

生成式引擎营销（GEM）的量化优化范式研究 ——基于CPCQ（点击成本量化）的理论建构与 方法论迁移

何亚涛¹，郭继伟²，丁力³

1. 玫瑰互动网络科技（北京）有限公司，北京；

2. 北京时光对话品牌管理有限公司，北京；

3. 上海后思信息科技有限公司，上海

DOI:10.62836/ssr.v3n5.1512

摘要：生成式人工智能正在推动信息分发模式从“检索”向“推理”转变，AI答案生成引擎取代传统搜索结果页成为品牌与用户之间的新中介。既有研究围绕生成式引擎优化（GEO）已形成初步的知识积累，但多停留于内容操作层面，缺乏对“付费营销”这一维度的系统理论建构。本文在GEM（Generative Engine Marketing，生成式引擎营销）框架下，提出CPCQ（Cost Per Click Quantification，点击成本量化）量化优化范式。CPCQ的核心命题是：AI搜索广告优化的第一性问题不是“出多少钱”，而是“量化什么”；其核心理论贡献在于，将广告优化的对象从“出价策略”转向“广告对象本身”。本文从量化交易的方法论迁移出发，构建“答案层—交互层—交易意图层”三层量化维度体系，设计“多维度量化采样—量化基准建立—异常检测—策略调整—效果验证”的优化闭环，提出以“传统指标+Q”为命名规则的CPCQ指标体系，并讨论其可归因性与方法论边界。本文认为，CPCQ的提出标志着AI搜索广告从“竞价思维”向“量化思维”的范式转换。

关键词：生成式引擎营销（GEM）；CPCQ；点击成本量化；量化交易；AI搜索广告；oCPC

Research on the Quantitative Optimization Paradigm of Generative Engine Marketing (GEM)

Yatao He¹, Jiwei Guo², Li Ding³

1. Rose Interactive Network Technology (Beijing) Co., Ltd., Beijing;

2. Time Dialogue Brand Management Co., Ltd., Beijing;

3. Housi Information Technology (Shanghai) Co., Ltd., Shanghai

Abstract: Generative AI is driving information distribution from “retrieval” to “reasoning,” as AI answer engines replace traditional search results pages as the new intermediary between brands and users. Existing research on Generative Engine Optimization (GEO) has laid an initial foundation but remains largely at the content-operation level, lacking systematic theoretical construction of the paid-marketing dimension. Under the Generative Engine

*作者介绍：何亚涛，GEM优化领域拓荒者奠基人。

Marketing (GEM) framework, this paper proposes CPCQ (Cost Per Click Quantification), a quantitative optimization paradigm. Its core proposition is that the primary question of AI search advertising optimization is not “how much to bid” but “what to quantify.” The paper migrates methodology from quantitative trading, constructs a three-layer quantitative dimension system (answer layer, interaction layer, and transaction-intent layer), designs an optimization closed loop (sampling, benchmarking, anomaly detection, strategy adjustment, and validation), and proposes a “traditional metric + Q” naming convention for CPCQ indicators. The paper argues that CPCQ marks a paradigm shift from bidding thinking to quantitative thinking in AI search advertising.

Keywords: generative engine marketing (GEM); CPCQ; cost per click quantification; quantitative trading; AI search advertising;

1 引言

AI搜索正在改变广告的底层逻辑。当用户在ChatGPT、Perplexity、Google AI Overview等AI搜索产品中提问时，AI直接给出综合答案，而非返回链接列表。Pew Research Center（2025）基于900名美国用户、68879次Google搜索的追踪研究显示，出现AI摘要时传统结果页点击率从15%降至8%，相对降幅约47%[1]。多份行业研究进一步表明，约60%—68%的Google搜索以零点击结束[2,3]。然而，品牌信息在AI答案中被提及、被推荐、被比较的过程并未停止，只是以更隐蔽的方式发生。

这一变化对广告优化提出了根本性的挑战。传统SEM的CPC体系建立在“曝光—点击—转化”的漏斗假设之上，信息流广告的oCPC体系虽引入转化预估，但其优化的对象仍然是“点击”这一行为本身。当点击不再必然发生、甚至不再必要的时候，以点击为中心的优化框架正在失去解释力。

现有Generative Engine Optimization（GEO，生成式引擎优化）领域的系列研究中，系统梳理了“九级信任跃迁模型”，构建了从信息曝光到用户转化的逻辑链条，并提出了DataAsset GEO™优化方法论与白帽合规框架[4]。这些研究解决了“如何被AI正确回答”的问题，但尚未系统回答“如何通过付费手段在AI答案中实现商业目标”这一GEM层面的问题。

本文在这一研究脉络上继续推进，提出CPCQ（Cost Per Click Quantification，点击成本量化）量化优化范式。CPCQ不是oCPC的又一个变体，而是AI搜索结果广告的量化优化范式。其核心命题是：在AI搜索广告中，优化的第一性问题不是“出多少钱”，而是“量化什么”；其核心理论贡献在于，将广告优化的对象从“出价策略”转向“广告对象本身”。本文将从理论来源、哲学基础、量化维度体系、指标体系设计与优化闭环五个层面，系统建构CPCQ的理论框架。

2 文献回顾：从GEO到GEM

2.1 GEO研究的既有进展

生成式引擎优化（GEO）作为一个新兴研究领域，已在学术和产业层面引起广泛关注。相关研究提出了GEO“九级信任跃迁模型”，从AI对信息的发现、读取、分析与理解出发，延伸至信任、推荐等认知层级，构建了从信息曝光到用户转化的完整逻辑链条[4]。该模型的核心贡献在于将GEO从“技术操作”提升到“信任建构”的层面，为企业数字内容建设提供了理论指引。

在产业层面，Smyth与Dawson于2025年在《Journal of Brand Strategy》发表的论文首次系统阐述了GEM的概念框架，提出品牌需要确保被AI系统“准确理解”和“有效浮现”，并引入Share of Model平台通过提及率、平均位置、品类关联等新指标分析LLM

如何感知品牌[5]。该研究为GEM的度量体系建设提供了重要基础。

2.2 GEM的理论缺口

谢冬冬、岳宏志在《中国商论》2026年第9期发表的论文指出，当前围绕GEO的研究“多停留于技术操作层面，缺乏市场营销范式高度的理论建构”，并首次提出从营销战略范式视角构建GEM理论框架[6]。该研究揭示了GEM兴起的四大前提和五大根本性转变，提出了“从AI获取洞察”“向AI优化供给”双路径核心框架。

然而，上述研究均未系统回答一个关键问题：在GEM的付费投放场景中，优化的核心变量是什么？传统oCPC的出价优化逻辑在AI搜索场景中是否仍然适用？如果AI的行为数据密度已经足以预判交易意图，那么广告优化的起点应该是什么？

GEM-Bench的研究也明确指出，当前GEM领域“缺乏专门设计的基准”，这一空白“限制了未来研究”[7]。本文提出的CPCQ正是试图在“优化范式”这一维度上填补这一理论缺口。

3 CPCQ的理论建构

3.1 核心定义与命题

CPCQ（Cost Per Click Quantification，点击成本量化）是一种面向AI搜索结果广告的量化优化范式。其核心理论贡献在于：将广告优化的对象从“出价策略”转向“广告对象本身”。在GEM账户语境下，“广告对象本身”可进一步具象化为Ads DataAsset（广告数据资产），即结构资产、数据信号资产、创意资产与对话意图资产的总和。因此，CPCQ不仅是一种量化优化方法，也是一套Ads DataAsset的资产评估与增值方法论。

CPCQ的基本定义是：在AI搜索结果广告中，以多维度量化信号为核心，以建立量化基准、检测异常、优化投放为闭环，将不确定性广告效果转化为可比较、可追踪、可优化概率信号的优化方法论。其理论主张可以概括为一句话：GEM的核心不是优化“怎么买广告”，而是量化并增值“广告对象本身”——量化品牌在AI答案中的存在状态（答

案层资产）、量化用户与AI的交互深度（交互层资产）、量化交易意图的确定性程度（交易意图层资产），并通过持续优化使这些资产不断增值。

其核心命题可以形式化表达为：

传统oCPC的逻辑：设定转化目标 → 系统预估转化价值 → 智能出价。

CPCQ的逻辑：定义Ads DataAsset的量化维度 → 建立资产基准 → 基于资产反馈优化投放 → 实现资产增值。

oCPC的“O”是Optimized，优化的是出价策略；CPCQ的“Q”是Quantification，量化的是广告对象本身，即Ads DataAsset。oCPC是“先出价后量化”，CPCQ是“先量化后优化”，并在优化中实现资产增值。

这一区分的理论意义在于：oCPC假定优化师已经知道“什么值得被优化”，其工作是在既定目标下寻找最低成本的出价策略；CPCQ则指出，在AI搜索广告这一新场景中，“什么值得被优化”本身就是一个需要被回答的问题，而这个问题的答案就是Ads DataAsset——优化的起点不是出价，而是对广告数据资产的量化定义与增值规划。

3.2 方法论来源：量化交易的思想迁移

CPCQ的“量化”选择有明确的方法论出处——量化交易。

量化交易的核心逻辑是：不依赖人的直觉判断，而是通过系统化的数据建模、多因子分析和统计验证，将交易决策转化为可回测、可优化、可迭代的算法过程。它在金融市场的成功证明了一个基本命题：当决策变量足够多、市场变化足够快时，量化框架比经验判断更可靠。

AI搜索广告面临的恰恰是同样的局面。一次GEM投放涉及多平台、多轮对话、多维度效果信号，变量数量远超传统广告。金融领域的量化分析方法已经被引入移动广告技术领域。行业内已有实践者将金融量化分析方法引入广告技术领域（具体机构与年份以公开行业资料为准），其核心动因在于传统的流量价格评估体系难以准确衡量投放效果。这一实践验证了方法论迁移的可行性。

本文进一步将这一迁移系统化：量化交易中的基准建立（benchmarking）、异常检测（anomaly detection）、策略回测（backtesting）和统计验证（statistical validation）四个核心环节，分别对应CPCQ中的量化基准建立、效果偏离识别、优化策略验证和归因显著性检验。

3.3 哲学基础：在不确定性中量化确定性

广告本质上是一种不确定的业务。看到广告不见得购买，点击了不见得转化，转化了不见得复购。传统CPC承认这种不确定性，用“点击”作为第一次确定化信号。oCPC更进一步，用算法预测点击率和转化率，试图在不确定性中寻找概率最优解。

但oCPC仍然停留在“出价优化”层面。CPCQ的哲学基础可以用“确定性阶梯”来概括：曝光（不确定性最高）→点击（第一次确定化）→对话（第二次确定化）→交易意图（第三次确定化）→交易（最终确定化）。

CPCQ优化的不是某一个孤立的点击，而是这个确定性阶梯上的量化跃迁成本。它的Q，就是Quantification——量化。量化不是消灭不确定性，而是把不确定性拆解成可比较、可追踪、可优化的概率信号。这是CPCQ区别于oCPC的哲学内核。

3.4 数据基础：AI行为轨迹的连续性

如果说量化交易提供了方法论框架，那么AI行为数据则提供了量化维度的全新来源。

在SEM和Feeds AD时代，用户行为数据是碎片化的、场景化的——搜索关键词、浏览页面、点击记录。这些数据能反映意图，但无法构成一个连续的行为画像。

AI搜索改变了这一点。当用户与AI进行多轮对话时，AI积累的是一个连续的、上下文完整的、跨场景的行为数据流。这不是“用户在搜索什么”的离散信号，而是“用户正在经历什么”的连续叙事。这意味着AI搜索广告的精准逻辑发生了质变：传统广告的精准是“匹配”，AI搜索广告的精准是“预判”——AI基于对用户完整行为轨迹的理

解，在用户尚未明确表达需求时，就已经能够判断其决策阶段和潜在交易意图。

Kato等人提出的GMMM（Generative Marketing Mix Modeling）研究已经初步验证了这一方向：通过将赞助位置记录与注意概率相结合，可以估计GEM的因果效应[8]。CPCQ的量化维度体系正是建立在这一数据基础之上。

4 CPCQ量化维度体系与指标体系

4.1 三层量化维度

CPCQ的量化维度可分为三个层次，每一层都直接受益于AI行为数据的连续性：

第一层：答案层量化。品牌在AI生成答案中的状态不是二值的“出现/未出现”，而是连续的量化光谱。包括：AI引用率（品牌被AI提及的频次与概率）、排序位置（在多品牌共存时本品牌的推荐优先级）、信源引用总量（发布内容被AI的RAG机制抓取并作为参考来源的次数）。Smyth与Dawson提出的mention rate、average position和category associations等指标，正是在这一层面进行量化[5]。

第二层：交互层量化。用户与AI搜索广告的交互比传统广告更复杂。包括：对话发起率（用户是否在AI给出初步推荐后进一步追问）、用户停留时长、追问深度（揭示用户的决策阶段）。由于AI行为数据天然具有连续性，这些交互信号不是孤立的快照，而是可以串联为行为轨迹的序列数据。

第三层：交易意图层量化。这是CPCQ最具差异化的维度。当AI掌握了用户连续的行为轨迹后，可以构建“交易意图强度”的量化评分——用户处于认知阶段、评估阶段还是决策阶段；对品牌或品类的倾向性是否正在强化；近期行为信号是否指向即将发生的交易行为。Semrush（2025）对500余个主题的研究显示，通过ChatGPT等AI工具到达网站的访客，其转化率约为传统有机搜索访客的4.4倍，原因正在于这些访客是经过AI预筛选的高意向潜在客户[2]。

4.2 CPCQ指标体系设计

CPCQ不仅是一个主范式，也是一套指标体

系。其命名规则是：传统指标+Q（后缀式）。选择后缀而非前缀，基于三个理由：认知成本最低（保留CPM、CPC、CTR等行业的“肌肉记忆级”锚点）、发音更顺畅（避免辅音连缀）、理论逻辑更严密（传统指标是不确定性下的基础度量，Q是叠加在上面的“确定性量化”楼层）。CPCQ指标体系映射如表1所示。

CPCQ是“主义”，CPC-Q是“工具”。这一区分为GEM优化师提供了从方法论到考核指标的操作路径。

4.3 CPCQ优化工作流程

CPCQ落地主要围绕三个对象：①广告系列；②广告组；③广告创意。与“oCPC”先出价、后优化”不同，CPCQ要求每个环节先定义”量化什么”，再基于量化反馈优化投放。

步骤1：创建广告系列/活动——量化目标与约束（界定量化范围）

定义目标、预算、日期和定位，完成三项量化前置：目标对齐（明确对应确定性阶梯哪一层跃迁）、基准预设（建立AI引用率、排序位置、CTR-Q等基准线）、约束声明（预算、地区、平台边界）。无基准，后续异常检测便失去参照。

步骤2：创建广告组——量化意图与情境提示（编码量化信号）

广告组是CPCQ的核心操作层，承载最具差异化的动作：情境提示（Situation Hint）的量化采样与持续调优。其字段即广告组层级的上下文提示（Context Hint）——不是关键词匹配，而是帮助AI

理解广告适用场景的补充信息。CPCQ先按意图优先级将其分为三层：

H2核心场景：权重最高，优先匹配。描述用户最直接、最精准的核心需求，作首条提示，决定对最高意向流量的捕获。

H3次要场景：中等权重，次级匹配。描述衍生场景（比价、咨询、避坑、学习），承接考察期潜在客户。

H4边缘场景：最低权重，兜底匹配。描述相关但远离转化的外围场景，用于拓宽曝光。

三层之上，叠加H5条件层：描述具体条件与约束（地域、时间、价格、供给），将量化漏斗收窄到可执行的具体场景，决定具体场景胜出，如“在[城市]提供非营业时间住宅管道服务，上门费**美元”。

H2—H4按意图优先级分层（决定流量广度与权重），H5条件层叠加其上做精准限定（决定具体场景胜出），共同构成从宽到窄的量化漏斗。约束须转化为可量化提示并随变化同步更新。情境提示优化是持续闭环：采样→比对→调优→验证。核心逻辑：情境提示不是固定文案，而是持续量化的优化对象——这正是CPCQ区别于oCPC的关键。

步骤3：创建广告——量化创意与一致性（兑现量化跃迁）

创意含品牌名、Logo、标题、文案、图片、着陆页。CPCQ要求：要素符合量化规范（标题16—24字符、文案32—48字符、图片正方形≤1200×1200）；创意与情境提示语义一致；着陆页配置UTM与转化追踪，确保AI对话到落地页的行为路径可量化（以

表1. CPCQ指标体系映射表

编号	传统指标	CPCQ量化指标	含义
1	CPM	CPM-Q	每千次“有效量化曝光”的花费
2	CPC	CPC-Q	核心范式：先量化，再计费
3	CTR	CTR-Q	AI行为数据预判下的点击概率
4	CVR	CVR-Q	对话深度与追问意图带来的确定性转化率
5	CPA	CPA-Q	按“量化后的确定行动”付费
6	CPD	CPD-Q	基于用户全量行为轨迹的预判下载成本
7	CPI	CPI-Q	基于AI行为数据预判的安装激活成本
8	CTCVR	CTCVR-Q	从不确定曝光到确定交易的全链路量化
9	ROI	ROI-Q	剔除噪音后的真实量化收益

ChatGPT Ads Beta为例）。

步骤4：提交验证与量化启动 提交前验证必填字段、命名一致性、JSON格式、字符限制、链接有效性。投放后24小时内启动量化采样记录初始基准；因数据延迟，建议设48小时观察窗口，再进行首轮量化比对。

核心逻辑总结 CPCQ将“先量化，再优化”落到三层：系列层完成目标、基准与约束；广告组层完成H2/H3/H4/H5情境提示（Situation Hint）的量化闭环；创意层完成规范、一致性与着陆页验证。与oCPC线性流程不同，CPCQ是循环式：每次量化结果，都成为下一轮提示优化与创意迭代的基准输入。H2—H5 量化漏斗对照如表2所示。

CPCQ优化工作中的情境提示优化闭环

采样—基准—检测—调整—验证：

采样：按单条Hint拆分消耗、CTR-Q、CVR-Q、有效线索率；

建基：以H2高转化场景为基准，标记各层基线；

检测：识别高消耗低转化与高CTR-Q零转化场景；

调整：删/改劣质Hint、精简H4、收紧人群、加约束、预算向H2倾斜；

验证：重量化对比，以数据而非感觉判断。

情境提示是量化闭环最可操作的承载单元：既是维度先验采样，又是基准与检测对象。oCPC把“什么值得优化”交给黑箱，CPCQ交还优化师，通过分层、约束与持续调优，实现“先量化，再优化；量化即优化”。

4.4 量化优化闭环

CPCQ的运作闭环是：多维度量量化采样→量化基准建立→异常检测与策略调整→量化效果验证。

这一闭环的设计逻辑直接来自量化交易：建立基准，检测偏离，执行策略调整，验证调整效果。量化交易中，策略的有效性不靠“感觉”，靠回测和统计显著性检验。CPCQ同样如此——GEM投放的优化动作是否有效，需要用量化数据来回答。

5 讨论：CPCQ与oCPC的本质区别及可归因性

5.1 从“怎么买”到“买什么”

CPCQ与oCPC的根本区别不在于技术实现层面，而在于对“优化”的定义：

oCPC的“优化”：在既定转化目标下，寻找最低成本的出价策略。优化的是“怎么买”。

CPCQ的“优化”：在复杂的AI搜索场景中，量化多维度效果信号，基于量化反馈调整投放策略。优化的是“买什么”和“买到什么效果”。

更本质地看，oCPC建立在“用户会点击”的假设之上，而CPCQ建立在“AI已经知道用户想要什么”的洞察之上。当AI的行为数据密度足以预判交易意图时，广告优化的起点就不再是点击，而是对用户行为轨迹的量化理解。

5.2 可归因性挑战与应对

CPCQ面临的核心质疑是：量化维度如何避免沦为“看起来很美”的指标体系？答案是：CPCQ的量化维度必须具备可归因性。

行业内从业者提出的GEO归因思路提供了参考——预埋“暗号”关键词追踪二次搜索、链接追踪与平台闭环溯源、A/B测试与交叉对比[8]。这一思路与危机管理领域的双模型框架亦有相通之处：郭继伟在《危机破局》中提出的“PEPSC五度原则+6P原则”双模型，以心理、情绪、信息、手段、声明、风险六大层面的系统性准备，构建从预警、

表2. H2—H5量化漏斗对照表

层级	权重	匹配优先级	描述内容	量化作用
H2核心	最高	优先匹配	最精准核心需求，作首条提示	捕获最高意向流量
H3次要	中等	次级匹配	衍生场景（比价、咨询、学习）	承接潜在客户
H4边缘	最低	兜底匹配	相关但远离转化的外围场景	拓宽曝光
H5条件	叠加限定	场景胜出	具体条件与约束（地域、时间、价格）	决定具体场景胜出，如“非营业时间上门，**美元”

应对到恢复的全周期管理机制，其本质是在不确定性中建立可准备、可验证的量化基准，与CPCQ“先量化、再优化”的可归因逻辑一脉相承[9]。GMMM框架则通过exposed/control方法论建立了因果推断的统计基础[10]。CPCQ的量化优化不是追求“全知全能”的效果归因，而是在可验证的范围内建立量化基准，用数据证明优化动作确实干预了AI的输出结果。

5.3 研究局限与未来方向

本文作为CPCQ的理论建构研究，存在以下局限：第一，CPCQ的量化维度体系尚需更大规模的实证验证，目前主要基于逻辑推理和初步的行业实践观察；第二，AI搜索广告平台的数据开放程度有限，量化基准的建立面临数据获取的约束；第三，CPCQ与GEO、GMMM等框架的协同机制有待进一步研究。

未来研究可在以下方向展开：CPCQ量化维度的效度检验、跨平台量化基准的标准化、CPCQ优化闭环的实证效果评估，以及CPCQ与白帽GEO合规框架的整合研究。

6 总结

本文在GEM框架下提出了CPCQ（Cost Per Click Quantification，点击成本量化）量化优化范式。CPCQ的核心命题是：在AI搜索广告中，优化的第一性问题不是“出多少钱”，而是“量化什么”；其核心理论贡献在于，将广告优化的对象从“出价策略”转向“广告对象本身”。oCPC的“O”优化的是出价策略，CPCQ的“Q”量化的是广告对象本身。

CPCQ的理论来源是量化交易的方法论迁移，哲学基础是“在不确定性中量化确定性”，数据基础是AI行为轨迹的连续性。其量化维度体系覆盖答案层、交互层和交易意图层三个层次，指标体系采用“传

统指标+Q”的后缀式命名规则，优化闭环遵循“采样—基准—检测—调整—验证”的量化交易逻辑。

搜索营销的每一次范式转移，都要求优化师重新定义“什么值得被度量”。CPCQ的提出，正是试图在“量化”这个维度上完成AI搜索广告的范式转换。先量化，再优化；量化即优化。

参考文献

- [1]Google. Google's response to Pew Research Center study on AI Overviews[EB/OL]. (2025-07-22)[2026-09-21]. <https://www.google.com>.
- [2]SEMrush. AI search vs. organic search traffic study[R]. Boston: Semrush, 2025.
- [3]SPARKTORO. Zero-click search statistics 2026[R]. San Francisco: SparkToro, 2026.
- [4]何亚涛.AI搜索背景下GEO优化的信任跃迁机制与企业数字资产建设研究[J].环球社科评论,2026,3(4), 96-101.
- [5]SMYTH J, DAWSON J. Building a brand in the artificial intelligence era: Generative engine marketing[J]. Journal of Brand Strategy, 2025, 14(4): 310-321.
- [6]谢冬冬,岳宏志.AI快速发展背景下生成式引擎营销(GEM)的新范式研究[J].中国商论,2026(9):9-13.
- [7]HU S, ZHANG S, SHI Y, et al. GEM-Bench: A benchmark for ad-injected response generation within generative engine marketing[C]// Proceedings of the 32nd ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD '26). ACM, 2026.
- [8]张亮.解决了效果归因，GEO才能叫好又叫座[N].福布斯中国,2026-07-06.
- [9]郭继伟.危机破局：双模型赋能下的危机管理新范式[M].企业管理出版社,2025.
- [10]KATO M, HONMA D, KATO T. Generative marketing mix modeling: A causal inference framework linking GEO and GEM to business impact[J]. arXiv preprint arXiv:2609.11915, 2026.

