

DOI: 10.3969/j.issn.2096-8248.2026.01.007

引用格式: 仲兆满, 徐俊康, 李梦晗, 等. 基于客户需求的多式联运物流方案推荐算法[J]. 江苏海洋大学学报(自然科学版), 2026, 35(1): 54-65.

基于客户需求的多式联运物流方案推荐算法

仲兆满^{1,2}, 徐俊康¹, 李梦晗¹, 陈柯含¹

(1. 江苏海洋大学 计算机工程学院, 江苏 连云港 222005;

2. 江苏省海洋资源开发研究院, 江苏 连云港 222005)

摘要: 随着全球经济一体化和“一带一路”倡议的推进, 港口物流在区域经济发展中的作用愈发重要。然而, 客户对物流服务需求的多样化和个性化, 使得传统物流方案决策系统难以满足复杂需求, 制约了港口物流企业的竞争力。研究提出了一种基于客户需求的多式联运物流方案推荐算法 (COMLRA), 通过深度学习技术构建智能推荐决策系统, 精准识别客户需求并生成个性化物流方案。该算法利用嵌入层、注意力机制、交叉网络和深度网络, 捕捉特征间的复杂交互关系, 并引入动态损失权重和排序损失优化预测性能。实验结果表明, COMLRA 在 HR@5 和 NDCG@5 指标上优于其他方法, 验证了其有效性和优越性。该研究为港口物流企业提供了高效、灵活的决策支持工具, 助力智慧物流技术的深度应用和港口物流行业的智能化升级。

关键词: 客户需求; 推荐算法; 多式联运; 注意力机制; 深度学习

中图分类号: TP39

文献标志码: A

文章编号: 2096-8248(2026)01-0054-12

Multi modal logistics solution recommendation algorithm based on customer needs

ZHONG Zhaoman^{1,2}, XU Junkang¹, LI Menghan¹, CHEN Kehan¹

(1. School of Computer Engineering, Jiangsu Ocean University, Lianyungang 222005, China;

2. Jiangsu Research Institute of Marine Resources Development, Lianyungang 222005, China)

Abstract: With the promotion of global economic integration and the “the Belt and Road” initiative, port logistics plays an increasingly important role in regional economic development. However, the diversification and personalization of customer needs for logistics services make it difficult for traditional logistics decision-making systems to meet complex needs, which constrains the competitiveness of port logistics enterprises. This study proposes a customer need based multimodal logistics solution recommendation algorithm (COMLRA), which constructs an intelligent recommendation decision system through deep learning technology to accurately identify customer needs and generate personalized logistics solutions. This algorithm utilizes embedding layers, attention mechanisms, crossover networks, and deep networks to capture complex interactions between features, and introduces dynamic loss weights and ranking losses to optimize prediction performance. The experimental results indicate that COMLRA is HR@5

收稿日期: 2025-05-21; 修订日期: 2025-08-07

基金项目: 国家自然科学基金资助项目(72174079); 江苏省“青蓝工程”大数据优秀教学团队(2022-29); 连云港市重点研发(产业前瞻与关键核心技术)项目(CG2323)

作者简介: 仲兆满, 教授, 博士, 研究方向为互联网舆情大数据分析及管控等, (E-mail) zhongzhaoman@163.com。

and NDCG@5. It outperforms other methods in terms of indicators, verifying its effectiveness and superiority. This study provides efficient and flexible decision support tools for port logistics enterprises, facilitating the deep application of smart logistics technology and the intelligent upgrading of the port logistics industry.

Key words: customer needs; recommendation algorithm; multimodal transport; attention mechanism; deep learning

0 引言

随着全球经济一体化进程的加速以及“一带一路”倡议的深入推进,国际贸易与区域经济的联系愈发紧密,港口物流作为连接全球贸易的关键节点,其重要性也愈发凸显。港口物流不仅承担着货物运输、仓储与配送等基础功能,更是区域经济发展的核心驱动力之一。此外,我国的多式联运最早应用于外贸运输,多在长三角、珠三角和环渤海等经济较为发达的地区开展,但运量占比较低,2024年,全国港口集装箱铁水联运量达到1 335万TEU(twenty-foot equivalent unit)^[1]。连云港港作为新亚欧大陆桥的东桥头堡,凭借其独特的地理位置和优越的交通条件,在区域经济发展中扮演着举足轻重的角色^[2]。近年来,连云港港积极响应国家政策,充分利用自身区位优势,大力发展铁水联运、海铁联运等多式联运业务,并逐步探索实现港口、铁路、公路等多种运输方式的无缝对接,取得了显著成效。然而,随着多式联运业务的快速发展,港口物流行业也面临着新的挑战。现有物流推荐算法虽然在一定程度上提升了推荐的准确性,但大多集中在单一运输模式或简单的物流场景中,对于多式联运这种涉及多种运输方式协同运作的复杂场景,其适用性和有效性受到限制。例如,一些基于协同过滤或内容推荐的方法无法有效处理多式联运中的复杂特征交互,也难以适应动态变化的客户需求。此外,现有方法在处理大规模物流数据时,往往面临计算效率低、模型泛化能力不足等问题,难以满足实时性和准确性的双重需求。

针对上述问题,本研究提出了一种基于客户需求的多式联运物流方案推荐算法(customer-oriented multi-modal logistics recommendation algorithm, COMLRA)。该算法通过深度学习方法构建智能推荐决策系统,能够精准识别客户的多维度需求,并生成高效、灵活的个性化物流方案。具体创新点如

下:首先,COMLRA算法通过嵌入层将分类特征转化为低维嵌入向量,利用注意力机制自动学习特征的重要性权重,并结合交叉网络和深度网络捕捉特征之间的复杂交互关系,有效处理多式联运中的复杂性。其次,算法引入动态损失权重和排序损失,优化模型的预测性能,提升整体推荐质量。实验结果表明,COMLRA算法在HR@5和NDCG@5等评价指标上优于现有方法。该研究不仅为港口物流企业提供了高效、灵活的决策支持工具,也为智慧物流技术的深度应用提供了理论支撑,助力我国港口物流行业的智能化升级。

本研究的主要贡献包括:①提出面向多式联运的物流方案推荐算法(COMLRA),满足复杂场景下的个性化需求;②引入深度学习技术,精准捕捉客户需求特征,提升推荐系统的智能化水平;③为其他港口物流企业提供有益参考,推动智慧物流平台的建设与发展。

1 相关工作

1.1 客户需求分析

在物流方案智能决策中,客户需求分析是实现精准决策的关键环节,其他领域的推荐系统所采用的用户需求建模方法为物流领域的需求分析提供了借鉴。近年来,电子商务、社交媒体和金融服务等领域的快速发展推动了推荐系统技术的进步。这些推荐系统通过深入分析用户的行为数据、偏好信息以及上下文环境,构建了丰富多样的用户需求模型,为各自领域客户需求分析的理论与实践提供了宝贵的经验和启示。例如,徐尚英等^[3]通过引入“本体”概念和模糊模型,量化企业用户的需求偏好,并通过计算用户需求与服务资源之间的综合相似度来输出推荐结果,这是通过模糊模型量化企业用户的需求偏好。冯勇等^[4]通过生成对抗网络实现了推荐结果的多样性,并通过考虑用户需求进一步提升了推荐的准确性。这是在生成器中引入用户需求,使得推

荐结果既满足多样性,又符合用户的个性化需求。张飞等^[5]提出的多准则推荐方法能够综合考虑产品属性和客户的定性偏好,通过偏序集方法进行产品排序,推荐最能满足客户当前需求且质量最优的产品。这能够适应客户在不同属性维度上的定性需求分化,给出综合不同需求的折衷排序,具有很强的适用性。Li等^[6]通过分析用户的多维需求,并结合知识图谱的语义信息和强化学习的决策能力,为用户提供更符合其个性化需求的推荐结果。Li^[7]通过分析用户数据和行为,模型能够提供个性化、以用户为中心的旅行路线推荐,显著提升旅行体验,满足现代人对深度体验和休闲旅行的心理需求。上述是在其他领域的研究。在物流领域上,雷嵘嵘等^[8]提出了一种考虑多用户需求的物流服务知识图谱构建与推荐方法,以此来帮助物流服务平台的入驻商家和客户更高效地选择合适的物流服务。可见,在物流领域,精准的客户需求分析是实现高效推荐系统的关键。这一观点在多式联运物流场景中同样适用,充分考虑客户需求对于优化物流方案、提升服务质量具有至关重要的作用。

1.2 物流方案推荐系统

物流方案推荐系统的研究主要集中在算法设计和系统实现方面。例如, Li等^[9]通过引入知识图谱技术和多源数据融合,解决了传统推荐系统在冷链物流场景中的不足,提高了推荐的准确性和可解释性。除了引入知识图谱技术和多源数据融合,还可以与供应链管理结合起来提高物流推荐的准确度。Dadouchi等^[10]提出了一种将推荐系统与供应链管理相结合的方法,通过考虑供应链约束(如运输能力、交付时间窗口和利润)来优化产品推荐,从而提高供应链的敏捷性和响应能力。由于移动云计算具有资源丰富、随时随地通过任何设备访问“云”、提供强大计算和存储功能等优势,能够满足用户对便捷软件服务的需求。Liu等^[11]研究了移动云环境下的物流服务推荐模型及其应用,通过结合移动云计算的优势和大数据系统,为用户提供个性化的物流服务推荐,提高物流服务质量评价的效率和准确性。此外,在物流服务交易中,供需双方信息匹配的精准度和推荐效率也是个关键问题。李蒙等^[12]通过构建多目标优化匹配模型,结合改进的粒子群算法和DeepFM深度学习模型,实现了物流交易信息的精准匹配和高效推荐。张碧玉等^[13]针对现代物流中大件货物与应急零散货物的配送需求,提出了一

个两阶段车货匹配推荐系统。万玉龙等^[14]研究了冷链物流智能配载推荐算法,通过协同过滤技术降低冷链物流管理成本,提高经济效益,并助力国家双碳目标。可见,目前物流推荐系统的研究虽已取得显著进展,但针对多式联运场景的物流推荐系统研究仍相对匮乏。多式联运作为一种高效、灵活的物流运输方式,涉及多种运输模式的协同运作,其复杂性远高于单一运输模式。在多式联运中,货物需要在不同运输方式之间进行转运,这不仅增加了运输过程中的不确定性和复杂性,也对物流推荐系统提出了更高的要求。例如,推荐系统需要综合考虑不同运输方式的成本、时效性、可靠性以及货物的装卸和转运时间等因素,以生成最优的多式联运方案。因此,本文聚焦于开发能够适应多式联运复杂需求的推荐系统,通过引入深度学习等技术,提升推荐系统的智能化水平,为多式联运的高效运作提供有力支持。

2 COMLRA 模型

2.1 总体框架

本文提出的基于客户需求的多式联运物流方案推荐算法(COMLRA)主要由特征提取模块、神经网络模块以及推荐生成模块3个部分组成,如图1所示。

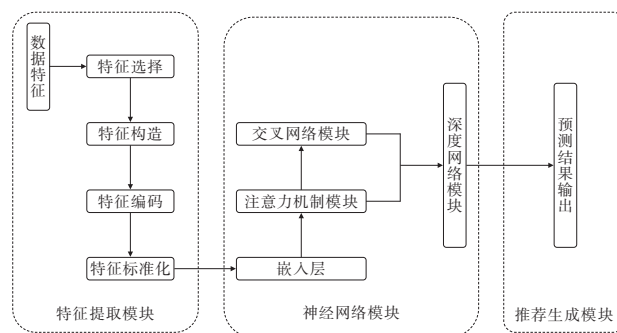


图1 COMLRA 模型架构图

Fig. 1 COMLRA model architecture diagram

2.2 特征提取模块

2.2.1 特征选择

特征选择的目的是从原始数据中筛选出与任务相关且具有预测价值的特征。基于多式联运物流推荐系统的业务需求,本研究主要选择了以下特征:

- (1) 起始地: 表示货物运输的起始地点。
- (2) 目的地: 表示货物运输的目的地。
- (3) 货物类型: 表示货物的种类,如集装箱或

散货。

(4) 中转站: 表示货物在运输过程中经过的中转站。

(5) 总运输时间: 表示货物从起始地到目的地的总运输时间。

(6) 运输方式种类: 表示货物在运输过程中涉及的运输方式数量。

(7) 各段运输时间: 表示货物在每一段运输路径上所花费的时间。

(8) 各段运输方式: 表示货物在每一段运输路径上所采用的运输方式。

(9) 标准金额: 表示运输方案的总成本。

以上这些特征直接反映了客户的物流需求和运输方案的特性, 是构建推荐系统的基础。

2.2.2 特征构造

特征构造是通过原始数据生成新特征的过程, 旨在捕捉数据中隐藏的模式和信息。本研究构造了以下新特征:

(1) 中转次数:

$$\text{中转次数} = \sum_{i=1}^3 I(\text{中转站}_i \neq \text{NaN})。 \quad (1)$$

其中 I 是指示函数, 表示中转站是否非空。具体来说, 当条件成立时, 指示函数的值为 1; 当条件不成立时, 指示函数的值为 0。通过将所有中转站的指示函数值相加, 能得到总的中转次数。该特征反映了运输过程中中转站的使用情况, 对运输时间和成本有直接影响。

(2) 运输方式多样性:

$$\text{运输方式种类} = \text{unique}(\{\text{运输方式}_1, \text{运输方式}_2, \text{运输方式}_3\})。 \quad (2)$$

unique 函数的作用是从所有运输方式中提取出所有不重复的运输方式。该函数将返回一个包含所有不同运输方式的集合。该特征反映了运输过程中涉及的运输方式数量, 有助于评估运输方案的灵活性和多样性。

2.2.3 特征编码

特征编码是将分类特征转换为数值特征的过程, 以便模型能够处理。本研究采用了以下编码方法:

(1) 固定编码: 将货物类型(如“集装箱”和“散货”)映射为数值,

$$\text{货物类型} = \begin{cases} 0, \text{集装箱;} \\ 1, \text{散货。} \end{cases} \quad (3)$$

(2) 运输方式编码: 将运输方式(如“公路”

“铁路”“海路”)映射为数值,

$$\text{运输方式} = \begin{cases} 0, \text{公路;} \\ 1, \text{铁路;} \\ 2, \text{海路。} \end{cases} \quad (4)$$

(3) 哈希编码: 对于其他分类特征(如起始地、目的地、承运公司、服务商公司名称等), 使用哈希编码进行处理。哈希编码通过将分类特征映射到固定数量的数值上, 减少了特征维度, 同时保留了特征的区分能力。

2.2.4 特征标准化

特征标准化是将连续特征的值缩放到一个特定范围的过程, 以提高模型的训练效率和性能。本研究采用了 Standard Scaler 对连续特征进行标准化:

$$\text{标准化特征} = \frac{\text{特征} - \mu}{\sigma}。 \quad (5)$$

其中 μ 和 σ 分别是特征的均值和标准差。标准化后的特征值范围接近于标准正态分布, 有助于模型更快地收敛。

通过上述特征提取模块的设计, 本研究不仅能够满足客户的多样化需求, 还能为模型提供丰富的特征信息, 从而提高推荐系统的准确性和可靠性。

2.3 神经网络模块

2.3.1 嵌入层

在多式联运物流推荐系统中, 分类特征(如起始地、目的地、货物类型等)通常具有高维度和稀疏性。为了将这些分类特征有效地转换为模型可处理的数值形式, 本研究采用了嵌入层(embedding layer)。嵌入层通过将分类特征映射到低维的连续向量空间, 不仅降低了特征的维度, 还保留了特征间的语义信息。

对于每个分类特征 cat_feature_i , 嵌入层的计算公式为

$$\text{embedding}_i = \text{embedding}(\text{cat_feature}_i)。 \quad (6)$$

其中 embedding 是一个可学习的矩阵, 将分类特征的索引映射到嵌入向量。所有嵌入向量在维度上拼接后形成嵌入特征矩阵 embedded :

$$\text{embedded} = \text{concat}(\text{embedding}_1, \text{embedding}_2, \dots, \text{embedding}_n)。 \quad (7)$$

2.3.2 注意力机制模块

注意力机制的核心思想是通过输入特征进行加权求和, 突出重要特征, 同时抑制不重要的特征。这种机制在处理序列数据和特征交互时非常有效,

能够使模型更加关注与任务相关的特征。

假设输入特征矩阵为 $X \in \mathbb{R}^{L \times D}$, 其中 L 是序列长度(或特征数量), D 是特征维度。注意力机制的计算过程如下:

首先, 是查询(Query, Q)、键(Key, K) 和值(Value, V) 的计算:

$$Q = W_Q X + b_Q, \quad (8)$$

$$K = W_K X + b_K, \quad (9)$$

$$V = W_V X + b_V. \quad (10)$$

其中 W_Q, W_K, W_V 是可学习的权重矩阵; b_Q, b_K, b_V 是偏置向量。

接着, 是注意力分数的计算:

$$\text{attn_scores} = \frac{QK^T}{\sqrt{D}}. \quad (11)$$

其中 \sqrt{D} 是一个缩放因子, 用于防止点积结果过大导致的梯度消失问题。

之后, 是注意力权重的计算:

$$\text{attn_probs} = \text{softmax}(\text{attn_scores}), \quad (12)$$

其中 softmax 函数将注意力分数归一化为概率分布:

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^L e^{z_j}}. \quad (13)$$

最后, 进行加权求和:

$$\text{attn_out} = \text{attn_probs} \cdot V. \quad (14)$$

最终的输出是加权后的值矩阵 V 。

通过注意力机制, 模型能够动态地关注与运输成本和时间预测相关的特征, 从而提高预测的准确性和可靠性。

2.3.3 交叉网络模块

交叉网络是一种用于学习特征交互的模块, 特别适合处理稀疏特征和高维特征。它通过逐层计算特征交互, 增强模型对特征组合的学习能力。

假设输入特征矩阵为 $X \in \mathbb{R}^{B \times D}$, 其中 B 是批量大小, D 是特征维度。交叉网络通过逐层计算特征交互, 能够有效地捕捉特征间的复杂关系, 从而提高模型的表达能力和预测性能。计算过程为

$$x_0 = X, \quad (15)$$

$$x_{l+1} = x_0 \cdot (x_l^T W_l) + b_l + x_l, \quad (16)$$

$$\text{cross_out} = x_L. \quad (17)$$

其中 x_0 是初始输入特征矩阵; x_l 是第 l 层的输出; W_l 是可学习的权重矩阵; b_l 是偏置向量; $x_0 \cdot (x_l^T W_l)$ 表示特征交互项, 通过矩阵乘法实现; L 是交叉网络的层数。

2.3.4 深度网络模块

深度网络是一个多层感知机(MLP), 用于对特

征进行非线性变换, 并进行最终预测。其通过多层全连接层和激活函数, 增强模型的表达能力。具体来说, 深度网络通过多层感知机和残差连接, 能够有效地处理复杂的非线性关系, 从而提高模型的预测性能。

假设输入特征矩阵为 $X \in \mathbb{R}^{B \times D}$, 深度网络的计算过程为

$$h_0 = X, \quad (18)$$

$$h_{l+1} = \text{BatchNorm}(\sigma(W_l h_l) + b_l) + h_l, \quad (19)$$

$$\text{output} = W_{\text{out}} h_L + b_{\text{out}}. \quad (20)$$

其中 h_l 是第 l 层的隐藏状态; W_l 是可学习的权重矩阵; b_l 是偏置向量; σ 是激活函数, 如 Mish; L 是深度网络的层数; W_{out} 和 b_{out} 是输出层的权重和偏置。

在整个神经网络模块中, 各子模块之间的协同工作机制对于模型的整体性能至关重要。嵌入层将高维度、稀疏的分类特征(如起始地、目的地、货物类型等)映射到低维的连续向量空间, 为后续模块提供更易于处理的特征表示。这些嵌入向量不仅为注意力机制模块提供了输入, 还与交叉网络模块协同工作, 增强了模型对特征组合的学习能力。注意力机制模块通过加权求和的方式突出重要特征, 抑制不重要的特征, 其输出与交叉网络模块的输出进行融合, 形成综合特征表示。这种融合策略结合了注意力机制对重要特征的聚焦能力和交叉网络对特征交互的建模能力, 进一步优化了特征表示。最终, 深度网络模块接收融合后的特征表示, 通过 MLP 进行非线性变换, 输出运输成本和时间的预测值。

2.3.5 特征融合与模型输出

在多式联运物流推荐系统中, 特征融合是实现精准推荐的关键环节。本研究采用加权求和的方式融合注意力机制的输出和交叉网络的输出。这种融合策略的理论依据如下: 注意力机制能够动态地关注与任务相关的特征, 突出重要特征, 同时抑制不重要的特征, 从而提高模型对关键信息的捕捉能力; 交叉网络通过逐层计算特征交互, 能够有效地捕捉特征间的复杂关系, 增强模型对特征组合的学习能力。加权求和融合策略能够平衡这两种机制的优势, 既保留了注意力机制对重要特征的聚焦能力, 又结合了交叉网络对特征交互的建模能力, 从而实现更优的特征表示。

与简单的特征拼接相比, 加权求和融合策略具有显著的优势。简单的特征拼接无法有效区分不同特征模块的重要性, 可能导致信息冗余和噪声积累。

本研究的加权求和融合策略通过引入可学习的权重参数, 能够根据任务需求自动调整不同特征模块的贡献, 从而更好地适应多式联运物流推荐任务的复杂性。

本部分将注意力机制的输出 $attn_out$ 和交叉网络的输出 $cross_out$ 进行融合, 形成综合特征:

$$x_{fused}=attn_out+cross_out. \quad (21)$$

融合后的特征 x_{fused} 作为深度网络的输入, 最终输出为

$$output=DeepNetwork(x_{fused}). \quad (22)$$

输出的两个维度分别表示运输成本和时间的预测值。具体过程如算法 1 所示。

算法 1 神经网络模块算法

输入: 分类特征 $cat_feature$

输出: 模型的预测输出 $output$

初始化嵌入特征列表 $embedding$

repeat

for each 嵌入层 $cat_feature_i$ in $cat_feature$ do

 获取当前分类特征列的索引 $cat_feature_i$

 使用嵌入层将分类特征索引转换为嵌入向量 $embedding_i$

 将嵌入向量添加到 $embedding$ 列表

end for

将 $embedding$ 列表中的所有嵌入向量进行拼接, 得到 $embedded$

将嵌入特征进行拼接:

$embedded=concat(embedding_1, embedding_2, \dots, embedding_n)$

应用注意力机制:

$attn_out=attn_probs \cdot V$

应用交叉网络:

$cross_out=x_L$

将 $attn_out$ 和 $cross_out$ 相加:

$x_{fused}=attn_out+cross_out$

通过深度网络得到最终输出:

$output=DeepNetwork(x_{fused})$

return $output$

这部分时间复杂度主要受注意力机制和深度网络的影响, 因此可以表示为 $O(LD^2+MD^2)$ 。其中, L 是序列长度, D 是特征维度, M 是残差块的数量, 注意力机制的时间复杂度为 $O(LD^2)$, 深度网络的时间复杂度为 $O(MD^2)$ 。

2.4 训练与评估

2.4.1 训练流程

在训练开始之前, 数据被划分为训练集、验证集和测试集。训练集用于模型的训练, 验证集用于超参数调整和早停机制, 测试集用于最终的模型性能评估。数据划分比例为 70% (训练集)、20% (验证集) 和 10% (测试集)。为了进一步提高模型的训练效果, 本研究采用了 OneCycleLR 学习率调度器。

为了同时优化运输成本和时间的预测性能, 本研究采用了加权的 Huber 损失函数, 并引入了排序损失 (ListMLE 损失) 来优化模型的排序性能。

(1) 加权 Huber 损失函数^[15]: Huber 损失函数是一种结合了均方误差 (MSE) 和平均绝对误差 (MAE) 的损失函数, 能够对离群值具有更好的鲁棒性。其定义为

$$\text{HuberLoss}(y, \hat{y}) = \begin{cases} \frac{1}{2} (y - \hat{y})^2, & \text{if } |y - \hat{y}| \leq \delta; \\ \delta \cdot (|y - \hat{y}| - \frac{1}{2}\delta), & \text{otherwise.} \end{cases} \quad (23)$$

其中 δ 是阈值, 用于控制损失函数在 MSE 和 MAE 之间的转换。在本研究中, δ 被设置为 1.0。

由于模型同时预测运输成本和时间的, 因此总损失函数为两个任务的加权和:

$$\text{TotalLoss}_{\text{Huber}} = \alpha \cdot \text{HuberLoss}_{\text{cost}} + (1 - \alpha) \cdot \text{HuberLoss}_{\text{time}}. \quad (24)$$

其中, α 是权重参数, 用于平衡两个任务的损失。在本研究中, α 被设置为 0.5, 表示对运输成本和时间的预测给予同等的重视。

(2) 排序损失 (ListMLE 损失)^[16]: 为了优化模型的排序性能, 本研究引入了 ListMLE 损失函数。ListMLE 损失函数通过最大化预测排序的似然度来优化模型的排序性能。其定义为

$$\text{ListMLELoss}(y_{\text{pred}}, y_{\text{true}}) = -\frac{1}{N} \sum_{i=1}^N (y_{\text{pred}, i} - \log(\sum_{j=1}^N e^{y_{\text{pred}, j}})). \quad (25)$$

其中, N 是样本数量, $y_{\text{pred}, i}$ 是模型对第 i 个样本的预测值。

最终的总损失函数为

$$\text{TotalLoss} = \text{TotalLoss}_{\text{Huber}} + \beta \cdot \text{ListMLELoss}. \quad (26)$$

其中, β 是权重参数, 用于平衡 Huber 损失和 ListMLE 损失。在本研究中, β 被设置为 0.5。

此外, 模型在训练过程中采用了数据增强技术,

比如,随机交换中转站和添加随机噪声技术。通过随机交换中转站和添加噪声,模型能够学习到数据的不变性特征,提高模型的泛化能力。在不同的物流场景中,数据可能受到各种噪声的影响,数据增强技术能够增强模型对这些噪声的鲁棒性。模型在训练过程中通过添加噪声等方法,能够提高对数据变化的适应能力。这种鲁棒性使得模型在面对不同场景下的数据变化时,能够保持较好的性能。

2.4.2 评估指标

为了全面评估模型的性能,本研究采用了以下评估指标:

(1) 命中率(Hit-Ratio@K)。

命中率用于衡量模型在前K个推荐方案中是否包含真实最优方案。其计算公式为

$$HR@K = \frac{1}{N} \sum_{i=1}^N I(\hat{y}_i \in \text{Top-}K(y_i))。 \quad (27)$$

其中I是指示函数,Top-K表示前K个预测值,N是测试集的样本数量, y_i 是真实值的排序, \hat{y}_i 是模型的预测值。

(2) 归一化折扣累积增益(NDCG@K)。

NDCG用于衡量模型推荐方案的质量和排序性能。其计算公式为

$$NDCG@K = \frac{\sum_{i=1}^K \frac{2^{y_i-1}}{\log_2(i+1)}}{\sum_{i=1}^K \frac{2^{\hat{y}_i-1}}{\log_2(i+1)}}。 \quad (28)$$

其中, y_i 是真实值的排序, \hat{y}_i 是模型的预测值,K是推荐列表的长度。

在本文中,经实验,K选取5。

2.5 推荐生成模块

在多式联运物流推荐系统中,推荐生成模块是将模型的预测结果转化为具体物流方案的关键环节。该模块的目标是根据客户的特定需求(如起始地、目的地、货物类型等),从所有可能的运输方案中筛选出最符合客户需求的前K个推荐方案。本研究提出的推荐生成模块综合考虑了模型预测的综合评分、多样性和去重等因素,以确保推荐结果的高质量和实用性。这些指标的设计同时实现推荐的准确性和多样性,确保推荐方案不仅在成本和时间上表现优异,同时也能提供多种不同的运输路径和运输方式组合,以满足不同用户的需求。

具体来说,首先,根据客户的起始地、目的地和货物类型,从数据集中筛选出符合条件的候选运输方案。

接着,使用训练好的神经网络模型对筛选出的候选方案进行预测,生成每个方案的运输成本和时间的预测值。基于这些预测值,计算每个方案的综合评分,综合评分可以表示为

$$\text{综合评分} = \lambda \cdot \text{预测成本} + (1-\lambda) \cdot \text{预测时间}。 \quad (29)$$

其中, λ 是权重参数,用于平衡运输成本和时间的的重要性。在本研究中, λ 被设置为0.6,表示更重视运输成本,但同时也不忽略运输时间。

为了确保推荐方案的多样性,引入多样性评分机制。多样性评分通过计算新方案与已推荐方案之间的相似度来评估,相似度越低,多样性评分越高。具体计算公式为

$$\text{多样性评分} = 1 - \frac{1}{M} \sum_{i=1}^M \frac{\text{路径相似度}_i + \text{运输方式相似度}_i}{2}。 \quad (30)$$

其中,M是已推荐方案的数量,路径相似度和运输方式相似度分别计算新方案与已推荐方案在路径和运输方式上的重合度。

之后,将每个候选方案的综合评分与多样性评分结合,得到最终的推荐评分:

$$\text{推荐评分} = \alpha \cdot \text{综合评分} + (1-\alpha) \cdot \text{多样性评分}。 \quad (31)$$

其中, α 是权重参数,用于平衡综合评分和多样性评分的重要性。在本研究中, α 被设置为0.7,表示更重视综合评分,但同时也不忽略多样性。

最后,对所有候选方案按照推荐评分进行排序,并去除重复的方案。最终,选择排名前K的方案作为推荐结果,提供给客户。

每个推荐方案的表示包括以下信息:

- (1) 路径:从起始地到目的地的完整路径,包括所有中转站。
- (2) 运输方式:每一段路径所采用的运输方式。
- (3) 预测成本:模型预测的运输成本。
- (4) 预测时间:模型预测的总运输时间。
- (5) 多样性评分:该方案的多样性评分。
- (6) 综合评分:该方案的综合评分。

该部分具体过程如算法2所示。

算法2 推荐生成模块算法

输入:起始地代号 start_code,目的地代号 end_code,货物类型 cargo_type
输出:推荐列表 recommendations
计算成本和时间的得分:

从 output 中提取成本 costs 和时间 times

计算综合得分 scores

生成推荐列表:

初始化空列表 recommendations 于存储推荐方案

对于 scores 中的每个索引 idx, 按得分从低到高排序:

获取对应的记录 record

构建推荐方案 plan, 包括路径、运输模式、估计成本、估计时间和多样性得分

计算 plan 的综合评分 final_score

将 plan 添加到 recommendations 列表

去重和排序:

初始化空集合 seen 用于存储已见过的推荐方案

初始化空列表 unique_recommendations 用于存储去重后的推荐方案

对于 recommendations 列表中的每个推荐方案 rec, 按 final_score 从高到低排序:

计算 rec 的键 Key

如果 Key 不在 seen 中:

将 Key 添加到 seen

将 rec 添加到 unique_recommendations

如果 unique_recommendations 的长度

达到 top_K, 跳出循环

返回推荐结果

最终生成推荐的总体时间复杂度主要受获取预测结果和生成推荐列表的步骤影响。因此, 本文提出算法时间复杂度可以表示为 $O(C(LD^2+MD^2)+C\log C)$ 。其中, CLD^2 表示对每个候选数据进行模型前向传播时, 由于注意力机制导致的计算量。

CMD^2 表示对每个候选数据进行模型前向传播时, 由于深度网络导致的计算量。

$C\log C$ 表示对所有候选数据的得分进行排序的计算量。

3 实验

3.1 数据集

本文实验所用的数据集为江苏蓝宝星球科技有限公司所提供的连云港港口多式联运物流数据。实验数据的统计信息如表 1 所示。

该数据集包含了货物运输与账单相关的信息, 可以用于分析运输业务流程和财务情况。数据集内包含了 5 144 条记录, 涵盖了 67 个不同方面的信息。

数据集中订单相关信息包含订单编号、运单编号、账单编号等唯一标识字段, 用于区分不同的订单、运单和账单。还有下单时间、接单时间、运输结束时间等信息, 可用于分析业务流程的时间跨度。在货物信息上有如货物类型、空重箱、数量、箱型、箱尺寸、货物质量等, 这些字段描述了货物的基本属性。有地点信息包括起始地代号、目的地代号以及多个中转站信息, 还有相应地点间的所用运输方式和所用时间, 可用于分析运输路线和效率。在业务参与方信息上涉及接单方、下单公司、订单所属公司、承运公司、账单人名称、服务商公司名称等, 明确了业务流程中的各个参与主体。在账单信息上有账单类型、账期、账单月份、标准金额、浮动折扣点、浮动金额、其他合计金额等, 可用于财务核算和分析。此外, 在数据集中大部分运输记录涉及 3 个中转站, 少数涉及 2 个或 4 个中转站。

表 1 实验数据统计信息

Table 1 Statistical information of experimental data

| 数据集 | 样本数量 |
|-----|-------|
| 训练集 | 3 600 |
| 验证集 | 1 030 |
| 测试集 | 514 |

3.2 实验设置

本实验在 Windows 11 和 Python 3.10 的环境下, 在系统内存为 32 GB, 显卡为 16 GB 显存的 NVIDIA RTX 4060Ti 上进行。采用 PyTorch 深度学习框架来构建基于客户需求的多式联运物流方案推荐算法并进行模型训练, 具体参数如表 2 所示。

表 2 参数设置

Table 2 Parameter settings

| 参数 | 值 |
|-----------|--------------------|
| Epoch | 50 |
| 学习率 | 1×10^{-5} |
| 权重衰减 | 1×10^{-4} |
| 隐藏层维度 | 64 |
| 深度网络层数 | 3 |
| Dropout | 0.3 |
| BatchSize | 64 |
| 优化器 | AdamW |

3.3 对比模型

为了验证所提模型的有效性, 本文选取了以下模型作为对比模型, 并通过实验验证及结果分析来评估其性能。在数据集上的比较结果如表 3 所示。

最佳结果用粗体标出。

(1) FPMC^[17]: 是一种融合了马尔可夫链与概率矩阵分解的序列预测模型, 该方法是针对序列化的购物篮数据设计的, 而多式联运的物流场景中也可能存在类似的序列数据。

(2) LightGCN^[18]: 是一种简化的图卷积网络, 通过去除不必要的复杂操作, 专注于 GCN 中最核心的邻域聚合操作, 从而提高了模型的训练效率和推荐性能。

(3) NGCF^[19]: 是一种结合协同过滤技术和神经网络的推荐模型, 通过显式建模用户与项目之间的高阶连通关系来优化消息传递, 从而更好地捕捉用户偏好。

(4) HeCo^[20]: 该模型从网络模式视图和元路径视图对节点进行编码, 同时引入了图掩码机制, 使得这两个视图能够相互补充和监督, 进一步提升了模型性能。

(5) FDSA^[21]: 该模型通过结合深度自注意力网络和对比学习, 能够更有效地捕捉用户的行为序列特征, 并提升推荐的准确性和鲁棒性。

(6) GSNP^[22]: 该模型通过结合多级自注意力机制, 能够更好地捕捉用户的长期和短期兴趣, 从而提高推荐的准确性和个性化程度。

(7) CIGF^[23]: 该模型通过结合压缩交互图卷积网络和多专家分离输入网络, 能够更好地利用多行为数据中的复杂关系, 同时避免多任务学习中的潜在问题。

表 3 对比实验结果

| 方法 | HR@5 | NDCG@5 |
|----------|----------------|----------------|
| FPMC | 0.395 7 | 0.411 8 |
| LightGCN | 0.560 5 | 0.654 9 |
| NGCF | 0.654 4 | 0.643 6 |
| HeCo | 0.764 5 | 0.809 2 |
| FDSA | 0.776 1 | 0.702 2 |
| GSNP | 0.702 7 | 0.626 5 |
| CIGF | 0.758 5 | 0.695 1 |
| COMLRA | 0.923 4 | 0.945 8 |

由表 3 可知, 本文提出的模型在所用数据集上始终优于其他方法。说明本文所提出的方法在处理多式联运物流推荐任务时具有更高的命中率和适用性, 能够更有效地捕捉用户偏好并提供精准的物流服务推荐。

3.4 消融实验

为了验证各个部分对整个模型的贡献及其有效

性, 本文设计了一系列的消融实验来评价模型中不同部分的作用。本文构造了模型的多个变体, 如下所示:

(1) -At: 去掉注意力机制模块。

(2) -CN: 去掉交叉网络模块。

(3) -DN: 去掉深度网络模块。

在数据集上的消融实验结果如表 4 所示。实验结果表明, 去掉模型中任意一个模块, 模型的推荐效果都会出现一定程度的降低, 说明了模型中各模块都是有效的。其中, 在去掉注意力机制模块后, HR@5 指标和 NDCG@5 指标分别降低了 0.36% 和 1.27%, 说明了注意力机制能够使模型更加关注与任务相关的特征。在去掉交叉网络后, HR@5 指标和 NDCG@5 指标分别降低了 4.16% 和 1.16%, 说明交叉网络可以增强模型对特征组合的学习能力, 有效提高模型的命中率。此外, 在去掉深度网络模块后, HR@5 指标和 NDCG@5 指标分别降低了 2.36% 和 1.65%, 说明了深度网络模块可以有效地处理复杂的非线性关系, 从而提高模型的预测性能。

表 4 消融实验结果

| 方法 | HR@5 | NDCG@5 |
|--------|---------|---------|
| -At | 0.919 8 | 0.933 2 |
| -CN | 0.881 8 | 0.934 2 |
| -DN | 0.899 8 | 0.929 3 |
| COMLRA | 0.923 4 | 0.945 8 |

3.5 特征重要性可视化分析

为了深入理解模型决策过程中各特征的贡献, 本研究对 COMLRA 算法中的特征重要性进行了可视化分析。图 2 展示了基于模型预测的各特征重要性分数, 其中特征的重要性分数通过特征在模型决策中的贡献度进行量化。

从图 2 中可以看出, “中转站 1~ 中转站 2 所用时间”和“中转站 2~ 中转站 3 所用时间”是影响模型预测的两个最为关键的特征, 其重要性分数显著高于其他特征。这表明在多式联运物流方案推荐中, 货物在中转过程中的时间消耗是客户关注的重点, 对最终的物流方案选择具有决定性影响。

其次, “承运公司”和“服务商公司名称”特征的重要性也相对较高, 说明客户在选择物流方案时, 也会考虑承运商和服务商的信誉和服务水平。这些信息可能影响货物运输的可靠性和服务质量, 从而对客户的决策产生影响。

“起始地~中转站 1 所用时间”特征的重要性相对较低，这可能是由于起始地到第一个中转站的时间通常较短，或者客户对这一阶段的时间敏感度较低。

总体而言，特征重要性分析揭示了客户在选择多式联运物流方案时关注的关键因素，为进一步优化物流服务和提升客户满意度提供了指导。此外，这些分析结果也为模型的解释性和透明度提供了支持，有助于增强客户对推荐结果的信任。




图 2 基于排序的特征重要性

Fig. 2 Feature importance based on sorting

3.6 参数敏感性分析

K 值、隐藏层维度以及深度网络层数是重要的参数，对于本文的推荐算法的指标值有着重要作用。因此为找出最优参数，本文分别做了 3 组实验。

3.6.1 K 值分析

对于 K 值的选取，本文选取 3, 5, 10 进行了对比实验，实验结果如图 3 所示。




图 3 不同 K 值对指标值的影响

Fig. 3 Influence of different K values on indicator values

由实验结果可知，不同的 K 值对 $NDCG@K$ 指标的值影响较小，但对 $HR@K$ 指标的值影响较大，在 $K=5$ 时，指标值达到最优。因此本文选取 5 作为最终的 K 值。

3.6.2 隐藏层维度分析

对于隐藏层维度的选取，本文选取 32, 64, 128, 256 进行了对比实验，实验结果如图 4 所示。由实验结果可知，随着维度从 32 增加到 64，模型的指标值也随着增加，但进一步增加维度后，指标值出现了降低的情况，由此得出隐藏层维度为 64 时，指标值达到最优。因此本文选取 64 作为最终的隐藏层维度。




图 4 不同维度对指标值的影响

Fig. 4 Impact of different dimensions on indicator values

3.6.3 深度网络层数分析

对于深度网络层数的选取，本文选取 1, 2, 3, 4, 5, 6, 7 进行了对比实验，实验结果如图 5 所示。

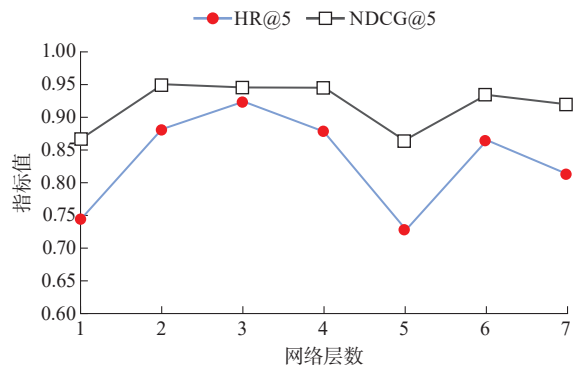


图 5 不同层数对指标值的影响

Fig. 5 Influence of different layers on indicator values

由实验结果可知，随着层数从 1 增加到 3，模型的指标值也随着增加，但进一步增加维度后，指标值出现了降低的情况，虽然层数增加到 6 层的时候指

标值又有所上升,但并未达到最优,由此得出层数为3的时候指标值达到最优。因此本文选取3作为最终的深度网络层数。

3.7 典型错误案例分析

为了深入探讨模型在某些场景下表现不佳或推荐失败的原因,本研究选取了一些具有代表性的错误案例进行详细分析。通过这些案例,揭示了模型在处理复杂特征交互、数据分布偏差以及数据噪声等问题时的局限性。以下详细描述3个典型错误案例,以揭示模型的局限性并提出相应的改进建议。

在高成本预测偏差的案例中,模型对中转次数与运输方式成本的交互关系建模不足。具体而言,尽管中转次数较多,但由于运输方式的高效组合(如海路和铁路的结合),实际成本并未显著增加。然而,模型未能准确捕捉这种复杂的特征交互关系,导致预测成本显著高于实际成本。这一问题表明,模型对中转次数这一特征的权重分配可能过高,而对运输方式的实际成本差异不够敏感。

在低效时间预测的案例中,模型对货物类型与运输方式效率的关系处理不够精细。具体而言,散货的运输时间通常较短,但模型未能准确捕捉这一特征关系。此外,模型对运输方式的效率建模不足,导致预测时间与实际时间之间存在较大误差。这一问题表明,模型对货物类型和运输方式效率的权重分配可能不合理,从而影响了时间预测的准确性。

在不合理的中转站推荐案例中,模型推荐了一条中转站较多的路线,尽管起始地和目的地代号相近且运输时间较短。具体而言,模型未能充分考虑起始地和目的地之间的直接运输可行性,而是过度依赖中转站的数量和分布。这一问题表明,模型在处理起始地和目的地之间的空间关系时存在局限性,未能有效评估直接运输与中转运输之间的成本和时间效益。

这些分析不仅为模型的改进提供了明确方向,如引入更复杂的特征交互机制(如Transformer结构)和优化注意力机制,还为实际应用中针对模型可能表现不佳的场景提供了有价值的参考,从而提高模型的实践指导价值和泛化能力。

4 总结与展望

本研究以连云港港口为背景,针对多式联运物流方案推荐问题,提出基于客户需求的多式联运物流方案推荐算法(COMLRA)。该算法由特征提取、

神经网络、推荐生成3大模块构成,能为连云港港口物流企业提供高效灵活的决策支持,生成最优物流方案,助力企业提质降本、增强竞争力,同时也为智慧物流技术在港口多式联运场景的深度应用提供技术支撑,推动港口物流行业智能化升级。

COMLRA模型设计具备较强通用性:特征工程构建的中转次数、运输方式多样性等组合特征,适用于港口物流、跨境电商、城市配送等多场景;哈希编码处理分类特征,提升效率的同时增强了模型对新类别、未知类别的适应性;嵌入层、注意力机制与交叉网络、深度网络相融合的架构,可处理复杂特征交互与数据分布;加权Huber损失函数结合ListMLE排序损失,能让模型根据场景调整优化目标、平衡各类指标;数据增强技术则提升了模型对数据变化的鲁棒性,适配不同场景的数据噪声。虽研究基于连云港港数据集,但上述设计为模型在其他港口及跨境电商、城市配送等场景的应用奠定了理论与实践基础。

此外,COMLRA算法仍有优化拓展空间:目前模型仅基于结构化数据推荐,未来可引入港口监控视频、货物图像等非结构化数据,通过多模态融合提升推荐精度;还可纳入交通状况、天气、港口拥堵等实时数据作为特征,增强模型对动态环境的适应性,更精准预测运输时间与成本,提供前瞻性决策支持。同时,未来可探索该算法在城市配送、跨境电商物流等更多物流场景的应用,进一步验证其泛化能力与优越性,为各领域物流企业提供个性化解决方案。

参考文献:

- [1] 中华人民共和国交通运输部. 2025中国多式联运合作大会在渝召开[EB/OL]. (2025-04-28). https://www.mot.gov.cn/jiaotongyaowen/202504/t20250428_4167865.html.
- [2] 连云港市人民政府. 中国(江苏)自由贸易试验区连云港片区新闻发布会[EB/OL]. (2020-04-03). <https://www.lyg.gov.cn/zglygzfmhwhz/xwfbh/content/6274473c-8590-4906-8c6d-31d58ce8382a.html>.
- [3] 徐尚英,刘晶,陈冬林,等. 基于企业用户需求的科技服务资源综合推荐算法构建[J]. 科技管理研究, 2022, 42(16): 182-189.
- [4] 冯勇,刘洋,王嵘冰,等. 面向用户需求的生成对抗网络多样性推荐方法[J]. 小型微型计算机系统, 2023, 44(6): 1192-1197.

- [5] 张飞, 蒋思, 岳立柱. 综合产品属性和客户需求的多准则推荐方法[J]. 辽宁工程技术大学学报(自然科学版), 2022, 41(1): 68-72.
- [6] LI Yinggang, TONG Xiangrong, LV Zhongming. Multi-dimensional requirements for reinforcement recommendation reasoning[J]. Applied Intelligence, 2025, 55(6): 545-545.
- [7] LI Xiuxia. Building a machine learning algorithm-based model to suggest tourist attractions in response to travelers' "slow life" requirements[J]. Journal of Cases on Information Technology, 2025, 27(1): 1-16.
- [8] 雷峥嵘, 鄢威, 张绪美, 等. 考虑多用户需求的物流服务知识图谱构建与推荐方法[J]. 物流工程与管理, 2024, 46(12): 7-12.
- [9] LI Xiang, XIE Qian, ZHU Quanyin, et al. Knowledge graph-based recommendation method for cold chain logistics[J]. Expert Systems with Applications, 2023, 227: 120230.
- [10] DADOUCHI C, AGARD B. Recommender systems as an agility enabler in supply chain management[J]. Journal of Intelligent Manufacturing, 2020, 32 (pre-publish): 1-20.
- [11] LIU Xiaojun, SUN Ming, LIU Yuzhuo. Research on logistics service recommendation model and application under mobile cloud environment[J]. Optik, 2023, 273: 170446.
- [12] 李蒙, 李文敬. 基于深度学习的物流服务交易群智推荐算法的研究[J]. 现代计算机, 2021, 27(34): 1-11.
- [13] 张碧玉, 刘毅, 孙哲, 等. 考虑协同配送的两阶段车货匹配推荐系统[J]. 物流科技, 2023, 46(20): 95-104.
- [14] 万玉龙, 顾峰, 柏小颖, 等. 冷链物流智能配载协同过滤推荐算法的设计研究[J]. 中国储运, 2022(6): 93-94.
- [15] HUBER P J. Robust estimation of a location parameter[J]. Annals of Mathematical Statistics, 1964, 35(1): 73-101.
- [16] XIA Fen, LIU Tieyan, WANG Jue, et al. Listwise approach to learning to rank: theory and algorithm[C]//Proceedings of the 25th International Conference on Machine Learning, 2008: 1192-1199.
- [17] RENDLE S, FREUDENTHALER C, SCHMIDT-THIEME L. Factorizing personalized markov chains for next-basket recommendation[C]. The Institute of Scientific and Industrial Research Osaka University, 2010: 811-820.
- [18] HE Xiangnan, DENG Kuan, WANG Xiang, et al. LightGCN: simplifying and powering graph convolution network for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2020: 639-648.
- [19] WANG Xiang, HE Xiangnan, WANG Meng, et al. Neural graph collaborative filtering[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2019: 165-174.
- [20] WANG Xiao, LIU Nian, HAN Hui, et al. Self-supervised heterogeneous graph neural network with co-contrastive learning[C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, 2021: 1726-1736.
- [21] HAO Yongjing, ZHANG Tingting, ZHAO Pengpeng, et al. Feature-level deeper self-attention network with contrastive learning for sequential recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(10): 10112-10124.
- [22] BAI Xinzhu, HUANG Yanping, PENG Hong, et al. Sequence recommendation using multi-level self-attention network with gated spiking neural P systems[J]. Information Sciences, 2024, 656: 119916.
- [23] GUO Wei, MENG Chang, YUAN Enming, et al. Compressed interaction graph based framework for multi-behavior recommendation[C]//Proceedings of the ACM Web Conference, 2023: 960-970.

(责任编辑: 李琴)