万字拆解谁才是 AI 落地的终极解药

（上）

回顾这两年的 AI 发展轨迹，你会发现两条截然不同却又并行不悖的主线：

一条是造脑路线：基础模型层（Foundation Models）的狂奔，各大厂商拼参数、拼算力，目标是通用人工智能（AGI）。

一条是造躯干路线：系统架构层（System Architecture）的迭代，拼架构、拼工程，目标是让 AI 在特定场景创造价值，试图解决如何让这个大脑稳定地控制躯体。

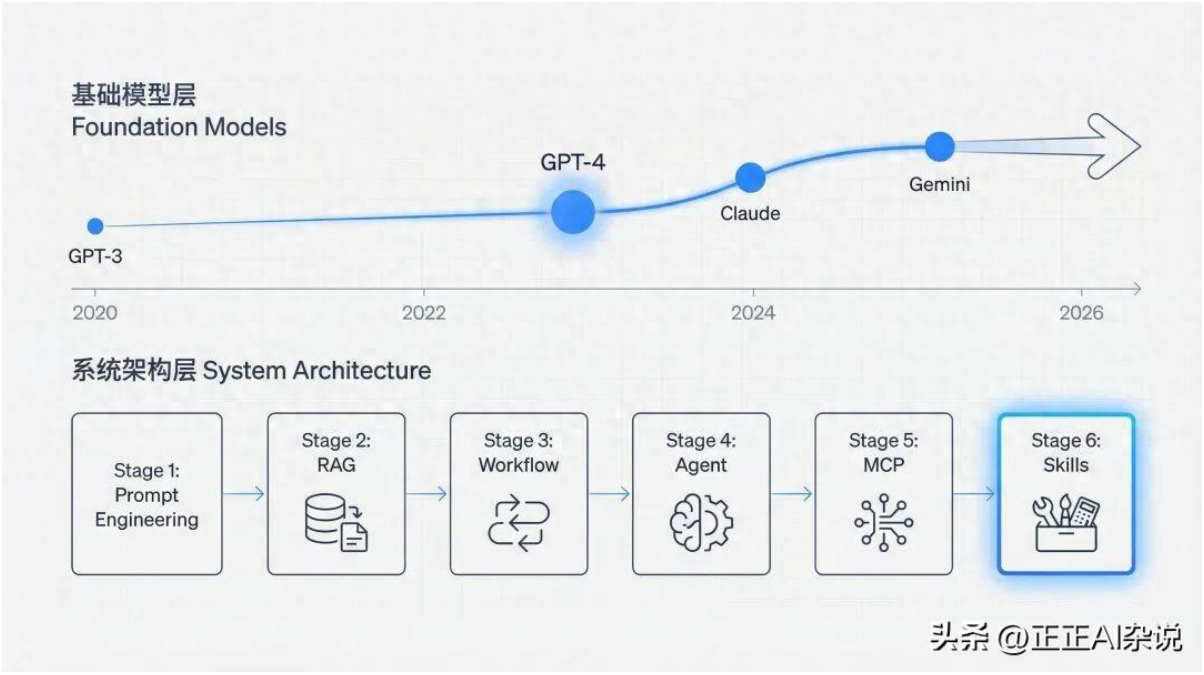

图示：AI 发展双轨并行，模型能力的指数增长与系统架构的线性积累

这篇文章不谈模型参数，只谈后者。

当下的 AI 行业正处于一种概念焦虑中：Agent、Skill、Workflow、RAG、MCP，新名词层出不穷。但这并非技术潮流的无序堆砌，而是我们为了让 AI 从能用走向好用，在工程上给出的不同维度的回答。

智能从来不是孤立存在的。 为了让 AI 真正落地，我们需要建立一种新的架构直觉：**当智能不再只蜷缩在模型参数里，而是流淌在模型、数据库、API 和业务流程之间时，我们该如何设计一套能承载它的容器？**

本文将尝试从系统分层的视角，梳理这些常被混用的概念，帮你在纷繁的技术名词背后，建立一套稳定、可迁移的 AI 产品架构认知。

Part 1｜概念膨胀背后的系统演进：从单体到系统

本章要点

- AI 正在从单体智能走向系统智能，概念爆发的本质是能力外置。
- 早期的模型中心主义导致了幻觉、时空封闭、执行无能等问题。
- Agent/Skill/Workflow/RAG 是同一个问题在不同维度的工程化回答。
- 稳定工作应由结构化系统承载，而非赌模型的概率。

如果将 AI 这几年的落地历程拉成一条时间轴，你会看到一个清晰的祛魅与重构的过程：我们正在从单体智能（Monolithic Intelligence）走向系统智能（Systemic Intelligence）。

1. 早期迷思：全能的黑箱

在 GPT-3.5 刚问世的早期，行业内弥漫着一种模型中心主义。大模型被普遍视为一个高度自治、近乎全能的黑箱。

那时的产品设计逻辑极其简单：只要 Prompt 写得足够精妙，模型似乎就能凭一己之力，同时承担起理解意图、逻辑推理、任务规划、知识检索甚至最终执行的所有职责。

这种预期导致了早期的 AI 应用架构非常轻，几乎所有压力都压在了 Prompt Engineering 上，极其依赖模型本身的临场发挥。

2. 现实的引力：幻觉与失控

然而，随着落地场景从闲聊转向严肃业务，单体模型的局限性开始暴露无遗：

- **幻觉问题：** 在缺乏约束的情况下，一本正经地胡说八道。
- **时空封闭：** 模型训练结束的那一刻，它的记忆就停止了，无法获取实时信息。

- **执行无能：** 它能写出完美的 Python 代码，却无法在你的生产环境中直接运行它；它能告诉你怎么定闹钟，却无法帮你按下那个按钮。
- **长程丢失：** 在处理一个跨越数小时、包含数十个步骤的复杂任务时，模型很容易忘形，丢失最初的目标。

3. 架构的觉醒：能力外置与分层

面对这些问题，工程界意识到：解决之道并不是逼迫模型更努力地思考，而是改变系统的拓扑结构。 我们开始进行「能力剥离」：

- 把"记忆"从模型参数中剥离，外置为 **RAG（检索增强生成）**；
- 把"手脚"从文本生成中剥离，封装为 **Tools & Skills（工具与技能）**；
- 把"经验"从隐性的上下文剥离，固化为 **Workflow（工作流）**；
- 把"连接"的各种胶水代码剥离，标准化为 **MCP（模型上下文协议）**。

全新技术概念的爆发，正是这种能力外置的产物，是分工原理在 AI 系统中的映射。

经过这两年多的落地探索，我们终于看清了底牌：大模型更像是一个拥有通用智力、但缺乏具体生活经验的超级大脑。而要完成一项具体工作，这个大脑必须配备灵活的手脚（工具）、可查阅的档案（知识库）和行事的规矩（流程）。

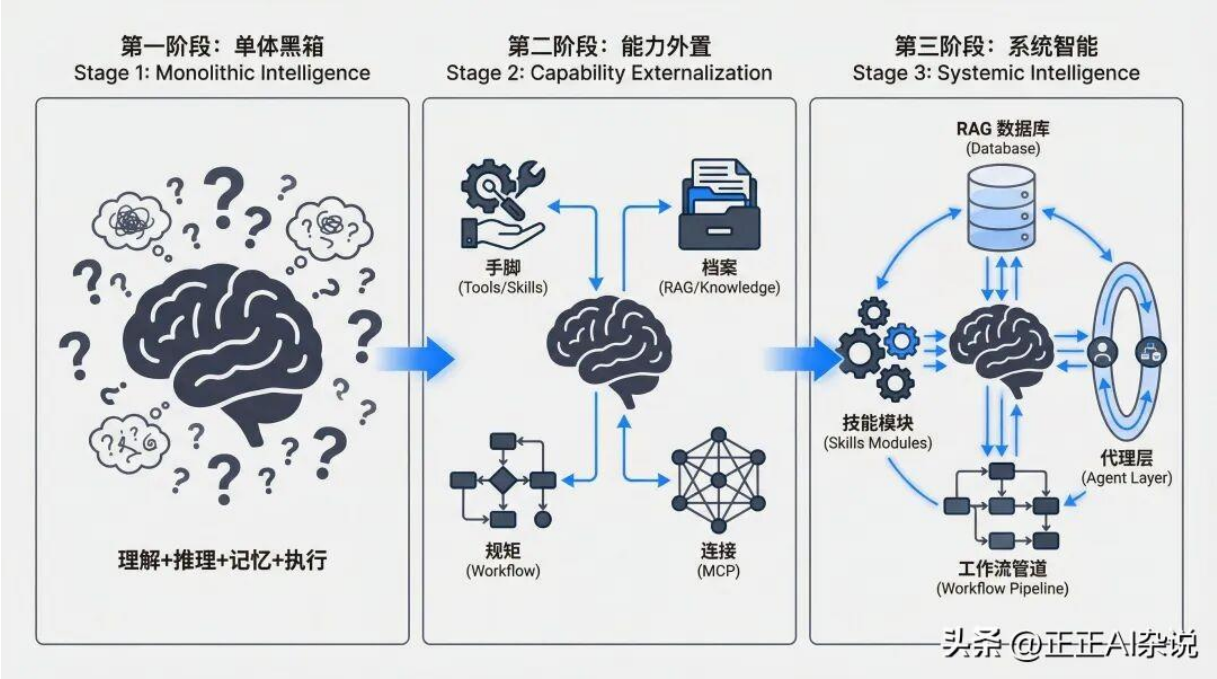

图示：AI 系统的演进：从全能黑箱到能力外置的组件化解耦

稳定、高频、可控的工作，应当由结构化的系统来承载，而不能赌模型的概率。

当下的混乱感，很大程度上源于我们正处在新旧范式的交界处： 旧的习惯让我们试图用一个 Prompt 解决所有问题，而新的实践要求我们将业务逻辑拆解并注入系统。

在这样的背景下，重新梳理这些组件各自的位置与边界，已经不只是技术选型问题，而是 AI 产品能否在真实世界长期存活的关键前提。

Part 2 | 解剖智能系统：从单体黑箱到精密机器

本章要点

- 将模型从全能指挥官降级为心脏，真正的大脑由系统逻辑接管
- 核心组件构成四大生理系统：动力与连接、能力支撑、行为控制、感知与免疫
- 架构设计遵循三大法则：祛魅（组件化）、解耦（分离变与不变）、归因（可调试）· 把不确定性的模型关进确定性的系统笼子里

当我们谈论 Agent、Skill、Workflow、RAG、MCP 这些概念时，许多人的困惑在于：这些词是不是技术圈造出来的新包装？但这背后其实隐藏着一个更根本的结构性问题：

当大模型不再仅仅被当作一个简单的函数调用，而是被嵌入到真实业务中时，我们究竟在搭建一套什么样的系统？

事实上，这并非单纯的概念堆砌，而是计算智能向实体系统进化的必然过程。

试想一下，最初的大模型就像一个**缸中之脑**，我们曾天真地以为它能接管一切。但在工程实践中，我们发现这个大脑太容易做梦（幻觉）且缺乏定力。

为了让它稳定干活，我们不得不对它进行降级使用：

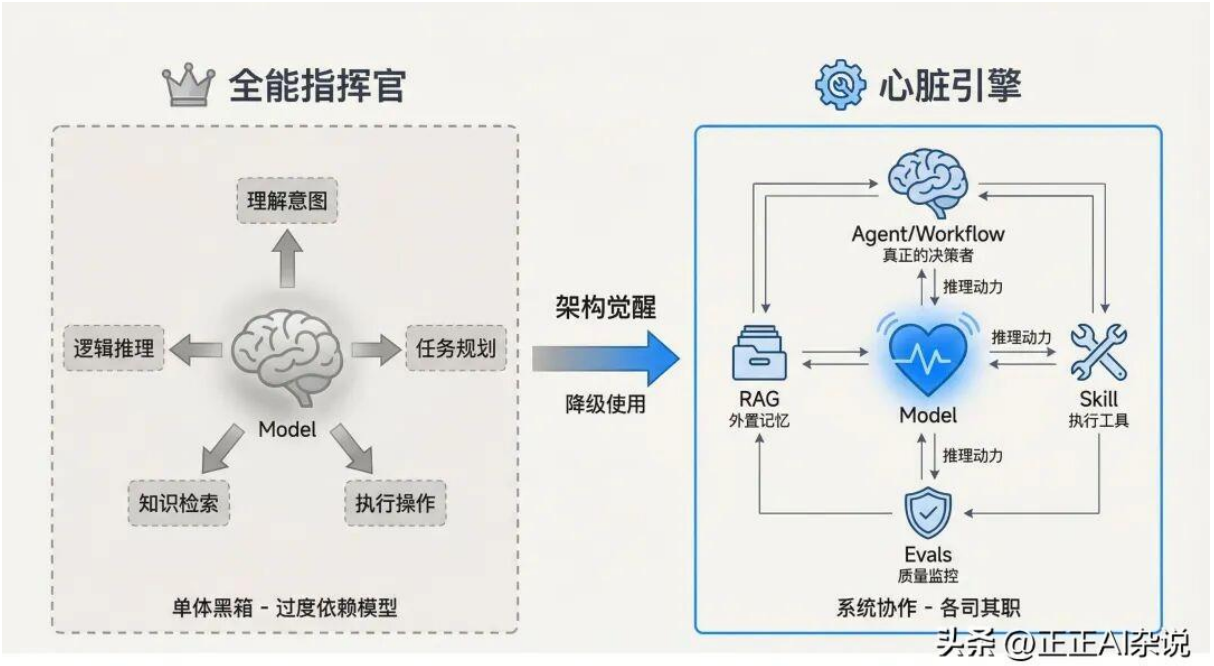

图示：大模型的降级使用

将它从全能指挥官的位置上撤下来，让它退居为提供源源不断推理能力的心脏。而真正的大脑前额叶（决策与控制），则由我们构建的系统逻辑（Agent/Workflow）来接管。

基于这个全新的**分工逻辑**，我们可以通过一张**能力地图**来重新审视它们的职责：

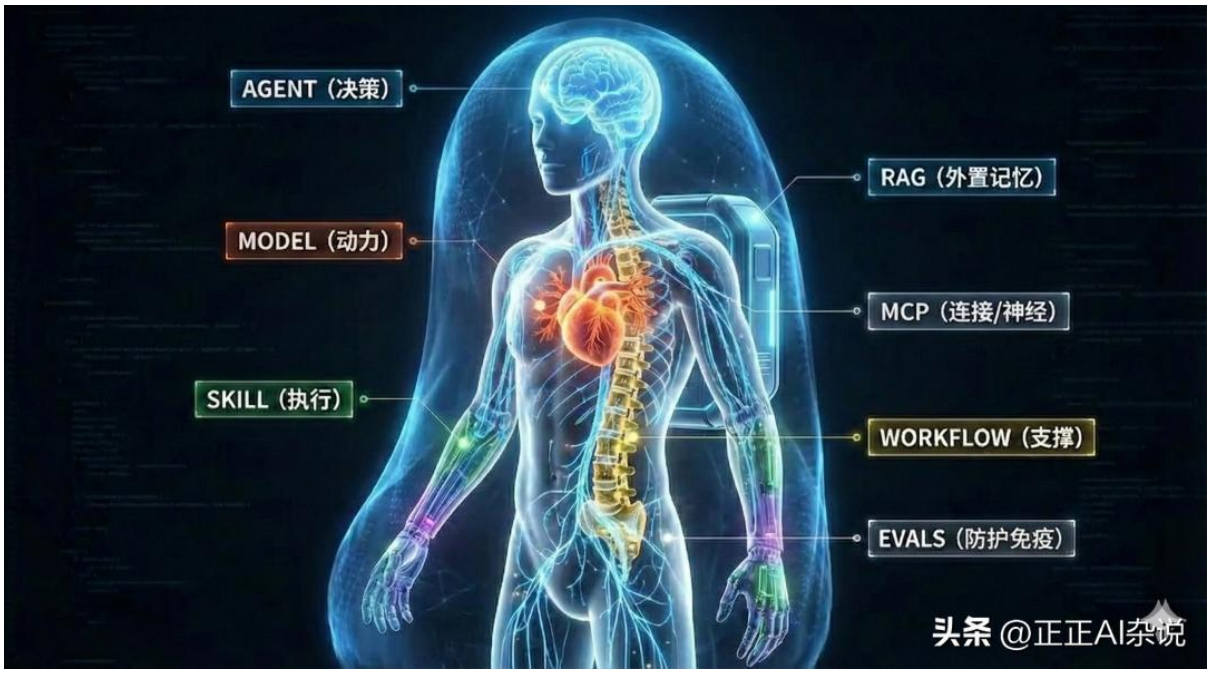

图示：AI 系统能力地图

- **核心动力层（Model）：** 系统的**心脏**。提供基础的推理与生成动力。
- **基础设施层（MCP）：** 系统的**神经与血管**。负责标准化的连接与数据流通。
- **知识与事实层（RAG）：** 系统的**海马体**。供给可靠、动态的外部信息。
- **能力执行层（Skill）：** 系统的**手脚**。将模糊意图转化为精确的工具和技能调用。
- **流程与调度层（Workflow）：** 系统的**骨架**。确保任务按照既定的 SOP 有序推进。
- **认知与决策层（Agent）：** 系统的**前额叶**。负责在复杂环境下的感知与动态决策。
- **感知与免疫层（Evals& Guardrails）：** 系统的**痛觉与白细胞**。建立从离线体检到在线监控的反馈闭环，负责感知幻觉痛点、拦截安全风险并维持系统的长期健康

为了看清这套系统的运作机理，我们不再单纯罗列，而是将其解构为维持系统运转的四大生理系统：

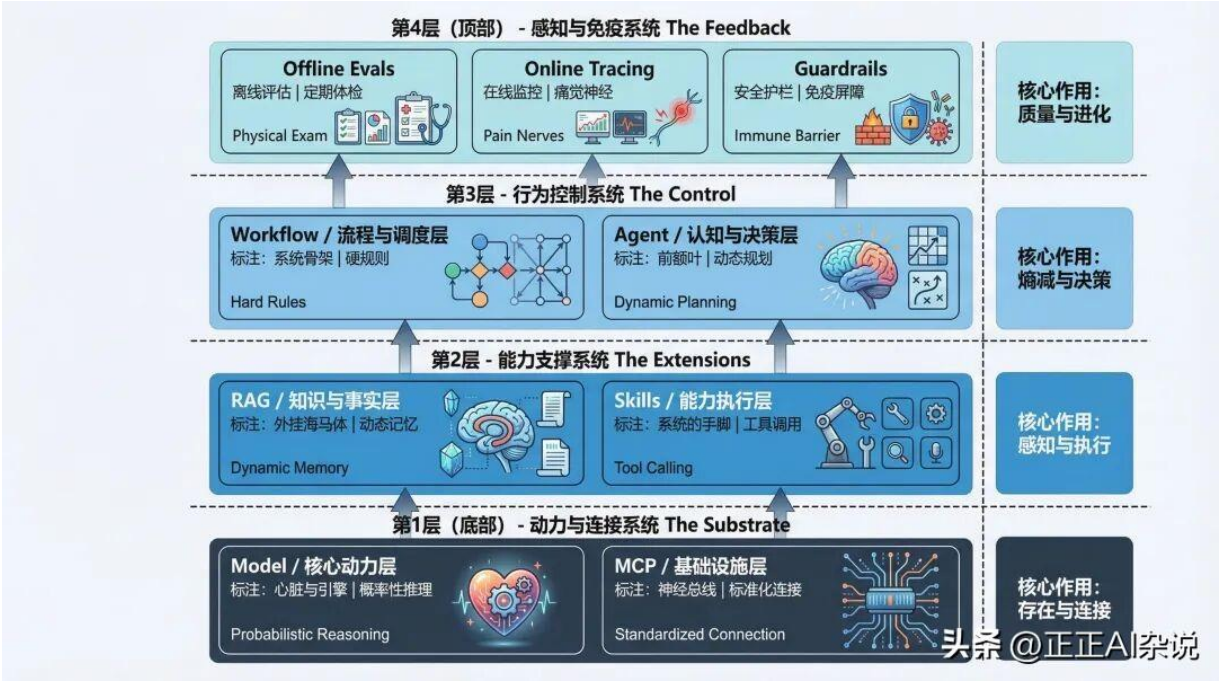

图示：AI 系统四层生理架构图

1. 动力与连接系统（The Substrate)

这是系统的基质，解决了存在与连接的问题。

核心动力层：Model (Foundation Model)
技术定义：概率性推理与生成引擎
核心隐喻：心脏与引擎

图示：Model 组件解析

- **架构洞察：动力的源头与熵的来源**
    - **定位：** 系统的**态势能**。就像台放在台架上的 V12 引擎，它拥有巨大的潜能，但不会自己产生业务价值。
    - **概率本质：** 它是系统中唯一的**熵源**：它既提供了理解力和创造力，也带来了幻觉和不确定性。架构师的任务，不是消除这种不确定性（那样就失去了智能），而是通过上层架构来管理这种不确定性。
- **使用边界：**
    - **不要微调模型去记知识：** 引擎是通用的，油箱（RAG）才是存燃料的。用昂贵的参数去记易变的数据，是架构上的浪费。
    - **不要指望模型自带逻辑闭环：** 引擎需要变速箱（Workflow）才能输出稳定的扭矩。

基础设施层：MCP (Model Context Protocol)

技术定义：系统的标准化连接协议
核心隐喻：神经总线

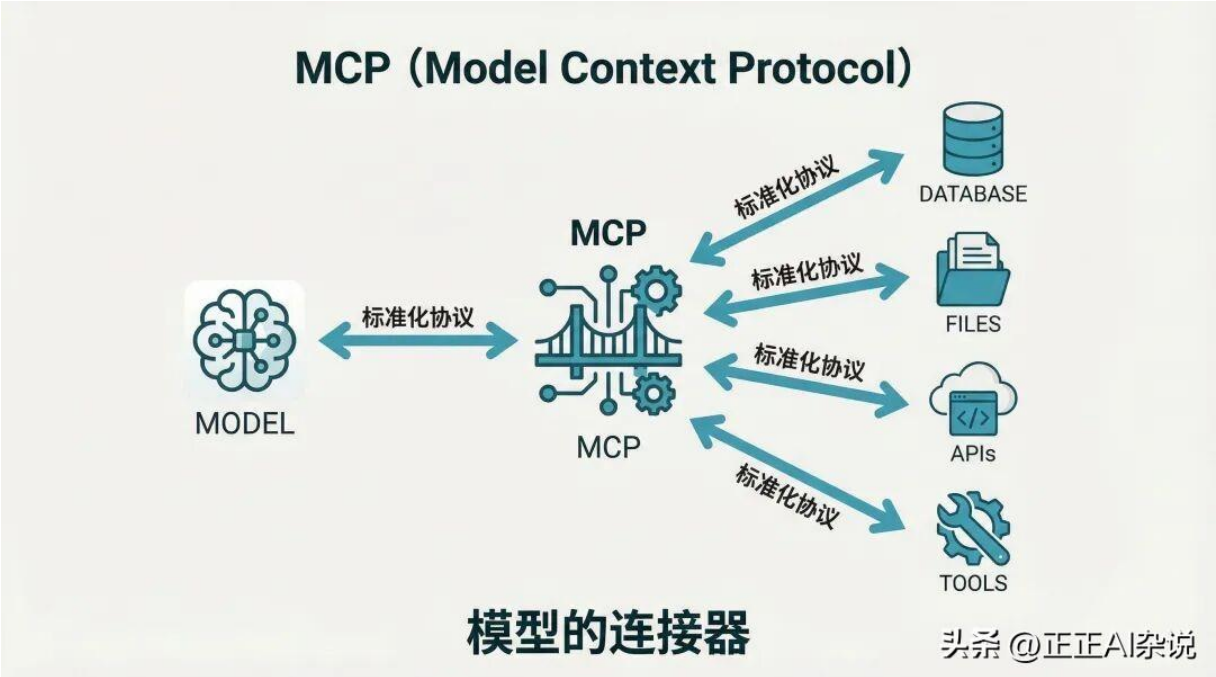

图示：MCP 组件解析

- **架构洞察：连接的标准化**

- **痛点：** 以前，AI 是一种孤岛智能。要让它读取本地文件、连接数据库，开发者需要编写大量脆弱的胶水代码。
- **变革：** MCP 的本质是上下文（Context）的标准化。它规定了所有的外部数据源和工具，必须以一种统一的格式向模型暴露接口。这就像 USB 协议，让鼠标、键盘、硬盘可以即插即用。

- **使用边界：**
  - 凡是涉及跨系统交互、异构数据读取，MCP 是必选项。

2. 能力支撑系统（The Extensions）

这是系统的物理延伸，解决了感知与执行的问题。

知识与事实层：RAG (Retrieval-Augmented Generation)

技术定义： 基于向量检索的上下文注入机制

核心隐喻：外挂海马体

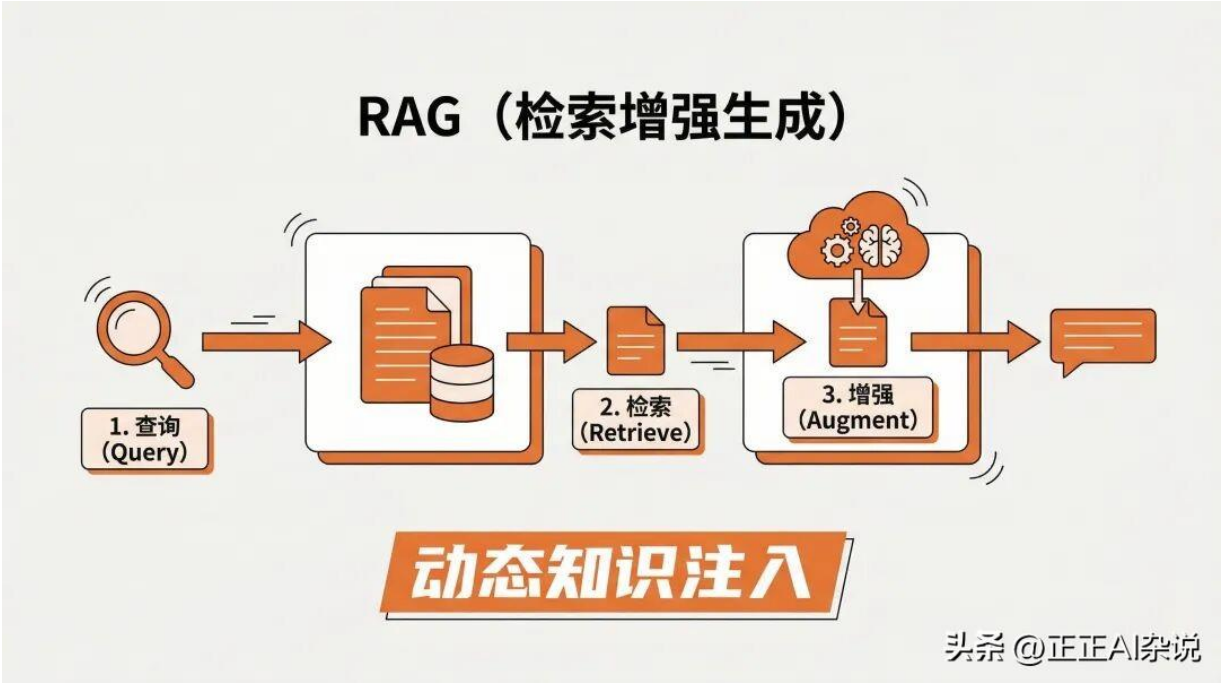

图示：RAG 组件解析

- **架构洞察：记忆与计算的解耦**
  - **误区纠正：** 许多人把知识和智力混为一谈。试图通过微调（Fine-tuning）来让模型记住新知识。这是架构上的重大误判。模型的参数应该用来存

储通用的逻辑与推理能力，而不应该用来存储精确的、易变的、私有的事实。
    - **本质：** RAG 不是为了让模型变聪明，而是系统的外置动态记忆。它的工作原理不是让模型记住，而是让模型看见。
    - **价值：** 它是当前物理上解决幻觉（Hallucination）和时效性问题的重要手段，将事实准确性的责任从模型转移到了数据库。
- **使用边界：**
    - **必须用 RAG：** 涉及私有数据（企业文档）、实时数据（新闻/股价）、高精度事实查证（法律条款）的场景。
    - **慎用 RAG：** 当任务需要模型展现通识、逻辑推演或创造性写作时，过度的检索反而会引入噪音。

能力执行层：Skill (Tools / Actions)

技术定义： 模块化的能力封装单元，打包了指令文档、可选脚本、参考资料与资源

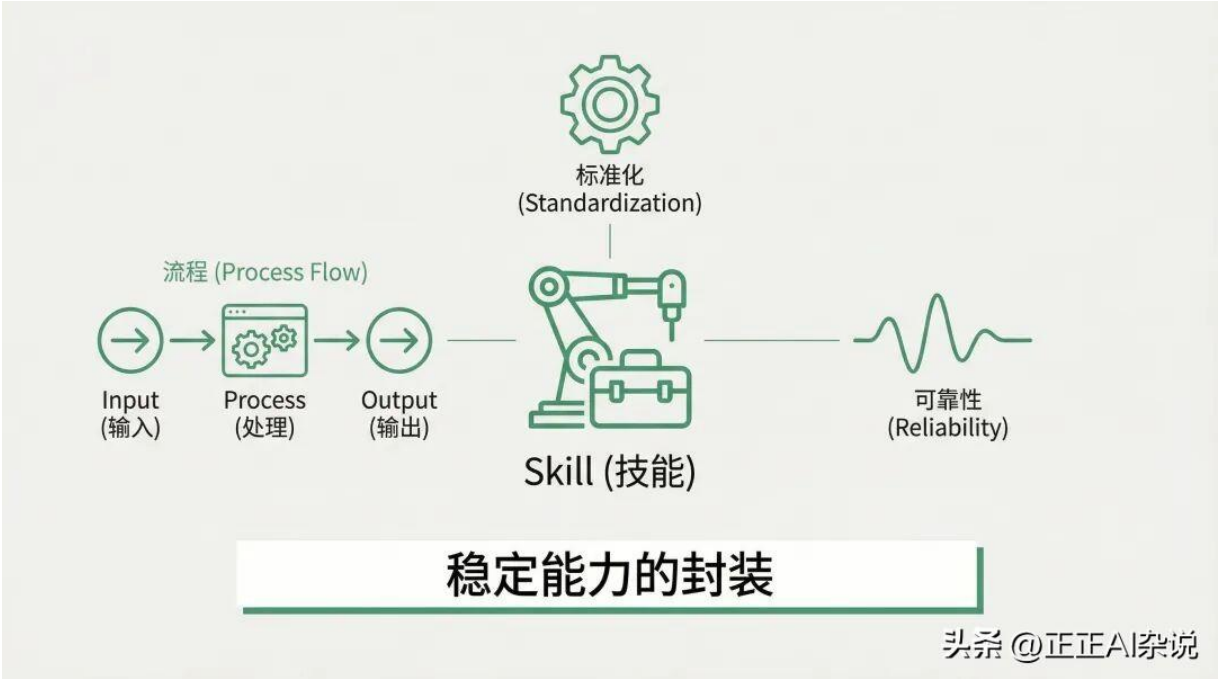

图示：Skill 组件解析

- **架构洞察：从空谈到实干的桥梁**

    - **本质：** Skill 是系统与真实世界交互的接口。Skill 将**具体的操作逻辑**（如查询天气 API、生成 PDF）封装成标准化的技能包，让 Agent 可以像人类使用工具一样调用它们。
- **分类与性能：**
    - **执行型 (Executable)：不经大脑的手**。它是确定性的代码（Function Calling），如：把 A 格式转为 B 格式。特点是快且准。
    - **指令型 (Instructional)：带脑子的手**。它是复杂的自然语言指引（SOP），如"根据以下原则写一篇公关稿"。特点是灵活但依赖模型智力。
    - **工程原则：** 在产品设计时要根据场景需求权衡。能用执行型 Skill 解决的，优先使用执行型。需要语义理解的，才使用指令型。

- **使用边界：**
    - **原子化 (Atomic)：** 一个 Skill 只做一件事。不要做一个万能 Skill，要像乐高积木一样，把复杂任务拆解为多个简单的 Skill 组合。
    - **安全红线：权限最小化。** 绝不允许模型在没有沙箱（Sandbox）的情况下直接生成并执行代码。所有的 Skill 应该是预先写好的、经过安全审计的白名单操作。

3. 行为控制系统 (The Control)

这是系统的控制单元，解决了熵减与决策的问题。

流程与调度层：Workflow

技术定义： 基于有向无环图（DAG）的流程编排
核心隐喻：系统的骨架

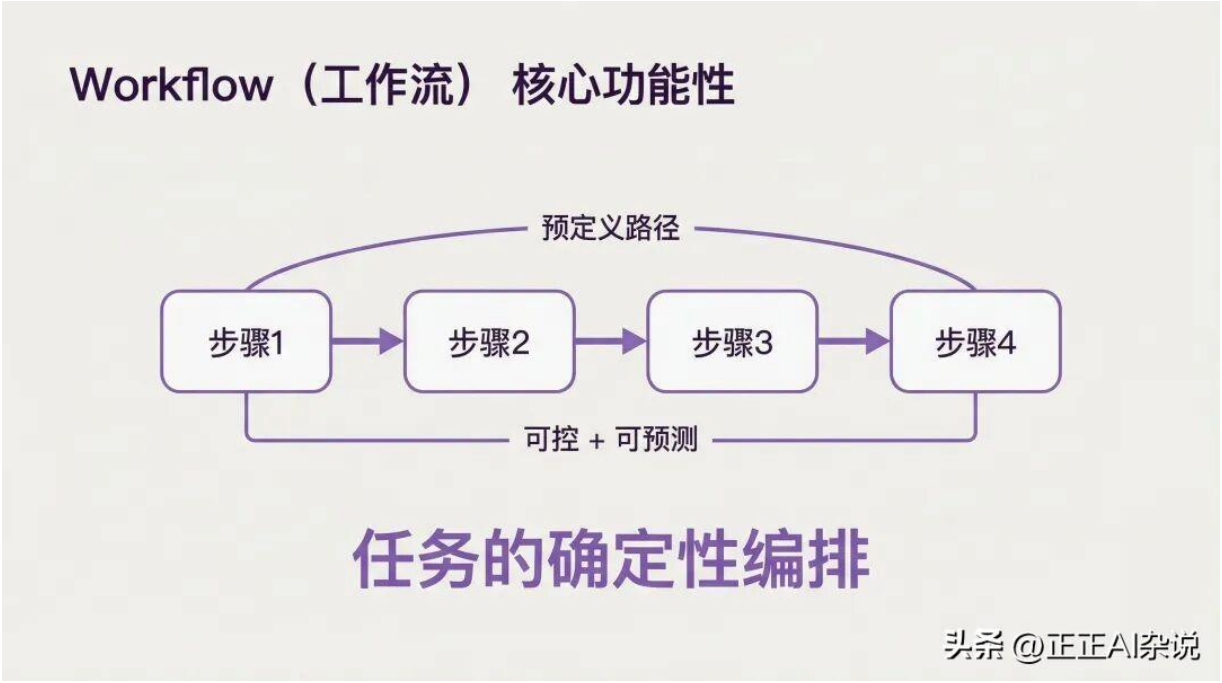

图示：Workflow 组件解析

- **架构洞察：用硬规则对抗软逻辑**
    - **熵减机制：** 模型的推理具有随机性。Workflow 的价值在于将人类的最佳实践（SOP）固化为代码逻辑。
    - **骨架作用：** 以内容创作为例，它规定了先选题、再大纲、后正文的顺序。无论模型在某个环节如何发散，整个业务流程的骨架是锁死的。这保证了业务交付的下限。
- **使用边界：**
    - **Workflow 优先原则：** 只要任务路径是可预测的、线性的（如审批流、报销、数据清洗），永远优先使用 Workflow，而不是 Agent。

认知与决策层：Agent (Autonomous Logic)

技术定义： 具备环境感知与动态规划能力的循环系统
核心隐喻：前额叶皮层

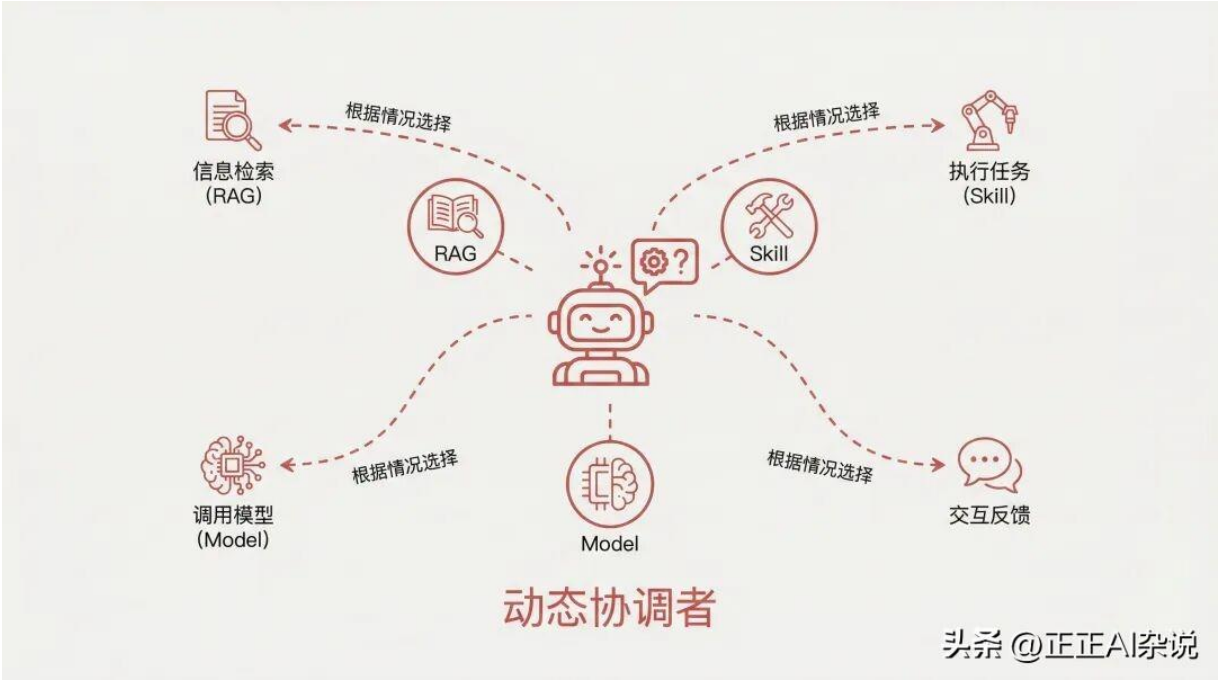

图示：Agent 组件解析

- **架构洞察：用算力换取灵活性**
    - **高阶形态：** Agent 是一个闭环控制系统。它利用引擎（Model）的能力，不断进行「观察-思考-行动」的循环。
    - **最后一道防线：** Agent 存在的意义，是为了处理 Workflow 无法覆盖的长尾复杂场景。它是用来处理意外的，而不是处理日常的。当传送带断裂时，机械运动失效，才需要 Agent 介入。
- **使用边界：**
    - **慎用原则：** Agent 意味着不可控和高成本。能用机械结构（Workflow）解决的问题，绝不动用生物算力（Agent）。
    - **适用场景：** 目标模糊、路径非线性、多步动态决策。

4. 感知与免疫系统 (The Feedback)

这是系统的**自我纠错机制**，解决了质量与进化的问题。 如果说前三个系统构成了 AI 的肉身，那么 Evals 就是它的**痛觉神经与免疫细胞**。

在这个架构中，Eval 和 Guardrail 不是事后的质检员，而是贯穿全流程的生命体征监测仪。

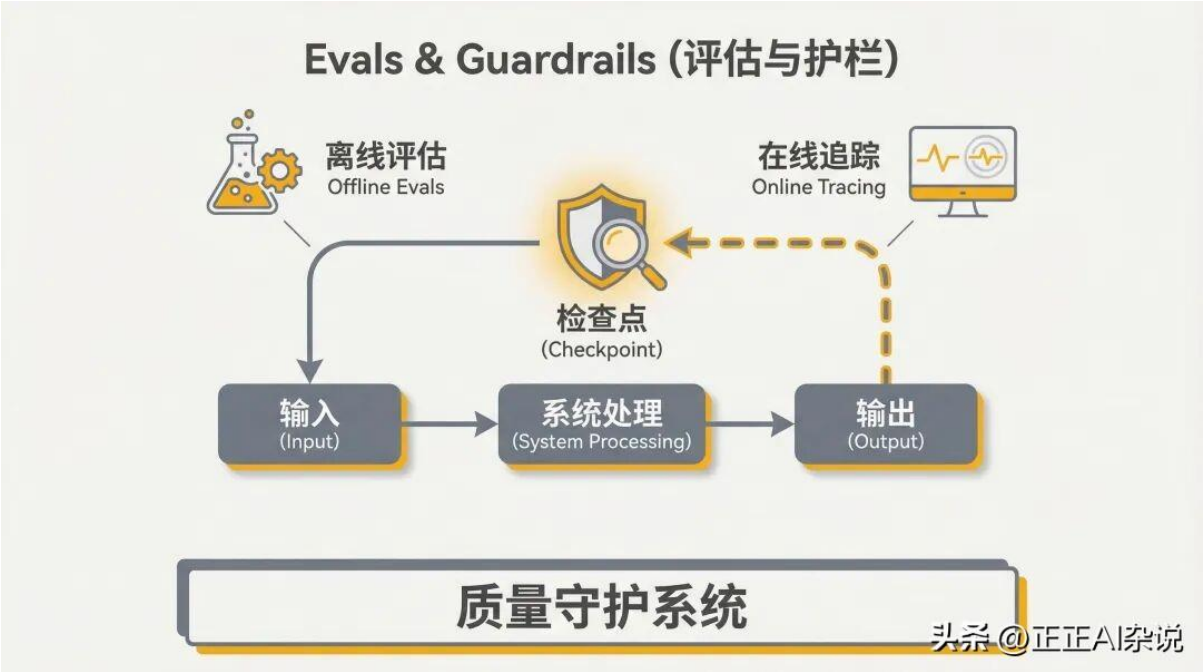

图示：Evals 组件解析

离线评估（Offline Evals）：系统的定期体检

- **技术定义：** 基于黄金数据集（Golden Dataset）的自动化测试管线。
- **核心隐喻：体检与模拟考。**
- **架构洞察：定义什么是好的标准。** 在传统软件工程中，我们要的是精准匹配。但在 AI 工程中，我们要的是语义相似度或逻辑正确性。
    - **针对 Model：** 这里的 Evals 是智商测试。换了新模型，逻辑推理能力提升了还是下降了？
    - **针对 RAG：** 这里的 Evals 是视力测试。召回的文档准确吗？有没有遗漏关键信息？（如 Ragas 框架）。
    - **针对 Skill：** 这里的 Evals 是动作测试。工具调用的参数格式对不对？成功率是多少？

在线监控（Online Tracing）：系统的痛觉神经

- **技术定义：** 基于 Trace 的全链路追踪与观测
- **核心隐喻：痛觉与本体感。**
- **架构洞察：让黑盒变透明。** 当 AI 回答错误时，痛觉神经能帮你瞬间定位病灶：

    - 是**眼睛**瞎了？（RAG 没查到数据）
    - 是**脑子**糊涂了？（Model 出现了幻觉）
    - 还是**手脚**笨拙？（Skill 报错）
    - 亦或是**骨架**散了？（Workflow 逻辑分支走错了）

安全护栏 (Guardrails)：系统的免疫屏障

- **技术定义：** 输入输出的过滤与拦截机制。
- **核心隐喻：白细胞与免疫系统**。
- **架构洞察：最后的防线。** 它负责识别并拦截病毒（恶意攻击、Prompt 注入）和病变细胞（输出违规、泄露隐私）。它不参与思考，但它拥有一票否决权，确保系统不会因为吃坏了东西而暴毙。

解构系统设计的三个底层逻辑

将系统如此分层，遵循了 AI 工程化的三个核心法则：

1. 祛魅 (Demystification)：将神还原为组件

我们必须打破对单体模型的崇拜。在系统架构中，大模型被降维打击为一个概率性的推理引擎。

它很重要，但它只是汽车的发动机。没有 RAG（油箱）、Workflow（变速箱）和 Skill（轮子），发动机不仅跑不远，还容易炸缸。

架构师的职责，就是不再把希望寄托在模型的灵光一现，而是建立一套机制来利用它的能力，同时规避它的缺陷。

2. 解耦 (Decoupling)：分离变与不变

这是系统设计的最高智慧。

- **模型是易变的：** 它的能力在进化，它的版本在迭代，它是系统中最不稳定的变量。
- **架构是恒定的：** 你的业务逻辑（Workflow）、你的数据资产（RAG）、你的工具接口（Skill/MCP）是公司的护城河。

- 通过分层，我们将**流动的智力**注入到**固定的结构**中。当新的模型发布时，只需要替换底层的“引擎”，而整套生产线依然能高效运转。这才是可演进的架构。

3. 归因 (Attribution)：给不确定性笼子

当 AI 产品出错时，传统的黑箱模式让人束手无策。但分层架构给了我们精准的调试能力：

- 事实错了？去修 RAG，别调 Prompt。
- 流程乱了？去改 Workflow，别怪模型。
- 意图理解歪了？这才是模型的锅。
- **架构的本质，就是把不确定性的模型，关进确定性的系统笼子里。** 我们用 Workflow 约束它的路径，用 RAG 限制它的发散，用 Skill 规范它的动作。

Part 3 | 基于不确定性的场景选择指南

本章要点

· 技术选型的本质是将不同类型的不确定性分发给最适合的组件
· 遵循"三步走"协议：诊断瓶颈、边界判定、SFT 博弈
· 能用确定性代码实现的，优先用 Skill/Workflow 而非让模型推理
· 选型的最高境界是守拙：把不确定性限制在最小认知范围内

理解了这套**精密的四大生理系统**，下一步就是工程实践中最关键的环节：技术选型。

这需要对业务场景中的不确定性进行精准的病理切片。产品架构设计的本质，就是将不同类型的不确定性，分发给系统中最适合处理它的组件。

在动手设计方案前，我们可以遵循这套三步走的架构决策协议。

第一步：诊断核心瓶颈

我们要问系统一个问题：在这个任务中，最让你头疼的难点究竟是什么？虽然构建系统通常遵循先骨架（Workflow）、后血肉（RAG）、再灵魂（Agent）的顺序，但在诊断不确定性时，我们应遵循瓶颈优先原则：先解决最致命的那个瓶颈，再逐层叠加其他组件。

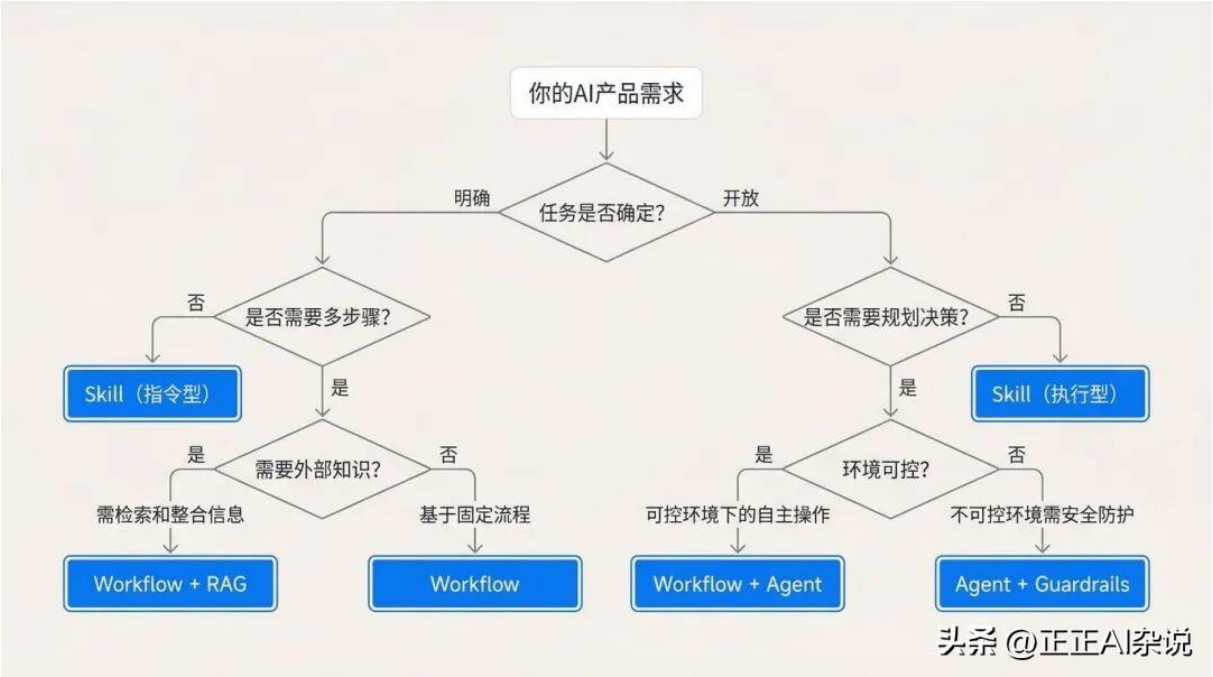

图示：AI 架构选型决策树

1. 执行不确定性 → 依赖技能与流程 (Skill & Workflow)

- **症状：** 目标极其明确(如"计算个税"或"审批报销")，但步骤繁琐、易出错，或者必须遵循严格的行业合规标准。这是纪律问题，非智力问题。
- **误区：** 凡是能用确定性代码实现的，优先用执行型 Skill 或 Workflow，而非让模型推理。

2. 信息不确定性 → 依赖检索 (RAG)

- **症状：** 任务依赖私有数据、实时新闻或极度垂直的行业知识，且这些信息是流动的。
- **误区：** 切记，不要试图通过微调（Fine-tuning）来解决信息的时效性问题。模型是逻辑的容器，不是数据的硬盘。

3. 策略不确定性 → 依赖智能体 (Agent)

- **症状：** 任务路径无法预设，必须根据中间结果动态调整方向（如“根据预算和天气实时调整旅行路线”）。
- **误区：** 如果路径是线性的（S1->S2->S3），强行上 Agent 只会增加不可控性和延迟。

4. 认知不确定性 → 依赖模型 (Model)

- **症状：** 用户的意图是模糊的（帮我写点东西），或者需要高度的逻辑推理和语义理解。
- **处方：** 这是一个典型的脑力问题。核心算力应投入在 **Prompt Engineeri zg** 和 **模型推理** 上。

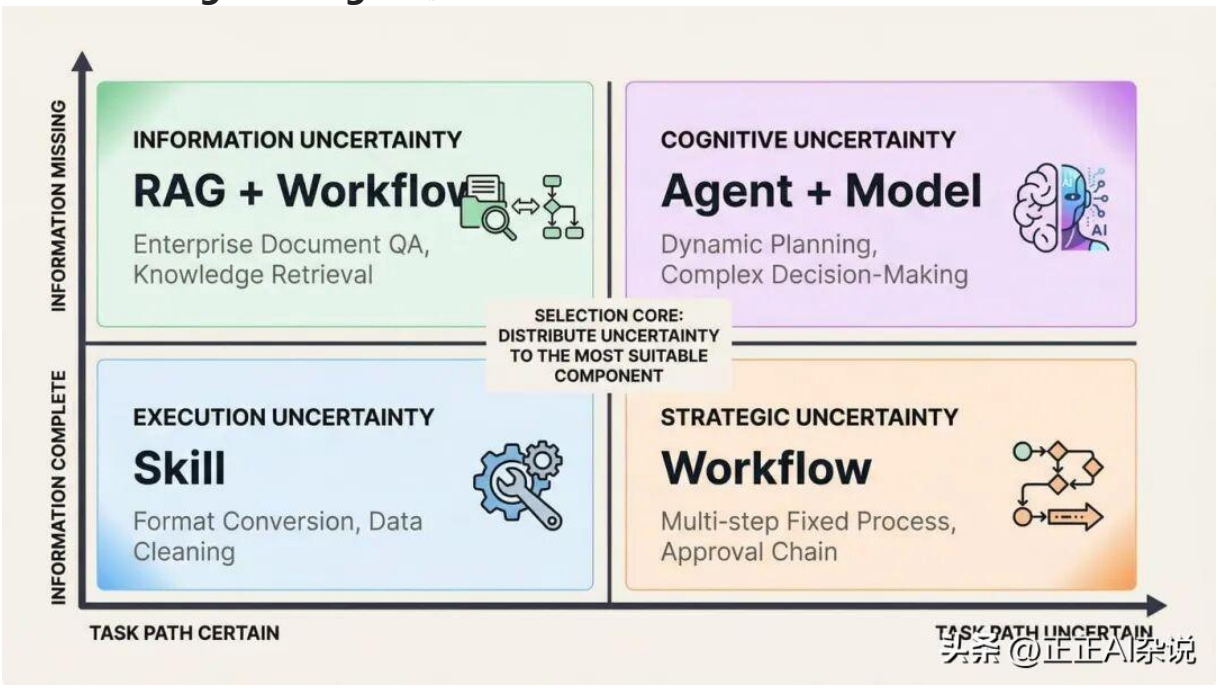

图示：不确定性类型矩阵

第二步：组件边界判定表（The Boundary Checklist）

这是产品架构师的自检清单。通过这套**排除法**，我们可以清晰地**界定每个组件的职责边界，避免把能力放错位置**。

1. 什么该放在【模型（Model)】里？

模型适合承载的只有三类东西：通用语言能力、逻辑推理能力、以及跨行业成立的底层常识。

架构师自检公式：

“这个知识点，一年后还成立吗？”

“换个平台/场景，它还适用吗？”

“模型升级后，这个微调会被直接覆盖吗？”

如果答案是否定的，那么它属于业务逻辑，不该训练进模型权重。

2. 什么该做成【Skill】？

Skill 的本质是：**稳定 Know-how 的封装**，它必须是像机械臂一样可靠的工具。

适合封装为 Skill 的：

- 行业 Workflow 中的关键原子操作。
- 固定套路(如:提取关键词、格式清洗)。
- 成熟的操作模板(如:将 A 格式转换为 B 格式)。

架构师自检公式：

- **稳定 Know-how + 可标准化调用（明确 Input/Output） + 不依赖实时变动 = Skill**

3. 什么该交给【RAG / 知识库】？

RAG 的核心属性是：**易变性 (Volatility) + 专有性 (Proprietary)**。

典型场景：

- 用户自己的历史数据（User Profile）。
- 每天变化的平台规则、热点。
- 千人千面的个性化标准。

架构师自检公式：

- 这个信息是不是：今天对，三个月后可能错？
- 不同用户的答案是否完全不同？**如果是，就必须用 RAG**

4. 什么该显性化为【Workflow】？

这是产品设计中最微妙的判断。Workflow 既是约束模型的绳索，也是引导用户的地图。

显性 vs 隐性：

- **显性化（让用户看到步骤）：** 当用户不知道怎么做时。Workflow 能帮用户拆解任务，降低心理负担。可以是显性化展示，或者将点击权利让渡给用户（通过 GUI 界面引导使用），例如：AI 写作软件中的"选题→大纲→生成"三步走。
- **隐性化（自动化执行）：** 当用户只是不想做时。不要让繁琐的内部判断打断用户，直接在后台自动化。
- **帮用户想清楚下一步 → 显性 Workflow**
- **帮用户省去操作步骤 → 隐性 Workflow / Automation**

5. 什么时候该启用【Agent】？

Agent ≠ 能力增强器，Agent = 动态编排器。

适合 Agent：

- 多步协作，且步骤之间存在依赖关系。
- 需要调用 Skill + RAG + 模型 共同完成。
- 需要管理长周期的上下文状态。

不适合 Agent：

- 用来掩盖模型能力不足（如果模型本身很笨，Agent 是救不了的）。
- 强行自动化一个本就不稳定的任务（结果往往是灾难性的连锁反应）。

架构师自检公式：

如果没有 Agent，这件事的人工逻辑是否成立？ 如果不成立，Agent 只是在自动化一个错误。只有当逻辑成立但路径太复杂时，才由 Agent 代劳。

图示：Workflow vs Agent 对比表

6. 什么时候系统在裸奔（Evals）？

别等用户投诉了才发现 AI 在胡说八道。

架构师自检公式：

- 我有定义好什么是好结果的黄金样本吗？

- 我能在一分钟内通过 Trace 定位是 RAG 错了还是 Prompt 错了吗？
- 如果没有，系统就是在裸奔

图示：组件边界判定检查清单

第三步：进阶辨析——SFT (微调) 与架构的博弈

在进行架构选型时，有一个必须正面回答的问题：**垂直领域的微调 (SFT)，在这个结构中到底算什么？**

很多团队最大的误区，就是把 SFT 当作解决一切问题的银弹，试图用微调来解决幻觉、解决逻辑错误、甚至解决知识更新。

在我们的精密机器架构中，**SFT 并不是一个独立的层级，而是对核心动力层（Model）的深度打磨。**

如果把通用大模型比作一台通用引擎，那么 SFT 就是把这台引擎拉回原厂，进行特种改装，让它更适配你设计的整车底盘。

1. SFT vs. RAG：记忆的内化与外置

- **误区：** 试图通过 SFT 让模型记住企业的海量文档或实时库存。
- **架构洞察：** 模型参数是昂贵的、静态的，数据库是廉价的、动态的。

    - **SFT (微调)：** 适合学习格式与风格（Form & Style）、指令遵循增强（Instruction Following）和特定任务的推理路径固化。例如：学会像医生一样说话，学会输出符合公司规范的 JSON 格式。
    - **RAG (检索)：** 适合存储事实与数据（Fact & Data）。
- **决策红线：** 凡是会变的数据，一个字都不要训练进模型。**用 SFT 学会如何阅读文档，用 RAG 提供文档本身。**

2. SFT vs. Workflow：流程的内化与显性

- **误区：** 试图通过 SFT 让模型学会一套包含 50 个步骤的复杂审批流。
- **架构洞察：**
    - **SFT (微调)：** 适合提升**单点原子任务**的良率。如病历结构化，通用模型只有 80% 准确率，通过 SFT 喂入 1000 条高质量数据，将其提升到 99%。
    - **Workflow (流程)：** 负责串联这 50 个步骤的**逻辑跳转**。
- **决策红线：** 流程逻辑必须显性化在代码（Workflow）中，而不是隐性化在模型参数（SFT）里。

3. SFT vs. Prompt：以空间换时间

- **架构洞察：** SFT 的另一个核心工程价值是**降低成本与延迟**。
    - 当你的 System Prompt 写了 3000 字的规则和 Few-shot 案例，过于复杂导致成本高企时。通过 SFT 将规则**“内化”**进模型参数。微调后的模型，不需要任何 Prompt 铺垫，就能直接输出完美结果。
- **决策公式：高频调用 × 复杂 Prompt = 考虑 SFT**

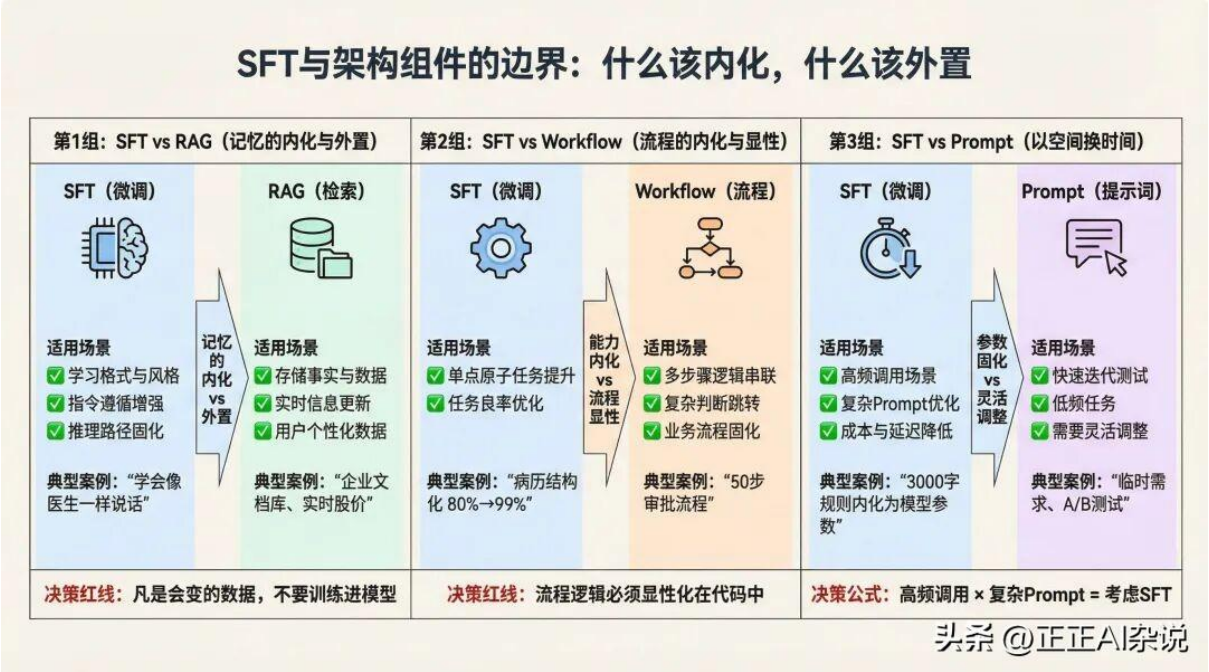

图示：SFT 与架构组件边界对比

选型的本质是守拙

架构选型的最高境界，不是追求最先进的概念，而是守拙。

- 能用 **Skill** 写死的代码，绝不让模型去猜；
- 能用 **Workflow** 固化的流程，绝不让 Agent 去试；
- 能用 **RAG** 外挂的知识，绝不塞进模型去背。

把不确定性限制在最小的认知范围内，用最大的确定性架构去承载它。 这才是应对复杂真实场景的生存之道。

回到我们最初的问题：Agent、Workflow、RAG 还是 Skill？

我的答案是：混合。

真正的 AI 系统架构师，不会执着于单一技术的优劣，而是懂得混搭。

就像一位优秀的厨师，不会只用一种调料，而是懂得如何将盐、糖、醋、酒、姜、蒜巧妙组合，才能烹出一道好菜。

AI 落地，不在于谁最强，而在于谁最配。

希望这篇文章，能成为你构建 AI 系统时的一张思维地图。

结语：从解剖室到手术台

至此，我们已经完成了对 AI 智能系统的全景解剖。

通过这万字拆解，我们祛除了对单体智能的迷信，建立了一套基于工程分层的架构直觉。我们拥有了六大生理组件，也手握一份应对不确定性的选型指南。

但在真实的商业战场上，事情往往没有这么漂亮。

拥有地图并不代表不会迷路。 回望两年多前，在那个大模型刚刚爆发、还没有所谓架构共识的混沌时期，我曾带领团队进行过长达一年的艰难探索。 在那段时间里，我们曾因误判了模型能力的边界，掉进过 SFT 的陷阱，也曾被迫用笨重的 Workflow 去挽救濒临崩溃的用户体验。

更重要的是，一个巨大的阴影始终笼罩在所有架构师心头： 我们今天费尽心力搭建的这套系统，究竟是 AI 时代的终极形态，还是仅仅是过渡期的义肢？ 当未来的模型参数无限扩张，推理能力达到专家水平时，我们今天设计的 RAG、Workflow、Skill 会沦为废铁吗？

在接下来的下篇（实战与演进篇）中，我将深度复盘早期操盘的一款 AI 产品，剖析我们是如何在那个草莽年代挣扎，又是如何无意中通过双轨制防御让产品获得了存活的机会。 以及展望未来，在义肢时代我们将如何构建我们的产品竞争壁垒？

万字拆解谁才是 AI 落地的终极解药

（下）

在上篇中，我们提出：

- AI 正从单体智能走向系统智能；
- 真正的落地不靠模型多强，而靠架构如何分配不确定性；
- 用人体四大生理系统隐喻，构建了 **Model + RAG + Skill + Workflow + Agent + Evals/Guardrails** 的完整框架。

但理论终需实践检验。本篇将通过一个真实的 AI 内容产品案例，进行深度复盘与架构推演：

- 拿着屠龙刀砍柴，却用木棍屠龙，揭示 AI 产品最常见的能力错配；
- 为什么不恰当的 SFT 微调，可能是一场 **ROI 极低**的资产泡沫？
- 如何靠一套**慢变量系统**构建系统韧性？
- 更重要的是，**如果今天重来，我会如何用最新技术（Agent/RAG/Skill）重构它？**

如果你正在设计 AI 产品、搭建智能系统，或曾因模型幻觉、投入打水漂而焦虑，这篇实战复盘+架构推演，或许正是你需要的避坑指南。

Part 4｜架构复盘：一个内容产品的结构性失误

本章要点

· 核心失误：拿着屠龙刀（优化能力）砍柴，却用木棍（创造能力）屠龙
· SFT 陷阱：在注定演进的基座上雕花，新模型发布后投入归零
· 隐性救赎：用慢变量（Workflow/RAG）对抗快变量（Model），获得架构韧性
· 真正的护城河是承载真实世界复杂性的系统，而非模型有多聪明

为了更深入地理解这套理论，我复盘一个曾经操盘过的 AI 内容产品。这个产品旨在辅助创作者从 0 到 1 产出高质量文章。

站在今天的系统工程视角看，该产品早期的困境，并非单一的决策失误，而是典型的**技术周期与产品愿景的错配**。我们试图在基础设施尚未成熟时（2023 年），去构建一个过于理想化的智能系统。

今天的复盘不包含战略层面的反思（当时选择的用户群、产品价值承诺也存在重大失误），本文重点讨论产品架构设计层面的部分。

第一幕：能力错配 —— 在错误的能力区间对赌

我们犯了一个早期产品常见的错误：无视模型物理特性，试图用短板攻克天险。

错误诊断：核心价值的误判

- **当时的模型具备两大类能力：**
- **创造力（0 到 1）：** 弱。就像一根脆弱的木棍，容易断裂（幻觉、逻辑混乱）。
- **优化力（1 到 100）：** 强。就像一把锋利的屠龙刀，削铁如泥（改写、总结、润色）。
- **决策失误：** 我们虽然开发了基于素材的「仿写/改写」功能，却将其视为**边缘辅助**；反而将极其依赖模型内功的「从 0 到 1 自由创作」，定义为产品的**核心主流程**。
- **实质：这是一种典型的架构重心战略误判。**我们拿着屠龙刀（1-100 的优化能力）去砍柴（做边缘功能），却试图用木棍（0-1 的创造能力）去屠龙（做核心主流程）。
- **后果：** 我们强行要求模型承担它扛不住的创造压力，结果无论如何微调 Prompt，产出始终徘徊在 60 分上下不可用状态。而真正能打的优化能力，却被埋没在工具箱的角落。

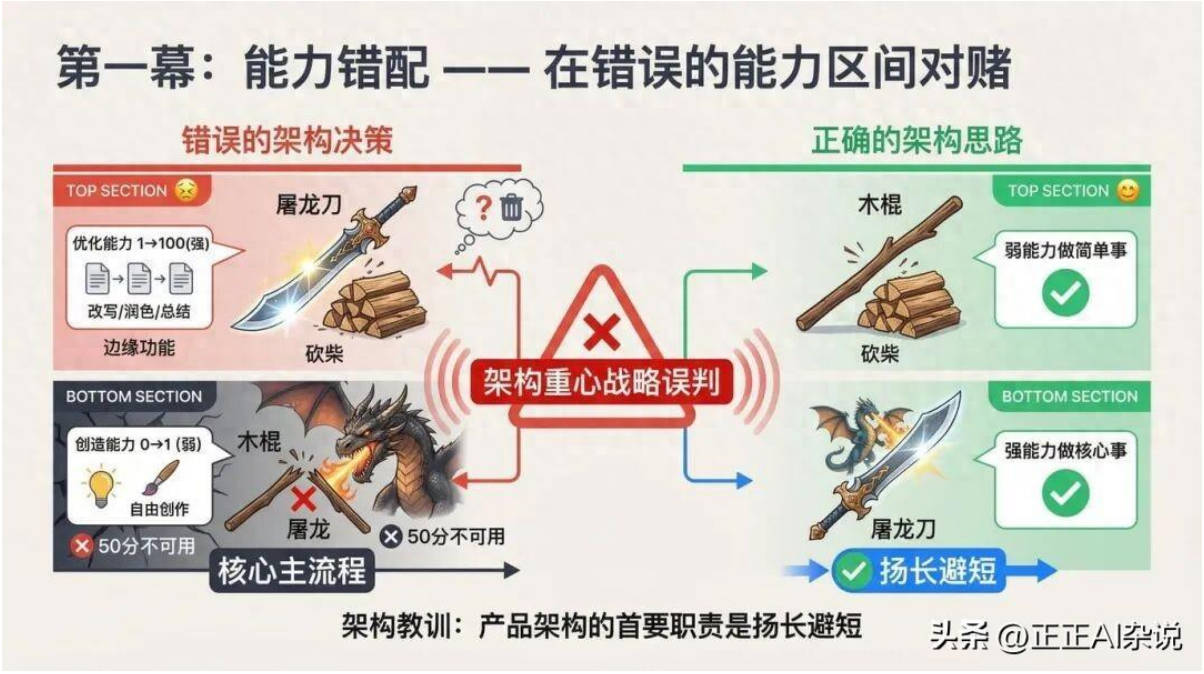

图示：能力错配对比图

架构教训：产品架构的首要职责是扬长避短。如果模型本质上是一个金牌编辑（**擅长润色**），**就不该在架构设计上强行逼它去当一个**天才作家（负责原创）。

第二幕：SFT 的陷阱 —— 资产泡沫化

为了弥补创造力的不足，我们采取了当时行业最主流的技术路线：**垂直领域微调 (SFT)**。我们和大多数 AI 创业团队一样，希望能通过微调建立壁垒。

错误诊断：战术上的勤奋，掩盖了战略上的代差

- **雕花的艺术（形似）：** 我们收集了大量优质内容，试图通过 SFT 让模型学会高质量写作。在技术上，我们做到了形似，模型学会了 Emoji、三段式结构和网感文风。
- **基座的局限（神散）：** 但皮囊的精致掩盖不了灵魂的空洞。由于当时的底座模型本身逻辑推理能力不足，SFT 只是让它学会了用最潮流的语气说废话。这就是典型的在屎上雕花。
- **资产的泡沫（归零）：** 更致命的是，我们是在一个注定演进的基座上进行这些投入。当下一代更强的通用大模型发布时，我们辛苦积累的 SFT 专用模型，其表现瞬间不如新基座的 Zero-

shot 能力。这其实早有预兆，**GPT-3.5** 的出现就已然干倒一批基于 **GPT-3** 微调的 **AI** 应用公司。

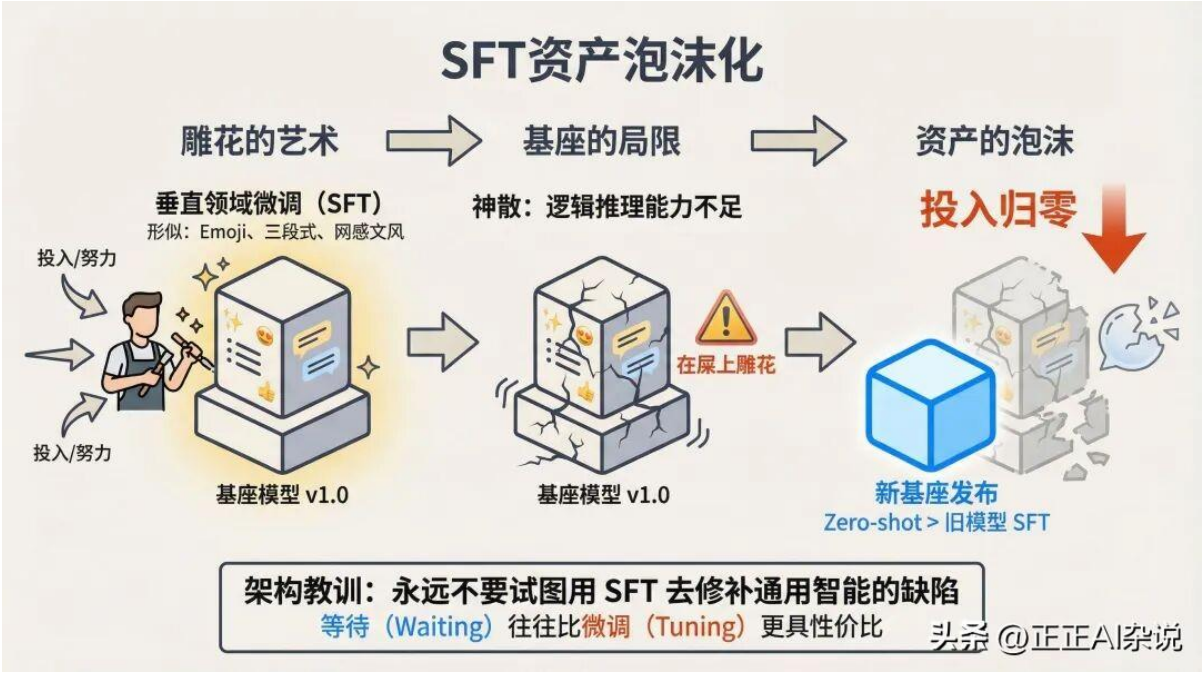

图示：SFT 资产泡沫化示意图

架构教训：永远不要试图用 SFT 去修补通用智能的缺陷，对于通用能力的不足，等待（Waiting）往往比微调（Tuning）更具性价比。

第三幕：隐性的救赎 —— 双轨制的防御性胜利

在激进的技术探索之外，出于产品经理的职业直觉，我们还保留了另一条务实的产品线。

当时的判断是：面对一个尚不稳定的概率性模型，普通用户无法靠对话框完成复杂的生产任务。为了兜底，我们坚持引入了厚重的 **SaaS 业务流程**。没想到，正是这套**用来防御的传统架构**，最终成为了产品的救生艇。

1. 交互的防御：用 GUI 流程对抗不确定性

- **设计逻辑：** 我们没有采用当时最酷炫的单一大框对话模式，而是构建了一套**全流程的 GUI 交互（选题-RAG 检索-生成-配图-分发）**。

- **实质：** 这是 **Workflow** 的显性化。我们用刚性的业务流程（SOP），去对冲了模型胡说八道的风险。当模型生成失控时，结构化的流程保证了用户体验没有崩盘。

2. 场景的防御：把「改写」作为基础配置

- **设计逻辑：** 我们保留并打磨了基于选题素材/用户指定材料的仿写/改写功能，并引入 RAG（知识库）来管理用户素材。
- **实质：** 事实证明，用户的高频痛点往往不是无中生有，而是借题发挥，这成为了对模型能力边界的有效补充。

深度解构：为什么防御反而成了核心？

现在回看，我们其实在过程中完成了一个关键转移：从模型能力产品到行业系统产品。

- **价值锚点的转移：**用户的价值感知从生成质量过渡到**到**流程完整性。用户觉得：虽然它写得不够完美，但这个流程帮我理清了思路，而且管理素材很方便。**这类价值，不会便因为模型升级而消失。**
- **敏捷度的解耦：**把模型短板变成了系统的一部分。模型只负责某一步的生成，而非全部承担最终的质量责任，**这也大幅降低了产品对模型版本的敏感度。**
- **用慢变量对抗快变量：**
    - **模型时间尺度:** 3～6 个月（极速迭代，易被颠覆）。
    - **行业时间尺度:** 3～5 年（相对稳定，SOP 不变）。
    - 我们构建的这套 Workflow，本质上是用一个**慢变量(行业系统)**，去对抗一个**快变量(模型迭代)**。

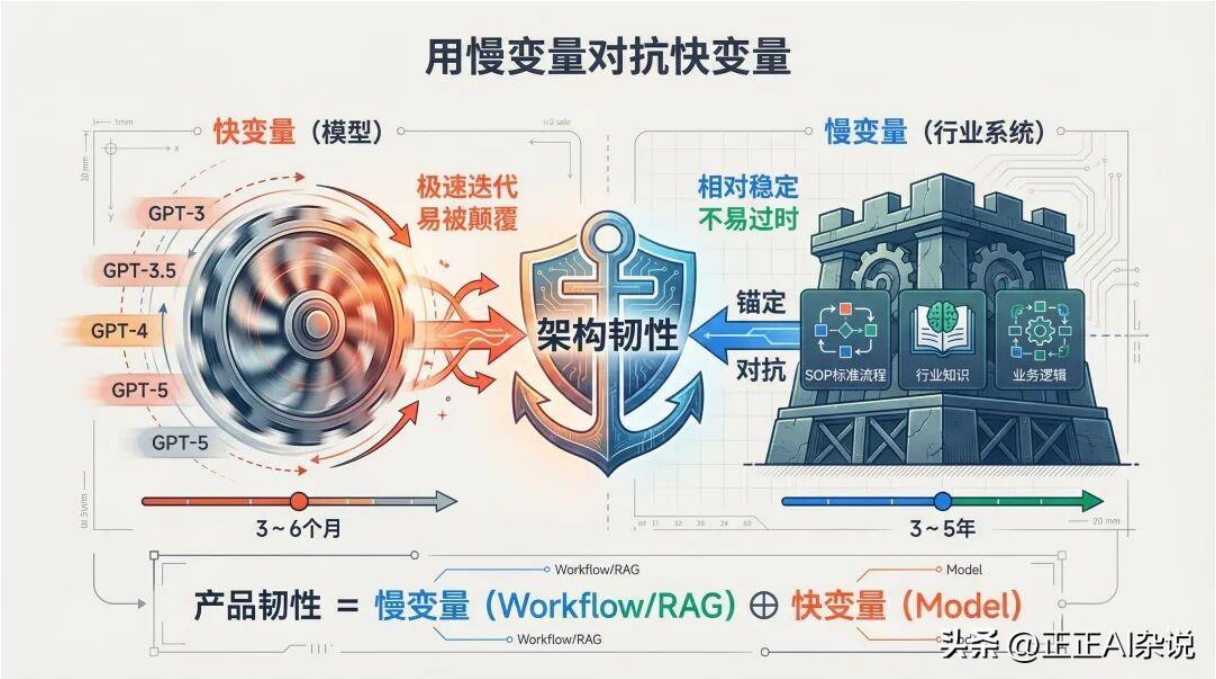

图示：慢变量对抗

总结：架构的韧性

这次复盘也呈现了我们在那个混沌时期双重下注的结果：

- **进攻端（SFT）：** 我们紧跟当时的技术潮流，试图冲击创造力的上限，但遗憾地遭遇了基座模型代差的降维打击。
- **防守端（Workflow）：** 我们坚守了产品的可用性底线，通过流程和知识库，稳住了用户的基本盘。

我并没有陪这个产品走到最后。但在我离开后，它维持着这种分裂但平衡的状态，并依然运营至今。

这也揭示了 AI 产品真正的护城河：

不纯粹依赖模型有多聪明，而是产品承载了多少真实世界的复杂性。正是因为我们把业务逻辑从模型中解耦出来，固化在 Workflow、RAG 中，这个产品才没有随着早期模型策略的失误而崩塌，而是获得了一个边跑边修的机会。

Part 5｜重构蓝图：如果今天重来，我会怎么做

本章要点

- **定位升级**：放弃全自动幻想，从内容创造者转型为内容放大器，以对抗平庸、责任与同质化三大陷阱。
- **架构哲学**：构建最小完备业务内核（Model + RAG + 官方 Skill + Workflow），确保可靠闭环。
- **交互克制**：拒绝全自动黑箱，建立 Agent 处理模糊意图 + Workflow 锁死执行边界的人机共驾模式。
- **生态壁垒**：通过 MCP 与自定义 Skill 开放接口，让**用户沉淀的资产**成为对抗模型快速迭代的终极护城河。

如果今天让我重新面对当年那个产品命题：辅助创作者产出高质量内容，我会怎么做？

虽已离开原团队近两年，不再有实际操盘的机会。

但也正是这段距离，让我能更冷静地审视：在技术红利与惨烈竞争并存的当下，一个真正有壁垒的内容智能产品，应该长成什么样子？

简单的套壳生成已无路可走。但也正是在这种压力下，我当年未能实现的个人工作台愿景，可能反而有了最坚实的落地土壤。

其核心架构：Agen + 工具集（Skill/Workflow）+ 知识库（RAG），早在 2023 年中就已成型（见下图），从运营工作台延伸至千行百业的个人工作台。它用**刚性流程对抗模型不确定性，用开放生态沉淀用户资产**。

虽然当时受限于模型能力不够强而未能完全落地，但这些早期的架构思考，为今天的架构推演提供了最坚实的起点。

图示 1：运营工作台架构图

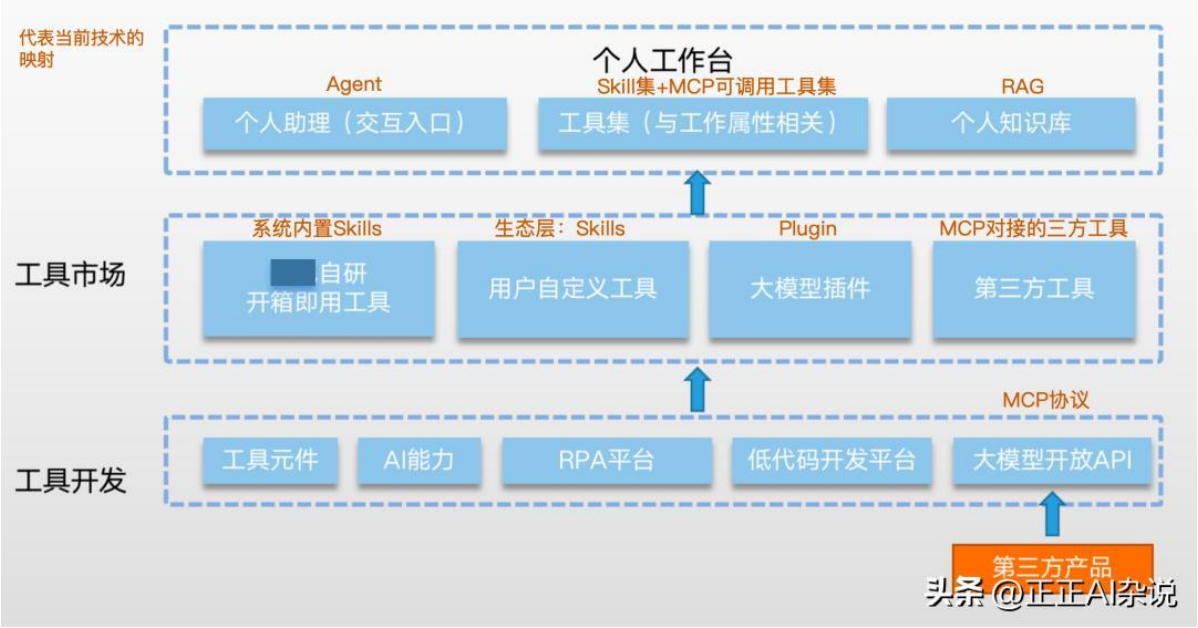

图示 2：个人工作台架构图

立足当下，我不会再追求「更好的生成器」，而是利用当下技术红利，把它重构成一个：懂业务的智能参谋。

以下设计构思不涉及具体的业务，仅是一份基于血泪教训的架构推演。

我想，真正的实践，不仅是动手建造，更是把经验变成他人的路标。

推演开始

1. 定位重构：从创造者转向放大器 (Product Redefinition)

核心反思:模型越强,我们越要警惕全自动的诱惑。

这是此次重构的灵魂。即使在模型能力极强的今天，我依然坚定地认为：产品必须定位为内容放大器，而非内容创造者。

新形态定义:

- **Input:** 用户的火种(一段录音、一篇喜欢的内容、一份草稿)。
- **Output:** AI 的燎原(全平台的优质内容矩阵、多文体分发、风格化润色)。

这会是一个痛苦但很有必要的市场筛选。

如果做创造者，取悦想要一键生成、无上下文需求的低投入用户，就要面临大厂免费工具的降维打击和用户的极低忠诚度。

如果做放大器，服务的就是有较高投入时间、有一定的上下文和工作流资产的高锁定性用户。只有在这个领域，产品的壁垒才成立。

这意味着，产品需要对抗三个致命的陷阱：

陷阱一：平庸陷阱 —— AI 生成的都是废话？

核心逻辑：AI 无法创造金子，但它可以帮你找到金子、打磨金子并量产金子。

如果定位为创造者（直接 0 到 1），AI 只能产出平庸的废话。而作为放大器，就可以利用**当下的技术红利**，实现 3 个放大：

图示：三个放大器的工作原理

- **决策放大（提升胜率）—— 帮你找对**
    - **痛点：** 很多时候，内容平庸不是因为写得差，而是因为**选题本身就平庸**。用户的灵感往往是随机的，不知道哪个选题能火。
    - **解法：** 利用 **RAG + 数据分析** 充当情报雷达，分析全网爆款，在杂乱信息中放大最有价值的选题信号。
    -
- **纵向放大（提升品质）—— 帮你写好**

    - **痛点：** 很多专家拥有 100 分的**洞察**，但只有 60 分的**表达**（逻辑跳跃、口语化）。
    - **旧瓶颈（2023）：** 早期的模型往往会产生磨皮效应，在润色时把犀利的观点稀释成平庸的片汤话。
    - **新红利（Now）：** 现在的模型已经具备了高保真的重构能力。它能在完全保留你 100 分洞察（棱角、情绪、黑话）的前提下，完美地把口语草稿清洗、结构化为 80 分的专业表达。
    -
- **横向放大（提升声量）—— 帮你传开**
    - **痛点：** 好内容不应是孤品。一篇深度长文（1 个 80 分），应该能转化为小红书笔记、推特金句、短视频脚本（N 个 80 分）。
    - **旧瓶颈（2023）：** 早期的改写是机械切割。它只会机械地缩短字数、堆砌 Emoji，产出的内容充满 AI 味，缺乏真正的平台原生感（Native Feel）。
    - **新红利（Now）：** 利用 **Skill** 引入不同平台的流量密码（如小红书的情绪钩子），实现一次生产，全域爆火。
    -

陷阱二：责任陷阱 —— 出错了算谁的？

核心逻辑：重新划分执行与决策的边界，重新分配不确定性。

- **痛点与悖论：** 这是一个关于价值与责任的跷跷板，单纯替用户写（创造者），一旦出错就是产品的锅。单纯让用户自己写（工具），产品又显得价值单薄。

图示：责任分配的新契约

- **解法：** 将产品定位为放大器，建立一种新型的人机契约：
    - **产品承担 100% 的执行责任：** 保证文笔流畅、格式精准、分发高效。
    - **产品分担 50% 的决策压力：** 不替用户拍板，但提供**数据支撑**（如：基于历史数据，这个标题的点击率预测比那个高 20%）。
    - **归还 100% 的最终决策权：** 最终选哪个，依然由用户按下确认键。
- **价值控制：** 产品不再是一个不可控的枪手，而是一套自带战术雷达的外骨骼机甲。雷达提供情报，机甲提供动力，但扣动扳机的，永远是人类指挥官。

陷阱三：同质化陷阱 —— 凭什么用户付费？

核心逻辑：构造产品的关键壁垒

- **逻辑:** 如果产品只是用来生成内容，竞争对手将是各种免费的大模型底座。它们模型迭代更快，产品将没有任何胜算。
- **解法:** 用户付费买单的理由，可以是买那套确定性的 SOP，而不是买那个人人都有的生成能力。产品本身，不试图创造正确

性，而是收敛不确定性、放大有效信号、并对结果进行校验与兜底。

2. 架构重构：构建最小完备内核 (The Core Kernel)

核心洞察：架构设计的首要原则是关注点分离。为了支撑放大器定位，我们需要先把内核做实，再把生态做开。

在 Part 2 中，我们解剖了智能系统的六大理论组件。但在重构的起步阶段，我们需要区分系统内核与外部连接。

我将 Agent 定义为交互模式，将 MCP 定义为外部协议（这两者将在后文详述）。剥离掉它们后，剩下的四个实体层，构成了直接承载业务逻辑的最小完备内核。 这是一个官方预置的、保证产品能跑通放大器闭环的刚性骨架。

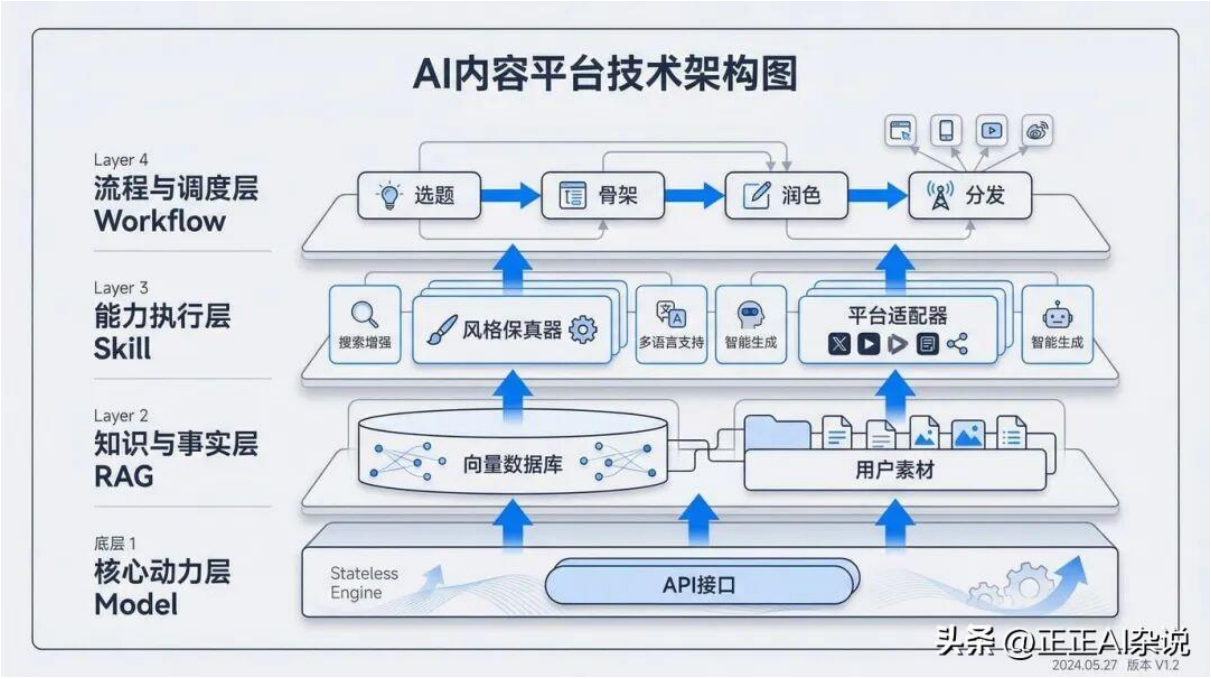

图示：最小完备内核架构

第一层：核心动力层 (Model) —— 极简的无状态底座

- **重构思路：彻底剥离**模型层的记忆和业务属性，将其视为**纯粹的文本推理引擎**。在代码层面，它仅仅是一个标准化的 API 调用接口。

- **预期价值：** 这种**热拔插设计**意味着：**当更高级的模型发布时，只需修改一行 API 配置，整个产品就能原地升级**，而无需重训任何数据，也不会丢失任何用户资产。

第二层：知识与事实层 (RAG) —— 高频更新的私有素材库

- **重构思路:** 构建一个秒级更新的**向量数据库**，专门存储用户的过往爆文、收藏素材、品牌/内容调性文档、个性化知识素材等。
- **预期价值：**这解决了灵感时差问题。**用户上一秒在浏览器插件里保存的素材，下一秒就能在写作中被精准引用**。
-

第三层：能力执行层 (Skill) —— 经验的原子化封装

- **重构思路：** 将虚无缥缈的内容创作心法，翻译成确定性的能力，强制模型在特定环节调用。注意，本层级仅讨论系统自带的能力（如官方提供的风格保真器），用户自定义的扩展能力将在生态层详述。
- **典型场景：**
    - **风格保真器：** 基于 RAG 读取用户历史语料库，提取个人化特征（高频词汇、情绪浓度等)，在润色时强制模型保持这些特征，确保输出像你的内容。
    - **平台适配器：** 将不同平台的流量密码封装成规则（小红书的 Emoji 密度与分段节奏等)，将一篇长文重构为符合各平台原生语言的多个版本。
- **预期价值：** 让输出结果从看运气变成了保下限，同时建立了通用模型无法复制的个性化壁垒。
-

第四层：流程与调度层 (Workflow) —— 锁死的生产流水线

- **重构思路：** 将金牌写手的方法论（选题策划 -> 内容借鉴 -> 骨架生成 -> 填充润色 -> 多渠道分发），固化为不可跳跃的 DAG（有向无环图）。
- **预期价值：** 它负责按住模型的手，保障生产流程，进一步提升效果下限。

3. 交互重构：Agent 的极度克制 (Restrained Agency)

既然有了灵魂（定位）和内核（架构），接下来我们要解决的是：这个前额叶如何与作为指挥官的人进行交互？

在 2023 年的规划中，我曾激进地设想过全自动 Agent：用户给一个目标，大模型自动生成规划并执行。但受限于当时的技术可行性（指令遵循差），我们做了一个极端的决定：彻底摒弃 Chat 对话框，回退到纯 GUI 的 Workflow。

站在今天，技术红利已允许重启 Agent，但我依然坚持极度克制。在工作台模式下，Agent 不应该试图成为替代你的 CEO，而是听你调遣的实习生。

我们需要构建一种 LUI（自然语言）+ GUI（图形界面）的混合交互模式：

- **守正（收敛）：**
    - **场景：** 确定的生产环节（如排版、审查、分发）。
    - **策略：** 坚持用 **Workflow + Skill**。哪怕 Agent 现在能做，也不让它自由发挥。
    - **价值：** 必须保证 **SOP 的刚性**。这些环节需要的是 100% 的精确和可控，而非 AI 的惊喜。
- **出奇（发散）：**
    - **场景：** 任务目标模糊的环节（如“不知道写什么选题”、“帮我规划下周内容”）。
    - **策略：** 重新引入 Chat 界面，允许用户输入模糊意图，利用 Agent 的推理能力进行意图对齐。
    - **价值：** 处理**模糊性（Ambiguity）**。这恰恰是 Workflow 的短板，却是 Agent 的天赋。
- **交互重构：从填空题到选择题**
    - **旧模式（2023）：** 用户必须在 GUI 上填完所有复杂的参数表单（痛苦的填空题），系统按部就班执行。
    - **新模式（Now） —— 提案决策流：**
- **用户给模糊目标（Chat）：** 下周要推新品，帮我规划 3 个选题。
- **Agent 给具体提案（Proposal）：** AI 调用 RAG 和 Skill，生成 3 个方案卡片。
- **用户做决策（Decision）：**用户点击其中一个方案。

- **系统跑流程（Workflow）：**确认后，系统界面重心切换至流水线开始生产。 同时，保留侧边栏入口，允许随时唤起 Agent 进行局部调整。
-

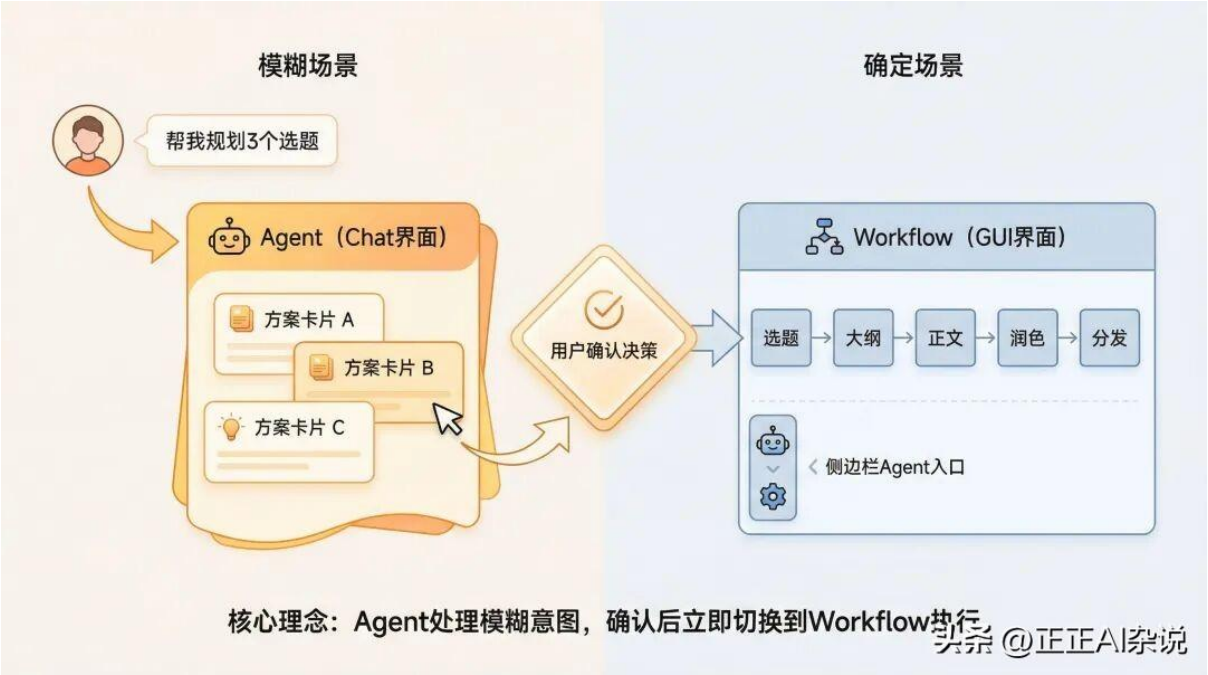

图示：**Chat + GUI 混合交互流程图**

4. 生态重构：从工具到平台

真正的壁垒，不是你预置了多少内核能力，而是用户能通过接口长出多少私有资产。
前文所述的四层架构（Model/RAG/Skill/Workflow）构成了产品的**业务内核**，但这只是一个更好用的工具。

如果只停留在内核层，依然会陷入同质化陷阱。竞争对手可以抄袭你的 Skill 库，可以复制你的 Workflow 模板。

为了建立壁垒，还需要把内核打开，通过开放性接口，让工具进化为平台。我们将重点重构两个关键接口，让用户资产沉淀进来：

第一层：连接接口——以 MCP 为代表的基础设施

MCP（Model Context Protocol）不仅是模型的能力扩展协议，更是产品打破孤岛、连接外部世界的关键接口。

MCP 与 Function Calling 的区别： MCP 旨在成为跨模型、跨厂商的通用协议，而当前主流的 Function Calling（如 OpenAI）仍是特定平台的私有接口。采用 MCP 有助于降低未来被单一厂商锁定的风险。

- **官方预置**：常见工具的 MCP 连接器（如 Notion、飞书文档、WordPress、数据分析工具）
- **用户自接**：提供 MCP 配置界面，让技术用户接入自己的私有工具
- **社区生态**：建立 MCP 连接器市场，用户可以分享/购买连接器

价值： 让产品从内容生产的孤岛，变成用户整个工作流的中枢节点。用户连接的工具越多，迁移成本越高。

第二层：定义接口 —— Skill 的用户级封装

如果说内核层里的 Skill 是官方教给系统的能力（保下限），那么这一层级的 Skill 则是用户教给系统的能力（拓上限）。

- **低代码模式：** 提供可视化的 Skill 编辑器。
    - 例如：我的智能引流。扫描全文核心知识点，在我的私有产品库（如付费课程、电子书）中进行 RAG 检索，若匹配度 > 80%则在文章末尾自动生成一段痛点+解决方案的转折文案并插入对应的商品购买卡片。
- **代码模式（面向高级用户）：**提供沙箱环境下的 Skill SDK，允许用户用 Python/JavaScript 编写自定义函数。
    - 例如：我的选题雷达。一个科技博主写了个 Skill，每天自动抓取他关注的 20 个特定 RSS 源 + 他的飞书收藏夹，用他自己训练的关键词权重模型（打分排序，每周一早上 9 点推送 Top 5 选题到他的工作台。
- **价值：** 让产品从固定能力变成可自定义平台。**用户封装的 Skill 越多，产品对他的价值就越大**。

战略意义：从 SaaS 到 PaaS

这种开放性设计，本质上是一次商业模式的跃迁：

1. **慢变量资产沉淀**：用户积累的 Skill 库和 MCP 连接，成为时间尺度为 3-5 年的慢变量资产。这是对抗模型快速迭代（3-6 个月）的终极武器。
2. **对抗同质化**：当所有 AI 写作工具都在拼谁的模型更好时，你在拼谁的生态更开放。模型可以被超越，但用户的资产沉淀无法被快速迁移。
3. **用户锁定效应**：用户在你的平台上封装的 Skill 越多，连接的工具越多，他们就越离不开你。这是比纯订阅付费更深的护城河。

尾声：义肢时代的思考

在结束这篇架构复盘之前，我必须向自己，也向所有阅读此文的从业者提出最后一个问题：

我们费尽心力搭建的这套精密系统（Model + RAG + Skill + Workflow），是 AI 的终局形态吗？

我的判断是：不是。这只是一个中间态。我们当前正处于一个义肢时代。

必须承认，我们今天之所以要外挂 RAG、封装 Skill、硬编码 Workflow，本质上是因为核心模型还不够强。

我们是在给一个尚有缺陷的婴儿神，搭建一套复杂的学步车和矫正器。真正的工程智慧，始于承认局限。

未来的趋势一定是能力的内化。 随着模型参数的扩张和推理能力的进化，那些原本属于系统层的能力，终将被吃进模型层。

- 当 Context Window 无限大且便宜时，复杂的 **RAG** 检索机制可能会演变为精细化的上下文筛选器，而不仅仅是挂在数据库；
- 当模型具备原生计算机操作能力时，预定义的 **Skill** 可能会消失，变为模型动态生成的动作；
- 当 System 2 的逻辑推理达到专家水平时，死板的 **Workflow** 路径可能会软化，变为模型自主规划的思维链。

那么，我们今天构建这套架构的意义何在？一旦模型变强，这套系统会沦为废铁吗？

绝不会。 即便技术上的补丁属性会减弱，但这套架构在商业与管理上的价值将永存。随着模型越来越强，我们的架构重心将发生一个微妙而深刻的转移：

从为了能力增强转移到为了安全控制，从指导 AI 如何作业转移到定义 AI 的业务边界。

即便未来的大模型强到能自动规划一切，商业公司依然不敢让它裸奔。

因为商业世界需要的不仅仅是强大的智能，更是可解释、可审计、可控的智能。

1. **可解释性 (Explainability)：**
2. **黑箱模式（AGI）：** “因为我直觉认为这笔贷款风险大。”
3. **—— 无法审计，合规挂科。**
4. **系统模式（Workflow）：** “因为我在 Step 3 查到他征信分低于 600。”
5. **—— 逻辑透明，合规通过。**
6. 价值：Workflow 将永远存在，这是一套独立于模型智力之外的**业务宪法**。
7.
8. **数据主权 (Sovereignty)：**
9. 你敢把公司的核心财务报表训练进通用的公有大模型里吗？
10. 价值：RAG 层将永远存在，作为私有数据资产的物理隔离带。
11.
12. **算力成本 (Cost)：**
13. 杀鸡焉用牛刀。1 个写死的 Python 脚本（Workflow）运行一次是 0.0001 美元，耗时 10ms。让 o1 思考出来可能需要 0.1 美元，耗时 5s
14. 以 OpenAI o1 为代表的推理模型虽然展现了惊人的复杂推理能力，但其高成本、低吞吐的物理特性，决定了它短期内无法替代确定性代码。对于高频、确定性的业务流程（如格式校验、数据转换、审批流转），Workflow 目前依然是性价比最优解。
15. 价值：Workflow 不仅仅是为了控制，更是为了降本增效。
16.

这套架构确实是时代的产物，但它不会随时代消失。 这套架构在今天看来是拐杖（因为模型不够强，需要辅助）。在明天看来则是缰绳（因为模型太强，需要约束）。

只要人类还需要对结果负责，这套将不确定性关进笼子里的架构，就是我们手中最后的底牌。

除此之外，还有我 1 年半前的其他几个判断，文章链接大模型中的两个概念：Agent 与记忆组件：

如今看来仍不过时：

- 从用户视角出发，用什么方式来解决问题，根本不重要。重要的是，能不能稳定的，持续的、较好的解决问题。
- 一个所谓长期有价值的事情，不意味着从始至终要用同一种手段，甚至是同一种技术，解决同一个问题。这个过程中，重要的是拿认知、拿反馈、拿迭代的方向。然后在技术成熟的时刻，切换为代价更小的方案。
- 技术快速迭代时期，充满了很多变数。需要做的：
- 1）确保自己正在解决真问题，或提供新价值；
- 2）紧跟技术演进方向，确保自己在问题上所花费的时间不会因为技术迭代而被快速的抹掉；
- 一张有趣的图，用于警示：警惕自己以为是路子 2，实际是路子 1，这也是我曾经犯过最大的错，后面有机会再继续唠。

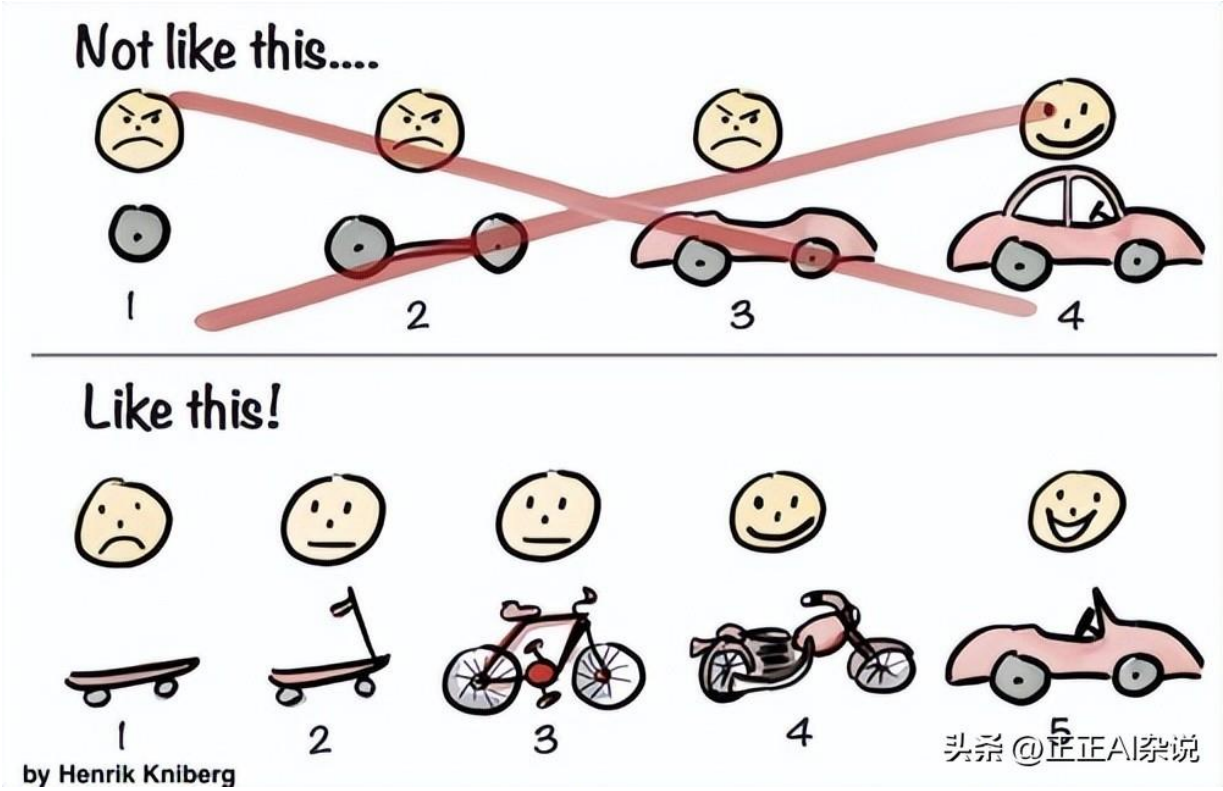

最后，回顾从单体黑箱到精密机器的演进，我们其实一直在回答同一个问题：如何与一个概率性的智能共存？

- 不要试图把神（模型）降维成机器，去强求它绝对精准。
- 也不要试图把机器（流程）神话为智能，去指望它自动涌现智慧。

最优秀的 AI 架构，一定是中庸的。 它用 RAG 承载记忆，用 Skill 封装经验，用 Workflow 约束边界，最后把 Model 放在核心，让它作为引擎轰鸣运转。

架构师的使命，不是创造智能，而是为智能构建一个既能锁住下限，又能撑开上限（才华）。