



计算机科学

COMPUTER SCIENCE

基于自注意力机制的图对比学习推荐算法

胡金涛, 洗广铭

引用本文

胡金涛, 洗广铭. 基于自注意力机制的图对比学习推荐算法[J]. 计算机科学, 2025, 52(11): 82-89.

HU Jintao, XIAN Guangming. Self-attention-based Graph Contrastive Learning for Recommendation [J]. Computer Science, 2025, 52(11): 82-89.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[MDGRec:基于多元关系融合的移动应用第三方库推荐方法](#)

MDGRec:Multi-relation Aware Third-party Library Recommendation with Dual Graph NeuralNetworks for Mobile Application Development

计算机科学, 2025, 52(11): 320-329. <https://doi.org/10.11896/jsjcx.241200129>

[基于时空关节映射的骨架动作识别方法](#)

Spatial-Temporal Joint Mapping for Skeleton-based Action Recognition

计算机科学, 2025, 52(10): 106-114. <https://doi.org/10.11896/jsjcx.240800108>

[基于动态病情建模的药物组合推荐模型](#)

Drug Combination Recommendation Model Based on Dynamic Disease Modeling

计算机科学, 2025, 52(9): 96-105. <https://doi.org/10.11896/jsjcx.250300033>

[基于句法、语义和情感知识的方面级情感分析](#)

Aspect-based Sentiment Analysis Based on Syntax,Semantics and Affective Knowledge

计算机科学, 2025, 52(7): 218-225. <https://doi.org/10.11896/jsjcx.240500124>

[双向特征图增强的图卷积网络算法](#)

Two-way Feature Augmentation Graph Convolution Networks Algorithm

计算机科学, 2025, 52(7): 127-134. <https://doi.org/10.11896/jsjcx.240600090>

基于自注意力机制的图对比学习推荐算法

胡金涛 冼广铭

华南师范大学人工智能学院 广东 佛山 528225

(hujintao@m.scnu.edu.cn)

摘要 随着互联网数据的爆炸性增长,推荐系统已成为解决信息过载问题的关键技术。基于图对比学习的推荐模型通过增强用户-项目交互图,在提升模型性能方面展现出了显著的优势。尽管这些模型取得了一定成功,但现有的大多数方法是通过扰动图结构来进行数据增强,这种方式在保持内在语义结构时表现不佳,且容易受到噪声干扰的影响。为了进一步提升推荐模型的性能,提出了一种新颖的基于自注意力的图对比学习推荐算法(AttGCL)。一方面,集成的自注意力机制能够增强用户与项目之间的联系,从而更精确地捕捉用户偏好和个体差异性。另一方面,采用的 ICL 损失函数能有效控制正样本和负样本的重要性,从而更好地对齐全局和局部表示。该方法保留了关键的用户-项目交互语义,使得模型不仅能更准确地反映用户偏好,还提升了推荐效果。在 3 个真实数据集上的实验结果表明,AttGCL 在性能上显著优于现有的图对比学习方法,展示了在高效性和鲁棒性上的优势。

关键词: 推荐系统; 图对比学习; 自注意力机制; 图卷积网络; 对比损失函数

中图分类号 TP391

Self-attention-based Graph Contrastive Learning for Recommendation

HU Jintao and XIAN Guangming

School of Artificial Intelligence, South China Normal University, Foshan, Guangdong 528225, China

Abstract With the explosive growth of Internet data, recommender systems have become crucial for addressing the problem of information overload. Graph contrastive learning-based recommendation models have demonstrated significant advantages in enhancing model performance by improving user-item interaction graphs. Although these models have achieved some success, most existing methods rely on perturbing graph structures for data augmentation. However, this approach struggles to preserve the inherent semantic structure and is vulnerable to noise interference. To further enhance the performance of recommendation models, this paper proposes a novel self-attention-based graph contrastive learning recommendation algorithm (AttGCL). On the one hand, the integrated self-attention mechanism strengthens the connections between users and items, allowing the model to capture user preferences and individual differences more accurately. On the other hand, the ICL loss function effectively controls the importance of positive and negative samples, leading to better alignment between global and local representations. This method retains the essential semantics of user-item interactions, enabling the model to reflect user preferences more accurately and improve recommendation effectiveness. Experimental results on three real-world datasets show that AttGCL significantly outperforms existing graph contrastive learning methods in terms of performance, demonstrating its advantages in efficiency and robustness.

Keywords Recommendation system, Graph contrastive learning, Self-attention mechanism, Graph convolutional network, Contrastive learning loss

1 引言

随着互联网的发展,推荐系统已成为缓解信息过载问题的关键技术,并在各个领域得到了广泛应用。协同过滤(Collaborative Filtering, CF)^[1-2]是一种基于用户行为数据的推荐算法。其核心原理是,通过分析用户的历史行为数据来计算用户之间的相似度,然后根据相似用户或项目的

评价来预测用户对未知项目的偏好。这种方法更好地捕捉了用户的个性化需求,并推荐与用户兴趣相似的项目。例如,传统的用户-项目协同过滤方法使用评分矩阵进行预测,而基于邻域的方法则推荐寻找相似用户或相似项目。然而,随着图神经网络(Graph Neural Network, GNN)的出现,基于 GNN 的 CF 模型^[3-7]便通过节点之间的信息传递来捕捉依赖性,实现了显著的改进。这些模型使用不

到稿日期:2024-09-23 返修日期:2024-12-09

基金项目:华南师范大学研究生科研创新计划(21RJJC15)

This work was supported by the Scientific Research Innovation Project of Graduate School of South China Normal University(21RJJC15).

通信作者:冼广铭(16649995@qq.com)

同的技术(如谱方法、非谱方法和图卷积)来增强用户-项目交互建模。

深度学习技术的兴起进一步推动了推荐系统的发展,在推荐系统中应用深度学习模型已成为热门研究课题。通过利用深度神经网络,推荐系统可以自动学习用户和项目的特征表示,并捕捉复杂的非线性关系,从而更准确地理解用户兴趣并生成更个性化的推荐。图对比学习(Graph Contrastive Learning, GCL)技术通过比较用户或项目之间的相似性和差异性,进一步提高了推荐系统的准确性。文献[8-11]提出的模型通过创建对比视图,使用结构扰动和多层 GNN 来增强性能,从而改进了特征表示。

尽管这些对比推荐系统具有有效性,但它们也存在固有的局限性。首先,通过随机扰动进行的图增强可能会丢失有价值的结构信息,从而误导表示学习。其次,启发式指导的表示对比方案严重依赖于视图生成器,限制了模型的泛化能力,并使其容易受到噪声用户行为的影响。最后,大多数基于 GNN 的对比推荐系统都面临过平滑问题,导致表示难以区分。受已有成功模型的启发,将自注意力机制与 GCL 结合,以优化推荐系统。本文提出了一种新的基于自注意力的图对比学习推荐框架 AttGCL。在此模型中,自注意力机制通过显著增强用户与项目之间的联系来增强图,这有助于模型更好地捕捉用户之间的相似性和差异性,从而提高推荐系统的性能和个性化程度。AttGCL 借鉴了重要性感知对比学习(Importance-Aware Contrastive Learning, ICL)损失函数^[12],从全局角度对正负样本的重要性进行控制,使得全局协作与局部交互的表示更好地对齐,有效提升了对比学习效果。与生成两个单独的增强视图不同,本文的图对比学习范式很好地保留了用户-项目交互的重要语义,使得自增强表示能够同时反映用户特定的偏好和跨用户之间的局部依赖性。本文的主要贡献如下:

- 1)将评分作为辅助信息融入用户-项目交互图中,使得不同用户对不同项目的权重信息得以保留;
- 2)提出了一种有效且高效的图增强对比学习范式 AttGCL,该模型通过自注意力机制和 ICL 损失学习局部-全局协作关系,缓解了由不准确的对比信号引起的问题;
- 3)在 3 个真实世界的数据集上进行了广泛的实验研究,结果表明 AttGCL 优于多种基于 GCL 的基线方法。

2 相关工作

2.1 基于图神经网络的推荐系统

图神经网络通过节点之间的消息传递来捕获图上的依赖关系,其主要思想是迭代地聚合邻域信息并将其集成到当前节点表示中。例如,文献[13]提出了一种名为 DGRec 的图神经网络推荐系统,其通过子模邻居选择、层注意机制和损失重加权三大模块,在提高推荐多样性的同时保持了较高的准确性。文献[14]提出的 EGD-GNN 模型,通过构建全局项目链接图和应用通道感知机制来捕获项目间的复杂关系,并利用变分自编码器和滑动窗口策略在局部层面上学习用户意图的动态变化。该模型结合全局和局部信息,旨在提高序列推荐的准确性,并通过学习解耦的表示增强模型的可解释性。文献[15]简化了 NGCF 中的非线性变换,并使用基于求和的邻域池化表示。文献[16]基于社会关系和历史行为建模用户偏好,应用文献[17]的框架来捕获社交扩散。这些模型采用各种方法将 GNN 应用于推荐系统,实现了更准确的用户和项目建模,并提升了推荐系统的性能和个性化程度。

2.2 图对比学习在推荐中的应用

图对比学习是推荐系统中广泛使用的技术^[18-19],旨在通过比较用户或项目之间的相似性和差异性来提高推荐准确性和个性化。其主要思想是,利用图结构中的节点和边来表示用户和项目之间的关系,并通过比较来发现隐藏的模式。例如,文献[20]通过结构上扰动原始图来生成新图,并使用多层 GNN 进行嵌入学习和对比学习,以提高推荐性能。文献[21]使用自适应结构扰动结合对比学习来优化节点表示,擅长处理稀疏交互。文献[22]采用奇异值分解(Singular Value Decomposition, SVD),设计了一种新的图增强方法,对用户-项目交互图进行分解,并对结果矩阵应用对比学习,进一步优化节点特征。此外,文献[23]通过超图增强的跨视图对比学习框架捕获局部和全局的协作关系,更好地捕捉用户和项目之间的复杂依赖关系。这些模型显著改善了稀疏交互节点的表示,提高了推荐系统的整体准确性和个性化程度。

3 AttGCL

如图 1 所示,AttGCL 模型基于数据集构建初始的用户-项目交互图,对其进行归一化后输入 GCN^[24]中使用。

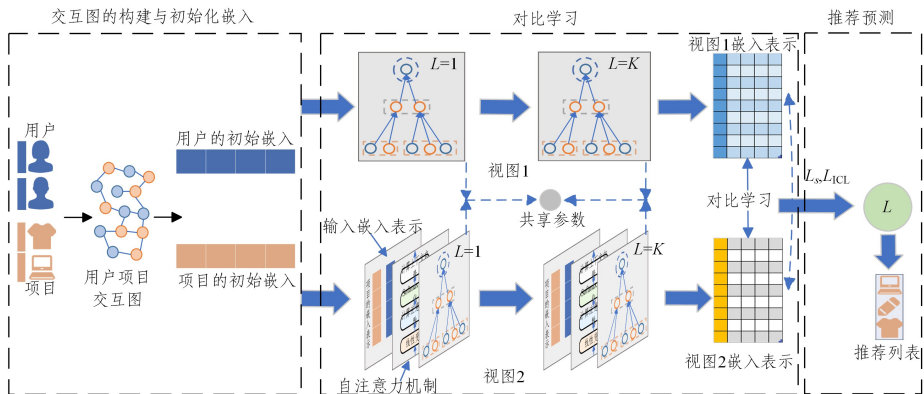


图 1 AttGCL 的框架

Fig. 1 Framework of AttGCL

模型通过视图 1 中的神经网络提取用户和项目之间的高阶关联特征,并对用户和项目节点的邻居信息进行聚合,从而捕获更深层的关系。在视图 2 中,引入了自注意力机制的神经网络,其可以动态调整权重,以丰富用户和项目关系的多样性,使模型更加灵活地根据不同关系学习用户特征。这两种视图虽然能够生成更优的特征视图,但可能缺乏优化信号来调整生成的视图以适应主要的 CF 任务。因此,采用了 ICL 损失函数,以平衡正负样本的重要性,从而缓解正样本不足且未被充分利用的问题。

3.1 局部图依赖建模

在协同过滤的常规做法中,为每个用户 u_i 和项目 v_j 分配一个嵌入向量 $e_i^{(u)} \in \mathbf{R}^d$ 和 $e_j^{(v)} \in \mathbf{R}^d$,其中 d 是嵌入的大小。所有用户和项目的嵌入集合分别定义为 $\mathbf{E}^{(u)} \in \mathbf{R}^{I \times d}$ 和 $\mathbf{E}^{(v)} \in \mathbf{R}^{J \times d}$,其中 I 和 J 分别是用户和项目的数量。如图 1 中的视图 1 所示,AttGCL 使用了 GCN 来聚合每个节点的邻域信息。在第 l 层,聚合过程表示如下:

$$\mathbf{z}_{i,l}^{(u)} = \sigma(p(\tilde{\mathbf{A}}_{i,\cdot}) \cdot \mathbf{E}_{\cdot,l}^{(v)}) \quad (1)$$

$$\mathbf{z}_{j,l}^{(v)} = \sigma(p(\tilde{\mathbf{A}}_{\cdot,j}) \cdot \mathbf{E}_{\cdot,l}^{(u)}) \quad (2)$$

其中, $\mathbf{z}_{i,l}^{(u)}$ 和 $\mathbf{z}_{j,l}^{(v)}$ 分别表示用户 u_i 和项目 v_j 在第 l 层的聚合嵌入; $\sigma(\cdot)$ 表示激活函数,此处为恒等函数; $\tilde{\mathbf{A}}$ 是经过归一化的邻接矩阵,在其上执行边丢弃操作,表示为 $p(\cdot)$,以减轻过拟合。节点的最终嵌入是来自所有层的嵌入之和,用户 u_i 和项目 v_j 的最终嵌入之间的内积预测了用户 u_i 对项目 v_j 的偏好。

$$\mathbf{e}_i^{(u)} = \sum_{l=0}^L \mathbf{z}_{i,l}^{(u)}, \mathbf{e}_j^{(v)} = \sum_{l=0}^L \mathbf{z}_{j,l}^{(v)} \quad (3)$$

$$\hat{y}_{i,j} = \mathbf{e}_i^{(u)\top} \mathbf{e}_j^{(v)} \quad (4)$$

3.2 引入自注意力机制

自注意力机制是一种用于处理序列数据的技术,被广泛应用于自然语言处理和推荐系统等领域。自注意力机制的计算过程可以表示为:

$$\text{Att}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^\top}{\sqrt{d_k}}\right)\mathbf{V} \quad (5)$$

其中, \mathbf{Q}, \mathbf{K} 和 \mathbf{V} 分别代表查询、键和值向量, d_k 是查询和键的维度。通过计算查询向量 \mathbf{Q} 与键向量 \mathbf{K} 的点积并除以缩放因子 $\sqrt{d_k}$,得到注意力分数。然后使用 softmax 函数将这些分数转换为权重,得到的权重被应用于值向量 \mathbf{V} ,以获得最终表示。在推荐系统中,自注意力机制有助于缓解数据稀疏性和监督信号不足的问题。通过采用自注意力机制,模型可以学习用户和用户之间、项目和项目之间的注意力分数,提取重要的协作信号,并自动关注重要的用户和项目。这允许模型学习更有效的嵌入向量,从而提高推荐性能。生成视图 2 嵌入表示的工作流程如图 2 所示。

具体来说,对于 GCN 网络的每一层,假设用户和项目的嵌入如下:

$$\mathbf{g}_i^{(u)} = \sigma(\tilde{\mathbf{A}} \cdot \mathbf{E}_{\cdot,l}^{(u)}) \quad (6)$$

$$\mathbf{g}_j^{(v)} = \sigma(\tilde{\mathbf{A}} \cdot \mathbf{E}_{\cdot,l}^{(v)}) \quad (7)$$

首先,根据以下自注意力公式进行计算。使用 $\mathbf{g}_i^{(u)}$ 和 $\mathbf{g}_j^{(v)}$ 作为自注意力机制的输入,计算相应的 $\mathbf{Q}_i^{(u)}, \mathbf{K}_i^{(u)}, \mathbf{V}_i^{(u)}$ 和 $\mathbf{Q}_j^{(v)}, \mathbf{K}_j^{(v)}, \mathbf{V}_j^{(v)}$ 。

$$\begin{cases} \mathbf{Q}_i^{(u)} = \mathbf{g}_i^{(u)} \times \mathbf{W}_{\text{query}} \\ \mathbf{K}_i^{(u)} = \mathbf{g}_i^{(u)} \times \mathbf{W}_{\text{key}} \\ \mathbf{V}_i^{(u)} = \mathbf{g}_i^{(u)} \times \mathbf{W}_{\text{value}} \end{cases} \quad (8)$$

$$\begin{cases} \mathbf{Q}_j^{(v)} = \mathbf{g}_j^{(v)} \times \mathbf{W}_{\text{query}} \\ \mathbf{K}_j^{(v)} = \mathbf{g}_j^{(v)} \times \mathbf{W}_{\text{key}} \\ \mathbf{V}_j^{(v)} = \mathbf{g}_j^{(v)} \times \mathbf{W}_{\text{value}} \end{cases} \quad (9)$$

其中, $\mathbf{W}_{\text{query}}, \mathbf{W}_{\text{key}}$ 和 $\mathbf{W}_{\text{value}}$ 是初始化的参数,对于第 l 层,将它们与 $\mathbf{g}_i^{(u)}$ 和 $\mathbf{g}_j^{(v)}$ 相乘,得到 $\mathbf{Q}_i^{(u)}, \mathbf{K}_i^{(u)}, \mathbf{V}_i^{(u)}$ 和 $\mathbf{Q}_j^{(v)}, \mathbf{K}_j^{(v)}, \mathbf{V}_j^{(v)}$ 。因此,第 l 层的注意力计算表示为:

$$\text{Att}(\mathbf{Q}_i^{(u)}, \mathbf{K}_i^{(u)}, \mathbf{V}_i^{(u)}) = \text{softmax}\left(\frac{\mathbf{Q}_i^{(u)}\mathbf{K}_i^{(u)\top}}{\sqrt{d_k}}\right)\mathbf{V}_i^{(u)} \quad (10)$$

$$\text{Att}(\mathbf{Q}_j^{(v)}, \mathbf{K}_j^{(v)}, \mathbf{V}_j^{(v)}) = \text{softmax}\left(\frac{\mathbf{Q}_j^{(v)}\mathbf{K}_j^{(v)\top}}{\sqrt{d_k}}\right)\mathbf{V}_j^{(v)} \quad (11)$$

结合式(10)和式(11)可以得到:

$$\mathbf{G}_i^{(u)} = \text{softmax}\left(\frac{\mathbf{Q}_i^{(u)}\mathbf{K}_i^{(u)\top}}{\sqrt{d_k}}\right)\mathbf{V}_i^{(u)} \quad (12)$$

$$\mathbf{G}_j^{(v)} = \text{softmax}\left(\frac{\mathbf{Q}_j^{(v)}\mathbf{K}_j^{(v)\top}}{\sqrt{d_k}}\right)\mathbf{V}_j^{(v)} \quad (13)$$

其中, $\mathbf{G}_i^{(u)}$ 和 $\mathbf{G}_j^{(v)}$ 是新生成的图结构视图中编码的用户和项目嵌入的集合。




图 2 生成视图 2 嵌入表示的工作流程

Fig. 2 Workflow for generating the embedded representation of view 2

为了提升模型的整体效率并优化内存使用,模型设计中引入了 K-Means 聚类算法和重叠批次处理两项技术。在模型训练前,先通过 K-Means 聚类对用户和项目进行批次划分,将相关性高的用户和项目分组。随后,通过重叠批次的方法实现批次间的数据共享,使相邻批次的数据存在一定重叠。这种设计不仅能确保同一批次内的用户和项目具有更高的关联性,还能够在批次间传递信息,从而实现更全面的全局信息捕捉,以增强模型的表达能力和对整体图信息的利用。

3.3 对比学习损失

传统的 GCL 方法,如 SGL^[20] 和 SimGCL^[25],构造了两个额外的视图来对比节点嵌入,而由原始图(主视图)生成的嵌入并不直接参与 InfoNCE^[26] 损失。这种复杂的三视图范式之所以被采用,是因为随机扰动增强可能会为主视图的嵌入带来误导性信号。然而,在 AttGCL 中,增强的视图是通过加强局部关系来构建的,在一定程度上提升了主视图的表示效果。因此,这一方法简化了对比学习框架,直接在 InfoNCE 损失中将自注意力增强的视图嵌入 $\mathbf{g}_{i,l}^{(u)}$ 与主视图嵌入 $\mathbf{z}_{i,l}^{(u)}$ 进行对比,如式(14)所示:

$$L_s^{(u)} = \sum_{i=0}^l \sum_{l'=0}^l -\log \frac{\exp(s(\mathbf{z}_{i,l}^{(u)}, \mathbf{g}_{i,l}^{(u)})/\tau)}{\sum_{i'=0}^l \exp(s(\mathbf{z}_{i,l}^{(u)}, \mathbf{g}_{i',l}^{(u)})/\tau)} \quad (14)$$

其中, $s(\cdot)$ 和 τ 分别表示余弦相似度和温度。

对项目的 InfoNCE 损失 $L_s^{(v)}$ 的定义,与式(14)中的 $L_s^{(u)}$ 相同。

3.4 模型训练

对比学习对处理的正样本和负样本同等对待,导致正样本和负样本之间的比例失衡问题。此外,在稀疏数据集中,正样本数量较少,理应得到更多关注。另一个关键问题在于,在推荐系统中,稀疏的正样本尚未被充分利用。因此,采用了 ICL 方法,该方法通过平衡正样本与负样本的重要性,并增强数据,有效地解决了以上问题。

$$L_{ICL} = -\frac{1}{N} \left(\sum_{(u,i) \in D} (\alpha f(u, i^+) / \tau) - (1-\alpha) \log \sum_{i \in I^-} \exp(f(u, i) / \tau) \right) \quad (15)$$

其中, $D = \{(u, i), u \in U, i \in I\}$ 是一个训练批次; U 和 I 分别是用户和项目的集合; i^+ 是目标用户 u 的正样本; I^- 是负样本的集合; $f(u, i)$ 用于计算 (u, i) 的相似度; α 是正样本的权重, $\alpha \in [0, 1]$ 。这种加权方法简单但有效地适应了各种数据集。结合式(14)和式(15),可以推导出最终的联合优化目标:

$$L = L_{ICL} + \lambda_1 \cdot (L_s^{(u)} + L_s^{(v)}) + \lambda_2 \cdot \|\Theta\|_2^2 \quad (16)$$

AttGCL 算法的伪代码如算法 1 所示。

算法 1 AttGCL 算法

输入: 用户集合 U , 项目集合 V , 用户项目交互列表

输出: 推荐列表

1. 构建邻接矩阵 A
2. 归一化邻接矩阵, 得到 \tilde{A} ;
3. 初始化所有参数;
4. for epoch $\leftarrow 0$ to total_epochs do;
5. for $l \leftarrow 1$ to L do;
6. $E_1^{(u)}, E_1^{(v)} \leftarrow$ 根据式(1)和式(2)计算;
7. $G_1^{(u)}, G_1^{(v)} \leftarrow$ 根据式(6)到式(13)计算;
8. end for // L
9. $L_s, L_{ICL} \leftarrow$ 根据式(14)和式(15)计算;
10. $L \leftarrow$ 根据式(16)计算损失函数;
11. 使用 Adam 更新参数;
12. end for // epoch
13. 返回推荐列表

4 实验

本章详细介绍了实验所需的数据集、评价指标和相关参数设置,并且进行了大量实验,以评估本文提出的 AttGCL 模型的有效性。实验结果可以回答以下研究问题:1)与各种先进的推荐系统相比,本文模型性能如何?2)AttGCL 的各个模块是如何为其在不同数据集上的整体性能做出贡献的?3)不同的超参数对 AttGCL 的推荐性能有何影响?

4.1 实验设置

4.1.1 数据集

本实验使用了 3 个公开的、不同大小、不同密度的数据集: LastFM, MovieLens 和 Yelp。

LastFM: LastFM 是一个在线音乐推荐和流媒体服务平台,可以记录用户听过的歌曲。LastFM 数据集包含用户的收听记录及相关信息,被广泛应用于音乐推荐系统的研究中。

MovieLens: MovieLens 数据集是由 GroupLens 研究团队

提供的电影推荐数据集,其中 ML-1M 表示包含 100 万个评分的数据集,本实验中使用了该版本的数据集。该数据集被广泛用于电影推荐系统的研究中。

Yelp: Yelp 是一个提供本地商业信息和用户评论的平台。Yelp 数据集包含大量用户评论和商业信息,被广泛应用于基于评论的推荐系统的研究中。

这些数据集的统计信息如表 1 所列。

表 1 实验数据集的统计信息

数据集	用户	项目	交互	密度
Last.FM	1892	17632	92834	0.00278
MovieLens	6040	3952	1000209	0.04200
Yelp	30912	66810	1033767	0.00050

4.1.2 评估协议

遵循 LightGCL, NGCF, LightGCN 和 SGL, 使用采用召回率 (Recall) 和归一化折损累积增益 (NDCG) 作为评估指标, 其中 $N = \{10, 20\}$ 。Recall 用于衡量测试数据中用户喜欢的项目在排名前 k 的列表中成功预测的数量。NDCG 考虑了项目的位置, 如果项目排名更靠前, 则会给出更高的分数。它是排名的一种度量, 因此对于 top-K 推荐很重要。这两个指标的值越大, 表示性能越好。

4.1.3 比较的基线方法

本实验通过将本文提出的 AttGCL 与各种基线进行比较来评估其性能。基线方法的详细信息如下。

LightGCN^[15]: 通过仅涉及线性变换和元素级加法的分层传播方案, 利用用户-项目交互图中的邻域信息。

SGL^[20]: 通过随机游走和节点/边丢弃来破坏图结构, 以进行数据增强, 从而将 LightGCN 与自监督对比学习相结合。

LightGCL^[22]: 特别利用奇异值分解 (SVD) 进行对比度增强, 从而通过全局协作关系建模实现无约束的结构细化。

HCCF^[23]: 使用超图编码全局图信息, 并将其与 GCN 编码的局部信息进行对比。

SHT^[27]: 在自监督学习范式下集成了超图神经网络和转换器, 以进行数据增强, 从而在推荐中去除用户-项目交互的噪声。

NeuMF^[28]: 一种基于神经网络的方法, 用多层神经网络替换传统矩阵分解中的点积运算, 允许模型捕获复杂的用户-项目交互并提供推荐。在比较中, 使用 NCF 的 NeuMF 变体。

ExpoMF^[29]: 构建了曝光概率的潜在变量, 使用 EM 算法进行参数优化, 并提出了基于流行度和内容的两个曝光概率参数模型。

4.1.4 参数设置

为了能够公平地进行比较, 综合考虑基线方法的参数并进行设置, 并且根据实验结果进行微调, 确保得到最佳性能。对于 AttGCL, 使用 Adam 优化方法, 学习率设置为 1×10^{-3} , 批量大小设置为 2048, 图卷积网络被设置成 2 层, 丢弃率设置成 0.1, 用户和项目的嵌入维度设置为 64, InfoNCE 损失的正则化权重 λ_1 设置为 $\{1 \times 10^{-4}, 1 \times 10^{-5}, 1 \times 10^{-6}, 1 \times 10^{-7}, 1 \times 10^{-8}\}$, 温度系数 τ 设置为 $\{0.1, 0.2, 0.4, 1.0, 2.0, 4.0\}$, 正样

本的权重 α 设置为 $\{0.4, 0.45, 0.5, 0.55, 0.6, 0.65, 0.7\}$ 。

4.2 总体性能比较

将 AttGCL 在 3 个数据集上与各种基线模型进行比较，

各模型在 Top-10 和 Top-20 评价指标上的实验结果如表 2 所列，其中粗体数据为当前指标下最好的性能，加下划线的数据为次优数据。根据表 2 数据，AttGCL 均优于基线模型。

表 2 AttGCL 在 Last.FM, MovieLens, Yelp 3 种数据集上与基线方法的性能比较

数据集	评价指标	AttGCL	LightGCL	SGL	SHT	LightGCN	HCCF	NeuMF	ExpoMF	提升百分比
Last.FM	Recall@10	0.1424	<u>0.1329</u>	0.1230	0.0799	0.0814	0.0676	0.1047	0.0842	7.14
	NDCG@10	0.1667	<u>0.1535</u>	0.1431	0.0906	0.0934	0.0758	0.1197	0.0927	8.60
	Recall@20	0.2128	<u>0.1840</u>	0.1832	0.1231	0.1287	0.1062	0.1542	0.1352	15.65
	NDCG@20	0.2041	<u>0.1098</u>	<u>0.1763</u>	0.1110	0.1195	0.0964	0.1454	0.1205	15.78
MovieLens	Recall@10	0.1585	0.0304	0.1133	0.1141	<u>0.1330</u>	0.1283	0.1224	0.0889	19.16
	NDCG@10	0.3479	0.1385	0.2703	0.3118	0.3057	<u>0.3425</u>	0.2995	0.1883	1.58
	Recall@20	0.2456	0.0516	0.1754	0.1793	<u>0.2248</u>	0.2043	0.1995	0.1476	9.25
	NDCG@20	0.3422	0.1262	0.2588	0.2921	0.3248	<u>0.3258</u>	0.2951	0.1942	5.03
Yelp	Recall@10	0.0816	<u>0.0740</u>	0.0729	0.0427	0.0570	0.0405	0.0406	0.0266	10.27
	NDCG@10	0.0811	<u>0.0727</u>	0.0724	0.0415	0.0538	0.0404	0.0379	0.0234	11.54
	Recall@20	0.1278	<u>0.1181</u>	0.1166	0.0696	0.0931	0.0671	0.0722	0.0472	8.20
	NDCG@20	0.0974	<u>0.0885</u>	0.0881	0.0516	0.0674	0.0500	0.0497	0.0312	10.06

评估结果显示，在 Top-10 和 Top-20 设置下，AttGCL 的性能超越了所有基线模型，这归功于所提出的对比学习框架在增强用户-项目交互数据方面的有效性。通过自注意力机制，AttGCL 能够充分利用有限的交互信息及用户与项目之间的关系，而 ICL 则平衡了正负样本的重要性，根据数据集的稀疏性调整正样本的权重。这两个模块的结合显著提升了用户和项目嵌入的学习效果，从而带来了更优质的推荐结果。AttGCL 在所有基于对比学习的基线模型中表现最佳，这一性能提升得益于对用户-项目交互信号和正负样本的注意力调整，有效增强了图对比学习。相比之下，其他基于对比学习的推荐系统（如 SGL, LightGCL, HCCF 等）则因受到噪声交互信息的影响，容易被误导性自监督信号干扰。总体而言，这些发现证明了所提出的对比学习方法在协同过滤中的有效性，并强调了为该任务设计有效的数据增强技术的重要性。

评估结果表明，自监督学习改善了现有的 CF 框架。这种改进得益于在输入数据中增加了一个提供正则化效果的增强学习任务。例如，SGL 采用随机数据增强生成多个视图，

而 LightGCL 通过 SVD 分解生成两类视图。然而，这些方法可能会丢失反映重要用户-项目交互模式的有用信号。相比之下，AttGCL 不依赖于随机数据增强来生成对比视图，而是基于用户-项目交互数据构建两种合理的视图。第一种视图捕获原始数据的关键模式，第二种视图进一步增强了用户和项目之间的交互信息。

4.3 消融实验

本节通过消融实验研究了 AttGCL 的关键模块对整体性能的影响和有效性。为了评估基于自注意力机制的数据增强技术和 ICL 损失函数的效率，将它们与常用的随机增强技术和 BPR 损失函数进行了比较。在消融实验中，自注意力机制的视图生成器被替换为随机边删除增强技术，ICL 损失函数被替换为传统的 BPR 损失函数。通过分别替换 AttGCL 中的两种模块，得到了 3 个变体方法：1) AttGCL-ICL，即替换了 ICL 模块；2) AttGCL-att，即替换了自注意力机制的数据增强模块；3) AttGCL-attICL，即同时替换两种模块。对不同变体进行重新训练和测试后，得到如表 3 所列的实验结果数据。

表 3 AttGCL 关键模块的消融实验结果

Table 3 Ablation study results of the key modules in AttGCL

数据集	评价指标	AttGCL-attICL	AttGCL-ICL	AttGCL-att	AttGCL
Last.FM	Recall@20	0.1381	0.1017	0.1441	0.2113
	NDCG@20	0.1268	0.0983	0.1298	0.2032
MovieLens	Recall@20	0.1565	0.1735	0.1747	0.2454
	NDCG@20	0.2672	0.2735	0.2596	0.3404
Yelp	Recall@20	0.0699	0.0739	0.0907	0.1281
	NDCG@20	0.0522	0.0561	0.0638	0.0973

从表 3 可以得出，与使用随机排列的对比视图生成器 (Edge D) 相比，AttGCL 方法的性能显著降低。这表明，随机增强方法在协同过滤中可能不足以生成信息丰富的对比视图。相比之下，基于自注意力机制的视图生成器对实现更好的结果至关重要。自注意力机制通过灵活的加权和强大的表达能力显著增强了用户之间的联系，这有助于模型更好地捕捉用户之间的相似性和差异性，从而提高推荐系统的性能和个性化程度。此外，在 3 个数据集上，AttGCL-ICL 的性能均低于 AttGCL。这表明，仅使用自注意力机制的视图生成器

和原始的用户-项目交互图进行对比训练可能不足以在协同过滤中实现最佳性能。引入 ICL 损失函数进行任务感知的视图生成器训练可以获得更好的性能，因为 ICL 通过平衡正负样本的重要性，解决了数据集中正样本的数据量小且利用率低的问题。这强调了将任务感知信息纳入视图生成器训练中的重要性，有助于捕获更多相关的用户-项目交互模式，从而提高生成的对比视图的质量。

4.4 超参数分析

本节通过实验研究了 AttGCL 对几个关键超参数的敏感

性。AttGCL 有 3 个重要的超参数:InfoNCE 损失的正则化权重 λ , 温度系数 τ , 以及正样本的权重 α 。

4.4.1 正则化权重 λ 的影响

本小节研究的是正则化权重 λ 对 AttGCL 的影响。在保证其他参数不变的情况下,通过调整 λ 的值来观察 AttGCL 的性能变化。图 3 给出了 AttGCL 分别在 Last.FM, MovieLens 和 Yelp 数据集上不同正则化权重 λ 的实验结果,横坐标为正则化权重 λ 的值,纵坐标为评价指标的值。在 Last.FM 数据集上,当 λ 从 1×10^{-4} 变化到 1×10^{-6} 时,AttGCL 的 Recall@20 和 NDCG@20 指标均呈下降趋势;进一步将 λ 调整到 1×10^{-8} 时,两项指标则呈现相反的变化。在 MovieLens 数据集上,AttGCL 性能先升后降。在 Yelp 数据集上,AttGCL 的性能则呈逐渐上升趋势。实验结果表明,在 Last.FM 数据集上,小幅度调整 λ 对 Recall 和 NDCG 影响不大,因为该数据集在低正则化下已具有较好的表示能力,进一步降低 λ 反而会带来波动。对于 MovieLens 数据集,适中的正则化显著提升了性能,既避免了过拟合,又保留了模型的复杂性;但当 λ 继续减小时,模型过拟合训练数据,泛化能力下降,Recall 和 NDCG 指标随之降低。这表明 MovieLens 数据集对正则化较为敏感,过高或过低的正则化均会影响模型表现。相较于其他数据集,Yelp 数据集的稀疏性较高,因此模型在低正则化下获得了更好的特征表达能力,但受限于数据稀疏,其增益不如 MovieLens 显著。

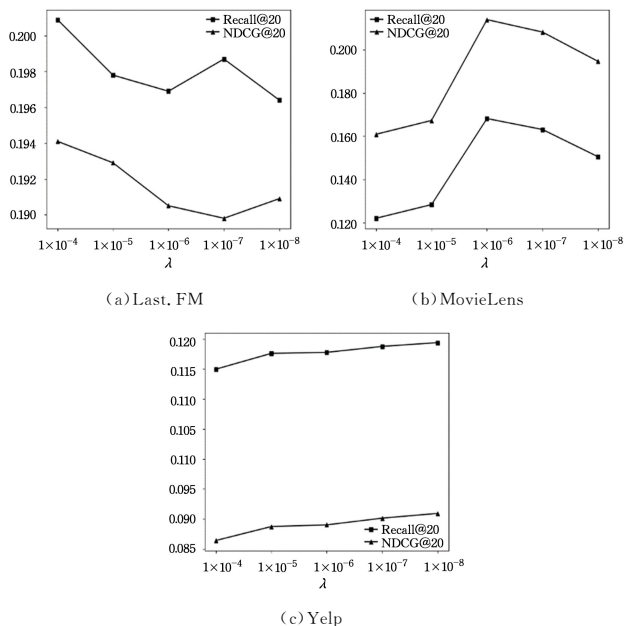


图3 正则化权重 λ 对 AttGCL 性能的影响

Fig. 3 Effect of regularization weights λ on AttGCL

4.4.2 温度系数 τ 的影响

本小节研究的是温度系数 τ 对 AttGCL 的影响。在保证其他参数不变的情况下,通过调整 τ 的值来观察 AttGCL 的性能变化。图 4 给出了 AttGCL 分别在 Last.FM, MovieLens 和 Yelp 数据集上不同温度系数 τ 的实验结果,横坐标为温度系数 τ 的值,纵坐标为评价指标的值。在 3 个数据集上,AttGCL 的性能均呈现先上升后下降的趋势。在 Last.FM 和

MovieLens 数据集上,当温度系数 τ 从 0.1 增加至 0.4 时,AttGCL 性能逐渐上升;当 τ 进一步增加到 4.0 时,AttGCL 性能则急剧下降。在 Yelp 数据集上也观察到了相同趋势,即 AttGCL 的性能在达到最优后逐渐下降。因此,对于 Last.FM 和 MovieLens 数据集, $\tau=0.4$ 时 AttGCL 性能最佳;而对于 Yelp 数据集,最佳性能出现在 $\tau=0.2$ 时。实验结果表明,在 LastFM 数据集上,适中的温度系数有助于平衡推荐的多样性和准确性。温度系数 τ 过低时,推荐集中于高概率项目,结果偏单一;过高的 τ 则会降低推荐置信度,使推荐更随机,从而影响 Recall 和 NDCG。在 MovieLens 数据集中,适中的温度系数 τ 提高了推荐的多样性和准确性,此时模型不会将权重集中于少数项,而是扩展到更多高相关性项目;当 τ 较大时,推荐的随机性增加,导致 Recall 和 NDCG 指标下降。对于 Yelp 数据集,较低的温度 τ 系数带来了最佳表现,说明其推荐对准确性要求较高。适中的 τ 值有助于集中推荐高相关性项目,而较高的 τ 值会使推荐过于分散,导致推荐质量下降。因此,对于稀疏性较高的数据集,其推荐效果对温度系数的变化尤为敏感,优化性能时需要结合数据集特性进行针对性调整。

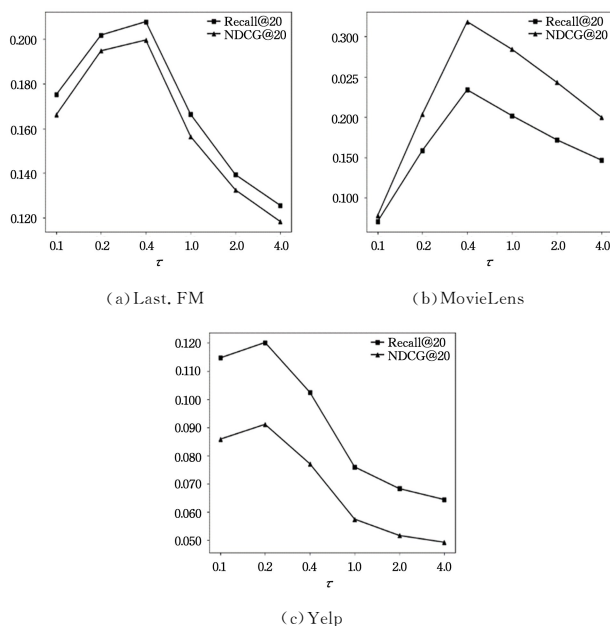


图4 温度系数 τ 对 AttGCL 性能的影响

Fig. 4 Effect of temperature coefficient τ on AttGCL

4.4.3 正样本的权重 α 的影响

本小节研究的是正样本的权重 α 对 AttGCL 的影响。在保证其他参数不变的情况下,通过调整 α 的值来观察 AttGCL 的性能变化。如图 5 所示,横坐标为 α 的变化值,纵坐标为评价指标。随着 α 的增加,在 LastFM 和 Yelp 数据集上,模型性能呈现下降趋势;而在 MovieLens 数据集上,性能先增加后降低。在 LastFM 数据集上, $\alpha=0.45$ 时,AttGCL 的最佳性能达到最高;在 MovieLens 数据集上, $\alpha=0.65$ 时,AttGCL 性能最佳;在 Yelp 数据集上, $\alpha=0.4$ 时,AttGCL 性能最佳。实验结果表明,在密度较低的数据集(如 LastFM 和 Yelp)中,用户对正样本的交互可能非常稀疏。这使得模型在处理正样本时可能会受到限制,导致对负样本的重视程度提高,因此需

要更低的 α 值来优化模型性能。在密度较高的数据集(如 MovieLens)中,可能存在更多的负样本信息,这使得模型能够

更好地学习负样本特征。在这种情况下,提高 α 值可以促进对正样本的重视,从而提高 Recall 和 NDCG。




图5 正样本的权重 α 对 AttGCL 的影响

Fig. 5 Effect of positive sample weights α on AttGCL

结束语 本文提出了一种简洁而有效的增强方法,用于图对比学习框架下的推荐系统优化。具体而言,模型通过自注意力机制从全局角度捕获用户和项目的内在语义,构建更丰富的对比视图,从而提升模型在不同数据场景下的适应能力。相比于传统的 BPR 损失函数,本文引入了 ICL 损失函数,旨在根据数据集的特点,灵活地调整正负样本的权重,以更好地适应数据分布的差异。实验结果表明,该图增强范式在多个公开数据集上实现了新的先进性能,尤其在数据稀疏性场景下展现了显著的抗稀疏能力。未来工作将聚焦于将用户和项目的属性信息纳入轻量级图对比学习模型,以进一步提升推荐效果,并有效减轻数据增强可能引发的混淆效应。

参考文献

- [1] ALHARBE N, RAKROUKI M A, ALJOHANI A. A collaborative filtering recommendation algorithm based on embedding representation[J]. *Expert Systems with Applications*, 2023, 215: 119380.
- [2] CHEN J, LIAN D, JIN B, et al. Fast Variational AutoEncoder with Inverted Multi-Index for Collaborative Filtering[C]// *Proceedings of the ACM Web Conference 2022*. New York: ACM, 2022: 1944-1954.
- [3] WANG J, MEI H, LI K, et al. Collaborative filtering model of graph neural network based on random walk[J]. *Applied Sciences*, 2023, 13(3): 1786.
- [4] HE L, WANG X, WANG D, et al. Simplifying Graph-based Collaborative Filtering for Recommendation[C]// *Proceedings of the 16th ACM international Conference on Web Search and Data Mining*. 2023: 60-68.
- [5] WU S, SUN F, ZHANG W, et al. Graph neural networks in recommender systems: a survey[J]. *ACM Computing Surveys*, 2022, 55(5): 97.
- [6] LIANG X, CHEN T, CUI L, et al. Lightweight Embeddings for Graph Collaborative Filtering[C]// *Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2024: 1296-1306.
- [7] LI C, KOU Y, SHEN D, et al. Cross-grained neural collaborative filtering for recommendation[J]. *IEEE Access*, 2024, 12: 48853-48864.
- [8] CHEN J, ZHOU J, MA L. Gnncl: A graph neural network recommendation model based on contrastive learning[J]. *Neural Processing Letters*, 2024, 56(2): 45.
- [9] WANG Y, ZHOU K, MIAO R, et al. AdaGCL: Adaptive Subgraph Contrastive Learning to Generalize Large-scale Graph Training[C]// *Proceedings of the 31st ACM International Conference on Information & Knowledge Management*. New York: ACM, 2022: 2046-2055.
- [10] YU J, 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): 913-926.
- [11] XIE X, SUN F, LIU Z, et al. Contrastive Learning for Sequential Recommendation[C]// *2022 IEEE 38th International Conference on Data Engineering (ICDE)*. IEEE, 2022: 1259-1273.
- [12] TANG H, ZHAO G, WU Y, et al. Multisample-based contrastive loss for top-k recommendation[J]. *IEEE Transactions on Multimedia*, 2023, 25: 339-351.
- [13] YANG L, WANG S, TAO Y, et al. Dgrec: Graph Neural Network for Recommendation with Diversified Embedding Generation[C]// *Proceedings of the 16th ACM International Conference on Web Search and Data Mining*. 2023: 661-669.
- [14] LI Y Y, HAO Y J, ZHAO P P, et al. Edge-enhanced global disentangled graph neural network for sequential recommendation[J]. *ACM Transactions on Knowledge Discovery from Data*, 2023, 17(6): 80.
- [15] 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: ACM, 2020: 639-648.
- [16] HU B, ZHOU N, ZHOU Q, et al. Diffnet: a learning to compare deep network for product recognition[J]. *IEEE Access*, 2020, 8: 19336-19344.
- [17] HAMILTON W L, YING R, LESKOVEC J, et al. Inductive Representation Learning on Large Graphs[C]// *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Curran Associates Inc., 2017: 1025-1035.
- [18] GONG X, YANG C, SHI C, et al. MA-GCL: Model augmenta-

- tion tricks for graph contrastive learning[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2023; 4284-4292.
- [19] YU J, XIA X, CHEN T, et al. XSimGCL: Towards extremely simple graph contrastive learning for recommendation[J]. IEEE Transactions on Knowledge & Data Engineering, 2024, 36(2): 913-926.
- [20] WU J, WANG X, FENG F, et al. Self-supervised Graph Learning for Recommendation[C]// Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2021; 726-735.
- [21] WANG Y, ZHOU K, MIAO R, et al. AdaGCL: Adaptive Sub-graph Contrastive Learning to Generalize Large-scale Graph Training[C]// Proceedings of the 31st ACM International Conference on Information & Knowledge Management. ACM, 2022; 2046-2055.
- [22] CAI X, HUANG C, XIA L, et al. LightGCL: Simple Yet Effective Graph Contrastive Learning for Recommendation[C]// The 11th International Conference on Learning Representations, 2023.
- [23] XIA L, HUANG C, XU Y, et al. Hypergraph Contrastive Collaborative Filtering[C]// Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2022; 70-79.
- [24] KIPF T N, WELING M. Semi-Supervised Classification with Graph Convolutional Networks[C]// International Conference on Learning Representations, 2017.
- [25] 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. ACM, 2022; 1294-1303.
- [26] OORD A, LI Y, VINYALS O. Representation learning with contrastive predictive coding[J]. arXiv:1807.03748, 2018.
- [27] XIA L, HUANG C, ZHANG C, et al. Self-Supervised Hypergraph Transformer for Recommender Systems[C]// Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. ACM, 2022; 2100-2109.
- [28] HE X, LIAO L, ZHANG H, et al. Neural Collaborative Filtering [C] // Proceedings of the 26th International Conference on World Wide Web. International World Wide Web Conferences Steering Committee, 2017; 173-182.
- [29] LIANG D, CHARLIN L, MCINERNEY J, et al. Modeling User Exposure in Recommendation[C]// Proceedings of the 25th International Conference on World Wide Web. International World Wide Web Conferences Steering Committee, 2016; 951-961.



HU Jintao, born in 1999, postgraduate. His main research interests include recommendation systems and information retrieval.



XIAN Guangming, born in 1975, Ph.D., associate professor. His main research interests include artificial intelligence, machine learning, big data and data mining.

(责任编辑:喻黎)