




CIO指南： 人工智能代 币经济学

如何在大规模上查看、控制和核算
AI 令牌支出



作者



阿约·门农

高级执行董事，数字核心，
负责人



兰关

高级副总裁 首席人工智能与
数据官



詹姆斯·伯罗斯

高级执行董事，数字核心，
技术战略负责人



苏里亚·穆克吉

首席总监 - 奥纬研究



企业AI正在创造一种新的商业成本：代币。随着消费规模的扩大，代币经济正成为一个实质性的风险与机遇，日益受到高管层和董事会的关注。

董事会正迫使CEO解释风险敞口与回报，CEO们正寻求CFO的管控，而CFO们则转向CIO以确保AI消耗可预测、经济上自律且价值显著。掌握这些经济规律的公司将比那些仅支付账单的公司获得优势。

我们的全球调研与分析，结合咨询工作，揭示出AI的代币挑战既是成本问题，也是管理问题。数据显示了五种有助于在不超出预算的情况下扩展AI使用的学科。始终领先的公司，在任务到达生产环境之前，会将可观测性融入每一项工作负载中，通过分摊机制建立财务问责制，将每项任务路由至能够交付所需结果的最低成本模型，在新的工作负载上线前要求有可衡量的价值案例，并培训员工和开发人员掌握选择合适模型和高效使用AI的技能。他们对待AI代币经济学与其他技术资源（如资本、云基础设施和软件资产）一样，都秉持同样的严谨态度。

总而言之，他们管理代币支出与管理任何其他生产成本的方式相同。这使CIO成为响应的中心，但并非唯一。控制代币经济需要CIO联合财务、业务领袖、人力资源以及C-suite的其他成员，共同改变人工智能的资助、部署和使用方式。

什么是代币经济学？

代币经济学基金会将AI代币经济学定义为：将能源和资本转化为AI的学科，然后高效地消耗AI服务以实现智能成果并驱动商业价值。¹ 代币是AI模型处理的数据单位。每个提示、响应、检索步骤和代理交互都会消耗它们。代币经济学是连接AI消耗与其所返回价值的学科。

收益十分显著。在24个月的展望期内，采用这些管理规范的公司可以避免代币成本预计增长44%，即每年支出1000万美元可避免约440万美元的成本增长（或支出1亿美元可避免4400万美元）。同样的规范同时关闭了第二个差距：目前，在代币支出中，只有每美元20美分能被表述为向董事会或首席财务官展示的量化财务成果。实施收费回溯和工作负载级度量的组织将该比例提高到每美元32美分，使得首次每10万美元支出中约有115万美元变得可证明。综合来看，每10万美元的年支出可节省成本并证明价值共计560万美元（或支出1亿美元时为5500万美元），所有这一切都不需要部署新模型或增加AI投资。

其他公司仍然像十年前管理企业软件那样管理人工智能：他们等着收账。但现在这种做法很快就不灵了，因为支出已从固定软件许可转向基于使用的AI，并且员工、代理和业务流程的消费都在增长。

随着标记成本上升，董事会越来越多地向CEO提出三个问题：是什么驱动了AI成本？这些成本将增长多快？以及AI正在创造怎样的商业价值？许多CIO目前还无法自信地回答其CFO、CEO和董事会的问题，这主要是因为他们缺乏对产生标记消耗的工作负载、驱动这些消耗的模型以及所创造的商业成果的可见性。同样重要的是，CIO们往往用技术术语而非CFO需要用来为CEO准备董事会会议的财务术语来解释这个问题。这使得投资分配、风险管理和自信地扩展AI变得更加困难。

采用五项纪律的公司，会将每一笔资金视为需要管理的生产投入，在花费之前进行管理，而不是事后审查的发票。结合五项纪律，能为CIO们提供所需的严谨性，以扩展企业AI应用，同时控制成本并证明其商业价值。

研究快照

我们于2026年7月进行了一项调查，涵盖来自全球17个年收入超过10亿美元的企业的750位高级管理人员，这项调查与2026年6月至7月期间对15位财富500强科技和金融领导者进行深入访谈相结合。受访者评估了其组织在人工智能消费、优化、路由、问责制和价值衡量方面的管理方式，从而提供了见解。

我们深入研究了人工智能部署的经济效益以及大规模治理所使用的机制。我们在研究生产过程中使用生成式人工智能。我们的研究专家尽可能使用传统研究方法来审查和验证生成式人工智能的输出，并应用埃森哲（Accenture）负责任人工智能（Responsible AI）标准。

1	商业挑战	第 07 页
2	解决方案	第22页
3	下一步	第 27 页
4	结论	第 35 页
5	埃森哲如何提供帮助	第 36 页

商业挑战

CIO的责任缺失

我们调查中的企业去年总共花费了约25亿美元用于AI代币。如果不加干预，这一数字在24个月内将攀升至36亿美元。³ 总体而言，范围很广：一家全球科技公司年支出超过2000万美元，一家欧洲保险公司的人工智能推理预算为1.5亿至2亿美元，以及一家政府承包商，其全球人工智能支出上限为2.5亿美元。由于支出因部署阶段和组织规模而异，我们的分析按每年1000万美元的代币支出额表示，而不是锚定任何单一基准。如果你的组织支出为3000万美元，则乘以三。如果支出为3亿美元，则乘以30。人工智能代币成本在所有人工智能成本驱动因素中排名第三，仅次于基础设施和软件开发与维护。

目前，仅凭代币支出本身可能不足以引起董事会关注，但其发展趋势正日益受到重视。随着消费加速和预测变得不再可靠，CFO们面临一个成本类别，它可能在极短的时间内从运营支出转变为重大的财务风险。这种压力会逐级向上传递，因为CFO们必须向CEO解释这种风险敞口，而CEO们则必须越来越多地向其董事会解释。

他们的担忧最终归结为两个缺口：难以按季度预测代币数量和支出，以及一旦资金支出，回报便无法解释。这两个问题形成了一种两难境地。当成本不可预测时，财务部门犹豫不决，不愿批准更大的AI预算。当价值难以衡量时，领导者无法为其AI预算申请进行辩护。这导致财务部门向CIO下达了新指令：在成本曲线成为董事会层面的问题之前，必须使AI的经济效益变得可见且可控。

该轨迹才是真正值得关注的问题。在我们调查中，公司预计未来24个月内，代币消耗量平均增长78%，而每个代币的价格平均下降19%。

这个警报绝非毫无道理。

优步在四个月内花掉了其全年人工智能代币预算的全部。一位在全球金融数据和媒体公司负责云、平台和安全架构的首席技术官直截了当地表示：


这确实是个问题……以分钟为单位、以天为单位不断增长……追踪[代币数量和使用情况]绝对是一项挑战，尤其是当它分散在多个组织、多个团队时。

一家美国主要金融机构的技术负责人描述了六个月内增长了5-10倍。在该范围的下限，一年1000万美元的基准收入在一年内变成了5000万至1亿美元的一年收入率，而在此之前的任何价格下降抵消措施都尚未实现。类似地，一家大型欧洲银行在一年内从近乎零增长到每年500万欧元（580万美元）的代币支出，在有人干预之前，单个工作负载每周运行20万欧元（约23.1万美元）。

三分之一的企业在年底前已经耗尽了其年度代金券预算。代金券费用不会自行稳定，以这种方式来支出人工智能费用已不再可持续（图1）。

图1：三种增长情景展示了代币面值为何无法自行稳定

代币价格将无法自行稳定。



埃森哲代币经济学调查（样本量=750）

注意：成本曲线是管理层的选择。受管理的增长将每年运行率维持在每消耗1亿美元接近当前水平；不受管理的增长将其推向1.44亿美元；突破性采用可以在价格下降提供实质性缓解之前将其提升至超过5亿美元。情景1和2使用基于调查的假设。情景3是基于访谈得出的压力测试案例，并非预测。

代币消耗主要源于三大类工作：员工和开发者工具，约占支出30%；内部流程自动化和企口口件，口29%；面向客口的口口、分析和代理式工作流，口39%。代理式工作流目前占比最小，为11%，但其每一步都会增加推理调用次数，且通常增长最快，使其成为最可能驱动下一波预算外成本增长类别。



这个问题有两个方面。

这两个问题触发了同一个警报。尽管它们看起来像是两个独立的故障，拥有两种不同的解决方案，但它们都源于同一个盲点：企业无法在业务负载层面看到代币消耗情况。与业务负载无关的支出无法预测，与业务负载无关的价值也无法证明。

1. 没人能预料的账单

组织并非针对代币实际花费的美元价值做出反应。它们是在应对无法预测、监管或解释账单到账时的这种情况。交易量增长速度快于价格下跌速度，两者之间的差距正在扩大。在自主工具成为主流之前建立的预算模型已无法适应。

该模式在采用前沿已初见端倪。我们采访的一家大型亚洲银行的高级工程负责人为其开发者启用了AI编码助手。其逻辑看似合理：生产力提升带来的收益将远超代币成本。三个月后，账单到账，远超预期。当时成千上万的工程师都选择了最强大的模型，而一个价格更低的模型同样能完成工作。没有人做错事。预算流程根本无法预见这种情况。

2. 没有人能证明的价值

人工智能投资回报是存在的。企业正在创造真实的生产力提升，加速决策并改善客户成果。但它们无法将回报与财务术语中的代币支出联系起来——这是首席财务官可以采取行动的、首席执行官可以证明的、以及董事会可以评估的。

每五枚企业代币支出中只有一美元会以量化财务成果的形式体现出来，无论是表现为收入影响、成本规避还是将生产力转化为具体金额。其余四美元则滞留于公司认为具有生产性但无法证明其价值的领域。价值确实存在。所缺乏的是能够将其与具体金额挂钩的内置追踪机制。

即使在那些领先应对此问题的公司中，价值归因依然难以捉摸。一位500强金融机构的AI战略总监描述了众多企业都熟悉的情况：AI显然在整个组织中创造着价值，但其所产生的价值并未与生产它所消耗的代币进行衡量。生产力的提升显而易见，成果正在改善，采用范围正在扩大，然而消费与影响之间的财务联系在很大程度上仍未量化。

解决这些问题的关键在于，通过工作负荷级别的可见性、责任归属和财务问责制来根除根本原因。

人工智能价格下跌正推动消费热潮。


悖论：每一份储蓄都意味着更多消费。

每token的价格正在下降。18个月前，一个每百万token成本一美元的模型，如今成本只是其几分之一。逻辑上讲，企业AI账单应该正在减少。但事实并非如此。

这是基于杰文斯悖论的经济逻辑：正如更高效的蒸汽机并未减少而是增加了英国的煤炭使用，不断下跌的代币价格会促使公司增加而非减少人工智能的运行（如图2所示）。当被问及如果价格再下降25%会怎么做时，只有五分之一的高管表示会省下节省的资金。其余人则会扩大规模：增加用户、拓展用例、优化模型。

图2：应对代币价格下跌

问：如果代币价格下跌25%或更多，您的组织最有可能采取什么行动？



埃森哲代币经济学调查（样本量=750）

下一步结论可以帮助Accenture

一家大型全球科技基础设施公司中负责人工智能、网络安全和数据的现场首席技术官（Field CTO）精确地描述了这种动态：

即使模型变得更便宜，团队也只是用得更多。这就像……你当年刚拿到第一个吉字节硬盘时？当时并不会觉得“哦我的天，我们要停止使用…这个硬盘空间了”。不，它只是呈指数级增长，因为道理完全一样。

曾经因成本过高而不划算的工作，如今突然变得经济合理。新的应用场景应运而生。那些按去年的价格会被禁止部署的代理，现在可以按今年的价格进行部署。需求量的增长淹没了价格下跌的影响，导致总费用不断攀升。

哈维是一家总部位于旧金山的法律人工智能公司，为超过10万名律师、1300多家律师事务所及企业法务团队提供服务。该公司每月的token消耗量从2026年1月的约1万亿个token增长至5月份的12万亿至13万亿个token。

增长表明，一旦人工智能深入生产，消费规模就能如何迅速扩大，以及为什么单位成本的巨大降幅也可能被规模增长所抵消。

六处易超预算的盲点

代币的真实成本隐藏在财务团队无法看到的六个地方（见图3）。

图3：人工智能预算超支背后的六个盲点



不可知任务成本

几乎您管理的其他每一项成本，在您做出承诺之前都会自行显现。软件许可、服务器、新员工：您事先都清楚具体数额。人工智能（AI）的token消耗则并非如此。一句指令就可能触发一连串代理行动，耗费数百万个token，而且无法预览。您无法凭直觉判断一项任务将花费一美元还是一百美元。

默认边界

你们的人会选择最能胜任的型号，部分原因是他们看不到成本差异，部分原因是因为没有人给他们提供理由或激励去选择其他选项。

埃森哲从O*NET数据库中分类了9,368项职业任务，发现其中不到10%的工作负载确实需要前沿模型能力。其余的90%则由成本比任务要求高出10到20倍的模型进行处理。一家大型全球科技公司企业AI战略副总裁观察到：

10%的人都在催促……[说]“为什么我没有最新款？”而其余的大部分组织基本上都在用这个来搜索。

代理乘数

代理式工作流会增加代币消耗。单个请求可能触发多个模型调用、更大的上下文窗口以及对相同信息的重复处理。随着工作流变得越来越复杂，成本曲线可能超过使用增长，使得传统预算越来越不可靠。

有一家公司大规模推出了一款AI编程助手，却发现自己的编程成本比预期增长得更快。在调查后，他们发现问题的症结在于架构而非价格。最大的节省来自于将开发者从高端模式转移到足以满足大多数编程任务的低成本模式，以及启用提示缓存功能，这样大型代码库就不再需要在每次交互时重新读取。

仅模型变更就使令牌消耗减少了约90%，而缓存则带来了进一步的节省。AI成本往往更多地由模型选择、上下文管理和架构设计决定，而非模型定价。用户教育和架构指导对于成本管理至关重要。

为昨日而制定的预算

大多数企业的AI预算是在自主工具成为主流之前制定的。因此，三分之一的组织在年底前就耗尽了年度代币预算。一家全球快餐连锁企业的首席技术官兼信息官描述了这一情况：

一开始，我们确实不太清楚预算会是多少。……有些部门肯定超支了，超出了预算的两三倍。

碎片化定价

大多数大型企业同时运行来自不同供应商的模型，每个模型都有其自身的定价、上下文窗口机制、缓存策略和输出令牌速率。没有人有一个综合的视图。每个新模型的发布，通常提前通知很少，都会打破先前可用模型的成本假设。定价正以与模型本身一样快的速度碎片化。

一位欧洲银行的资深技术领导者告诉我们，供应商越来越多地根据用例的业务价值来定价人工智能，而不是消耗的令牌数量。

一个联络中心解决方案的成本可能比通用型AI平台高出约10倍，而专业的法律工具定价也高出许多倍，因为供应商是参照他们所取代的专业人士的薪资水平来制定价格的。随着定价模式从按量消费转向按用例经济，相似的工负载可能会产生截然不同的账单，这或许能让单个供应商层面的预测变得更简单，但会使整个产品组合层面的预测更加复杂，并且总体成本更高。

商业定价设计可能导致预算无法预料的成本突变。B2B客户支持和代理式AI公司Pylon发现，当公司超过150个座席门槛并转向企业级定价时，其年令牌费用将从约40万美元上涨至140万美元。财务团队需要提前模拟供应商的定价层级和门槛，而不是在续约时才发现。

透明度而无问责制

代币余额通常隐藏在提供者控制面板中，财务团队和开发人员无法访问，管理员也无法实时核查。我们所说的“展示回溯”（showback）是指消费数据可见，但无财务后果。“计费回溯”（chargeback）则是指消费团队需为其使用量实际付费，从而形成直接的经济激励来管理消费。目前，超过一半的组织拥有展示回溯功能，而只有7%的组织实施了任何形式的计费回溯。展示回溯能提升意识，与KPI等指标结合时尤为有效。计费回溯能建立直接的责任制，但可能仍需辅以额外激励措施来推动行为改变。

每五美元中有四美元缺乏与商业成果的量化关联。


金融可以量化五分之一以下的资金投入所产生的回报。

请要求高管将他们的代币支出与可量化的财务成果挂钩——无论是影响收入、避免成本还是以美元体现的生产力——而不到五分之一的资金达到了这一标准。对于每支出1000万美元，组织无法将800万美元的回报转化为CFO管理投资、CEO为其辩护以及董事会日益期望看到（见图4）所需的财务语言。

图4：只有一小部分AI的回报能抵达董事会会议室

首席财务官可以将每支出10美元中不足2美元与业务成果联系起来。

首席财务官关注每一分钱的支出，但能够据理力争。
不到五分之一的回报



人工智能创造着金融无法看见的价值。

AI的成本方面可以清晰地分解：根据我们的调查，token只占总AI支出的25%或更少——这些成本可以明确识别、追踪，并归因于特定的业务负载和团队。

价值增值贯穿整个工作流程：由AI辅助工作流程带来的生产力提升，反映了该模型、其检索的数据、运行它的基础设施、设计该工作流程的工程师以及使用它的员工。无论多么仔细的衡量，都无法将属于代币本身的价值份额单独分离出来。

一家大型全球科技基础设施公司中负责人工智能、网络安全和数据的现场首席技术官阐述了核心问题：

经济问题不在于……消耗了多少[代币]，而在于那个代币实际做了什么？

百分之四十八的组织依赖共享的IT-财务问责制，没有单一的个人对AI成本和回报负责。技术团队可以看到是哪个功能或人员消耗了token，以及消耗的成本。但他们无法确定这种消耗是否产生了值得支付的价值。这个判断属于理解工作流程、客户互动或AI所支持的业务决策的业务部门负责人。大多数人从未被正式要求做出这种判断。

只有35%的组织能够计算其单一最大用例的成本效益，而59%的组织仍在使用方向性估算。一位来自财富500强金融机构的AI战略总监表示：


我会说，我们现在所做的大部分工作实际上是创造价值。但我不会说我们是通过关注代币来获得这种价值的。

驱动财务归因价值的证据清晰明确且具有可操作性（见图5）。

图5：问责制、路由和可见性使AI的价值可证明

三个信号驱动可归因的财务价值

财务问责是最强的信号；责任认定每一步都在提升。



埃森哲代币经济学调查（样本量=750）



财务问责制


这是其中一个最强的信号。从无偿分配到全额分摊，问责制阶梯的每一步，都会使财务归因支出增加大约六到七个百分点，无论成熟度、规模或行业如何。财务归因价值从无偿分配下的约5%变化到非正式报告下的13%，展示回溯下的23%，以及分摊下的32%。

路由质量

正是那个让你能智能路由——知晓哪个工作负载在哪个模型上运行、成本几何、结果如何的可观测层，对于归因结果至关重要。路由规范和价值归因是同一项投资的组成部分。你不能先建一个，再建另一个。

工作负载可见性

能够将代币消耗追踪到特定用户、团队或工作负载的组织，其复合归因得分几乎是无法做到这一点的组织的两倍。缺乏这种可见性，路由和财务问责制都无法有效运作。你无法路由你无法看到的东西，如果你没有对工作负载的观测层，你将无法为其归因价值。



解决方案

单笔建设，每支出1亿美元，可获560万美元股息。

我们的研究确定了四个独立预测因素，它们既影响成本优化，也影响价值归因：工作负载层面的命名所有权、成本分摊、测量精度和模型路由纪律。每个预测因素都独立地影响成本和价值，但所有四个因素都依赖于同一个基础：工作负载层面的所有权、可观察性和问责制。一旦建立这个基础，你就能同时提升等式两边的表现。

在工作量层面明确所有权，能够实现成本可预测性和价值衡量。否则，成本将变得模糊不清，价值也难以归因。成本分摊机制能够激励精确管理成本并证明价值。这种财务问责制不仅提升了成本意识，也驱动了展示回报的动机。衡量精度可减少预测误差，揭示AI创造财务回报的工作量，并为下一投资周期建立证据基础。模型路由规范既是成本优化的手段，也是工作量层面归因的前提。

一位在全球金融数据和媒体公司担任首席技术官（CTO），负责云、平台及安全架构的人，描述了这种架构在实践中所产生的效果：

我们刚刚就责任归属确定了组织层级，确定了团队，并且在大多数情况下，我们可以追溯到个人。我们之所以设计成这样，本质上是为了从一开始就确保收费模型能够明确责任归属。

如果你答对了，奖金的数额

目前，大多数组织已优化了23%的代币消耗量。我们的模型显示，随着未来24个月内用量增长近80%，他们需要大约31%的优化才能使支出保持稳定，这将留下一个8个百分点的差距。如果无所作为，每年1亿美元的支出将在24个月内攀升至1.44亿美元，并在36个月内攀升至1.73亿美元。

价值方面源于同一套构建。如今，代币支出中只有五分之一美元能够转化为财务回报。通过全额退款和精确计量，可证明的价值提升至每花费一美元约32美分。在每支出1000万美元的情况下，这种转变首次使约115万美元的价值得以证明。对于CFO而言，这就是CIO必须解决的问题：不仅仅是削减代币支出账单，而是要创建出使成本和价值都具备财务可读性的工具和运营规范。


一项治理建设，两大成果：每1亿美元年度支出中，可避免约440万美元的成本增长，并新增约115万美元的可见价值。这源于一次性对工作进行流程化，在任务层级明确责任主体和财务问责，并同步应用于成本和价值管理。

构建它的组织开始用回报而非仅仅是成本来衡量（如图6所示）。

图6：一个治理体系。两种结果。叠加影响。

同一种代币经济学（Tokenomics）规范，既能控制成本增长，又能实现规模化价值验证。

对于每一笔 1000 万美元的代币支出...



结合开放型和专有模型可以控制某些成本。

到目前为止，我们关注的是目前大多数企业使用的模型：通过提供商API或云平台按令牌付费。这种模式涵盖了70%的企业。但部署架构对账单的影响超出了大多数CIO的预期。选择范围从开放权重模型开始

CPU或自托管GPU，通过公有云平台或直接API，用于加载开源权重模型和专有模型。每种方式都有不同的成本结构，并且在速度、控制、质量和基础设施负担方面存在不同的权衡（图7）。

图7：不同的工作负载需要不同的成本结构

部署模型	成本结构	最适合	关键权衡
开核	极低的推理成本； 更高基础设施 人才与运营 成本	高通量、低 复杂任务： classification, 总结，提取	更慢；重要的 MLOps 根据上下文，“overhead”可能有以下几种翻译：*
GPU开放式负载 self-hosted	低推断成本 规模化；更高 基础设施、人才和 运营成本	大宗商品 规模化工作量	高昂的前期资本； 完整的基础设施 责任
公开加权 云	低推断成本； 额外云 基础设施和 管理成本	组织希望 开模成本 结构上没有 基础设施负担	最快增长模式； 比不上 前提
专有云服务 平台	按token计价； 基础设施和 包含操作	大多数生产 工作负载	主导企业 模式；前沿 能力；企业 SLAs
专有，直接来自 模型提供方	按token计价； 基础设施和 包含操作	直接API访问	功能等效于 大多数云平台 用途



对于大约90%无需前沿推理的任务，开放权重部署在成本方面颇具吸引力。数据从某种程度上证实了这一点：运行专有和开放权重模型比例大致相等的组织，其路由质量（55%的请求被正确路由，对比47%）和部署成熟度（61%规模化在生产环境中运行AI，对比32%）均高于以专有模型为主的组织。

其他方面的成本。商业支持需求以及内部能力差距一直制约着企业采用——尽管这两方面都在变化。新兴的开重量级模型和入门级基础设施现在能够胜任处理大多数通用企业工作负载。

除成本外，开放式权重模型还有三个进一步的优势：数据主权、对前沿模型出口管制更具韧性，以及在微调时对非英语、特定领域任务表现更佳。

总体而言，开放式重量模型是路由工具箱中一个有价值的选项，但根据我们的调查，在企业规模上很少是主导架构。对于没有专门团队和相应运营成熟度来支持它们的组织而言，上述其他成本可能会抵消甚至超过其在代币线上的收益。

这些限制同等重要。代币支出占人工智能总支出25%或更低；转向自托管开源权重模型通常会增加基础设施、人才和运营成本。

正确的定位是一个深思熟虑的连续体：将每一项工作任务指派到最能平衡成本、能力、数据治理和运营复杂性的模型层。

下一步

CIO的五大纪律

我们的研究和客户工作确定了五个领域：工作负载级别的可见性、财务问责制、更智能的路由、价值证明和具备AI技能的人才。这些领域共同构成了一个单一的运营模式，用于大规模运行AI。这些领域并非按顺序执行；它们作为一个整体运营模式协同工作。可见性优先，因为其他四个领域都依赖于它，而其余四个领域可以并行实施或按顺序排列，以匹配组织的AI成熟度。

■ 纪律 1：

在规模化之前，让每一项工作任务都变得可见

部署一个 AI 网关或可观测性层，用于捕获每次 AI 交互的：工作负载名称、所属团队、使用的模型、令牌成本和输出。在规模化应用中，这需要采用“政策即代码”和自动化的经济护栏，而不是对单个工作负载进行人工审核。它是成本管理和价值归因的先决条件。

包括 LangSmith、Arize 和 Helicone 在内的工具，能够在较低的开销下提供工作负载级别的成本归因。⁷

这种建设过于迟缓的模式如今已有详尽记录。优步鼓励工程师“尽可能多地”使用人工智能，并设立了内部排行榜来追踪代币消耗。到2026年4月，该公司在四个月内就耗尽了全年人工智能预算。随后，公司推出了每人1,500美元的限制。

Shutterstock展示了早期配置的重要性。当该公司审视其AI成本结构时，发现输出令牌占总令牌消耗的75%，而ChatGPT许可证在一个月内从50份扩展到750份。它还识别出25万美元的已承诺AI支出存在被闲置的风险。应对措施并非仅仅是限制AI使用。相反，Shutterstock扩大了其FinOps的职责范围，涵盖AI和云成本，在采用进一步扩大之前，将数据纳入与财务部门共同的处理流程中。结果是更早地洞察AI消耗和供应商承诺，从而在采用规模扩大之前解决潜在的浪费问题。

来自一家全球金融数据与媒体公司的技术高管接受本次研究采访时，描述了尽早建立该系统的回报：其责任归属可追溯至组织、团队，以及在大多数情况下是个人，并且从一开始就设定了收费模式，而非后期追加。

■ 纪律二： 让团队为其使用付费

账单按团队消耗的代币成本进行分配。从工程部门以及前三到四名高消耗功能开始。展示成本回溯（Showback）若无财务后果变化，仅能提高意识，但需与其他激励措施结合才能改变行为。在我们的研究中，成本回收（Chargeback）是成本优化和价值归属的最强预测指标之一，但如今只有不到十二分之一的组织在使用它。

该机制直接明了。当团队支付自身消费时，管理者会评估支出是否合理，工程师则会开始考虑成本来选择模型。实施费用分摊的组织通常在治理和可观察性方面更为成熟。该机制在伴随工作负载级别的可见性和清晰的职责划分时效果最佳，而非先于它们出现。在一个不够成熟的组织中，仅靠费用分摊不太可能产生同样的效果。某大型全球科技基础设施公司的领域CTO描述了一种集中标准、联邦问责的运营模式：每个生产工作负载都应有指定的业务单元负责人，负责解释其预期成果、成功指标和经济效益，并随着其扩展进行说明。

■ 纪律三：

将每个任务发送到它实际需要的模型

识别出大约10%的工作负载或流程步骤，这些确实需要前沿能力——复杂的推理、规划、多源综合和高风险生成——并将其他所有内容路由到功能强大的中端模型或开放权重模型。将此作为网关处的路由策略来强制执行，而不是留给每个开发者的判断作为指导。

价格差异显著：一个前沿模型的价格可能比一个功能完备的低端模型高出15倍或更多。由加州大学伯克利分校领衔、在ICLR 2025上发布的开源框架RouteLLM，在基准工作负载上实现了高达85%的成本降低，同时保留了旗舰级95%的品质。

一家大型全球科技公司企业AI战略的副总裁直截了当地指出了这个问题：目前企业AI的应用大多还停留在搜索和检索层面，而一小部分高级用户则需要更高级的模型来处理更复杂的工作。将这两种模式都通过同一个前沿模型进行处理，就会导致不必要的成本不断累积。

该全球快餐连锁店的CTIO在运营层面描述了同样的问题：由于用户尚未学会何时低成本的型号就足够了，他们最初习惯于将最昂贵的尖端型号用于即便是琐碎的任务。一个带有动态模型路由的中心网关正是防止这种默认行为演变成过度消费的原因。

埃森哲自身的生产平台通过结合自托管的开权推理和智能路由，每周处理约87万个token，其成本约为前沿API成本的六分之一。¹¹ 市场正朝着同一方向发展。根据IDC的2026年AI与自动化未来景观报告，到2028年，70%的顶尖AI驱动型企业将使用先进的多工具架构，动态且自主地管理跨不同模型的模型路由。¹² Vercel的2026年生产数据显示，这一模式已大规模出现，生产团队平均以35个模型作为一个路由图来运行。曾经是一种先进实践的做法，正迅速成为运营基准。¹³

如何为合适的任务匹配合适的模型层级

如前所述，前沿模型不应是默认选项。埃森哲从O*NET数据库中筛选掉了体力劳动和需要人工审核批准的任务，对剩余的9,368项职业任务进行了五次测试，以判断其是否需要前沿级人工智能。结果只有10%的任务通过了测试。其余的90%使用中端模型即可顺利运行，或者所需判断极少，模型几乎无关紧要。

这90%的工作并非简单。它包括评估网络设计、根据既定模板起草合同、处理安全事件以及对照已知标准分析数据。

这些任务需要真正的专业知识。它们所缺乏的是不可约性，即区分前沿与其他事物的特征。

一项任务在以下情况时是不可简化的：当没有任何既定方法能解决它；当早期的一个错误悄无声息地污染了所有后续工作；当工作一旦被分割就会导致整体破裂；当它强行将两个截然不同的专业领域结合起来；或者当它的价值存在于整体的连贯性中。如果这五个条件都不具备，那么即使工作看起来多么有挑战性，一个中档水平的有能力的模型也足够了。

成本后果是直接的。前沿模型的每个标记成本比功能齐全的中端替代方案高10到20倍。目前，已有54%的人工智能请求被路由到超出任务需求的更高层级。几乎每四位高管中就有一位将模型路由视为目前可用的最大效率杠杆，他们是对的。生产团队报告称，当他们将请求路由到能够胜任工作的最低成本模型时，模型服务费用降低了40%至60%。

■ 第四条纪律：

在任何工作量接近生产之前，都要要求提供证明其价值的案例和管理标准。

在将资本投入任何新的AI工作负载之前，请先明确以下三点：当前该流程的成本（以金钱或时间衡量）；AI将具体改善哪些财务成果；以及该成果将如何以美元衡量。然后把控好入口。只有当可观测性工具到位，能够在工作负载层面衡量消耗；优化路径可信且正朝着盈亏平衡发展；且预期价值能被表述为可量化的财务成果（无论是收入、成本规避还是以美元计的生产力）时，才批准商业案例。

这不必复杂。它需要在支出之前就存在，而不是在事后试图为其辩护。

匹配集团为从实验转向价值门槛的转变提供了一个清晰的范例。在之前允许人工智能试点项目拥有“几乎无限制的预算”后，首席财务官史蒂夫·贝利表示，该公司为2026年提高了标准。现在，材料人工智能支出需要一份商业案例，证明其通过成本节约、效率提升、收入增长或用户影响产生明确的影响。实验可以始于灵活性；而规模化则需要财务能够评估的回报。

荷兰合作银行（ABN AMRO）已将此流程正式化。该银行要求所有人工智能应用场景在投入生产前，必须至少对应其中一个定义的价值成果。截至2026年5月，该银行已有40个应用场景投入生产，每个场景都预先映射到相应的价值成果。成果具体表现为：其ICS语音机器人处理了约60,000个月度通话中的80%，实现了每周500小时的效率提升；其德尔菲风险评估工具每月为金融犯罪运营节省约800小时。这些数据是在部署前定义的，并在部署后进行测量。

克蓝娜在其客户支持部署中采取了类似的方法。它从一开始就将成果衡量融入了架构中，追踪解决时间、重复联系次数和转接率，并在2024年启动时报告节省了4000万美元的招聘成本，到2025年第三季度增长至约6000万美元。¹⁶ 团队能够衡量和归因使用情况，因为这种可见性从一开始就构建进去了。

那些早早制定这一标准的组织与那些没有制定标准的组织之间的对比，如今已体现在公共成果上。在优步，人工智能代理现在贡献了大约10%的承诺代码，首席运营官最近承认，仍然很难明确说明代币的使用如何转化为更好的产品。¹⁷ 投入先于衡量基础设施。优步现在正在实施弥补这一差距的规范——每位员工每月1500美元，内部仪表板以及超额审批。它的经验强调了更广泛的教训：表现最好的企业是在提供访问权限的同时建立衡量基础设施，而不是在第一次预算意外之后。

一家大型全球科技基础设施公司的首席技术官（CTO）表示，在缺乏这种纪律（指成本效益管理）的情况下，所有规模化发展的组织都会出现同样的情况。平台团队最终会准备报告，解释那些无人构建可观测性的成本，并为未量化的价值进行辩护。在推出前无法用财务术语表达其预期价值的商业案例，就不是商业案例，而是一项实验。要像对待实验一样资助它，明确其范围限制，并设定一个明确的产生证据或停止的节点。

本研究中，那些无法证明财务回报的组织，在大多数情况下并非未能产生回报，而是未能对其进行衡量。第四项原则是组织在支出之前就建立相关机制，而不是在事后试图为其辩护。

价值如何衡量完全取决于其功能和所属行业。在客户运营中，衡量标准是问题转接率和每次解决问题的成本。在软件开发中，衡量标准是开发周期和每位开发者的接受贡献量。在后台处理中，衡量标准是将每笔交易所需小时数折算成美元金额。在风险与合规领域，衡量标准是每位分析师的决策数量和误报率。定义会变化。要求不会：明确结果、设定基准，并在工作负载达到生产阶段前构建衡量体系。

■ 第五项纪律： 在整个组织中培养人工智能技能

大多数路由错误的发生，是因为人们缺乏明确指导，而非良好判断。开发者和员工会选择最强大的模型，因为他们看不到成本差异——而且通常没有简单规则来判断何时较便宜的模型就足够了。培训有所帮助，但仅限于此：65%的公司已引入某种形式用户培训，但路由差距依然存在。除非在选择时刻加以强化，否则意识并不能改变决策。

一家大型全球科技公司企业AI战略的副总裁直言不讳地说：

您的丰田凯美瑞完全足够好用。您不用很快就升级到法拉利。

同一位高管描述了他预期该规范将落地的方向：将代币效率纳入开发者KPI、根据用户画像和用例分配预算，并同步衡量AI使用的数量和质量。要实现这一目标，需要让相关人员理解他们的职责，并拥有满足这些期望所需的资源。

目标并非让人们为无法完全掌控的成本负责。总成本难以内部化：较便宜的模式可能需要更长时间，需要更多提示迭代，或产生需要更多人工审核的输出。目标是行为引导。为人们提供一个简单的框架，明确哪种模型层级适用于哪种任务。让成本可见性对需要的人可用。通过网关路由策略或桌面策略设置默认值，使正确的选择也是容易的选择，并将人工判断保留在真正重要的情况下。

表现良好的组织是在设定预期、提供信息并让治理结构承担执行责任。当指导清晰易懂时，人们便会遵循。CIO 的职责就是使其变得容易。

这超越了用户培训范畴。代币经济学跨越了技术、金融、人力资源和企业所有权等多个领域。首席信息官需要首席财务官为人工智能投资设定可衡量的价值与成本问责条件；首席人力资源官需要将模型选择和成本意识融入人力资源期望之中；而业务领导者则需要为每一项人工智能工作任务指派命名负责人、建立经济论证，并从第一天起就对其结果负责。

五项纪律可以构成技术运营模式，但让它们发挥作用是高管层的责任。CIO 的职责是进行统筹协调。

结论

该学科是区分点

人工智能的领导力关键在于控制和管理的纪律性。当公司能在代币成为需要证明其合理性的成本之前就对其进行管理，并将其与可解释的价值案例联系起来时，公司才能获胜。

在许多公司，先有接入，后有治理。账单出来时才进行治理。这个顺序是可逆的，但在财务压力下逆转它比在部署时正确处理它更困难、成本更高。正确处理这一点的公司并非特例。一位技术高管从一开始就将归因机制融入其中。一位现场C TO在工具规模化之前就问：“那个代币实际做了什么？”安盛（ABN AMRO）要求每个用例在生产前都要映射到定义好的价值结果。调查显示出相似的模式：运行早期试点项目的组织优化了约15%的代币支出，正确路由了30%的请求，而那些大规模在生产中运行AI的组织则达到了约28%和58%。所有这一切都源于拥有可见性、路由层、运营模式以及像制造商管理生产线一样运行AI基础设施的纪律：管理单位成本、削减浪费并持续衡量。

现在建设这项基础设施的组织将在数年内获得叠加优势。AI能力将持续提升。模型价格将持续变动。消费曲线将持续上升。所有这些都不会改变其基本逻辑。价值来源于代币的功能，而非投入其中的资金。

那就是该学科要填补的差距，而填补这个差距的窗口期就在下一代模型问世之时，或下一次自主性扩展之时，或某个不可预测的AI法案成为实质性问题之时。一旦发生这种情况，相关问题将迅速从董事会传到CEO，再从CEO传到CFO和CIO。现在行动的CIO们将拥有答案。代币经济学正成为企业级AI运营的标准学科。现在构建它，CIO就能让CFO对经济性有信心，让CEO获得可量化的回报，并让企业有依据而非凭空希望来扩展AI。

埃森哲如何提供帮助

一家公司的技术基础已不再是一个支持性职能。它是创造和放大优势的机制，而构建、资助和捍卫这一机制是CIO的职责。

为履行这一责任，技术领导者需要同时整合三件事：正确的基石、正确的运营模式以及正确的投资逻辑——与业务利益相关者协同推进，并制定优先考虑目标行动以最大化业务价值的路线图。当今，极少有公司能将这些方面全部连接起来，这也是为何人工智能的巨大潜力仍未能转化为切实的业务成果。

我们认为的不仅是技术栈的重构，更是商业的重塑。埃森哲帮助客户打造一个随时可以进行重塑的数字化核心，该核心贯穿现代业务架构的三个维度：引擎驱动企业运行，知识赋予企业对自身及外部环境的可信认知，而大脑则通过人工智能模型、编排和代理来解读这种认知并加以激活。所有这一切都由安全与治理层提供支撑。

埃森哲自身的生产平台通过自托管开放权重推理和智能路由，以约六分之一的边缘API成本，每周处理约87万亿个令牌。埃森哲令牌经济学通过一套经过验证的三阶段方法——看见它、修复它、保持它——将此能力带给客户，该套方法由埃森哲AI令牌导航器支持，这是一套涵盖AI资产取证评估、实时模型基准测试、预算即代码和策略即代码的运行时代码、每项成功业务行动的成本实时监控，以及使成本纪律持久的工程和人才实践在内的七种专业工具。

关于研究

我们的研究结合了三种输入：对分布在17个国家的750名高级管理人员的调查、与15位财富500强科技和金融领袖的深度对话，以及对6000名高级领导者的模拟，以测试我们在数据中观察到的模式。每位调查受访者都在年营收超过10亿美元的公司工作，并直接负责人工智能支出决策。

对 N=750 位高级管理人员、营收超过 10 亿美元的企业的初步调查，涉及 17 个国家，时间截至 2026 年 7 月。合成模拟：Aaru 平台，包含 6,000 名代理，分布在六个企业成熟度阶段，所有模拟数据均明确标注。定性访谈：与 15 位《财富》500 强科技和金融高管进行深度对话，于 2026 年 6 月至 7 月进行，数据已匿名化并汇总。统计方法：皮尔逊相关系数、多元回归、方差分析。所有回归和相关分析结果均具有统计学意义（ $p < 0.05$ ），除非另有说明。

致谢

研究团队：

阿马尔·塞巴斯蒂安，阿迪蒂·阿比吉特，比斯瓦迪普·戈什·哈兹拉，阿洛克·兰坎，阿杰伊·加尔，克里希纳·坎特·苏特拉耶，杰里·法尔科瓦，娜塔莉亚·西琴科，伊纳西奥·玛莫内，凯文·加尔格，加尔吉·查克拉巴蒂，普拉迪普·罗伊

SMEs/Leadership:

托尼·勒拉里斯，史蒂夫·克劳蒂，马特·拉戈多斯基，迈克·艾森斯坦

市场营销与传播：

陈碧娜，葛纳卡雷利，劳伦斯·麦金，埃德·梅尼，珍妮恩·斯坦库斯

词汇表

财务归因价值（复合归因）——组织能够表述为量化财务结果的代币总支出份额——即受影响的收入、避免的成本或转换为美元的生产力。它是一个复合指标，因为财务归因发生在两个阶段，每个阶段都由一个调查问题所捕捉。

- 关联性：可关联至可衡量业务成果的代币消耗占比。

- 金融表达：在那种关联消费中，可以表示为量化美元金额的部分。

由于第二阶段取决于第一阶段，复合指标就是它们的乘积：

复合归因 = 关联 × 财务表现

例如，一个将其60%的消费与某个结果挂钩，并财务上表达出这60%的组织，实现了 $0.60 \times 0.60 = 36\%$ 的复合归因。

优化率——组织通过效率提升（如路由、缓存、提示规范、上下文管理等手段）实现的token消耗减少量。以相对于未优化基准所移除消耗的百分比报告。

盈亏平衡优化——在24个月的时间范围内，为使总代币支出保持稳定，同时交易量增长且单位价格下降，所需的优化比率。此数据为推算得出，而非调查统计。

盈亏平衡点 = $1 - 1 / [(1 + \text{销量增长}) \times (1 + \text{价格变动})]$

根据调查预计的24个月销量增长（+78%）和价格变动（-19%），盈亏平衡率约为31%。

分摊与计费——分摊使消费团队可见化资源消耗，但不会产生财务后果；计费则向消费团队收取其使用的费用，从而直接形成管理消费的财务激励。该报告将从无成本分摊 > 非正式报告 > 分摊 > 计费的发展过程视为一个责任阶梯。

路由质量——指定向能够满足所需结果且成本最低的模型处理的AI请求的比例。发送给任务要求超出范围的更高级别模型的请求被视为“错误路由”。

工作负载级归因——将令牌消耗追溯至特定用户、团队、应用程序或工作负载的能力（路由和财务归因所依赖的可观测性基础）。

如何解读这些数字

报告核心指标速查，简明扼要。

Term	简而言之
复合归因	你能向董事会实际证明的每一美元代币的份额，作为... 财务结果。如今约为每美元20美分。
优化率	您通过效率节省了多少代币消耗量（路由、缓存、提示）。调查平均约23%。
盈亏平衡优化	为使账单随着业务量的增长而保持稳定，需要进行优化。 fall. ~31% over 24 months.
对账单与扣款单	展示回款 = 团队看到成本。追回款项 = 团队承担成本。 仅退款会改变行为。
路由质量	发送到仍可执行的最便宜模型的请求份额 这份工作。越高越好。



参考文献

1. 代币经济学基础，什么是AI代币经济学？
，2026年8月2日

2. 埃森哲分析。若无优化措施，代币成本预计将在24个月内增长约44%，增长主要受78%的量增驱动，部分被19%的价格下降所抵消。采用31%的优化率可将支出维持在原有轨迹水平。少数已实施完全成本分摊的组织（N≈53）报告称其优化率接近48%；鉴于样本量较小，这被视为趋势性指示而非总体基准。

3. 根据对741名已知消费额的受访者（N=741）的加权平均年令牌消费额3.37万美元进行估算。该24个月预测将调查得出的销量增长（+78%）和价格下降（-19%）假设应用于同一基准。

4. 娜塔莉·龙，优步限制使用Claude Code等人工智能工具以控制成本，《彭博》，2026年6月2日。

5. 贝内特·希姆库斯，哈佛CEO表示，该公司五月份的AI代币使用量达到12万亿，商业内幕，2026年6月19日

6. 亨利·尚德奈特，《商业内幕》报道，人工智能代币成本正迫使企业重新思考其招聘、预算和用例管理方式，2026年6月17日。

7. 克里斯·舒普林 (Chris Shuptrine)，《2026年跨供应商追踪AI令牌使用情况的7种工具》，托里 (Tori i)，2026年6月。

8. “我们创造了怪物”：企业因成本耗尽预算而限制人工智能使用，《金融时报》，2026年6月19日。

9. 麦肯齐·霍兰德，Shutterstock，普睿hal金融分享AI成本策略，《CIO Dive》报道，2026年6月11日。

10. 人工智能成本核算：模型资源优化配置，2026年，数字化应用，2026年6月23日。

11. 人工智能已纳入你的损益表。大多数公司仅理解了其中一半，埃森哲，2026年7月29日

12. 尼尔·沃德-达顿与南希·戈林，《人工智能的未来是模型路由》，IDC，2025年12月11日。

13. 人工智能成本核算：模型资源优化配置，2026年，数字化应用，2026年6月23日。

14. Match Group首席财务官为2026年人工智能支出设定“更高标准”，《CFO Dive》报道，2025年12月23日。

15. ABN AMRO 创新与科技、投资者关系、ABN AMRO 与人工智能：投资者会议，2026年5月20日。

16. Klarna AI客户支持效率，Twig，2026年6月10日。

17. 杰克·安吉洛，优步在四个月内烧光了其全部2026年人工智能预算。如今，其首席运营官正质疑这笔投入是否值得，《财富》杂志，2026年5月26日。

关于埃森哲

埃森哲帮助全球领先企业重塑，通过构建其数字核心并释放人工智能的力量，为各行各业的组织创造价值。我们的战略是成为客户的首选重塑合作伙伴，引领人工智能的安全、广泛采用，并成为全球最以客户为中心、人工智能赋能、工作环境最优秀的企业。我们汇聚了约799,000名员工的才智、专有资产和平台、深厚的流程和行业专业知识以及领先的生态系统关系，以规模化地提供端到端解决方案和可衡量的成果。通过我们的重塑服务，我们在网络安全、数字核心、金融、行业和企业、策略、供应链与工程以及人才等领域提供广泛的专业知识，并在人工智能与数据、行业与流程以及技术方面具备先进能力。我们服务约9,000家客户，并在2025财年创造了约700亿美元的营收。

埃森哲研究

埃森哲研究致力于就组织面临的最紧迫的商业问题创建思想领导力。我们的团队由来自20个国家的300名研究人员组成，他们结合创新研究技术（例如数据科学主导的分析）以及对行业和技术深刻理解，每年发布数百份报告、文章和观点。我们在研究生产过程中使用生成式人工智能。在可能的情况下，我们的研究专家会使用传统研究方法审查和验证生成式人工智能的输出，并应用埃森哲的负责任人工智能标准。我们与世界领先的组织合作开发的思想启发性的研究，帮助客户拥抱变革、创造价值，并展现技术和人类智慧的强大力量。

访问 [accenture.com](https://www.accenture.com)。

访问 Accenture Research，请访问 [accenture.com/research](https://www.accenture.com/research)。

免责声明：本文件中的内容反映的是本文件编制时（如首页所示日期）可获得的信息，但全球形势瞬息万变，立场可能随之改变。本内容仅供一般信息参考，未考虑读者的具体情况，亦不旨在取代咨询我们的专业顾问。埃森哲根据适用的法律所允许的最大程度，声明对本文档中信息的准确性和完整性，以及基于此类信息所采取的任何行为或未采取的行为，概不承担责任。

埃森哲不提供法律、法规、审计或税务建议。读者应自行从其法律顾问或其他持牌专业人士处获取此类建议。本文件提及由第三方拥有的标记。所有此类第三方标记均为其各自所有者的财产。本内容未明确或暗示地获得此类标记所有者的赞助、认可或批准。

© 2026 埃森哲。保留所有权利。埃森哲及其标志是埃森哲的注册商标。

