

XSGCL: 用于推荐的轻量级图对比学习框架

张震¹, 游兰¹, 彭庆喜², 金红¹, 曾昊秋¹, 夏宇春¹

(1. 湖北大学计算机与信息工程学院, 湖北 武汉 430062; 2. 武汉学院信息工程学院, 湖北 武汉 430212)

摘要: 传统的基于对比学习的推荐模型通常首先对原始交互图进行数据增强, 然后尽可能提高不同视图编码后的表示一致性。虽然这种方法已被证明是有效的, 但最近的研究发现, 由于图数据中节点的边遵循幂律分布, 图增强往往会引入对对比学习不利的偏差。此外, 图结构的扰动使得处理大规模数据集变得计算密集, 限制了基于对比学习模型的灵活性。为了应对这些挑战, 提出一种高低方差分离的特征增强方法 (HLVS), 该方法不仅避免了对图结构的直接扰动, 还减轻了传统特征扰动方法中存在的语义偏差问题。同时, 为了缓解推荐系统中的流行度偏差问题, 在任务中引入流行度指标, 并设计一种新的损失函数——基于物品流行度的贝叶斯个性化排序 (PBPR) 损失, 以实现热门与冷门节点表示的平衡。最后, 通过整合对比学习、HLVS 和 PBPR, 设计一个轻量级的无参数图对比学习框架 (XSGCL), 该框架可以自然地集成到推荐模型中, 以提高训练效率和性能。通过在 5 个公共数据集上的广泛实验, 证明了将 XSGCL 集成到 LightGCN 后, 不仅显著提升了训练效率, 并且相较于先进模型具有更好或者相当的性能, 例如在 Yelp2018 数据集上, 相比于 LightGCN, 模型训练效率提升了 91.2%; 在 Alibaba-iFashion 数据集上, Recall@10 和 NDCG@10 指标分别提高了 32.21% 和 33.73%。

关键词: 推荐系统; 对比学习; 数据增强; 流行度偏差; 图神经网络; 协同过滤

中图分类号: TP18

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0070143

XSGCL: A Lightweight Graph Contrastive Learning Framework for Recommendation

ZHANG Zhen¹, YOU Lan¹, PENG Qingxi², JIN Hong¹, ZENG Haoqiu¹, XIA Yuchun¹

(1. School of Computer Science and Information Engineering, Hubei University, Wuhan 430062, Hubei, China;

2. School of Information Engineering, Wuhan College, Wuhan 430212, Hubei, China)

【Abstract】 Traditional recommendation models based on contrastive learning first perform data augmentation on the original interaction graph and then strive to improve the consistency of representations encoded from different views. Although this method has been proven effective, recent research has found that graph augmentation often introduces bias owing to the power-law distribution of node edges in graph data: such biases are detrimental to contrastive learning. In addition, the graph structure distribution makes the processing of large-scale datasets computationally intensive, limiting the flexibility of contrastive learning models. To address these challenges, this study proposes a High-Low Variance Separation feature enhancement method (HLVS), which not only avoids direct perturbations to the graph structure but also alleviates the semantic bias problem that exists in traditional feature perturbation methods. Simultaneously, to alleviate the issue of popularity bias in recommendation systems, popularity metrics are introduced into the main task, and a new loss function, Popularity Bayesian Personalized Ranking (PBPR) loss, is designed to balance the representation of popular and unpopular nodes. Finally, by integrating contrastive learning, HLVS, and PBPR, a lightweight and parameter-free graph contrastive learning framework, eXtremely Simple Graph Contrastive Learning (XSGCL), is designed, which can be naturally integrated into recommendation models to improve training efficiency and performance. Extensive experiments on five public datasets prove that integrating XSGCL into LightGCN not only significantly improves training efficiency but also achieves a performance that is better or comparable to that of advanced models. For example, on the Yelp2018 dataset, compared to LightGCN, the proposed model improves training efficiency by 91.2%. On the Alibaba-iFashion dataset, Recall@10 and NDCG@10 indicators increase by 32.21% and 33.73%, respectively.

【Key words】 recommendation system; contrastive learning; data augmentation; popularity bias; Graph Neural Network (GNN); collaborative filtering

基金项目: 湖北省重点研发计划(2022BAA044); 湖北省高校优秀中青年科技创新团队项目(T2022055)。

作者简介: 张震, 男, 硕士研究生, 主研方向为推荐系统、深度学习; 游兰、彭庆喜 (CCF 会员、通信作者), 教授、博士; 金红, 讲师、博士; 曾昊秋、夏宇春, 硕士研究生。

收稿日期: 2024-07-17

修回日期: 2024-10-11

E-mail: pqx@whu.edu.cn

0 引言

最近,对比学习被越来越多的研究用来提高表示学习能力,这得益于其能从大量未标记数据中提取不变特征,并以自监督方式优化表示^[1-3]。在推荐系统领域,多项研究专注于图增强策略,例如随机丢弃边/节点,旨在通过引入不确定性以揭示用户-物品交互的不变信息^[4-6]。然而,一些最新研究指出,随机图增强可能引入对对比学习产生不利影响的无关噪声^[1,7-8]。于是,特征扰动方法逐渐流行,它通过直接向用户/物品表示中添加随机噪声来增加数据多样性,以提升模型的泛化能力,具有操作简便的优势^[1-2,9]。然而,现有方法通常未区分对待各特征,对高方差和低方差特征都施加相同程度的扰动,可能会对低方差特征造成更大的语义变化和损害。为此,本文提出了一种高低方差分离的特征增强方法(HLVS),仅对高方差特征进行扰动,保持低方差特征稳定,从而避免增强后节点表示的语义发生较大偏差,影响下游的对比学习任务。

贝叶斯个性化排序(BPR)损失因其在指导用户和物品节点的学习中的有效性而被广泛应用于推荐系统任务^[10]。然而,在现实应用场景中,物品的分布常呈现长尾特性,这导致依赖 BPR 损失可能会加剧热门物品由于曝光机会较多而表现更佳,而冷门物品由于交互稀少而表现较差的问题。为了缓解这种流行度偏见,本文在 BPR 损失的基础上引入了一个物品流行度指标,设计了一种新的损失函数——基于物品流行度的贝叶斯个性化排序(PBPR)损失。这种方法有效地平衡了热门与冷门物品的表示,提升了对长尾物品的推荐性能。

基于对比学习推荐模型的多通道架构除了推荐任务的前向和反向传播通道外,每个小批量内的对比学习任务还需要 2 个额外的前向和反向传播通道。这种架构导致计算成本增加到传统推荐模型的近 3 倍^[2],在大规模数据集中表现得尤为明显,极大地增加了基于对比学习模型的计算成本。因此,本文提出了一个轻量级的无参数图对比学习框架(XSGCL)。该框架有效地整合了对比学习、HLVS 和 PBPR 方法,在执行每次小批量对比学习任务时,仅在模型的最终预测层进行一次 HLVS 操作,最后通过 PBPR 损失指导模型训练。得益于其无参数设计,XSGCL 不增加任何推荐系统的训练负担,并易于集成到推荐模型中。这些特点使得 XSGCL 在提升推荐性能的同时,显著提升了现有对比学习架构

的训练效率。本文的工作主要如下:

1)提出了 HLVS 方法,针对样本特征表示中的方差特性,施加不同程度的扰动,缓解常用特征扰动方法带来的语义偏差问题。

2)结合了物品流行度指标,设计了新的 PBPR 损失以缓解推荐系统中的流行度偏差问题。

3)有效整合了对比学习、HLVS 和 PBPR 方法,设计了用于推荐的轻量级图对比学习框架 XSGCL,该框架简化了传统的多通道对比学习推荐模型架构,提高推荐性能的同时提升了模型的训练效率。

4)将 XSGCL 框架应用于广泛使用的 LightGCN^[11]推荐模型上,在 5 个公共数据集上的实验结果表明,集成后的模型性能优于或相当于先进模型,证明了 XSGCL 框架的有效性。

1 相关工作

1.1 用于推荐的数据增强

推荐系统中常用的数据增强技术可分为 3 类:基于序列的、基于图的和基于特征的^[8]。基于序列的数据增强^[12-14]包括物品裁剪、重排序和替换,旨在保留原始序列信息的同时注入较少扰动,以提高对用户行为模式的识别和预测。基于图的数据增强^[4-6]通过随机移除或生成图中的边或节点来增强节点表示的鲁棒性,并识别影响力较大的节点。基于特征的数据增强包括随机丢弃小部分嵌入特征和向样本添加随机噪声^[9,15],旨在增强模型对不完整数据的处理能力以及对细微变化的感知。然而,现有的方法通常没有将节点嵌入表示中每个维度的特征看作一个整体,而是将噪声独立地添加到节点嵌入表示矩阵的每一个元素上,如图 1(a)所示(彩色效果见《计算机工程》官网 HTML 版,下同)。这种处理方式通常涉及生成一个与节点嵌入表示矩阵同等大小的噪声矩阵,并将其逐元素地与节点嵌入表示矩阵相加,得到用于对比学习的增强表示矩阵。这种做法可能会忽视节点嵌入的语义信息,甚至破坏原有的语义表示。因为嵌入表示的语义信息往往与特征维度密切相关,特征维度在宏观上定义了节点在编码后表示空间中的语义信息。而当前方法主要关注嵌入表示矩阵中每个元素的数值,未能充分考虑维度特征的整体语义信息。此外,这些方法通常从相同分布中生成噪声矩阵,对嵌入表示中的每个元素施加相似程度的扰动。在节点的嵌入表示中,不同特征维度具有不同的方差特性。若如现有方法般不区分对待各特征,则可能对低方差特征造

成较大的语义变化和损害,同时让高方差特征未得到足够扰动,最终削弱模型的鲁棒性。

为了解决上述问题,本文提出一种高低方差分离的特征增强方法 HLVS,仅对高方差特征进行扰动,保持低方差特征稳定,如图 1(b)所示。通过这

种方式,HLVS 不仅将节点嵌入表示的每一维特征视为一个整体来考量,而且根据不同特征的方差特性进行分别处理,从而避免在数据增强过程中引发节点表示的语义偏差,保证了对比学习任务的效果和模型的稳定性。

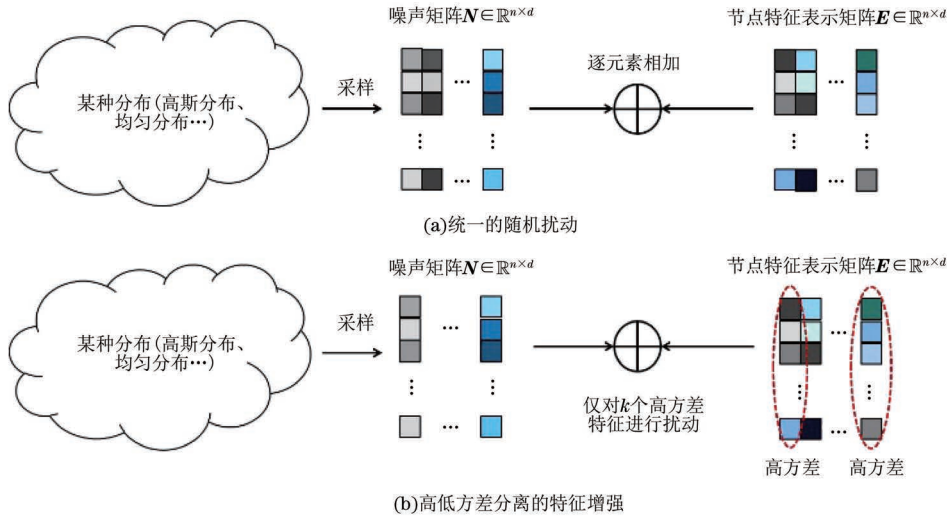


图 1 统一的随机扰动与高低方差分离的特征增强

Fig. 1 Unified random perturbation and high-low variance separation feature enhancement

1.2 用于推荐的对比学习

对比学习的核心思想是通过最大化不同增强视图间的一致性来提高模型的性能。SGL^[4]通过随机丢弃边/节点来增强图数据,并使用节点的自判别进行对比学习。NCL^[16]则将用户(或物品)的结构和语义邻居纳入对比对,有效提升了推荐模型性能。与传统的图增强方法不同,SimGCL^[1]直接在嵌入空间中添加均匀噪声,以更均匀地分布用户/物品表示,在推荐准确性和训练效率方面显著超越了过去基于图增强的方法。然而,以上方法都采用了基于对比学习的多通道架构,如图 2(a)所示。这种架构由于需要 2 个额外的前向和反向传播通道,导致计算成本增加到传统推荐模型的近 3 倍,大幅降低了基于对比学习模型的训练效率。尽管 XSimGCL^[2]通过设计跨层对比的方式简化了多通道对比学习架构,减少了一部分计算负担,但仍需要通过人工试错来选择最佳的对比层。假设模型层数为 L ,最多需要 $C(L, 2)$ 次操作才能确定最优配置,这无疑增加了人力成本。此外,如图 2(b)所示,与 SimGCL 类似,XSimGCL 在训练过程中也需要对每一层的所有节点施加噪声,进一步加重了模型训练的负担。于是本文提出了 XSGCL 架构,通过仅在小批量的最终预测层进行单次高低方差分离的特征增强以解决上述问题,并显著提升训练效率。具体提升效果可参考本文第 3.5.2 节。

1.3 协同过滤

协同过滤^[17]作为一种有效的推荐方法,其核心假设为行为相似的用户倾向于对相同物品有类似的偏好。基于协同过滤的推荐系统专注于分析用户和物品之间的历史交互行为(例如购买、点击),因为这些行为信息对提升推荐系统性能至关重要^[18]。为了深入挖掘用户与物品之间的行为关系,从早期的矩阵分解开始^[10],到后续的研究^[19-20]将个人的交互历史作为初始特征,并结合历史物品的嵌入信息来丰富用户的表示。近期的研究^[11,21]则将所有历史交互构建成一个用户-物品图,并通过整合多跳邻居信息来丰富表示,从而达到更先进的性能水平。为了加强并优化协同过滤推荐系统的性能,图对比学习方法引入了一种全新的视角。这种方法通过引入自监督学习机制,在提取深层次、非显式的行为模式方面尤为有效,这些模式是传统协同过滤算法难以直接学习到的。具体来说,通过对每个用户和物品节点生成多个视图并强化这些视图之间的一致性,图对比学习能够产生更加丰富和鲁棒的用户及物品特征表示,不仅捕获了传统协同过滤可能忽略的细微结构信息,还通过增强学习过程中的特征表示来克服数据稀疏性的限制。

2 XSGCL 框架

XSGCL 框架独立于推荐模型,专用于处理模

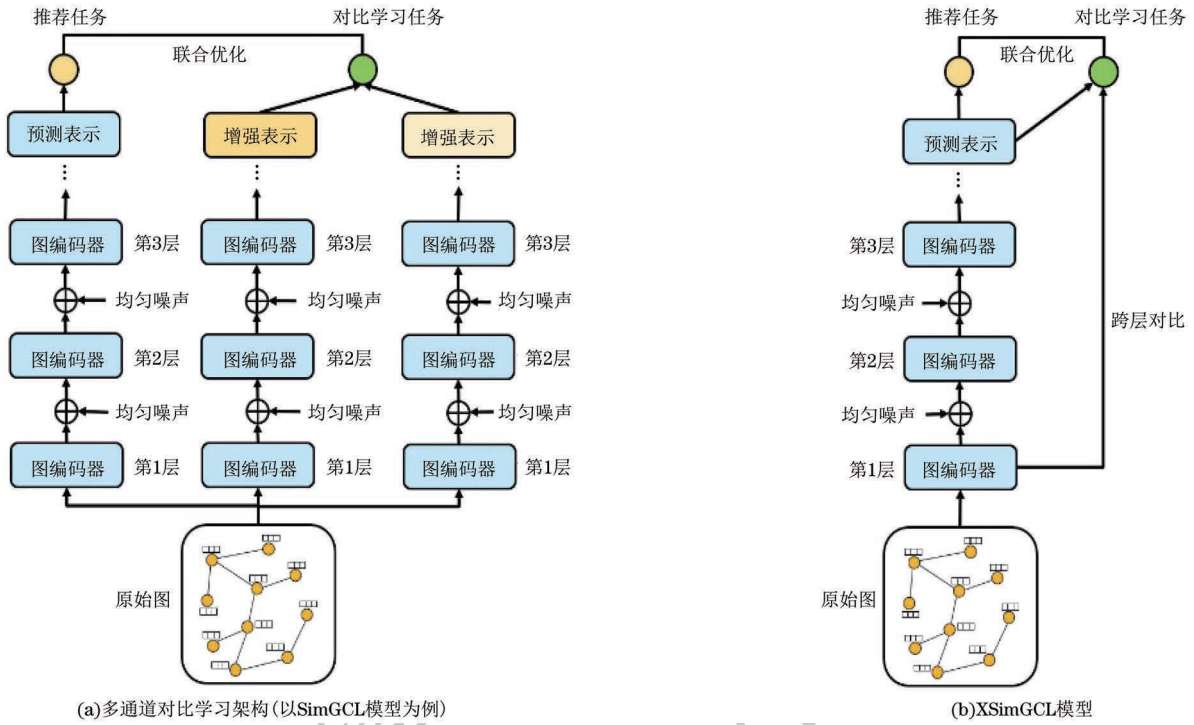


图 2 多通道对比学习架构(以 SimGCL 为例)与 XSimGCL

Fig. 2 Multi-channel contrastive learning architecture (using SimGCL as an example) and XSimGCL

型的最终预测表示。如图 3 所示,该框架通过 HLVS 方法对预测表示进行特征扰动以生成对应的增强表示并应用于对比学习任务,以缓解数据稀疏和提升表征质量。此外,为了减轻流行度偏差,本文通过引入每个物品的流行度指标改进了现有的 BPR 损失,提出了 PBPR 损失。最后,预测表示被同时应用于对比学习任务 and PBPR 损失进行联合优化。

非零条目的数量。在获得每一层的节点嵌入后,根据式(2)使用加权和来获得最终嵌入表示:

$$E = \frac{1}{L} \sum_{l=1}^L E^{(l)} \quad (2)$$

式中: E 是在聚合每个层的节点信息之后用于模型预测的最终特征表示; L 表示卷积运算的层数。

2.1 HLVS 方法

近期研究通常将随机噪声(如高斯或均匀噪声)直接加入样本的特征表示中,这种方法虽高效,但可能导致语义失真。尤其是对于方差较小的特征,过大的扰动可能引起本质的语义改变,而对方差较大的特征则影响较小。为此,提出了 HLVS 方法来区分高方差和低方差特征,仅对高方差特征进行扰动,保持低方差特征不变。这样有助于保留增强后特征表示中的原始语义。具体来说,首先通过式(3)、式(4),在预测表示中选择方差最大的 k 个列索引:

$$i_{\text{indices}} = \text{top-}k(\text{var}(\tilde{E}), k) \quad (3)$$

$$k = \text{int}(d \cdot h_{\text{ratio}}) \quad (4)$$

式中: $\tilde{E} \in \mathbb{R}^{b \times d}$ 是每个小批量中的预测表示,其中 b 是批次大小; $\text{int}()$ 是取整函数; h_{ratio} 是一个超参数,范围为 $(0, 1)$, 用于控制高低方差的选择比例。经过筛选后,只对高方差特征添加均匀噪声 $N \in \mathbb{R}^{b \times k} \sim U(0, 1)$ 。生成的增强表示 V 如式(5)所示:

$$V = \tilde{E}[:, i_{\text{indices}}] + \epsilon N \quad (5)$$

式中: ϵ 是用来控制噪声大小的缩放因子。

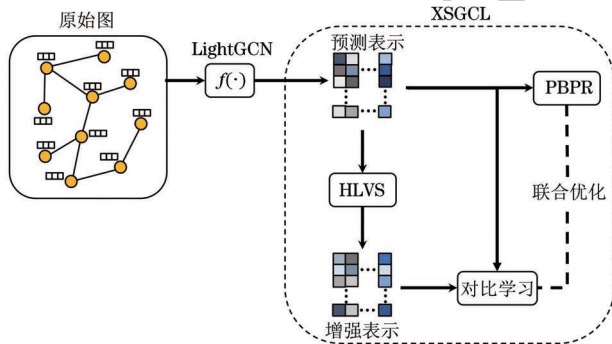


图 3 XSGCL 框架

Fig. 3 XSGCL framework

本文采用广泛使用的 LightGCN 作为基础编码模型,用于挖掘用户物品之间的交互信息。设第 0 层特征表示为 $E^{(0)} \in \mathbb{R}^{(m+n) \times d}$, 其中, d 是嵌入表示的大小, m 和 n 分别为用户和物品数量。于是传播过程中的每一层节点嵌入如式(1)所示:

$$E^{(l+1)} = (D^{-\frac{1}{2}} A D^{-\frac{1}{2}}) E^{(l)} \quad (1)$$

式中: D 是对角矩阵(也称为度矩阵),大小为 $(m+n) \times (m+n)$, D_{ii} 表示邻接矩阵 A 的第 i 行向量中

2.2 单视图对比学习

为提高多通道对比学习架构的训练效率,在每次迭代训练时,只对每个小批次内的预测表示 $\tilde{\mathbf{E}}$ 做一次特征扰动,生成单个增强视图用于对比学习任务。具体而言,批次内的任意节点 i ,其原始特征表示 \mathbf{e}_i 作为锚点样本,而增强后的表示 \mathbf{v}_i 作为正样本。批次内其他节点的增强表示 \mathbf{v}_j ($j \neq i$) 则作为负样本。对比损失函数 L_{cl} [22] 定义为式(6):

$$L_{cl} = \sum_{i \in \mathcal{B}} -\log_a \frac{\exp(\mathbf{e}_i^T \mathbf{v}_i / \tau)}{\sum_{j \in \mathcal{B}} \exp(\mathbf{e}_i^T \mathbf{v}_j / \tau)} \quad (6)$$

式中: \mathbf{e}_i 和 \mathbf{v}_j 是 L2 规范化后的特征表示; $\tau > 0$ (例如 0.2) 是控制难负样本上惩罚强度的超参数。

2.3 结合流行度的 PBPR

在推荐系统中,BPR 损失通常用于从用户偏好中区分正负样本对,定义为式(7):

$$L_{BPR} = - \sum_{(u,i,j) \in \mathcal{B}} \log_a(\sigma(\hat{y}_{ui} - \hat{y}_{uj})) \quad (7)$$

式中: u 是用户; i 是用户 u 交互过的物品; j 是用户未交互过的物品; \hat{y}_{ui} 是模型预测用户 u 对物品 i 的偏好得分; σ 是 Sigmoid 函数; \mathcal{B} 是一个批次内所有用户的正负样本对集合。

BPR 损失函数优化目标仅仅是提升用户与已交互物品的预测得分相对于未交互物品的得分,从而学习用户偏好。然而,现实中的物品交互数据通常呈现长尾分布,其中少数热门物品的交互频次高,而大多数物品(即长尾物品)的交互极少。这种分布特征导致推荐模型在训练过程中更频繁地采样热门物品,使得这些物品的表示更加精确,而长尾物品由于曝光不足,其表示较为粗糙,最终结果是流行物品的推荐倾向性增强,而非主流物品则趋向被忽略,形成了所谓的“流行度偏差”问题。为了缓解该问题,本文引入了每个物品的流行度指标 I_{pop} , 定义为该物品的交互次数占所有物品交互次数总和的比例。该指标反映了每个物品相对于其他物品的受欢迎程度,并可用于调整模型的优化过程,以增强模型对长尾物品的学习能力和推荐的多样性。

为了方便计算,利用式(8)将 I_{pop} 通过 min-max 归一化映射到 $[0,1]$ 之间:

$$\hat{I}_{pop} = \frac{I_{pop} - \min(I_{pop})}{\max(I_{pop}) - \min(I_{pop})} \quad (8)$$

归一化后的 \hat{I}_{pop} 可以用来调整正负样本对的损失权重,于是结合流行度的贝叶斯个性化排序 PBPR 损失定义为式(9):

$$L_{PBPR} = - \sum_{(u,i,j) \in \mathcal{B}} \omega_{ij} \cdot \log_a(\sigma(\hat{y}_{ui} - \hat{y}_{uj})) \quad (9)$$

式中: ω_{ij} 是基于物品 i 和 j 的流行度指标计算的权重,反映了模型减少对流行物品的依赖程度。权重 ω_{ij} 定义为式(10):

$$\omega_{ij} = \exp(-\alpha(\hat{I}_{i-pop} - \hat{I}_{j-pop})) \quad (10)$$

式中: \hat{I}_{i-pop} 和 \hat{I}_{j-pop} 分别是归一化后的物品 i 和物品 j 的流行度指标; α 是一个超参数,用于调整流行度对权重的影响程度。当物品 i 的流行度高于物品 j 时, $\omega_{ij} < 1$,这减少了流行物品在模型训练中的主导性,使得模型在学习时不会过分偏向这些高流行度的物品;反之,如果物品 i 的流行度低于物品 j ,则增加了模型关注非流行物品的动机,激励模型更多地关注这些长尾物品,从而提升模型在推荐长尾物品方面的能力。

2.4 多任务联合训练

本文按照 SGL [4] 中的联合优化方案训练模型,主任务使用前述的 PBPR 损失,结合流行度指标计算交互预测损失。此外,XSGCL 包含对比学习辅助任务,旨在增强稀疏交互节点的表征。最终损失函数定义为式(11):

$$L = L_{PBPR} + \lambda_1 L_{cl} + \lambda_2 \theta_2 \quad (11)$$

式中: λ_1 是用于平衡主任务和辅助任务损失权重的超参数; θ 表示节点的初始嵌入参数; λ_2 控制 L_2 正则化的强度。

2.5 算法与时间复杂度分析

XSGCL 框架的核心功能通过伪代码在算法 1 中进行了详细展示。该框架主要包括以下几个关键模块:HLVS 操作、单视图对比学习和结合流行度的 PBPR。

算法 1 XSGCL 算法

输入 批次内的节点预测表示 $\tilde{\mathbf{E}}$; 高方差选择比例 h_{ratio} ; 噪声大小 ϵ ; 对比损失权重 λ_1

输出 优化后的模型 f

1. for 每个轮次 do
2. for 每个批次 do
3. 定位 $\tilde{\mathbf{E}}$ 中的高方差特征[参照式(3)和式(4)]
4. 计算 $\tilde{\mathbf{E}}$ 对应的增强表示 \mathbf{V} [参照式(5)]
5. 将 $\tilde{\mathbf{E}}$ 和 \mathbf{V} 进行对比学习并计算对比损失 L_{cl} [参照式(6)]
6. 计算物品流行度 I_{pop} , 并进行归一化处理得到 \hat{I}_{pop} [参照式(8)]
7. 计算面向流行度的权重 ω_{ij} 和 PBPR 损失 L_{PBPR} [参照式(9)和式(10)]
8. 结合 L_{cl} 和 L_{PBPR} 对模型进行多任务联合优化 [参照式(11)]
9. end
10. end

1) HLVS 操作。首先计算嵌入矩阵 \hat{E} 中每个维度的方差, 时间复杂度为 $O(bd)$; 随后, 根据式(3)和式(4), 选出方差最高的前 k 个维度, 并对这些维度添加大小为 $b \times k$ 的均匀噪声。生成噪声和执行加法操作的时间复杂度均为 $O(bd)$, 因此 HLVS 操作的总时间复杂度为 $O(bd + bk)$ 。

2) 单视图对比学习。和现有基于对比学习的推荐模型一致^[1-2,4], XSGCL 通过 InfoNCE 损失进行优化, 其时间复杂度为 $O(b^2d)$ 。

3) 结合流行度的 PBPR。PBPR 在传统的 BPR 损失基础上增加了流行度的权重计算及其应用, 计算权重的时间复杂度为 $O(b)$, 将权重应用于每个批次的损失中同样需要 $O(b)$ 。由于 BPR 损失的时间复杂度为 $O(bd)$, 因此 PBPR 的总时间复杂度可近似为 $O(bd + 2b) \approx O(bd)$ 。

综合考虑上述所有步骤, 由于 $b \gg d > k$, 因此 XSGCL 的整体时间复杂度为 $O(bd + bk + b^2d + bd) \approx O(b^2d)$ 。虽然理论上与 XSimGCL 的时间复杂度一致, 但由于 XSGCL 仅对批次内的节点进行特征扰动, 因此实际训练效率更高。具体的效率比较可参考本文第 3.5.2 节的实验结果。此外, XSGCL 不涉及最佳层选择问题, 从而在人工试错成本上优于 XSimGCL。

3 实验与分析

3.1 数据集

本文在 5 个公共数据集上验证了 XSGCL 的性能: MovieLens、Douban-book、Yelp2018、Amazon-Kindle 和 Alibaba-iFashion。数据集的统计信息如表 1 所示。数据集分为训练集、验证集和测试集, 比例为 7:1:2。依据先前研究的方法^[1-2,4], 首先在验证集上优化超参数, 然后合并训练集和验证集进行模型训练, 最后在测试集上评估性能。

表 1 数据集统计信息
Table 1 Dataset statistics

Datasets	# Users	# Items	# Feedback	Density/%
MovieLens	6 040	3 952	1 000 209	0.042
Douban-book	23 298	41 215	598 420	0.062
Yelp2018	31 668	38 048	1 561 406	0.130
Amazon-Kindle	138 333	98 572	1 909 965	0.014
Alibaba-iFashion	300 000	81 614	1 607 813	0.007

3.2 评估指标

为了评估推荐结果的准确性, 本文采用了 2 个 Top-N 指标: 召回率 (Recall) 和归一化折损累积增益 (NDCG), 均设定 $N=10, 20$ 。为确保实验结果的

可靠性, 对所有候选物品进行全面排名, 并报告测试集中所有用户的平均结果。实验结果为 5 次训练迭代后的平均值, 以保证实验的严谨性和公正性。

3.3 参数设置

为了确保实验的公平性, 本文采用了各基准模型在参考文献中提供的源代码或 SELFRec (<https://github.com/Coder-Yu/SELFRec>) 框架来实现模型, 并使用了各自文献中报告的最优超参数设置。所有的实验均在同一台机器 (一个 Intel® Xeon® Gold 5218 CPU @2.30 GHz 和一个 Tesla V100-PCIe-32 GB GPU) 上运行。实验中设置早停的阈值为 10 次迭代无改善, 以 Recall@20 作为早停的评估指标。为保证不同模型间性能比较的公正性, 所有模型的表示嵌入均采用 Xavier 方法进行初始化, 嵌入的维度设置为 64, 设置超参数 $\lambda_2 = 10^{-4}$, 批量大小设置为 2 048, 且都使用 Adam 优化器, 学习率设置为 0.001。此外, 对于涉及到的每个物品的流行度指标 I_{pop} , 在实验中, 会在每次 XSGCL 训练前根据数据集的交互数据预先计算, 以确保这一处理不会影响 XSGCL 自身的训练和推理过程。

3.4 对比模型

为了证明 XSGCL 的有效性, 将它集成到 LightGCN 中, 并与下面这些代表性模型进行比较。

1) 基于图的模型。

LightGCN^[11]: 一种高效的轻量级图卷积网络, 常用作基于卷积神经网络 (GNN) 模型研究的基线。

DirectAU^[23]: 通过直接优化用户和物品表示的对齐和一致性来改进协同过滤, 显著提高了基于 GNN 和协同过滤的推荐模型的性能。

2) 基于图和数据增强的模型。

MixGCF^[24]: 引入一种将多个负样本合成为难负样本的通用负采样方法, 用于训练 GNN 推荐模型。

BUIR^[25]: 通过 2 个编码器网络并最小化交叉预测误差来学习用户和物品表示, 有效解决数据稀疏问题, 无需负样本采样。

SelfCF^[26]: 在不需要负样本或标签的情况下扰动孪生网络上的用户和物品嵌入, 有效地提高了推荐系统的训练速度和准确性。

3) 基于图 and 对比学习的模型。

SGL^[4]: 通过节点丢弃、边丢弃和随机游走的数据增强算子生成增强视图用于对比学习任务, 增强了节点表示的准确性和稳健性。本次实验默认采用边丢弃算子。

NCL^[16]: 结合图结构和语义空间邻居设计对比

学习任务,提高了数据稀疏环境中的推荐性能。

SimGCL^[1]:通过向嵌入空间添加均匀噪声创建增强视图,与基于图增强的方法相比,在推荐准确性和训练效率方面都显示出优势。

XSimGCL^[2]:利用层间对比学习简化了 SimGCL 的模型架构,在推荐准确性和训练效率方面都得到了提升。

3.5 模型性能比较与分析

本节对各种模型进行了全面的比较,重点关注 4 个方面:推荐准确性、训练效率、长尾物品的推荐

能力以及在不同交互密度场景下的推荐表现。

3.5.1 推荐准确性

表 2 显示了不同模型在 5 个数据集上的性能差异(最优值用加粗标示,次优值用下划线标示,下同)。可以明显地观察到,集成了 XSGCL 后的 LightGCN 推荐准确性在所有数据集上均显著提升,特别是在最稀疏的 Alibaba-iFashion 数据集上,Recall@20 和 NDCG@20 分别提升了 29.9% 和 33.5%。这一显著的提升证明了 XSGCL 在提高推荐模型表示上的有效性。

表 2 模型推荐准确性比较

Table 2 Comparison of model recommendation accuracy

数据集	指标	LightGCN	BUIR	SelfCF	NCL	DirectAU	MixGCF	SGL	SimGCL	XSimGCL	XSGCL
MovieLens	Recall@10	0.178 8	0.105 8	0.116 7	0.174 5	0.065 7	0.176 2	0.182 5	0.110 3	<u>0.182 7</u>	0.189 9
	NDCG@10	0.302 0	0.199 1	0.215 3	0.300 5	0.092 7	0.301 2	0.310 3	0.162 1	<u>0.315 8</u>	0.319 3
	Recall@20	0.270 6	0.181 1	0.197 3	0.259 9	0.106 2	0.272 7	0.274 6	<u>0.291 9</u>	<u>0.291 9</u>	0.292 7
	NDCG@20	0.303 6	0.213 1	0.230 7	0.294 2	0.100 4	0.306 0	0.309 7	0.324 9	0.327 4	<u>0.325 2</u>
Douban-book	Recall@10	0.097 5	0.116 2	0.054 3	0.101 2	0.100 5	0.128 4	0.122 5	0.120 4	0.119 2	<u>0.124 1</u>
	NDCG@10	0.114 9	0.137 9	0.060 7	0.118 6	0.113 6	0.158 1	0.144 5	0.142 6	0.143 7	<u>0.147 7</u>
	Recall@20	0.149 2	0.090 3	0.084 7	0.151 3	0.135 1	0.176 8	0.170 9	0.175 5	0.179 4	<u>0.177 3</u>
	NDCG@20	0.126 3	0.071 1	0.067 1	0.123 0	0.119 4	0.162 4	0.149 6	0.152 5	<u>0.157 2</u>	0.153 5
Yelp2018	Recall@10	0.034 5	0.040 7	0.024 3	0.034 4	0.042 1	0.040 9	0.039 8	0.043 1	0.041 7	<u>0.042 8</u>
	NDCG@10	0.039 4	0.046 7	0.028 1	0.039 6	0.048 4	0.046 9	0.045 3	0.049 2	0.047 7	<u>0.048 6</u>
	Recall@20	0.059 8	0.043 5	0.045 1	0.067 5	0.071 1	0.069 4	0.067 5	<u>0.072 4</u>	0.072 2	0.072 6
	NDCG@20	0.049 1	0.035 5	0.036 8	0.055 5	0.058 9	0.056 8	0.055 5	<u>0.059 7</u>	0.059 6	0.059 8
Amazon-Kindle	Recall@10	0.138 2	0.124 7	0.040 7	0.134 9	0.122 8	0.140 9	0.155 4	0.147 1	0.146 4	<u>0.150 8</u>
	NDCG@10	0.102 7	0.090 3	0.026 5	0.098 9	0.088 2	0.101 8	0.116 1	0.107 9	0.108 6	<u>0.112 1</u>
	Recall@20	0.188 8	0.070 1	0.062 8	0.190 3	0.174 8	0.205 1	<u>0.206 3</u>	0.200 1	0.205 9	0.207 9
	NDCG@20	0.120 0	0.038 1	0.033 4	0.118 1	0.103 6	0.125 3	0.130 3	0.125 2	<u>0.131 6</u>	0.132 3
Alibaba-iFashion	Recall@10	0.059 6	0.061 5	0.043 1	0.062 5	0.077 9	0.077 8	0.075 5	0.067 8	<u>0.078 4</u>	0.078 5
	NDCG@10	0.033 8	0.035 6	0.023 6	0.035 1	<u>0.045 2</u>	0.044 6	0.043 4	0.039 8	0.044 8	0.045 2
	Recall@20	0.088 3	0.070 9	0.06 4	0.091 4	0.113 0	0.112 7	0.109 9	0.114 9	0.103 4	<u>0.114 7</u>
	NDCG@20	0.040 9	0.031 6	0.028 5	0.042 9	0.054 8	0.054 4	0.052 5	0.054 8	0.048 8	<u>0.054 6</u>

对于基于图和数据增强的模型,DirectAU 的性能相对较差,可能是由于其优化过程中过度强调对齐指标,而忽略了其他重要的模型特性,导致错误对齐信息的识别。这种单一的优化焦点可能会导致模型在交互较少的数据环境下适应性不足。BUIR 和 SelfCF 在稀疏数据集上的表现不佳,可能是因为它们没有采用负样本采样,导致“模型坍塌”问题,即节点表示的分布过于集中,使得模型无法有效区分不同的节点。这种分布的过度集中削弱了模型在面对不同用户或物品时的区分能力。而 MixGCF 通过合成具有挑战性的负样本,有效地挖掘样本中的不变信息,从而在各个数据集上表现较好。这种方法通过增加模型对不同样本特征的敏感度,提高了其区分不同用户或物品

的能力。对于基于对比学习的模型 SGL、NCL、SimGCL、XSimGCL 和 XSGCL,在所有数据集上均表现优异,这反映出对比学习中的自监督信号能够显著提升推荐表现。此外,对比学习的引入也提供了一种解决“模型坍塌”问题的有效策略。因为该方法不仅强调节点间表示的对齐,还注重保持节点表示分布的均匀性,并且这种均匀性已被证明是提升推荐性能的关键因素^[1]。然而,NCL 在稀疏数据集上表现较差,可能是由于其聚类算法在获取节点原型时受到数据稀疏性的限制。而 SimGCL 和 XSimGCL 不考虑不同特征的方差特点,直接向节点的所有特征表示中添加均匀噪声,可能会对某些低方差特征造成过度扰动,生成失真的增强表示,从而损害下游的对比学习任务,导

致推荐性能的次优。相比之下, XSGCL 保持易受干扰的特征不变, 仅对变换范围大的特征进行特征扰动操作, 有效地保持了低方差特征的稳定性和语义一致性, 从而提高了模型的推荐性能。

值得注意的是, 从整体结果上看, XSGCL 仅获得与 SimGCL、XSimGCL 相当的性能, 可能的原因在于尽管 XSGCL 只对变换范围大的特征进行扰动, 但这些特征未必是推荐任务中最有信息量或最重要的特征。如果被扰动的特征并非对模型预测至关重要, 那么即使这种扰动方法相对保守和精确, 其对整体性能的提升也可能有限。另外, XSGCL、SimGCL 和 XSimGCL 都依赖于模型对于这些扰动的响应来学习鲁棒的特征表示。如果模型对特征中较小程度的扰动不够敏感, 导致未能充分激活模型的学习能力, 那么即使是更加精细的扰动方法也可能无法显著提升性能。这也提示在未来的研究中可以探索结合特征重要性评估和模型敏感度分析, 以发展更高效的特征扰动策略。

3.5.2 训练效率

为验证 XSGCL 可以提升推荐模型的训练效率, 将其与 LightGCN 和其他 3 种最先进的对比学习模型 (SGL、SimGCL 和 XSimGCL) 在 MovieLens、Yelp2018 和 Alibaba-iFashion 数据集上进行了比较, 结果如表 3 所示, 其中提升率为 XSGCL 的训练总时间相较于其他方法的提升百分比。所有模型的批量大小和模型层数的设置分别统一为 2 048 和 3, 以确保比较的公平性。结果表明, LightGCN 的单轮时间效率最高, 但整体收敛最慢。而集成 XSGCL 后的 LightGCN, 总训练时间被大幅缩短。由于 SGL 和 SimGCL 采用多通道对比学习设置, 每轮消耗时间最长, 几乎是 LightGCN 的 2 倍。而 XSimGCL 采用跨层对比方法代替多通道设置, 每轮时间缩短了近一半。由于 XSGCL 仅对

批次内的节点施加单次特征扰动来生成单个增强视图, 相较于其他方法, 它在训练效率上得到了极大的提升, 证明了其合理性。

表 3 训练效率比较

Table 3 Comparison of training efficiency

数据集	模型	单轮 时间/s	轮数/ 轮	训练总 时间/s	提升率/ %
MovieLens	LightGCN	5.3	227	1 203	58.8
	SGL	12.5	45	563	11.9
	SimGCL	12.1	137	1 658	70.1
	XSimGCL	6.6	<u>70</u>	462	-7.4
	XSGCL	<u>6.2</u>	80	<u>496</u>	—
Yelp2018	LightGCN	35.1	296	10 390	91.2
	SGL	82.4	26	2 142	57.1
	SimGCL	84.0	17	1 428	35.7
	XSimGCL	38.5	28	<u>1 077</u>	14.8
	XSGCL	<u>38.3</u>	<u>24</u>	918	—
Alibaba-iFashion	LightGCN	159.2	76	12 099	84.0
	SGL	263.1	14	3 683	47.5
	SimGCL	271.4	9	<u>2 443</u>	20.8
	XSimGCL	167.0	17	2 839	31.9
	XSGCL	<u>161.2</u>	<u>12</u>	1 934	—

3.5.3 推荐长尾物品的能力

为了验证 PBPR 可以缓解流行度偏见, 测试集被分为 10 组, ID 为 1~10, 每组包含相同数量的交互。ID 越高表明包含的热门项目越多。为了评估推荐性能, 选取了 NDCG@20 作为评估指标。选择 NDCG 指标的原因在于相对于 Recall 指标, 其能够综合考虑推荐结果的相关性和排名顺序, 特别适用于长尾物品推荐场景。因为它能够较好地反映用户对推荐结果的整体满意度, 同时有效区分推荐系统在冷门物品上的表现, 能够更真实地评估推荐系统的实际效果。

实验结果如图 4 所示, 相较于 XSGCL, 其他方

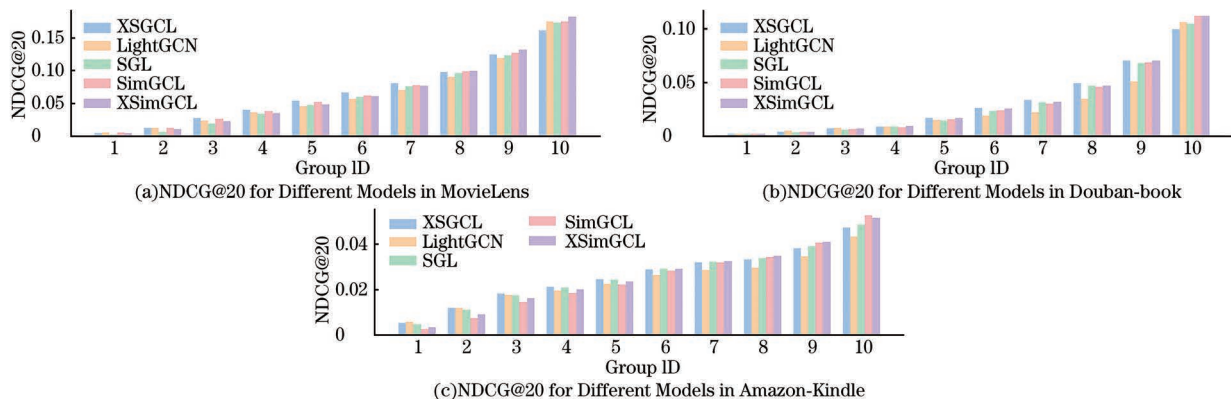


图 4 推荐长尾物品的能力比较

Fig. 4 Comparison of the ability to recommend long tail items

法都倾向于推荐流行物品,其中 XSimGCL、SGL 和 SimGCL 分别在 3 个数据集上获得最高的 NDCG 值。相比之下,XSGCL 在每个数据集上的第 10 组表现并不突出,但由于其在各组中的表现都很均衡,弥补了它在流行物品中的损失,最终获得整体最优的推荐性能。这表明在长尾分布的推荐场景下,引入流行度指标来平衡热门和冷门物品之间的表示是有必要且有益的。

3.5.4 交互密度对模型性能的影响

上一节展示了 XSGCL 在缓解流行度偏见问

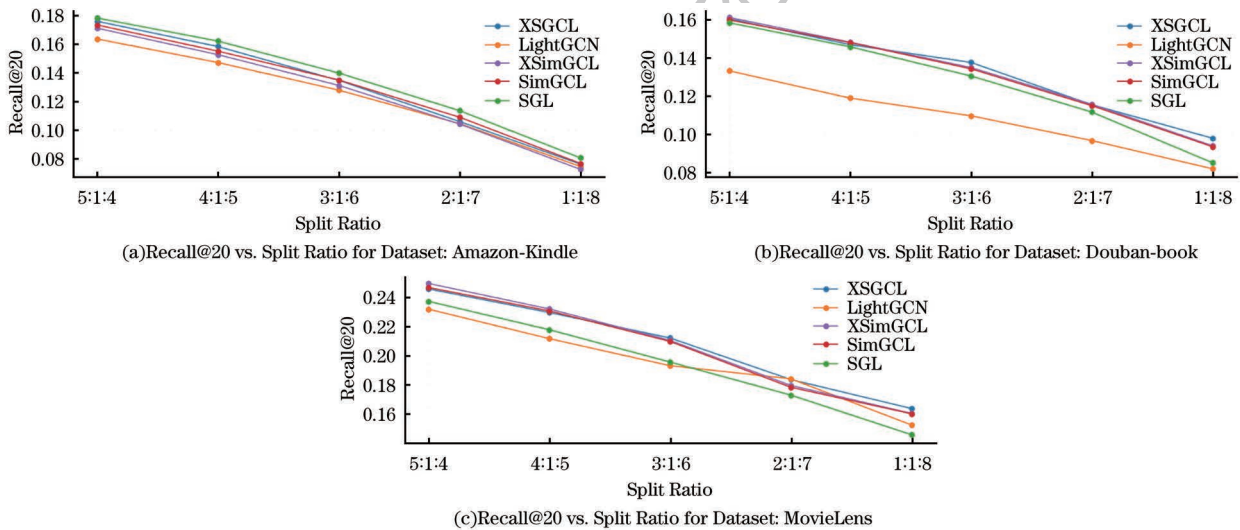


图 5 不同模型在不同交互密度场景下的性能比较

Fig.5 Performance comparison of different models in different interaction density scenarios

在数据密度相对较高的 MovieLens 和 Douban-book 数据集中,XSGCL 和 XSimGCL 在较小训练集的情况下表现优于其他模型,尤其是 XSGCL,在最少训练集的情况下表现最佳。这进一步证实了 XSGCL 在处理交互较少的节点上的优势。该优势可能源于 XSGCL 结合 HLVS 和对比学习的策略,帮助模型在引入适当噪声的情况下对这些节点进行有效的自监督学习。然而,在规模更大且数据更稀疏的 Amazon-Kindle 数据集中,采用多通道架构的 SimGCL 和 SGL 表现更佳。这可能是由于多通道架构的数据增强和对比学习操作独立于模型的预测表示,减少了对样本预测表示的干扰,并通过多路数据增强引入更多增强信息,即使在交互较少的条件下也能为模型带来了一些益处。相比之下,虽然 XSimGCL 和 XSGCL 采用了跨层对比和单次特征增强,但在训练数据较少时的表现不及多通道架构。值得注意的是,虽然多通道架构的这些优势会随着训练数据的丰富而逐渐消失,但这些观察结果依然启示未来的研究可以更多地关注如何在优化对比学习框架的同时,为模型提供足够的增强信息,以改善

题中的效果,并从侧面展示了其对交互较少物品的较强建模能力。为进一步验证这一效果,本节按不同比例(5:1:4、4:1:5、3:1:6、2:1:7、1:1:8)切分数据集,构造了不同密度的交互场景。结果如图 5 所示,随着训练集规模的减少,所有模型的性能均有所下降。值得注意的是,相较于 LightGCN,XSGCL 在每个数据集切分上的推荐性能均显著优于 LightGCN,验证了 XSGCL 对交互较少样本的建模能力,同时提升了模型的整体鲁棒性。

在交互较少场景下的节点表示。

3.6 XSGCL 通用性的实证分析

为了探讨 XSGCL 框架的通用性及其在其他图神经网络模型中的应用效果,本文选取了 NGCF 和 DGCF 作为基本的图编码模型,并将 XSGCL 框架集成其中。通过本节的实验,旨在观察 XSGCL 对模型在推荐准确性和训练效率方面的影响。

图 6、图 7 展示了集成 XSGCL 前后,NGCF 和 DGCF 模型在训练过程中 Recall@20 指标和对应训练损失的变化。从图中可以清晰地看到,在集成 XSGCL 后,无论是 NGCF 还是 DGCF 模型都能更快地收敛到最佳表现,并且其推荐准确性和训练效率均得到了显著提升。

具体来看,如表 4 所示,当 XSGCL 集成到 NGCF 模型中时,在 Douban-book 数据集上,Recall@20 从 0.122 3 提高到 0.136 7,训练总时长从 1 860 s 缩短至 874 s,显示了 XSGCL 在提升推荐性能和减少训练时间上的有效性。相似的趋势也观察到在 DGCF 模型上,其 Recall@20 从 0.082 9 提升至 0.155 1,同时训练总时长从 11 099 s 降低至

10 683 s。在 Amazon-Kindle 数据集上,XSGCL 的加入同样显著提升了 NGCF 和 DGCF 模型的表现。NGCF 模型的 Recall@20 从 0.126 7 提升至

0.143 8,训练总时长显著降低,从 22 175 s 减少至 4 246 s。DGCF 模型则从 0.158 5 提升至 0.177 0,训练时间从 209 890 s 显著减少至 66 036 s。




图 6 集成 XSGCL 后不同模型的训练过程 (Douban-book 数据集)

Fig. 6 The training process of different models after integrating XSGCL (on the Douban-book dataset)




图 7 集成 XSGCL 后不同模型的训练过程 (Amazon-Kindle 数据集)

Fig. 7 The training process of different models after integrating XSGCL (on the Amazon-Kindle dataset)

表 4 XSGCL 在不同模型上的表现

数据集	模型	Recall@20	轮数/轮	训练总时间/s
Douban-book	NGCF	0.122 3	81	1 080
	NGCF+XSGCL	0.136 7	49	874
	提升率/%	11.8	—	19.1
	DGCF	0.082 9	35	11 099
	DGCF+XSGCL	0.155 1	32	10 683
提升率/%	87.1	—	3.7	
Amazon-Kindle	NGCF	0.126 7	140	22 175
	NGCF+XSGCL	0.143 8	46	4 246
	提升率/%	13.5	—	80.9
	DGCF	0.158 5	166	209 890
	DGCF+XSGCL	0.177 0	53	66 036
提升率/%	11.7	—	68.5	

以上实验结果证明了 XSGCL 在提升图神经网络模型的推荐准确性和训练效率方面具有通用性和有效性。这一发现为 XSGCL 在推荐系统中的进一步应用提供了有力的支持和实证依据。

3.7 超参数影响

本节探索了 h_{ratio} 、 λ_1 和 ϵ 在固定 $L=3, \tau=0.2$ 的情况下对模型性能的影响。

3.7.1 超参数 h_{ratio}

超参数 h_{ratio} 的作用是调控高低方差特征的选择比例,以减少对敏感特征的大幅度扰动。为了探究 h_{ratio} 值对推荐性能的影响,本次实验固定了

XSGCL 在不同数据集上的最佳超参数 λ_1 和 ϵ ,并探讨了 h_{ratio} 在 $[0,1]$ 范围内对推荐性能的影响。性能评估指标包括 Recall@20 和 NDCG@20,具体实验结果如图 8 所示。

实验观察到,推荐性能的总体趋势基本上都是随着 h_{ratio} 的值先增高后降低,且在极端值 0 处表现最差,极端值 1 处表现一般。这里,0 表示未应用特征增强方法,而 1 则代表使用传统的特征增强方法,即对所有特征不加区分地施加随机噪声。当 h_{ratio} 的取值在 $[0.5, 0.7]$ 范围内时,模型的表现往往最佳。具体来说,如图 8(a)、图 8(b)和图 8(c)所示,在 MovieLens、Douban-book 和 Yelp2018 数据集上,设定 $h_{ratio}=0.5$ 时,模型展现出最佳的效果;如图 8(d)所示,在 Alibaba-iFashion 数据集上,最佳设定为 0.6;而在 Amazon-Kindle 数据集上,则为 0.7,如图 8(e)所示。出现这一现象可能是由于不同数据集的稀疏性不同,因此需要不同程度的扰动。MovieLens、Douban-book 和 Yelp2018 数据集的交互相对稠密,使得模型能够较好地从中学习信息,因此不需要引入较大范围的特征扰动来获取更多信息。相比之下,Alibaba-iFashion 和 Amazon-Kindle 这类较为稀疏且规模较大的数据集,由于模型难以从现有的交互行为中充分学习,因此需要通过增加信息的引入来增强模型的表达能力和鲁棒性。

以上结果表明,相比现有方法,本文提出的 HLVS

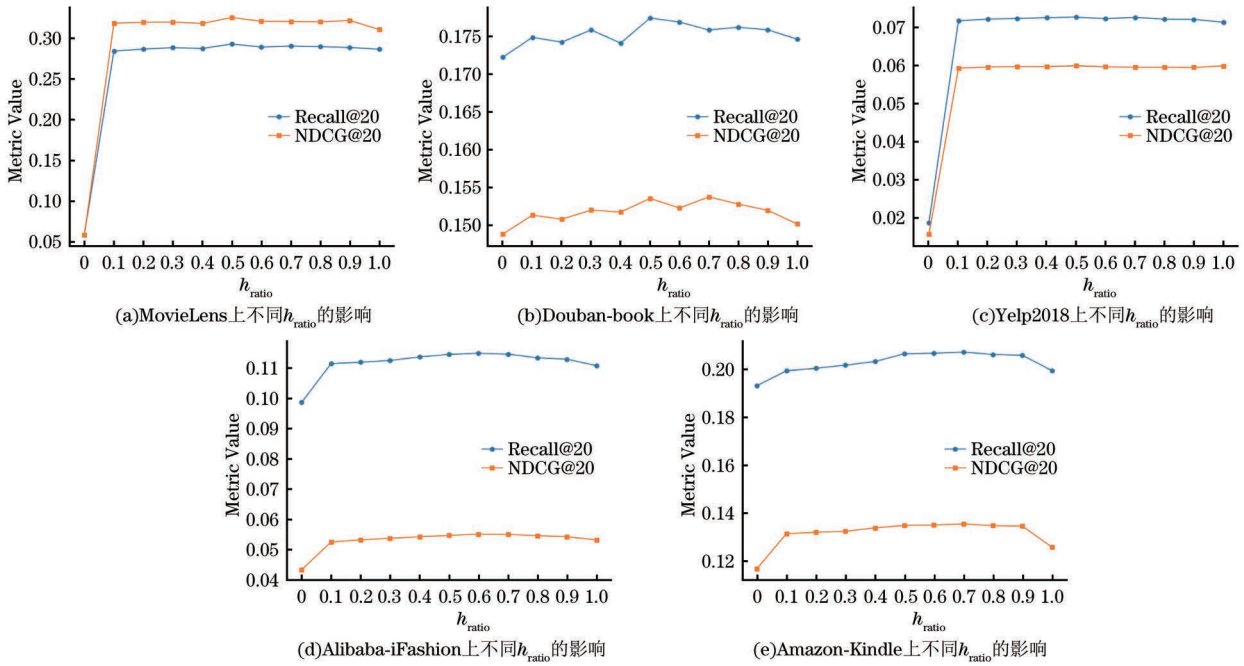


图 8 各数据集上不同 h_{ratio} 的影响

Fig. 8 The influence of different h_{ratio} on different datasets

方法能有效缓解增强过程中的语义失真,从而在对比学习中实现更优的表示增强,进一步提升推荐模型的性能。

3.7.2 超参数 λ_1 和 ϵ

图 9 展示了 λ_1 和 ϵ 的不同组合在 5 个数据集 中对推荐性能的具体影响。




图 9 各数据集上不同 λ_1 和 ϵ 的影响

Fig. 9 The influence of different λ_1 and ϵ on different datasets

超参数 λ_1 起到平衡主任务与辅助任务损失权重的作用。本次实验中, λ_1 的值设置为 $\{0.01, 0.02, 0.05, 0.1, 0.5, 0.7\}$ 。在数据集较为稀疏的环境下, 较为适中的 λ_1 值可以减少对辅助任务的依赖, 从而让模型更多地关注于捕捉稀疏的用户-物品交互数据, 这一调整对于大部分稀疏数据集是有

益的。如图 9(a)、图 9(b)、图 9(d)、图 9(e) 所示, 模型在不同数据集上表现最佳的 λ_1 值各不相同: 在 MovieLens、Douban-book 和 Amazon-Kindle 数据集上, 最优值都为 0.05; 而在 Alibaba-iFashion 数据集上为 0.02。在这些数据集上, λ_1 值的增减均显著影响模型性能。而对于用户-物品交互较稠密的数

数据集,例如 Yelp2018,如图 9(c)所示,较大的 λ_1 值有助于加强辅助任务的影响,甚至可以取值至 0.7,进而促进模型泛化能力的提升,避免过拟合。

超参数 ϵ 作为随机噪声大小的缩放因子,对模型的鲁棒性和语义损害具有直接影响。本次实验中 ϵ 的值设置为 $\{0.001, 0.005, 0.01, 0.05, 0.1\}$ 。在需要模型更精确捕获微小特征的稀疏数据集中,例如在 Douban-book 数据集中, ϵ 最优取值为 0.01;而在 Amazon-Kindle 和 Alibaba-iFashion 数据集中, ϵ 最优取值为 0.005。从图 9(b)、图 9(d)和图 9(e)中可见,在这些较稀疏的数据集上,模型对噪声大小极为敏感,随着噪声扰动幅度的增大,模型性能显著下降。因此,在稀疏数据集中选择较小的 ϵ 值有助于在不损害特征表示的前提下提高模型表达能力。另一方面,在数据较稠密的环境下,如 MovieLens 和 Yelp2018,如图 9(a)和图 9(c)所示,模型能够从数据集中现有的较丰富交互信息中充分学习,因此对噪声的扰动表现出较高的鲁棒性,即使噪声影响幅度增大,模型性能并未显示出显著下降。在这种情况下,可以尝试使用较大的 ϵ 值以进一步增强模型对噪声的抵抗力,从而提升模型的整体鲁棒性。

根据以上分析,可以根据数据集的稀疏度选择较优的超参数策略,并通过实验反馈反复调整。需要注意的是, λ_1 和 ϵ 的范围并不局限于本次实验,在实践中可能需要更广的范围和更精细的步长。

4 结束语

本文针对传统特征扰动方法可能导致的语义偏差问题,提出了一种高低方差分离的特征扰动策略 HLVS。通过仅对具有较高鲁棒性的高方差特征进行扰动,同时保持低方差特征不变,有效避免了原始特征表示中的语义丢失。此外,为了缓解推荐任务中的流行度偏差问题,设计了一种结合物品流行度指标的损失函数 PBPR,有效地平衡了热门物品和冷门物品之间的节点表示。最后,通过整合对比学习、HLVS 和 PBPR,设计了一个极其轻量且无参数的图对比学习框架 XSGCL,在提升推荐性能的同时,显著提高了模型的训练效率,并进一步增强了模型对长尾物品的推荐能力。这些创新为基于对比学习的协同过滤推荐提供了新的思路。未来的研究将进一步探索如何识别并扰动关键特征以生成更难识别的正负样本,再结合对比学习挖掘数据中更深层次的不变信息。

参考文献

- [1] YU J, YIN H, XIA X, 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, USA: ACM Press, 2022: 1294-1303.
- [2] YU J L, XIA X, CHEN T, et al. XSimGCL: towards extremely simple graph contrastive learning for recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 36(2): 1-14.
- [3] DENG H, LI Y L, JU S G, et al. Combines contrastive learning and primary capsule encoder for target sentiment classification[C]//Proceedings of International Conference on Web Information Systems and Applications. Singapore: Springer Nature Singapore, 2023: 284-296.
- [4] WU J C, WANG X, FENG F L, 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, USA: ACM Press, 2021: 726-735.
- [5] YANG Y H, WU L, HONG R C, et al. Enhanced graph learning for collaborative filtering via mutual information maximization [C]// Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2021: 71-80.
- [6] 姚迅,王海鹏,胡新荣,等.基于自适应增强的多视图对比推荐算法[J].计算机工程,2025,51(5):103-113.
YAO X, WANG H P, HU X R, et al. Multi-view contrastive learning for recommendation via adaptive augmentation[J]. Journal of Computer Engineering, 2025, 51(5): 103-113. (in Chinese)
- [7] TIAN Y, SUN C, POOLE B, et al. What makes for good views for contrastive learning? [J]. Advances in Neural Information Processing Systems, 2020, 33: 6827-6839.
- [8] ZHANG Y F, ZHU H, SONG Z X, et al. COSTA: covariance-preserving feature augmentation for graph contrastive learning [C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2022: 2524-2534.
- [9] 余鹏,杨佳琦,陈欣然,等.基于二部图对比学习的特征增强推荐算法[J].计算机工程,2025,51(7):100-110.
YU P, YANG J Q, CHEN X R, et al. Feature-enhanced recommendation algorithm based on bipartite graph contrastive learning [J]. Journal of Computer Engineering, 2025, 51(7): 100-110. (in Chinese)
- [10] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]//Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence. New York, USA: ACM Press, 2009: 452-461.
- [11] HE X N, DENG K, WANG X, 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, USA: ACM Press, 2020: 639-648.
- [12] ZHOU K, WANG H, ZHAO W X, et al. S3-Rec: self-supervised learning for sequential recommendation with mutual information maximization [C]//Proceedings of the 29th ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2020: 1893-1902.
- [13] XIE X, SUN F, LIU Z Y, et al. Contrastive learning for sequential recommendation [C]//Proceedings of the IEEE

- 38th International Conference on Data Engineering (ICDE). Kuala Lumpur, Malaysia: IEEE Press, 2022: 1259-1273.
- [14] 赵容梅, 孙思雨, 鄢凡力, 等. 基于对比学习的多兴趣感知序列推荐系统[J]. 计算机研究与发展, 2024, 61(7): 1730-1740.
- ZHAO R M, SUN S Y, YAN F L, et al. Multi-interest aware sequential recommender system based on contrastive learning [J]. Journal of Computer Research and Development, 2024, 61(7): 1730-1740. (in Chinese)
- [15] 钱忠胜, 黄恒, 朱辉, 等. 融合层注意力机制的多视角图对比学习推荐方法[J]. 计算机研究与发展, 2025, 62(1): 160-178.
- QIAN Z S, HUANG H, ZHU H, et al. Multi-perspective graph contrastive learning recommendation method with layer attention mechanism[J]. Journal of Computer Research and Development, 2025, 62(1): 160-178. (in Chinese)
- [16] LIN Z H, TIAN C X, HOU Y P, et al. Improving graph collaborative filtering with neighborhood-enriched contrastive learning[C]//Proceedings of the ACM Web Conference 2022. New York, USA: ACM Press, 2022: 2320-2329.
- [17] 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, USA: ACM Press, 2001: 285-295.
- [18] WANG X, JIN H Y, ZHANG A, et al. Disentangled graph collaborative filtering [C] // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2020: 1001-1010.
- [19] LIANG D W, KRISHNAN R G, HOFFMAN M D, et al. Variational autoencoders for collaborative filtering [C] // Proceedings of the 2018 World Wide Web Conference. New York, USA: ACM Press, 2018: 689-698.
- [20] HE X N, HE Z K, SONG J K, et al. NALS: neural attentive item similarity model for recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 30(12): 2354-2366.
- [21] WANG X, HE X N, WANG M, et al. Neural graph collaborative filtering [C] // Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2019: 165-174.
- [22] OORD A, LI Y, VINYALS O. Representation learning with contrastive predictive coding [EB/OL]. [2024-07-02]. <https://arxiv.org/abs/1807.03748>.
- [23] WANG C Y, YU Y Q, MA W Z, et al. Towards representation alignment and uniformity in collaborative filtering [C] // Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2022: 1816-1825.
- [24] HUANG T L, DONG Y X, DING M, et al. MixGCF: an improved training method for graph neural network-based recommender systems [C] // Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2021: 665-674.
- [25] LEE D H, KANG S, JU H, et al. Bootstrapping user and item representations for one-class collaborative filtering [C] // Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2021: 317-326.
- [26] ZHOU X, SUN A X, LIU Y, et al. SelfCF: a simple framework for self-supervised collaborative filtering [J]. ACM Transactions on Recommender Systems, 2023, 1(2): 1-25.

文字编辑 金胡考
栏目编辑 赖玉玲