده شود**: برای هر قاعده دست‌کم یک آزمون مثبت و یک آزمون منفی، و آزمون «ترتیب»؛ همچنین سیاست‌ها نسخه‌دار و بخشی از مانیفست انتشار هستند (فصل ۶).

کد ۱۰-۱ (گزیده‌ی `policy.py`). موتور سیاست مرجع: ابزار بیرون از قرارداد رد؛ سپس اولین قاعده‌ی منطبق؛ پیش‌فرض رد.

```
class PolicyEngine:
    """First matching rule wins; the default is deny (fail-safe
    default)."""
    def __init__(self, rules: list[Rule], default: str = "deny"):
        self.rules, self.default = rules, default
```

```
def decide(self, tool: str, args: dict, allowed_tools:
frozenset[str])
-> Decision:
    if tool not in allowed_tools:
        return Decision("deny", "contract.allowed_tools", f"{tool} is
not in the task contract")
    for r in self.rules:
        if r.tool not in (tool, "*"):
            continue
        if r.when_arg:
            name, needle = r.when_arg
            if needle not in str(args.get(name, "")):
                continue
        return Decision(r.effect, r.rule_id, f"matched {r.rule_id}")
    return Decision(self.default, "default", "no rule matched")
```

محدودیت‌ها: موتور مرجع شرط ساده‌ی «زیررشته در یک آرگومان» دارد؛ سیاست واقعی به شرط‌های ساخت‌یافته (مبلغ بزرگ‌تر از آستانه، فهرست مجاز مقصد، وابستگی به هویت و زمان) نیاز دارد. زبان‌های سیاست‌نویسی تخصصی برای این کار هست، اما انتخاب آن‌ها خارج از دامنه‌ی این کتاب و بدون ارزیابی مستقل ما بوده است.

۱۰.۸ ثبت شواهد و قابلیت حسابرسی

حسابرسی یعنی بتوان پس از واقعه، قابل‌اتکا اثبات کرد چه اتفاقی افتاد. ردگیری فصل ۷ این را فراهم می‌کند، اما اگر مهاجم یا خود اپراتور بتواند آن را تغییر دهد، ارزش حسابرسی از بین می‌رود. راهکار کلاسیک، زنجیره‌ی درهم‌ریزی (hash chain) است: هر رکورد حاوی درهم‌ریز رکورد قبلی است و تغییر، حذف یا جابه‌جایی هر رکورد، اعتبار همه‌ی بعدی را می‌شکند. پیاده‌سازی مرجع (audit.py) همین را با SHA-256 انجام می‌دهد.

کد ۱۰-۲ (audit.py). دفتر حسابرسی با زنجیره‌ی درهم‌ریزی: افزودن و راستی‌آزمایی.

```

"""Append-only. Every line stores the hash of the previous line, so
editing, deleting or reordering
any earlier record breaks verification of everything after it."""
def __init__(self, path: str):
    self.path = path
    self.last = GENESIS
    try:
        with open(path, encoding="utf-8") as f:
            for line in f: self.last = json.loads(line)["hash"]
    except FileNotFoundError:
        pass

def append(self, record: dict) -> str:
    h = _digest(self.last, record)
    with open(self.path, "a", encoding="utf-8") as f:
        f.write(json.dumps({"record": record, "prev": self.last,
"hash": h}, ensure_ascii=False, sort_keys=True) + "\n")
    self.last = h
    return h

def verify(path: str) -> tuple[bool, int | None]:
    """-> (ok, index of the first bad line or None)."""
    prev = GENESIS
    with open(path, encoding="utf-8") as f:
        for i, line in enumerate(f):
            row = json.loads(line)
            if row["prev"] != prev or row["hash"] != _digest(prev,
row["record"]):
                return False, i
            prev = row["hash"]
    return True, None

```

مثال code/examples/ch10_audit.py چهار رکورد را ثبت می‌کند، یکی را

دست‌کاری می‌کند و نتیجه‌ی راستی‌آزمایی را نشان می‌دهد (خروجی واقعی):

```

append 0: hash=d08d6707e235...
append 1: hash=593f7bb735a1...
append 2: hash=cab3d6cb9b10...
append 3: hash=5a9fb1133bbf...
verify (untouched) : (True, None)
verify (record 1 edited): (False, 1)

```

نکته‌ی مهم: این زنجیره تغییر را آشکار می‌کند، نه جلوگیری؛ کسی که به فایل

دسترسی دارد هنوز می‌تواند همه‌ی آن را بازنویسی کند. برای اتکای واقعی، باید آخرین درهم‌ریز به‌طور دوره‌ای در مکان مستقل (سامانه‌ی دیگر، خدمت زمان‌مهر یا ذخیره‌ی فقط‌افزودنی) لنگر شود؛ و دسترسی نوشتن به ذخیره‌ی شواهد از صفحه‌ی اجرا حذف شود (مرز اعتماد ۵). در مقیاس واقعی از ذخیره‌ساز فقط‌افزودنی و کنترل دسترسی استفاده می‌شود؛ نمونه‌ی ما آموزشی است.

۱۰.۹ حریم خصوصی، انطباق و پاسخ‌گویی

دو چارچوب رسمی ساختار حاکمیتی روشنی می‌دهند. چارچوب مدیریت ریسک هوش مصنوعی (۱۰.۰ AI RMF) NIST چهار کارکرد دارد: حاکمیت (Govern)، نگاشت (Map)، اندازه‌گیری (Measure) و مدیریت (Manage) و آن را به‌عنوان راهنمایی داوطلبانه برای شناسایی، اندازه‌گیری و اولویت‌بندی ریسک‌های هوش مصنوعی در سراسر چرخه‌ی عمر معرفی می‌کند (Tabassi, ۲۰۲۳). پروفایل مولد آن (NIST AI ۶۰۰-۱، ژوئیه ۲۰۲۴) دوازده رده‌ی ریسک ویژه یا تشدیدشده‌ی هوش مصنوعی مولد را برمی‌شمارد: اطلاعات و قابلیت‌های CBRN، تصویرسازی کاذب (confabulation)، محتوای خطرناک، خشونت‌آمیز یا نفرت‌انگیز، حریم خصوصی داده، اثرات زیست‌محیطی، سوگیری زیان‌بار یا همگن‌سازی، پیکربندی انسان-هوش مصنوعی، یکپارچگی اطلاعات، امنیت اطلاعات، مالکیت فکری، محتوای مستهجن یا تحقیرآمیز، و یکپارچگی زنجیره‌ی ارزش و مؤلفه‌ها (National Institute of Standards and Technology, ۲۰۲۴). استاندارد ISO/IEC ۴۲۰۰۱:۲۰۲۳ نیز الزامات استقرار، نگهداری و بهبود مستمر «سامانه‌ی مدیریت هوش مصنوعی» را در سازمان‌ها می‌دهد (International Organization for Standardization).

International Electrotechnical Commission, ۲۰۲۳؛ جزئیات این استاندارد در بررسی ما فقط از صفحه‌ی ثانویه‌ی فروشگاه IEC تأیید شد و متن استاندارد دیده نشد).

نگاشت پیشنهادی نگارنده (ع۴): AO-RA و کارکردهای NIST. حاکمیت: نقش‌ها و مسئولیت‌ها (ماتریس فصل ۴)، سیاست‌ها، مانیفست انتشار. نگاشت: تعریف مسئله، قرارداد وظیفه، مدل تهدید، سطح خودمختاری. اندازه‌گیری: ردگیری، ارزیابی رفتاری، شاخص‌های پایش، آزمون امنیتی. مدیریت: سیاست و بودجه پیش از اجرا، تأیید انسانی، بازیابی، رخدادها، بازنشتگی. این نگاشت یک پیشنهاد مفهومی است و گواهی انطباق با چارچوب نیست.

سه ملاحظه‌ی حریم خصوصی و انطباق: **حداقل سازی و پاک‌سازی در ردگیری (فصل ۷)؛ قابلیت حذف و دسترسی** (امکان یافتن و حذف داده‌ی یک فرد در ردگیری‌ها و حافظه، اگر قانون لازم کند)؛ و **تعیین مسئول:** برای هر عامل مشخص باشد چه کسی مسئول رفتار آن است (ماتریس فصل ۴). الزامات قانونی بسته به کشور و حوزه متفاوت‌اند و این کتاب مشاوره‌ی حقوقی نیست؛ برای هر استقرار باید با مشاور حقوقی هم‌خوانی بررسی شود.

۱۰.۱۰ طراحی حاکمیت متناسب با سطح ریسک

حاکمیت یکسان برای همه‌ی عامل‌ها دو خطا دارد: یا برای عامل ساده‌ی کم‌ریسک سنگین و کند است، یا برای عامل پرریسک ناکافی. راه حل، **حاکمیت لایه‌ای** بر پایه‌ی سطح خودمختاری (فصل ۴) و ریسک است. جدول ۱۰-۲ حداقل کنترل‌ها را برای سه رده‌ی ریسک پیشنهاد می‌کند.

جدول ۱۰-۲. حداقل کنترل‌های پیشنهادی بر حسب رده‌ی ریسک (منبع: نگارنده)

کنترل	ریسک پایین (سطح ۰ و ۱)	ریسک متوسط (سطح ۲)	ریسک بالا (سطح ۳ و ۴)
ردگیری	رویدادهای پایه، نگهداری کوتاه	ردگیری کامل پاک‌سازی‌شده	ردگیری کامل + دفتر حسابرسی زنجیره‌ای
سیاست	فهرست مجاز ابزارها	سیاست مشروط + بودجه	سیاست مشروط + تأیید انسانی + بودجه‌ی سخت
ارزیابی پیش از انتشار	سناریوهای مرجع	pass^k و آزمون امنیتی	+ آزمون خصمانه‌ی مستقل، بازیابی انسانی
جداسازی	حداقل	جعبه‌ایزوله برای ابزار پرریسک	جعبه‌ایزوله‌ی کامل، شبکه‌ی فهرست مجاز
پایش	شاخص‌های پایه	+ هشدار رفتاری	+ ارزیابی برخط نمونه‌ای + ممیزی خاموش
بازبینی حاکمیتی	سالانه	شش ماهه	سه ماهه و پس از هر تغییر نسخه

جمع‌بندی فصل

اختیار، مسئله‌ی امنیتی عامل‌هاست. مدل تهدید شامل مهاجم از طریق محتوا، کاربر بدخواه، سرویس‌دهنده‌ی آلوده و خود مدل است. تزریق دستورالعمل ریشه‌ی ساختاری دارد چون مدل‌ها راه رسمی برای تمایز دستور از داده ندارند؛ پس دفاع باید بر کنترل پیش از اجرا استوار باشد: اختیار هر عامل اشتراک قرارداد، سیاست و مجوز پایین‌دست است؛ اسرار هرگز به زمینه‌ی مدل نمی‌رسند؛ اجرای کد در جعبه‌ایزوله است؛ تأیید انسانی شرطی و مبتنی بر شواهد است؛ و شواهد در دفتری تغییرناپذیر (زنجیره‌ی درهم‌ریزی) ثبت می‌شود. چارچوب‌های NIST و ISO ساختار حاکمیت

را فراهم می‌کنند و نگاشت پیشنهادی ما با آن‌ها هم‌خوان است. حاکمیت باید لایه‌ای و متناسب با ریسک باشد.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. چرا تزریق دستورالعمل را نمی‌توان با «قول گرفتن» از مدل مهار کرد؟ دلیل ساختاری آن چیست؟ (Debenedetti et al., ۲۰۲۴)
۲. سه علت ریشه‌ای «اختیار بیش‌ازحد» را در یک عامل مدیریت تیکت شناسایی و برای هر یک کنترل پیشنهاد دهید.
۳. چرا قاعده‌ی «بازپرداخت بالای سقف نیازمند تأیید» باید پیش از «بازپرداخت مجاز» بیاید؟ آزمونی بنویسید که ترتیب را بیازماید.
۴. دفتر حسابرسی زنجیره‌ای چه تهدیدی را آشکار می‌کند و چه تهدیدی را نه؟ برای تهدید دوم راه‌حل پیشنهاد دهید.
۵. یک درخواست تأیید انسانی را طراحی کنید: چه اطلاعاتی نشان داده می‌شود، چه مهلتی دارد و پس از انقضا چه می‌شود؟
۶. (عملی) آزمونی برای `audit.py` بنویسید که جابه‌جایی دو رکورد را تشخیص دهد.
۷. (تحلیلی) با فهرست دوازده‌گانه‌ی ۱-۶۰۰ NIST AI، چهار رده را که برای عامل بازپرداخت مرتبط‌اند انتخاب و برای هر کتتری از AO-RA معرفی کنید.
۸. (تحلیلی) نگاشت پیشنهادی AO-RA به کارکردهای NIST را نقد کنید. چه چیزی از دید حاکمیت جا افتاده است؟

- Debenedetti, E., Zhang, J., Balunović, M., Beurer-Kellner, L., Fischer, M., & Tramèr, F. (2024). AgentDojo: A dynamic environment to evaluate prompt injection attacks and defenses for LLM agents (arXiv:2406.13352). arXiv. <https://doi.org/10.48550/arXiv.2406.13352>
- Greshake, K., Abdelnabi, S., Mishra, S., Endres, C., Holz, T., & Fritz, M. (2023). Not what you've signed up for: Compromising real-world LLM-integrated applications with indirect prompt injection (arXiv:2302.12173). arXiv. <https://doi.org/10.48550/arXiv.2302.12173>
- International Organization for Standardization & International Electrotechnical Commission. (2023). Information technology - Artificial intelligence - Management system (ISO/IEC 42001:2023). ISO/IEC.
- Model Context Protocol. (2026). Model Context Protocol specification (version 2026-07-28). <https://modelcontextprotocol.io/specification/latest> (accessed 2026-10-21)
- National Institute of Standards and Technology. (2024). Artificial Intelligence Risk Management Framework: Generative Artificial Intelligence Profile (NIST AI 600-1). <https://doi.org/10.6028/NIST.AI.600-1>
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Saltzer, J. H., & Schroeder, M. D. (1975). The protection of information in computer systems. *Proceedings of the IEEE*, 63(9), 1278-1308.
- Tabassi, E. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-1>

بخش چهارم: استقرار و بهره‌برداری در مقیاس تولید

زیر ساخت، ارکستراسیون و تحویل پیوسته

عامل‌ها

تا اینجا درباره‌ی «چه چیزی» باید کنترل شود حرف زدیم: قرارداد، ردگیری، ارزیابی، سیاست. این فصل به «کجا و چگونه» می‌پردازد: عامل چگونه در محیط تولید اجرا می‌شود، وقتی کارگر اجرایی می‌میرد چه می‌شود، چگونه نسخه‌ی جدید بی‌خطر منتشر می‌شود و چگونه ظرفیت برآورد می‌شود. محتوای این فصل بیش از فصل‌های قبل مهندسی عمومی نرم‌افزار است؛ شواهد علمی اختصاصی درباره‌ی استقرار عامل‌ها محدود است و بخش بزرگی از توصیه‌ها بر الگوهای شناخته‌شده‌ی مهندسی سامانه‌های توزیع‌شده تکیه دارد. هر جا چنین است، آن را صریح می‌گوییم و برچسب (۲ع) یا (۴ع) می‌زنیم. از نام‌بردن محصولات تجاری خودداری کرده‌ایم، چون ارزیابی مستقلی از آن‌ها نداریم.

اهداف فصل. (۱) الگوهای استقرار عامل را مقایسه کنیم؛ (۲) اجرای طولانی‌مدت و قابل‌بازایی را با مثال اجرایی نشان دهیم؛ (۳) صف، هم‌زمانی و ظرفیت را مدل کنیم؛ (۴) مدیریت وابستگی‌ها و نسخه‌ی ابزارها را روشن کنیم؛ (۵) خط لوله‌ی CI/CD مخصوص عامل و انتشار تدریجی را طراحی کنیم؛ (۶) پیکربندی و محیط‌ها را مدیریت کنیم؛ (۷) یک معماری استقرار مرجع سازمانی ارائه دهیم.

۱۱.۱ الگوهای استقرار عامل در ابر و زیرساخت اختصاصی

سه تصمیم استقرار از همه مهم‌ترند. اول، مدل کجا اجرا می‌شود؟ عامل می‌تواند از سرویس مدل میزبانی‌شده‌ی بیرونی استفاده کند یا از مدل میزبانی‌شده در زیرساخت خود. وانگ و همکاران مشاهده می‌کنند که با رشد نگرانی‌های امنیت داده، شمار فزاینده‌ای از سامانه‌های عامل برخط، مدل‌های متن‌باز با میزبانی محلی را به‌عنوان موتور استنتاج برمی‌گزینند (Wang et al., ۲۰۲۵). این انتخاب پیامد عملیاتی هم دارد: مدل میزبانی‌شده‌ی محلی امکان پایش داخلی‌تر (دسترسی به لجیت و حالت‌های میانی، رویکرد «جعبه‌سفید») را فراهم می‌کند، در حالی که مدل سرویس‌محور اغلب جعبه‌سیاه است و فقط ورودی و خروجی دیده می‌شود (Wang et al., ۲۰۲۵). دوم، عامل کجا اجرا می‌شود؟ کارگرهای اجرایی در ابر عمومی، ابر خصوصی یا زیرساخت اختصاصی؛ مرز اعتماد ۴ (فصل ۵) را نسبت به ابزارها و داده‌ها تعیین می‌کند. سوم، وضعیت کجا نگه‌داری می‌شود؟ حافظه و نقاط ذخیره‌ی وضعیت باید خارج از فرایند کارگر باشند تا مرگ کارگر وظیفه را از بین نبرد.

دو قاعده‌ی کلی (۴ع): کارگرهای عامل بی‌حالت (stateless) طراحی شوند، یعنی هر وضعیت لازم در ذخیره‌ی پایدار باشد تا هر کارگر بتواند هر وظیفه‌ای را از سر بگیرد؛ و تمام اثرهای بیرونی از دروازه‌ی ابزار بگذرند تا نقطه‌ی کنترل یکتا بماند (فصل ۵).

۱۱.۲ معماری سرویس‌گرا و گردش کارهای طولانی‌مدت

وظایف عامل می‌توانند ثانیه‌ها تا ساعت‌ها طول بکشند، به‌ویژه وقتی تأیید انسانی یا

ابزار کند در مسیر است. چنین وظایفی با الگوی درخواست و پاسخ هم‌زمان (HTTP) که منتظر نتیجه می‌ماند) جور نیستند. الگوی مناسب **اجرای ناهمگام** است: درخواست یک شناسه‌ی وظیفه برمی‌گرداند و مصرف‌کننده بعداً وضعیت را می‌پرسد یا اعلان می‌گیرد. جالب است که مشخصات MCP هم برای همین نیاز افزونه‌ای اختیاری به نام «Tasks» تعریف کرده است: اجرای ناهمگام عملیات طولانی با پرس‌وجوی دوره‌ای، ورودی میان‌راه و دستگیره‌های پایدار (Model Context Protocol, ۲۰۲۶). حتی اگر از این افزونه استفاده نکنید، نیازهای آن (شناسه‌ی وظیفه‌ی پایدار، وضعیت قابل پرس‌وجو، امکان تأمین ورودی میان‌راه) نیازهای هر معماری عامل‌اند.

الگوی پیشنهادی (ع۴). هر وظیفه یک ماشین حالت با حالت‌های روشن است: `created`, `running`, `waiting_approval`, `waiting_tool`, `succeeded`, `failed`, `stopped`, `budget_exceeded`. گذار میان حالت‌ها فقط از طریق رویداد انجام می‌شود (و در صفحه‌ی شواهد ثبت می‌شود) و حالت فعلی همیشه از ذخیره‌ی پایدار قابل خواندن است.

۱۱.۳ مدیریت وضعیت پایدار و اجرای قابل‌بازيابی

وانگ و همکاران نکته‌ای را یادآور می‌شوند که برای استقرار حیاتی است: در سامانه‌های عامل می‌توان وضعیت را در هر لحظه از روی داده بازتولید کرد و ثبت وضعیت در گام‌های مختلف (نقاط ذخیره: حافظه و محیط) امکان بازگشت و رفع مشکل را فراهم می‌کند (Wang et al., ۲۰۲۵). این همان پایه‌ی **اجرای قابل‌بازيابی** است: پس از هر اقدام تکمیل‌شده، وضعیت لازم برای ادامه ذخیره شود تا اگر کارگر بمیرد، کارگر دیگر از آخرین نقطه ادامه دهد.

سه چیز باید در نقطه‌ی ذخیره باشد: **تاریخچه** و **فهرست اقدام‌های انجام‌شده**، **شمارنده‌های بودجه** (تا بودجه‌ی مصرف‌شده برگردد) و **نتایج idempotency** (تا اقدام‌های انجام‌شده دوباره اجرا نشوند). سومی ظریف‌ترین است: اگر عامل پس از اجرای بازپرداخت و پیش از ثبت نتیجه بمیرد، و ادامه‌ی اجرا همان فراخوانی را دوباره بزند، دو بار پول پرداخت می‌شود، مگر کلید یکتا و نتیجه‌ی قبلی هم همراه نقطه‌ی ذخیره بیاید. در پیاده‌سازی مرجع، **checkpoint** پس از هر اقدام یک نمای JSON از این سه مورد می‌دهد و **resume** همان را برمی‌گرداند و نتایج **idempotency** را به دروازه‌ی تازه منتقل می‌کند.

کد ۱۱-۱ (گزیده‌ی agent.py). بازگردانی از نقطه‌ی ذخیره و ثبت نقطه‌ی ذخیره پس از هر اقدام.

```
seen: dict = {}
if resume:                                     # continue a run
from
    its last checkpoint
    history[:] = resume["history"]; calls[:] = [tuple(c) for c in
resume["calls"]]
    ledger.steps, ledger.tokens, ledger.usd = resume["steps"],
resume["tokens"], resume["usd"]
    seen = {tuple(k): v for k, v in resume["seen"]}
    gateway.import_cache(resume["idempotency"])
    trace.emit("resume", from_step=resume["steps"])
    if checkpoint:                             # durable state
after
    every completed action
        checkpoint({"history": history, "calls": [list(c) for c
in
    calls], "steps": ledger.steps,
        "tokens": ledger.tokens, "usd": ledger.usd,
        "seen": [[list(k), v] for k, v in seen.items()],
        "idempotency": gateway.export_cache()})
```

مثال `code/examples/ch11_resume.py` یک کارگر را شبیه‌سازی می‌کند که

درست پس از اجرای بازپرداخت می‌میرد؛ کارگر دوم از نقطه‌ی ذخیره ادامه می‌دهد

(خروجی واقعی):
 run 1 crashed: node lost | effects so far: [('refund', '7214', 40)]
 checkpoint : steps = 2 | history length = 2 | idempotency keys = 2
 run 2 resumed: success | refunded 40 | events: ['task.start', 'resume',
 'decision', 'task.end']
 effects total: [('refund', '7214', 40)] -> refund executed 1 time(s)

نتیجه: پس از مرگ کارگر و ازسرگیری، اثر بیرونی دقیقاً یک بار رخ داد و ردگیری
 رویداد **resume** را همراه با گام شروع مجدد ثبت کرد. این ویژگی با آزمون واحد
 هم بررسی شده است. **محدودیت‌ها:** «دقیقاً یک بار» در اینجا به شرطی برقرار است
 که نقطه‌ی ذخیره پس از اثر و پیش از مرگ ثبت شده باشد؛ اگر کارگر بین اجرای
 اثر و ثبت نقطه‌ی ذخیره بمیرد، اثر انجام شده و نتیجه‌اش ثبت نشده است، و فقط
idempotency در **سرویس پابین‌دست** (که کلید را بشناسد) می‌تواند اجرای دوباره
 را ایمن کند. این مسئله‌ی کلاسیک سامانه‌های توزیع‌شده است و راه‌حل کامل آن در
 نمونه‌ی درون‌حافظه‌ای ما نیست.

۱۱.۴ صف‌ها، زمان‌بندی و اجرای هم‌زمان

وظایف از صف به کارگرا می‌رسند. چهار مسئله‌ی مهندسی مهم است. ۱. **هم‌زمانی**
محدود: هم مدل و هم ابزارها محدودیت نرخ دارند؛ هم‌زمانی بیشتر از ظرفیت آن‌ها
 فقط صف و خطا می‌سازد. باید برای هر منبع مشترک (مدل، هر ابزار) سقف هم‌زمانی
 تعریف شود. ۲. **فشار برگشتی (backpressure):** وقتی صف پر می‌شود، سامانه
 باید درخواست جدید را رد یا کند کند، نه بی‌نهایت بپذیرد. ۳. **اولویت و انصاف:**
 وظایف پریسک یا تعاملی بر پس‌زمینه‌ای اولویت دارند، و هیچ کاربر یا عامل نباید

بتواند منابع را انحصاری کند؛ OWASP برای مهار مصرف نامحدود (LLM10) محدودیت نرخ، سهمیه‌ی کاربر، مدیریت منابع به‌ازای کاربر یا درخواست، مهلت و کاهش تدریجی کیفیت در بار زیاد را برمی‌شمارد (OWASP GenAI Security Project, ۲۰۲۵). ۴. اجرای مجدد ایمن: وظیفه‌ی بازگردانده‌شده به صف باید با همان کلیدهای idempotency اجرا شود.

برای برآورد ظرفیت، رابطه‌ی ساده‌ای کمک می‌کند که از نظریه‌ی صف می‌آید (قانون لیتل): تعداد متوسط وظایف هم‌زمان برابر است با نرخ ورود وظایف ضرب در زمان متوسط اجرای هر وظیفه. مثال عددی فرضی: اگر ۲ وظیفه در ثانیه می‌رسد و هر وظیفه به‌طور متوسط ۲۵ ثانیه طول می‌کشد، به‌طور متوسط ۵۰ وظیفه هم‌زمان در جریان است؛ پس اگر هر کارگر هم‌زمان ده وظیفه را مدیریت کند، دست‌کم پنج کارگر لازم است، به‌اضافه‌ی حاشیه‌ی ایمنی برای اوج بار. این محاسبه‌ی تقریبی است و بر اساس میانگین است؛ اوج‌های واقعی و توزیع دم‌بلند زمان اجرا (مثلاً وظایف منتظر تأیید انسانی) باید جداگانه مدل شوند.


۱۱.۵ مدیریت وابستگی‌ها و نسخه‌بندی ابزارها

ابزارها وابستگی‌های اصلی عامل‌اند و تغییرشان بی‌صدا می‌تواند رفتار را عوض کند. وانگ و همکاران خاطرنشان می‌کنند که حتی پس از استانداردسازی با MCP، تغییر پیکربندی سرویس‌دهنده‌ها اغلب به آنومالی‌های کنشی می‌انجامد (Wang et al., ۲۰۲۵). سه قاعده (۴ع): ۱. نسخه‌ی ابزار را سنجاق کنید، شامل رابط (طرح‌واره‌ی ورودی/خروجی) و رفتار؛ ۲. قرارداد ابزار را آزمون کنید: برای هر ابزار مجموعه‌ای از آزمون‌های قرارداد که در خط لوله اجرا می‌شود و تغییر ناسازگار را زود می‌گیرد؛ ۳.

تغییر ابزار را مانند تغییر نسخه‌ی عامل تلقی کنید: دروازه‌ی ارزیابی را فعال می‌کند. به‌ویژه برای ابزارهای بیرونی که کنترلشان با شما نیست (سرور MCP شخص ثالث)، توصیف و رفتار نامعتبر تلقی می‌شود (Model Context Protocol, ۲۰۲۶) و باید در مرز اعتماد ۴ با سیاست و آزمون محافظت شود.

۱۱.۶ خط لوله‌ی CI/CD و انتشار عامل

هامبل و فارلی «خط لوله‌ی استقرار» را فرایند خودکار مدیریت همه‌ی تغییرات از ثبت در مخزن تا انتشار تعریف می‌کنند (Humble & Farley, ۲۰۱۰). خط لوله‌ی عامل از همان ایده می‌آید، با دو تفاوت: (الف) واحد تغییر گسترده‌تر است: کد، دستورالعمل، ابزار، سیاست و مدل، همگی هر یک می‌توانند خط لوله را فعال کنند؛ (ب) آزمون آماری است: یک مرحله‌ی ارزیابی با اجراهای تکراری و آستانه‌های بازه‌ی اطمینان، قلب دروازه‌ی کیفیت است (فصل ۸). شکل ۱۱-۱ مراحل پیشنهادی را نشان می‌دهد.



شکل ۱-۱۱. خط لوله‌ی CI/CD عامل: از تغییر تا انتشار کامل و بازگشت (منبع: نگارنده، با اقتباس از ایده‌ی خط لوله‌ی استقرار Humble & Farley, ۲۰۱۰)

جدول ۱-۱۱. مراحل خط لوله‌ی عامل: ورودی، آزمون و شرط عبور (منبع: نگارنده)

مرحله	چه چیزی اجرا می‌شود	ابزار خودکار	شرط عبور
۲	آزمون واحد (ابزار، سیاست، بودجه) و آزمون قرارداد با مدل ساختگی	آزمون‌های واحد	همه‌ی آزمون‌ها سبز
۳	ارزیابی سناریوها با مدل واقعی و اجراهای تکراری	مهار ارزیابی (فصل ۸)	pass ¹ ، pass ^k و CPST بر پایه‌ی بازه‌ی اطمینان
۴	ساخت ReleaseManifest و امضا	ابزار ساخت	نسخه‌ی دقیق همه‌ی اجزا ثبت شده

مرحله	چه چیزی اجرا می‌شود	ابزار خودکار	شرط عبور
۵	انتشار سایه‌ای	مسیریابی ترافیک	نبودن انحراف معنادار از نسخه‌ی جاری
۶	انتشار قناری	مسیریابی درصدی	شاخص‌های رفتاری در محدوده
۷	انتشار کامل	استقرار تدریجی	پایش پس از انتشار

۱۱.۷ انتشار تدریجی، آزمون سایه‌ای و بازگشت نسخه

سه مرحله‌ی انتشار را در فصل ۶ معرفی کردیم؛ این‌جا جزئیات اجرایی می‌آوریم. در انتشار سایه‌ای، ترافیک واقعی به نسخه‌ی جدید هم می‌رود اما اقدام‌های آن اجرا نمی‌شوند (ابزارهای نوشتنی در حالت شبیه‌سازی یا خشک) و فقط تصمیم‌هایش ثبت و با نسخه‌ی جاری مقایسه می‌شود. نکته‌ی ظریف: عامل اغلب به نتیجه‌ی اقدام قبلی وابسته است، پس در حالت سایه‌ای مسیر نسخه‌ی جدید ممکن است از مسیر واقعی جدا شود؛ مقایسه باید در نقطه‌های تصمیم مشترک انجام شود. در انتشار قناری، درصد کمی از ترافیک واقعی (با اثر واقعی) به نسخه‌ی جدید می‌رود و شاخص‌های رفتاری (فصل ۷) پایش می‌شوند. بازگشت باید سریع و خودکار باشد و از قبل آزموده شود: بازگشت صرفاً یعنی «برگرداندن مانیفست انتشار قبلی»، که چون مانیفست همه‌ی اجزا (مدل، دستورالعمل، ابزار، سیاست) را سنجاق کرده، کامل است.

ارتباط با بودجه‌ی خطا: در سنت SRE، بودجه‌ی خطا تعیین می‌کند چه زمانی می‌توان آزادانه منتشر کرد و چه زمانی باید روی پایداری سرمایه‌گذاری کرد

(Alvidrez, ۲۰۱۶). پیشنهاد نگارنده (ع ۴) تعمیم آن به بودجه‌ی خطای رفتاری است: برای هر عامل، یک سقف نرخ مجاز برای شکست‌های رفتاری (مثلاً نرخ ردهای سیاست یا وظایف ناموفق نمونه‌ای) تعریف می‌شود؛ تا وقتی باقی است، انتشارها ادامه دارد، و وقتی مصرف شد، انتشار متوقف و تمرکز به رفع می‌رود. این ایده در این بررسی آزمون نشده است.

۱۱.۸ مدیریت پیکربندی و تفکیک محیط‌ها

پیکربندی عامل تنها «متغیرهای محیطی» نیست؛ شامل دستورالعمل، پارامترهای نمونه‌برداری، فهرست ابزارها، سیاست و بودجه است و همه باید به صورت کد (نسخه‌دار، قابل بازبینی) نگهداری شوند. چهار محیط معمول: توسعه (مدل ساختگی و ابزارهای ساختگی)، آزمایشی (staging: ابزارها و داده‌ی شبه‌واقعی)، پیش تولید / ارزیابی (مدل واقعی با داده‌ی ناشناس) و تولید. قواعد: هیچ داده‌ی واقعی مشتری در محیط‌های پایین‌تر نباشد؛ اسرار هر محیط جدا؛ هویت‌ها و مجوزها در هر محیط مستقل؛ و کلید توقف اضطراری در هر محیط جداگانه. مهم‌تر از همه، پیکربندی تولید فقط از مسیر خط لوله تغییر کند، نه با ویرایش دستی؛ تغییر دستی اضطراری (مثل سخت‌گیرانه‌تر کردن سیاست) مجاز است، ولی باید ثبت و سپس به مخزن بازگردانده شود.


۱۱.۹ ظرفیت‌سنجی و مقیاس‌پذیری افقی

چون کارگراها بی‌حالت‌اند، مقیاس‌پذیری افقی ساده است: با افزایش بار، کارگر بیشتر. گلوگاه‌های واقعی معمولاً جای دیگرند: (۱) سقف نرخ مدل (تعداد درخواست و

توکن در دقیقه) که فراتر از آن شکست یا صف رخ می‌دهد؛ (۲) ابزارهای پایین دست که ظرفیت مستقل دارند؛ (۳) ذخیره‌ی وضعیت و ردگیری با حجم نوشتن بالا؛ (۴) هزینه: مقیاس‌پذیری افقی یعنی هزینه‌ی خطی در بار و باید با بودجه (فصل ۱۲) هم‌خوان باشد. روش عملی: آزمون بار با سناریوهای واقعی و مدل ساختگی (برای جدا کردن ظرفیت زیرساخت از تأخیر مدل)، و آزمون با مدل واقعی برای سنجش گلوگاه‌های وابسته به مدل. هشدارهای ظرفیت باید بر صف (طول و زمان انتظار) تعریف شوند، نه فقط بر استفاده‌ی پردازنده.

۱۱.۱۰ معماری مرجع استقرار سازمانی

شکل ۱۱-۲ استقرار مرجع AO-RA را نشان می‌دهد. صفحه‌ی کنترل شامل API و احراز هویت، مخزن سیاست و مانیفست انتشار و صف تأیید انسانی است. صفحه‌ی اجرا صف وظایف، کارگرهای بی‌حالت، دروازه‌ی ابزار و جعبه‌ایزوله، و ذخیره‌ی وضعیت پایدار را دارد. صفحه‌ی شواهد مخزن فقط‌افزودنی ردگیری و حسابرسی است. مدل از ارائه‌دهنده‌ای بیرونی یا میزبانی داخلی می‌آید و ابزارها بیرون از مرز اعتماد ۴ قرار دارند.



شکل ۱۱-۲. معماری استقرار مرجع سازمانی (منبع: نگارنده)

این معماری یک الگو است، نه نسخه‌ای قابل خریداری؛ و به‌ویژه سه نکته را تضمین نمی‌کند: امنیت پیکربندی واقعی (مثلاً سخت‌سازی شبکه)، انطباق قانونی و هزینه‌ی مناسب. این‌ها در هر استقرار باید جداگانه بررسی شوند.

جمع‌بندی فصل

استقرار عامل بر سه تصمیم بنا می‌شود: محل مدل، محل اجرای کارگرها و محل وضعیت. کارگرها بی‌حالت و وضعیت پایدار است؛ وظایف طولانی با ماشین حالت و اجرای ناهمگام مدیریت می‌شوند. نقطه‌ی ذخیره‌ی شامل تاریخچه، بودجه و نتایج idempotency، ازسرگیری ایمن را ممکن می‌کند، و مثال اجرایی نشان داد اثر بیرونی پس از مرگ کارگر دقیقاً یک بار رخ می‌دهد. صف و هم‌زمانی باید با سقف‌های

مدل و ابزارها هماهنگ باشند. ابزارها نسخه‌ی سنجاق‌شده و آزمون قرارداد دارند. خط لوله‌ی عامل ایده‌ی خط لوله‌ی استقرار را با آزمون آماری و واحد تغییر گسترده‌تر می‌گیرد، و انتشار سایه‌ای، قناری و بازگشت مبتنی بر مانیفست آن را کامل می‌کنند.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. چرا کارگرهای عامل باید بی‌حالت باشند؟ چه چیزی باید در نقطه‌ی ذخیره بیاورد تا ازسرگیری ایمن باشد؟
۲. در مثال ۱۱.۳ اگر کارگر بین اجرای بازپرداخت و ثبت نقطه‌ی ذخیره می‌مرد، چه می‌شد؟ چه راهی ایمن می‌کند؟
۳. با نرخ ورود ۵ وظیفه در ثانیه و میانگین زمان ۴۰ ثانیه، تعداد هم‌زمانی متوسط و تعداد کارگر لازم (با ظرفیت ۱۲ وظیفه‌ی هم‌زمان برای هر کارگر) را حساب کنید.
۴. فرق انتشار سایه‌ای و قناری را بنویسید. چرا مقایسه‌ی سایه‌ای عامل‌ها ظریف‌تر از سرویس‌های سنتی است؟
۵. یک ماشین حالت برای وظیفه طراحی کنید که شامل تأیید انسانی و بازگشت باشد؛ گزاره‌های مجاز را بنویسید.
۶. (عملی) در `ch11_resume.py` سناریویی بنویسید که کارگر پیش از ثبت نقطه‌ی ذخیره بمیرد و نتیجه را توضیح دهید.
۷. (تحلیلی) «بودجه‌ی خطای رفتاری» را برای عامل بازپرداخت تعریف کنید: چه شاخصی، چه سقفی و چه واکنشی؟ چه ایرادی ممکن است داشته باشد؟

منابع

- Alvidrez, M. (2016). Embracing risk. In B. Beyer, C. Jones, J. Petoff, & N. R. Murphy (Eds.), Site reliability engineering: How Google runs production systems (Chapter 3). O'Reilly Media. <https://sre.google/sre-book/embracing-risk/>
- Humble, J., & Farley, D. (2010). Continuous delivery: Reliable software releases through build, test, and deployment automation. Addison-Wesley.
- Model Context Protocol. (2026). Model Context Protocol specification (version 2026-07-28). <https://modelcontextprotocol.io/specification/latest> (accessed 2026-10-21)
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>

هزینه، کارایی و بهره‌وری اقتصادی

بیشتر عامل‌هایی که در آزمایش خوب کار می‌کنند، در تولید با یک پرسش اقتصادی روبه‌رو می‌شوند: «آیا ارزشش را دارد؟» هزینه‌ی عامل صرفاً قیمت توکن نیست؛ تلاش‌های ناموفق، اجرای مجدد، ابزارهای پولی، ذخیره‌ی ردگیری، تأیید انسانی و خسارت اقدام نادرست هم در آن‌اند. این فصل هزینه را مانند یک قید مهندسی اولویت‌دار می‌بیند: اجزای آن را تعریف می‌کند، معیار «هزینه‌ی هر وظیفه‌ی موفق» را می‌سازد، با مثال عددی نشان می‌دهد چه چیزی را می‌سند و چه چیزی را نه، و بهینه‌سازی را بر پایه‌ی شواهد سامان می‌دهد. **همه‌ی قیمت‌ها و اعداد هزینه در این فصل فرضی‌اند؛ هدف آموزش روش است نه گزارش قیمت واقعی بازار.**

اهداف فصل. (۱) اجزای هزینه‌ی اجرای عامل را مشخص کنیم؛ (۲) تأخیر و هزینه را در مسیرهای چندمرحله‌ای تحلیل کنیم؛ (۳) موازنه‌ی کیفیت، سرعت و هزینه را بیان کنیم؛ (۴) بودجه‌گذاری برای وظیفه را به‌کار ببندیم؛ (۵) تکنیک‌های بهینه‌سازی (نهان‌سازی، مسیریابی مدل، دسته‌بندی) را با خطرهایشان بسنجیم؛ (۶) شاخص «هزینه‌ی هر وظیفه‌ی موفق» را تعریف و با مثال اجرایی آزمایش کنیم.

۱۲.۱ اجزای هزینه‌ی اجرای عامل

مرور وانگ و همکاران در دسته‌بندی سنجه‌های پایش، «سنجه‌های هزینه» را دسته‌ی جداگانه‌ای در سامانه‌های عامل می‌داند، با نمونه‌هایی مثل تعداد کل توکن‌ها و هزینه‌ی

هر وظیفه؛ و تأکید می‌کند که چون هزینه عامل حیاتی است، سنجه‌های هزینه در کنار سنجه‌های سیستمی و عملکرد برنامه‌ریزی می‌شود (Wang et al., ۲۰۲۵). ابزارهای AgentOps هم «ردیابی و مدیریت هزینه‌ی LLM» (پیگیری مصرف توکن نزد ارائه‌دهندگان مدل) را از قابلیت‌های پایش می‌شمارند (Dong et al., ۲۰۲۴). مرور ارزیابی عامل‌ها نیز هشدار می‌دهد که ارزیابی‌های جاری اغلب بر کارایی تمرکز می‌کنند و هزینه و کارایی را نادیده می‌گیرند، و پیشنهاد می‌کند هزینه‌ی مصرف توکن، هزینه‌ی API، زمان استنتاج و مصرف کلی منابع به‌عنوان سنجه‌ی هسته‌ای دنبال شود (Yehudai et al., ۲۰۲۵). جدول ۱۲-۱ اجزای هزینه را در یک مدل ساده می‌آورد.

جدول ۱۲-۱. اجزای هزینه‌ی یک وظیفه‌ی عامل (منبع: نگارنده)

جزء	چه چیزی	چگونه اندازه‌گیری می‌شود
مدل	توکن ورودی و خروجی در هر فراخوانی (شامل زمینه‌ی تکرارشونده در هر گام)	رویداد llm.call: توکن × قیمت
ابزارها	فراخوانی‌های پولی (API، جست‌وجو)، اجرای کد	رویداد tool.result: هزینه‌ی هر فراخوانی
زیرساخت	کارگرها، صف، ذخیره‌ی وضعیت	سهم‌بندی هزینه‌ی ماهانه بر وظایف
ردگیری و ارزیابی	ذخیره‌سازی رویدادها، ارزیابی برخط، داور مدلی	حجم داده و تعداد ارزیابی‌ها
انسان	تأیید، بازبینی، رسیدگی به رخداد	زمان انسانی × نرخ ساعتی
شکست	اجرای مجدد، جبران اثر، خسارت اقدام نادرست	شمارش شکست‌ها × میانگین هزینه‌ی رفع

دو مورد از این فهرست اغلب فراموش می‌شود. اول، هزینه‌ی زمینه‌ی تکرارشونده: در حلقه‌ی چندمرحله‌ای، هر گام معمولاً کل تاریخچه را دوباره به مدل می‌دهد؛ پس

هزینه‌ی توکن ورودی با تعداد گام‌ها سریع‌تر از خطی می‌رود، مگر زمینه فشرده یا نهان‌سازی شود. دوم، هزینه‌ی شکست: عامل ناموفق هم هزینه کرده و باید دوباره اجرا یا جبران شود.

۱۲.۲ مصرف توکن، فراخوانی ابزار و هزینه‌ی زیرساخت

مصرف توکن در هر گام به سه چیز بستگی دارد: اندازه‌ی دستورالعمل ثابت، اندازه‌ی تاریخچه‌ی انباشته و اندازه‌ی خروجی. برای طراحی کم‌هزینه سه اهرم وجود دارد (۴ع): کوتاه‌سازی زمینه‌ی ثابت (دستورالعمل فشرده، ابزارهای کمتر در زمینه)، مدیریت تاریخچه (خلاصه‌سازی یا حذف مراحل قدیمی، با توجه به خطر فراموشی اطلاعات مهم؛ فصل ۳)، و محدود کردن خروجی. در ابزارها، هزینه‌ی پولی هر فراخوانی (مثلاً API جست‌وجو) باید در همان رویداد ثبت شود و در بودجه‌ی وظیفه بیاید (در کد مرجع، `ToolResult.cost_usd`). هزینه‌ی زیرساخت معمولاً ثابت‌تر است و به‌صورت سهم‌بندی بر وظایف توزیع می‌شود.

۱۲.۳ اندازه‌گیری تأخیر در مسیرهای چندمرحله‌ای

تأخیر یک وظیفه‌ی عامل مجموع تأخیر گام‌هاست: هر گام یک فراخوانی مدل و گاهی ابزار. سه نکته‌ی اندازه‌گیری: (۱) تأخیر باید به تفکیک گام و نوع ثبت شود (مدل، ابزار، انتظار تأیید)، تا گلوگاه معلوم باشد. (۲) میانگین گمراه‌کننده است؛ توزیع را گزارش کنید (میان و صدک‌های بالا)، چون وظایف طولانی با گام‌های بیشتر دُم توزیع را سنگین می‌کنند. (۳) زمان انتظار انسانی را جدا کنید: وظیفه‌ای که منتظر تأیید است سرویس کند نیست، و ادغام این دو شاخص‌ها را بی‌معنا می‌کند. وانگ و همکاران

تأخیر هر فراخوانی ابزار، زمان کل تکمیل وظیفه، تأخیر فراخوانی مدل و فراوانی فراخوانی API را از سنجش‌های سیستمی عامل می‌دانند (Wang et al., ۲۰۲۵).

۱۲.۴ موازنه‌ی کیفیت، سرعت و هزینه

همه‌ی بهبودهای کیفیت هزینه دارند. در فصل ۲ دیدیم روش «سازگاری درونی» چند مسیر مستقل را نمونه می‌گیرد و پاسخ پرتکرار را برمی‌گزیند (X. Wang et al., ۲۰۲۳): کیفیت بالاتر ولی چندبرابر شدن هزینه‌ی استدلال؛ یا بازبینی مدل‌محور (فصل ۸) که یک فراخوانی دیگر اضافه می‌کند. تصمیم درست، موازنه‌ی صریح است: برای هر وظیفه، سه مقدار (کیفیت، تأخیر، هزینه) را بسنجید و با قرارداد رفتاری مقایسه کنید. کمک مهم: وظایف را بر حسب ریسک و ارزش طبقه‌بندی کنید. وظیفه‌ی کم‌ریسک و پرحجم با مدل ارزان و ارزیابی نمونه‌ای؛ وظیفه‌ی پرریسک با مدل قوی‌تر و تأیید انسانی. این همان تناسب کنترل با ریسک است که در فصل ۱۰ آمد.

۱۲.۵ بودجه‌گذاری برای وظیفه و محدودسازی مصرف

بودجه‌ی وظیفه در AO-RA یک قید ساختاری است (فصل ۵): گام، توکن، هزینه‌ی دلاری و مهلت. چهار پرسش برای تعیین بودجه: (۱) هزینه‌ی هدف برای یک اجرای موفق عادی چقدر است (از تجربه یا آزمایش)؟ (۲) حاشیه‌ی اجرای دشوار چقدر مجاز است (مثلاً دو تا سه برابر هدف)؟ (۳) پس از رسیدن به سقف چه می‌شود (توقف و ارجاع به انسان، نه ادامه‌ی نامحدود)؟ (۴) بودجه‌ی تجمیعی برای کاربر یا گروه در بازه‌ی زمانی چیست؟ OWASP برای مهار «مصرف نامحدود» همین کنترل‌ها را توصیه می‌کند: محدودیت نرخ، سهمیه‌ی کاربر، مدیریت منابع به‌ازای کاربر

یا درخواست، مهلت، پایش و ثبت مصرف (OWASP GenAI Security Project, ۲۰۲۵). تفاوت آن با بودجه‌ی ساختاری ما این است که مصرف نامحدود در OWASP بیشتر به حمله‌ی انکار سرویس و هزینه‌ی مالی می‌پردازد؛ ما همان کنترل را برای مهار حلقه‌ها و خطاهای عادی هم به‌کار می‌بریم.

۱۲.۶ نهان‌سازی، دسته‌بندی درخواست‌ها و بهینه‌سازی مسیر

تکنیک‌های رایج کاهش هزینه، همگی موازنه‌ای دارند و باید با ارزیابی تأیید شوند. جدول ۱۲-۲ آن‌ها را فهرست می‌کند؛ فهرست بر پایه‌ی تجربه‌ی مهندسی عمومی است (ع۲) و هیچ‌یک را در این کتاب به‌صورت تجربی ارزیابی نکرده‌ایم. جدول ۱۲-۲. تکنیک‌های کاهش هزینه و خطر هر کدام (منبع: نگارنده بر پایه‌ی تجربه‌ی عمومی مهندسی)

تکنیک	کاهش هزینه از	خطر یا هزینه‌ی پنهان
نهان‌سازی (cache) پاسخ یا نتیجه‌ی ابزار	حذف فراخوانی تکراری	پاسخ منسوخ؛ نشت داده بین کاربران؛ باید کلید و انقضای دقیق باشد
فشرده‌سازی تاریخچه	کاهش توکن ورودی هر گام	فراموشی اطلاعات مهم؛ ریسک آنومالی حافظه (فصل ۳)
مسیریابی مدل بر حسب پیچیدگی	وظیفه‌ی ساده با مدل ارزان	خطای مسیریاب؛ پیچیدگی ارزیابی
دسته‌بندی درخواست‌ها (batch)	بازده بهتر زیرساخت	تأخیر بیشتر؛ شکست دسته‌ای
کوتاه‌کردن مسیر (ابزار ترکیبی)	کاهش گام‌ها	ابزار بزرگ‌تر و پراختیارتر؛ ریسک امنیتی
مدل کوچک‌تر	قیمت کمتر هر توکن	نرخ شکست بالاتر؛ باید با CPST سنجید

تکنیک «مسیریابی» یکی از پنج الگوی گردش کار در راهنمای Anthropic است (Anthropic, ۲۰۲۴)؛ خود مسیریاب یک مؤلفه‌ی تصمیم‌گیر است و بنابراین باید به همان دقت بقیه‌ی اجزا ارزیابی شود.

۱۲.۷ انتخاب مدل متناسب با پیچیدگی وظیفه

انتخاب مدل در فصل ۶ با قرارداد رفتاری مقایسه شد. از دید اقتصادی، معیار «قیمت هر توکن» گمراه‌کننده است. مدل ارزان‌تر با نرخ موفقیت پایین‌تر ممکن است وظیفه‌ی بیشتری ناموفق و اجرای مجدد تولید کند. معیار درست «هزینه‌ی هر وظیفه‌ی موفق» است که در بخش‌های بعد تعریف و آزموده می‌شود.

۱۲.۸ تحلیل هزینه‌ی شکست و اجرای مجدد

وقتی وظیفه‌ای شکست می‌خورد، سه هزینه می‌سازد: **هزینه‌ی مستقیم اجرای ناموفق**، **هزینه‌ی اجرای مجدد** (اگر خودکار تکرار شود) و **هزینه‌ی خسارت یا رفع (جبران اقدام، رسیدگی انسانی، آسیب به اعتبار)**. مورد سوم اغلب بزرگ‌ترین است و به‌سختی اندازه‌گیری می‌شود. برای سامانه‌های پرریسک، یک برآورد (حتی تقریبی) از «هزینه‌ی هر شکست» لازم است، چون در انتخاب مدل و سطح کنترل تعیین‌کننده است.

۱۲.۹ هزینه‌ی هر وظیفه‌ی موفق و شاخص‌های اقتصادی

تعریف (ع۴): **هزینه‌ی هر وظیفه‌ی موفق (CPST)**. مجموع هزینه‌ی همه‌ی اجراها (موفق و ناموفق) تقسیم بر تعداد وظایف موفق. این شاخص هزینه‌ی شکست‌ها را به وظایف موفق «بار

می‌کند». **هزینه‌ی کل هر وظیفه‌ی موفق با خسارت (TCPS)** آن را با هزینه‌ی رفع شکست‌ها گسترش می‌دهد: (هزینه‌ی همه‌ی اجراها + تعداد شکست‌ها $\times$ هزینه‌ی هر شکست) تقسیم بر تعداد موفقیت‌ها.

پایاده‌سازی مرجع، **CPST** را به‌صورت تابعی ساده دارد (**cpst** در **cost.py**). برای آزمودن اینکه این شاخص چه می‌سنجد، مثال **code/examples/ch12_cpst.py** سه «مدل» فرضی با قابلیت اطمینان و قیمت متفاوت می‌سازد و ۴۰۰ اجرا از هر کدام را با قرارداد رفتاری فصل ۶ می‌سنجد. **هشدار صداقت:** مدل‌ها شبیه‌ساز تصادفی بذردارند، قیمت هر گام فرضی است (۰/۰۰۲، ۰/۰۰۶، و ۰/۰۲۰ دلار) و هزینه‌ی رفع

هر شکست هم فرضی (۰/۴۰ دلار) است. خروجی واقعی اجرا:

model	success	per request	CPST	CPST+damage
small	0.850	0.0080	0.0094	0.0800
medium	0.932	0.0200	0.0214	0.0504
large	0.980	0.0620	0.0633	0.0714

چهار برداشت، با دقت:

۱. **هزینه‌ی هر درخواست مدل کوچک را ارزان‌ترین نشان می‌دهد (۰/۰۰۸۰)**
۲. **CPST** این نتیجه را در این مثال **تغییر** نمی‌دهد: ترتیب همان است (۰/۰۰۹۴، ۰/۰۲۱۴، ۰/۰۶۳۳)، چون هزینه‌ی هر گام در مدل بزرگ ۱۰ برابر است و جبران افزایش نرخ موفقیت (۰/۸۵ در برابر ۰/۹۸) نمی‌کند. فرضیه‌ی اولیه‌ی ما (فصل ۱۴: **CPST** تصمیم انتخاب مدل را متفاوت می‌کند) در این مثال ساده **تأیید نشد**؛ و این نتیجه‌ی مهمی است که نباید پنهانش کرد. ۳.
- اما **TCPS** (**CPST** به‌علاوه‌ی هزینه‌ی رفع شکست) ترتیب را عوض می‌کند: مدل متوسط ارزان‌ترین می‌شود (۰/۰۵۰۴) و مدل کوچک گران‌ترین (۰/۰۸۰۰)، چون هر شکست مدل کوچک ۰/۴۰ دلار خسارت دارد و ۱۵٪ اجراهایش شکست می‌خورد.

۴. بزرگ‌ترین حساسیت، به هزینه‌ی شکست است، و آن همان چیزی است که کمتر اندازه‌گیری می‌شود. پس نتیجه‌ی مهندسی این نیست که «مدل متوسط بهتر است» (قیمت‌ها و خسارت فرضی‌اند)، بلکه این است که انتخاب مدل باید بر پایه‌ی هزینه‌ی کل هر موفقیت با لحاظ خسارت شکست باشد، و تحلیل حساسیت نسبت به هزینه‌ی شکست جزو تصمیم است.

این مثال محدودیت‌های روشنی دارد: شبیه‌سازها مستقل‌اند و قیمت‌ها و خسارت فرضی؛ در واقعیت قیمت هر گام با طول زمینه تغییر می‌کند؛ هزینه‌ی انسانی و ردگیری محاسبه نشده؛ و اندازه‌ی نمونه (۴۰۰) بازه‌ی اطمینان پهنی دارد (فصل ۸). برای تصمیم واقعی، همین روش را با قیمت‌ها و داده‌ی واقعی خودتان تکرار کنید.

۱۲.۱۰ بهینه‌سازی مبتنی بر شواهد عملیاتی

بهینه‌سازی هزینه مانند بهینه‌سازی کارایی کد باید با اندازه‌گیری هدایت شود. حلقه‌ی پیشنهادی (ع ۴): اندازه‌گیری (توزیع هزینه به تفکیک جزء و وظیفه) ← شناسایی بزرگ‌ترین سهم (اغلب چند وظیفه‌ی پرگام یا زمینه‌ی بزرگ) ← آزمایش یک تغییر (مثلاً فشرده‌سازی زمینه یا مدل ارزان‌تر) ← سنجش با قرارداد رفتاری (کیفیت افت نکرده باشد؛ فصل ۸) ← انتشار تدریجی (فصل ۱۱) ← تکرار. دو قاعده: هیچ بهینه‌سازی هزینه بدون دروازه‌ی کیفیت منتشر نشود، و هزینه‌ی خود اندازه‌گیری و ارزیابی (ردگیری، داور مدلی، تأیید انسانی) در حساب بیاید.

جمع‌بندی فصل

هزینه‌ی عامل از مدل، ابزار، زیرساخت، ردگیری و ارزیابی، انسان و شکست تشکیل

می‌شود و زمینه‌ی تکرارشونده و شکست دو جزء فراموش شده‌اند. تأخیر و هزینه باید به تفکیک گام و با توزیع اندازه‌گیری شوند. بودجه‌ی وظیفه قید ساختاری است. تکنیک‌های کاهش هزینه (نهان‌سازی، مسیریابی، فشرده‌سازی) موازنه دارند و باید با ارزیابی تأیید شوند. در مثال شبیه‌سازی شده، CPST به‌تنهایی ترتیب مدل‌ها را نسبت به هزینه‌ی هر درخواست عوض نکرد، اما هزینه‌ی کل هر موفقیت با لحاظ خسارت شکست، آن را عوض کرد؛ نتیجه‌ی عملی این است که انتخاب مدل باید به هزینه‌ی شکست حساس باشد و تحلیل حساسیت داشته باشد.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. شش جزء هزینه‌ی عامل را بنویسید. کدام دو تا بیشتر فراموش می‌شوند و چرا؟
۲. چرا هزینه‌ی توکن ورودی با تعداد گام‌ها سریع‌تر از خطی رشد می‌کند؟ دو راه کاهش آن را با خطرهایشان بنویسید.
۳. در جدول خروجی مثال ۱۲.۹، اگر هزینه‌ی هر شکست از $0/40$ به $0/05$ دلار کاهش یابد، ترتیب TCPS چه می‌شود؟ (محاسبه کنید).
۴. CPST و TCPS را تعریف کنید و توضیح دهید هر یک چه تصمیمی را بهتر پشتیبانی می‌کند.
۵. برای عامل بازپرداخت، بودجه‌ی وظیفه‌ی پیشنهادی را با چهار پرسش بخش ۱۲.۵ تعیین کنید.
۶. (عملی) `ch12_cpst.py` را با سه مقدار متفاوت `FAILURE_DAMAGE` اجرا کنید و نقطه‌ای را بیابید که مدل ارزان‌ترین عوض می‌شود.
۷. (تحلیلی) چه عواملی باعث می‌شود نتیجه‌ی این شبیه‌سازی به واقعیت تعمیم‌پذیر

نباشد؟ دست‌کم پنج مورد.

منابع

- Anthropic. (2024, December 19). Building effective agents. <https://www.anthropic.com/engineering/building-effective-agents>
- Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Wang, X., Wei, J., Schuurmans, D., Le, Q., Chi, E., Narang, S., Chowdhery, A., & Zhou, D. (2023). Self-consistency improves chain of thought reasoning in language models. International Conference on Learning Representations (ICLR 2023). arXiv:2203.11171. <https://doi.org/10.48550/arXiv.2203.11171>
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>
- Yehudai, A., Eden, L., Li, A., Uziel, G., Zhao, Y., Bar-Haim, R., Cohan, A., & Shmueli-Scheuer, M. (2025). Survey on evaluation of LLM-based agents (arXiv:2503.16416). arXiv. <https://doi.org/10.48550/arXiv.2503.16416>

عملیات چندعاملی و مدل عملیاتی سازمان

وقتی یک عامل به گروهی از عامل‌ها تبدیل می‌شود، مسائل فصل‌های قبل «ضرب» می‌شوند: ردگیری باید میان عامل‌ها منتقل شود، اختیار و بودجه باید میان آن‌ها تقسیم شود، شکست یک عامل به دیگران سرایت می‌کند و مسئولیت میان افراد و تیم‌های بیشتری پراکنده می‌شود. این فصل دو بخش دارد. بخش اول، **عملیات چندعاملی**: معماری‌ها، هماهنگی، شکست‌های بین‌عاملی، کنترل دسترسی و بودجه‌ی گروه. بخش دوم، **مدل عملیاتی سازمان**: نقش‌ها، مدیریت رخداد، مدل بلوغ پنج‌سطحی و شاخص‌های آمادگی.

اهداف فصل. (۱) معماری‌های چندعاملی و تقسیم مسئولیت را بررسی کنیم؛ (۲) هماهنگی و انتقال وظیفه را با قرارداد مشخص کنیم؛ (۳) شکست‌های بین‌عاملی را مهار کنیم؛ (۴) اختیار و بودجه را در سطح گروه با کد آزمون‌شده کنترل کنیم؛ (۵) نقش‌ها و مدیریت رخداد را تعریف کنیم؛ (۶) مدل بلوغ و شاخص‌های آمادگی سازمان را بسازیم؛ (۷) مدیریت تغییر و پذیرش را بحث کنیم.

۱۳.۱ معماری‌های چندعاملی و تقسیم مسئولیت

سامانه‌های عامل‌محور را بر حسب تعداد عامل‌ها به تک‌عاملی و چندعاملی تقسیم می‌کنند؛ و وانگ و همکاران خاطرنشان می‌کنند که همین تمایز، آنومالی‌ها را به درون‌عاملی و بین‌عاملی تقسیم می‌کند، مشابه معماری سرویس‌ها که خطا می‌تواند

درون یک سرویس یا در ارتباط میان سرویس‌ها رخ دهد (Wang et al., ۲۰۲۵). پنج الگوی گردش کار مرجع Anthropic (زنجیره‌ی دستورالعمل‌ها، مسیریابی، موازی‌سازی، هماهنگ‌کننده و کارگران، و ارزیاب و بهینه‌ساز) هر یک ساختار چندعاملی خاصی ایجاد می‌کنند (Anthropic, ۲۰۲۴). از دید عملیات، سه الگوی پرکاربرد را با ریسک‌هایشان مقایسه می‌کنیم.

جدول ۱۳-۱. الگوهای چندعاملی و ریسک عملیاتی (منبع: نگارنده، با اتکا بر Anthropic, ۲۰۲۴; Cemri et al., ۲۰۲۵)

الگو	ساختار	ریسک عملیاتی غالب
هماهنگ‌کننده و کارگران	یک عامل مرکزی وظیفه را می‌شکند و به کارگرا می‌سپارد	نقطه‌ی شکست مرکزی؛ انتقال ناقص زمینه؛ تأیید ناکافی نتایج کارگرا
موازی‌سازی	چند عامل هم‌زمان روی بخش‌های مستقل یا رأی‌گیری	هزینه‌ی چندبرابر؛ ناسازگاری نتایج؛ تعارض بر منبع مشترک
ارزیاب و بهینه‌ساز	یک عامل خروجی را می‌سازد و عامل دیگر نقد می‌کند	حلقه‌ی بازبینی بی‌پایان؛ هم‌خانواده بودن ارزیاب و تولیدکننده (سوگیری خودتقویتی)

تحلیل MAST نشان داد که در سامانه‌های چندعاملی، شکست‌ها نه تنها از ضعف مدل بلکه از طراحی سامانه و هماهنگی می‌آیند؛ سامانه‌ی خوب طراحی شده با همان مدل عملکرد بهتری دارد (Cemri et al., ۲۰۲۵). این به معنای تقسیم مسئولیت صریح است: هر عامل نقش، ابزار، بودجه و مرز مشخص دارد و هر نقض آن‌ها (مثلاً «نقض مشخصات نقش»، FM-1.2) قابل تشخیص است.

۱۳.۲ هماهنگی، ارتباط و انتقال وظیفه میان عامل‌ها

ارتباط میان عامل‌ها مهم‌ترین نقطه‌ی ضعف است. حالت‌های شکست MAST دسته‌ی کاملی را به ارتباط اختصاص می‌دهند: بازنشانی گفت‌وگو، درخواست نکردن توضیح، انحراف از وظیفه، کتمان اطلاعات، نادیده گرفتن ورودی عامل دیگر و عدم تطابق استدلال و اقدام (Cemri et al., ۲۰۲۵). وانگ و همکاران نیز آنومالی‌های ارتباطی (مثل افزونگی) و آنومالی‌های اعتماد را جزو آنومالی‌های بین‌عاملی می‌شمارند و برای تشخیص برخی از آن‌ها روش‌هایی را فهرست می‌کنند که بر «گراف عامل‌ها» کار می‌کنند (Wang et al., ۲۰۲۵).

راه‌حل مهندسی، قرارداد انتقال (handoff contract) است: هر واگذاری وظیفه از یک عامل به عامل دیگر شامل فیلدهای ثابت باشد، نه متن آزاد. فهرست حداقلی (پیشنهاد نگارنده، ع ۴): (۱) هدف دقیق برای گیرنده؛ (۲) قیود و سیاست‌ها (که از والد به ارث می‌رسند و تنها محدودتر می‌شوند)؛ (۳) بودجه‌ی اختصاص‌یافته؛ (۴) مراجع شواهد (شناسه‌ی ردگیری والد، اسناد بازیابی‌شده)؛ (۵) شکل خروجی مورد انتظار و معیار پذیرش؛ (۶) شرط توقف و مسیر گزارش خطا (چه زمانی گیرنده باید برگردد و سؤال کند). بند ۶ مستقیماً به حالت «درخواست نکردن توضیح» (FM-2.2) پاسخ می‌دهد.

۱۳.۳ مدیریت وابستگی‌ها و شکست‌های بین‌عاملی

سرایت شکست در سامانه‌ی چندعاملی با کانال زبان طبیعی رخ می‌دهد. مثال وانگ و همکاران، شبیه‌سازی مزایده‌ای است که حمله به یک خریدار باعث پیشنهادهای

بسیار بالا و فروپاشی مزایده می‌شود (Wang et al., ۲۰۲۵). سه کنترل مهار شکست بین‌عاملی (ع۴): ۱. تأیید خروجی هر عامل پیش از مصرف: خروجی یک کارگر داده‌ی غیرقابل‌اعتماد برای هماهنگ‌کننده است (مرز اعتماد ۲)؛ نه دستور. تحلیل MAST هم نشان می‌دهد که تأییدگر نهایی با بررسی سطح پایین کافی نیست و تأیید چندسطحی لازم است (Cemri et al., ۲۰۲۵). ۲. مدارشکن و مهلت بین عامل‌ها: اگر عاملی پاسخ نداد یا پیاپی خطا داد، دیگران منتظر نمانند. ۳. جداسازی منابع مشترک: سهمیه‌ی جداگانه برای هر عامل بر منبع مشترک، تا یک عامل بهینه‌شده انحصارش نکند؛ وانگ و همکاران همین سناریو را درباره‌ی پیامد ناخواسته‌ی رفع یک آنومالی ذکر می‌کنند (Wang et al., ۲۰۲۵).

۱۳.۴ مشاهده‌پذیری تعاملات چندعاملی

فصل ۷ انتشار زمینه‌ی ردگیری را بیان کرد؛ این‌جا سه افزوده: (۱) ثبت پیام‌ها میان عامل‌ها به‌عنوان رویداد جداگانه (فرستنده، گیرنده، محتوا یا مرجع، قرارداد انتقال)؛ (۲) نمای گراف: تعاملات یک وظیفه به‌صورت گراف عامل‌ها (گره: عامل، یال: واگذاری یا پیام) قابل‌نمایش و تحلیل باشد؛ (۳) شاخص‌های سطح گروه: تعداد واگذاری‌ها به‌ازای وظیفه، نرخ بازگشت پرسش از کارگر به هماهنگ‌کننده، هزینه و زمان به تفکیک عامل. ثبت جداگانه‌ی رویدادهای هر عامل بدون ردگیری میان‌عاملی، همان حالتی است که تحلیل شکست چندعاملی را ناممکن می‌کند.

۱۳.۵ کنترل دسترسی و بودجه در سطح گروه عامل‌ها

قاعده‌ی بنیادین (ع۴): اختیار از والد به فرزند هرگز افزایش نمی‌یابد. کارگر یک

عامل هماهنگ‌کننده نمی‌تواند ابزاری داشته باشد که هماهنگ‌کننده ندارد، و بودجه‌اش از **باقی‌مانده‌ی** بودجه‌ی والد برداشت می‌شود، نه از چیزی جدا. این قاعده، «تشدید امتیاز» (privilege escalation) از طریق واگذاری را مسدود می‌کند و با اصل حداقل اختیار (فصل ۱۰) سازگار است. پیاده‌سازی مرجع تابع **delegate** را دارد که قرارداد فرزند می‌سازد و دو شرط را اعمال می‌کند: ابزارها زیرمجموعه‌ی والد و بودجه $\geq$ باقی‌مانده‌ی والد؛ سطح ریسک هم به ارث می‌رسد.

کد ۱۳-۱ (**delegation.py**). واگذاری که فقط محدودتر می‌کند.

```
def delegate(parent: TaskContract, parent_ledger: Ledger, child_id: str,
            goal: str, tools: set[str],
            steps: int, tokens: int, usd: float, success=None) ->
    TaskContract:
    """Create a child contract. Rules: tools must be a subset of the
    parent's; the budget is carved out of
    what the parent has LEFT (never more); risk tier is inherited (never
    lowered)."""
    extra = set(tools) - set(parent.allowed_tools)
    if extra:
        raise DelegationError(f"privilege escalation: {sorted(extra)} not
        in parent's allowed_tools")
    left_steps = parent.budget.max_steps - parent_ledger.steps
    left_tokens = parent.budget.max_tokens - parent_ledger.tokens
    left_usd = parent.budget.max_usd - parent_ledger.usd
    if steps > left_steps or tokens > left_tokens or usd > left_usd + 1e-
12:
        raise DelegationError(f"budget exceeds what the parent has left
        (steps {left_steps}, tokens {left_tokens}, usd {left_usd:.4f})")
    kwargs = {"success": success} if success else {}
    return TaskContract(child_id, goal, frozenset(tools), Budget(steps,
    tokens, usd, parent.budget.deadline_s),
    parent.risk_tier, **kwargs)
```

مثال `code/examples/ch13_delegate.py` یک هماهنگ‌کننده با دو کارگر را

نشان می‌دهد (خروجی واقعی):

```
parent budget: 12 steps, 3000 tokens, 0.12 usd
W1 ok          : tools = ['lookup_order'] | parent left: 8 steps
escalation     -> refused: privilege escalation: ['delete_db'] not in
```

```
parent's allowed_tools
over budget -> refused: budget exceeds what the parent has left (steps
8, tokens 2100, usd 0.0900)
W2 ok      : tools = ['refund'] | risk tier inherited: high
```

کارگر اول مجاز شد و بودجه‌اش از والد کم شد (۴ گام از ۱۲)؛ درخواست کارگر دوم برای ابزار `delete_db` به‌عنوان تشدید امتیاز رد شد؛ درخواست ۹ گام هم رد شد چون والد فقط ۸ گام داشت؛ و کارگر دوم با ابزار و بودجه‌ی مجاز پذیرفته شد. سه آزمون واحد همین رفتارها را بررسی می‌کند. **محدودیت‌ها:** این نمونه بودجه‌ی «ثابت» را کنترل می‌کند و واگذاری بازگشتی چندسطحی یا هم‌زمانی میان کارگرها را مدل نمی‌کند؛ در سیستم واقعی باید بودجه‌ی مصرف‌شده‌ی کارگرها به دفتر والد گزارش شود (در مثال با `ledger.charge` دستی نشان داده شده).

۱۳.۶ مسئولیت‌های توسعه‌دهندگان، مهندسان پلتفرم و اپراتورها

جدول مسئولیت فصل ۴ را برای سامانه‌های چندعاملی دو افزوده تکمیل می‌کند. مالک گروه (`orchestration owner`) که مسئول ساختار گروه، قراردادهای انتقال و بودجه‌ی تجمیعی است و مالک هر عامل که مسئول رفتار فردی‌اش است. دانگ و همکاران مسئولیت مشترک میان مالک عامل، ارائه‌دهنده‌ی مدل پایه و ارائه‌دهندگان ابزارها و عامل‌های بیرونی را از چالش‌های اصلی می‌شمارند که شناسایی منبع شکست را سخت می‌کند (Dong et al., ۲۰۲۴). رفع این ابهام با دو ابزار ممکن است: ردگیری که منبع هر تصمیم را نشان دهد (کدام عامل، کدام نسخه، کدام مدل) و قرارداد روشن با ارائه‌دهندگان درباره‌ی نسخه‌بندی، اطلاع از تغییر و مسئولیت.


۱۳.۷ مدیریت رخداد و پاسخ‌گویی عملیاتی

فرایند رخداد در فصل‌های ۶ و ۹ آمد؛ این‌جا ساختار سازمانی آن. **سطح‌بندی (ع۴):**

(الف) رخداد **بحرانی**: اثر بیرونی نادرست و گسترده یا نشت داده؛ پاسخ فوری، توقف اضطراری، اطلاع‌رسانی؛ (ب) **جدی**: افت رفتار قابل‌توجه بدون اثر بیرونی گسترده؛ (ج) **جزئی**: انحراف شاخص بدون پیامد. **نقش‌ها**: فرماندهی رخداد، تحلیل‌گر ردگیری، مالک عامل، نماینده‌ی امنیت و نماینده‌ی ارتباطات. **خروجی لازم پس از هر رخداد جدی**: خط زمانی از ردگیری، گام آنومال و بُعد علی (فصل ۹)، تأثیر و جبران، سناریوی جدید در قرارداد رفتاری، و اقدام اصلاحی با مسئول و مهلت.

۱۳.۸ مدل بلوغ سازمانی AgentOps

مدل بلوغ ابزار تشخیص و برنامه‌ریزی است. مدل زیر پیشنهاد نگارنده (ع۴) است و از مدل رسمی خاصی برگرفته یا بر داده‌ی تجربی مبتنی نیست؛ ارتباط آن با شاخص‌های عملیاتی فرضیه‌ی ۶ است و در فصل ۱۴ بحث می‌شود.



شکل ۱۳-۱. مدل بلوغ پنج‌سطحی AgentOps (منبع: نگارنده)

جدول ۱۳-۲. ماتریس بلوغ: توانمندی‌ها در هر سطح (منبع: نگارنده)

توانمندی	سطح ۱	سطح ۲	سطح ۳	سطح ۴ و ۵
قرارداد	هدف شفاهی	شرح وظیفه	قرارداد وظیفه و رفتاری	قرارداد نسخه‌دار، سناریوی هر رخداد
مشاهده‌پذیری	لاگ متنی	رویداد پایه	ردگیری ساخت یافته، بازپخش	+ شاخص‌های رفتاری، ممیزی خاموش
ارزیابی	آزمون دستی	چند سناریو	سناریوها با اجراهای تکراری	pass^k، بازه‌ی اطمینان، آزمون امنیتی خودکار
امنیت و حاکمیت	بی‌قاعده	فهرست مجاز ابزار	سیاست پیش از اجرا، تأیید انسانی	دفتر حسابرسی، حاکمیت میان‌عاملی
استقرار	دستی	اسکرپت	خط لوله با دروازه	انتشار سایه‌ای و قناری، بازگشت خودکار
هزینه	بی‌اندازه‌گیری	هزینه‌ی کل	بودجه‌ی وظیفه	.CPST/TCPS بهینه‌سازی مبتنی بر شواهد
سازمان	فرد	مالک مشخص	نقش‌ها و ماتریس مسئولیت	بازنگری منظم، مدیریت رخداد

۱۳.۹ شاخص‌های آمادگی سازمان

پیش از آنکه یک سازمان عامل پراختیار منتشر کند، دوازده پرسش آمادگی را می‌توان بررسی کرد (ع ۴): (۱) سطح خودمختاری عامل صریح ثبت شده است؟ (۲) قرارداد رفتاری با سناریو دارد؟ (۳) ردگیری کامل و بازپخش‌پذیر است؟ (۴) ارزیابی با اجرای تکراری و آستانه‌ی آماری انجام می‌شود؟ (۵) سیاست پیش از اجرا و پیش‌فرض رد

دارد؟ (۶) اسرار از زمینه‌ی مدل جدا هستند؟ (۷) تأیید انسانی برای اقدام‌های پراثر وجود دارد؟ (۸) کلید توقف اضطراری آزموده شده است؟ (۹) جبران یا بازگشت برای اقدام‌های نوشتنی طراحی شده است؟ (۱۰) بودجه‌ی گام، توکن و هزینه اعمال می‌شود؟ (۱۱) مالک هر عامل و فرایند رخداد مشخص است؟ (۱۲) سناریوی هر رخداد به قرارداد برمی‌گردد؟ پاسخ «نه» به هر یک از پرسش‌های ۵، ۷ و ۸ برای عامل سطح ۳ یا ۴ مانع انتشار است.

۱۳.۱۰ مدیریت تغییر و پذیرش عامل‌ها در سازمان

عامل‌ها فقط یک تغییر فنی نیستند؛ فرایندهای کاری و اعتماد را تغییر می‌دهند. چند توصیه‌ی عملی (ع۴): با وظایف کم‌ریسک و پرحجم شروع کنید و سطح خودمختاری را بر پایه‌ی شواهد بالا ببرید؛ انسان را در حلقه نگه دارید و دلیل بدهید، نه فقط دستور؛ نتایج را شفاف گزارش کنید (شاخص‌های رفتاری و رخدادها، نه فقط موفقیت‌ها)؛ آموزش بدهید: کارکنان باید بدانند عامل چه می‌تواند و چه نمی‌تواند و چگونه خطا را گزارش کنند؛ مسیر بازگشت داشته باشید تا اعتماد با تجربه‌ی نخست بد از بین نرود. اعتماد به عامل هم باید از شواهد بیاید: فرضیه‌ی بنیادین کتاب این است که ردگیری و ارزیابی، بر خلاف اطمینان‌بخشی ذهنی، مبنای اعتماد قابل دفاع‌اند.

جمع‌بندی فصل

سامانه‌ی چندعاملی مسائل تک‌عاملی را ضرب می‌کند. الگوهای هماهنگ‌کننده، موازی‌سازی و ارزیاب هر یک ریسک خاص دارند و شکست‌ها بیشتر از طراحی و هماهنگی می‌آیند تا ضعف مدل. قرارداد انتقال، تأیید خروجی هر عامل پیش

از مصرف، مدارشکن میان عامل‌ها و جداسازی منابع، شکست را مهار می‌کنند. اختیار و بودجه هرگز از والد به فرزند افزایش نمی‌یابد و با کد آزمون‌شده نشان داده شد. مسئولیت‌ها با مالک گروه و مالک هر عامل تکمیل می‌شود و مدیریت رخداد سطح‌بندی و نقش دارد. مدل بلوغ پنج‌سطحی و دوازده پرسش آمادگی ابزار سازمانی‌اند؛ هر دو پیشنهاد نگارنده‌اند و هنوز اعتبارسنجی نشده‌اند.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. سه الگوی چندعاملی جدول ۱۳-۱ را با ریسک‌هایشان مقایسه کنید. برای هر کدام یک کنترل پیشنهاد دهید.
۲. چرا خروجی یک کارگر برای هماهنگ‌کننده «داده‌ی غیرقابل اعتماد» است؟ این چه ارتباطی با تزریق دستورالعمل دارد؟
۳. قرارداد انتقال شش‌فیلدی را برای واگذاری «بررسی سفارش» از هماهنگ‌کننده به کارگر بنویسید.
۴. در کد `delegate`، سطح ریسک فرزند همیشه از والد به ارث می‌رسد. اگر بخواهیم فرزند بتواند ریسک **بالتر** (نه پایین‌تر) اعلام کند، چه تغییری لازم است و چرا کاهش ریسک نباید ممکن باشد؟
۵. سازمان خود را (یا یک سازمان فرضی) در ماتریس بلوغ قرار دهید و سه گام بعدی را اولویت‌بندی کنید.
۶. (عملی) کد `delegate` را به گونه‌ای گسترش دهید که مصرف واقعی کارگر به دفتر والد گزارش و در صورت عبور از بودجه‌ی واگذارشده خطا بدهد.
۷. (تحلیلی) مدل بلوغ پنج‌سطحی چه نقدهایی دارد؟ چگونه می‌توان آن را با داده‌ی

سازمانی اعتبارسنجی کرد؟

منابع

Anthropic. (2024, December 19). Building effective agents. <https://www.anthropic.com/engineering/building-effective-agents>

Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>

Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>

Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>

بخش پنجم: اعتبارسنجی علمی و مسیر آینده

روش‌شناسی پژوهش و اعتبارسنجی

چارچوب AgentOps

در چهار بخش قبلی چارچوبی پیشنهاد شد: تعریف، اصول، معماری، قابلیت‌های مهندسی و الگوهای استقرار. بخش مهمی از آن، پیشنهاد نگارنده است و هنوز اعتبارسنجی تجربی نشده است. این فصل صادقانه می‌گوید چه چیزی را می‌توان گفت، چه چیزی را نمی‌توان، و چگونه می‌توان آن را آزمود. نخست روش مرور ادبیات و تفکیک یافته‌های موجود از پیشنهادها را بیان می‌کنیم؛ سپس شش فرضیه را به طرح‌های آزمایش تبدیل می‌کنیم؛ و دو آزمون کوچک شبیه‌سازی (نه تجربی روی عامل واقعی) را گزارش می‌کنیم که فقط رفتار ابزارهای اندازه‌گیری ما را روشن می‌کنند و یکی از آن‌ها یک فرضیه‌ی اولیه‌ی ما را اصلاح کرد. اصل راهنمای فصل: طرح اعتبارسنجی را گزارش می‌کنیم، نتیجه‌ی تجربی روی عامل واقعی ندارد.

اهداف فصل. (۱) روش مرور نظام‌مند را شرح دهیم؛ (۲) یافته‌های موجود را از پیشنهادهای کتاب تفکیک کنیم؛ (۳) فرضیه‌ها را به پرسش‌های قابل‌آزمون با سنج و طرح تبدیل کنیم؛ (۴) طرح آزمایش، مجموعه‌ی سناریوی شکست و خط مبنا را طراحی کنیم؛ (۵) طرح مطالعه‌ی موردی را بیان کنیم؛ (۶) تهدیدهای اعتبار را بررسی کنیم؛ (۷) آزمون‌های شبیه‌سازی را با محدودیت‌هایشان گزارش کنیم؛ (۸) محدودیت‌های چارچوب و گزارش نتایج منفی را بپذیریم.

۱۴.۱ مرور نظام‌مند ادبیات و شناسایی شکاف پژوهشی

راهنمای کیچنهام و چارترز برای مرور نظام‌مند در مهندسی نرم‌افزار، چارچوب استانداردِ عرضه می‌کند: تعریف پرسش‌های پژوهشی، راهبرد جست‌وجو، معیار ورود و خروج، ارزیابی کیفیت، استخراج داده و ترکیب (Kitchenham & Charters, ۲۰۰۷). دانگ و همکاران نمونه‌ی خوبی از به‌کارگیری روش‌های نزدیک ارائه می‌دهند: مطالعه‌ی نگاشت نظام‌مند ابزارهای AgentOps با جست‌وجو در GitHub (چهار رشته‌ی جست‌وجو و ۷۶۰ مخزن اولیه که با پایش صفحه‌های نخست و غربال‌گری به ۱۱ ابزار رسید) و جست‌وجوی تکمیلی گوگل که ۶ ابزار دیگر افزود، و در مجموع ۱۷ ابزار با معیارهای ورود مشخص (پشتیبانی از ردگیری یا پایش، ردگیری در سطح عامل یا برنامه‌ی مبتنی بر مدل، نسخه‌ی رسمی و مستندات عمومی) (Dong et al., ۲۰۲۴).

محدودیت این کتاب: مرور ادبیات ما یک مرور نظام‌مند کامل نیست. جست‌وجو از طریق arXiv و وب عمومی انجام شد؛ پایگاه‌های ACM، IEEE Xplore، Springer و ScienceDirect به‌صورت ساختاریافته پیمایش نشدند؛ منابع ارزیابی کیفیت صوری (فراداده‌ی صفحه‌ی رسمی) انتخاب شدند؛ و بخشی از منابع به‌صورت چکیده و فراداده بررسی شد. پیوست F روش پیشنهادی برای مرور نظام‌مند کامل را می‌آورد. **شکاف‌های پژوهشی** که از این مرور شناسایی شد (فهرستی کوتاه): (۱) نبود تعریف رسمی و اجماع بر «AgentOps»، چون دو سنت پژوهشی با تأکیدهای متفاوت وجود دارد (Wang et al., ۲۰۲۵؛ Dong et al., ۲۰۲۴)؛ (۲) ضعف ارزیابی هزینه‌کاری، ایمنی و استحکام (Yehudai et al., ۲۰۲۵)؛ (۳) نبود

ارزیابی تجربی معماری‌های مرجع عملیاتی در محیط واقعی؛ (۴) نبود شواهد دربارۀ اثر کنترل‌های پیشگیرانه (سیاست، تأیید انسانی) بر موفقیت وظیفه.

۱۴.۲ تفکیک یافته‌های موجود از پیشنهاد‌های جدید کتاب

شفافیت علمی ایجاب می‌کند خواننده بتواند برای هر ادعا بفهمد در چه رده‌ای است. جدول ۱۴-۱ ادعاهای اصلی کتاب را بر پایه‌ی برچسب‌های ۱ تا ۵ (فصل مقدمه‌ی پروژه) رده‌بندی می‌کند.

جدول ۱۴-۱. رده‌بندی ادعاهای اصلی کتاب بر حسب وضعیت دانش (منبع: نگارنده)

ادعا	رده	منبع یا وضعیت
عامل‌ها آنومالی درون‌عاملی و بین‌عاملی دارند؛ چهار مرحله‌ی پایش تا رفع	۱ع	Wang et al., ۲۰۲۵
ردگیری با بازه‌ها، مصنوعات عامل را قابل مشاهده می‌کند	۱ع	Dong et al., ۲۰۲۴
۱۴ حالت شکست چندعاملی در ۳ دسته؛ طراحی سامانه عامل شکست است	۱ع	Cemri et al., ۲۰۲۵
موفقیت یک‌باره برای عامل‌های ابزارمحور کافی نیست؛ pass ⁴ k	۱ع	Yao et al., ۲۰۲۴
توزیع دستورالعمل و اختیار بیش‌ازحد ریسک‌های اصلی‌اند	۳ع	OWASP GenAI Security Project, ۲۰۲۵
کارکردهای حاکمیت، نگاشت، اندازه‌گیری، مدیریت	۳ع	Tabassi, ۲۰۲۳
معماری سه‌صفحه‌ای و هشت‌لایه‌ی AO-RA	۴ع	این کتاب؛ آزمون نشده
قرارداد رفتاری و قرارداد وظیفه	۴ع	این کتاب؛ آزمون نشده
AgentOps-FT طبقه‌بندی	۴ع	ترکیب Wang et al. و Cemri et al.؛ آزمون نشده
شاخص CPST/TCPS	۴ع	این کتاب؛ مثال شبیه‌سازی شده

ادعا	رده	منبع یا وضعیت
مدل بلوغ پنج‌سطحی	۴ع	این کتاب: آزمون‌نشده
فرضیه‌های H1 تا H6	۵ع	بخش ۱۴.۴

۱۴.۳ استخراج نیازمندی‌ها و طراحی چارچوب مرجع

فرایند ساخت چارچوب در این کتاب، به‌صورت مرحله‌های قابل پیگیری بود: (۱) شناسایی شکست‌ها از ادبیات (وانگ و همکاران، Cemri و همکاران) و ثبت الگوهای شکست (فصل ۳)؛ (۲) استخراج ده نیازمندی R1 تا R10 از آن شکست‌ها؛ (۳) طراحی معماری که هر نیازمندی را به یک لایه یا قرارداد نگاشت کند (فصل ۵)؛ (۴) پیاده‌سازی مرجع آزمون‌پذیر (بسته‌ی aorch با ۳۴ آزمون واحد)؛ (۵) تعریف فرضیه‌های قابل آزمون برای ادعاهایی که از آن پیامد می‌شوند. ماتریس ردیابی (نیازمندی ← لایه ← کد ← آزمون) برای بازیابی‌گر قابل ساخت است و در پیوست E آمده است.

۱۴.۴ فرضیه‌های قابل آزمون و پرسش‌های پژوهشی

شش فرضیه‌ی کتاب را به‌شکل دقیق (در یک قاب «سنجه، طرح، داده») بازنویسی می‌کنیم. دو فرضیه (H2 و H5) پس از آزمون‌های شبیه‌سازی اصلاح شده‌اند و این اصلاح را صریحاً مشخص کرده‌ایم.

جدول ۱۴-۲. فرضیه‌های اصلاح‌شده و طرح هر یک (منبع: نگارنده)

شناسه 4	فرضیه (ع ۵ - اثبات نشده)	سنجه	طرح پیشنهادی
H1	ردگیری ساخت‌یافته‌ی سطح تصمیم همراه با بازپخش، زمان و دقت تشخیص نقطه‌ی علی شکست را نسبت به لاگ متنی بهبود می‌دهد	زمان تشخیص؛ درستی نقطه‌ی علی	آزمایش درون‌آزمودنی با مهندسان؛ خطاهای کاشته‌شده
H2) ۱) صلاح (شده)	قاعده‌ی انتشار با الزام $pass^k$ پیامد انتشار نسخه‌ی ناپایدار را (از دید استفاده‌ی تکراری) بهتر بازتاب می‌دهد؛ نه اینکه توان آماری بیشتری داشته باشد	رابطه‌ی قاعده با تجربه‌ی تکراری کاربر	مطالعه با کاربران یا داده‌ی استفاده‌ی واقعی؛ شبیه‌سازی (بینید ۱۴.۷)
H3	سیاست حداقل اختیار با تأیید انسانی شرطی، موفقیت حمله‌ی تزریق غیرمستقیم را بدون افت معنادار موفقیت وظیفه کاهش می‌دهد	نرخ موفقیت حمله؛ نرخ موفقیت وظیفه	ارزیابی روی محیط AgentDojo (Debenedetti et al., ۲۰۲۴) با و بدون سیاست
H4	بودجه‌ی گام و محافظ تکرار هزینه‌ی حلقه‌ها را بدون افت بزرگ در موفقیت کاهش می‌دهد	هزینه، موفقیت، نرخ حلقه	طرح عاملی روی عامل‌های واقعی؛ شبیه‌سازی (بینید ۱۴.۷)
H5) ۱) صلاح (شده)	شاخص TCPS (با لحاظ هزینه‌ی رفع شکست) انتخاب مدل را نسبت به هزینه‌ی هر درخواست تغییر می‌دهد	رتبه‌ی مدل‌ها	تحلیل حساسیت بر داده‌ی واقعی هزینه و شکست
H6	سطح بلوغ سازمان با پیامدهای عملیاتی (زمان بازیابی، تعداد رخدادهای جدی) رابطه دارد	رابطه‌ی آماری	پیمایش یا مطالعه‌ی موردی چندسازمانی

۱۴.۵ طراحی آزمایش برای ارزیابی چارچوب

ووهلین و همکاران چارچوب استاندارد برای آزمایش در مهندسی نرم‌افزار می‌دهند: تعریف فرضیه، متغیرهای مستقل و وابسته، آزمودنی‌ها، اشیای آزمایش، طرح (مثلاً درون‌آزمودنی یا بین‌آزمودنی)، ابزار، اجرا، تحلیل و تهدیدهای اعتبار (Wohlin et al., ۲۰۱۲). برای H1 مثلاً: متغیر مستقل «نوع شواهد» (ردگیری ساخت‌یافته با بازپخش در برابر لاگ متنی)، متغیر وابسته «زمان تا نقطه‌ی علی» و «درستی»، آزمودنی‌ها مهندسان با تجربه‌ی مشابه، اشیای مجموعه‌ی خطاهای کاشته‌شده (FM-1.3، FM-2.6 و ...) با ترتیب تصادفی و موازنه‌ی ترتیب، و تحلیل با آزمون آماری مناسب (با توجه به اندازه‌ی نمونه‌ی کوچک انسانی). اندازه‌ی اثر و توان آزمون باید پیش از آزمایش تعیین شود تا از «آزمایش بی‌توان» پرهیز شود.

۱۴.۶ ساخت سناریوهای شکست و مجموعه‌ی آزمون

مجموعه‌ی سناریوی شکست باید دو منبع داشته باشد: ۱. طبقه‌بندی‌های موجود: هر یک از ۱۴ حالت MAST و رده‌های F01 تا F16 دست‌کم یک سناریوی کاشته‌شده؛ ۲. حمله‌های شناخته‌شده: برای H3، محیط AgentDojo با ۹۷ وظیفه و ۶۲۹ مورد آزمون امنیتی (Debenedetti et al., ۲۰۲۴). هر سناریو باید قطعی‌پذیر باشد: شکست کاشته‌شده با کنترل بذریه، ابزار ساختگی یا مدل اسکریپتی قابل‌بازتولید باشد، اما رفتار مدل واقعی هم در لایه‌ی جداگانه سنجیده شود. همچنین برچسب «مصنوعی» یا «واقعی» روی هر مورد بماند.

۱۴.۷ معیارهای مقایسه، خط مبنا و آزمون‌های شبیه‌سازی

هر ادعای بهبود به خط مبنا نیاز دارد. خطوط مبنای پیشنهادی: (الف) سامانه‌ی بدون هیچ‌یک از کنترل‌های AO-RA (فقط پایش سرویس و آزمون یک‌باره)؛ (ب) سامانه‌ی با ردگیری ساده‌ی متنی؛ (ج) نسخه‌های ساده‌شده‌ی چارچوب (فقط سیاست، یا فقط ارزیابی). مقایسه‌ی منصفانه یعنی همه‌ی شرایط روی همان وظایف و همان بودجه.

برای روشن کردن رفتار ابزارهای اندازه‌گیری، دو آزمون کوچک شبیه‌سازی انجام دادیم. هشدار: هر دو روی «مدل‌های» تصادفی بذردار با پارامترهای فرضی انجام شدند. آن‌ها ابزار و منطق اندازه‌گیری را می‌آزمایند، نه عامل‌های واقعی را؛ نتیجه‌ی آن‌ها نباید به‌عنوان شواهد اثر کنترل‌ها بر عامل‌های واقعی گزارش شود.

آزمون شبیه‌سازی ۱ (فرضیه‌ی H2): قدرت تشخیص دو دروازه. دو دروازه‌ی انتشار را مقایسه کردیم: دروازه‌ی A (رد اگر میانگین pass^1 کمتر از آستانه) و دروازه‌ی B (رد اگر میانگین pass^4 کمتر از آستانه). هر آزمایش شامل دو سناریو و ۴۰ اجرا برای هر سناریو بود و ۲۰۰۰۰ تکرار از هر شرایط؛ احتمال موفقیت هر اجرا q و اجراها مستقل. نخست آستانه‌ها را دلخواه گذاشتیم ($A: 0/92$ و $B: 0/78$). نتیجه: دروازه‌ی B بیشتر افت را می‌گرفت (برای $q = 0/90: 90/6\%$ در برابر $69/6\%$)، اما هشدار کاذب آن هم بیشتر بود ($35/8\%$ در برابر $10/6\%$ روی نسخه‌ی پایه با $q = 0/95$). یعنی مقایسه مخدوش بود: B فقط سخت‌گیرتر بود. دوباره، این بار با آستانه‌های کالیبره‌شده به‌گونه‌ای که هشدار کاذب هر دو دروازه روی نسخه‌ی پایه $\approx 5\%$ باشد ($A: 0/912$ ، $B: 0/684$). نتیجه‌ی آزمون با شرایط مساوی (خروجی واقعی

:ch14_h2_pilot.py

20000 trials per row; 2 scenarios x 40 runs; thresholds calibrated so

each gate has ~5% false alarms on the baseline $q=0.95$

gate A: reject if $\text{mean pass}^1 < 0.912$ gate B: reject if $\text{mean pass}^4 < 0.684$

true per-run success q	gate A (pass^1)	gate B (pass^4)
0.95 (baseline)	0.045	0.045
0.93 (small regression)	0.197	0.196
0.90 (regression)	0.551	0.551
0.85 (large regression)	0.927	0.926

دو دروازه توان تشخیص یکسانی دارند. این منطقی است: در مدل اجراهای مستقل، pass^k برای هر سناریو یک تابع صعودی از شمار موفقیت‌هاست؛ پس تغییر آستانه‌ی pass^1 به آستانه‌ی pass^4 تنها محل برش را عوض می‌کند. این نتیجه فرضیه‌ی اولیه‌ی ما را رد کرد (« pass^k افت را بیشتر آشکار می‌کند») و $H2$ را به شکل جدول ۱۴-۲ اصلاح کرد: مزیت pass^k در الزامی است که می‌گذارد، یعنی «بی‌نقص بودن در استفاده‌ی تکراری»، نه در توان آماری. محدودیت‌های این نتیجه: فرض استقلال اجراها، دو سناریو با q یکسان؛ و در عامل‌های واقعی که اجراها هم‌پسته‌اند و سناریوها ناهمگن‌اند، رفتار می‌تواند فرق کند.

آزمون شبیه‌سازی ۲ (فرضیه‌ی $H4$): جاروب بودجه‌ی گام. عامل

شبیه‌سازی‌شده‌ای که در ۲۰٪ اجراها در حلقه می‌افتد (فرضی) و از این حلقه‌ها ۳۰٪ پس از ۱۴ گام اضافه خارج می‌شوند، با سقف‌های گام متفاوت اجرا شد (۲۰۰۰ اجرا؛

هزینه‌ی هر گام فرضی ۰/۰۰۵ دلار). خروجی واقعی `ch14_pilot.py`:

max_steps	success	mean steps	mean cost
6	0.780	3.88	0.0194
10	0.780	4.76	0.0238
16	0.780	6.07	0.0304
25	0.840	7.51	0.0376
50	0.840	9.91	0.0496

سقف ۱۰ گام موفقیت را از ۰/۸۴ به ۰/۷۸ کاهش داد (شش واحد درصد: همان

حلقه‌هایی که بالقوه بازبایی می‌شدند) و هزینه‌ی متوسط را از ۰/۰۴۹۶ به ۰/۰۲۳۸

رساند (حدود ۵۲٪ کمتر). هزینه به‌ازای هر وظیفه‌ی موفق (هزینه‌ی متوسط تقسیم بر نرخ موفقیت) از حدود ۰/۰۵۹ (سقف ۵۰) به حدود ۰/۰۳۰ (سقف ۱۰) رسید. این «موازنه» را آشکار می‌کند: فرضیه‌ی H4 («بدون افت بزرگ») به آستانه‌ی «بزرگ» و نرخ بازیابی حلقه‌ها بستگی دارد، که در عامل واقعی مجهول است. شبیه‌سازی فقط نشان می‌دهد ابزار اندازه‌گیری ما این موازنه را می‌سنجد.

۱۴.۸ مطالعه‌ی موردی و ارزیابی عملیاتی

برای H6 و ارزیابی کلی چارچوب، مطالعه‌ی موردی مناسب‌تر از آزمایش است. رونسون و هوست راهنمای گزارش مطالعه‌ی موردی در مهندسی نرم‌افزار را با فهرست‌های وارسی عرضه کرده‌اند (Runeson & Höst, ۲۰۰۹). طرح پیشنهادی (ع ۴): سازمان یا تیم با دست‌کم یک عامل در تولید انتخاب شود؛ مداخله‌ی تدریجی (نخست ردگیری، سپس قرارداد و ارزیابی، سپس سیاست) با ثبت شاخص‌های پایه قبل و بعد؛ داده‌ها شامل رخدادها، زمان بازیابی، هزینه و مصاحبه با تیم؛ تحلیل کیفی و کمی؛ و گزارش شامل محدودیت‌ها و تهدیدها. تعمیم تک‌مطالعه محدود است؛ مطالعه‌ی چندموردی ترجیح دارد.

۱۴.۹ اعتبار درونی، اعتبار بیرونی و تهدیدهای اعتبار

چهار نوع تهدید اعتبار معمولاً بررسی می‌شود (Wohlin et al., ۲۰۱۲): اعتبار درونی (آیا تغییر در نتیجه واقعاً ناشی از مداخله است؟ تهدیدها: تاریخچه، انتخاب، بلوغ، ابزار)؛ اعتبار بیرونی (آیا نتیجه به عامل‌ها و سازمان‌های دیگر تعمیم می‌یابد؟)؛ اعتبار سازه (آیا سنجه همان چیزی را می‌سنجد که مد نظر است؟ مثلاً آیا $pass^k$

- همان «قابلیت اطمینان» است؟)؛ و اعتبار نتیجه‌گیری (آیا تحلیل آماری معتبر است؟ توان کافی؟ چندگانگی آزمون‌ها؟). تهدیدهای ویژه‌ی عامل‌ها:
- تغییر مدل پایه در طول آزمایش (ارائه‌دهنده نسخه‌ی شناسه را عوض کند): نسخه‌ها سنجاق و ثبت شوند.
 - آلودگی داده‌ی ارزیابی: سناریوها در دستورالعمل یا آموزش راه یافته باشند.
 - وابستگی اجراها: فرض استقلال برقرار نیست و بازه‌های اطمینان خوش‌بینانه‌اند.
 - داور مدلی: سوگیری‌های داور بر نتایج اثر می‌گذارد (Zheng et al., ۲۰۲۳).
 - سوگیری نویسنده: پیشنهاددهنده‌ی چارچوب، خودش آن را ارزیابی می‌کند؛ ارزیابی مستقل لازم است.

۱۴.۱۰ گزارش نتایج منفی و محدودیت‌های چارچوب

در این فصل و فصل ۱۲ دو بار نتیجه‌ی شبیه‌سازی با انتظار اولیه‌ی ما نخواند: (۱) $pass^k$ در توان تشخیص مزیتی بر $pass^1$ نداشت؛ (۲) CPST به‌تنهایی ترتیب مدل‌ها را عوض نکرد. این‌ها را عمداً گزارش کردیم، چون نتیجه‌ی منفی داده‌ی علمی است و پنهان کردن آن‌ها پیشنهاد را بی‌اعتبار می‌کند. محدودیت‌های کلی چارچوب: (۱) آزمون‌نشده روی عامل‌های واقعی در تولید؛ (۲) وابسته به مجموعه‌ی کوچک منابع بررسی‌شده؛ (۳) بخشی از تحلیل‌ها بر فرض‌های ساده (استقلال، هزینه‌ی ثابت) استوار است؛ (۴) نگاشت‌ها (NIST، OWASP) پیشنهادی‌اند و گواهی انطباق نیستند؛ (۵) سازمان‌های کوچک ممکن است بار چارچوب را سنگین ببابند.

جمع‌بندی فصل

روش اعتبارسنجی بر مرور نظام‌مند، تفکیک شفاف یافته‌ها از پیشنهادها، تبدیل ادعاها به فرضیه‌های قابل‌آزمون، طرح آزمایش و مطالعه‌ی موردی استوار است و تهدیدهای اعتبار صریح شده‌اند. دو آزمون شبیه‌سازی به ما نشان دادند ابزار اندازه‌گیری چگونه رفتار می‌کند و دو فرضیه ($H2$ و $H5$) را اصلاح کردند: $pass^k$ الزام متفاوتی می‌گذارد، نه توان آماری بیشتر؛ و تصمیم انتخاب مدل به هزینه‌ی رفع شکست حساس است. چارچوب هنوز بر عامل‌های واقعی در تولید آزموده نشده و این مهم‌ترین محدودیت آن است.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. تفاوت یافته‌ی ع ۱ و پیشنهاد ع ۴ را با سه مثال از جدول ۱۴-۱ توضیح دهید.
۲. چرا مقایسه‌ی اول دو دروازه (با آستانه‌های دلخواه) مخدوش بود؟ چگونه با تنظیم آستانه رفع شد؟
۳. فرض کنید عامل واقعی اجراهایش هم‌بسته‌اند. بازه‌ی اطمینان ویلسون خوش‌بینانه‌تر می‌شود یا بدبینانه‌تر؟ چرا؟
۴. برای $H3$ طرح آزمایش بنویسید: شرایط، متغیرهای مستقل و وابسته، تعداد اجرا و تحلیل.
۵. سه تهدید اعتبار بیرونی برای نتایج یک آزمایش روی یک عامل پشتیبانی را بنویسید.
۶. (عملی) آزمون شبیه‌سازی ۱ را برای $k = 2$ و $k = 8$ تکرار کنید. آیا هنوز توان دو دروازه برابر است؟

۷. (تحلیلی) اگر سناریوها ناهمگن باشند (q مختلف)، $pass^k$ میانگین بیشتر یا کمتر از $k \square (q)$ می‌دهد؟ چرا؟ چه پیامدی برای تفسیر دارد؟

منابع

- Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>
- Debenedetti, E., Zhang, J., Balunović, M., Beurer-Kellner, L., Fischer, M., & Tramèr, F. (2024). AgentDojo: A dynamic environment to evaluate prompt injection attacks and defenses for LLM agents (arXiv:2406.13352). arXiv. <https://doi.org/10.48550/arXiv.2406.13352>
- Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>
- Kitchenham, B., & Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering (Version 2.3; EBSE Technical Report EBSE-2007-01). Keele University and University of Durham.
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Runeson, P., & Hl̈st, M. (2009). Guidelines for conducting and reporting case study research in software engineering. Empirical Software Engineering, 14(2), 131-164. <https://doi.org/10.1007/s10664-008-9102-8>
- Tabassi, E. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-1>
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>
- Wohlin, C., Runeson, P., Hl̈st, M., Ohlsson, M. C., Regnell, B., & Wessl̈n, A. (2012). Experimentation in software engineering. Springer. <https://doi.org/10.1007/978-3-642-29044-2>
- Yao, S., Shinn, N., Razavi, P., & Narasimhan, K. (2024). tau-bench: A benchmark for tool-agent-user interaction in real-world domains (arXiv:2406.12045). arXiv. <https://>

doi.org/10.48550/arXiv.2406.12045

Yehudai, A., Eden, L., Li, A., Uziel, G., Zhao, Y., Bar-Haim, R., Cohan, A., & Shmueli-Scheuer, M. (2025). Survey on evaluation of LLM-based agents (arXiv:2503.16416). arXiv. <https://doi.org/10.48550/arXiv.2503.16416>

Zheng, L., Chiang, W.-L., Sheng, Y., Zhuang, S., Wu, Z., Zhuang, Y., Lin, Z., Li, Z., Li, D., Xing, E. P., Zhang, H., Gonzalez, J. E., & Stoica, I. (2023). Judging LLM-as-a-judge with MT-Bench and Chatbot Arena. NeurIPS 2023 Datasets and Benchmarks Track. arXiv:2306.05685. <https://doi.org/10.48550/arXiv.2306.05685>

مسائل باز و آینده‌ی مهندسی عامل‌های هوشمند

هر فصل این کتاب پاسخ‌هایی ارائه داد؛ اما صادقانه‌ترین بخش یک کتاب مرجع، فهرست آن چیزی است که هنوز نمی‌دانیم. این فصل هشت مسئله‌ی باز را معرفی می‌کند. برای هر مسئله چهار چیز را مشخص کرده‌ایم: **وضعیت دانش** (با برچسب ع ۱ تا ع ۵)، **دلیل دشواری**، **پرسش پژوهشی مشخص** و **معیار موفقیت**. بخش‌هایی از این فصل ناگزیر پیش‌بینی‌اند و به‌صراحت با برچسب (ع ۵) آمده‌اند؛ نباید آن‌ها را به‌عنوان یافته‌ی اثبات‌شده خواند.

اهداف فصل. (۱) مسائل باز مهندسی عامل‌ها را با وضعیت دانششان فهرست کنیم؛ (۲) برای هر مسئله پرسش پژوهشی و معیار موفقیت تعریف کنیم؛ (۳) پرسش‌های اولویت‌دار را برای پژوهشگران و مهندسان مشخص کنیم؛ (۴) چشم‌انداز بلوغ AgentOps را جمع‌بندی کنیم.

۱۵.۱ استانداردسازی مفاهیم و داده‌های عملیاتی

وضعیت دانش. تعریف AgentOps میان دست‌کم دو سنت پژوهشی متفاوت است: چرخه‌ی عملیات (پایش تا رفع؛ Wang et al., ۲۰۲۵) و مشاهده‌پذیری مصنوعات (Dong et al., ۲۰۲۴). در حوزه‌ی داده، قراردادهای معنایی OpenTelemetry برای هوش مصنوعی مولد در مخزنی جداگانه در حال تدوین‌اند و وضعیت پایداری

آن‌ها را در این بررسی تأیید نکردیم (OpenTelemetry, n.d). مشخصات MCP نیز نسخه‌بندی تاریخ‌دار دارد و افزونه‌های اختیاری در حال تکامل‌اند (Model Context Protocol, ۲۰۲۶). **دلیل دشواری:** حوزه جوان است، ابزارها مدام تغییر می‌کنند و ذی‌نفعان (پژوهشگران، فروشندگان، سازمان‌ها) منافع متفاوت دارند. پرسش پژوهشی: کوچک‌ترین طرح‌واره‌ی رویداد مشترک که برای بازپخش، ارزیابی و حسابرسی کافی باشد کدام است و چگونه با قراردادهای موجود نگاشت می‌شود؟ معیار موفقیت: دو ابزار مستقل بتوانند ردگیری‌های یکدیگر را بدون اتلاف معنایی بخوانند و بازپخش کنند.

۱۵.۲ ارزیابی رفتارهای نوظهور و دشواری پیش‌بینی

وضعیت دانش. وانگ و همکاران «آنومالی رفتار نوظهور» را یکی از انواع آنومالی بین‌عاملی می‌شمارند (Wang et al., ۲۰۲۵)، اما در جدول خلاصه‌ی روش‌های تشخیص و مهار آنان، برای چند نوع آنومالی از جمله رفتار نوظهور، خاتمه، مشخصات وظیفه و محیط، روش مشخصی ثبت نشده است (Wang et al., ۲۰۲۵). این خودش گویای شکاف است. تحلیل MAST نیز تأکید می‌کند فهرست آن جامع نیست (Cemri et al., ۲۰۲۵). **دلیل دشواری:** رفتار نوظهور از برهم‌کنش اجزایی پدید می‌آید که هر یک به‌تنهایی معقول‌اند؛ پس آزمون مؤلفه‌ای آن را نمی‌گیرد، و فضای حالت گروه بزرگ است. پرسش پژوهشی: کدام سنجه‌های سطح گروه (مثلاً الگوهای ارتباطی، رقابت بر منابع) پیش‌نگر رفتار نوظهور زیان‌بارند؟ معیار موفقیت: سنجه‌ای که روی ردگیری‌های شبیه‌سازی شده و واقعی، هشدار زودتر از وقوع شکست گروهی بدهد با نرخ هشدار کاذب معلوم.

۱۵.۳ یادگیری مستمر بدون تخریب قابلیت‌های پیشین

وضعیت دانش. دانگ و همکاران «تکامل مستمر» را از ویژگی‌های عامل می‌شمارند که هماهنگی با کیفیت و ایمنی مورد نظر را در طول عمر دشوار می‌کند (Dong et al., ۲۰۲۴). این کتاب بر عامل‌های با رفتار «تثبیت‌شده در هر نسخه» تمرکز کرد و یادگیری برخط عامل را عملاً کنار گذاشت: هر تغییر، نسخه‌ی جدید با دروازه‌ی ارزیابی است. **دلیل دشواری:** اگر عامل در حین اجرا از بازخورد یاد بگیرد (حافظه‌ی در حال تغییر، دستورالعمل خودتنظیم‌شونده)، نسخه‌ی عامل دیگر یک شیء ثابت نیست و دروازه‌ی انتشار نمی‌تواند رفتارش را تضمین کند. پرسش پژوهشی: چگونه می‌توان به یک عامل اجازه‌ی یادگیری داد در حالی که یک ناوردا یا مجموعه‌ی قیود رفتاری (قرارداد) با تضمین آماری حفظ شود؟ **معیار موفقیت:** روشی که قیود قرارداد را در طول یادگیری با احتمال معین نگه دارد و هزینه‌ی راستی‌آزمایی مستمر مشخص باشد (۵ع).

۱۵.۴ حاکمیت عامل‌های با اختیار گسترده

وضعیت دانش. OWASP «اختیار بیش‌ازحد» را با سه علت ریشه‌ای توصیف می‌کند و تأیید انسانی را برای اقدام‌های پراثر توصیه می‌کند (OWASP GenAI Security, ۲۰۲۵ Project)؛ چارچوب NIST ساختار حاکمیت را می‌دهد (Tabassi, ۲۰۲۳). اما شواهد تجربی درباره‌ی اثر این کنترل‌ها بر موفقیت وظیفه و بر امنیت در محیط واقعی محدود است؛ و AgentDojo نشان داد که حمله‌های موجود برخی ویژگی‌های امنیتی را می‌شکنند ولی نه همه را، و مدل‌های پیشرفته حتی بدون حمله در بسیاری وظایف شکست می‌خورند (Debenedetti et al., ۲۰۲۴). **دلیل دشواری:** تأیید

انسانی مقیاس‌پذیر نیست و «خستگی تأیید» ایمنی را می‌کاهد؛ و تعیین حد مناسب اختیار برای هر وظیفه محتاج ارزیابی ریسک پویاست. پرسش پژوهشی: سیاستی که آستانه‌ی ارجاع به انسان را به صورت تطبیقی بر پایه‌ی ریسک و عدم قطعیت تعیین کند چگونه است و چه اندازه‌ی مجموع خطر را می‌کاهد؟ معیار موفقیت: کاهش مستند نرخ اقدام زیان‌بار به ازای هر ساعت تأیید انسانی نسبت به آستانه‌ی ثابت.

۱۵.۵ عملیات عامل‌های توزیع شده و خودتکثیرشونده

وضعیت دانش (ع ۵: پیش‌بینی). سامانه‌هایی که عامل جدید خلق می‌کنند یا ابزار جدید می‌سازند، در ادبیات این کتاب بررسی نشده‌اند و هیچ شاهد تجربی مستقلی در منابع تأییدشده‌ی ما درباره‌ی عملیات آن‌ها نداریم. تنها قاعده‌ی ساختاری که این کتاب ارائه کرد این است که اختیار از والد به فرزند افزایش نمی‌یابد (فصل ۱۳).
دلیل دشواری: هویت، مسئولیت و بودجه‌ی عامل‌های ایجادشده‌ی پویا باید در زمان اجرا تعریف شوند؛ حسابرسی گراف متغیر عامل‌ها دشوار است. پرسش پژوهشی: کدام مجموعه‌ی کمینه‌ی قواعد (سقف تعداد نسل، بودجه‌ی جمعی، هویت ارثی) از رشد کنترل‌نشده جلوگیری می‌کند؟ معیار موفقیت: اثبات یا ارزیابی تجربی اینکه تحت قواعد، بودجه و اختیار کل گروه هیچ‌گاه از سقف والد ریشه فراتر نمی‌رود.

۱۵.۶ تعامل عامل‌ها با سامانه‌های فیزیکی و دنیای واقعی

وضعیت دانش (ع ۵: پیش‌بینی). تعریف عامل در ادبیات کلاسیک، محیط را شامل دنیای فیزیکی هم می‌داند (Wooldridge & Jennings, ۱۹۹۵)، اما تمرکز این کتاب بر عامل‌های نرم‌افزاری با اثر بیرونی دیجیتال بود. دلیل دشواری: اقدام فیزیکی

اغلب برگشت‌ناپذیر است؛ جبران به شیوه‌ی ساگا ممکن نیست؛ تأخیر و ایمنی بلادرنگ اهمیت دارد؛ و آزمون در محیط واقعی خطرناک است. پرسش پژوهشی: چگونه می‌توان ارزیابی، سیاست و توقف اضطراری را برای اقدام‌هایی طراحی کرد که جبران‌ناپذیرند؟ معیار موفقیت: چارچوبی با قیود ایمنی قابل‌راستی‌آزمایی در شبیه‌ساز و پایش تولید، که ریسک اقدام فیزیکی را به حد مجاز کاهش دهد. این مسئله محتاج همکاری با رشته‌های ایمنی صنعتی است و فراتر از دامنه‌ی این کتاب است.

۱۵.۷ سنجش اعتمادپذیری و تضمین‌های قابل اثبات

وضعیت دانش. وانگ و همکاران آنومالی اعتماد را جزو آنومالی‌های بین‌عاملی می‌شمارند و در جدول خود برای آن یک روش مبتنی بر نقشه‌ی توجه فهرست می‌کنند (Wang et al., ۲۰۲۵). تضمین‌های صوری درباره‌ی رفتار مدل‌های زبانی بزرگ در منابع بررسی‌شده‌ی ما نیامده‌اند. بنچمارک‌ها و آزمون‌های آماری (فصل ۸) شواهد احتمالی می‌دهند، نه اثبات. دلیل دشواری: رفتار مدل تابع پیچیده‌ای از متن است و نمی‌توان آن را با روش‌های صوری کلاسیک مشخص و راستی‌آزمایی کرد؛ و حتی تعریف «ویژگی مطلوب» برای زبان طبیعی مبهم است. پرسش پژوهشی: برای کدام دسته از ویژگی‌های ایمنی (مثلاً «ابزار X هرگز بدون تأیید فراخوانی نمی‌شود») می‌توان تضمین قطعی ارائه کرد، با قرار دادن آن‌ها در سطح سیاست قطعی (نه مدل)؟ معیار موفقیت: فهرستی از ویژگی‌های ایمنی که تحت یک مدل تهدید مشخص و بدون اتکا به رفتار مدل اثبات‌پذیرند؛ این همان اصل معماری ماست که کنترل پیش از اجرا قطعی باشد (ع ۴).

۱۵.۸ طراحی زیرساخت‌های خودترمیم‌شونده

وضعیت دانش. پژوهش اخیر مسیر «عملیات پیش‌دستانه» را پیشنهاد می‌کند: دو جهت آینده‌ی عملیات عامل‌ها، AgentOps به‌هنگام و پیش‌دستانه (عبور از تحلیل پس از واقعه به شناسایی و مداخله پیش از انباشت حالت‌های نادرست؛ از جمله با نقاط ذخیره و اصلاح در حین اجرا) و AgentOps دقیق و مبتنی بر شواهد (استفاده از سیگنال‌های غنی‌تر و معنایی، چون سنج‌ها و لاگ‌ها و ردگیری‌های متعارف برای آشکار کردن شکست‌های معنایی استدلال و تصمیم‌گیری و تعامل کافی نیستند) است (Wang et al., ۲۰۲۶). همین مرور یادآور می‌شود که رفع در عامل‌ها فرایندی تکرارشونده است و می‌تواند پیامدهای مرتبه‌ی دوم بسازد (Wang et al., ۲۰۲۵). دلیل دشواری: خودترمیمی یعنی عامل (یا سامانه) خودش رفع کند؛ اما اگر رفع نادرست باشد، تشدید مشکل رخ می‌دهد و «چه کسی ناظر ناظر است؟». پرسش پژوهشی: کدام مداخله‌های ترمیمی را می‌توان خودکار انجام داد (مثلاً تلاش مجدد، سخت‌تر کردن سیاست) و کدام‌ها باید با تأیید انسانی بمانند؟ معیار موفقیت: کاهش زمان بازیابی بدون افزایش رخدادهای ثانویه، در یک ارزیابی کنترل‌شده.

۱۵.۹ پرسش‌های پژوهشی اولویت‌دار

از هشت مسئله‌ی بالا و فصل ۱۴، فهرست زیر را برای پژوهشگران و مهندسان پیشنهاد می‌کنیم (۵ع):

۱. اعتبارسنجی تجربی معماری AO-RA یا نسخه‌ی ساده‌شده‌ی آن بر عامل‌های واقعی در تولید (فرضیه‌های H1، H3، H4).

۲. گسترش pass^k و سنجه‌های پایداری برای اجراهای هم‌بسته و سناریوهای ناهمگن.
۳. نظریه‌ی آماری ارزیابی عامل‌ها: اندازه‌ی نمونه، دروازه‌ی چندسنجه‌ای و کنترل هشدار کاذب.
۴. سنجه‌های سطح گروه برای رفتار نوظهور.
۵. روش‌های کاهش هزینه‌ی ردگیری با حفظ توان بازپخش و تشخیص.
۶. تعیین هزینه‌ی واقعی شکست در حوزه‌های مختلف و ساخت داده‌ی باز برای TCPS.
۷. مدل‌های سیاست‌نویسی ساخت‌یافته و آزمون‌پذیر (فراتر از شرط زیررشته‌ای).
۸. ارزیابی تأیید انسانی: خستگی، آستانه‌ی بهینه و طراحی رابط.
۹. بنچمارک استاندارد برای رخداد و بازیابی (نه فقط وظیفه‌ی موفق).
۱۰. اعتبارسنجی مدل بلوغ با داده‌ی چندسازمانی (H6).
۱۱. روش‌های بازپخش و بازتولید رفتار مدل (نه فقط بقیه‌ی سامانه).
۱۲. چارچوب‌های انطباق: نگاشت دقیق AO-RA به الزامات رسمی و حقوقی در حوزه‌های مختلف.

۱۵.۱۰ جمع‌بندی و چشم‌انداز بلوغ AgentOps

AgentOps هنوز یک حوزه‌ی جوان است: دو سنت پژوهشی با تأکیدهای متفاوت، ابزارهایی که مدام تغییر می‌کنند و شواهد تجربی محدود. اما مسیر روشن است. از یک سو، **عمل مهندسی** باید از «اجرای مدل» به «مهندسی رفتار» ارتقا یابد: قرارداد، ردگیری، ارزیابی آماری، سیاست پیش از اجرا و بودجه. از سوی دیگر، **پژوهش** باید این ادعاها را با آزمایش و مطالعه‌ی موردی بیازماید و نتایج منفی را هم گزارش کند.

اگر بخواهیم چشم‌اندازی بگوییم (۵۶)، حوزه به‌سوی عملیاتی پیش‌دستانه و مبتنی بر شواهد حرکت می‌کند (Wang et al., ۲۰۲۶): ردگیری معنایی، ارزیابی پیوسته، مداخله پیش از انباشت خطا، و حاکمیت متناسب با ریسک. اما سطح بلوغ حوزه را شواهد تعیین می‌کند، نه تمایل ما.

در یک جمله: اعتماد به عامل، مانند هر سامانه‌ی مهندسی، از شواهد می‌آید؛ و کار AgentOps ساختن همان شواهد است.

جمع‌بندی فصل

هشت مسئله‌ی باز معرفی شد: استانداردسازی، رفتار نوظهور، یادگیری مستمر، حاکمیت عامل‌های پراختیار، عامل‌های خودتکثیرشونده، تعامل با دنیای فیزیکی، تضمین‌های اثبات‌پذیر و زیرساخت‌های خودترمیم‌شونده. برای هر یک وضعیت دانش، دلیل دشواری، پرسش و معیار موفقیت تعیین شد، و دوازده پرسش اولویت‌دار فهرست شد. چشم‌انداز حوزه عملیاتی پیش‌دستانه و مبتنی بر شواهد است.

پرسش‌های مروری و تمرین‌های تحلیلی

۱. دو سنت تعریف AgentOps را بنویسید. چه چیزی استانداردسازی را دشوار می‌کند؟
۲. چرا نبودن روش تشخیص برای رفتار نوظهور در جدول وانگ و همکاران (Wang et al., ۲۰۲۵) مهم است؟
۳. «یادگیری مستمر» چه مشکلی برای دروازه‌ی انتشار ایجاد می‌کند؟ راهی پیشنهاد دهید.
۴. چرا تضمین صوری درباره‌ی رفتار مدل دشوار ولی درباره‌ی سیاست قطعی ممکن است؟

۵. از میان دوازده پرسش اولویت‌دار، یکی را انتخاب و طرح پژوهشی کوتاه (سنجه، طرح، داده) برایش بنویسید.
۶. (تحلیلی) کدام یک از هشت مسئله‌ی باز از دید شما مهم‌ترین است؟ استدلال کنید.

منابع

- Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>
- Debenedetti, E., Zhang, J., Balunović, M., Beurer-Kellner, L., Fischer, M., & Tramèr, F. (2024). AgentDojo: A dynamic environment to evaluate prompt injection attacks and defenses for LLM agents (arXiv:2406.13352). arXiv. <https://doi.org/10.48550/arXiv.2406.13352>
- Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>
- Model Context Protocol. (2026). Model Context Protocol specification (version 2026-07-28). <https://modelcontextprotocol.io/specification/latest> (accessed 2026-10-21)
- OpenTelemetry. (n.d.). Semantic conventions for generative AI. GitHub. <https://github.com/open-telemetry/semantic-conventions-genai> (accessed 2026-10-21; stability status not verified)
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Tabassi, E. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-1>
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>
- Wang, Z., Pei, C., Liu, Y., Li, J., Huo, Y., Zhou, Q., Si, H., Cui, H., Liu, Z., Xie, G., Sun, F., Pei, D., & Lo, D. (2026). Agent system operations: Categorization, challenges, and future directions (arXiv:2606.01581). arXiv. <https://doi.org/10.48550/arXiv.2606.01581>

Wooldridge, M., & Jennings, N. R. (1995). Intelligent agents: Theory and practice. *The Knowledge Engineering Review*, 10(2), 115-152. <https://doi.org/10.1017/S0269888900008122>

نتیجه‌گیری کل کتاب

این کتاب با یک تمایز آغاز شد: اجرای بدون خطا با اجرای درست یکی نیست. هرچه در ده فصل بعدی آمد، تلاشی بود برای ساختن ابزار مهندسی در فاصله‌ی میان این دو. اگر بخواهیم حاصل کتاب را در چند جمله بگوییم، این‌هاست.

نخست، واحد مدیریت عوض شده است. در DevOps واحد مدیریت تغییر کد بود و در MLOps سه‌گانه‌ی کد، داده و مدل. در عامل‌های هوشمند، واحد، رفتار است: دنباله‌ی تصمیم‌ها و اقدام‌هایی که برای تحقق هدفی تحت قیود انجام می‌شود. رفتار را باید تعریف کرد (قرارداد وظیفه و رفتاری)، مشاهده کرد (ردگیری ساخت‌یافته و بازپخش)، سنجید (ارزیابی آماری با اجراهای تکراری)، محدود کرد (سیاست پیش از اجرا، حداقل اختیار، بودجه) و در صورت شکست بازیابی کرد (idempotency، جبران، توقف ایمن).

دوم، اعتماد از شواهد می‌آید. مدل نمی‌تواند تضمین کند که فریب نمی‌خورد، توهم ندارد یا تصمیم درست می‌گیرد؛ تحلیل ما نشان داد که خوداصلاحی بدون سیگنال بیرونی قابل اتکا نیست و تزریق دستورالعمل ریشه‌ای ساختاری دارد. بنابراین کنترل‌های اساسی باید قطعی و پیش از اجرا باشند، و شواهد باید در صفحه‌ای فقط افزودنی ثبت شود تا پاسخ‌گویی ممکن باشد.

سوم، ارزیابی یک مسئله‌ی آماری است. موفقیت یک‌باره نمی‌تواند رفتار تکراری را نشان دهد؛ برای تصمیم باید اندازه‌ی نمونه، بازه‌ی اطمینان و الزام پایداری (pass^k) را در نظر گرفت. اما این کتاب نکته‌ای را هم به‌طور تجربی (در شبیه‌سازی)

آموخت: $pass^k$ توان آماری بیشتری از $pass^1$ ندارد؛ الزام متفاوتی می‌گذارد. این‌ها دو چیز متفاوت‌اند و خلط آن‌ها به تصمیم بد می‌انجامد.

چهارم، هزینه یک قید مهندسی است. هزینه‌ی هر وظیفه‌ی موفق و هزینه‌ی رفع شکست، انتخاب مدل و سطح کنترل را تعیین می‌کنند؛ و بودجه‌ی گام و توکن و مهلت، قید ساختاری است نه گزارش پس از واقعه.

پنجم، عمل مهندسی بدون صداقت علمی بی‌ارزش است. معماری AO-RA، قرارداد رفتاری، طبقه‌بندی AgentOps-FT و مدل بلوغ پیشنهاد نگارنده‌اند و هنوز بر عامل‌های واقعی در تولید اعتبارسنجی نشده‌اند. دو بار نتیجه‌ی شبیه‌سازی با انتظار ما نخواند و هر دو را گزارش و فرضیه‌ها را اصلاح کردیم. این رویه باید ادامه یابد.

برای عمل، فهرست کوتاه زیر را پیشنهاد می‌کنیم: پیش از هر عامل پرائر، سطح خودمختاری را ثبت کنید؛ قرارداد رفتاری و سناریوهای مرجع بنویسید؛ ردگیری کامل و پاک‌سازی شده بسازید؛ سیاست پیش‌فرض‌رد با تأیید انسانی برای اقدام‌های پرائر بگذارید؛ بودجه را قید کنید؛ اجراهای تکراری را در دروازه‌ی انتشار بیاورید؛ کلید توقف را بیازمایید؛ و هر رخداد را به یک سناریوی جدید تبدیل کنید. برای پژوهش، فصل ۱۵ دوازده پرسش اولویت‌دار را فهرست کرده است.

مدل داده‌ی پیشنهادی برای ثبت ردگیری

اجرای عامل

این پیوست طرح‌واره‌ی `TraceEvent` پیاده‌سازی مرجع (فصل ۷) را به صورت JSON Schema (پیش‌نویس ۲۰۲۰-۱۲) می‌آورد. طرح‌واره با ۴۶ رویداد واقعی تولیدشده توسط پیاده‌سازی مرجع (اجرای موفق، رد سیاست، تأیید، توقف با بودجه، محافظ تکرار) اعتبارسنجی شد و یک رویداد عمداً نادرست را رد کرد. حالت‌های `stop`، `guard` و `resume` در فهرست انواع هستند ولی در این ۴۶ رویداد همگی آن‌ها نبودند. طرح‌واره پیشنهاد نگارنده است و استاندارد نیست؛ اگر قصد صادرات به `OpenTelemetry` دارید، نسخه‌ی جاری قراردادهای معنایی آن را بررسی کنید (فصل ۷).

```
{
  "$schema": "https://json-schema.org/draft/2020-12/schema",
  "title": "A0-RA TraceEvent",
  "type": "object",
  "required": ["trace_id", "span_id", "parent_id", "kind", "ts", "data"],
  "additionalProperties": false,
  "properties": {
    "trace_id": {"type": "string", "minLength": 1},
    "span_id": {"type": "integer", "minimum": 1},
    "parent_id": {"type": ["integer", "null"]},
    "kind": {"enum": ["task.start", "decision", "policy", "approval", "tool.result", "budget", "guard", "stop", "resume", "task.end"]},
    "ts": {"type": "number"},
    "data": {"type": "object"}
  },
  "allOf": [
    {"if": {"properties": {"kind": {"const": "task.start"}}},
    {"then": {"properties": {"data": {"required": ["task_id", "goal",
```

```

"risk"]}}}},
{"if": {"properties": {"kind": {"const": "decision"}}},
  "then": {"properties": {"data": {"required": ["step", "proposal"],
    "properties": {"proposal": {"enum": ["tool", "final"]}}}}}},
{"if": {"properties": {"kind": {"const": "policy"}}},
  "then": {"properties": {"data": {"required": ["decision", "rule",
    "tool"], "properties": {"decision": {"enum": ["allow", "deny",
    "require_approval"]}}}}}},
{"if": {"properties": {"kind": {"const": "tool.result"}}},
  "then": {"properties": {"data": {"required": ["tool", "status"],
    "properties": {"status": {"enum": ["ok", "error",
    "transient_error"]}}}}}},
{"if": {"properties": {"kind": {"const": "task.end"}}},
  "then": {"properties": {"data": {"required": ["status", "steps",
    "tokens", "usd"]}}}}
]
}

```

یک رویداد نمونه (از خروجی واقعی `ch07_trace.py`: فیلد حساس با پاک‌ساز

نقاب‌دار شده است):

```

{"trace_id": "trace-7", "span_id": 4, "parent_id": 1, "kind":
"tool.result", "ts": "<ts>",
  "data": {"tool": "lookup_order", "args": {"order_id": "7214"}, "status":
"ok", "replayed": false,
    "output": {"order_id": "7214", "customer_email": "***",
"days_late": 5, "total": 40}}}

```

فیلدهای پیشنهادی گسترش (برای رویدادهای `llm.call` و `memory`*) در جدول

۷-۲ آمده است. هر رویداد جدید باید در طرح‌واره نسخه‌دار شود و آزمون خودکار

اعتبارسنجی داشته باشد.

الگوی طبقه‌بندی شکست و رخداد

الف) طبقه‌بندی AgentOps-FT (خلاصه). رده‌ها و شرح تفصیلی در فصل ۹ (جدول ۹-۲) آمده‌اند. در ثبت هر شکست، دو برچسب بنویسید: رده‌ی شکست (F01 تا F16) و بُعد علی‌غالب (سامانه‌محور، مدل‌محور، ارکستراسیون‌محور). اگر چند رده هم‌زمان صدق می‌کند، همه را ثبت کنید.

جدول B-۱. قالب ثبت یک شکست یا رخداد (منبع: نگارنده)

فیلد	شرح
شناسه و تاریخ	شناسه‌ی رخداد، زمان وقوع و تشخیص
سطح	بحرانی، جدی یا جزئی (بخش ۱۳.۷)
عامل و نسخه	شناسه‌ی عامل و مانیفست انتشار
وظیفه و ردگیری	شناسه‌ی وظیفه و ردگیری
شرح مشاهده	چه چیزی دیده شد، توسط چه کسی یا چه سازوکاری
اثر بیرونی	چه اقدامی انجام شد، چه کسی/چه چیزی متأثر شد
رده‌ی شکست و بُعد علی	F01 تا F16؛ سامانه/مدل/ارکستراسیون
گام آنومال	گامی که اگر عادی بود، وظیفه موفق می‌شد
مهار	چه اهرمی به کار رفت (توقف، سیاست، بازگشت)
جبران	اقدام‌های جبرانی و وضعیت نهایی
ریشه و درس‌ها	علت‌ها؛ چه چیزی تغییر می‌کند
سناریوی جدید	شناسه‌ی سناریوی افزوده‌شده به قرارداد رفتاری
اقدام اصلاحی	مسئول، مهلت، معیار تأیید رفع

ماتریس ارزیابی بلوغ AgentOps

برای هر پرسش، سطح را از ۱ تا ۵ بنویسید (راهنمای سطوح در جدول ۱۳-۲). نمره‌ی کل میانگین ۱۴ پرسش است. **هشدار:** این ماتریس پیشنهاد نگارنده است، اعتبارسنجی نشده و فقط برای گفت‌وگو و برنامه‌ریزی درون سازمان به کار می‌رود، نه مقایسه‌ی بین سازمان‌ها.

جدول C-۱. پرسش‌های ارزیابی بلوغ (منبع: نگارنده)

#	پرسش	شاهد مورد انتظار برای سطح ۳ یا بالاتر
۱	آیا هر عامل سطح خودمختاری ثبت شده دارد؟	سند یا فیلد در قرارداد وظیفه
۲	آیا قرارداد وظیفه و رفتاری وجود دارد؟	فایل نسخه‌دار با سناریوها
۳	آیا هر تصمیم و اقدام ردگیری می‌شود؟	رویدادهای ساخت‌یافته در تولید
۴	آیا بازپخش اجرا ممکن است؟	نمونه‌ی بازپخش موفق
۵	آیا ارزیابی با اجرای تکراری و آستانه انجام می‌شود؟	گزارش ارزیابی هر نسخه
۶	آیا آزمون امنیتی (تزریق، اختیار) بخشی از ارزیابی است؟	مجموعه‌ی آزمون خصمانه
۷	آیا سیاست پیش از اجرا با پیش‌فرض رد وجود دارد؟	کد سیاست با آزمون
۸	آیا تأیید انسانی شرطی برای اقدام‌های پراثر وجود دارد؟	صف و ثبت تأیید
۹	آیا اسرار از زمینه‌ی مدل جدا هستند؟	بازبینی طراحی
۱۰	آیا بودجه‌ی گام، توکن و هزینه اعمال می‌شود؟	ثبت رویداد budget
۱۱	آیا جبران یا بازگشت برای اقدام‌های نوشتنی طراحی شده است؟	آزمون جبران
۱۲	آیا انتشار تدریجی و بازگشت خودکار دارید؟	خط لوله و مانیفست
۱۳	آیا مالک هر عامل و فرایند رخداد مشخص است؟	ماتریس مسئولیت
۱۴	آیا هر رخداد به سناریوی جدید تبدیل می‌شود؟	سابقه‌ی رخدادها

چک‌لیست آمادگی استقرار در محیط تولید

پیش از انتشار عامل پراثر، موارد زیر را واریسی کنید. پاسخ «نه» به موارد علامت‌دار با * برای عامل‌های سطح ۳ و ۴ خودمختاری مانع انتشار است.

قرارداد و ارزیابی

- [] سطح خودمختاری و رد ریسک ثبت شده است.
- [] قرارداد وظیفه و قرارداد رفتاری با سناریوهای مرجع نسخه‌دار موجود است.
- [] ارزیابی با اجرای تکراری، بازهی اطمینان و آستانه‌ی $pass^1$ و $pass^k$ انجام شده است.
- [] هزینه‌ی هر وظیفه‌ی موفق (و در صورت لزوم با خسارت شکست) در محدوده‌ی تعیین شده است.
- [] آزمون امنیتی (تزریق مستقیم و غیرمستقیم، اختیار بیش‌ازحد) انجام شده است. *

مشاهده‌پذیری

- [] ردگیری ساخت‌یافته‌ی همه‌ی تصمیم‌ها و اقدام‌ها فعال است.
- [] داده‌ی حساس پیش از ثبت پاک‌سازی می‌شود و سیاست نگهداری تعیین شده است.
- [] بازپخش اجرا آزموده شده است.
- [] شاخص‌های رفتاری و هشدارها تعریف شده‌اند.

امنیت و کنترل

- [] سیاست پیش از اجرا با پیش‌فرض رد وجود دارد و آزموده شده است. *

- [] اختیار ابزارها حداقلی است و مجوز پایین‌دست اعمال می‌شود.
- [] اسرار هرگز وارد زمینه‌ی مدل نمی‌شوند.
- [] تأیید انسانی شرطی و مبتنی بر شواهد برای اقدام‌های پراثر وجود دارد. *
- [] اجرای کد (در صورت وجود) در جعبه‌ایزوله است.
- [] دفتر حسابرسی (در سطوح بالا تغییرناپذیر) موجود است.

قابلیت اطمینان و استقرار

- [] بودجه‌ی گام، توکن، هزینه و مهلت اعمال می‌شود؛ محافظ تکرار فعال است.
- [] کلید توقف اضطراری آزموده شده است. *
- [] برای اقدام‌های نوشتنی، idempotency و جبران طراحی و آزموده شده است.
- [] اجرای قابل‌بازیابی (نقطه‌ی ذخیره) در صورت نیاز آزموده شده است.
- [] انتشار تدریجی (سایه‌ای، قناری) و بازگشت به نسخه‌ی قبلی آزموده شده‌اند.
- [] نسخه‌ی مدل، دستورالعمل، ابزارها و سیاست در مانیفست سنجاق شده‌اند.

سازمان

- [] مالک عامل، مالک گروه (در سامانه‌ی چندعاملی) و فرایند رخداد مشخص است.
- [] مسیر بازگشت و ارتباط با کاربران و ذی‌نفعان تعریف شده است.
- [] الزامات حقوقی و حریم خصوصی با مشاور مربوطه بررسی شده است.

نمونه‌های فنی، طرح‌های آزمایشی و قراردادهای رفتاری

الف) فهرست کد و مثال‌ها. همه‌ی فایل‌ها در پوشه‌ی `code`: اجرای آزمون‌ها:
`python3 -m unittest tests.test_aorch` (۳۴ آزمون، همگی سبز در زمان
نگارش). مثال‌ها: `python3 examples/<name>.py`.

جدول E-۱. فهرست مثال‌های اجرایی کتاب (منبع: نگارنده)

فایل	فصل	موضوع
examples/ ch02_loop.py	۲	حلقه‌ی کمینه‌ی عامل با قرارداد، سیاست و بودجه
examples/ ch06_08_eval.py	۶ و ۸	قرارداد رفتاری و ارزیابی با اجراهای تکراری (شبیه‌سازی)
examples/ ch07_trace.py	۷	ردگیری JSONL، پاک‌سازی فیلد، بازپخش و تشخیص واگرایی
examples/ ch09_recovery.py	۹	محافظ تکرار، کلید توقف و جبران ساگا
examples/ ch10_audit.py	۱۰	دفتر حسابرسی زنجیره‌ی درهم‌ریزی و تشخیص دست‌کاری
examples/ ch11_resume.py	۱۱	نقطه‌ی ذخیره و ازسرگیری بدون تکرار اثر
examples/ ch12_cpst.py	۱۲	CPST و TCPS با مدل‌ها و قیمت‌های فرضی
examples/ ch13_delegate.py	۱۳	واگذاری که فقط محدود می‌کند

فایل	فصل	موضوع
examples/ ch14_pilot.py	۱۴	جاروب بودجه‌ی گام (شبیه‌سازی)
examples/ ch14_h2_pilot.py	۱۴	مقایسه‌ی دو دروازه‌ی انتشار با هشدار کاذب برابر (شبیه‌سازی)

ب) ماژول‌های بسته‌ی **aorch. contract** (قرارداد وظیفه و بودجه)، **events** (رویداد، ردگیر، پاک‌ساز)، **policy** (موتور سیاست)، **tools** (دروازه‌ی ابزار، idempotency، دفتر جبران)، **agent** (حلقه‌ی عامل با توقف، محافظ تکرار، نقطه‌ی ذخیره)، **cost** (دفتر بودجه و CPST)، **evalkit** (pass@k، pass^k)، بازه‌ی ویلسون)، **behavior** (قرارداد رفتاری و مهار ارزیابی)، **replay** (بازپخش اجرایی)، **audit** (حسابرسی زنجیره‌ای) و **delegation** (واگذاری).

پ) الگوی طرح آزمایش **H3** (سیاست حداقل اختیار در برابر تزریق غیرمستقیم). پرسش: آیا سیاست پیش از اجرا با تأیید انسانی شرطی، نرخ موفقیت حمله‌ی تزریق غیرمستقیم را بدون افت معنادار موفقیت وظیفه کاهش می‌دهد؟ شرایط: (الف) بدون سیاست؛ (ب) فقط فهرست مجاز ابزار؛ (ج) سیاست کامل با تأیید. اشیا: وظایف و موارد آزمون امنیتی (Debenedetti et al., ۲۰۲۴) **AgentDojo** یا زیرمجموعه‌ی معرفی شده. سنجه‌ها: نرخ موفقیت حمله، نرخ موفقیت وظیفه بدون حمله، نرخ ارجاع به انسان. اجرا: هر شرایط روی همان وظایف، چند اجرای تکراری با بذر ثابت؛ مدل‌ها و نسخه‌ها سنجاق. تحلیل: بازه‌ی اطمینان نسبت‌ها، آزمون مقایسه‌ی جفتی، گزارش اندازه‌ی اثر. تهدیدها: وابستگی اجراها، آلودگی، تفاوت محیط با

واقعیت.

ت) الگوی طرح آزمایش H1 (ردگیری و تشخیص علت). متغیر مستقل: نوع شواهد (ردگیری ساخت‌یافته با بازپخش در برابر لاگ متنی). وابسته: زمان تا نقطه‌ی علی و درستی تشخیص. آزمودنی‌ها: مهندسان با تجربه‌ی مشابه؛ طرح درون‌آزمودنی با موازنه‌ی ترتیب. اشیا: خطاهای کاشته‌شده‌ی نماینده‌ی رده‌های F01 تا F16 در یک عامل نمونه. تحلیل: آزمون مناسب نمونه‌های جفتی با تعیین اندازه‌ی اثر و توان از پیش. اخلاق: رضایت آگاهانه و ناشناس‌سازی داده‌ها.

روش مرور منابع و معیار انتخاب پژوهش‌ها

الف) آنچه در این کتاب انجام شد. جست‌وجو از طریق arXiv، صفحه‌های رسمی استانداردها و سازمان‌ها (OWASP، NIST، مشخصات MCP) و وب عمومی؛ برای هر منبع کلیدی، فراداده (عنوان، نویسندگان، تاریخ، شناسه) از صفحه‌ی رسمی استخراج شد، و برای منابع اصلی AgentOps (چهار مقاله) متن کامل دانلود و خوانده شد. فقط منابعی ارجاع شده‌اند که فراداده‌ی آن‌ها راستی‌آزمایی شد. این یک مرور نظام‌مند کامل نیست.

ب) محدودیت‌ها. پایگاه‌های ACM، IEEE Xplore، Springer و ScienceDirect به‌صورت ساختاریافته پیمایش نشدند؛ ارزیابی کیفیت منابع صورتی بود؛ ISO/IEC ۲۰۰۱ و مجموعه‌ی قراردادهای معنایی OpenTelemetry برای هوش مصنوعی مولد فقط تأیید جزئی دارند؛ از فهرست OWASP فقط ورودی‌های LLM01، LLM02، LLM06 و LLM10 با جزئیات خوانده شد (سایر موارد فقط در حد عنوان)؛ و منابع کتاب‌محور (مثلاً هامبل و فارلی، فورسگرن و همکاران، کتاب SRE) از طریق فراداده‌ی ناشر و فصل‌های برخط بررسی شدند، نه تمام متن.

ج) پروتکل پیشنهادی برای مرور نظام‌مند کامل (برای کار بعدی).

۱. پرسش‌های پژوهشی: (RQ1) کدام تعریف‌ها و چارچوب‌ها برای عملیات عامل‌های مبتنی بر مدل زبانی وجود دارد؟ (RQ2) کدام روش‌های ارزیابی و پایش گزارش شده‌اند و با چه شواهدی؟ (RQ3) کدام کنترل‌های امنیتی و حاکمیتی مؤثر گزارش شده‌اند؟

۲. راهبرد جست‌وجو: رشته‌های برگرفته از دانگ و همکاران (Dong et al., ۲۰۲۴) به‌اضافه‌ی «agent AND (operations OR observability OR evaluation OR reliability OR security)» و واژگان هم‌معنا؛ پایگاه‌ها: arXiv، ACM DL، IEEE، Xplore، Springer، ScienceDirect؛ بازه‌ی زمانی از ۲۰۲۲.
۳. معیار ورود: مقاله‌ی علمی یا پیش‌چاپ معتبر درباره‌ی عامل‌های مبتنی بر مدل زبانی با اثر بیرونی؛ ارائه‌ی روش، ابزار یا شواهد تجربی. معیار خروج: صرفاً وبلاگ بدون روش، تکراری، فاقد متن کامل.
۴. ارزیابی کیفیت: پرسش‌نامه‌ی مشخص (وضوح روش، وجود داده‌ی تجربی، تهدیدهای اعتبار) با امتیازدهی دو نفره.
۵. استخراج داده: تعریف، معماری، سنجه، شواهد، محدودیت.
۶. ترکیب و گزارش: مطابق راهنمای کیچنهام و چارترز (Kitchenham & Charters, ۲۰۰۷).

واژه‌نامه‌ی تخصصی فارسی - انگلیسی

واژه‌نامه‌ی زیر معادل‌های پیشنهادی کتاب است. معادل‌های برچسب‌خورده با «پیشنهاد نگارنده» ابداع این کتاب‌اند و معادل رایج یا استاندارد نیستند.

انگلیسی	فارسی	یادداشت
agent	عامل	معادل رایج؛ «ایجنت» در گفتار؛ در کتاب «عامل»
intelligent agent	عامل هوشمند	
agentic system	سامانه عامل‌محور	
multi-agent system	سامانه چندعاملی	
agency	عاملیت	توانایی کنش هدف‌مند
autonomy	خودمختاری	
autonomous	خودمختار	
environment	محیط	
observation	مشاهده	
action	اقدام	در مقابل «کنش» که برای تعامل عمومی
feedback	بازخورد	
planning	برنامه‌ریزی	
reasoning	استدلال	
tool	ابزار	
tool use / tool calling	استفاده از ابزار / فراخوانی ابزار	
memory	حافظه	
context	زمینه	context window = «پنجره‌ی زمینه»
retrieval	بازیابی	RAG = «تولید افزوده‌به‌بازیابی»
large language model (LLM)	مدل زبانی بزرگ	

انگلیسی	فارسی	یادداشت
prompt	دستورالعمل (ورودی)	«پرامپت» در گفتار؛ در کتاب «دستورالعمل» و در صورت ابهام «prompt»
system prompt	دستورالعمل سیستمی	
prompt injection	تزریق دستورالعمل	indirect = غیرمستقیم
workflow	گردش کار	
orchestration	ارکستراسیون (هماهنگ‌سازی اجرا)	واژه فارسی «هماهنگ‌سازی» برای coordination
coordination	هماهنگی	
operations	عملیات	
DevOps	دواپس (DevOps)	در متن لاتین
MLOps	ام‌ال‌آپس (MLOps)	
LLMOps	ال‌ال‌ام‌آپس (LLMOps)	
AIOps	ای‌آی‌آپس (AIOps)	عملیات فناوری اطلاعات با کمک هوش مصنوعی — با AgentOps متفاوت
AgentOps	ایجنت‌آپس / AgentOps	عنوان کتاب: «مهندسی عامل‌های هوشمند»
observability	مشاهده‌پذیری	
monitoring	پایش	
tracing	ردگیری	
trace	ردگیری (اسم) / ردگیر	یک اجرا = «یک ردگیری»؛ span = «دامنه/بازه» ← تصمیم: «span» لاتین
span	span (بازه ردگیری)	
log	گزارش رویداد / لاگ	«ثبت رویداد» برای event logging
event	رویداد	
metric	سنجه	
telemetry	دورسنجی	
evaluation	ارزیابی	

انگلیسی	فارسی	یادداشت
benchmark	بنچمارک	
test	آزمون	
regression	رگرسیون (بازگشت کیفیت)	در متن «رگرسیون رفتاری»
LLM-as-a-judge	داور مبتنی بر مدل	
ground truth	حقیقت مینا	
success criterion	معیار موفقیت	
reliability	قابلیت اطمینان	
availability	دسترسی‌پذیری	
fault tolerance	تحمل خطا	
failure	شکست	
fault	عیب	
error	خطا	
anomaly	آنومالی (ناهنجاری)	«anomaly»: S01
root cause analysis	تحلیل علت ریشه‌ای	
resolution	رفع	
recovery	بازیابی (اجرا)	retrieval نیز «بازیابی» ← در متن «بازیابی اطلاعات» برای retrieval و «بازگرداندن/بازیابی اجرا» برای recovery
rollback	بازگشت به نسخه قبل	
compensation	جبران	
idempotency	خودتوانی (idempotency)	«تکرارپذیری ایمن» توضیحی؛ اصطلاح لاتین نگه داشته می‌شود
circuit breaker	مدار شکن	
retry	تلاش مجدد	
timeout	مهلت اجرا	
budget	بودجه	
cost	هزینه	

انگلیسی	فارسی	یادداشت
token	توکن	
latency	تاخیر	
throughput	گذردهی	
security	امنیت	
threat model	مدل تهدید	
least privilege	حداقل دسترسی	
excessive agency	اختیار بیش از حد	OWASP LLM06
sandbox	جعبه‌ایزوله	
secret	راز (اسرار)	credential = اعتبارنامه
governance	حاکمیت	
audit	حسابرسی	
accountability	پاسخ‌گویی	
compliance	انطباق	
policy	سیاست	policy engine = موتور سیاست
human-in-the-loop	انسان در حلقه	
approval	تأیید	
release	انتشار	
deployment	استقرار	
canary release	انتشار قناری (تدریجی)	
shadow testing	آزمون سایه‌ای	
version	نسخه	
configuration	پیکربندی	
lifecycle	چرخه عمر	
maturity model	مدل بلوغ	
control plane	صفحه کنترل	
execution plane	صفحه اجرا	
evidence plane	صفحه شواهد	پیشنهاد نگارنده

انگلیسی	فارسی	یادداشت
trust boundary	مرز اعتماد	
reference architecture	معماری مرجع	
behavioral contract	قرارداد رفتاری	پیشنهاد نگارنده
task contract	قرارداد وظیفه	پیشنهاد نگارنده
cost per successful task	هزینه هر وظیفه موفق	CPST – پیشنهاد نگارنده
hypothesis	فرضیه	
validity (internal/external)	اعتبار (درونی/بیرونی)	
systematic review	مرور نظام‌مند	

نمایه‌ی اصطلاحات و اختصارات

این نمایه بر پایه‌ی فصل است: برای هر اصطلاح، فصل‌هایی را که در آن‌ها به‌کار رفته است فهرست می‌کند. نمایه‌ی صفحه‌به‌صفحه پس از صفحه‌آرایی نهایی و تثبیت شماره‌ی صفحات ساخته می‌شود و هنوز تولید نشده است.

اصطلاح	فصل‌ها
AgentOps	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۹، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵
AIOps	۱، ۴
AO-RA	۵، ۷، ۱۰، ۱۱، ۱۲، ۱۴، ۱۵
CI/CD	۱، ۴، ۱۱
CPST	۴، ۵، ۶، ۷، ۸، ۱۱، ۱۲، ۱۳، ۱۴
DevOps	۱، ۳، ۴
idempotency	۴، ۵، ۸، ۹، ۱۱
ISO	۱۰
LLMOps	۱، ۴
MAST	۲، ۳، ۵، ۷، ۹، ۱۳، ۱۴، ۱۵
MCP	۱، ۲، ۳، ۵، ۶، ۱۰، ۱۱، ۱۵
MLOps	۱، ۳، ۴
NIST	۴، ۵، ۷، ۱۰، ۱۴، ۱۵
OWASP	۳، ۴، ۵، ۶، ۹، ۱۰، ۱۱، ۱۲، ۱۴، ۱۵
pass^k	۱، ۲، ۵، ۶، ۸، ۹، ۱۰، ۱۱، ۱۳، ۱۴، ۱۵
RAG	۲، ۳، ۶، ۹
TCPs	۴، ۱۲، ۱۳، ۱۴، ۱۵
آنومالی	۱، ۲، ۳، ۴، ۵، ۶، ۹، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵
ابزار	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵
اختیار بیش‌ازحد	۳، ۴، ۶، ۱۰، ۱۴، ۱۵

اصطلاح	فصل‌ها
ارزیابی	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵
استقرار	۱، ۴، ۵، ۶، ۷، ۹، ۱۰، ۱۱، ۱۳، ۱۴
اسرار	۵، ۶، ۱۰، ۱۱، ۱۳
اعتبار	۱، ۶، ۷، ۸، ۹، ۱۰، ۱۲، ۱۳، ۱۴، ۱۵
انتشار سایه‌ای	۱۱، ۱۳
بازهی اطمینان	۸، ۱۱، ۱۲، ۱۳، ۱۴
بازپخش	۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۳، ۱۴، ۱۵
بازگشت به نسخه	۶
بازیابی	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۹، ۱۰، ۱۱، ۱۳، ۱۴، ۱۵
بودجه	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵
تأخیر	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۹، ۱۱، ۱۲، ۱۵
تأیید انسانی	۲، ۳، ۴، ۵، ۶، ۷، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵
تزریق دستورالعمل	۳، ۵، ۱۰، ۱۳، ۱۴
توهم	۱، ۲، ۳، ۹، ۱۰
جبران	۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۲، ۱۳، ۱۵
جعبه‌ایزوله	۵، ۱۰، ۱۱
حافظه	۱، ۲، ۳، ۴، ۵، ۷، ۹، ۱۰، ۱۱، ۱۲، ۱۵
حداقل اختیار	۱، ۳، ۴، ۵، ۹، ۱۰، ۱۳، ۱۴
حریم خصوصی	۵، ۶، ۷، ۱۰
حسابرسی	۱، ۴، ۵، ۷، ۱۰، ۱۱، ۱۳، ۱۵
حلقه‌ی عامل	۲، ۵، ۶، ۹
خودمختاری	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۹، ۱۰، ۱۳
داور	۲، ۸، ۹، ۱۲، ۱۴
دروازه‌ی ابزار	۲، ۴، ۵، ۷، ۹، ۱۱
ردگیری	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵
رگرسیون	۸
زمینه	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۹، ۱۰، ۱۱، ۱۲، ۱۳

اصطلاح	فصل‌ها
ساگا	۵، ۹، ۱۵
سناریو	۱، ۴، ۵، ۶، ۸، ۹، ۱۰، ۱۱، ۱۳، ۱۴، ۱۵
سیاست	۱، ۲، ۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱، ۱۳، ۱۴، ۱۵
شبیه‌سازی	۳، ۴، ۶، ۸، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵
صفحه‌ی اجرا	۴، ۵، ۱۰، ۱۱
صفحه‌ی شواهد	۴، ۵، ۷، ۱۱
صفحه‌ی کنترل	۴، ۵، ۱۱
طبقه‌بندی شکست	۲، ۳، ۵، ۹
ظرفیت	۷، ۱۱
عاملیت	۲، ۴
علت ریشه‌ای	۱، ۲، ۳، ۴، ۶، ۹، ۱۰، ۱۵
فرضیه	۱، ۲، ۴، ۹، ۱۲، ۱۳، ۱۴، ۱۵
قرارداد رفتاری	۱، ۴، ۶، ۸، ۹، ۱۲، ۱۳، ۱۴
قرارداد وظیفه	۲، ۳، ۴، ۵، ۶، ۸، ۱۰، ۱۳، ۱۴
قناری	۶، ۱۱، ۱۳
مانیفست انتشار	۴، ۶، ۱۰، ۱۱
محافظ تکرار	۹، ۱۴
مدار شکن	۵، ۷، ۹، ۱۳
مدل بلوغ	۵، ۱۳، ۱۴، ۱۵
مرز اعتماد	۵، ۹، ۱۰، ۱۱، ۱۳
مشاهده‌پذیری	۱، ۴، ۵، ۷، ۱۳، ۱۵
مقیاس‌پذیری	۱، ۸، ۱۱
نتایج منفی	۱۴، ۱۵
نسخه‌بندی	۱، ۲، ۴، ۶، ۷، ۱۱، ۱۳، ۱۵
نقطه‌ی ذخیره	۱۱
هزینه‌ی هر وظیفه‌ی موفق	۵، ۶، ۱۲
هویت	۵، ۶، ۱۰، ۱۱، ۱۵

اصطلاح	فصل‌ها
واگذاری	۱۳
چندعاملی	۲، ۳، ۴، ۵، ۷، ۹، ۱۳، ۱۴
کلید توقف	۹، ۱۱، ۱۳

فهرست یکپارچه‌ی منابع ارجاع‌شده‌ی کتاب (سبک ۷ APA). هر منبع فراداده‌ی

راستی‌آزمایی‌شده دارد؛ جزئیات وضعیت راستی‌آزمایی در پیوست F آمده است.

Alvidrez, M. (2016). Embracing risk. In B. Beyer, C. Jones, J. Petoff, & N. R. Murphy (Eds.), Site reliability engineering: How Google runs production systems (Chapter 3). O'Reilly Media. <https://sre.google/sre-book/embracing-risk/>

Anthropic. (2024, December 19). Building effective agents. <https://www.anthropic.com/engineering/building-effective-agents>

Cemri, M., Pan, M. Z., Yang, S., Agrawal, L. A., Chopra, B., Tiwari, R., Keutzer, K., Parameswaran, A., Klein, D., Ramchandran, K., Zaharia, M., Gonzalez, J. E., & Stoica, I. (2025). Why do multi-agent LLM systems fail? (arXiv:2503.13657). arXiv. <https://doi.org/10.48550/arXiv.2503.13657>

Chen, M., Tworek, J., Jun, H., Yuan, Q., Pinto, H. P. d. O., Kaplan, J., Edwards, H., Burda, Y., Joseph, N., Brockman, G., Ray, A., Puri, R., Krueger, G., Petrov, M., Khlaaf, H., Sastry, G., Mishkin, P., Chan, B., Gray, S., . . . Zaremba, W. (2021). Evaluating large language models trained on code (arXiv:2107.03374). arXiv. <https://doi.org/10.48550/arXiv.2107.03374>

Debenedetti, E., Zhang, J., Balunović, M., Beurer-Kellner, L., Fischer, M., & Tramèr, F. (2024). AgentDojo: A dynamic environment to evaluate prompt injection attacks and defenses for LLM agents (arXiv:2406.13352). arXiv. <https://doi.org/10.48550/arXiv.2406.13352>

Dong, L., Lu, Q., & Zhu, L. (2024). AgentOps: Enabling observability of LLM agents (arXiv:2411.05285). arXiv. <https://doi.org/10.48550/arXiv.2411.05285>

Ewaschuk, R. (2016). Monitoring distributed systems. In B. Beyer, C. Jones, J. Petoff, & N. R. Murphy (Eds.), Site reliability engineering: How Google runs production systems (Chapter 6). O'Reilly Media. <https://sre.google/sre-book/monitoring-distributed-systems/>

Forsgren, N., Humble, J., & Kim, G. (2018). Accelerate: The science of lean software and DevOps: Building and scaling high performing technology organizations. IT Revolution Press.

Garcia-Molina, H., & Salem, K. (1987). Sagas. Proceedings of the 1987 ACM SIGMOD International Conference on Management of Data, 249-259. <https://doi.org/10.1145/38713.38742>

- Greshake, K., Abdelnabi, S., Mishra, S., Endres, C., Holz, T., & Fritz, M. (2023). Not what you've signed up for: Compromising real-world LLM-integrated applications with indirect prompt injection (arXiv:2302.12173). arXiv. <https://doi.org/10.48550/arXiv.2302.12173>
- Huang, J., Chen, X., Mishra, S., Zheng, H. S., Yu, A. W., Song, X., & Zhou, D. (2024). Large language models cannot self-correct reasoning yet. International Conference on Learning Representations (ICLR 2024). arXiv:2310.01798. <https://doi.org/10.48550/arXiv.2310.01798>
- Humble, J., & Farley, D. (2010). Continuous delivery: Reliable software releases through build, test, and deployment automation. Addison-Wesley.
- International Organization for Standardization & International Electrotechnical Commission. (2023). Information technology - Artificial intelligence - Management system (ISO/IEC 42001:2023). ISO/IEC.
- Jimenez, C. E., Yang, J., Wettig, A., Yao, S., Pei, K., Press, O., & Narasimhan, K. (2024). SWE-bench: Can language models resolve real-world GitHub issues? International Conference on Learning Representations (ICLR 2024). arXiv:2310.06770. <https://doi.org/10.48550/arXiv.2310.06770>
- Kitchenham, B., & Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering (Version 2.3; EBSE Technical Report EBSE-2007-01). Keele University and University of Durham.
- Kreuzberger, D., Klhl, N., & Hirschl, S. (2022). Machine learning operations (MLOps): Overview, definition, and architecture (arXiv:2205.02302). arXiv. <https://doi.org/10.48550/arXiv.2205.02302>
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Klittler, H., Lewis, M., Yih, W.-t., Rocktschel, T., Riedel, S., & Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive NLP tasks. Advances in Neural Information Processing Systems, 33 (NeurIPS 2020). arXiv:2005.11401. <https://doi.org/10.48550/arXiv.2005.11401>
- Liu, N. F., Lin, K., Hewitt, J., Paranjape, A., Bevilacqua, M., Petroni, F., & Liang, P. (2023). Lost in the middle: How language models use long contexts (arXiv:2307.03172). arXiv. <https://doi.org/10.48550/arXiv.2307.03172>
- Model Context Protocol. (2026). Model Context Protocol specification (version 2026-07-28). <https://modelcontextprotocol.io/specification/latest> (accessed 2026-10-21)
- National Institute of Standards and Technology. (2024). Artificial Intelligence Risk Management Framework: Generative Artificial Intelligence Profile (NIST AI 600-1). <https://doi.org/10.6028/NIST.AI.600-1>

- OpenTelemetry. (n.d.). Semantic conventions for generative AI. GitHub. <https://github.com/open-telemetry/semantic-conventions-genai> (accessed 2026-10-21; stability status not verified)
- OWASP GenAI Security Project. (2025). 2025 top 10 risk & mitigations for LLMs and Gen AI apps. OWASP Foundation. <https://genai.owasp.org/llm-top-10/> (accessed 2026-10-21)
- Park, J. S., O'Brien, J. C., Cai, C. J., Morris, M. R., Liang, P., & Bernstein, M. S. (2023). Generative agents: Interactive simulacra of human behavior (arXiv:2304.03442). arXiv. <https://doi.org/10.48550/arXiv.2304.03442>
- Perez, F., & Ribeiro, I. (2022). Ignore previous prompt: Attack techniques for language models. ML Safety Workshop, NeurIPS 2022. arXiv:2211.09527. <https://doi.org/10.48550/arXiv.2211.09527>
- Runeson, P., & Hlŕst, M. (2009). Guidelines for conducting and reporting case study research in software engineering. *Empirical Software Engineering*, 14(2), 131-164. <https://doi.org/10.1007/s10664-008-9102-8>
- Saltzer, J. H., & Schroeder, M. D. (1975). The protection of information in computer systems. *Proceedings of the IEEE*, 63(9), 1278-1308.
- Schick, T., Dwivedi-Yu, J., Dessi, R., Raileanu, R., Lomeli, M., Zettlemoyer, L., Cancedda, N., & Scialom, T. (2023). Toolformer: Language models can teach themselves to use tools (arXiv:2302.04761). arXiv. <https://doi.org/10.48550/arXiv.2302.04761>
- Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., & Dennison, D. (2015). Hidden technical debt in machine learning systems. *Advances in Neural Information Processing Systems*, 28 (NIPS 2015).
- Shinn, N., Cassano, F., Berman, E., Gopinath, A., Narasimhan, K., & Yao, S. (2023). Reflexion: Language agents with verbal reinforcement learning (arXiv:2303.11366). arXiv. <https://doi.org/10.48550/arXiv.2303.11366>
- Sigelman, B. H., Barroso, L. A., Burrows, M., Stephenson, P., Plakal, M., Beaver, D., Jaspan, S., & Shanbhag, C. (2010). Dapper, a large-scale distributed systems tracing infrastructure (Technical Report dapper-2010-1). Google. <https://research.google/pubs/pub36356/>
- Tabassi, E. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-1>
- Wang, L., Ma, C., Feng, X., Zhang, Z., Yang, H., Zhang, J., Chen, Z., Tang, J., Chen, X., Lin, Y., Zhao, W. X., Wei, Z., & Wen, J.-R. (2023). A survey on large language model

- based autonomous agents (arXiv:2308.11432). arXiv. <https://doi.org/10.48550/arXiv.2308.11432>
- Wang, X., Wei, J., Schuurmans, D., Le, Q., Chi, E., Narang, S., Chowdhery, A., & Zhou, D. (2023). Self-consistency improves chain of thought reasoning in language models. International Conference on Learning Representations (ICLR 2023). arXiv:2203.11171. <https://doi.org/10.48550/arXiv.2203.11171>
- Wang, Z., Li, J., Zhou, Q., Si, H., Liu, Y., Li, J., Xie, G., Sun, F., Pei, D., & Pei, C. (2025). A survey on AgentOps: Categorization, challenges, and future directions (arXiv:2508.02121). arXiv. <https://doi.org/10.48550/arXiv.2508.02121>
- Wang, Z., Pei, C., Liu, Y., Li, J., Huo, Y., Zhou, Q., Si, H., Cui, H., Liu, Z., Xie, G., Sun, F., Pei, D., & Lo, D. (2026). Agent system operations: Categorization, challenges, and future directions (arXiv:2606.01581). arXiv. <https://doi.org/10.48550/arXiv.2606.01581>
- Wei, J., Wang, X., Schuurmans, D., Bosma, M., Ichter, B., Xia, F., Chi, E., Le, Q., & Zhou, D. (2022). Chain-of-thought prompting elicits reasoning in large language models (arXiv:2201.11903). arXiv. <https://doi.org/10.48550/arXiv.2201.11903>
- Wohlin, C., Runeson, P., Hl̄st, M., Ohlsson, M. C., Regnell, B., & Wessl̄n, A. (2012). Experimentation in software engineering. Springer. <https://doi.org/10.1007/978-3-642-29044-2>
- Wooldridge, M., & Jennings, N. R. (1995). Intelligent agents: Theory and practice. The Knowledge Engineering Review, 10(2), 115-152. <https://doi.org/10.1017/S0269888900008122>
- Yao, S., Shinn, N., Razavi, P., & Narasimhan, K. (2024). tau-bench: A benchmark for tool-agent-user interaction in real-world domains (arXiv:2406.12045). arXiv. <https://doi.org/10.48550/arXiv.2406.12045>
- Yao, S., Zhao, J., Yu, D., Du, N., Shafran, I., Narasimhan, K., & Cao, Y. (2022). ReAct: Synergizing reasoning and acting in language models (arXiv:2210.03629). arXiv. <https://doi.org/10.48550/arXiv.2210.03629>
- Yehudai, A., Eden, L., Li, A., Uziel, G., Zhao, Y., Bar-Haim, R., Cohan, A., & Shmueli-Scheuer, M. (2025). Survey on evaluation of LLM-based agents (arXiv:2503.16416). arXiv. <https://doi.org/10.48550/arXiv.2503.16416>
- Zheng, L., Chiang, W.-L., Sheng, Y., Zhuang, S., Wu, Z., Zhuang, Y., Lin, Z., Li, Z., Li, D., Xing, E. P., Zhang, H., Gonzalez, J. E., & Stoica, I. (2023). Judging LLM-as-a-judge with MT-Bench and Chatbot Arena. NeurIPS 2023 Datasets and Benchmarks Track. arXiv:2306.05685. <https://doi.org/10.48550/arXiv.2306.05685>

معرفی کتاب

هوش مصنوعی در حال عبور از مدل‌های پیش‌بینی‌گر و رابط‌های گفت‌وگو محور به سوی سامانه‌هایی است که می‌توانند برنامه‌ریزی کنند، از ابزارها بهره بگیرند، اقدامات را هماهنگ سازند و با محیط‌های پیچیده تعامل داشته باشند.

این تحول، چالش‌های عملیاتی تازه‌ای ایجاد می‌کند که فراتر از روش‌های سنتی توسعه و استقرار نرم‌افزار و مدیریت چرخه عمر مدل‌های یادگیری ماشین هستند.

کتاب «مهندسی عامل‌های هوشمند: تکامل بعدی دواپس و ام‌ال‌آپس» به بررسی رویکردی مهندسی برای طراحی، استقرار، مشاهده‌پذیری، ارزیابی، حاکمیت و بهبود مستمر عامل‌های هوش مصنوعی می‌پردازد.

این اثر با بررسی مبانی دواپس، ام‌ال‌آپس و معماری‌های عامل محور، چارچوبی مفهومی برای شناخت الزامات عملیاتی سامانه‌های نرم‌افزاری خودمختار ارائه می‌کند.

قابلیت اطمینان، ارزیابی رفتار، ردیابی اجرا، امنیت، کنترل اختیار عمل، مدیریت چرخه عمر و اعتبارسنجی علمی چارچوب‌های عملیاتی از محورهای اصلی این کتاب هستند.

این کتاب برای مهندسان حرفه‌ای دواپس، ام‌ال‌آپس، هوش مصنوعی و معماری سیستم نوشته شده است و می‌کوشد مبانی مهندسی لازم برای بهره‌برداری مسئولانه و مقیاس‌پذیر از سامانه‌های عامل محور را تبیین کند.

موضوعات کتاب

- مبانی نظری و معماری مرجع AgentOps
- مهندسی چرخه عمر عامل‌های هوش مصنوعی
- مشاهده‌پذیری و ارزیابی رفتار
- قابلیت اطمینان، امنیت و حاکمیت
- استقرار، مقیاس‌پذیری و بهینه‌سازی هزینه
- روش‌های پژوهش و مسیرهای آینده

درباره نویسنده

محمد تفکری عبد، مهندس نرم‌افزار و فعال حوزه فناوری است. علایق حرفه‌ای او شامل هوش مصنوعی، معماری نرم‌افزار، خودکارسازی و مهندسی سامانه‌های هوشمند است. این کتاب به بررسی چالش‌های مهندسی و عملیاتی سامانه‌های عامل محور در پیوند میان مهندسی نرم‌افزار و زیرساخت هوش مصنوعی می‌پردازد.