

谢程远, 张恒, 龚文正, 等. 基于对比学习的记忆图协同过滤推荐方法[J]. 智能计算机与应用, 2025, 15(10): 195–200.
DOI:10.20169/j.issn.2095-2163.251030

基于对比学习的记忆图协同过滤推荐方法

谢程远, 张恒, 龚文正, 程宇

(安徽建筑大学 电子与信息工程学院, 合肥 230601)

摘要: 图协同过滤一直是协同过滤推荐领域的先进方法, 尽管图协同过滤展现了强大的性能, 但在实际场景中通常存在数据稀疏的问题。为了减小数据稀疏带来的影响, 图协同过滤采用对比学习来提升性能。现有的方法在构建对比视图时通常采用随机采样等方法, 对图原有的语义结构有较大影响, 且对视图中高阶邻居节点的信息损失问题缺乏处理。因此提出一种新颖的基于对比学习的记忆图协同过滤推荐方法 (A Memory Graphs Collaborative Filtering recommendation method based on comparative learning, MGCF)。该方法利用门控循环单元记忆节点在信息传播过程中自身的部分特征表达, 并将用户 (项目) 的同质邻居节点视为正对比对进行对比学习。在 4 个公开数据集上的实验结果表明 MGCF 的预测准确性与基线方法相比有较大提升。

关键词: 对比学习; 协同过滤; 图神经网络; 门控循环单元

中图分类号: TP391.3

文献标志码: A

文章编号: 2095-2163(2025)10-0195-06

A collaborative filtering recommendation method for memory graphs based on comparative learning

XIE Chengyuan, ZHANG Heng, GONG Wenzheng, CHENG Yu

(School of Electronics and Information Engineering, Anhui Jianzhu University, Hefei 230601, China)

Abstract: Graph Collaborative Filtering has been an advanced method in the field of collaborative filtering recommendation, although graph collaborative filtering shows strong performance, there usually exists the problem of data sparsity in actual scenarios. In order to minimize the impact of data sparsity, graph collaborative filtering employs contrast learning to improve performance. Existing methods usually adopt random sampling and other methods when constructing the contrast view, which has a large impact on the original semantic structure of the graph and lacks to deal with the problem of information loss of high-order neighbor nodes in the view. Therefore, the paper proposes a novel Memory Graph Collaborative Filtering recommendation method based on comparative learning (MGCF). The method utilizes the gated recurrent unit memory nodes to express some of their own features during the information dissemination process and considers the homogeneous neighboring nodes of users (items) as positive contrast pairs for comparative learning. Experimental results on four publicly available datasets show a significant improvement in the prediction accuracy of MGCF compared to the baseline method.

Key words: contrast learning; collaborative filtering; graph neural networks; gated recurrent units

0 引言

在互联网时代, 网络数据规模呈现出爆发式的增长, 使得用户经常面临信息过载的困境。个性化推荐在发现用户偏好并帮助用户决策等方面发挥了重要作用。协同过滤 (Collaborative Filtering, CF)^[1] 一直是实现个性化推荐的常用手段。能从历史用户

与项目的交互 (例如对话、购买、点击等) 生成有效推荐。学习用户和物品的信息表示对于提高 CF 的效果至关重要。为此, 加深用户-项目关系的研究已成为学界的热点方向。最近, 图神经网络 (Graph Neural Networks, GNN) 的快速发展^[2] 以及其处理复杂多源异构信息的优良性质进一步增强了 CF 的效果, 通过将交互数据建模为图 (例如, 用户-项目交

作者简介: 张恒 (1998—), 男, 硕士研究生, 主要研究方向: 个性化推荐, 对比学习; 龚文正 (1996—), 男, 硕士研究生, 主要研究方向: 个性化推荐, 神经网络; 程宇 (2000—), 男, 硕士研究生, 主要研究方向: 个性化推荐, 深度学习。

通信作者: 谢程远 (1998—), 男, 硕士研究生, 主要研究方向: 个性化推荐, 图神经网络。Email: xcy1998@foxmail.com。

收稿日期: 2024-01-25

哈尔滨工业大学主办 ◆ 科技创见与应用

互图),再应用 GNN 学习有效的节点表示用于推荐,称为图协同过滤。图协同过滤在推荐领域取得了显著的效果,但仍然面临冷启动和数据稀疏等问题。图对比学习作为一种自监督学习方式可以有效地缓解图中结构不公平和缺失数据标签等问题^[3]。

尽管图对比学习近些年凭借其出众的性能表现获得了广泛应用,但大多数现有的图对比学习方法或者在用户-项目交互图上执行随机增强(如节点/边缘扰动),或者依赖基于启发式的增强技术(例如,用户聚类)来生成对比视图,破坏了图中数据原有完整的语义结构^[4],且对视图中节点高阶协同信息远距离传递过程中的信息衰减问题缺乏处理。

为此,提出一种新颖的基于对比学习的记忆图协同过滤推荐方法(MGCF),研究摒弃传统的破坏原有图语义结构的对比学习方式,在图中引入门控循环单元(Gated Recurrent Unit, GRU)^[5]增强节点在消息传递过程中自身的信息,使节点的特征可以聚合更加完整的高阶邻居嵌入。

1 相关工作

协同过滤利用与目标用户相似的用户行为(评分、点击次数等)推断目标用户对特定产品的喜好程度,并根据这种喜好程度进行相应推荐^[6-7]。矩阵分解^[8]将用户/项目表示在潜在向量的低维空间,通过用户/项目的潜在向量的内积来预测用户对项目的评分。其他的早期协同过滤推荐方法将个人历史作为用户预先存在的特征引入,并整合历史项目的嵌入来丰富其表示。

由于用户-项目交互数据对二分图结构天然的适应性及计算力的提升,基于图神经网络的推荐模型越来越受到关注。Berg 等学者^[9]提出了 GC-MC 方法,从图上链接预测的角度考虑推荐系统的矩阵补全。Qu 等学者^[10]提出邻域交互的概念,将用户项目交互通过图扩展为邻域与邻域的交互。Wang 等学者^[11]提出神经图协同过滤模型(NGCF),将图卷积的方法应用在推荐中,通过图网络结点连通的特性,获取高阶的协同信息,并融入进目标用户/项目的特征向量中。He 等学者^[12]提出轻量化图卷积模型(LightGCN),针对推荐任务特征较少的特点,对 NGCF 进行精简优化,提升训练效率。

实际场景中图数据往往缺少标签,对大量的图数据进行标注需要耗费大量的资源和人力。图对比学习得益于可以有效缓解图神经网络对标签数据的依赖及结构不公平等问题,在近些年获得了广泛的

应用,如 Wu 等学者^[13]从不同方面设计了3种类型的数据增强来构建辅助对比任务,提出了 SGL 模型。Lin 等学者^[14]提出 NCL 方法,利用结构和语义上的相邻关系构建对比视图。Yu 等学者^[15]研发了一种简单的对比学习方法,在嵌入空间中添加噪声以创建对比视图。Shen 等学者^[16]提出了 NCLA 模型,在不同视图中引入多头注意力机制,学习不同视图边的权重并融入节点特征。Cai 等学者^[17]提出了 LightGCL,采用奇异值分解的方式对图数据进行重构,以保留图中的全局协同信息。

尽管现有的工作在一定程度上提升了推荐的效果,但这些方法不能很好地保留内在的语义结构,且节点在消息传递过程中存在信息丢失,解决上述问题可以进一步提高推荐算法的精度。

2 MGCF 模型

与现有的图协同过滤对比学习方法不同,本文提出了 MGCF 方法,保留图中原有且完整的结构状态,并在节点特征传递至下一层的过程中使用 GRU 增强当前层的节点特征以缓解信息衰减,在此基础上本文采用结构邻居的对比方法进行对比学习。模型整体结构如图1所示,由3部分组成:

(1)图协同过滤主干。由图卷积网络生成用户与项目的基本嵌入。

(2)门控记忆模块。在节点信息聚合完成后传递至下一层时引入 GRU 保留部分当前层的节点特征。

(3)结构邻居对比模块。将节点与其同质邻居进行对比。

2.1 图协同过滤模块

遵循图协同过滤的常见做法^[12]是,为每个用户 u 和项目 i 分配了一个嵌入向量 e_{u_m}, e_{i_n} , 这里 m 和 n 分别表示用户与项目的数量。研究中采用3层 GCN 来聚合每个节点的邻居信息。在第 k 层,聚合过程表示如下:

$$e_u^{k+1} = \sum_{i \in N_u} \frac{1}{\sqrt{|N_u| \cdot |N_i|}} e_i^k \quad (1)$$

$$e_i^{k+1} = \sum_{u \in N_i} \frac{1}{\sqrt{|N_i| \cdot |N_u|}} e_u^k \quad (2)$$

其中, $1/\sqrt{|N_u| \cdot |N_i|}$ 表示相关性系数,采用图卷积网络中常用的拉普拉斯范数,表示为一阶邻域节点对目标节点的贡献程度,邻居节点的一阶邻域越大,则其对目标节点的贡献度就越小。

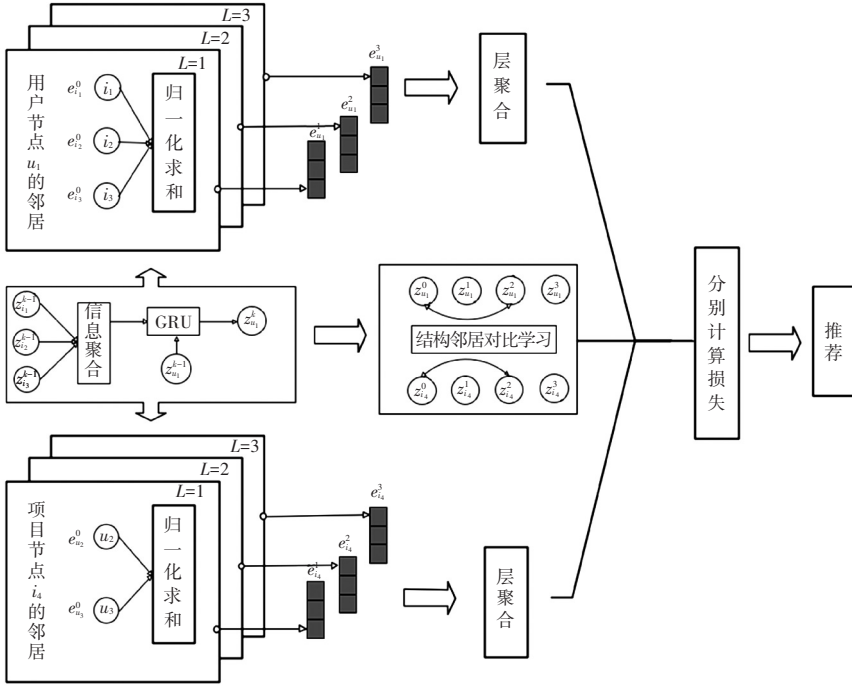


图 1 MGCF 模型结构

Fig. 1 MGCF model structure graph

经过 K 层传播后,采用平均分配的方式进行层组合,得到节点的最终表示如下:

$$e_u = \frac{1}{K+1} \sum_{k=0}^K e_u^k \quad (3)$$

$$e_i = \frac{1}{K+1} \sum_{k=0}^K e_i^k \quad (4)$$

研究采用内积来预测用户 u 与项目 i 交互的可能性:

$$\hat{y}_{u,i} = e_u^T e_i \quad (5)$$

为了正样本和负样本之间的得分之差尽可能地大(正样本是用户交互过的,而负样本是没有进行交互的),本文使用贝叶斯(Bayesian Personalized Ranking, BPR^[18])损失函数对模型进行训练,提升最大化边际概率。优化目标如下:

$$L_{BPR} = \sum_{u, i, j \in P} -\ln \sigma(\hat{y}_{u,i} - \hat{y}_{u,j}) \quad (6)$$

其中, $P = \{(u, i, j) \mid (u, i) \in R^+, (u, j) \in R^-\}$ 表示用户与项目的交互数据集; R^+ 表示观测到的用户-项目交互; R^- 表示未观测到的交互; σ 为 Sigmoid 函数。

2.2 门控记忆模块

通过 L_{BPR} 训练损失可以对用户项目交互进行建模,但迭代过程中节点的自身特征被不断稀释,因此引入门控记忆模块缓解该问题。

GRU 利用重置门 r_t 决定遗忘信息的数量,并加

入最新状态信息 \tilde{h}_t , 得到 GRU 的输出 h_t , 其数学表示为:

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (7)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (8)$$

$$\tilde{h}_t = \tanh(W_h[r_t \odot h_{t-1}, x_t]) \quad (9)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (10)$$

其中, W_r, W_z, W_h 表示权重矩阵; σ 表示 Sigmoid 激活函数; h_{t-1} 表示上一时刻的输出状态; x_t 表示本时刻的输入; $[\cdot, \cdot]$ 表示对 2 个向量进行拼接; “ \odot ” 表示哈达玛积。为了论述方便,将上述公式形式化为:

$$h_t = f_{GRU}(x_t, h_{t-1}) \quad (11)$$

其中, $f_{GRU}()$ 表示 GRU 网络。

在该模块中, z_u^0 与 e_u^0 一样,为初始化的节点嵌入。节点 u_1 利用前一层的邻居节点的信息聚合作为输入,自身前一层的特征 $z_{u_1}^{k-1}$ 作为隐状态,输入至 GRU 网络后共同更新当前层的特征状态 $z_{u_1}^k$ 。

对堆叠的 K 层卷积层执行门控记忆模块,可以使得用户(项目)节点获得 K 阶邻居的信息。如此一来,目标节点不仅考虑了周围邻居的信息,也保留了自身前一状态的信息,并以此来更新嵌入表征:

$$z_u^{k+1} = f_{GRU}\left(\sum_{i \in N_u} \frac{z_i^k}{\sqrt{|N_u| \cdot |N_i|}}, z_u^k\right) \quad (12)$$

$$z_i^{k+1} = f_{\text{GRU}}(\sum_{u \in N_i} \frac{z_u^k}{\sqrt{|N_u| \cdot |N_i|}}, z_i^k) \quad (13)$$

2.3 结构邻居对比模块

门控记忆模块最突出的特点是使得节点在传递消息时能够保留前一状态的信息并参与至下一次节点向量的更新中。因此在对比学习模块中,本文采用结构邻居对比^[14]的方法,捕获用户与项目间的潜在邻居,充分利用 z_u, z_i 保留原始状态的特点,对同质邻居 z_u^L, z_i^L 进行对比学习。同质邻居为相同特征属性的节点,如在一个3层GNN中,用户 u 的初始特征为 e_u^0 ,经过第一层聚合后的 e_u^1 邻居为其交互过的项目节点,第二层邻居为与用户 u 拥有相似兴趣的其它用户节点,即可以在GNN模型的偶数层(如2,4,6)输出中获得同质邻居的表示。具体来说,将节点的初始嵌入与经过门控记忆模块保留初始信息的偶数层嵌入视为正对比对,不同节点的嵌入视为复对比对(如 $\{(z_u^k, z_v^0) \mid u, v \in U, u \neq v\}$)。基于InfoNCE,通过最小化节点之间的差距进行对比计算损失:

$$L_S^U = \sum_{u \in U} -\log \frac{\exp(z_u^q \cdot z_u^0 / \tau)}{\sum_{v \in U} \exp(z_u^q \cdot z_v^0 / \tau)} \quad (14)$$

$$L_S^V = \sum_{i \in I} -\log \frac{\exp(z_i^q \cdot z_i^0 / \tau)}{\sum_{j \in I} \exp(z_i^q \cdot z_j^0 / \tau)} \quad (15)$$

其中, $U = \{u_1, u_2, \dots, u_m\}$ 表示所有用户; $I = \{i_1, i_2, \dots, i_n\}$ 表示所有项目; q 表示偶数; τ 表示温度超参数; $\{u, v \in U, u \neq v\}, \{i, j \in I, i \neq j\}$ 。

完整的结构对比目标函数是上述 2 个损失之和:

$$L_S = L_S^U + L_S^V \quad (16)$$

2.4 模型优化

由于协同过滤的主要目标是对用户和项目之间的交互进行建模,因此将所提出的对比学习损失视为补充,并利用多任务学习策略来联合训练传统排名损失和所提出的对比损失。计算公式具体如下:

$$L = L_{\text{BPR}} + \lambda_1 L_S + \lambda_2 \|\Theta\|_2^2 \quad (17)$$

其中, λ_1 表示平衡 BPR 损失和对比损失的超参数; λ_2 表示控制正则化强度的超参数; Θ 为 GNN 模型的参数集。

3 实验结果与分析

3.1 数据集

实验数据集采用 Gowalla、Yelp2018、Amazon -

Book、MovieLens - 1M 四个公开数据集。其中, Gowalla 数据集为 Gowalla 签到数据集,采集的时间跨度为 2009 年 2 月至 2010 年 10 月。Yelp2018 为 Yelp 通过数据集挑战赛(Yelp DataSet Challenge)公开的自 2004 年至 2018 年的部分数据。Amazon - Book 包含有关 212 404 本书的 3 M 书评,并为每本书提供这些书评的用户的信息。MovieLens - 1M 数据集为 2003 年 2 月发布的 6 000 名用户对 4 000 部电影的 100 万次评分。表 1 给出了 4 个数据集的统计信息。

表 1 实验信息数据
Table 1 Experimental information data

数据集	用户	项目	交互记录	稀疏度
Gowalla	29 858	40 981	1 027 370	0.000 84
Yelp2018	31 668	38 048	1 561 406	0.001 30
Amazon-Books	52 643	91 599	2 984 108	0.000 62
MovieLens-1M	6 040	3 900	1 000 209	0.038 16

3.2 评价指标基线方法

本文中,采用常用的评价指标,即召回率(Recall@N)和归一化折损累计增益(NDCG@N)(Normalized Discounted Cumulative Gain),以评估推荐方法的性能。默认情况下,设置 $k = 20$ 。

这 2 个评价指标也被广泛应用于前期的研究工作中^[9-13]。其中,Recall@N 是 top - N 个推荐结果中命中用户访问将访问的项目的比例,用来衡量推荐的全面性。NDCG@N 是基于排序结果的评价指标,用来衡量排序的质量。

3.3 基线方法

为了验证所提出的基于对比学习的记忆图协同过滤推荐方法 MGCF 的有效性,本文将所提的方法与 5 种先进的协同过滤算法进行对比实验。

(1)NGCF^[11],基于图卷积神经网络的先进推荐方法。该模型传播用户-项目图中节点的特征,以充分挖掘高阶连接中隐藏的信息来提高推荐性能。

(2)LightGCN^[12],基于图结构的协同过滤推荐方法。通过在交互图上线性传播来学习嵌入表示,将不同传播层嵌入信息的加权和作为最终嵌入,去除特征转换和非线性激活,同时以层组合方式代替自连接;

(3)SGL^[13],引入自监督学习的推荐方法。从不同方面设计了 3 种类型的数据增强来构建辅助对比任务。

(4)NCL^[14],基于对比学习的图协同过滤推荐方法。分别对节点的结构邻居和语义邻居进行对比

学习。

(5) LightGCL^[17], 一个简单且有效的图对比学习范式。专门利用奇异值分解进行对比增强。

3.4 实验及参数设置

本文模型及基线使用 Python 3.9 语言, 基于 RecBole 框架实现, 机器配置为 Xeon Gold 5117 2.50 GHz, NVIDIA Grid V100D-32Q, 操作系统为 Windows10。在实验中, 对于每个数据集, 随机选取每个用户 80% 的历史交互组成训练集, 再选 10% 作为测试集, 剩下的 10% 的作为验证集。

对超参数进行优化, 对所有实验, 采用 Adam^[19] 作为优化器, 参数初始化采用 Xavier^[20] 方式。每次处理的数据量大小为 4 096, 嵌入大小为 64。SGL 采用 SGL-ED 作为实例化。采用网格搜索方法调整最优参数, L_2 正则化系数 λ_2 在 $\{10^{-5}, 10^{-4}, \cdots, 10^{-2}\}$ 中调整, 学习率在 $\{0.000\ 1, 0.000\ 5, 0.001\ 0, 0.005\ 0\}$ 中搜索。根据实验结果调整模型结构邻居层数 $q = 2$ 。模型迭代次数为 1 000 次时收敛。

3.5 整体性能比较与分析

将本文模型与对比模型分别在相同的 4 个数据集上独立进行 5 次实验, 平均实验结果见表 2。分析表 2, 可以发现 MGCF 与上述基线方法对比均有提升。

分析表 2 中数据可知, 由于协同过滤推荐场景下节点自身不含语义信息, NGCF 的性能表现最差。LightGCN 对 NGCF 进行了优化, 但其采用归一化求和的聚合方式过于简单, 在稀疏数据的环境下其表现可能会更差。相较于传统图协同过滤方法, 引入对比学习的推荐方法在性能上均有不错的表现, SGL 采用边缘丢弃的策略进行对比, 虽然获得了性能的提升但对图的原本结构造成了一定的损失。NCL 同时考虑了图的结构邻居和语义邻居, 但却忽视了节点信息进行高阶传播时自身信息丢失的问题, 使用损失信息后的节点进行对比学习降低了推荐的精度。LightGCL 在所有基线中取得了最好的表现, 得益于其采用 SVD 方式增强用户-项目交互图结构, 但仍然没有关注节点的信息衰减问题, 因此表现不如 MGCF。

表 2 基线模型性能对比

Table 2 Performance comparison of baseline model

模型	Gowalla		Yelp		Amazon-Book		MovieLens	
	Recall	NDCG	Recall	NDCG	Recall	NDCG	Recall	NDCG
NGCF	0.173 4	0.103 2	0.103 5	0.057 7	0.098 1	0.055 7	0.274 8	0.261 9
LightGCN	0.198 3	0.116 1	0.116 8	0.065 8	0.121 0	0.069 2	0.280 4	0.263 1
SGL	0.208 8	0.123 1	0.129 4	0.074 5	0.133 7	0.078 1	0.285 7	0.265 5
NCL	0.213 7	0.127 1	0.138 0	0.082 2	0.138 8	0.081 9	0.304 2	0.284 8
LightGCL	0.215 5	0.129 2	0.139 7	0.084 1	0.140 3	0.083 8	0.307 2	0.286 7
MGCF	0.217 3	0.131 7	0.141 1	0.085 6	0.143 1	0.084 6	0.311 2	0.268 5

MGCF 引入了 GRU 有效提高了推荐性能。从模型推荐效果的总体比较来看, MGCF 在 4 种数据集上的 2 个评价指标的表现均优于其他对比方法。说明了模型设计的合理性, 同时也证明了模型的高效性和良好的泛化能力。

3.6 结构邻居层数影响

在 MGCF 中, 结构邻居对应于 GCN 中的不同

层, 为了进一步探究不同结构邻居的影响, 研究选择第 1、2、3 个偶数层作为结构邻居进行对比并测试其性能, 结果见表 3。可以发现符合本次研究中对距离更近的邻居比距离更远的邻居更相似的印象, 第一个偶数层的表现最好, 且随着层数的增加, 模型的复杂度成倍增长, 因此研究采用第一个偶数层作为 MGCF 的结构邻居。

表 3 结构邻居层数对比

Table 3 Structural neighborhood floor comparison

q	Gowalla		Yelp		Amazon-Book		MovieLens	
	Recall	NDCG	Recall	NDCG	Recall	NDCG	Recall	NDCG
2	0.217 3	0.131 7	0.141 1	0.085 6	0.143 1	0.084 6	0.311 2	0.268 5
4	0.208 1	0.123 3	0.134 7	0.076 9	0.134 2	0.079 1	0.303 3	0.265 1
6	0.206 6	0.121 4	0.131 8	0.073 7	0.132 1	0.077 2	0.300 5	0.263 9

4 结束语

在这项工作中,本文提出了一种基于对比学习的记忆图协同过滤推荐方法(MGCF),模型在图协同过滤主干网络中引入门控循环单元,增强高阶信息传递过程中节点的自身信息,采用结构邻居对比学习的方法,将节点与其记忆过后的同质邻居进行对比。在 4 个数据集中的大量实验证明了所提出的 MGCF 的有效性。

参考文献

[1] SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based collaborative filtering recommendation algorithms [C]//Proceedings of the 10th International Conference on World Wide Web. New York:ACM, 2001: 285-295.

[2] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model [J]. IEEE Transactions on Neural Networks, 2008, 20(1): 61-80.

[3] JAISWAL A, BABU A R, ZADEH M Z, et al. A survey on contrastive self-supervised learning [J]. Technologies, 2020, 9(1): 2.

[4] 吴国栋,吴贞畅,王雪妮,等. 图对比学习研究进展[J]. 小型微型计算机系统,2025,46(1):44-54.

[5] CHO K, MERRIËNBOER V B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. arXiv preprint arXiv,1406.1078, 2014.

[6] 赵俊逸,庄福振,敖翔,等. 协同过滤推荐系统综述[J]. 信息安全学报,2021,6(5):17-34.

[7] SUGANESHWARI G, SYED I S P. A survey on collaborative filtering based recommendation system [C]//Proceedings of the 3rd International Symposium on Big Data and Cloud Computing Challenges (ISBCC-16'). Cham:Springer, 2016: 503-518.

[8] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems [J]. Computer, 2009, 42(8): 30-37.

[9] BERG R, KIPF T N, WELLING M. Graph convolutional matrix completion[J]. arXiv preprint arXiv,1706.02263, 2017.

[10] QU Yanru, BAI Ting, ZHANG Weinan, et al. An end-to-end neighborhood-based interaction model for knowledge-enhanced

recommendation [C]//Proceedings of the 1st International Workshop on Deep Learning Practice for High-Dimensional Sparse Data. New York:ACM, 2019: 1-9.

[11] 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. New York:ACM, 2019: 165-174.

[12] 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.

[13] WU Jiancan, WANG Xiang, FENG Fuli, et al. Self-supervised graph learning for recommendation [C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York:ACM, 2021: 726-735.

[14] LIN Zihan, TIAN Changxin, HOU Yupeng, et al. Improving graph collaborative filtering with neighborhood-enriched contrastive learning [C]//Proceedings of the ACM Web Conference. New York:ACM,2022: 2320-2329.

[15] 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.

[16] SHEN Xiao, SUN Dewang, PAN Shirui, et al. Neighbor contrastive learning on learnable graph augmentation [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(8): 9782-9791.

[17] CAI Xuheng, HUANG Chao, XIA Lianghao, et al. LightGCL: Simple yet effective graph contrastive learning for recommendation [J]. arXiv preprint arXiv,2302.08191, 2023.

[18] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback [J]. arXiv preprint arXiv,1205.2618, 2012.

[19] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. arXiv preprint arXiv,1412.6980, 2014.

[20] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [J]. Journal of Machine Learning Research,2010, 9:249-256.