

面向电商复杂用户行为序列的多视角协同学习框架研究

李炜玮, 李 华*

贵州大学省部共建公共大数据国家重点实验室, 贵州 贵阳

收稿日期: 2026年6月17日; 录用日期: 2026年7月1日; 发布日期: 2026年8月11日

摘 要

针对电商用户行为序列建模中特征提取不全、时序与频率特征融合不足的问题, 本文提出多视角协同学习框架TPA-Net。该框架通过多尺度特征提取、时空频三路径并行编码与跨路径注意力融合, 实现复杂行为序列的高维表征。在阿里巴巴用户行为数据集的6分类任务中, TPA-Net准确率达92.17%, Macro-F1达91.12%, 较双路径CNN-LSTM显著提升。模型精度提升的同时计算成本有所增加, 可为电商用户价值细分、流失预警与精准营销提供技术支撑, 也为复杂时序预测提供参考。

关键词

用户行为序列, 多视角协同学习, 时空频域建模, 多尺度特征提取, 用户价值细分

Research on Multi-Perspective Collaborative Learning Framework for Complex E-Commerce User Behavior Sequences

Weiwei Li, Hua Li*

State Key Laboratory of Public Big Data, Guizhou University, Guiyang Guizhou

Received: June 17, 2026; accepted: July 1, 2026; published: August 11, 2026

Abstract

To address the problems of incomplete feature extraction and insufficient fusion of temporal and frequency features in modeling e-commerce user behavior sequences, this paper proposes a multi-

*通讯作者。

文章引用: 李炜玮, 李华. 面向电商复杂用户行为序列的多视角协同学习框架研究[J]. 电子商务评论, 2026, 15(8): 242-252. DOI: 10.12677/ecl.2026.158870

perspective collaborative learning framework, TPA-Net. The framework realizes high-dimensional representation of complex behavior sequences through multi-scale feature extraction, temporal-spatial-frequency three-path parallel encoding, and cross-path attention fusion. In the 6-class classification task on the Alibaba user behavior dataset, TPA-Net achieves 92.17% accuracy and 91.12% Macro-F1, with significant improvements over the dual-path CNN-LSTM. While improving accuracy, the model incurs a higher computational cost. It can provide technical support for user value segmentation, churn warning, and precision marketing in e-commerce, and also serve as a reference for complex time-series prediction.

Keywords

User Behavior Sequences, Multi-Perspective Collaborative Learning, Temporal-Spatial-Frequency Modeling, Multi-Scale Feature Extraction, Customer Value Segmentation

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

在数字经济全球化深入推进的背景下, 电子商务凭借便捷高效的核心优势, 已深度渗透到生产生活的各个领域, 不仅成为拉动消费、促进产业升级的重要动力, 更成为全球经济增长的核心引擎。据中国互联网络信息中心发布的第 57 次《中国互联网络发展状况统计报告》[1]显示, 截至 2025 年 12 月, 我国网络购物用户达 9.37 亿, 网上零售额 15.97 万亿元, 同比增长 8.6%。用户行为日趋复杂, 精准的用户行为分类是电商平台实现个性化推荐、精准营销与风险防控的关键。

为此, 本文提出三路径深度学习模型 TPA-Net, 核心创新点如下:

1. 提出多尺度特征提取器, 整合多尺度卷积分支、膨胀卷积分支、注意力门控机制与上下文特征捕获模块, 可同时提取用户行为序列中的短程、中程、长程特征及局部与全局上下文特征, 有效解决传统模型特征提取不全面的问题;
2. 设计三路径并行处理网络, 针对时序依赖、局部模式、周期性特征分别设计时间路径、空间路径与频率路径, 实现多维度特征的并行提取与深度处理, 显著提升特征表示的丰富性;
3. 引入跨路径注意力融合机制, 建立三条路径之间的双向信息交互渠道, 实现互补特征的协同增强, 有效解决单一路径特征表达能力有限的问题, 进一步提升模型的分类精度与泛化能力。

2. 相关工作

2.1. 电子商务分类相关工作

数字经济下, 电子商务分类是平台精细化运营与精准服务的基础, 研究重心已从静态商品分类转向动态用户行为序列分析, 技术也从传统机器学习向端到端深度学习演进。早期商品分类依赖手工特征与传统机器学习, 面对海量高维数据时泛化能力不足。随着行为数据增长, 研究转向用户行为分类, 曹志斌等[2]的研究指出, 精准的用户行为分类能够为个性化推荐策略提供关键的底层支撑, 是提升平台转化率的核心逻辑。相比于基于消费金额等统计特征的传统方法, 深度学习技术为挖掘行为背后的深层规律提供了有效工具。黄梦婷[3]通过引入注意力机制改进卷积神经网络, 有力证明了深度学习在捕捉用户行为特征信号方面的卓越效能。

尽管深度学习已推动电商分类进入新阶段,但现有的研究成果仍存在明显的局限性。正如 Dritsas 等[4]在系统梳理机器学习应用挑战时所强调的,如何在多变的应用语境下实现特征的高效融合,仍是当前技术发展的核心阻碍。

2.2. 多尺度特征提取技术研究与应用

多尺度特征提取可捕获不同粒度特征,弥补单一尺度不足,是提升分类精度的关键技术。在电商领域,该技术已用于商品识别与用户行为分析。早期商品分类侧重局部特征,忽略全局关联;多尺度膨胀卷积成为行为依赖提取的主流方法。Chen 等[5]提出的 DeepLab 模型通过引入空间金字塔池化与膨胀卷积架构,为复杂场景下的多尺度信息整合提供了重要范式,也为本文在频率路径中设计空洞卷积层提供了关键的技术借鉴。尽管此类方法能区分不同消费者的短程依赖,但在处理高度异构的行为序列时,特征融合方式仍显单一,且未能充分挖掘行为数据中隐含的周期性规律。

近年来,学术界尝试通过整合多种先进组件来优化多尺度提取的效果。冯雅莉[6]验证了多尺度特征在时序行为挖掘中的价值;结合注意力或 Transformer 的方案存在计算量大、频域信息融合不足等缺陷。如王露薇等[7]融合频域信息构建推荐模型,为本文频率路径提供思路。

2.3. 注意力机制研究与应用

注意力机制可自适应加权特征,突出关键信息、抑制噪声,已发展为空间、通道、时序等多维度融合技术。Vaswani 等[8]提出的自注意力机制(Self-Attention)通过挖掘序列内部的全局依赖关系,不仅颠覆了传统序列建模范式,也为本文时间路径中时序注意力模块的构建提供了坚实的理论支撑。Hu 等[9]的 SE-Net 为本文通道注意力设计提供参考;CBAM 模块可增强局部信息,但多路径场景下路径间交互不足。甘鹏飞等[10]将注意力与 LSTM 融合用于电商预测,验证了其对时序特征的增强效果;夏云舒[11]的长短期兴趣学习框架为跨路径融合提供借鉴。当前多路径研究多采用简单拼接或单向传递,缺乏双向交叉注意力交互,特征难以深度协同增强。

3. 模型设计

3.1. 模型整体架构

本文提出了一种增强的三路径用户行为分类模型(TPA-Net),该模型采用端到端的深度学习架构,旨在从用户行为序列数据中提取多层次、多视角的特征表示,提升电子商务分类的精度与泛化能力。模型整体架构如图 1 所示,主要由四个核心模块组成:多尺度特征提取器、三路径并行处理网络、跨路径注意力融合模块以及分类决策模块。

模型的工作流程如下:首先,将预处理后的用户行为序列数据输入多尺度特征提取器,提取多尺度、多维度的初始特征;随后,将初始特征送入三路径并行处理网络,分别通过时间路径、空间路径、频率路径进行深度特征提取,得到三种不同类型的特征表示;接着,通过跨路径注意力融合模块,实现三条路径特征之间的信息交互与协同增强;最后,将融合后的特征送入分类决策模块,输出分类结果。

3.2. 特征提取一体化设计

为解决传统模型多尺度特征提取不全、模块耦合度低的问题,本文设计特征提取一体化结构,深度融合多尺度卷积与膨胀卷积,结合上下文捕获与特征精炼,为三路径网络提供高质量特征输入。

该结构整合多尺度卷积分支与膨胀卷积分支,同步提取短程、中程、长程特征。膨胀卷积感受野计算公式为:

$$RF = (k - 1) \times d + 1$$

其中, RF 为感受野大小, k 为卷积核尺寸, d 为膨胀率。通过可学习的尺度权重参数实现自适应加权融合, 确保特征提取的全面性, 多尺度特征融合公式为:

$$F_{ms} = \sum_{i=1}^N w_i \cdot F_i$$

其中, F_{ms} 为融合后的多尺度特征, w_i 为第 i 个卷积分支的可学习权重(经 Softmax 归一化, 满足 $\sum_{i=1}^N w_i = 1$), F_i 为第 i 个卷积分支的输出特征, N 为卷积分支总数。同时结合局部与全局上下文特征捕获, 提升特征的上下文感知能力, 进一步优化特征质量。该一体化结构实现多尺度特征同步捕获与高效融合, 避免模块脱节, 在提升特征判别力的同时简化模型架构, 具备良好的合理性与创新性。




Figure 1. Overall architecture of the model
图 1. 模型整体架构图

3.3. 三路径并行处理架构

经过多尺度特征提取器处理后, 特征被送入三条并行路径进行深度处理。每条路径针对特定的特征类型进行优化设计, 分别专注于捕获用户行为序列中的时序依赖、局部模式和周期性特征, 实现多维度特征的深度挖掘与表达。三条路径的结构相互独立但又相互关联, 通过后续的跨路径注意力融合模块实现信息交互。

3.3.1. 时间路径

时间路径专注于捕获用户行为序列中的时序依赖关系, 即用户不同行为之间的时间先后顺序与依赖关系(如用户先浏览商品, 再加入购物车, 最后下单的行为逻辑)。该路径采用三阶段卷积结构, 逐步将特

征通道数从 64 扩展至 512, 同时通过最大池化操作将序列长度压缩, 实现特征的逐步深化与维度提升。

为提升训练稳定性并缓解深层网络的梯度消失, 各阶段均集成预激活残差块。其结构遵循“BN → ReLU → 卷积 → BN → ReLU → 卷积”并辅以残差连接。这种设计将归一化与激活函数置于卷积层之前, 有助于梯度有效传递, 避免深层性能退化。

路径末端引入了 CBAM 与时序注意力模块。CBAM 从通道和空间两个维度实现特征自适应增强: 通道注意力通过全局池化捕获全局信息, 空间注意力则通过聚合通道特征学习位置权重。时序注意力模块则利用多头自注意力机制建模长距离依赖。相比传统 RNN, 自注意力机制不受位置距离限制, 能更高效地捕获长程时序特征; 多头机制则允许模型在不同表示子空间并行学习, 显著增强了表征能力。

具体计算过程通过线性变换生成查询(Q)、键(K)和值(V), 利用缩放点积计算权重并对 V 加权求和, 公式如下:

$$\begin{aligned} Q &= \text{Linear}Q(F_{time}) \\ K &= \text{Linear}K(F_{time}) \\ V &= \text{Linear}V(F_{time}) \\ \text{Attention}(Q, K, V) &= \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \end{aligned}$$

其中 F_{time} 为时间路径的输入特征, $\text{Linear}Q$ 、 $\text{Linear}K$ 、 $\text{Linear}V$ 为可学习的线性变换矩阵, d_k 为每个注意力头的维度。

3.3.2. 空间路径

空间路径旨在捕获用户行为序列中的局部模式和形态特征, 即用户行为的局部关联与特征模式(如用户在短时间内多次浏览同一类商品的行为模式)。该路径采用多尺度卷积块作为基本构建单元, 每个多尺度卷积块包含三个并行卷积分支, 分别使用 3×1 、 5×1 和 7×1 的卷积核, 能够同时提取不同尺度的局部特征。

三个分支的输出通过通道拼接进行融合, 并与残差连接相加后通过批归一化和 ReLU 激活。残差连接能够保留原始局部特征信息, 避免特征丢失; 批归一化和 ReLU 激活则进一步增强特征的非线性表达能力, 加速模型训练。这种多尺度卷积块的设计, 使得空间路径能够同时捕获短程、中程的局部特征, 提升局部特征表示的丰富性。

空间路径同样采用三阶段结构, 通道数逐步扩展至 512。每个阶段后接残差块和最大池化层: 残差块用于缓解梯度消失问题, 增强特征传递能力; 最大池化层用于压缩序列长度, 降低计算开销, 同时保留局部特征的关键信息。最后, 空间路径的末端引入 CBAM 注意力模块进行特征增强, 从通道和空间两个维度突出局部关键特征, 提升特征的判别能力。

3.3.3. 频率路径

频率路径专门用于捕获用户行为序列中的周期性、重复频次与波动模式, 其理论依据源于时序信号频域分析: 用户行为本质是离散时序信号, 包含固定周期、访问频率、行为密度等频域特征, 膨胀卷积可等效实现时序信号的多尺度频域滤波, 无需傅里叶变换即可高效提取周期分量。该路径以膨胀卷积为核心, 通过递增膨胀率捕获短/中/长周期行为规律, 适配电商用户周度、月度消费周期等典型场景。

频率路径的三个阶段分别采用膨胀率为 2、4 和 8 的膨胀卷积, 卷积核尺寸均为 3×1 。通过递增的膨胀率, 频率路径的感受野逐步扩大, 能够分别捕获短周期、中周期和长周期的用户行为模式。膨胀卷

积的引入, 使得模型能够在不增加参数数量的情况下, 有效捕获不同周期的特征, 避免因周期过长而无法捕捉长周期行为模式的问题。

频率路径的每个阶段同样包含卷积层、批归一化层、ReLU 激活函数和残差块, 确保特征提取的有效性与稳定性。与时间路径和空间路径不同, 频率路径的末端引入 SE 注意力模块, 而非 CBAM 注意力模块。SE 模块仅关注通道维度的重要性建模, 计算开销更小, 适合处理频率特征——频率特征的核心是通道维度的周期性信息, 通过 SE 模块能够自适应地突出重要的频率分量, 抑制冗余频率特征, 提升频率特征的表示能力。

3.4. 跨路径注意力融合与分类决策

为发挥三条路径的特征互补优势, 解决传统模型交互不足的问题, 本文设计了跨路径注意力融合机制。该机制借鉴交叉注意力思想, 在时间 - 空间、时间 - 频率、空间 - 频率三对路径间建立双向连接。以时空融合为例, 公式为:

$$F_{time \leftarrow space} = Attention(F_{time}, F_{space}, F_{space})$$

其中, $F_{time \leftarrow space}$ 为空间路径特征对时间路径特征的增强结果, F_{time} 为时间路径特征, F_{space} 为空间路径特征。通过该公式将每条路径的特征作为查询, 另外两条路径的特征作为键值, 计算路径间的依赖关系, 将互补特征融入每条路径的特征表示中, 实现三条路径特征的协同优化。

融合后的特征经 1×1 卷积降维至 512 通道, 利用残差块与 SE 模块进一步精炼以提升判别力。分类决策模块引入双向 LSTM 增强时序建模, 结合全局平均池化与最大池化策略拼接特征向量, 旨在全面捕获序列的全局趋势与局部关键信息。分类头采用集成 BN、ReLU 和 Dropout 的三层全连接网络以抑制过拟合, 最终通过 Softmax 函数输出类别概率分布:

$$p_i = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}}$$

其中, p_i 为第 i 类的预测概率, z_i 为全连接网络输出的第 i 类 logits 值, C 为分类类别总数。

4. 实验验证

4.1. 数据集介绍

为有效支撑 TPA-Net 模型的设计与验证, 本研究选取阿里巴巴淘宝 UserBehavior.csv 数据集作为核心对象。该数据集涵盖浏览、收藏、加购及购买四类真实行为数据, 具有场景全面、分布均衡等特点, 高度契合电商领域用户行为分析的实际需求。

数据预处理流程如下: 首先, 加载原始数据并提取用户 ID、行为类型及时间戳等字段; 接着, 将文本行为映射为数字编码(1~4)以统一格式; 随后, 按用户 ID 分组并依时间戳排序, 构建连续行为序列以完整保留时序依赖。在此基础上, 本研究创新性地基于序列统计特征, 将用户划分为 6 个业务含义明确的价值类别(见表 1), 旨在多维度反映用户的购买潜力与活跃度, 为精准营销和流失预警提供支撑。

针对现实场景中各类别样本分布不均的问题, 本研究实施了数据平衡策略。以划分后的最小类别样本数为基准, 对超出基准的类别执行随机下采样。此策略确保了各类别样本规模基本一致, 有效消除了模型训练过程中因样本偏置导致的识别精度下降, 增强了模型的泛化能力。

预处理完成后, 将处理后的 150,000 条结构化数据按照 7:2:1 的比例划分为训练集、验证集与测试集。在划分过程中, 严格确保各子集的分类分布与全集保持高度一致, 从而保证了模型训练、参数调优及最终性能评估的客观性与公正性。

Table 1. Customer value segmentation standards
表 1. 用户价值类别划分标准

类别	名称	分类标准
0	高价值忠诚用户	购买 ≥ 3 次, 且同时有收藏 + 加购行为
1	高价值活跃用户	购买 ≥ 1 次, 有收藏或加购行为
2	中价值意向用户	无购买, 但有收藏 + 加购行为
3	低价值浏览用户	无购买, 仅有收藏或加购(单一行为)
4	潜在流失用户	仅浏览行为, 浏览次数 < 20
5	沉默浏览用户	仅浏览行为, 浏览次数 ≥ 20

4.2. 评价指标选取

针对电子商务用户行为多分类任务特点, 选取准确率(Accuracy)、平均召回率(Recall)、平均 F1 值(F1-Score)、宏平均 F1 值(Macro-F1)作为核心评价指标, 全面衡量模型分类性能。各指标核心定义如下: 准确率衡量模型整体分类效果, 平均召回率衡量模型对各类别样本的识别能力, 平均 F1 值平衡模型精确性与召回率, 宏平均 F1 值衡量多分类任务整体均衡性, 训练时间与参数量反映模型实时适用性与工程化部署可行性。

4.3. 实验结果与分析

本次实验分为三个核心部分: TPA-Net 模型与传统机器学习模型、主流深度学习模型的性能对比实验、模型核心设计模块的消融实验、模型泛化能力验证实验。所有实验均在标准化软硬件环境与统一参数设置下完成, 通过详细的实验数据、图表对比与深度分析, 全面验证 TPA-Net 模型的优越性、有效性与实用性。

4.3.1. 模型性能对比实验

为明确 TPA-Net 模型的分类性能优势, 选取 3 种传统机器学习模型(SVM、随机森林、逻辑回归)与 4 种主流深度学习模型(CNN、LSTM、CNN-LSTM、双路径 CNN-LSTM)作为对比模型, 在阿里巴巴淘宝公开数据集上开展对比实验, 所有模型采用相同的数据集预处理方式、训练参数与评价标准, 确保实验对比的公平性与客观性, 实验结果如表 2 所示。

Table 2. Model performance comparison experiment results
表 2. 模型性能对比实验结果

模型	准确率(%)	平均召回率(%)	平均 F1 值(%)	Macro-F1 (%)	参数量(M)	训练时间(s/epoch)
SVM	72.34	70.12	71.23	70.85	0.12	12.56
随机森林	75.68	73.45	74.56	74.12	0.25	18.73
逻辑回归	70.15	68.32	69.24	68.76	0.08	8.91
CNN	82.46	80.35	81.42	81.03	12.36	25.47
LSTM	84.72	82.61	83.67	83.24	18.59	38.62
CNN-LSTM	86.89	85.14	86.02	85.67	25.71	45.38
双路径 CNN-LSTM	88.53	86.92	87.73	87.35	32.48	52.16
TPA-Net	92.17	90.64	91.41	91.12	38.65	58.79

根据表 2 所示的实验数据, 本研究对 TPA-Net 在阿里巴巴淘宝用户行为序列数据集上的分类性能进行了分析。结果清晰呈现了从传统机器学习到基础深度学习, 再到本文三路径架构在复杂用户行为分类上的性能提升。

从实验数据来看, 传统机器学习模型的准确率仅分布在 70.15%至 75.68%之间, 其性能瓶颈主要在于过度依赖手动构建的统计特征, 难以有效捕捉用户行为序列中深层的动力学规律及长距离时序依赖, 如逻辑回归受限于线性假设, 在处理高度非线性的价值分类任务时表现最差。相比之下, 深度学习架构实现了性能的跨越式提升, 基础的 CNN 与 LSTM 模型通过端到端的特征提取, 将准确率基准提升至 82.46%与 84.72%, 充分验证了神经网络在学习局部模式与时序关联方面的优越性。进一步对比发现, CNN-LSTM 融合模型及双路径架构通过整合空间与时间维度的特征, 将准确率推高至 88%左右, 这有力地证明了在复杂电商场景下, 单一视角的特征提取已不足以完全刻画用户的多维意图, 多路径特征融合才是提升模型判别能力的关键路径。

本文提出的 TPA-Net 模型在所有评价指标上均取得了显著领先。其准确率达到 92.17%, Macro-F1 值达到 91.12%, 较之目前性能最优的双路径 CNN-LSTM 模型分别提升了 3.64%和 3.77%。这种实质性的突破直接得益于 TPA-Net 的“三路径并行处理网络”与“跨路径注意力融合模块”设计。不同于对比模型仅关注时空特征, TPA-Net 引入了频率路径, 能够精准捕捉用户行为的波动频率。在分类决策过程中, 模型不仅能识别出空间特征, 例如“收藏”或“购买”等关键动作, 还能感知这些动作发生的先后顺序以及操作的密集程度, 即频率特征, 从而实现了对于 6 类用户价值类别的精准画像。

此外, TPA-Net 的平均召回率高达 90.64%, 证明跨路径注意力融合模块能有效从冗余行为序列中聚焦关键转化节点, 抑制无效噪声。高水平的 Macro-F1 值反映出模型对各类样本识别的高度一致性, 避免了偏向优势类别的过度拟合。

在效率权衡方面, 虽然 TPA-Net 的参数量(38.65 M)略有增加, 但在实际电商预警与营销场景中, 其带来的跨越 90%精度的增益具有显著的工业价值。综上, TPA-Net 在多维特征表征与复杂序列分类任务中展现出卓越的鲁棒性与实用价值。为直观展示性能差异, 图 2 呈现了各模型核心指标的对比轨迹:




Figure 2. Performance comparison between TPA-Net and benchmark models
图 2. TPA-Net 与对比模型性能对比

4.3.2. 模型消融实验

为验证 TPA-Net 核心模块的有效性, 本文设计消融实验, 依次移除关键组件构建 4 种变体模型: TPA-Net-1 (移除多尺度特征提取, 改用单尺度卷积)、TPA-Net-2 (移除三路径, 采用单路径)、TPA-Net-3 (移除跨路径注意力, 改用特征拼接) 及完整模型 TPA-Net。所有模型在相同实验设置下基于阿里巴巴公开数据集训练测试, 结果如表 3 所示。

Table 3. Ablation experiment results
表 3. 消融实验结果

模型变体	核心修改	准确率(%)	平均 F1 值(%)
TPA-Net-1	移除多尺度特征提取, 改用单尺度卷积	87.32	86.45
TPA-Net-2	移除三路径, 改用单路径结构	85.67	84.78
TPA-Net-3	移除跨路径注意力, 改用简单拼接	88.91	88.03
TPA-Net	全模块保留	92.17	91.41

根据表格对比数据表明, 移除三路径结构导致准确率从 92.17% 跌至 85.67%, F1 值下降 6.63%。这证明单一视角难以全面刻画复杂的价值类别。TPA-Net 通过时、空、频并行协同, 能多视角挖掘行为深层逻辑, 精准识别行为密度及频率差异明显的细分用户。

其次, 多尺度特征提取器对捕捉不同粒度模式至关重要。移除该模块后, 准确率下降 4.85%。这证明了用户行为具有显著的多尺度特性, 如即时兴趣与长期偏好, 多尺度设计能打破单尺度感受野的限制, 提取出更为丰富的多维初始特征。

此外, 跨路径注意力模块显著增强了模型精度。替换为简单拼接后, 准确率下降 3.26%。这是由于注意力机制解决了特征冗余及重要性失衡问题, 通过动态加权实现了路径间深度交互, 使特征表达由“数量堆叠”向“质量增强”跨越, 有效抑制了噪声干扰。

综上, 消融实验充分验证了 TPA-Net 核心模块设计的合理性。多尺度提取深化了原始特征表达, 三路径架构拓宽了感知维度, 跨路径注意力则优化了整合效率。三者深度耦合, 确保了模型在复杂分类任务中的高精度与稳健性。为直观展示各组件性能贡献, 消融实验结果对比图如图 3 所示。




Figure 3. Figure of ablation experiment results comparison
图 3. 消融实验结果对比图

4.3.3. 不同分类用户类别的分类性能细化分析

为进一步分析 TPA-Net 的识别稳定性, 本研究结合个用户类别分类性能(图 4 左)与混淆矩阵(图 4 右)对分类结果进行了深层解析。结果显示, 模型在“流失用户”与“高价值用户”类别表现最出色, F1 值分别达 93.5%和 92.0%。这得益于两类用户特征鲜明: 流失用户多为极低频浏览, 高价值用户则表现为高频深度交互。TPA-Net 的三路径结构能敏锐捕捉这类极端的频率与空间特征, 实现极高的精确率与召回率。

相比之下, “潜力”与“活跃”用户识别难度略高。混淆矩阵显示, 潜力用户有 5.0%和 4.3%分别被误判为“沉睡”与“流失”用户, 主因是三者行为模式高度相似, 仅存在浏览频次的阈值差异。同样, 部分“活跃用户”向相邻类别漂移, 反映了意向行为临界点的识别挑战, 这也佐证了引入多尺度特征提取的必要性。

总体来看, 混淆矩阵对角线分类精度均处于 86.0%至 93.0%的高位区间, 且误判多发生于逻辑相邻类别间, 未出现跨度较大的严重错判。这证明 TPA-Net 不仅具备卓越的宏观预测精度, 亦能精准感知用户价值演变的动态特征。模型对 6 类价值类别的均衡识别能力, 为电商平台实施差异化运营与精准营销提供了科学的决策依据。




Figure 4. Classification performance for different user categories

图 4. 不同分类用户类别分类性能

5. 结论

本文面向数字经济场景下电商复杂用户行为序列的精准分类需求, 提出三路径深度学习框架 TPA-Net。模型通过多尺度特征提取、时间 - 空间 - 频率三路径并行编码与跨路径注意力融合机制, 实现用户行为特征的高效捕获与深度协同表征。实验结果表明, TPA-Net 在 6 类用户价值分类任务中准确率达到 92.17%, 综合性能显著优于传统机器学习模型与主流深度学习基线。

应用层面, TPA-Net 可直接支撑电商平台用户价值细分、流失风险预警、精准画像构建与动态价值评估, 为个性化推荐、精准营销等业务提供高精度特征表征与建模支撑。该多视角协同学习架构不仅提升了复杂行为序列的建模精度与泛化能力, 也为多路径神经网络在多维时序数据分类领域提供了可复用的设计思路与实践经验。

未来, 本研究将重点推进三方面工作: 一是模型轻量化设计, 压缩参数量与计算复杂度以适配移动

端及边缘计算低延迟部署；二是引入联邦学习等隐私计算技术，在保障数据安全与隐私合规的同时提升训练效能；三是探索跨平台、跨域迁移学习，增强模型在多源异构电商场景的泛化与复用能力，为数字贸易智能运营与决策提供更普适高效的技术方案。

基金项目

贵州黔程慧通科技发展有限公司科研项目“西南山区道路养护工程科学决策一体化应用研究” (No. QCHT-2025-06)。

参考文献

- [1] 中国互联网络信息中心. 第 57 次中国互联网络发展状况统计报告[R/OL]. <https://www.cnnic.cn/NMediaFile/2026/0304/MAIN1772588317069TUXN3827X8.pdf>, 2026-03-29.
- [2] 曹志斌, 郑淼. 电子商务平台的用户行为分析与个性化推荐策略研究[J]. 商场现代化, 2025(23): 45-47.
- [3] 黄梦婷. 基于注意力机制卷积神经网络的电商用户行为预测分析[J]. 集成电路应用, 2025, 42(10): 115-117.
- [4] Dritsas, E. and Trigka, M. (2025) Machine Learning in E-Commerce: Trends, Applications, and Future Challenges. *IEEE Access*, **13**, 99048-99067. <https://doi.org/10.1109/access.2025.3572865>
- [5] Chen, L., Papandreou, G., Kokkinos, I., Murphy, K. and Yuille, A.L. (2018) DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **40**, 834-848. <https://doi.org/10.1109/tpami.2017.2699184>
- [6] 冯雅莉. 用户时序行为数据的模式发现与预测[D]: [博士学位论文]. 广州: 广东工业大学, 2025.
- [7] 王露薇, 孙克雷. 融合频域信息的多尺度序列推荐模型[J/OL]. 廊坊师范学院学报(自然科学版): 1-8. <https://link.cnki.net/urlid/13.1391.n.20260303.1305.002>, 2026-03-27.
- [8] Vaswani, A., Shazeer, N., Parmar, N., et al. (2017) Attention Is All You Need. arXiv: 1706.03762.
- [9] Hu, J., Shen, L. and Sun, G. (2018) Squeeze-and-Excitation NETWORKS. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 7132-7141. <https://doi.org/10.1109/cvpr.2018.00745>
- [10] 甘鹏飞, 江雨燕. 注意力机制融合长短期记忆网络与深度神经网络的电商销售预测研究[J/OL]. 重庆工商大学学报(自然科学版): 1-11. <https://link.cnki.net/urlid/50.1155.N.20260307.1341.002>, 2026-03-27.
- [11] 夏云舒. 电商用户序列中基于长短期兴趣学习的精准推荐研究[D]: [硕士学位论文]. 大连: 东北财经大学, 2022.