

## 基于椭球空间表征的数据动态定价方法

余增文<sup>1,2,3</sup>, 李国浩<sup>2</sup>, 池臧博<sup>3</sup>, 杨力<sup>1</sup>, 姜奇<sup>4</sup>, 方志<sup>2,3</sup>

(1. 西安电子科技大学计算机科学与技术学院, 陕西 西安 710071; 2. 国防科技大学大数据与决策国家级重点实验室, 湖南 长沙 410073;  
3. 北京计算机技术及应用研究所, 北京 100854; 4. 西安电子科技大学网络与空间安全学院, 陕西 西安 710071)

**摘要:** 在数据交易场景中, 数据所有者通常希望对不同消费者实施差异化定价以提升收益。然而, 消费者的估值模型往往不可得, 数据提供者只能依赖每轮交易的成交与否来间接推断其价格接受度。为此, 提出一种基于椭球空间表征的数据动态定价方法, 通过对椭球空间迭代裁剪的形式学习消费者的估值函数, 在每轮交易中设定更贴近真实估值的价格, 以实现收益最大化。此外, 进一步设计基于平行切分的椭球空间裁剪策略, 加快参数更新的收敛速度。理论分析表明, 所提方法满足无套利约束, 能够保证在线更新过程的有效性。基于真实数据集的实验验证了该方法在定价合理性、收敛速度和运行效率方面的显著优势。

**关键词:** 数据交易; 椭球空间表征; 动态定价; 椭球空间裁剪

**中图分类号:** TP399

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2026045

## Dynamic data pricing via ellipsoidal space representation

Yu Zengwen<sup>1,2,3</sup>, Li Guohao<sup>2</sup>, Chi Zangbo<sup>3</sup>, Yang Li<sup>1</sup>, Jiang Qi<sup>4</sup>, Fang Zhi<sup>2,3</sup>

1. School of Computer Science and Technology, Xidian University, Xi'an 710071, China

2. Laboratory for Big Data and Decision, National University of Defense Technology, Changsha 410073, China

3. Beijing Institute of Computer Technology and Application, Beijing 100854, China

4. School of Cyber Engineering, Xidian University, Xi'an 710071, China

**Abstract:** In data trading scenarios, differentiated pricing is often pursued by data owners across heterogeneous consumers to maximize revenue. However, consumer valuation models are typically unobservable, and price acceptance can only be inferred from binary transaction outcomes, indicating whether a transaction was accepted or rejected. To address this challenge, a dynamic pricing method based on an ellipsoidal representation of the valuation space was proposed. Consumers' valuation functions were learned by iteratively cutting the ellipsoid, and transaction prices were subsequently set to more closely approximate true valuations at each round. In addition, an ellipsoid cutting strategy based on parallel splits was introduced, through which valuation weights were estimated more accurately and the convergence of parameter updates was accelerated. Theoretical analysis showed that the proposed method satisfied the no-arbitrage constraint and ensured the effectiveness of the online update process. Experiments on real-world datasets demonstrated strong performance in pricing accuracy, convergence speed, and computational efficiency.

**Keywords:** data trading, ellipsoidal space representation, dynamic pricing, ellipsoid cutting

### 0 引言

随着信息基础设施的完善与数据资源的广泛积累, 数据已成为现代经济运行的重要依托, 其

价值实现机制也日益成为国家数字治理与制度创新的重点方向<sup>[1]</sup>。近年来, 我国围绕确权、流通、安全和定价等环节持续推进数据要素基础制度建

收稿日期: 2025-11-28; 修回日期: 2026-02-10

通信作者: 李国浩, guohaoli@nudt.edu.cn

基金项目: 国家自然科学基金资助项目(No.62572377, No.62472337)

**Foundation Items:** The National Natural Science Foundation of China (No.62572377, No.62472337)

设。2023年12月发布的《关于构建数据基础制度更好发挥数据要素作用的意见》首次提出构建数据作为生产要素的基础制度框架，并明确建立健全数据要素定价机制；2024年10月发布的《关于加快公共数据资源开发利用的意见》强调健全公共数据产品供给与定价机制，提升公共数据市场（data marketplace, DM）效率；2025年1月印发的《关于完善数据流通安全治理更好促进数据要素市场化价值化的实施方案》提出探索灵活的定价模式，引导形成合理的数据价格体系；2025年10月通过的《中共中央关于制定国民经济和社会发展第十五个五年规划的建议》进一步明确要健全数据要素基础制度，建设开放共享、安全的全国一体化数据市场，深化数据资源开发利用。上述政策共同推动数据定价由理念探索迈向制度化与应用化阶段。

数据定价是指数据提供方基于特定数据资源，结合消费者的潜在价值判断，对数据进行收益导向的定价决策过程<sup>[2-3]</sup>。在数据交易中，数据所有者通常希望针对不同消费者设定差异化价格，以提升整体交易收益。由于不同消费者对同一数据的支付意愿可能存在差异，若能准确把握其价值判断方式，便能实现更优定价<sup>[4-5]</sup>。为此，数据提供方通常依据多轮交易反馈不断调整报价以提高收益，这一随时间更新价格的策略即动态定价<sup>[6]</sup>。在该过程中，数据提供方根据成交结果持续修正对消费者估值的判断，从而逐步逼近其真实支付意愿<sup>[7]</sup>。然而，在实际数据交易中，数据动态定价仍面临两项关键挑战：其一，卖方无法直接获取消费者的估值信息，只能依赖交易是否达成这一有限反馈信号进行偏好推断<sup>[8]</sup>；其二，系统每轮仅产生“成交”或“未成交”等二元反馈，难以为定价策略提供充分的学习支撑，尤其在估值结构复杂或特征维度较高的情形下，易导致学习效率低与收敛速度慢的问题<sup>[9]</sup>。

针对上述估值不可见与反馈稀疏带来的困难，学界围绕数据动态定价开展了大量研究，相关工作大体可以归纳为3条技术路径。第一类方法基于行为反馈学习，从消费者的成交行为中反演其估值结构，通常假设支付意愿满足线性或广义线性形式，在每轮交互中依据成交与否构造线性不等式约束，通过在线学习方式更新可行解集。例如，Luo等<sup>[10]</sup>提出的无分布定价框架在探索与利用之间取得平衡，但在特征维度升高时收敛速度明显下降。

Erginbas等<sup>[11]</sup>将此类模型推广至多用户多商品情形，可刻画买家之间的竞争关系，但高度依赖成交反馈，稳定性受交互密度限制。Zhao等<sup>[12]</sup>进一步考虑非稳态环境，引入变化点检测与广义线性建模以适应偏好随时间的变化。Javanmard等<sup>[13]</sup>及后续研究<sup>[14-16]</sup>则尝试通过结构化参数表达增强多维估值的可学习性。总体来看，该类方法普遍依赖显式构造高维多面体约束，其更新过程在维度升高和反馈稀疏时面临计算复杂度高、收敛缓慢等问题。

第二类研究摆脱对估值函数的直接建模，转而从查询结构、策略形态或复杂度约束出发构造定价规则，以降低对估值分布假设的依赖。例如，部分工作从查询的覆盖范围与语义结构出发构建稳健的定价函数<sup>[17-18]</sup>。Jia等<sup>[19]</sup>基于价格单调复杂度分析不同策略类的遗憾下界，并给出相应的高效算法。Xu等<sup>[20]</sup>进一步在弱假设条件下分析线性策略的无遗憾性与抗噪能力。Perivier等<sup>[21]</sup>则在多维Logit模型下利用二阶信息提出在线牛顿步长算法，在对抗性环境中获得了 $O(d\sqrt{TnT})$ 的理论界限，其中 $d$ 表示特征维度， $T$ 表示交互轮次。然而，此类方法往往预先限定策略的表达形式（如线性）以控制复杂度，其表达能力在异质偏好和高维估值场景中受到一定限制，且在实际系统中仍可能面临计算与实现上的开销约束。

第三类方法从卖方收益角度出发，强调在定价过程中纳入隐私性或公平性等约束，以提升策略的可执行性与收益稳健性。例如，方嘉豪等<sup>[22]</sup>和Cai等<sup>[23]</sup>分别从属性隐私与高维私有数据出发，构建了面向隐私敏感场景的数据交易机制，强调在隐私保护约束下提升交易的可行性与卖方收益。Baby等<sup>[24]</sup>将卖方收益约束直接纳入优化模型，在非平稳上下文环境下取得较低的累计遗憾。Liu等<sup>[25]</sup>从公平性视角出发抑制不同群体间的价格差异，提升定价策略在策略性买家干预下的稳健性。相关工作强调机制稳健性与收益合理性，但往往需要额外的激励结构或隐私预算，难以在保持模型灵活性的同时兼顾高维估值的高效学习。

综上所述，尽管动态定价研究已取得诸多进展，但在实际数据交易场景中仍存在两点不足：其一，多数方法难以刻画估值权重随交互反馈的动态演化，使定价策略难以及时适应消费者偏好的变化；其二，依赖显式多面体约束或复杂策略空间的

估值学习方法在高维场景中计算开销显著,与真实数据市场的高频定价需求存在张力。

此外,随着数据要素市场建设逐步从可交易走向可规范交易,相关标准体系也在完善:一方面,交易平台需要对交易标的进行结构化描述与登记,以支持挂牌、撮合与结算等流程(如《信息技术数据交易服务平台交易数据描述》);另一方面,数据交易活动需要满足参与方、平台、标的与交易过程的安全要求,并可被监管与评估(如《数据安全 数据交易服务安全要求》)。在此背景下,面向标准化交易流程的动态定价方法需要明确其与确权合规、标的描述、过程留痕与审计评估等环节的衔接关系。

为此,本文以衔接现有标准为前提,在第一类行为反馈学习框架下开展研究,同时吸收第三类方法中对卖方收益的关注,引入椭球空间对估值权重进行几何表征,通过成交反馈驱动的椭球空间裁剪实现高维估值学习与报价策略更新,兼顾定价合理性、收敛速度和运行效率。本文的主要贡献如下。

1) 提出一种基于椭球空间表征的数据动态定价方法。数据提供方将消费者估值函数的权重参数视为椭球空间中的未知向量,在每轮交易中根据成交反馈构造线性不等式,对估值空间进行几何裁剪与迭代更新最小外接椭球,从而实现对消费者估值参数的推断与动态定价。

2) 进一步设计了一种基于平行切分的椭球空间裁剪机制,通过并行施加多组线性约束提升裁剪效率,增强对估值权重范围的表达精度,加快参数更新的收敛速度。

3) 分析与现有标准的适配性,证明满足无套利约束,并进行模拟实验评估。结果表明,该方法在周期驱动与盈余导向两类典型数据交易场景中表现出良好的定价合理性。同时,对比测试了基础方法与并行加速策略实现定价的运行效率,进一步验证了方法在实际应用中的计算可行性。

## 1 系统模型及问题定义

### 1.1 系统模型

图1展示了定价系统的3类实体:数据提供者(data provider, DP)、数据消费者(data consumer, DC)和数据市场。本文定价方法面向数据要素流通全流程的价格形成环节,可作为数据市场的定价

模块接入既有交易流程。其上游衔接确权登记与合规审查等前置步骤,下游对接估值核算、交付结算与安全审计等环节,并满足现有数据交易安全与合规要求,适配性分析见3.3节。



图1 系统模型

数据提供者是原始数据资产的所有者,依据预设的隐私补偿机制,生成初始报价,以覆盖隐私风险与合规成本。随后DP在多层交易过程中利用成交/未成交反馈对报价进行动态调整,以逐步贴近需求侧的真实支付意愿并提升整体收益。交易达成后,DP按既定的数据交付规则向需求方提供对应的数据产品或数据服务。

数据消费者是数据使用方实体,向数据市场提出查询请求并对目标数据形成支付意愿。本文假设DC的支付意愿由预设的线性估值函数给出,该估值刻画了DC在当轮请求下可接受的价格水平,并作为交易判定的输入之一。当交易达成时,DC按规则支付相应费用并获得对应的数据产品或数据服务。

数据市场是连接DP与DC的平台,负责提供统一的注册、认证、查询与响应接口,维护交易会话,并协调数据交付流程。DM本身不拥有数据,也不直接参与数据估值或定价,但其执行逻辑在系统中起到核心协调作用。

DM被视为可信实体,负责正确执行系统初始化配置,例如数据确权与身份认证等,并在交易过程中根据DC的报价与DP的定价进行匹配判断:若报价不低于定价,则判定交易成立。DP被视为诚实方,按照协议生成报价并在收到付款后提供数据。DC被假设为诚实但好奇的实体,可能通过多轮适应性交互分析定价反馈,以推断定价机制参数或隐含敏感信息并获取价格优势;但其诚实遵循协议流程,不会主动中止交易或以拒绝服务等方式干扰交易流程。此外,各实体间交互通信均受安全通道保护,不会受到来自外部的窃听、篡改、伪装等攻击。

### 1.2 目标与问题定义

本文的目标可以概括为以下3个方面。

定价合理性：DP 定价动态贴合 DC 的支付意愿，以提高交易成功率并实现收益最大化。

无套利约束：DC 不能通过拆分或重复查询，以更低成本获得等价数据。

计算效率：在保证估值表达能力的前提下，兼顾运行效率与收敛性能，使算法具备实际可行性。

围绕上述目标，现给出动态数据定价问题的形式化定义。令交易轮次为  $T = \{1, 2, \dots, N\}$ ，在第  $t \in T$  轮中，假设 DC 的估值行为可由线性模型刻画并以权重向量反映其对数据的偏好特征，即 DC 对数据视图  $\mathbf{x}_t \in \mathbb{R}^n$  的估值为  $v_t = \mathbf{x}_t^T \boldsymbol{\theta} + \delta_t$ ， $\boldsymbol{\theta} \in \mathbb{R}^n$  表示 DC 的估值权重参数， $\delta_t$  为独立扰动项，模拟主观估值不确定性。该设定与现有研究中普遍采用的线性估值假设一致<sup>[26-28]</sup>。在每轮交易中，DC 提交查询  $Q_t$ ，平台提取对应特征向量  $\mathbf{x}_t$ ，进而触发定价过程。由于  $\boldsymbol{\theta}$  与  $\delta_t$  对平台不可见，DP 仅可观测  $\mathbf{x}_t$ ，并通过历史反馈逐步逼近期望估值  $\mathbb{E}(v_t) = \mathbf{x}_t^T \boldsymbol{\theta}$ 。随后，DP 基于当前策略设定报价  $p_t$ ，若  $p_t \leq v_t$ ，交易达成并获得收益  $p_t$ ；否则，交易失败，收益为零。因此，为最大化总体收益，本文的目标是调整定价策略  $\mathcal{A}$ ，使多轮交互中的累积期望收益最大化。

$$\max_{\mathcal{A}} \sum_{t=1}^N \mathbb{E}(\mathbb{I}(p_t \leq v_t) \cdot p_t) \quad (1)$$

其中， $\mathbb{I}(\cdot)$  为指示函数，表示交易是否成功。定价策略  $\mathcal{A}$  包括基于交互反馈推测消费者估值参数的学习阶段，以及据此生成报价的价格发布机制，构成完整的动态定价过程。

为衡量当前定价与最优定价之间的差距，引入遗憾作为性能指标。设 DP 在第  $t$  轮设定的保留价格为  $r_t$ （发布价格不低于该值），令  $p$  表示 DP 可选择的报价值，则 DP 最优报价可表示为

$$p_t^* = \arg \max_{p \in [r_t, +\infty)} \{p \cdot \Pr(p \leq v_t)\} \quad (2)$$

第  $t$  轮的遗憾  $\text{reg}_t$  定义为当前报价相较最优报价造成的期望收益损失。

$$\text{reg}_t = \begin{cases} 0, & r_t > v_t \\ p_t^* \cdot \Pr(p \leq v_t) - p_t \cdot \mathbb{I}(p_t \leq v_t), & \text{其他} \end{cases} \quad (3)$$

平台的优化目标可转化为最小化累积遗憾  $\min \text{Reg}_t = \sum_{t=1}^N \text{reg}_t$ ，以实现长期收益最优。为实现最小化遗憾目标，每轮交易后，DP 根据成交反馈构造线性约束裁剪参数空间，并通过计算其最小外接椭球实现对估值参数  $\boldsymbol{\theta}$  的紧凑建模与迭代更新，从而实现定价策略  $\mathcal{A}$  的动态优化。

## 2 基于椭球空间表征的数据定价方法

图 2 为基于椭球空间表征的数据动态定价流程，每轮交易由 3 个阶段构成。首先，在交易查询提交阶段，数据消费者向平台提交交易查询请求，明确其所需访问的数据子集。平台将请求转发至对应的数据提供者，后者据此筛选符合条件的数据记录，并依据预设的隐私等级规则为每条记录计算隐私补偿值。数据提供者基于补偿信息构建估值所需的特征向量，并设定该轮的保留价格，再将特征向量返回至数据市场。其次，在数据估值与定价阶段，数据市场向数据消费者提供估值  $v_t$ ，并向数据提供者提供保留价格  $p_t$ 。数据提供者根据保留价格  $p_t$  选择发布价格  $p_t$ 。最后，在定价策略优化阶段，根据交易结果更新参数空间  $K_{t+1} = K_t \cap \left\{ \boldsymbol{\theta} \in \mathbb{R}^n \mid \begin{cases} \mathbf{x}_t^T \boldsymbol{\theta} > p_t, \mathbb{I}(p_t \leq v_t) = 1 \\ \mathbf{x}_t^T \boldsymbol{\theta} \leq p_t, \mathbb{I}(p_t \leq v_t) = 0 \end{cases} \right\}$ 。

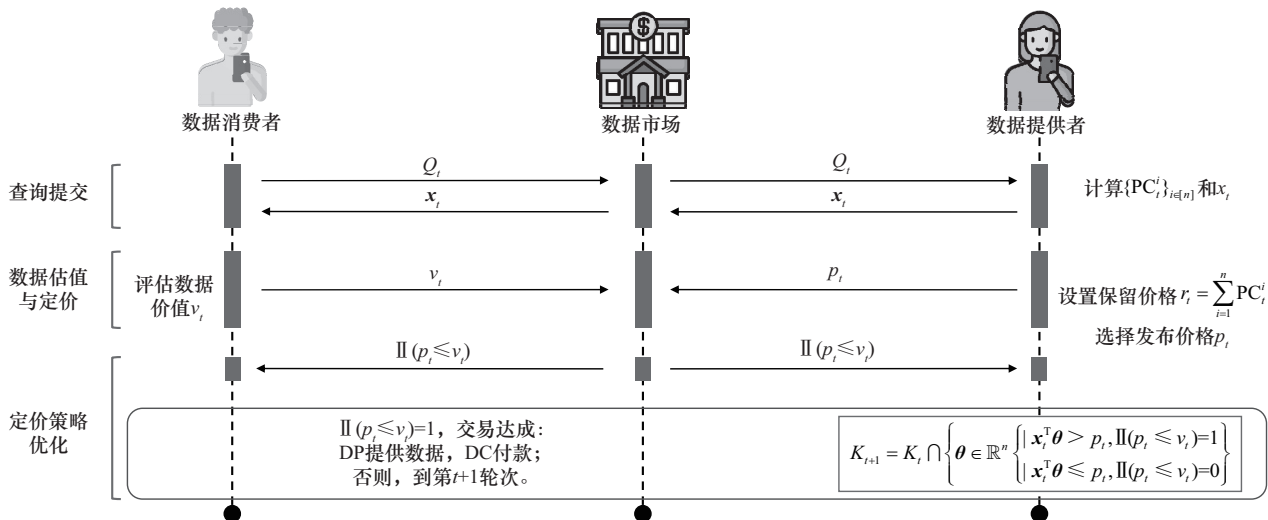


图 2 基于椭球空间表征的数据动态定价流程

段, 数据提供者根据探索策略生成发布价格, 数据消费者利用当前估值模型对所请求数据进行价值评估, 平台据此获取该轮的估值结果与发布价格。最后, 在交易执行与模型更新阶段, 平台比较估值结果与发布价格, 判断该轮交易是否达成。若估值不低于探索价格, 则判定成交; 反之, 则视为交易失败。平台随后将交易结果反馈给数据消费者与提供者。DP 根据成交标志更新估值参数的不确定空间: 若交易达成, 则构造约束强化当前特征方向上的估值; 若交易失败, 则收紧相应方向的估值上界。通过不断迭代裁剪参数空间并计算其最小外接椭球, DP 可逐步逼近 DC 的估值模型, 从而优化后续的定价策略。

隐私补偿 (privacy compensation, PC)<sup>[29]</sup>是指将数据使用所引入的隐私损失进行量化, 并以货币形式对数据提供者予以补偿的机制。隐私损失度量方面, 本文以文献[30]的信息论隐私含量计算方法为依据, 并假设可在查询执行前对该查询可能访问的记录隐私含量进行预评估。该方法以记录自身的熵刻画敏感度, 并进一步纳入记录与其他信息项之间统计关联引起的推断增益与隐私外溢, 从而得到表征隐私暴露与推断风险的隐私含量。基于该隐私含量, 本文进一步将本次查询涉及的记录划分为若干隐私等级, 并为不同等级配置相应的补偿标准, 以实现单次查询触发下可操作的隐私补偿分配 (详见2.1节)。

### 2.1 交易请求提交

数据交易的第一阶段由 DC 发起查询请求  $Q_t$  开始, 该请求描述了其希望访问的数据子集。DM 作为可信中介, 将请求转发给相应的 DP, 后者据此识别涉及的数据记录并计算交易所需的信息。该

阶段的核心任务是构造一组可用于估值模型输入的特征向量, 刻画当前查询对数据隐私的潜在影响。为此, 本文方法通过以下两步将查询请求映射为结构化的特征向量, 具体流程如下。

1) 数据视图生成与隐私补偿分配: 在第  $t$  轮交易中, DP 根据查询请求  $Q_t$  提取符合条件的数据记录, 构成当前轮次的数据视图  $view_t$ 。随后, 依据内部定义的隐私等级规则, 为数据视图中的每条记录分配对应的隐私补偿金额, 形成补偿向量  $PC_t = \{PC_t^1, PC_t^2, \dots, PC_t^n\}$ 。如图3所示, 当查询条件筛选出记录  $R_1$ 、 $R_2$  与  $R_3$ , 补偿向量即  $PC_t = (5.0, 3.0, 3.5)$ 。

2) 特征向量构造与保留价格计算: 为构造结构化输入特征, DP 将补偿向量  $PC_t$  划分为  $m$  个子组 ( $1 \leq m \leq n$ ), 并对每组求和以构造特征向量  $x_t \in \mathbb{R}^m$ 。该策略支持灵活调控粒度: 当  $m=1$  时,  $x_t$  仅反映总隐私成本; 当  $m=n$  时, 保留最细粒度的个体补偿信息, 如图3所示。此外, DP 计算当前数据视图该轮的保留价格  $r_t = \sum_{i=1}^n PC_t^i$ , 作为对该数据视图的最低可接受估值。在后续描述中, 令  $m=n$ , 即完成聚合后的特征向量  $x_t \in \mathbb{R}^n$  作为估值模型的输入, 用于后续的数据估值与定价流程。

### 2.2 数据估值与定价

在数据估值与定价阶段, 系统的目标是在有限反馈下合理选择发布价格, 以在保证交易成功概率的前提下不断提升收益并逼近 DC 的估值模型。该阶段包含两类操作: 一是由数据消费者根据数据特征向量  $x_t$  使用线性估值模型计算其主观价值  $v_t = x_t^T \theta + \delta_t$ ; 二是由 DP 确定一个合适的发布价格  $p_t$ , 用于诱导反馈与提升交易成功率。为了表征 DP 对

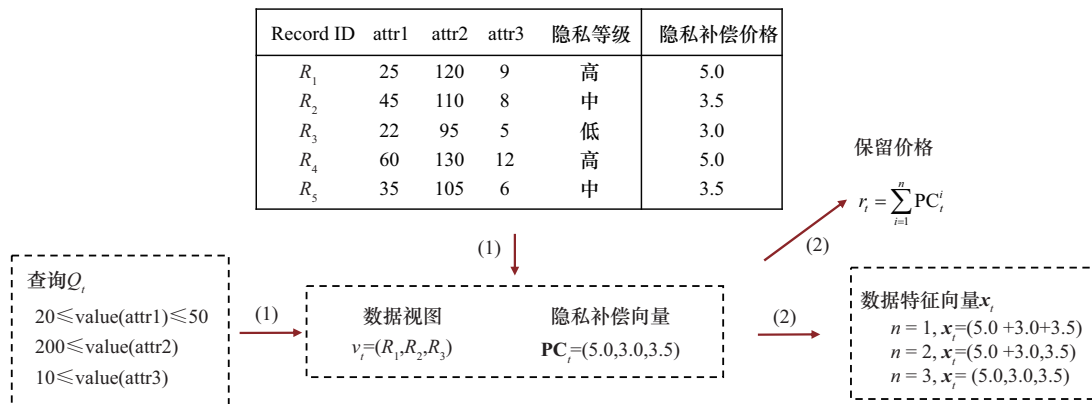


图3 特征向量构造示例

估值参数  $\theta$  的不确定性, 引入参数空间  $K_t \subseteq \mathbb{R}^n$ , 用于刻画其在第  $t$  轮交易前对  $\theta$  的可行猜测范围。该空间以线性约束的形式逐步构建, 每轮交易反馈都会引入一条新的线性不等式, 用于进一步裁剪参数空间。

DP 无法观测  $\theta$ , 因此只能基于当前参数估计空间  $K_t$  来推测  $v_t$  的可能取值区间。具体地, 其可计算估值的上下界为

$$\bar{p}_t = \max_{\theta \in K_t} \mathbf{x}_t^\top \theta, \underline{p}_t = \min_{\theta \in K_t} \mathbf{x}_t^\top \theta \quad (4)$$

同时, DP 根据当前数据视图的隐私补偿总量设定保留价格  $r_t = \sum_{i=1}^n \text{PC}_i^t$ , 作为最低可接受价格下界。此时, 发布价格需满足  $p_t \geq \max(r_t, \underline{p}_t)$ 。为了在估值区间  $[\underline{p}_t, \bar{p}_t]$  内合理探索, 引入两类定价机制: 探索价格与利用价格, 旨在在长期收益最大化与短期交易成功之间实现动态平衡。

**探索价格:** 该机制强调主动探索估值空间, 关注长期总体收益的提升。该策略下发布价格为

$$p_t = \max\left(r_t, \frac{\bar{p}_t + \underline{p}_t}{2}\right) \quad (5)$$

**利用价格:** 该机制侧重于当前收益的实现, 依据历史成交反馈选择更有可能促成交易的价格区间, 避免不必要的模型扰动与参数更新。该策略下发布价格为

$$p_t = \max(r_t, \underline{p}_t) \quad (6)$$

为在两类定价策略之间实现灵活切换, 设定阈值  $\epsilon > 0$ 。当探索价格与利用价格之间的差异满足  $\epsilon > |\bar{p}_t - \underline{p}_t|$ , 则优先使用探索价格以提升估值模型的泛化能力; 否则, 优先使用利用价格策略。该混合机制兼顾参数学习的探索性与收益实现的稳定性, 能够在多轮交易过程中自适应地调整定价行为。

### 2.3 定价策略优化

当 DM 收到来自 DC 的估值  $v_t$  与 DP 的发布价格  $p_t$  后, 若满足  $\mathbb{I}(p_t \leq v_t) = 1$ , 则交易达成, DC 支付费用, DP 提供数据; 否则交易失败, 平台将交易结果反馈给 DP, 用于其后续定价策略的动态调整。为逼近 DC 的真实估值模型, DP 在交易过程中维护关于估值参数  $\theta$  的估计空间  $K_t$ 。在 2.2 节中, 定价策略依赖于该估计空间的动态演化。本节将详细阐述基于椭球几何结构的更新方法, 实现对

$K_t$  的迭代收缩。具体而言, 在每轮交易结束后, DP 根据成交与否的反馈结果生成一组线性约束, 对当前估计空间  $K_t$  进行裁剪并更新为更紧致的  $K_{t+1}$ 。该过程在不断缩小估值误差范围的同时, 使估值参数逐步逼近 DC 估值模型中的真实权重向量  $\theta$ , 进而保证定价的合理性, 最大化 DP 利益。

2.2 节已给出 DP 依据价格差异阈值进行定价策略选择的机制。若其第  $t$  轮选择探索价格作为发布报价, 则根据交易反馈更新估值参数空间; 反之, 若选择利用价格, 则估值空间保持不变, 仅用于收益最大化。因此, 估值空间的演化仅在执行探索行为时发生。DP 在每轮交易后以最小外接椭球  $E_t$  对当前参数估计空间  $K_t$  进行紧凑逼近, 并在后续报价策略中用作估值边界。将 DP 在第 1 到第  $t$  轮中基于历史反馈信息所进行的估值参数空间学习过程展示如下。

**初始空间设定:** 系统初始假设估值参数  $\theta$  落在一个有界区间内, 对每个分量  $\theta_i$  给定上下界  $[l_i, u_i]$ , 构成初始参数空间  $K_1 = \{\theta \in \mathbb{R}^n | l_i \leq \theta_i \leq u_i, l_i \in \mathbb{R}, u_i \in \mathbb{R}\}$ , 这是一个凸多面体, 为后续计算便利, 令其最小外接椭球为初始估计椭球  $E_1$ , 其中

$$E_1 = \{\theta \in \mathbb{R}^n | \|\theta\|_2 \leq D\}, D = \sqrt{\sum_{i=1}^n \max(l_i^2, u_i^2)} \quad (7)$$

**参数空间更新:** 在每一轮交易中, DP 通过是否成交反馈可获得一条关于  $\theta$  的线性约束, 用于裁剪当前估计空间  $K_t$ 。设第  $t$  轮的查询特征为  $\mathbf{x}_t$ , 发布价格为  $p_t$ , 则参数空间的更新规则为

$$K_{t+1} = \begin{cases} K_t \cap \{\theta \in \mathbb{R}^n | p_t > \mathbf{x}_t^\top \theta\}, & \mathbb{I}(p_t \leq v_t) = 0 \\ K_t \cap \{\theta \in \mathbb{R}^n | p_t \leq \mathbf{x}_t^\top \theta\}, & \mathbb{I}(p_t \leq v_t) = 1 \end{cases} \quad (8)$$

该过程使得  $K_{t+1}$  保持为凸多面体, 随着交易轮数增加而逐步收缩。

**椭球逼近与区间估值:** 为便于后续计算, 用一个最小外接椭球  $E_{t+1}$  对每轮裁剪后的  $K_{t+1}$  进行紧致逼近。DP 可估计当前特征向量  $\mathbf{x}_t$  下的最大估值  $\bar{p}_t = \max_{\theta \in K_t} \mathbf{x}_t^\top \theta$  与最小估值  $\underline{p}_t = \min_{\theta \in K_t} \mathbf{x}_t^\top \theta$ 。若当前保留价格  $r_t$  超过估值上界  $\bar{p}_t$ , 即满足  $p_t > r_t > \bar{p}_t > v_t$ , 则可断定该轮交易必然失败, 不需要进行尝试。若  $r_t < \underline{p}_t$ , 则系统将根据估值区间宽度  $\bar{p}_t - \underline{p}_t$  与阈值  $\epsilon$  比较, 选择探索价格策略或利用价格策略。无论如何选择, 实际交易反馈仍将作为裁剪当前椭球  $E_t$

的依据,从而更新下一轮的估值空间  $K_{t+1}$ ,并构造其外接椭球  $E_{t+1}$ ,完成本轮学习闭环。此时切分超平面为  $\{\theta \in \mathbb{R}^n | p_t = \mathbf{x}_t^T \theta\}$ 。DP可以通过计算  $\alpha_t = \frac{\bar{p}_t + p_t}{2} - p_t$ , 即在  $\mathbb{R}^n$  中从椭球中心  $\mathbf{c}_t \in \mathbb{R}^n$  到该切分超平面的距离来定位此超平面。

考虑估值扰动下的缓冲更新机制:前述裁剪逻辑默认估值过程为确定性计算,未显式考虑潜在估值误差。然而在实际交易中,DC对查询视图的估值不可避免地受到主观判断与环境因素的扰动。为此,在估值模型中引入扰动项  $\delta_t$ ,形式为  $v_t = \mathbf{x}_t^T \theta + \delta_t$ ,其中  $\delta_t$  描述了估值的随机性偏差。

假设  $\delta_t$  服从  $\sigma$ -次高斯分布,即存在常数  $C \in \mathbb{R}^+$  使

$$\forall z > 0, \Pr(|\delta_t| > z) \leq C \cdot \exp\left(-\frac{z^2}{2\sigma^2}\right) \quad (9)$$

由次高斯尾界不等式(10)可得,其一组可行解为  $z = \sqrt{2\ln C} \cdot \sigma \ln N$ ,从而有

$$\forall t \in [N], \Pr(|\delta_t| \leq z) \geq 1 - N^{1-\ln N} \geq 1 - \frac{1}{N} \quad (10)$$

即估值扰动在每一轮中以至少  $1 - \frac{1}{N}$  的概率被上界  $z$  所约束。基于该界限,系统可引入固定缓冲量  $z$ ,以提升参数空间裁剪时的鲁棒性,避免因单轮误差导致空间误剪。当发布价格  $p_t$  被拒绝 ( $p_t > v_t$ ) 时,DP对  $\theta$  做出估计。

$$p_t > v_t = \mathbf{x}_t^T \theta - \delta_t \geq \mathbf{x}_t^T \theta - z \quad (11)$$

进而获得对  $\theta$  的保守上界约束。相应地,若发布价格  $p_t$  被接受 (即  $p_t \leq v_t$ ),则有

$$p_t \leq v_t = \mathbf{x}_t^T \theta + \delta_t \geq \mathbf{x}_t^T \theta + z \quad (12)$$

据此获得保守下界信息。当保留价格满足  $p_t \geq r_t \geq \bar{p}_t + z \geq v_t$ ,可直接判定交易不会发生。在价格决策上,也可根据扰动边界优化探索策略。为提升交易成功率,DP将发布价格设为  $p_t = \max(r_t, \bar{p}_t - z)$  从而保证即便估值出现负向偏移,依然具备达成交易的可能性。

此外,基于椭球表征的动态定价过程每一次迭代通常伴随数值计算误差的累积,导致椭球可能无法准确地包含待求解的凸集。为了克服这一问题,对迭代过程中产生的椭球进行适度的放大(乘以系数  $\xi$ ),确保新的椭球可以安全地包围原始凸集,以

防止数值误差带来的椭球漂移。这种放大过程对椭球矩阵进行比例调整,保证每一步迭代后的椭球都严格包含目标集合,从而维持算法的理论正确性与收敛性。完整定价过程如算法1所示。

**算法1** 基于 Löwner-John 椭球的动态数据定价算法

输入  $A_1 = D^2 I_{n \times n}, \mathbf{c}_1 = \mathbf{0}_{n \times 1}, D = \sqrt{\sum_{i=1}^n \max(l_i^2, u_i^2)}$ ,

$\epsilon, \delta = \sqrt{2\ln C \ln N}$

输出 发布价格  $p_t$

1) for  $t = 1$  to  $N$

2) 产生特征向量  $\mathbf{x}_t \in \mathbb{R}^n$ , 计算保留价格  $r_t$

3)  $\mathbf{b}_t = \frac{A_t \mathbf{x}_t}{\sqrt{\mathbf{x}_t^T A_t \mathbf{x}_t}}, \xi = 1 + \frac{(\alpha_t n)^2}{2n^2}$

4)  $\bar{p}_t = \max_{\theta \in K_t} \mathbf{x}_t^T (\mathbf{c}_t + \mathbf{b}_t), \underline{p}_t = \min_{\theta \in K_t} \mathbf{x}_t^T (\mathbf{c}_t - \mathbf{b}_t)$

5) if  $r_t \geq \bar{p}_t$  then

6)  $A_{t+1} = A_t, \mathbf{c}_{t+1} = \mathbf{c}_t$

7) else

8) if  $\bar{p}_t - \underline{p}_t \geq 2\sqrt{\mathbf{x}_t^T A_t \mathbf{x}_t} > \epsilon$  then

9)  $p_t = \max(r_t, \frac{\bar{p}_t + p_t}{2})$

10) if  $p_t$  被拒绝 then

11)  $\alpha_t = \frac{p_t + \delta - \mathbf{x}_t^T \mathbf{c}_t}{\sqrt{\mathbf{x}_t^T A_t \mathbf{x}_t}}$

12) if  $-\frac{1}{n} \leq -\alpha_t \leq 1$  then

13)  $A_{t+1} = \xi \frac{n^2(1 - \alpha_t^2)}{n^2 - 1} [A_t -$

$\frac{2(1 - n\alpha_t)}{(n+1)(1 + \alpha_t)} \mathbf{b}_t \mathbf{b}_t^T], \mathbf{c}_{t+1} = \mathbf{c}_t -$

$\frac{1 - n\alpha_t}{n+1} \mathbf{b}_t$

14) else

15)  $A_{t+1} = A_t, \mathbf{c}_{t+1} = \mathbf{c}_t$

16) end if

17) else

18)  $\alpha_t = \frac{p_t - \delta - \mathbf{x}_t^T \mathbf{c}_t}{\sqrt{\mathbf{x}_t^T A_t \mathbf{x}_t}}$

19) end if

20) else

21)  $p_t = \max(r_t, \underline{p}_t - \delta)$

- 22)  $A_{t+1} = A_t, c_{t+1} = c_t$
- 23) end if
- 24) end if
- 25) return  $p_t$
- 26) end for

#### 2.4 基于椭球平行切分的动态定价加速方法

在参数空间更新中, 若仅依赖单侧切分, DP 会基于交易反馈生成单一约束并对估值空间进行裁剪。虽然该方法实现较为简单, 但约束条件过于单薄, 往往导致空间收缩过激, 进而引起估值偏移或学习振荡。在算法 1 中, DP 根据交易结果对 DC 的估值权重  $\theta$  进行迭代裁剪。其基本形式是利用交易反馈生成的单一线性约束划分潜在空间, 即获取满足以下条件的  $\theta$  并计算其最小外接椭球。

$$K_{t+1} = E_t \cap \{ \theta \in E_t | \mathbf{x}_t^T \theta \geq \mathbf{x}_t^T \mathbf{c}_t + \alpha_t \}, \alpha_t \in [0, 1] \quad (13)$$

受 Liao 等<sup>[31]</sup>研究的启发, 相比于这种单侧切分, 采用双侧线性约束构造的裁剪区间能够显著提高紧致性与稳定性, 从而避免过度收缩带来的误估或振荡。具体而言, 平行切分策略在椭球中心两侧引入对称超平面, 其约束形式为

$$K_{t+1} = \{ \theta \in E_t | \mathbf{x}_t^T \mathbf{c}_t + \alpha_t \leq \mathbf{x}_t^T \theta \leq \mathbf{x}_t^T \mathbf{c}_t + \beta_t \} \quad (14)$$

其中,  $\alpha_t = \frac{-\max(r_t, p_t)}{\sqrt{\mathbf{x}_t^T A_t \mathbf{x}_t}}$  和  $\beta_t = \frac{p_t}{\sqrt{\mathbf{x}_t^T A_t \mathbf{x}_t}}$  控制裁剪

带宽。令  $-1 \leq \alpha_t \leq \beta_t \leq 1$ , 可通过对椭球平行切分更新  $K_{t+1}$ , 如算法 2 所示。该策略引入中心对称的裁剪方式, 从而改变了椭球形状  $A_t$  的秩, 满足  $\text{rank}(A_{t+1}) = \text{rank}(A_t) - 1$ 。这意味着仅需简单的浮点运算即可求得  $(\eta, \tau, \rho, \sigma)$  等参数, 使得椭球  $E_{t+1}$  在  $\mathbf{c}_t$  方向维度上进一步缩减, 搜索空间得以显著压缩, 从而提升了计算效率与估值精度 (详见算法 2)。

基于椭球平行切分的动态定价加速方法在复杂度上保持可控的多项式级开销: 每轮计算与更新均为  $O(n^2)$ , 总体运行规模随交易轮次呈线性增长。同时, 在有限探索轮次下, 该方法保证累积遗憾的上

界为  $O(\max(n^2 \ln(\frac{N}{n}), \frac{n^3 \ln(\frac{N}{n})}{N}))$  (详见定理 1)。

**算法 2** 基于椭球平行切分的动态定价加速方法

输入  $\alpha_t, \beta_t, A_t, \mathbf{c}_t, \mathbf{b}_t$

输出 第  $t+1$  轮椭球体参数  $A_{t+1}, C_{t+1}$

- 1) if  $\alpha_t \beta_t < -\frac{1}{n}$  then
- 2)  $A_{t+1} = A_t$
- 3)  $\mathbf{c}_{t+1} = \mathbf{c}_t$
- 4) else if  $-\frac{1}{n} < \alpha_t \beta_t \wedge (\alpha_t + \beta_t) \neq 0$  then
- 5)  $\zeta = 1 + \frac{(\alpha_t n)^2}{2n^2}$
- 6)  $\eta = \sqrt{4(1 - \alpha_t^2)(1 - \beta_t^2) + n^2(\beta_t^2 - \alpha_t^2)^2}$
- 7)  $\tau = \frac{2(1 - n\alpha_t) + n(\beta_t^2 - \alpha_t^2)^2 - \eta}{(n+1)(\beta_t^2 - \alpha_t^2)^2}$
- 8)  $\rho = \frac{(\beta_t - \alpha_t)\tau}{2}, \sigma = \frac{n^2(2 - \alpha_t^2 - \beta_t^2 + \frac{\eta}{n})}{2(n^2 - 1)}$
- 9)  $A_{t+1} = \zeta \sigma (A_t - \tau \mathbf{b}_t \mathbf{b}_t^T)$
- 10)  $\mathbf{c}_{t+1} = \mathbf{c}_t + \rho \mathbf{b}_t$
- 11) else if  $-\frac{1}{n} < \alpha_t \beta_t \wedge (\alpha_t + \beta_t) = 0$  then
- 12)  $A_{t+1} = \frac{\zeta n(1 - \beta_t^2)(A_t - \frac{1 - n\beta_t^2}{(1 - \beta_t^2)} \mathbf{b}_t \mathbf{b}_t^T)}{n - 1}$
- 13)  $\mathbf{c}_{t+1} = \mathbf{c}_t$
- 14) end if
- 15) return  $A_{t+1}, \mathbf{c}_{t+1}$

#### 2.5 非线性估值模型泛化与多用户竞争场景定价策略扩展

1) 基于核化椭球空间表征的动态数据定价

当估值函数呈现非线性时, 可借鉴 Srinivas 等<sup>[32-33]</sup>关于核函数建模与不确定性刻画思路, 将估值函数置于核诱导的隐式特征空间中进行表征, 并在该空间内维护其可行范围, 结合成交反馈逐步收紧该范围, 从而将本文方法自然推广到非线性估值结构。

具体而言, 设非线性估值满足  $v(\mathbf{x}_t) = f(\mathbf{x}_t) + \delta_t$ 。其中,  $f \in \mathcal{H}_k$  表示由核函数  $k(\cdot, \cdot)$  诱导的再生核希尔伯特空间  $\mathcal{H}_k$  中的未知估值函数, 用于表征消费者对查询特征的非线性估值结构。记  $\hat{f}_t$  为第  $t$  轮基于历史反馈得到的当前估计函数, 可由核展开的在线更新准则构造。围绕  $\hat{f}_t$  在核空间中定义非线性椭球可行集合  $\mathcal{C}_t = \{ f \in \mathcal{H}_k : \| f - \hat{f}_t \|_{\mathcal{H}_k} \leq \beta_t \}$ , 其中  $\beta_t$  刻画估值不确定半径。每轮成交或未成交反馈

可转化为对 $f(x_t)$ 的约束,从而对 $\mathcal{C}_t$ 进行收缩更新,并由更新后的可行集合诱导估值区间以生成当轮价格,形成“核空间非线性估值建模—非线性椭球表征—收缩更新—动态定价”的扩展路线。

## 2) 并发询价下的权重驱动用户选择

当第 $t$ 轮出现多用户并发询价时,可采用“先选后价”的思路,将并发竞争规约为与本文一致的单用户序列交互。

具体做法是,平台先在并发到来的请求集合 $\mathcal{U}_t$ 中确定本轮被服务的用户 $i_t^*$ ,随后对 $i_t^*$ 直接复用本文基于椭球空间表征的动态定价与反馈裁剪更新流程。该扩展仅在定价前增加一次服务选择,不改变本文核心机制与更新逻辑,从而提升方法对实际数据市场并发请求场景的适用性。为刻画平台的服务规则与历史贡献,可为每个用户维护优先级权重 $w_{i,t}$ ,用于综合反映其历史成交贡献与平台治理目标<sup>[34]</sup>,例如近期成交收益较高者权重更大,同时对新用户保留适度倾斜以避免长期只服务头部用户。在并发到来时,平台可基于本文椭球表征为每个候选请求计算一个保守价格 $\tilde{p}_{i,t}$ (例如由估值下界给出,或在下界基础上作轻微折扣以吸收不确定性),并以 $w_{i,t}\tilde{p}_{i,t}$ 作为本轮评分,选择 $i_t^* = \arg \max_{i \in \mathcal{U}_t} w_{i,t}\tilde{p}_{i,t}$ ,被选择的用户进入当轮交互并产生反馈用于椭球裁剪更新,其余请求顺延至后续轮次处理。该选择规则可理解为在资源受限条件下对收益与服务优先级的联合权衡,与优先级服务定价相关研究中“通过价格与优先级差异化实现收益提升”的思想一致。

## 3 方案分析

本节首先给出无套利性的定义,并证明所提定价方案满足无套利要求,随后对方案的时间与空间复杂度进行分析,最后讨论方案与现有政策及相关标准的适配性。

### 3.1 无套利性定义与证明

在数据市场中,确保DC无法通过任务拆分等操作绕过正常定价机制,是实现公平交易的基础要求。这种要求被形式化为无套利性,要求定价函数对整体查询的定价不高于所有子查询价格之和,从而防止不当获利行为。所提出的定价函数严格满足无套利性约束。

**定义1** 无套利性。设定价函数 $\pi(Q)$ ,若对任意查询任务 $Q$ 及其可分解的互斥子查询集合 $\{Q_1, Q_2, \dots, Q_m\}$ ,满足 $Q = \bigcap_{i=1}^m Q_i$ 且 $\forall i=j$ ,

$Q_i \cap Q_j = \emptyset$ ,皆有 $\pi(Q) \leq \sum_{i=1}^m \pi(Q_i)$ ,则称 $\pi(\cdot)$ 为无套利性定价函数。

**定理1** 动态定价函数满足无套利性。所提定价方法在每轮交易中生成的定价函数 $\pi(\cdot)$ 满足定义1所述的无套利性约束,即对任意查询任务 $Q$ 及其可分解的互斥子查询集合 $\{Q_1, Q_2, \dots, Q_m\}$ ,均有 $\pi(Q) \leq \sum_{i=1}^m \pi(Q_i)$ 。

**证明** 第 $t$ 轮查询定价为 $p_t = \max\left(r_t, \frac{\bar{p}_t + \underline{p}_t}{2}\right)$

或 $p_t = \max(r_t, \underline{p}_t)$ ,其中 $\bar{p}_t$ 与 $\underline{p}_t$ 分别为当前轮估值参数空间的下界与上界, $r_t$ 为保留价格,满足 $r_t \leq v_t$ , $v_t$ 为该轮真实估值。

**步骤1** 假设套利存在。假设该定价机制不满足无套利性,则存在查询组合 $\phi \subseteq \{1, 2, \dots, m\}$ ,使DC可以通过组合查询获取套利收益,即 $\sum_{i \in \phi} p_t < \sum_{i \in \phi} v_t$ 。

**步骤2** 分析单轮定价机制。对于任意单次查询 $Q_i$ ,其定价始终满足 $p_t \geq r_t$ 。若

- 1)  $p_t > v_t$ ,则数据消费者不接受报价,该轮交易未达成,不会产生任何套利收益;
- 2)  $p_t \leq v_t$ ,交易达成,数据消费者支付不少于 $r_t$ 的金额。

因此,每轮套利空间受限于估值误差,且不会出现显著低估或高估行为被持续利用的情形。

**步骤3** 估值空间的动态收敛。由于基于椭球空间建模的估值参数上下界 $(\bar{p}_t, \underline{p}_t)$ 会随查询反馈逐步收敛,存在任意小的 $\epsilon > 0$ ,使得在充分多轮交互后有 $|\bar{p}_t - \underline{p}_t|, |\bar{p}_t - v_t|$ ,以及 $|\underline{p}_t - v_t|$ 均不超过 $\epsilon$ 。即定价误差满足 $\lim_{t \rightarrow \infty} |p_t - v_t| = 0$ ,套利空间趋于消失。

**步骤4** 推广至组合查询。将上述收敛结果推广至任意有限查询组合 $\phi$ ,易得 $\sum_{i \in \phi} p_t \approx \sum_{i \in \phi} v_t$ 。即使初期存在定价误差,随着查询轮次增加,整体套利

空间逐步收缩, 最终满足当  $|\phi| \rightarrow \infty$ ,  $\sum_{t \in \phi} |p_t - v_t| \rightarrow 0$ 。

这与步骤 1 中的假设矛盾, 故假设不成立。

综上, 所提出的定价机制满足无套利性原则。

### 3.2 空间复杂度与时间复杂度分析

在一次数据定价过程中, DP 在第  $t$  轮的数据计算开销主要来自两个部分: 一是计算发布价格, 另一是更新椭球的中心  $c_t$  和形状  $A_t$ 。对前者而言, 计算  $p_t$  需要进行  $n$  维的矩阵-向量乘法与向量-向量乘法, 对后者而言, 更新椭球相关参数主要进行一维的向量-向量运算, 时间复杂度为  $O(n^2)$ , 考虑到  $A_t \in \mathbb{R}^{n \times n}$  的矩阵, 描述椭球中心的  $c_t$  向量为  $(n \times 1)$  的向量, 空间复杂度为  $O(n^2)$ 。

为分析加速定价方法在迭代过程中的误差积累与遗憾上界, 需首先界定方法在交易过程中进行价格探索的轮次数。由于探索价格会触发椭球空间的更新, 故其迭代次数与椭球体积的收缩过程密切相关。特别地, 探索轮数的界定依赖于交易反馈对所维护的 Löwner-John 外接椭球体积变化的影响范围。有研究<sup>[35]</sup>已对椭球在一次切分后, 其新外接椭球体积相对于原始椭球体积的上界进行了界定, 而下界则可通过最小特征值的下界估计获得。为便于推导累积遗憾的上界, 本文引入以下 3 个命题, 用以刻画特征值变化、探索轮数与空间收缩之间的定量关系。

**命题 1** 对于第  $t$  轮交易, 若  $\epsilon \geq 4n\delta$ , 且存在常数  $\zeta \in \mathbf{R}$  使  $\gamma_n(A_t) \leq \zeta\epsilon^2$  且  $\mathbf{x}_t^T A_t \mathbf{x}_t \geq \frac{\epsilon^2}{4}$ , 则有  $\gamma_n(A_{t+1}) \geq \gamma_n(A_t)$ 。

**命题 2** 若在第  $t$  轮采用探索价格策略, 则椭球特征值的更新满足  $\gamma_n(A_{t+1}) \geq \frac{n^2(1-\beta_t^2)}{(n+1)^2} \gamma_n(A_t)$ 。

**命题 3** 在满足上述条件的前提下, 探索价格的使用次数不超过  $T_e \leq 2n^2 \ln(2DL^2 \frac{n+1}{\epsilon})$ ,  $L$  是特征向量的范数上界。

**定理 2** 如果  $\delta = O(\frac{n}{N})$ , 交易中最坏情况下

的遗憾上界为  $O\left(\max\left(n^2 \ln\left(\frac{N}{n}\right), \frac{n^3 \ln\left(\frac{N}{n}\right)}{N}\right)\right)$ 。

**证明** 设交易总轮次为  $N$ , 在第  $t$  轮交易中, 由于选择探索价格而造成的遗憾其上界为  $\bar{p}_t + \delta$ ,

又由于  $\bar{p}_t = \max_{\theta \in K_t} \mathbf{x}_t^T \theta$ , 则上界可进一步被界定为

$DL + \delta$ , 因而由于选择探索价格造成的累积遗憾不超过  $T_e(DL + \delta)$ , 当选择利用价格时, 其遗憾上界为  $(\bar{p}_t + \delta) - (p_t - \delta)$ 。又由于此时  $\bar{p}_t - p_t < \epsilon$ , 则由于选择利用价格造成的遗憾上界为  $(\epsilon + 2\delta)$ 。整个交易中的累积遗憾其上界为  $T_e(DL + \delta) + (N - T_e)(\epsilon + 2\delta)$ 。当  $\delta = O(\frac{n}{N})$ ,  $T_e$  选择其上界  $2n^2 \ln(2DL^2 \frac{n+1}{\epsilon})$ , 且  $\epsilon$  被设  $\max(\frac{n^2}{N}, 4n\delta)$  时, 整个交易在最坏情况下累积遗憾上

界为  $O\left(\max\left(n^2 \ln\left(\frac{N}{n}\right), \frac{n^3 \ln\left(\frac{N}{n}\right)}{N}\right)\right)$ 。

### 3.3 政策适配性分析

#### 1) 与相关政策、标准的适配性分析

本文方法的适配性可从价格形成机制与交易安全要求两个方面进行说明。一方面, 《关于建立公共数据资源授权运营价格形成机制的通知》强调公共数据授权运营的价格形成应遵循规范化程序与可核算原则, 突出定价过程的透明性、可复核性以及与成本核算、收益边界等管理要求的匹配。本文以多轮成交/未成交反馈驱动估值函数的在线更新, 并输出连续报价序列与更新轨迹等过程信息, 这些信息能够形成可留痕的价格形成依据, 为事后核算、复核与内部管理提供可核算的过程证据, 从而与上述价格形成机制对“程序化、可核算、可追溯”的治理导向相一致。另一方面, 《数据安全技术数据交易服务安全要求》从参与方、平台、交易对象与交易过程等维度提出安全控制与审计留痕要求。本文方法在平台既有身份鉴别、权限控制、访问控制与日志留存等安全机制约束下运行, 并将定价交互过程中产生的必要过程记录纳入留痕范围, 以支撑交易过程的可追溯性与可审计, 从而在不改变既有安全治理框架的前提下实现可嵌入部署。

#### 2) 与数据流通其他环节的衔接

在数据确权与合规来源环节, 本文不试图替代交易场所既有的权属声明、来源合法性审查、授权与使用范围约束以及分类分级与安全评估等制度性流程, 而是将其作为动态定价与交互学习的前置条件, 从而明确方法边界并保证交易对象的合规可用

性。在估值核算环节,本文方法在运行过程中自然形成可核算的过程证据,包括连续报价记录、成交与未成交反馈以及由反馈驱动的可行域收缩轨迹等信息,这些信息可用于解释价格形成依据,支撑事后复算与复核,并为平台内部核算留痕与审计评估提供材料支撑。通过上述衔接,本文方法能够将估值学习与定价决策嵌入既有的确权合规与核算审计链路,增强政策合规性与推广可行性。

### 4 实验分析

为验证所提方法的合理性及效率,开展了系统模拟实验。所有实验均在统一的本地环境下完成:CPU为2.5 GHz 16核 Intel Core i7,内存32 GB (1600MHz DDR3),硬盘为512 GB SSD, GPU为 NVIDIA GeForce MX550 (2 GB 显存)。所有算法基于 Python 3.10 实现,并在上述环境中对本文方法进行统一性能评估。实验选取了来自 Kaggle 数据社区的3个公开数据集,并构造5个合成数据集,具体如表1所示。

表1 数据集细节

数据集名称	大小(行×列)	特征维度	隐私含量
Dynamic pricing dataset(D1)	1 000 × 10	10	198
Personal data datasets(D2)	8 765 × 40	40	9 743
Pricing model dataset(D3)	21 662 × 34	34	24 809
Synthetic Dataset 1(D2')	8 765 × 40	40	5 075
Synthetic Dataset 2(D3')	21 662 × 34	34	12 480
Synthetic Dataset 3(D1'')	1 000 × 10	100	198
Synthetic Dataset 4(D2'')	8 765 × 40	100	9 743
Synthetic Dataset 5(D3'')	21 662 × 34	100	24 809

### 4.1 评价指标

1.2节定义累积遗憾 Reg, 本节定义累积遗憾率  $Cr = \frac{Reg}{T}$ 、累积盈余等其他基本指标。

累积盈余 (cumulative surplus, Cs): 买方效益指标, 衡量DC从定价中获得的超额价值。定义  $Cs = \mathbb{E} \left[ \sum_{t=1}^N \lambda_t (v_t - p_t) \right]$ , 其中  $\lambda_t = \mathbb{I}(p_t \leq v_t)$  为成交指示变量。Cs 越大, 表明DC在交易中获益越多。

累积收益 (cumulative profit, Cp): 卖方效益指标,  $Cp = \sum_{t=1}^N |p_t - r_t|$  为衡量DP实际获得的定价利润, 即各轮成交价格高于保留价格的部分。

累积价格偏差 (cumulative deviation, Cd): 定价方法精度指标, 表示发布价格与数据真实估值之间的总偏差, 定义  $Cd = \sum_{t=1}^N |p_t - v_t|$ 。

累积时间 (cumulative time, Ct): 方法效率能力指标, 表示方法在T轮交易中总的运行耗时。算法计算速度越快, 说明其实用性与部署能力越强。

上述5个指标从合理性与效率两个维度对动态定价算法进行评价, 其中Cs与Cp反映交易双方的效益平衡, Cd刻画定价结果对真实估值的逼近精度, Cr从最优策略对比的角度量化性能损失, 这些验证定价机制在灵活性与精确性上的合理性, Ct用于衡量算法在迭代过程中的运行开销。

### 4.2 定价合理性验证

图4(a)与图4(b)展示了在交易轮次分别为  $T=500$  和  $T=10\,000$  的情况下, 本文方法的累积盈余与累

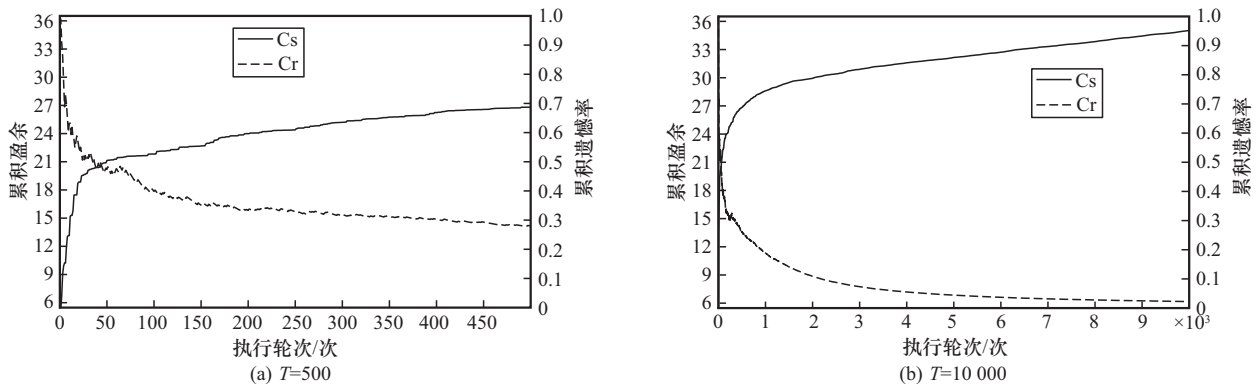


图4 T轮累积盈余与累积遗憾率

积遗憾率的演化趋势。随着估值权重在交互过程中不断被精确逼近，发布策略逐步优化，模型表现出稳定的策略收敛能力与收益提升能力。Cr 持续下降并趋于收敛，说明定价策略能够有效贴合消费者偏好；与此同时，Cs 保持稳定增长，体现出本文方法在长期博弈中的稳健盈利能力。

为评估本文方法在应对不同估值偏好与价值波动条件下的灵活性，选取现实中具有代表性的两类典型动态定价场景，以模拟 DP 在不同目标导向下的定价行为。周期驱动的估值场景（场景 1），数据价值受长期趋势与短期扰动共同影响，DP 关注在整个交易周期内实现累积盈余最优化；盈余导向的估值场景（场景 2），DP 在每轮交易中根据即时反馈动态调整定价，以最大化当轮交易的预期盈余。对于同一数据视图，其特征向量  $x_i^T$  在多轮交易中通常保持稳定，估值的动态变化主要由权重参数  $\theta$  与扰动项  $\theta_i$  决定。

在周期驱动的估值场景下，选取传统查询定价方法与基于劳资博弈的定价方法<sup>[30]</sup>作为对比基线，以评估各方法对数据属性变化的响应能力。如图 5(a) 所示，对比 D2 与 D2' 可见，在记录规模相同而维度与隐私含量更高的情况下，本文方法与文献[30]方法均能体现定价随数据复杂度提升而上升的趋势，而传统查询定价方法无法区分两者。进一步地，对于 D3 与 D3' 记录数与维度一致而隐私含量不同的数据集，本文方法能根据隐私差异显著调整定价，展现出对隐私价值的敏感感知与自适应能力；相比之下，文献[31]方法调整有限，传统方法则完全忽略隐私差异。

在盈余导向的估值场景中，通过调整  $\theta$  的更新频率（记为 Sep）及总定价轮次  $T$ ，评估不同设置下定价方法的表现。表 2 给出了在数据集 D1 下不同设置的实验结果。随着轮次  $T$  增加，累积遗憾率持续下降、累积收益总体提升，体现了方法的学习与收敛能力；不同 Sep 的差异也十分明显，其中 Sep=100 整体表现最佳，Sep=50 次之，Sep=10 受限于调整幅度不足而收益偏低。图 5(b) 进一步展示了单位时间平均收益的变化趋势：场景 1 收益随轮次稳步提升；场景 2 收益对 Sep 较为敏感，Sep=100 始终保持最高水平，Sep=50 随轮次增加逐渐接近场景 1，Sep=10 表现始终落后。

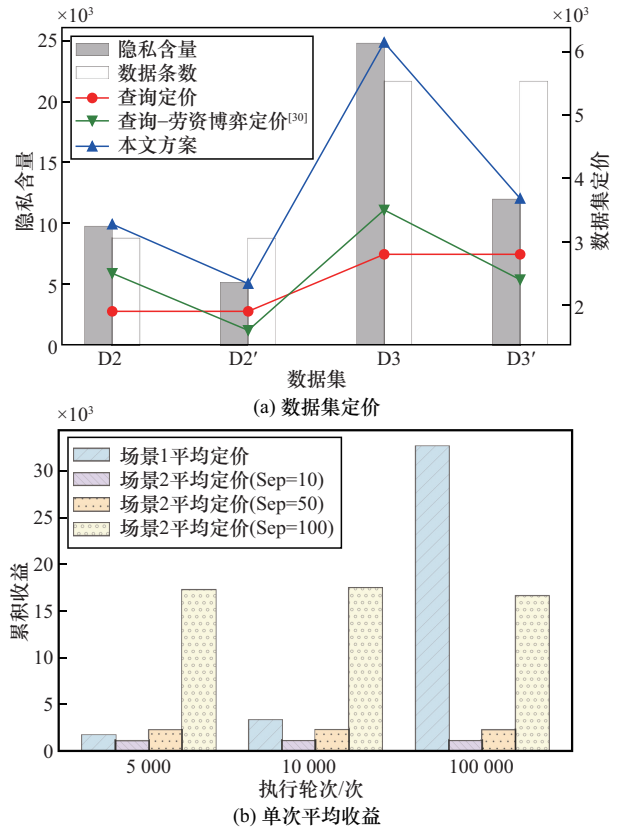


图 5 定价方法合理性验证

表 2 DC 追求最大盈余累积遗憾率和累积收益对比

轮次/次	Sep	Cr (盈余导向)	Cp (盈余导向)	Cp (周期驱动)
5 000	10	0.177	5 492 705	8 467 619
	50	0.108	5 418 969	8 467 588
	100	0.091	5 412 870	8 467 569
10 000	10	0.125	22 300 830	33 089 161
	50	0.058	22 861 960	33 089 222
	100	0.048	22 585 972	33 089 203
100 000	10	0.018	1 729 215 783	3 264 431 716
	50	0.005	1 749 067 574	3 264 431 599
	100	0.003	1 663 727 868	3 264 431 756

### 4.3 计算效率分析

本节进行了多轮定价模拟，算法在 NVIDIA CUDA 11.8 环境下实现加速运行，并以 Ct 作为指标验证计算效率。表 3 对定价过程各阶段的计算开销进行了拆分，实验结果表明特征向量提取阶段为整体计算开销的主要来源，且耗时随特征维度显著上升。D1 特征向量提取耗时为 0.092 s，D3 为 6.115 s。这是由于该阶段涉及椭圆估计与约束更新，其核心

计算为  $n \times n$  的矩阵与  $n \times 1$  向量运算, 整体复杂度为  $O(n^2)$ 。数据估值与价格发布阶段计算量较小, 仅涉及向量与标量运算, 耗时几乎不随维度变化。椭球权重空间更新阶段在多维数据下也表现出一定计算负担, 尤其在 D3'' 上耗时达 0.058 7 s, 构成次要性能瓶颈。所提定价方法在每轮迭代中需完成两个主要步骤: 一是基于估值模型  $v_i = x_i^T \theta + \delta_i$  判断与发布价格  $p_i$  的大小关系, 计算复杂度为  $O(n)$ ; 二是根据反馈结果更新椭球中心  $c_i$  和形状矩阵  $A_i$ , 涉及多个  $n$  维向量与矩阵运算, 空间复杂度为  $O(n^2)$ 。因此, 随着特征维度的增加, 定价过程中相关阶段的耗时也随之显著提升。

表3 DC 追求最大盈余累积遗憾率和累积收益对比

数据集	提交查询/s	估值/s	定价/s	椭球空间裁剪/s	总时间/s
D1	0.092	0.010 1	0.011 7	0.010 3	0.124 1
D2	3.113	0.010 2	0.013 3	0.010 0	3.146 5
D3	6.115	0.010 3	0.009 6	0.013 3	6.145 2
D1''	4.843	0.030 2	0.021 9	0.019 0	4.914 1
D2''	6.307	0.059 8	0.032 2	0.032 0	6.431 0
D3''	9.115	0.095 1	0.062 1	0.058 7	9.330 9

此外, 图6展示了基于椭球平行切分机制的数据定价方法在运行效率方面的提升效果。本文在3个典型数据集D1、D2和D3上分别对比了基线方法(Baseline)与提出的基于平行切分的约束更新方法(Optimized)的运行时间表现。实验结果表明, 随着执行轮次增加, 基础方法在所有数据集上均表现出运行时间的指数式增长, 至第10 000轮时耗时已达80~100 s。优化方法通过在约束更新中引

入并行切分机制与高效椭球逼近策略, 在高轮次场景下显著降低了计算开销, 运行时间始终保持在10 s以内, 体现出良好的可扩展性与计算效率。

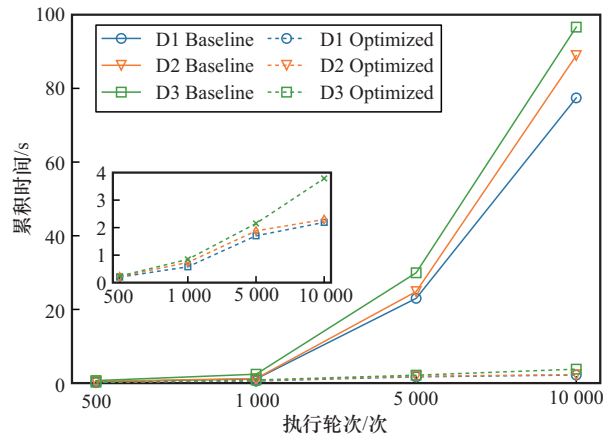


图6 优化方法与基础方法运行时间对比

#### 4.4 相关方法对比

本文将所提方法与方法1 (PDRP<sup>[25]</sup>) 和方法2 (Fairness-aware<sup>[26]</sup>) 在Cr与Ct两个指标上进行了对比, 实验执行轮次范围设为  $T=0 \sim 10\,000$ , 数据集为D1, 结果如图7所示。从图7(a)可以看出, 随着执行轮次  $T$  的增加, Fairness-aware的Cr上升最快, 呈现近似线性甚至加速增长的趋势; PDRP的Cr增速较缓, 整体低于Fairness-aware; 相比之下, 本文方法在整个区间内均保持最低的Cr, 其增长幅度最小, 体现出更加稳定且更优的决策性能。如图7(b)所示, Fairness-aware的运行开销随执行轮次显著上升, Ct远高于另外两种方法; PDRP虽然总体时间开销较低, 但仍随执行轮次逐步增长; 本文方法在三者中最为高效, 累积时间增长最为缓慢, 表明




图7 累积遗憾率与累积时间对比

其在保证性能的同时具备更高的计算效率。总体来看, 本文方法在 Cr 与 Ct 两个指标上均表现最佳, 既有效降低了决策误差的累积, 也显著减少了整体运行开销, 验证了其在实际应用场景中的优越性。

## 5 结束语

本文提出了一种基于椭球空间表征的数据动态定价方法。该方法通过迭代构造最小外接椭球, 对消费者估值空间进行紧致刻画, 从而在不需要依赖显式梯度或边界建模的条件下, 实现对偏好参数的渐进逼近与定价策略的动态调整。进一步地, 本文设计了基于平行切分的加速裁剪机制, 以提升椭球迭代收缩的效率, 降低冗余计算开销, 使整体方法在多维估值与复杂偏好结构下仍具备良好的可扩展性。在反馈稀疏、多维估值及偏好异质性等条件下, 该方法展现出稳定的收敛性与计算可行性, 验证了几何约束方法在复杂估值结构中开展动态定价的有效性与潜力。未来工作可扩展至非线性估值模型与异步反馈环境, 以进一步增强其实用部署的灵活性和泛化能力, 从而为数据要素市场的定价机制设计提供新的理论思路与技术支持。

## 参考文献:

- [1] 陶晓明, 彭劫扬, 王钺, 等. 基于信息熵的数据元件信息计量: 以数据定价及其电能统计应用分析为例[J]. 中国科学(信息科学), 2025, 55(3): 654-680.  
Tao X M, Peng J Y, Wang Y, et al. Information metrics for data components based on information entropy: data pricing and its application analysis for electric energy statistics[J]. Science in China (Information Sciences), 2025, 55(3): 654-680
- [2] 蔡莉, 黄振弘, 梁宇, 等. 数据定价研究综述. [J]计算机科学与探索, 2021, 15(9): 1595-1606.  
Cai L, Huang Z H, Liang Y, et al. Survey of data pricing[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(9): 1595-1606.
- [3] Pei J. A survey on data pricing: from economics to data science[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(10): 4586-4608.
- [4] Zhang J X, Lei L Y, Zhang S C, et al. Dynamic vs. static pricing in a supply chain with advertising[J]. Computers & Industrial Engineering, 2017, 109: 266-279.
- [5] 江东, 袁野, 张小伟, 等. 数据定价与交易研究综述[J]. 软件学报, 2023, 34(3): 1396-1424.  
Jiang D, Yuan Y, Zhang X W, et al. Survey on data pricing and trading research[J]. Journal of Software, 2023, 34(3): 1396-1424.
- [6] Gallego G, van Ryzin G V. Optimal dynamic pricing of inventories with stochastic demand over finite horizons[J]. Management Science, 1994, 40(8): 999-1020.
- [7] 毕文杰, 陈美芳. 考虑策略型消费者的高斯过程回归动态定价算法[J]. 计算机应用与软件, 2024, 41(2): 250-256.  
Bi W J, Chen M F. A Gaussian process regression dynamic pricing algorithm considering strategic consumers[J]. Computer Applications and Software, 2024, 41(2): 250-256.
- [8] 陈思远, 陈辰, 袁野, 等. 具有复制鲁棒性的高效数据交易估值框架[J]. 计算机科学与探索, 2025, 19(9): 2532-2547.  
Chen S Y, Chen C, Yuan Y, et al. Efficient data trading valuation framework with replication robustness[J]. Journal of Frontiers of Computer Science and Technology, 2025, 19(9): 2532-2547.
- [9] 扈文秀, 刘亚洲, 苏欣欣. 考虑权力结构和价值不确定性的数据供应链定价策略分析[J]. 计算机工程与应用, 2025, 61(4): 310-322.  
Hu W X, Liu Y Z, Su X X. Analysis of pricing strategies in data supply chains considering power structures and value uncertainty[J]. Computer Engineering and Applications, 2025, 61(4): 310-322.
- [10] Luo Y Y, Sun W W, Liu Y F. Distribution-free contextual dynamic pricing[J]. Mathematics of Operations Research, 2024, 49(1): 599-618.
- [11] Erginbas Y E, Courtade T, Ramchandran K, et al. Online pricing for multi-user multi-item markets[C]//Proceedings of the 37th International Conference on Neural Information Processing Systems. New York: ACM Press, 2023: 29718-29740.
- [12] Zhao Z F, Jiang F Y, Yu Y, et al. High-dimensional dynamic pricing under non-stationarity: learning and earning with change-point detection[PP]. V2. (2023-03-20)[2025-11-28]. arXiv: arXiv. 2303.07570.
- [13] Javanmard A, Nazerzadeh H, Shao S M. Multi-product dynamic pricing in high-dimensions with heterogeneous price sensitivity[C]//Proceedings of the 2020 IEEE International Symposium on Information Theory (ISIT). Piscataway: IEEE Press, 2020: 2652-2657.
- [14] Xu J Y, Wang Y X. Logarithmic regret in feature-based dynamic pricing[C]//Advances in Neural Information Processing Systems (NeurIPS 2021). Red Hook: Curran Associates, Inc., 2021: 13898-13910.
- [15] Niu C Y, Zheng Z Z, Wu F, et al. Online pricing with reserve price constraint for personal data markets[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(4): 1928-1943.
- [16] Cohen M C, Lobel I, Paes Leme R. Feature-based dynamic pricing[J]. Management Science, 2020, 66(11): 4921-4943.
- [17] Bolivar A, Garcia V, Alejo R, et al. Data-centric solutions for addressing big data veracity with class imbalance, high dimensionality, and class overlapping[J]. Applied Sciences, 2024, 14(13): 5845.
- [18] 王煜心, 李建平, 郝俊. 集成效用与数据产品最优定价[J]. 中国科学: 信息科学, 2024, 54(11): 2533-2553.  
Wang Y X, Li J P, Hao J. Integrated utility and optimizing pricing of data products[J]. Scientia Sinica (Informationis), 2024, 54(11): 2533-2553.
- [19] Jia S, Li A, Ravi R. Dynamic pricing with monotonicity constraint under unknown parametric demand model[C]//Proceedings of the 36th International Conference on Neural Information Processing Systems. New York: ACM Press, 2022: 19179-19188.
- [20] Xu J, Wang Y X. Towards agnostic feature-based dynamic pricing: Linear policies vs linear valuation with unknown noise[C]//Proceedings of

the International Conference on Artificial Intelligence and Statistics (AISTATS 2022). Brookline: PMLR, 2022: 9643-9662.

- [21] Perivier N, Goyal V. Dynamic pricing and assortment under a contextual MNL demand[C]//Advances in Neural Information Processing Systems (NeurIPS 2022). Red Hook: Curran Associates, Inc., 2022: 3461-3474.
- [22] 方嘉豪, 郭兵. 基于属性隐私的统计查询定价模型[J]. 计算机应用研究, 2024, 41(10): 2978-2986.  
Fang J H, Guo B. Pricing statistical query based on attribute privacy[J]. Application Research of Computers, 2024, 41(10): 2978-2986.
- [23] Cai H, Yang Y Y, Fan W B, et al. Towards correlated data trading for high-dimensional private data[J]. IEEE Transactions on Parallel and Distributed Systems, 2023, 34(3): 1047-1059.
- [24] Baby D, Wang Y X. Non-stationary contextual pricing with safety constraints[J]. Transactions on Machine Learning Research, 2023: 1-23.
- [25] Liu P P, Sun W W. Fairness-aware contextual dynamic pricing with strategic buyers[PP]. V2. (2026-03-04) [2025-11-28]. arXiv: arXiv. 2501.15338.
- [26] Mao J M, Leme R P, Schneider J. Contextual pricing for lipschitz buyers[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. New York: ACM Press, 2018: 5648-5656.
- [27] Lobel I, Leme R P, Vladu A. Multidimensional binary search for contextual decision-making[J]. Operations Research, 2018, 66(5): 1346-1361.
- [28] Paes L R, Schneider J. Contextual search via intrinsic volumes[C]//Proceedings of the 2018 IEEE 59th Annual Symposium on Foundations of Computer Science (FOCS). Piscataway: IEEE Press, 2018: 268-282.
- [29] Shen Y C, Guo B, Shen Y, et al. Personal big data pricing method based on differential privacy[J]. Computers & Security, 2022, 113: 102529.
- [30] 王会举, 黄玮焯, 岳晓. 基于劳资博弈模型的实用查询定价新算法[J]. 计算机研究与发展, 2024, 61(12): 3154-3167.  
Wang H J, Huang W X, Yue X. Novel practical query pricing algorithm based on labor game model[J]. Journal of Computer Research and Development, 2024, 61(12): 3154-3167.
- [31] Liao A P, Todd M J. The ellipsoid algorithm using parallel cuts[J]. Computational Optimization and Applications, 1993, 2(4): 299-316.
- [32] Srinivas N, Krause A, Kakade S M, Seeger M W. Gaussian process optimization in the bandit setting: no regret and experimental design[C]//Proceedings of the 27th International Conference on Machine Learning (ICML 2010). Madison: Omnipress, 2010: 1015-1022.
- [33] Srinivas N, Krause A, Kakade S M, et al. Information-theoretic regret bounds for Gaussian process optimization in the bandit setting[J]. IEEE Transactions on Information Theory, 2012, 58(5): 3250-3265.
- [34] Cao P, Wang Y L, Xie J G. Priority service pricing with heterogeneous customers: impact of delay cost distribution[J]. Production and Operations Management, 2019, 28(11): 2854-2876.
- [35] Todd M J. On minimum volume ellipsoids containing part of a given ellipsoid[J]. Mathematics of Operations Research, 1982, 7(2): 253-261.

## [作者简介]



余增文 (1985-), 男, 陕西安康人, 西安电子科技大学博士生, 主要研究方向为数据分析和数据安全。



李国浩 (1996-), 男, 河南洛阳人, 博士, 国防科技大学在站博士后, 主要研究方向为应用密码学、数据安全聚合和可验证聚合。




池臧博 (1997-), 男, 河北张家口人, 北京计算机技术及应用研究所工程师, 主要研究方向为数据安全、强化学习和大模型。



杨力 (1977-), 男, 陕西乾县人, 博士, 西安电子科技大学教授、博士生导师, 主要研究方向为应用密码学、网络安全、云安全和可信计算。



姜奇 (1983-), 男, 安徽滁州人, 博士, 西安电子科技大学教授、博士生导师, 主要研究方向为安全协议、物联网安全和数据安全。



方志 (1979-), 男, 湖南岳阳人, 博士, 北京计算机技术及应用研究所研究员、博士生导师, 主要研究方向为大数据、人工智能和数据分析。