企业 AI 的账单，
哪些花在你看不见的地方

——Token 经济学视野下的 AI 账单真相

你的 AI 账单，为什么和预算对不上

预算与实际账单的差距高达

3–5倍

账单的绝大部分，

从来没有出现在你的那张成本表上。

错把大模型当成一种按量计费的云资源——用多少、付多少，线性、可预测，真实的生产环境里，这个设想在三个层面上同时失效：



计费口径是显性的，成本结构是隐性的

发票能看到的只是被计量的那一层，结构性的成本从来没有科目。



价格是透明的，价值是模糊的

单价随时可查，但同样一个 Token 在不同场景里换回的东西差异极大。



采购是即时的，成本与收益的周期是错配的

钱在项目初期集中花出去，价值却在后续数年才逐步释放。

每一次产业革命，都会催生一个新的通用计量单位

表 1

技术革命阶段	核心生产要素	核心产出形态	通用计量单位
第一次工业革命（蒸汽时代）	资本、劳动力、煤炭	工业制成品	实物单位（件、吨、米）
第二次工业革命（电力时代）	电力、资本、重工业设备	通用能源服务	**千瓦时（度）**
第三次工业革命（信息时代）	算力、存储、带宽	计算与传输服务	CPU 时长、流量、存储容量
第四次工业革命（智能时代）	**算力、数据、算法**	**通用智能服务**	**Token**

高固定成本、低边际成本——老项目制核算法两头落空；巨额前期固定成本难以合理分摊到每次产出；不同模型、厂商、场景缺乏统一计量标准，无法横向对比——成本 **既不可追溯、也不可拆解、更不可对比**，这就是"看不见的账单"形成的制度土壤。

Token 不只是流量计：它有四重身份

四者合一，构成通用经济标尺



01 生产端

成本核算单元

每一分算力花在哪里，第一次可以被归因与摊销。



02 产出端

效率度量标尺

同样一个 Token 的处理量、准确率、响应时长可被横向对比。



03 流通端

价值交换尺度

这是它能够被定价、被结算、被交易的底层依据。



04 应用端

经营管理锚点

企业围绕它做预算、考核、优化——就像工厂围绕千瓦时做能耗核算。

KEY INSIGHT

看不见的账单，藏在第 2 到第 4 重属性里

当你只把 Token 当作一项费用科目时，你看到的永远是账单的冰山一角。

只有把它当作标尺——同时看成本、效率、价值与经营——你才能看清冰山的全貌。

一次请求，七成花在路上

表 2 · 一次企业 AI Agent 请求的完整 Token 消耗构成

消耗环节	典型 Token 量	是否每次调用都产生
用户原始输入	20–200	是
系统提示词（角色 / 工具 / 行为准则）	**500–3,000**	**是，每次调用都携带**
对话历史	第 N 轮 ≈ N × 单轮消耗	多轮场景累积
RAG 检索结果注入	500–5,000	知识问答场景
模型输出	200–1,000	是
质量校验（可选）	100–500	额外一次模型调用

一个看似只消耗 **200** Token 的用户提问，完整链路中实际可能触发 **3,000 至 8,000** Token 的消耗；某主流智能体框架实测：仅 **23%** 用于核心交互，其余 **77%** 被**呼吸成本**吞噬。

呼吸成本的四个真实场景

全部为生产环境实测口径

1 ReAct 循环的「记忆税」

感知 → 决策 → 动作 → 状态更新的状态机循环；对话到 20 轮时，每次新请求需加载的历史上下文可能超过 10KB。

82%
历史上下文读取占比

2 心跳机制的空转消耗

心跳即使空闲也定期执行：环境状态检查、上下文完整性验证、连接状态保持。

3.2万
每 15 分钟一查，日增 Token

3 系统提示的「初始化税」

系统提示是智能体的「数字基因」：角色定义、工具链配置、行为准则。某复杂智能体提示文本超 5,000 字符。

1.2万
每次初始化，约 0.3 美元

4 检索注入的膨胀

RAG 是消耗最大的变量，成本随注入量线性甚至超线性增长；许多团队仍沿用默认参数。

Top10
× 单篇 1,000 Token

呼吸成本

那些与用户实际使用无关、却因系统运行而持续发生的消耗——就像人在睡眠中依然在呼吸。

传统 IT 预算模型里没有「呼吸」这一项，这正是 AI 账单区别于传统 IT 账单的根本之处。

注意

这些成本不体现在任何一次可感知的用户交互里

却真实地、持续地、按量地流走。它们的共同特征是：不在你的预算表里，也不在你的监控看板上。

发票上不会出现的第二类成本，也在侵蚀AI投资的回报

表 3 · 企业 AI 隐性成本的四类来源

成本类别	表现形式	风险特征
数据蔓延与治理债务	数据副本在云环境、沙盒、模型中大量增殖	推高存储与算力成本，同时放大合规与安全风险
提示工程低效	优化不佳的提示词、冗余上下文、重复调用	直接放大 Token 消耗，隐蔽且持续
模型漂移	未监控的模型行为变化、不必要的计算周期	质量下降引发返工，间接推高总成本
幕后人力成本	数据准备、标注、调优、集成、边缘场景人工介入	**不在 AI 预算科目内，却随 AI 规模同步增长**

叠加 AI 投入特有的**周期错配**：训练、部署、数据治理等前期投入集中在项目初期，业务价值却在后续数年逐步释放——成本与收益的时间周期不匹配，导致短期 ROI 测算严重失真。

引入变动成本法：把打包成本拆成「固定 + 可变」两种成本

表 4 · 智能投入的 Token 化成本性态拆解

成本类别	核心构成	成本特征	分摊方式	典型场景
固定 Token 成本	模型训练微调、算力基建折旧、系统集成、初始部署	一次性投入，不随短期调用量变动	按预计总 Token 产出量线性摊销	专属模型训练、私有化部署、系统对接
可变 Token 成本	推理调用、数据服务、运维支持、接口调用	随消耗量实时变动，单位成本相对稳定	按实际调用量直接计入当期成本	日常大模型调用、API 付费、增值服务

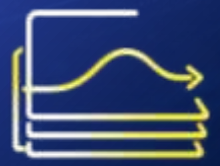

固定成本 · 平滑摊销

解决前期高投入导致的短期成本失真——不再让一次性的重投入全部压在当期损益上。

按预计总 Token 产出量摊销



可变成本 · 精准归因

可以对应到具体的部门、流程与场景，让「谁在用、用在哪、花了多少」第一次可查。

按实际调用量直接计入当期

五个动作：从「看不见」到「管得住」

每一项都有实测口径

01	**可观测性：延伸到三个维度** 成本 · 使用 · 价值，按「意图—环节—模型」建 Token 看板	次/ 30 分钟
02	**分层模型：不同任务用不同等级的模型** 决策层 / 执行层 / 感知层三层架构，用数据而非直觉分层	降本 73%
03	**缓存与上下文治理：收回「记忆税」** 提示缓存 + 小分块 + 重排序 + 三级冷缓存，几乎不需架构改造	降本 59%→70%
04	**硬预算与熔断：为失控装上刹车** 每个 Agent 设支出阈值与自动警报，异常变化时自动熔断	必须做
05	**跨职能价值闭环：让 IT 与财务同频** IT 与财务共享联合仪表板，把 AI 当作活跃的财务系统	组织保障



60%–85%

的 AI 支出可以被收回

收回路径

这五项动作构成一条完整路径：从「看不见」，走到「看得见、管得住、算得清」。

每一项都不需要推翻现有架构，但都需要现在就开始。

动作一・可观测性 & 动作二・分层模型

动作一

可观测性要超越基础设施

按「意图—环节—模型」三个维度建立 Token 消耗看板：意图维度识别 Top 10 高耗意图；环节维度定位分类、检索、生成的消耗热点；模型维度验证分层策略效果。

同时要包括数据如何被访问、复制和治理——可观测性的对象不只是支出。

业内建议的监控频率是每 30 分钟一次——「等待月底对账的日子已经结束了。」

动作二

并非所有任务都需要最贵的模型

三层架构：决策层处理复杂推理（高频次低调用量）、执行层处理确定性操作、感知层处理基础信息提取（低频次高调用量）。

混合路由测算：日均 10 万次请求，全用旗舰模型日成本 **3,000 美元**；分层后降至 **715 美元**，节省约 76%。

用数据而非直觉分层：轻量模型准确率仅低 2–3 个百分点、成本低 10 倍，选择就很清晰。

某智能客服系统采用分层方案后

−73%

直接成本节约

−83%	−65%	−92%
意图识别成本	对话管理成本	知识检索成本

日均 Token 消耗从 **45 万** 降至 **12 万**，平均响应时间缩短 **40%**。

动作三・缓存治理 & 动作四・预算熔断

动作三

提示缓存 + 上下文治理

提示缓存是投入产出比最高的单项技术，几乎不需要架构改造。三大主流厂商的缓存读取折扣差异显著：**10%** 基准价 / 固定 **50%** / 高达 **90%**。

实测：启用缓存后成本降低 **59%**，十天内达 **70%**，命中率约 74%；另有开发者月成本从 720 美元降至 72 美元。可缓存前缀可占输入 Token 的 70%–90%。

上下文治理：某律所应用将检索文档从 60,000 Token 压缩至 15,000，成本降低 75%；小分块（200–300 Token）配合重排序、Top 10 精选为 Top 3–5，可减少 50%–70% 注入。

动作四

为每一个 Agent 装上刹车

最容易被忽视、却可能造成最大损失的一类成本，是失控的 Agent 循环。CIO 应要求为每一个 Agent 设置明确的支出阈值与自动警报，并在使用模式异常变化时触发自动熔断。

264h
多智能体无限循环，累积 47,000 美元无上限支出

48h
被盗 API Key 产生 14,200+ 次失败请求，损失 82,314 美元

30,000
美元——开发者因递归工具生成报告

三个共同点

没有硬预算上限，告警没有被及时处理

这些损失不是单价问题，是边界问题——只要不设上限，一次异常循环就足以吃掉一整年的节省。

缓存折扣的三个档位

10% 部分厂商缓存读取价 = 基准输入价的 10%

50% 有的厂商提供固定 50% 折扣

90% 还有的缓存读取折扣高达 90%

选型时务必把缓存折扣算进总成本。

动作五・让财务和工程保持同一个节奏

IT 与财务的联合治理

治理维度	IT 侧职责	财务侧职责
成本可见性	Token 消耗看板、调用链路追踪、数据访问与复制的可观测性	统一摊销口径、把成本归集到具体科目
预算控制	Agent 支出阈值、自动警报与熔断机制	预算滚动预测、异常波动预警
价值核算	场景 ROI 数据采集与归因，按三级传导逐层核算	价值确认与入账、投资回报复核
生命周期	数据血缘、模型版本管理与问责制	资产化管理、投资决策复核

闭环管理机制

Token 投入 → **产出监控** → **价值核算** → **迭代优化**

从三个层面支撑决策：**场景优先级排序**（优先布局高回报、高杠杆场景）、**投入策略动态优化**（低复杂度场景用轻量模型，高价值场景用高性能模型）、**价值闭环管理**（持续追踪 ROI 表现，识别低效环节）。

观点：

敏捷的治理不能只靠财务监督必须与工程保持同样的节奏。

用于数据保护和恢复的纪律性同样适用于于 AI：明确的血缘关系、生命周期管理，以及对每个数据集和模型的问责制。

让 CFO 参与进来——这是多位 CIO 一致强调的经验。

账单上没有的秘密，
从来不是技术秘密，而是管理秘密。

AI 的每一分钱都花得清清楚楚——只是需要你用正确的标尺，才能看见它。

企业AI的账单，哪些花在你看不见的地方 · Token 经济学视野下的智能投入成本真相