

基于联邦学习的电商数据协同与精准网络营销研究

刘佳伶, 彭定涛*

贵州大学数学与统计学院, 贵州 贵阳

收稿日期: 2026年8月5日; 录用日期: 2026年8月20日; 发布日期: 2026年10月27日

摘要

在数字经济背景下, 电商平台、商家、支付及物流等多方主体积累了海量互补行为数据, 但数据孤岛与隐私约束限制了跨主体协同建模。特别是在精准网络营销场景中, 大促高并发的业务需求与传统联邦学习边缘算力受限、通信高延迟及数据高度异构等瓶颈产生严重冲突。为此, 本文提出一种面向跨主体协作的轻量级联邦数据协同机制, 通过优化云端与边缘侧的协同逻辑, 有效降低了商家终端在处理大规模营销数据时的资源负载, 并增强了模型对多变消费行为的捕捉能力。实验表明, 在模拟大促的高并发环境下, 该机制通信量较传统模式降低约94%, 可在不挤占核心业务带宽的前提下实现网络营销策略的敏捷迭代, 为打破电商数据孤岛提供高效的商业决策支撑。

关键词

精准网络营销, 联邦学习, 平台 - 商家协同, 数据孤岛

Research on Precision Marketing and E-Commerce Data Collaboration via Federated Learning

Jialing Liu, Dingtao Peng*

School of Mathematics and Statistics, Guizhou University, Guiyang Guizhou

Received: August 5, 2026; accepted: August 20, 2026; published: October 27, 2026

Abstract

In the digital economy, e-commerce platforms, merchants, payment institutions, and logistics providers accumulate massive complementary data, while data silos and privacy constraints hinder collaborative modeling. In precision marketing scenarios, traditional federated learning suffers

*通讯作者。

from limited edge resources, high communication costs, and heterogeneous data under high-concurrency environments. To address these challenges, this paper proposes a lightweight federated data collaboration mechanism for cross-entity cooperation. By optimizing cloud-edge collaboration, the proposed method reduces terminal resource consumption and enhances the modeling of dynamic consumer behaviors. Experimental results show that under the high-concurrency environment simulating e-commerce large-scale promotions, the proposed mechanism reduces communication overhead by approximately 94% compared with traditional methods, enabling efficient and agile marketing updates without occupying critical business bandwidth and providing efficient commercial decision support for breaking e-commerce data silos.

Keywords

Precision Online Marketing, Federated Learning, Platform-Merchant Collaboration, Data Silos

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

1.1. 电商数据孤岛与跨主体协同建模挑战

在数字经济快速发展的背景下,伴随流量红利的消减,电子商务的竞争核心已逐步从增量的粗放式营销竞争转向存量市场的深耕与精细化运营[1] [2]。电商平台、入驻商家、支付机构与物流企业在日常经营过程中,积累了海量交易订单、支付记录、用户行为和物流配送数据等多维数据,这些涵盖用户属性、行为路径与交易互动等多维度的数据既是电商精准网络营销与个性化推荐优化的重要支撑[3],也是数字经济时代提升商业决策智能化水平的核心资源。然而,随着我国《中华人民共和国个人信息保护法》¹及全球 GDPR 等隐私合规法规的相继落地,数据资产化进程面临着严峻的合规挑战[4]。在实际业务运营场景中,受制于主体间的竞争壁垒与合规边界,这些高度互补的数据资源多分散存储在不同的利益主体手中,电商平台掌控用户浏览轨迹与搜索偏好数据,入驻商家留存核心交易流水与用户复购行为数据,物流企业则掌握精准配送路径与终端签收反馈的数据,由此形成了跨平台协同的“数据孤岛”现象[5]。传统的将所有敏感数据汇聚到中心服务器进行统一训练的“集中式学习”模式因隐私安全红线与商业机密保护而难以为继,导致跨主体的协同建模陷入停滞,严重制约了精准网络营销的广度与深度。因此,如何打破行业数据壁垒,在保障用户隐私和商业机密的前提下构建一种适应合规要求且能释放数据协同价值的网络营销机制,已成为推动电商行业从数据割裂走向数智协同的关键课题[6]。

1.2. 联邦学习在协同营销中的应用价值与实施挑战

在此背景下,联邦学习作为一种“数据不出本地、模型协同训练”的机器学习范式应运而生[7],它允许各电商主体在保留原始数据的前提下,仅依靠交换模型参数或梯度信息实现网络营销策略优化,有效平衡了隐私合规与数据价值共享之间的矛盾。目前,联邦学习已在电商跨平台精准网络营销等任务中展现出巨大潜力,FedCTR [8]、GPFed [9]等经典模型能在保护数据隐私的同时有效提升推荐系统的点击率预估性能。

然而,在真实电商场景中部署该机制仍面临严峻的业务实践挑战。其一,精准网络营销具有极高的实时性要求,电商 App 往往需要在用户手机端实时进行点击率预估与商品重排[10],以实现毫秒级个性

¹http://www.npc.gov.cn/npc/c2/c30834/202108/t20210820_313088.html

化服务响应,但参与协作的商家终端节点多为算力、存储空间及续航能力均受限的边缘终端;电商推荐场景所采用的深度神经网络参数量庞大,终端频繁执行本地多步迭代不仅会迅速消耗移动设备的电池电量,还会因CPU占用率过高导致App出现严重的滑动卡顿或操作延迟等问题,进而严重降低用户的购物体验[11]。其二,电商边缘体系存在明显的硬件异构性,边缘网络多依托网络带宽有限、链路波动较大的无线通信方式,双十一等电商大促时段的海量用户并发访问,还会进一步引发基站网络拥堵;而且不同终端的处理器性能差异巨大,传统模式下服务器须等待低终端完成计算,易引发“掉队者”效应,这在高并发购物高峰期极易造成系统响应崩溃。除硬件资源瓶颈外,电商数据的高度异构性同样是阻碍精准网络营销的重要因素,不同地域、不同年龄段以及不同消费水平的用户均表现出差异化的购物偏好,如南方用户与北方用户在生鲜类目检索倾向上差异显著,青年群体与中老年群体也存在截然不同的消费行为特征,尤其在双十一等大促时段,海量商品特征中潜藏的高维隐性信息与用户脉冲式的消费序列交织也会导致数据分布极度不均衡[12],这种异构性会导致协作过程中的模型震荡,若直接进行权重平均,往往无法精准捕捉普适性的点击规律。现有的各类优化机制(如FedProx [13]、FedADMM [14]等)虽能部分缓解上述问题,但往往伴随着更高的网络通信带宽需求或更重的终端算力负担,难以在带宽稀缺的大促窗口期实现敏捷应用。因此,针对电商协同网络营销中算力碎片化与数据强漂移的双重现实难题,构建一种低能耗、高响应的轻量级协同机制,是突破电商数智化转型瓶颈的关键。

1.3. 本文研究贡献

针对电商精准网络营销中隐私合规、边缘资源受限及大促协同效率等挑战,本文提出了一种面向跨主体协作的轻量级联邦数据协同机制。为缓解移动终端复杂运算带来的App卡顿与电量损耗问题,设计了轻量级本地更新策略,将复杂迭代转化为低开销单步计算,在保障用户无感购物体验的同时降低了中小商家的协同成本;针对双十一等场景下的脉冲式消费波动与网络拥塞,引入动态缓冲与敏捷迭代机制,有效平滑数据异构引发的模型震荡,提升了高并发环境下营销策略的拟合精度与系统稳定性;此外,本文还构建了兼顾隐私保护与商业价值的数据协同架构,为打破平台与商家间的“数据孤岛”、推动电商网络营销向数据驱动的数据驱动转型提供了理论参考与实践支撑。

2. 电商精准网络营销协同框架与问题描述

2.1. 电商协同网络营销架构与决策目标描述

本文构建如图1所示的“平台-商家”联邦架构,该系统由电商云端聚合平台和 m 个节点商家组成,旨在不泄露各商家私有用户数据的前提下,实现跨主体的联合画像刻画。将全局待学习的模型权重为 $\mathbf{w} \in \mathbf{R}^n$ 映射为不同行为特征对用户点击率的敏感度,通过联邦协同,各商家可共享特征对点击概率的全局敏感度,从而挖掘跨店铺商品与用户兴趣的隐含关联,有效缓解单一商家点击率数据稀疏难题。在此基础上,我们将每个商家(客户端) $i \in 1, \dots, m$ 所拥有的本地私有数据具象化为:样本特征 $\mathbf{a}_i^t \in \mathbf{R}^n$ 表示第 i 个商家节点中第 t 个用户的多维行为特征向量;点击标签 $b_i^t \in \{0, 1\}$ 代表该用户对应的真实反馈,其中 $b_i^t = 1$ 表示产生了点击或购买行为, $b_i^t = 0$ 表示未产生转化; d_i 代表第 i 个商家拥有的本地样本总数,即商家 i 私有数据集 $\mathbf{D}_i$ 的数据量。

为衡量当前网络营销策略与本地用户真实偏好之间的偏离程度,各商家节点采用逻辑回归进行联邦协同训练,该模型在处理高维稀疏点击特征时具备良好的计算高效性[15]。将第 i 个客户端的本地目标函数 $f_i(\mathbf{w})$ 定义为带有 L_2 正则化的逻辑损失函数:

$$f_i(\mathbf{w}) = \frac{1}{d_i} \sum_{t=1}^{d_i} \left(\ln \left(1 + e^{\langle \mathbf{a}_i^t, \mathbf{w} \rangle} \right) - b_i^t \langle \mathbf{a}_i^t, \mathbf{w} \rangle \right) + \frac{\lambda}{2} \|\mathbf{w}\|^2$$

$\lambda > 0$ 为正则化系数。全平台的全局优化目标为:




Figure 1. E-commerce multi-party data collaboration architecture based on Federated Learning

图 1. 基于联邦学习的电商多方数据协同架构图

其中 α_i 为权重系数, 满足 $\sum \alpha_i = 1$ 。这种建模方式能够有效缓解单一商家面临的数据稀疏难题, 实现网络营销资源在整个电商生态中的最优化配置。

2.2. 面向大促场景的轻量级协同机制设计

针对电商协同场景下的分布式逻辑回归问题, 我们引入辅助变量 $w_i \in \mathbf{R}^n$ 代表第 i 个商家的本地个性化网络营销模型, 将全局优化目标变为:

$$\min_{w, w_i} \sum_{i=1}^m \alpha_i f_i(w_i), \quad \text{s.t. } w_i = w, \quad \forall i \in \{1, \dots, m\}$$

其中 w 为服务器维护的全局网络营销模型, 上述约束问题的增广拉格朗日函数为:

$$\mathcal{L}_{\alpha, \beta}(w, W, \Lambda) = \sum_{i=1}^m \left\{ \alpha_i f_i(w_i) + \langle \lambda_i, w_i - w \rangle + \frac{\beta_i}{2} \|w_i - w\|^2 \right\}$$

其中 $W = (w_1, \dots, w_m)^T \in \mathbf{R}^{mn}$ 为本地个性化网络营销模型所形成的矩阵, $\Lambda = (\lambda_1, \dots, \lambda_m) \in \mathbf{R}^{mn}$ 为拉格朗日乘子矩阵, $\beta_i > 0$, $\alpha = (\alpha_1, \dots, \alpha_m)^T \in \mathbf{R}^m$, $\beta = (\beta_1, \dots, \beta_m)^T \in \mathbf{R}^m$ 。以初始点 (w^0, W^0, Λ^0) 为起点, 传统 FedADMM 通过 ADMM 迭代更新变量, 但在真实的电商网络中, 尤其是在双十一等大促高峰期, 传统的协作机制要求的本地多轮复杂迭代会极大消耗边缘侧的计算资源, 造成 App 卡顿并损害用户购物体验。

在真实的电商精准网络营销协同部署中, 边缘侧物理环境复杂且设备异构性突出, 电商平台参与主体涵盖海量移动端用户与中小型商家, 受设备续航能力、网络接入稳定性及商家维护周期的限制, 要求数以万计的节点在每一轮全局通信中均保持在线状态, 显然不具备现实可行性; 而且在双十一等电商大促期间, 电商骨干网络带宽资源极为稀缺, 若每轮迭代均进行参数同步, 极易诱发严重的网络链路拥塞,

还会造成模型训练效率急剧下滑。因此本文采用“部分参与”策略与设定“通信间隔 k_0 ”，仅让活跃商家子集在特定轮次上传本地个性化营销模型参数，从系统层面避免挤占核心业务带宽。

为彻底消除上述各商家节点内层循环的算力瓶颈，本文提出 FedPL-ADMM 机制，其核心在于降低商家的协作门槛，转而采用变度量邻近线性化策略。具体而言，为了在降低计算开销的同时捕捉损失函数的二阶曲率信息，本文基于 Barzilai-Borwein 步长思想动态构造对角矩阵 $\mathbf{Q}_i^k$ ，定义变量差与梯度差向量为

$$\mathbf{s}_i^k = \mathbf{w}_i^k - \mathbf{w}_i^{k-1}, \mathbf{y}_i^k = \nabla f_i(\mathbf{w}_i^k) - \nabla f_i(\mathbf{w}_i^{k-1})$$

对于矩阵的第 j 个对角元素，我们设置：

$$[\mathbf{Q}_i^k]_{jj} = \max \left(\frac{([\mathbf{y}_i^k]_j)^2}{[\mathbf{s}_i^k]_j [\mathbf{y}_i^k]_j}, \epsilon \right)$$

其中 $\epsilon > 0$ 为极小常数，用于保证矩阵的严格正定性；如此一来，原电商精准网络营销协同子问题就被重构为：

$$\mathbf{w}_i^{k+1} = \arg \min_{\mathbf{w}_i} \left\{ \langle \alpha_i \nabla f_i(\mathbf{w}_i^k), \mathbf{w}_i - \mathbf{w}_i^k \rangle + \frac{1}{2} \|\mathbf{w}_i - \mathbf{w}_i^k\|_{\mathbf{Q}_i^k}^2 + \langle \lambda_i^k, \mathbf{w}_i - \mathbf{w}_i^{k+1} \rangle + \frac{\beta_i}{2} \|\mathbf{w}_i - \mathbf{w}_i^{k+1}\|^2 \right\}$$

随后得到第 i 个商家的本地个性化网络营销模型为：

$$\mathbf{w}_i^{k+1} = (\mathbf{Q}_i^k + \beta_i \mathbf{I})^{-1} [\mathbf{Q}_i^k \mathbf{w}_i^k - (\alpha_i \nabla f_i(\mathbf{w}_i^k) + \lambda_i^k) + \beta_i \mathbf{w}_i^{k+1}]$$

这一改进实现了营销策略的无感快速更新。此外，考虑到大促期间脉冲式消费引发的参数震荡，本文在聚合端引入了 Nesterov 动量作为稳定性缓冲器，并结合过松弛机制作为效率加速器。这种设计确保了在大促期间带宽极度拥塞的极端环境下，网络营销模型仍能保持敏捷的迭代频率与卓越的收敛稳定性，从而精准捕捉瞬息万变的商业机遇。完整算法流程如表 1 所示。

Table 1. Algorithm pseudocode

表 1. 算法伪代码

算法： FedPL-ADMM 算法

输入： m, α_i, k_0, c

超参数： $\beta_i, \rho, \epsilon > 0$

初始化： $k = 0, M_0 = M, \mathbf{w}_i^0, \mathbf{w}^0, \lambda_i^0 = -\alpha_i \nabla f_i(\mathbf{w}_i^0)$ 。

for $k = 0, 1, 2, \dots$ **do**

if $k \bmod k_0 = 0$ **then**

 服务器收集 M_k 的参数 $(\beta_i \mathbf{w}_i^k + \lambda_i^k)$ ，计算 $\hat{\mathbf{w}}^{k+1}$ ，更新 $\mathbf{w}^{k+1} = \hat{\mathbf{w}}^{k+1} + \gamma_k (\hat{\mathbf{w}}^{k+1} - \hat{\mathbf{w}}^k)$

 将 $\mathbf{w}^{k+1}$ 广播给随机选择的活跃商家节点

end if

for $i \in M_{k+1}$ **in parallel do**

 计算 $\mathbf{y}_i^k$ 与 $\mathbf{s}_i^k$ ，构造 $\mathbf{Q}_i^k$ 以更新 M_{k+1}

$$\mathbf{w}_i^{k+1} = (\mathbf{Q}_i^k + \beta_i \mathbf{I})^{-1} [\mathbf{Q}_i^k \mathbf{w}_i^k - (\alpha_i \nabla f_i(\mathbf{w}_i^k) + \lambda_i^k) + \beta_i \mathbf{w}_i^{k+1}]$$

 更新 $\lambda_i^{k+1} = \lambda_i^k + \beta_i \rho (\mathbf{w}_i^{k+1} - \mathbf{w}_i^k)$

end for

end for

3. 实验验证与商业实效分析

为验证本文提出的轻量级数据协同机制在处理电商精准网络营销多方协作任务时的实效价值, 本章开展了基于真实业务数据的数值模拟实验。通过与传统联邦协作模式的对比, 本研究不仅关注模型对消费偏好捕捉的准确度, 更重点从网络营销策略的响应敏捷度、商家端运营成本消耗以及在极端数据异构环境下的协同稳定性等核心商业维度进行综合评估。本实验旨在明晰技术赋能精准网络营销的内在机制, 为电商企业在流量红利消减背景下突破营销困境、增强核心竞争力提供实证依据与理论借鉴。

3.1. 实验数据来源与业务特征挖掘

本研究选取具有高度行业代表性的 Criteo 广告点击数据集作为实证对象。该数据集深度还原了真实电商场景中的用户行为轨迹与商品属性特征, 涵盖了从初步浏览到最终点击的完整决策链条, 是评估精准网络营销效能与商品搜索排序逻辑的理想载体; 该数据集属于典型的二分类任务数据集, 整体样本总量规模为 50 万条, 每条样本包含 1 个反映转化结果的预测变量与 40 维业务属性特征, 其中包含 13 维反映用户活跃程度的连续性行为指标, 以及 26 维表征用户身份、地理位置及广告位属性的离散型特征, 构成了支持精细化运营的多维度指标体系。

针对电商精准网络营销中普遍面临的类别特征高维稀疏性挑战, 本文通过精细化特征工程提升了模型对长尾消费行为的捕捉能力; 在预处理阶段, 通过对 13 维连续型数值特征进行量纲对齐, 并借助特征哈希技术将 26 列高维类别特征映射至 1000 维的稀疏特征空间, 最终构建起稀疏度约为 0.93% 的立体画像模型, 这一过程不仅模拟了真实协同建模中处理高维隐性信息的难度, 也有效解决了传统网络营销模式下用户画像分类模糊的问题, 为后续方案在处理复杂业务特征时的鲁棒性提供了验证基础。在构建多方数据协同仿真环境时, 本研究模拟了电商生态中“头部平台与长尾商家”并存的规模异构特性, 系统通过随机索引技术系统通过随机索引技术将 Criteo 样本划分至 $m = 100$ 个不同规模电商主体的联邦节点, 并引入病态标签倾斜机制, 以还原由于地域偏好、消费水平及大促脉冲行为差异导致的“数据孤岛”现象。最后, 针对现实场景中商家规模不一带来的贡献度衡量难题, 本文采用了样本量加权聚合机制, 这一设计旨在明晰技术赋能下跨主体数据融合的内在逻辑, 确保全局模型能客观反映各参与方的商业贡献度, 从而为电商企业在流量红利消减时代实现降本增效与数智化转型提供决策参考。

3.2. 实验设置与商业效能评估

本研究选取了当前分布式数据治理中具有代表性的四种协同机制与本文的 FedPL-ADMM 机制进行真实电商精准网络营销场景的效能对比, 对照组涵盖了 FedAvg、FedProx、SCAFFOLD 以及 FedADMM。在此次基于 Criteo 高维稀疏商业数据集的对比中, 本研究跳脱了单一的算法性能视角, 转而从网络营销预测准确度、商家端运营资源损耗以及平台策略同步效率三个商业维度, 全面评估本文机制的实效性, 为确保评估的公平性, 各对比机制均在验证集上调至最优商业匹配状态。

在真实的电商精准网络营销场景中, 算力资源与时间窗口高度受限, 尤其是在双十一等流量高峰期, 网络营销模型必须在极短的计算周期内完成对海量用户行为数据的学习与拟合。为模拟这一极端商业环境, 本文在极低商家参与率 $\rho = 0.2$ 与大通信间隔 $k_0 = 10$ 下进行实验, 量化对比各机制在电商实时营销场景下的特征挖掘效率, 以应对电商生产环境下“信息碎片化”与“网络高延迟”的挑战, 实验结果如图 2 所示。FedAvg 与 FedProx 出现明显的策略响应迟滞, 难以在瞬息万变的商业环境中快速捕捉高维稀疏特征背后的真实点击意图; SCAFFOLD 机制虽然在协同稳定性上略胜一筹, 但其网络营销策略的启动预热期过长, 完全无法满足电商大促对于瞬时响应的严苛要求。与此同时, FedADMM 虽具备初期加速效果, 但面对大促期间复杂的点击率剧烈波动时极易产生策略回弹, 缺乏必要的商业鲁棒性。相比之下, FedPL-

ADMM 机制继承了对偶优化的快速启动特性, 显著压缩了网络营销策略的响应周期, 虽在面对极端数据偏斜时曾出现小幅的策略微调震荡, 但在大促核心时段迅速趋于平稳, 将预测偏差成本损失降至最低, 表明本机制在商家参与度受限、跨主体通信受阻的极端条件下, 能以极高时效性与稳定性完成精准网络营销策略的无感更新, 完美适配电商大促场景“快、准、稳”的业务核心需求。




Figure 2. Loss convergence under fixed 1000 iterations
图 2. 固定 1000 次迭代的损失收敛性

真实电商场景普遍面临极度拥塞的网络链路, 频繁的全局信息交互会严重挤占支付、结算及物流等核心业务带宽, 而且商家节点高度异构且不稳定, 仅有少量活跃商家能参与网络营销策略模型的同步更新。为检验各机制在有限营销窗口内完成点击率预估策略实时更新的能力, 本实验设定严苛的收敛指标进行实验, 以达到该精度所需的总运行时间作为响应时间测量指标, 并统计各算法达到目标精度时对应的通信轮次与总耗时, 实验结果如图 3 和表 2 所示。结果表明, FedAvg 与 FedProx 机制达成业务目标需耗费巨大的同步成本, 耗时均超过 13.5 秒, 在瞬息万变的电商环境下, 这种迟滞的响应速度极易导致商家错过消费者实时波动的点击偏好与潜在购买意愿; SCAFFOLD 虽然压缩了信息交互轮次, 但每轮交互的数据载荷过大, 在带宽稀缺的营销高峰期仍显得过于臃肿, 难以支撑商家的敏捷反应; FedADMM 机制在处理高维稀疏点击特征方面展现出了一定的业务适配性, 但在响应效率上仍有提升空间。相比之下, FedPL-ADMM 仅需 2 轮全局信息交互即可完成高精度的网络营销策略拟合, 较基准机制大幅压减了 94% 的协同交互轮次, 总响应耗时全场最低, 不仅有效降低了商家的技术参与门槛, 更为大促期间的精准网络营销决策释放了宝贵的网络资源, 确保了在隐私合规的前提下, 营销系统能够与核心支付链路和谐并跑, 切实赋能电商生态的数智化升级。

Table 2. Communication rounds and time consumption of different algorithms
表 2. 不同机制的交互轮次与耗时对比

机制	通信轮次	时间
FedAvg	33	14.180sec
FedProx	27	13.537sec
SCAFFOLD	11	11.648sec

续表

FedADMM	7	11.213sec
FedPL-ADMM	2	11.157sec





Figure 3. Comparison of loss function and communication rounds

图 3. 损失函数与交互轮次对比图

Figure 4. Bandwidth cost comparison to achieve the accuracy target of 10^{-9} 图 4. 达到 10^{-9} 精度目标的带宽成本对比

在数字经济生态中, 电商精准网络营销模型往往包含海量的用户与商品特征, 真实的协同运营成本不仅取决于信息同步的频次, 更受制于单次交互的数据体量。本实验以累计消耗网络带宽(MB)为核心运维指标, 检验各协同机制在双十一窄带宽下的商业落地可行性, 实验结果如图 4 所示。结果表明, FedAvg

与 FedProx 横轴延伸最长, 产生了较大的累计带宽负荷, 这种高昂的网络通信开销使其难以在网络资源紧张、运维预算有限的中小商家端广泛部署; SCAFFOLD 机制虽在一定程度上压缩了交互轮次, 但单次同步需承载双倍的底层数据载荷, 导致大促前期的带宽挤占程度甚至劣于传统方法; FedADMM 则存在明显的“流量拖尾”现象, 长尾的网络占用极易干扰商家常规的订单处理业务。而本文提出的轻量级协作机制 FedPL-ADMM 通过摒弃复杂的内层嵌套计算并维持单倍数据载荷交互, 以极低的累计流量率先达成了网络营销策略的高效协同, 这种“轻量级负载、敏捷化响应”的特性, 确保了在完全不挤占大促期间核心交易与支付数据流的前提下, 助力电商平台与各参与商家实现精准网络营销策略的极速上线与商业变现。

4. 总结与展望

本文针对电商多方数据协同建模过程中的效能瓶颈, 构建了一套具有显著商业应用价值的轻量级联邦协同网络营销机制。实证结果表明, 该机制不仅能显著降低中小商家及移动终端参与协同的运营负担, 有效解决企业获取精准画像的成本难题, 更能在消费偏好高度异构的复杂市场环境中展现出优异的决策稳定性。在实际业务落地场景中, 该机制通过极低的协同交互成本实现网络了营销策略的敏捷优化, 相较于传统模式大幅释放了渠道带宽资源, 这确保了精准网络营销系统在不干扰核心交易及支付链路的前提下, 实现策略的秒级迭代更新, 为电商平台在大促时段捕捉瞬时消费动机、提升客户转化路径提供了实时、可靠的决策支撑。后续研究将进一步探讨该机制在复杂动态网络环境下的自适应调节能力, 并尝试将其拓展至跨境电商风控、柔性供应链预测等海量数据垂直领域, 通过在隐私合规框架下持续释放数据资产的商业价值。

基金项目

国家自然科学基金项目(12661062,12261020)和贵州省基础研究计划重点项目(黔科合基础ZD[2026]054)。

参考文献

- [1] 朱樱. 大数据背景下电子商务精准网络营销运营策略实践[J]. 现代商业研究, 2026(2): 106-108.
- [2] 李海平. 基于大数据的精准网络营销模式创新路径研究[J]. 营销界, 2025(22): 10-12.
- [3] 王斯颖. 基于多维度数据分析的电子商务用户行为分析与精准网络营销研究[J]. 中国企业管理知识仓库, 2025, 23(5): 231-234.
- [4] 孙跃. 数字经济时代企业数据合规及其构建[J]. 湖北社会科学, 2022(8): 119-128.
- [5] 金晶, 刘晓冉, 陈妍君, 等. 生成式 AI 与联邦学习融合下的跨境电商风控体系重构——基于阿里巴巴国际站与亚马逊的比较分析[J]. 现代商贸工业, 2026, 47(1): 55-58.
- [6] 刘佳丽, 李道彬. 大数据时代电子商务精准网络营销策略优化研究[J]. 营销界, 2025(24): 79-81.
- [7] McMahan, H.B., Moore, E., Ramage, D., et al. (2017) Communication-Efficient Learning of Deep Networks from Decentralized Data. 2017 *International Conference on Artificial Intelligence and Statistics*, Fort Lauderdale, 20-22 April 2017, 1273-1282.
- [8] Wu, C., Wu, F., Lyu, L., Huang, Y. and Xie, X. (2022) FedCTR: Federated Native Ad CTR Prediction with Cross-Platform User Behavior Data. *ACM Transactions on Intelligent Systems and Technology*, **13**, 1-19. <https://doi.org/10.1145/3506715>
- [9] Di, Y., Fan, J., Zhang, R., Shen, S., Bao, J., Hu, R., et al. (2025) Global Perception Federated Recommender System for Click-Through Rate Prediction. 2025 *IEEE International Conference on Multimedia and Expo (ICME)*, Nantes, 30 June-4 July 2025, 1-6. <https://doi.org/10.1109/icme59968.2025.11209581>
- [10] Zhou, G., Mou, N., Fan, Y., Pi, Q., Bian, W., Zhou, C., et al. (2019) Deep Interest Evolution Network for Click-Through Rate Prediction. *Proceedings of the AAAI Conference on Artificial Intelligence*, **33**, 5941-5948.

- <https://doi.org/10.1609/aaai.v33i01.33015941>
- [11] Hard, A., Straiton, A., Rao, K., *et al.* (2018) Federated Learning for Mobile Keyboard Prediction. <https://doi.org/10.48550/arXiv.1811.03604>
 - [12] 朱江湖. 新型电商平台广告点击率算法研究与实现[D]: [硕士学位论文]. 重庆: 重庆邮电大学, 2022.
 - [13] Li, T., Sahu, A. and Zaheer, M. (2020) Federated Optimization in Heterogeneous Networks. 2020 *Proceedings of Machine Learning and Systems*, Austin, 2-4 March 2020, 429-450.
 - [14] Zhou, S. and Li, G.Y. (2023) Federated Learning via Inexact ADMM. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **45**, 9699-9708. <https://doi.org/10.1109/tpami.2023.3243080>
 - [15] 史汶泽, 陆林, 秦文杰, 于涛. 一种可信执行环境下的联邦逻辑回归评分卡系统[J]. 应用科学学报, 2023, 41(3): 488-499.