

牟大恩, 倪琳, 宋娜. 自监督超图在用户个性化推荐场景的应用研究 [J]. 智能计算机与应用, 2025, 15(4): 158-164. DOI: 10.20169/j.issn.2095-2163.24121801

自监督超图在用户个性化推荐场景的应用研究

牟大恩, 倪琳, 宋娜

(上海证券有限责任公司 金融科技总部, 上海 200002)

摘要: 本文运用自监督超图的深度学习方法 and DBSCAN 聚类算法, 对用户个性化推荐场景中的点击率预估进行了深入研究。基于用户与物品的交互数据, 研究构建了用户与交互物品的超图, 并利用超图神经网络对用户多元异构交互行为进行建模, 从而获取用户的超图嵌入表示, 并基于用户的超图嵌入表示开展客群聚类分析。最后, 本文融合用户基础属性和多模态向量特征, 在深度学习的双塔 DSSM 模型基础上, 构建个性化推荐点击率 (Click-Through Rate, CTR) 预估模型。实验证明, 本文提出的模型框架具有较好的预测能力, 与基准模型相比, AUC 值提升了 7.40%。本研究为提升用户推荐效果提供了理论支撑和实践指导。

关键词: 个性化推荐; 自监督超图; 超图神经网络; 聚类分析; 点击率预估模型

中图分类号: TP391.3

文献标志码: A

文章编号: 2095-2163(2025)04-0158-07

Research on the application of self-supervised hypergraph in personalized recommendation scenarios

MOU Da'en, NI Lin, SONG Na

(FinTech Department, Shanghai Securities Co., Ltd., Shanghai 200002, China)

Abstract: This paper conducts an in-depth study on Click-Through Rate (CTR) prediction in user personalized recommendation scenarios, leveraging self-supervised hypergraph deep learning methods and the DBSCAN clustering algorithm. Based on user-item interaction data, a hypergraph is constructed to capture relationships between users and their interactive items. A hypergraph neural network models users' multiple heterogeneous interaction behaviors, generating hypergraph embeddings. These embeddings enable customer clustering analysis using the DBSCAN algorithm. By integrating user base attributes and multi-modal vector features, a personalized recommendation CTR prediction model is built using the two-tower DSSM framework in deep learning. Experiments show that the proposed model framework exhibits strong predictive power, achieving a 7.40% improvement in AUC over the benchmark. This research offers both theoretical and practical insights for enhancing user recommendation performance.

Key words: personalized recommendation; self-supervised hypergraph; hypergraph neural network; clustering analysis; CTR prediction model

0 引言

随着数字化技术的飞速发展, 个性化推荐系统已成为各类在线服务平台提升用户体验、增强用户粘性及促进业务增长的关键技术之一。尤其是在证券、电商、社交媒体等领域, 精准的用户个性化推荐能够显著提升用户满意度和转化率, 为企业带来巨大的商业价值。然而, 面对海量、多维且稀疏的用户数据, 如何有效挖掘用户潜在兴趣, 实现精准推荐,

仍是当前研究的热点和难点。

传统的推荐系统主要依赖于协同过滤、内容推荐等算法, 但这些方法在处理用户复杂多变的交互行为时往往难以充分挖掘和利用用户数据中的丰富信息。近年来, 深度学习技术的兴起为推荐系统提供了新的解决思路。通过深度学习模型, 挖掘用户数据的潜在特征, 提升推荐的准确性和多样性。

在深度学习的诸多方法中, 图神经网络 (Graph Neural Network, GNN) [1-2] 因其能够处理图结构数

作者简介: 牟大恩 (1985—), 男, 硕士, 主要研究方向: 机器学习, 深度学习, 数据挖掘, 自然语言处理, 大语言模型及推荐算法。Email: moudaen@126.com; 倪琳 (1990—), 女, 硕士, 主要研究方向: 统计学, 机器学习, 深度学习, 数据挖掘, 大语言模型及推荐算法; 宋娜 (1994—), 女, 硕士, 主要研究方向: 机器学习, 深度学习, 自然语言处理, 数据挖掘, 大语言模型及推荐算法。

收稿日期: 2024-12-18

哈尔滨工业大学主办 ◆ 专题设计与应用

据,有效捕捉节点间的复杂关系,而在推荐系统中展现出巨大的潜力^[3-5]。然而,传统的图神经网络主要关注于二元关系(如用户-物品对),忽略了用户与多个物品之间可能存在的多元异构交互关系^[6-8]。为了更全面地捕捉用户行为特征,超图(Hypergraph)作为一种能够表示更复杂关系的图结构,逐渐被引入到推荐系统的研究中。

自监督学习是近年来机器学习领域的一个热门方向,它通过利用未标注数据中的内在结构进行训练,能够提升模型的泛化能力和鲁棒性。将自监督学习与超图神经网络相结合,可以进一步挖掘用户数据的潜在特征,提高推荐系统的性能。

综上所述,本文旨在探索自监督超图在用户个性化推荐场景中的应用,通过构建用户与交互物品的超图结构,利用超图神经网络对用户多元异构交互行为进行建模,并融合用户基础属性和多模态向量特征,构建个性化推荐的点击率预估模型。

1 相关技术

1.1 超图神经网络

超图是一种广义上的图结构,在复杂的应用场景中具有很好的表达能力,通过超边扩展实现对多模态、异构数据表征的抽取,更准确地捕捉节点之间的关系和整体结构^[9]。超图神经网络(Hypergraph Neural Networks, HGNN)是一种用于数据表示学习的框架,以编码高阶数据的相关性^[10-11]。HGNN利

用超图拉普拉斯进行表示学习计算,构建超边卷积运算,汇聚周边节点信息,以此更新目标节点的表示,进而抽取高阶关系嵌入的显式表达^[12]。

1.2 点击率预估模型

CTR 预估模型旨在预测用户在特定场景下点击某个展示项(如广告、推荐内容等)的概率。通过构建精准的 CTR 预估模型,可以优化推荐系统的性能,提高用户体验和收益。CTR 预估模型的演进经历了多个阶段,从早期的逻辑回归(Logistic Regression, LR)结合大量人工特征工程处理,到后来的因子分解机^[13](Factorization Machines, FM)、域感知因子分解机^[14](Field-aware Factorization Machines, FFM)等模型,再到深度学习时代的神经网络模型,如前馈神经网络(Feedforward Neural Network, FNN)^[15]、基于乘积的神经网络(Product-based Neural Networks, PNN)^[16]、DeepFM^[17]、DCN^[18]等。这些模型在特征交互、数据处理、模型复杂度等方面不断优化,以提高 CTR 预估的准确性和效率。

2 研究方法

2.1 整体框架

为解决传统基于图神经网络的深度学习推荐算法较难建模用户和物品的多元关系,并易受噪音数据干扰的问题,研究引入自监督超图技术和 DBSCAN 聚类算法构建了用户个性化推荐点击率预估的算法模型框架,整体框架如图 1 所示。

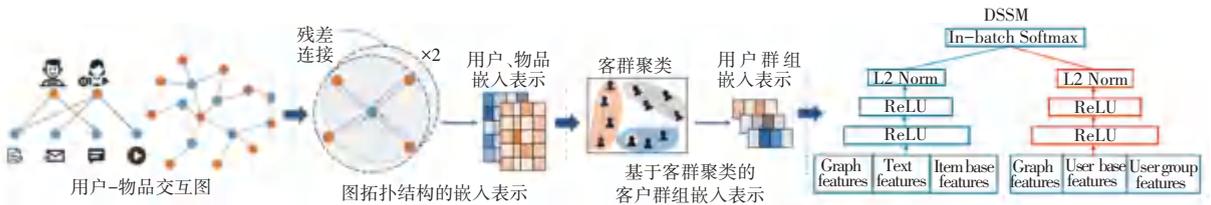


图1 面向用户个性化推荐点击率预估的总体结构框图

Fig. 1 Overall structural block diagram for Click-Through Rate prediction in user personalized recommendation

首先,基于用户与物品的历史交互行为数据,构建用户与物品的二分图。然后,基于二分图,采用自监督超图技术挖掘用户与物品的高阶关联性,获取超图拓扑结构下的嵌入表示。基于用户超图嵌入表示,开展聚类分群,以获取各用户群组的嵌入表示。再将用户侧经特征工程处理后的基础特征、图嵌入表示及用户群组的嵌入表示拼接为用户侧的输入特征向量,将物品侧经特征工程处理后的基础特征、文本特征及图嵌入表示拼接为物品侧的输入特征向量,输入到深度语义模型(Deep Structured Semantic Model, DSSM)双塔模型结构中进行预测,最终得到

用户个性化推荐点击概率。

2.2 嵌入表示

基于自监督超图 Transformer 框架 SHT^[19],研究将局部协作关系编码器的建模与全局超图学习相统一,促进基于图的神经网络模型从带有噪音和稀疏的用户交互数据中学习较完善的用户和物品的图结构嵌入表示。具体算法步骤如下。

2.2.1 局部图结构学习

为刻画用户和物品的交互模式,将第 i 个用户 u_i 和第 j 个物品 v_j 的嵌入表示映射到 d 维空间,分别记为 $e_i, e_j \in \mathbb{R}^d$ 。聚合所有用户和物品的嵌入表示,

分别得到嵌入矩阵 $\mathbf{E}^{(u)} \in \mathbb{R}^{I \times d}$ 和 $\mathbf{E}^{(i)} \in \mathbb{R}^{J \times d}$ 。基于超图 G , 该局部图结构学习采用 2 层轻量级图卷积网络(GCN), 因此, 用户拓扑感知嵌入表示 $\bar{\mathbf{E}}^{(u)}$ 如下式所示:

$$\bar{\mathbf{E}}^{(u)} = \text{GCN}^2(\mathbf{E}^{(v)}, G) \quad (1)$$

2.2.2 全局图结构关系学习

首先, 计算节点到超边的信息传播。以用户节点为例, $\tilde{z}_k \in \mathbb{R}^d$ 为第 k 条超边的嵌入表示, 通过拼接 H 个头的超边嵌入表示 $\tilde{z}_{k,h} \in \mathbb{R}^{d/H}$ 得到。从用户节点到超边的传播过程如下所示:

$$\tilde{z}_k = \parallel_{h=1}^H \tilde{z}_{k,h} \in \mathbb{R}^d; \tilde{z}_{k,h} = \sum_{i=1}^I v_{i,h} k_{i,h}^T q_{k,h} \quad (2)$$

其中, $q_{k,h}, k_{i,h}, v_{i,h} \in \mathbb{R}^{d/H}$ 分别表示注意力机制中用户 u_i 和超边 k 的查询、键和数值。类似地, 得到物品对应的节点到超边的信息传播。此外, 在超图神经网络结构中采用了残差连接, 以促进梯度传播。

其次, 计算超边到节点的信息传播。基于最终的超边嵌入表示 \hat{Z} , 通过反向过程将信息从超边传播到节点, 得到经传播后的用户嵌入表示 \tilde{e}'_i , 推得的公式为:

$$\tilde{e}'_i = \parallel_{h=1}^H \tilde{e}'_{ih} \in \mathbb{R}^d; \tilde{e}'_{ih} = \sum_{k=1}^I v'_{k,h} k'_{i,h}^T q'_{k,h} \quad (3)$$

其中, $q'_{k,h}, k'_{i,h}, v'_{i,h} \in \mathbb{R}^{d/H}$ 表示注意力机制中用户 u_i 和超边 k 的查询、键和数值。

接着, 计算交替超图的信息传播。通过递归地应用超图编码 $\text{HyperTrans}(\cdot)$ 来提取全局协同关系, 以捕获远距离的用户(物品)的依赖关系, 得到节点嵌入表示 \hat{E} , 公式定义为:

$$\hat{E}_l = \text{HyperTrans}(\hat{E}_{l-1}); \hat{E} = \sum_{l=1}^L \hat{E}_l \quad (4)$$

2.2.3 局部图结构关系自增强学习

首先, 构建元网络的超边可靠性标签。通过连接多头键向量并应用感知机来消除用户-物品超边关系学习和用户-物品关系学习之间的差距, 得到更新的用户(物品)的嵌入表示计算方式具体如下:

$$\Gamma_i = \phi^{(u)}(\parallel_{h=1}^H k_{i,h}); \Gamma_j = \phi^{(v)}(\parallel_{h=1}^H k_{j,h}) \quad (5)$$

其中, ϕ 为感知机。

因此, 通过 2 层神经网络后, 超边 (u_i, v_j) 的可靠性标签 $s_{i,j}$ 的定义公式如下:

$$s_{i,j} = \text{Sigmoid}(\mathbf{d}^T \cdot \sigma(\mathbf{T} \cdot [\Gamma_i; \Gamma_j]) + \Gamma_i + \Gamma_j + c) \quad (6)$$

其中, $\mathbf{T} \in \mathbb{R}^{d \times 2d}$ 表示参数矩阵; $c \in \mathbb{R}^d$ 表示参

数向量; $[\cdot; \cdot]$ 表示向量拼接。

然后, 计算超边的可靠性排序。为增强拓扑结构的超边嵌入表达, SHT 采用一个附加的目标函数来更好地预测超边的可靠性得分。自监督学习损失函数为:

$$L_{sa} = \sum_{r=1}^R \max(0, 1 - (\hat{s}_{u_r, 1^{v_r, 1}} - \hat{s}_{u_r, 2^{v_r, 2}})(s_{u_r, 1^{v_r, 1}} - s_{u_r, 2^{v_r, 2}})), \quad (7)$$

$$\hat{s}_{u_r, 1^{v_r, 1}} = \mathbf{e}_{u_r, 1}^T \mathbf{e}_{u_r, 1}; \hat{s}_{u_r, 2^{v_r, 2}} = \mathbf{e}_{u_r, 2}^T \mathbf{e}_{u_r, 2}$$

其中, $\hat{s}_{u_r, 1^{v_r, 1}}$ 和 $\hat{s}_{u_r, 2^{v_r, 2}}$ 表示预测的可靠性得分; $s_{u_r, 1^{v_r, 1}}$ 和 $s_{u_r, 2^{v_r, 2}}$ 表示自监督超图得到的可靠性标签; $u_r, 1$ 和 $v_r, 1, u_r, 2$ 和 $v_r, 2$ 分别表示边 $e_{r, 1}$ 、边 $e_{r, 2}$ 对应的用户和物品的节点。

2.3 用户聚类分群

基于上述超图提取的用户嵌入表示, 研究中开展用户聚类分群。在用户嵌入表示融入周围相似邻居的信息能够在一定程度上提升用户嵌入表示的稳健性和准确性。用户聚类分群的算法流程如图 2 所示, 下面将详细介绍用户聚类分群的具体步骤。

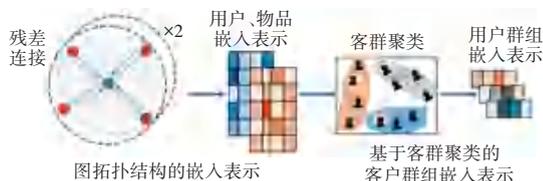


图 2 用户聚类分群算法的流程示意图

Fig. 2 Algorithm flowchart for user clustering

(1) 生成降维的用户超图嵌入表示。基于用户和物品的交互行为构建超图, 从而获取用户的超图嵌入表示 $e_{u_{sh}}$ 后, 采用非线性降维算法 t-SNE 记为 f_{tsne} 对用户的超图嵌入表示进行降维, 映射至低维空间, 得到降维后的用户超图嵌入表示 $e_{u_{tsne}}$, 具体公式为:

$$e_{u_{tsne}} = f_{tsne}(e_{u_{sh}}) \quad (8)$$

(2) 基于 DBSCAN 的用户聚类分群。基于密度的噪声应用空间聚类算法 DBSCAN^[20] 对步骤 1 的用户特征 $e_{u_{tsne}}$ 开展聚类分析。基于 DBSCAN 算法(记为 f_{dbscan}), 给定超参数点密度阈值 $Minpts$ 和领域半径 ε , 得到 M 个客群簇, 其中, 第 m 个用户群组记为 C_m , 其定义为:

$$C_m = f_{dbscan}(e_{u_{tsne}} | MinPts, \varepsilon), m = 1, \dots, M \quad (9)$$

(3) 生成用户分群的嵌入表示。根据客群分类 C_m 及基于 t-SNE 降维后的超图用户嵌入表示 $e_{u_{tsne}}$, 得到基于超图的每个客群的聚类簇中心点的嵌入表示 E_m , 可以表示为:

$$E_m = average(e_{u_{tsne,1}}, \dots, e_{u_{tsne,i}}, \dots, e_{u_{tsne,m_N}}) \quad (10)$$

其中, $u_{tsne,i} \in C_m$, 用户群组 C_m 包含 m_N 个用户。

2.4 用户个性化推荐建模

用户个性化推荐点击率预估模型结构主要包含

用户的表征模块和推荐物品的表征模块。通过多层感知机 (Multilayer Perceptron, MLP) 深度提取用户和物品的嵌入表示,再基于用户和物品嵌入表示的相似度函数,最终得到点击率预估,如图 3 所示。

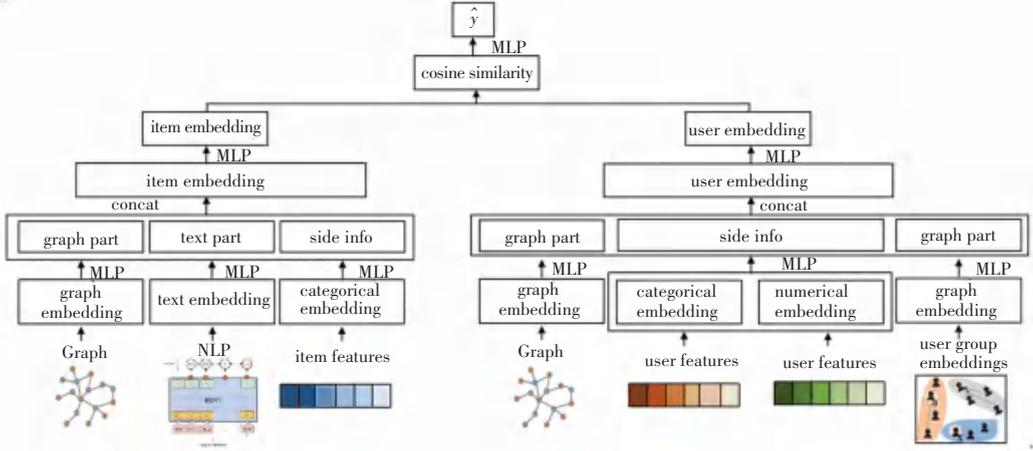


图 3 基于自监督超图的用户个性化推荐点击率预估的示意图

Fig. 3 Schematic diagram of CTR prediction for user personalized recommendation based on self-supervised hypergraph

令 $\{(U_k, I_k)\}$ 为训练数据分布 D 的其中一个用户和物品的数据对, $\{(e_{u_k}, e_{i_k})\}$ 为双塔模型框架下对应用户和物品双塔的最后层神经网络的嵌入表示, N 为正负样本数据对的数量。为防止模型过拟合,对模型参数进行 $L2$ 正则化约束。整体模型学习的损失函数的计算公式如下:

$$L = \sum_{k=1}^N Similarity(e_{u_k}, e_{i_k}) + \lambda L_{reg}(\theta) \quad (11)$$

其中, $Similarity(e_{u_r}, e_{i_r})$ 表示监督学习的推荐任务的损失函数,此处采用 cosine 函数; λ 表示参数正则化的惩罚系数; θ 表示模型参数; $L_{reg}(\theta)$ 表示模型参数正则化的损失函数。

3 实验结果与分析

3.1 数据集

本文在公开数据集 Yelp 数据集上开展用户个性化推荐点击率模型效果的实验验证。该数据集包含用户在 Yelp 网站中给不同商户的打分数据、评论数据,以及商户的类别、位置、评论数量、平均得分等数据。

研究采用 K 核过滤器处理该数据集,并且将数据集按照 3 : 1 : 1 的比例划分为训练集、验证集和测试集。样本数据集总计共包含 27 529 名用户、5 923 个物品以及 563 858 条用户-物品交互数据。

3.2 实验设置

在模型训练过程中,统一采用了 Adam 优化器,将 batch_size 设置为 128,学习率初始值设为 0.001,并采用了学习率衰减策略以优化训练过程。实验中,设定

的用户和物品嵌入表示维度大小为 8,前向传播的深度神经网络(DNN)共为 3 层,各层的维度分别为 512、64 和 8。此外,为了防止模型过拟合并在测试阶段提高泛化能力,还在训练过程中引入了 $L2$ 正则化技术,并应用了 dropout 策略,其中 dropout 比率设定为 0.3。

为了综合对比推荐算法的模型效果,采用基于推荐排序的评价指标 AUC (Area Under Curve) 和 $F1$ 分数 ($F1 - score$) 来评估模型的准确性。一般而言,较高的 AUC 和 $F1$ 分数均表示较优的推荐模型效果。

3.3 性能比较

为验证本文应用的自监督超图技术在提高个性化推荐算法模型效果的有效性,将本文构建的模型与基线模型的性能进行对比分析。

基线模型为仅基于用户及其交互物品的基础属性特征构建的个性化推荐点击率预估 DSSM 模型,而不使用任何基于图建模技术学到的嵌入表示和物品的文本信息的嵌入表示。

针对上述 2 种点击率预估模型,都采用了 5 个不同的随机种子进行参数初始化,并在测试集上基于训练结果进行了模型预测能力的比较,模型效果对比结果见表 1。

表 1 个性化推荐点击率预估模型效果对比

Table 1 Performance comparison of different personalized recommendation CTR prediction models

序号	点击率预估模型	AUC 值	F1 分数
1	基线模型	0.685 9	0.593
2	自监督超图模型	0.736 7	0.758

通过对各模型 AUC 指标的分析,发现基线用户个性化推荐点击率预估模型利用深度神经网络分别对用户和物品进行建模并抽取高维特征,展现出一定的预测能力,表现为 AUC 值为 0.685 9, $F1$ 分数为 0.593。当引入自监督超图及文本嵌入表示时,个性化推荐点击率预估模型预估效果有明显提升, AUC 值达到 0.736 7, $F1$ 分数为 0.758, AUC 值相对基线模型增幅达到 7.40%,验证了自监督超图嵌入表示及文本嵌入表示的引入对提升用户个性化点击率预估准确性方面有显著效果。

3.4 消融实验

本实验探讨自监督超图嵌入表示及预训练模型的文本嵌入表示对个性化推荐点击率预估模型的贡献。研究中构建以下 3 个模型进行消融实验。

(1) 基线用户个性化推荐点击率预估模型(本文简称为基线模型):仅基于用户及其交互物品的基础属性等特征,构建嵌入表示。

(2) 结合超图的个性化推荐点击率预估模型(本文简称为超图模型):在基线模型的基础上,通过超图卷积图神经网络学习得到用户与物品嵌入表示,即超图嵌入表示。

(3) 超图多模态用户个性化推荐点击率预估模型(本文简称为超图多模态模型):在基线模型的基础上,同时引入通过超图学习得到的嵌入表示和基于预训练模型的文本嵌入表示。

文中对以上模型分别进行训练,并在测试集上比较模型推理的准确性,结果见表 2。

表 2 个性化推荐点击率预估模型的消融实验结果

Table 2 Results of ablation experiments for personalized recommendation CTR prediction models

序号	点击率预估模型	AUC 值	$F1$ 分数
1	基线模型	0.685 9	0.593
2	自监督超图模型	0.724 3	0.720
3	超图多模态模型	0.736 7	0.758

经对比分析,在基线模型上,引入了超图建模的嵌入表示后,超图模型的 AUC 值取得了额外的 5.60% 的提升,达到 0.724 3, $F1$ 分数也升至 0.720,展现了超图嵌入在用户特征表征方面的优势,有助于提升模型的预估效果。

当进一步引入文本嵌入表示时,自监督超图模型的准确率再进一步提升, AUC 值达到 0.736 7, $F1$ 分数为 0.758。相较于超图模型,自监督超图模型的 AUC 值进一步又增加了 1.71%,验证了文本型嵌入表示的加入对个性化推荐点击率预估模型效果有

一定的提升。

3.5 模型可视化

本实验旨在探究自监督超图建模得到的样本特征分布与普通图建模得到的样本特征分布变化情况,以进一步证明文中应用的模型结构的合理性。

将本文应用的自监督超图模型与基线模型 LightGCN^[21] 进行对比实验。采用 t-SNE 算法将 Yelp 数据集中的样本嵌入表示投影到二维空间,并进行可视化分析,不同颜色的点代表了不同模型下的样本嵌入表示,蓝色代表 SHT 模型得到的样本嵌入表示,绿色代表 LightGCN 模型得到的样本嵌入表示。

LightGCN 和 SHT 提取用户特征的可视化结果如图 4 所示。在图 4 中,横纵轴是通过 t-SNE 算法将用户特征投影至二维空间生成的坐标轴,二者均为无量纲。同理,LightGCN 和 SHT 提取物品特征的可视化结果如图 5 所示。在图 5 中,横纵轴对应物品特征的 t-SNE 二维投影坐标,亦无量纲属性。从图 4、图 5 中可以看到,经过基准模型 LightGCN 的信息提取后,各样本的特征分布相对独立,相关性较小。相较而言,经过自监督超图模型的提取,各样本的特征分布更向中心聚拢,呈现出更强的相关性。这表明了自监督超图技术通过超边的广泛连接性对样本间的潜在关联信息进行了更有效地传递,因而,经由自监督超图结构提取的样本特征分布展现出更强的相关性。

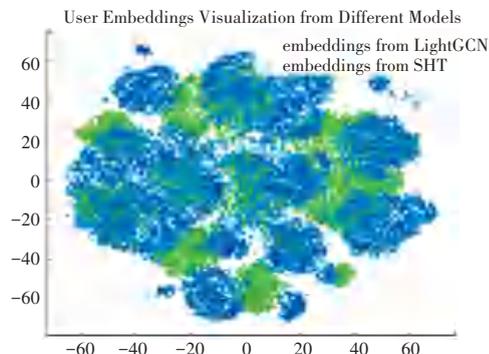


图 4 LightGCN 和 SHT 提取用户特征的可视化

Fig. 4 Visualization of user feature extraction by LightGCN and SHT

3.6 超参实验

本节开展超参实验以探究不同的超参组合对用户聚类分群模型的影响,为后续对用户嵌入表示融入周围相似邻居的信息,以提升用户嵌入表示的稳健性和准确性。

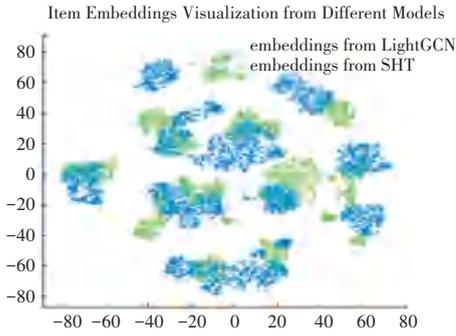


图 5 LightGCN 和 SHT 提取物品特征的可视化

Fig. 5 Visualization of item feature extraction by LightGCN and SHT

在 DBSCAN 算法中,针对领域半径 (eps) 和核心对象在领域半径内的最少点数 ($MinPts$) 进行超参数调优,以确定较优的超参组合。采用 2 个聚类评估的主要指标来衡量用户聚类分群效果,分别为异常点的比例 ($outlier_pct$) 和用户聚类的群组数量 ($n_cluster$)。超参实验结果如图 6 所示。在

图 6 中,横轴为核心对象在领域半径内的最少点数,单位为个;纵轴反映用户聚类结果中异常值的占比,无量纲属性。较为理想情况下,异常点的比例应尽可能少,聚类群组的数量应尽可能均衡。由图 6 分析发现,2 组超参组合的效果都相对较好,即超参组合分别为: ($eps = 0.05, MinPts = 400$) 和 ($eps = 0.04, MinPts = 400$), 为了更深入地对比这 2 组超参数对应的聚类效果,进一步采用了 t-SNE 数据可视化方法,结果如图 7 所示。基于给定的超参数组合 ($eps, MinPts$), 图 7 中的横轴和纵轴分别对应 t-SNE 算法生成的用户特征二维投影坐标,二者均为无量纲。图 7(a) 展示了使用超参数组合 $eps = 0.04$ 和 $MinPts = 400$ 得到的用户聚类分群结果, 而图 7 (b) 则展示了使用超参数组合 $eps = 0.05$ 和 $MinPts = 400$ 得到的用户聚类分群结果。通过对比发现,图 7 (b) 中的异常点比例相对较低。因此,基于 DBSCAN 算法,文中选择超参数组合 $eps = 0.05$ 和 $MinPts = 400$ 来进行用户聚类分群。

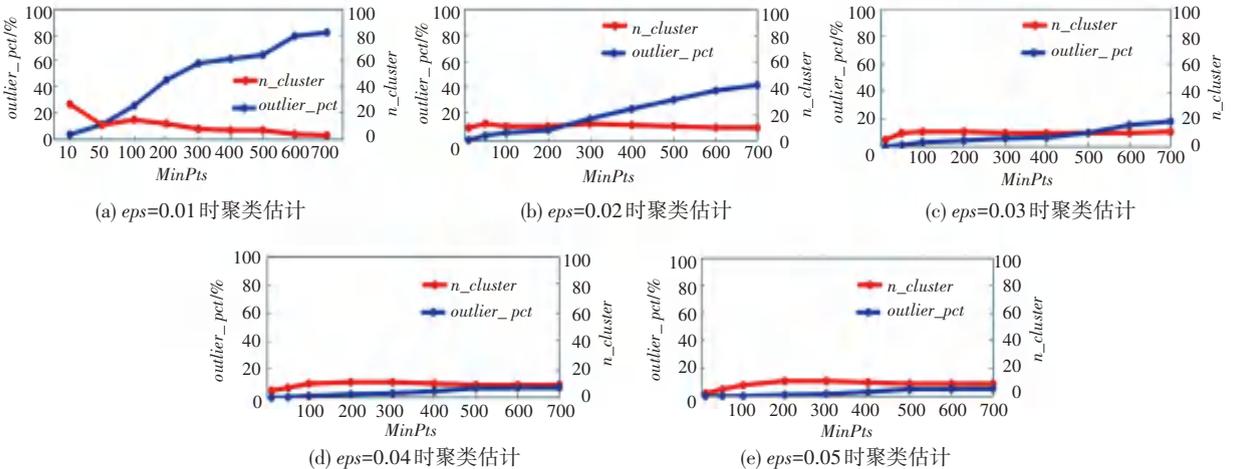


图 6 DBSCAN 用户聚类分群的超参调优结果

Fig. 6 Hyperparameter tuning results for user clustering using DBSCAN

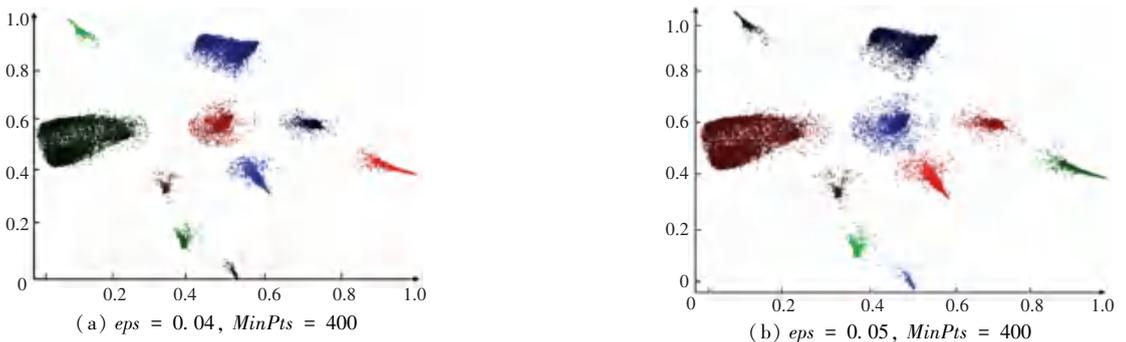


图 7 2 组不同超参配置下, DBSCAN 用户聚类分群结果对比图

Fig. 7 Comparison of DBSCAN model results for user clustering with two different groups of hyperparameters

基于 DBSCAN 算法,研究中采用选定的超参数组合 $eps = 0.05$ 和 $MinPts = 400$ 来进行客群聚类分

群,汇总得到对应客群分布情况,见表 3。此外,为了更直观地表示每个用户群组的特征,还计算了每

个群组的中心点,以此作为客群的嵌入表示。

表3 用户聚类分群结果统计表

Table 3 Statistics of user clustering results

客群类别	客群人数/个	数占比/%
cluster_1	7 922	9.75
cluster_2	4 457	28.78
cluster_3	2 685	1.75
cluster_4	882	7.06
cluster_5	1 748	9.23
cluster_6	2 242	6.35
cluster_7	1 784	6.48
cluster_8	2 541	8.14
cluster_9	1 944	16.19
cluster_10	482	3.20

4 结束语

本文深入探讨了用户个性化推荐点击率预估问题。基于用户和物品的交互信息,本文应用自监督超图技术深度挖掘用户和物品交互数据中的高阶潜在关联性,从而能够更精确地刻画用户偏好,进而提升了推荐算法的准确性。同时,研究了基于超图嵌入表示的用户分群算法,采用 DBSCAN 聚类算法对用户进行了更细致的分析,更准确地理解用户之间的相似性,并对噪声数据展现出较好的鲁棒性,进一步增强了推荐算法的性能。

在此基础上,进一步融合了用户账户信息、历史交易记录、评分记录等数据,并在预训练大语言模型中提取文本型信息,将多模态嵌入表示引入到用户个性化推荐模型中,在公开数据集上取得了更好的点击率预测效果。

未来,将从群体归因和个体归因两个层面,深入探究影响用户点击行为的关键因素,进一步更好地理解用户转化的过程和原因。

参考文献

[1] WANG Xiao, JI Houye, SHI Chuan, et al. Heterogeneous graph attention network [C]//Proceedings of the World Wide Web Conference. New York:ACM,2019:2022-2032.

[2] WU F, ZHANG Tianyi, SOUZA A, et al. Simplifying graph convolutional networks [C]//Proceedings of the International Conference on Machine Learning. New York:PMLR,2019:6861-6871.

[3] LI Xiao, SUN Li, LING Mengjie, et al. A survey of graph neural network based recommendation in social networks [J]. Neurocomputing,2023,549:126441.

[4] WEI Wei, REN Xubin, TANG Jiabin, et al. Llmrec: Large language models with graph augmentation for recommendation [C]//Proceedings of the 17th ACM International Conference on Web Search and Data Mining. New York:ACM,2024: 806-815.

[5] GAO C, WANG X, HE X, et al. Graph neural networks for recommender system [C]//Proceedings of the 15th ACM International Conference on Web Search and Data Mining. New York:ACM,2022:1623-1625.

[6] YU Junliang, YIN Hongzhi, XIA Xin, et al. Are graph augmentations necessary? simple graph contrastive learning for

recommendation[C]//Proceedings of the 45th international ACM SIGIR Conference on Research and Development in Information Retrieval. New York:ACM,2022:1294-1303.

- [7] CHEN Mengyu, HUANG Chao, XIA Lianghao, et al. Heterogeneous graph contrastive learning for recommendation [C]//Proceedings of the 16th ACM International Conference on Web Search and Data Mining. New York:ACM,2023:544-552.
- [8] JIANG Yangqin, HUANG Chao, HUANG Lianghao. Adaptive graph contrastive learning for recommendation [C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York:ACM, 2023: 4252-4261.
- [9] 牛雪琼. 基于图/超图神经网络的节点分类研究 [D]. 桂林:桂林电子科技大学,2021.
- [10] 陆佳炜,李端倪,王策策,等. 基于超图卷积神经网络的多行为感知服务推荐方法 [J]. 浙江大学学报(工学版), 2023, 57 (10):1977-1986.
- [11] 尤恺翔. 基于超图和多特征融合的视频推荐方法研究 [D]. 南京:南京邮电大学,2021.
- [12] WANG Jizhe, HUANG Pipei, ZHAO Huan, et al. Billion-scale commodity embedding for e-commerce recommendation in alibaba [C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York:ACM,2018:839-848.
- [13] RENDLE S. Factorization machines [C]//Proceedings of the 2010 IEEE International Conference on Data Mining. Piscataway, NJ:IEEE,2010:995-1000.
- [14] JUAN Y, ZHUANG Yong, CHIN W S, et al. Field-aware factorization machines for CTR prediction [C]//Proceedings of the 10th ACM Conference on Recommender Systems. New York:ACM,2016:43-50.
- [15] ZHANG Weinan, DU Tianming, WANG Jun. Deep learning over multi-field categorical data: A case study on user response prediction [C]//Proceedings of the 38th European Conference on IR Research: Advances in Information Retrieval. Cham:Springer,2016:45-57.
- [16] QU Yanru, CAI Han, REN Kan, et al. Product-based neural networks for user response prediction [C]//Proceedings of the 16th International Conference on Data Mining (ICDM). Piscataway, NJ:IEEE,2016:1149-1154.
- [17] GUO Huifeng, TANG Ruiming, YE Yunming, et al. DeepFM: A factorization-machine based neural network for CTR prediction [C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence. New York:ACM,2017:1725-1731.
- [18] WANG Ruoxi, FU Bin, FU Gang, et al. Deep & cross network for ad click predictions [C]//Proceedings of the ADKDD'17. New York:ACM,2017:1-7.
- [19] XIA Lianghao, HUANG Chao, ZHANG C. Self-supervised hypergraph transformer for recommender systems [C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York:ACM,2022: 2100-2109.
- [20] ESTER M, KRIEGEL H P, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise [C]//Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining. Menlo Park:AAAI,1996:291-316.
- [21] 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. New York:ACM,2020:639-648.