

### 基于轻量级图卷积和隐式反馈增强的多样化推荐

黄春淦, 王桂平, 吴波, 白鑫

引用本文

黄春淦, 王桂平, 吴波, 白鑫. 基于轻量级图卷积和隐式反馈增强的多样化推荐[J]. 计算机科学, 2024, 51(6A): 230900038-11.

HUANG Chungan, WANG Guiping, WU Bo, BAI Xin. [Diversified Recommendation Based on Light Graph Convolution Networks and Implicit Feedback Enhancement](#) [J]. Computer Science, 2024, 51(6A): 230900038-11.

---

### 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)

[结合图卷积神经网络和集成方法的推荐系统恶意攻击检测](#)

Malicious Attack Detection in Recommendation Systems Combining Graph Convolutional Neural Networks and Ensemble Methods

计算机科学, 2024, 51(6A): 230700003-9. <https://doi.org/10.11896/jsjcx.230700003>

[基于相似网络融合算法的癌症亚型预测](#)

Cancer Subtype Prediction Based on Similar Network Fusion Algorithm

计算机科学, 2024, 51(6A): 230500006-7. <https://doi.org/10.11896/jsjcx.230500006>

[基于双重方向向量的大规模多目标进化算法](#)

Dual Direction Vectors-based Large-scale Multi-objective Evolutionary Algorithm

计算机科学, 2024, 51(6A): 230700155-11. <https://doi.org/10.11896/jsjcx.230700155>

[基于图卷积和注意力神经网络的旅行商问题新解法](#)

New Solution for Traveling Salesman Problem Based on Graph Convolution and Attention Neural Network

计算机科学, 2024, 51(6A): 230700222-8. <https://doi.org/10.11896/jsjcx.230700222>

[基于不变图卷积神经网络的文本分类](#)

Text Classification Based on Invariant Graph Convolutional Neural Networks

计算机科学, 2024, 51(6A): 230900018-5. <https://doi.org/10.11896/jsjcx.230900018>

# 基于轻量级图卷积和隐式反馈增强的多样化推荐

黄春淦 王桂平 吴波 白鑫

重庆交通大学信息科学与工程学院 重庆 400074

(cghuang1116@163.com)

**摘要** 近年来,研究人员一直在努力提高推荐系统的准确性,而忽视了多样化对用户满意度的重要影响。目前大多数多样化推荐算法在传统算法生成的准确性候选列表后施加多样性约束进行后处理。然而,这种解耦设计总是导致推荐系统的次优状态。与此同时,尽管利用图卷积神经(Graph Convolution Networks,GCN)的推荐算法在提高推荐准确性方面的有效性已得到证实,但用于推荐的适用性和多样性设计仍然被忽视。此外,推荐算法采用用户购买这一单一的显式反馈无可避免地陷入“推荐过剩”。因此,提出一种端到端的多样化轻量级图卷积网络推荐模型(Diversified Light Graph Convolution Networks Recommendation,DLGCRec)来克服以上弊端。首先,将图卷积简化为轻量级图卷积(Light Graph Convolution Networks,LGCN)以便于推荐,并利用轻量级图卷积将多样化推向上游准确性匹配推荐过程。然后,在轻量级图卷积的采样阶段,利用引入了用户隐式反馈的多样性增强负采样来探索用户的多样化偏好。最后,利用多层特征融合策略捕获节点的完整特征嵌入,提升推荐性能。在真实数据集上进行实验,结果验证了DLGCRec在适用推荐和提升多样性方面的有效性。进一步的消融研究证实,DLGCRec有效地缓解了准确性-多样性困境。

**关键词:**推荐系统;多样性;图卷积;隐式反馈;准确性-多样性困境

中图分类号 TP391

## Diversified Recommendation Based on Light Graph Convolution Networks and Implicit Feedback Enhancement

HUANG Chungan, WANG Guiping, WU Bo and BAI Xin

School of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China

**Abstract** In recent years, researchers have been striving to improve the accuracy of recommendation systems while ignoring the critical impact of diversity on user satisfaction. Most current diversified recommendation algorithms impose diversity constraints after the accuracy candidate list generated by traditional post-processing algorithms. However, this decoupled design consistently results in a sub-optimal system. Meanwhile, although the effectiveness of recommendation algorithms using graph convolution networks(GCN) in improving recommendation accuracy has been demonstrated, the applicability and diversity design for recommendation remain neglected. In addition, recommendation algorithms employing a single explicit user feedback of purchasing inevitably fall into “recommendation overload”. Therefore, an end-to-end diversified light graph convolution networks recommendation (DLGCRec) is proposed to overcome these drawbacks. Firstly, GCN is simplified to light graph convolution networks(LGCN) to be suitable for recommendation, and LGCN is utilized to push diversity upstream to the recommendation process of accuracy match. Then, in the sampling phase of LGCN, diversity-boosted negative sampling that introduces user implicit feedback is utilized to explore the user’s diversified preferences. Finally, a multi-layer feature fusion strategy is utilized to capture the complete feature embedding of the nodes to enhance the recommendation performance. Experimental results on real datasets validate the effectiveness of DLGCRec in applying in recommendations and enhancing diversity. Further ablation studies confirm that DLGCRec effectively mitigates the accuracy-diversity dilemma.

**Keywords** Recommendation systems, Diversity, Graph convolution networks, Implicit feedback, Accuracy-diversity dilemma

## 1 引言

推荐系统通常利用用户过去与项目的交互历史来推断他们的偏好和兴趣,选择最符合他们偏好的项目来提高系统的

准确性。然而,目前大多数推荐算法都把重点放在提高推荐的准确性上,但准确的推荐并不是必要的、令人满意的推荐<sup>[1]</sup>。影响用户对推荐内容感知的因素众多,如新鲜度、及时性、可靠性、多样性、可解释性等。21世纪初,推荐系统的多

基金项目:国家自然科学基金(62073051);重庆交通大学研究生教育创新基金(2020S0054)

This work was supported by the National Natural Science Foundation of China(62073051)and Chongqing Jiaotong University Graduate Education Innovation Foundation(2020S0054).

通信作者:王桂平(wgp@cqjtu.edu.cn)

样性作为提高用户对推荐结果满意度的重要因素开始引起研究人员的关注。推荐的多样性是推荐质量的一个重要方面,并且多样性将直接影响用户在推荐场景中的参与度<sup>[2]</sup>,仅仅考虑准确性会导致“信息过载”和“信息茧房”。更具体地说,推荐结果受用户和推荐项目之间的相似性以及推荐项目内部的不相似性的影响,这些因素共同构成了推荐效果。推荐项目缺乏多样性会导致用户因重复而产生挫败感。多样化的推荐可以提高满足用户需求的可能性,避免同质化内容,发掘用户的潜在兴趣。

目前许多推荐系统中的多样化算法都是通过推荐系统生成的准确性候选推荐项目之后施加多样性约束来实现的。这种解耦设计使得推荐系统在多样性方面始终处于次优状态。一般来说,推荐系统有两种主要方法:基于内容的方法和基于协同过滤(Collaborative Filtering, CF)的方法。这些方法主要依赖于相似性,往往会导致次优结果。例如,基于内容的方法会生成符合用户兴趣的项目,但往往只关注有限的主题范围。协同过滤的方法倾向于优先推荐热门项目,而对鲜为人知的长尾项目则推荐机会较少。此外,这些次优方法容易陷入准确性-多样性的困境,即一味地以牺牲准确性来换取多样性的提升。

最近,图神经网络强大的建模能力受到了广泛关注,由于用户-物品交互图是一个天然的二部图,研究人员提出了几种基于图的推荐算法,这些算法有的使用非常简单的随机游走<sup>[3-4]</sup>,有的使用更复杂的方法,如 GCN<sup>[5-8]</sup>。在用户-物品二部图中,用户的高阶邻居包含更多物品,既有用户的交互物品,也有类似用户的首选物品。这一特性为挖掘图的多样性提供了基础。由于图上自然的高阶连接性,在图中挖掘多样性具有优势,从而更容易获取多样化的项目。此外,在 GCN 的框架内应用多样化还解决了之前研究中模型解耦设计的问题,即把多样化与上游关联匹配模型分开。然而,如果没有专门的多样化设计,利用这些高阶连接来发现不同的项目可能不会自动发生<sup>[9]</sup>。并且,以上方法都是利用用户购买行为这一单一显式反馈来建模,这必然推荐出用户购买过的类似商品,而这些商品需要通常已经被满足,从而影响用户满意度和推荐的多样性。

为了解决上述问题,本文借助图卷积神经网络,专注于提高推荐列表的多样化,提出了一种基于轻量级图卷积神经网络的端到端多样化推荐模型(DLGCRec),该模型降低了推荐计算的时间成本,在极大提升多样性的同时提高了一定的准确性,并将多样化过程推进到匹配阶段,弥补了传统多样性推荐的解耦设计缺陷。首先,简化后的 LGCN 模型,只使用了三层图卷积层并删除了 GCN 中与协同过滤任务无关的特征转换和非线性激活部分。其次,为项目嵌入保留了原始负采样,以学习完整的项目特征,并对用户嵌入采用多样性增强负采样来提高采样到不同项目的概率。此外,还使用多层特征融合模块来区分不同层的偏好贡献,从而优化嵌入特征的代表。本文主要贡献包括以下 4 个部分:

1)研究了当前多样化推荐算法的现状和缺点,同时提出了一种端到端的多样化推荐模型,简化 GCN 以适用推荐并利用简化后的 LGCN 的固有优势将多样性整合到匹配过程中。本文方法解决了以往研究中这种解耦模型

设计结构的局限性。

2)为了生成多样化的相关项目,引入了用户隐式反馈,探索多种类型的用户行为对多样性的影响。为 LGCN 精心设计了一个多样性增强的负采样过程,缓解了多样性-准确性困境。此外,还对 LGCN 进行了多层特征融合,通过区分各层对最终嵌入的不同贡献,更好地学习节点的特征表示。

3)提出了一种新的评估方法 RQ,用于捕获推荐列表在多样性和准确性之间的权衡,从而更直观地评估模型对推荐质量的影响。

4)使用真实数据集来评估所提方法的有效性。实验结果表明,该方法在提高推荐多样性的同时小幅提升了准确性,并降低了推荐的时间成本,有效改善了准确性-多样性困境。此外,还进行了消融研究,以确定每个所提组件的必要性。

本文第 2 章讨论了基本概念;第 3 章概述了相关工作;第 4 章阐述了 DLGCRec 的设计及其实现的具体细节;第 5 章重点介绍了所进行的对比实验和消融实验,并对实验结果进行了分析;最后总结全文并展望未来。

## 2 相关概念

### 2.1 多样性

本文的重点是提高推荐系统中用户内部层面的多样性,具体来说,目标是提高每个用户推荐项目的多样性。为此,本文主要提高推荐结果的项目类别多样性分布,而把满足用户多样性需求<sup>[10]</sup>作为未来工作的一部分。多样性和偶然性或新颖性容易混淆,但在根本上是不同的。偶然性和新颖性指推荐系统提供满足用户潜在兴趣的项目的能力,而这些项目是用户以前从未接触过的。然而,多样性指用户推荐列表中多样性分布的一种衡量标准,它趋于平稳并具有广泛的类别,从而提高满足用户需求的概率。例如,在一个容量为 5 的推荐列表中,2+2+1 的类别组合比 4+1 的类别组合具有更高的多样性。

### 2.2 隐式反馈

隐式反馈是推荐系统中比较常见的一种数据形式,它指用户并不直接表达对物品的偏好,而是通过隐性行为暗示的反馈<sup>[11]</sup>。这些行为可以是用户查看、点击、分享、收藏、评论等。所有这些行为都可以被视为用户对物品的一种隐性反馈。由于隐式反馈是被动地记录偏好,更能体现用户真实需求,目前的研究大多集中对单一显式反馈的复杂建模上,并且隐式反馈相比显式反馈(如用户评分、评论、评级等)更难解释和理解。因此需要对这些隐式数据进行处理和分析,从中提取有用的信息,以便于计算用户对物品的潜在偏好,为推荐系统提供相关度高且具有多样性的推荐结果。此外,在面对冷启动问题时,隐式反馈也能帮助推荐系统对新用户和新项目做出更准确的推荐。

### 2.3 准确性-多样性困境

在推荐系统中,准确性和多样性是两个核心指标。具体来说,准确性指推荐系统提供的推荐结果与用户实际需求的吻合程度,而多样性则指推荐系统提供的推荐结果的“丰富程度”,能否满足用户的不同需求和偏好。这两个指标之间往往存在矛盾关系,被称为“准确性-多样性困境”。通常情况下,在提高多样性时很难摆脱所谓的准确性-多样性困境<sup>[12]</sup>,尤

其是在大多数推荐系统中都是基于离线评估的情况。一般来说,较高的多样性通常会降低一定程度的准确性。当推荐系统为了提高准确性而倾向于向用户推荐与其历史兴趣相似的项目时,推荐结果可能会缺乏多样性,从而导致用户不满意;反之,为了提高多样性,推荐系统可能会推荐许多与用户兴趣无关的项目,从而降低了准确性,也降低了用户体验和满意度。

准确性-多样性困境是推荐系统中的一个重要问题,需要在准确性和多样性之间进行权衡和优化。近年来,相关研究人员尝试通过调整推荐算法参数<sup>[13]</sup>、引入领域知识<sup>[14]</sup>等多种手段来解决这一问题。在第 5.5 节会进一步比较 DL-GCRec 和其他几种多样性推荐算法在准确性和多样性之间的权衡。

### 3 相关工作

#### 3.1 多样化推荐

为了提高用户满意度并改善推荐多样性,研究人员从 4 个方向提出了各种方法,包括后处理/重新排序(Post-processing/Re-ranking)、行列式点过程(Determinantal Point Process)、学习排序(Learning to Rank)和多目标优化方法(Multi-objective Optimization)。在多样化推荐研究的最初阶段,对推荐的候选项目实施了辅助的重新排序或后处理子模块。这些子模块利用启发式方法确定项目顺序,旨在实现相

关性和多样性之间的权衡。重新排序策略独立于推荐模型的优化,与候选项生成过程脱钩,这一策略能灵活地将多样化方法与现有的推荐模型相结合。此外,一个新出现的研究方向使用概率模型 DPP<sup>[15-17]</sup> 作为基于后处理方法中采用的启发式方法的替代方法。这种方法可以直接生成有序的项目列表。然而,这两种方法的多样化信号均没有被纳入上游相关性匹配模型,这往往导致最终推荐结果的多样性次优。总之,现有的后处理或基于 DPP 的解决方案旨在提高多样性,同时不影响匹配过程。推荐系统的性能在很大程度上取决于匹配过程中获得的用户和项目的代表性,从而限制多样化推荐的性能。因此,解耦设计是否能在不影响准确度的情况下有效提高推荐多样性仍不确定。学习排序方法需要一个难以构造的列表数据集,而多目标优化方法将准确性和多样性作为模型优化的两个目标,它通过平衡准确性和多样性之间的参数,在不过度损失准确性的情况下实现多样性,因此这类模型复杂且参数众多,计算成本高,并且往往不可避免地会导致准确性的损失。

目前几乎所有创建多样化推荐列表的算法都是在使用现有方法之一生成推荐列表后,通过重新排序来实现的<sup>[18-19]</sup>。这意味着这些算法已经假定推荐结果是多样化的,只需要重新排序就能实现最大可能的多样化。上述解耦模型设计将提高多样性表现为对准确性项目的冗余重排序。图 1 给出了这些解耦设计的原理,表 1 列出了有关多样化推荐的相关工作。

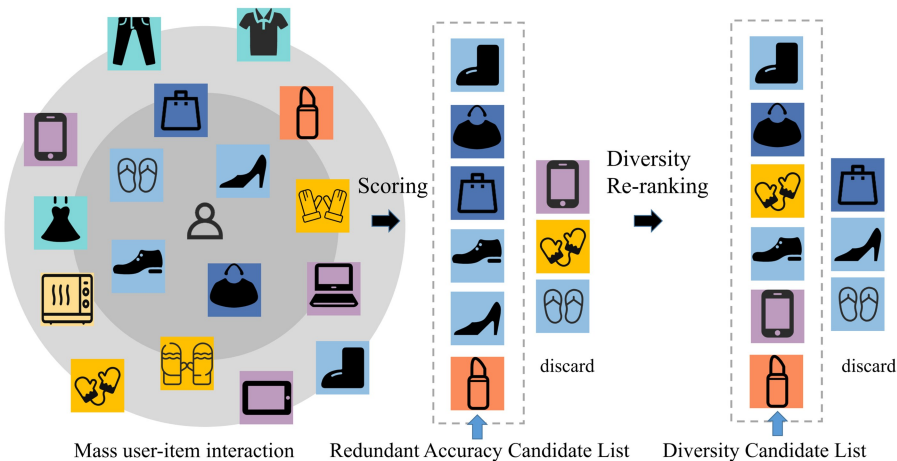


图 1 传统的基于重排序的多样化推荐算法(颜色代表不同的类别)

Fig. 1 Traditional diversified recommendation algorithms based on re-ranking(Color represents different categories)

表 1 多样性推荐方法

Table 1 Diversity recommendation method

方法	模型	思想	优点	缺点
Post-processing	MMR <sup>[19]</sup>	按多样性约束对准确性候选列表重新排序	可以灵活地将各种多样化方法与现有推荐模型相结合	多样化与推荐过程的解耦设计
Determinantal Point Process	DPP <sup>[15]</sup>	通过调整行列式的权重来实现多样性	通过数学模型避免推荐过于相似	计算行列式的算法复杂,多样化与推荐过程的解耦设计
Learning to Rank	DCF <sup>[20]</sup>	通过学习算法实现最佳排名	为用户提供个性化推荐	需要列表数据集
Multi-objective Optimization	DUM <sup>[21]</sup> PMF+ $\alpha$ + $\beta$ <sup>[13]</sup>	将推荐的准确性和多样性视为两个优化目标	更好地兼顾准确性和多样性	算法复杂,需要优化多个评价指标
Graph-based	DGCN <sup>[9]</sup> DTGCF <sup>[22]</sup> DGRec <sup>[23]</sup>	利用用户-项目二部图的自然图结构建模和对 GNN 的特殊设计实现多样性	利用图的高阶连通性探索多样化项目	图神经网络用于推荐时的冗余组件会影响推荐性能

与上述在准确度匹配后进行多样化的解耦设计工作不同,DLGCRec 模型是一种端到端的方法,利用图卷积网络有

效地整合了多样性和准确性匹配过程。在用户-项目二部图中,高阶邻域不仅包括特定用户的交互项目,还包括其他类似

用户的交互项目,从而包含了更多不同的项目。由于图上的高阶连通性,这对提升多样性是有利的,因为高阶连通性提高了更广泛项目的可访问性。

### 3.2 基于图卷积的推荐

图卷积网络(GCN)在表征学习任务<sup>[24-26]</sup>中取得了显著进步,例如节点分类<sup>[27]</sup>和链接预测<sup>[28]</sup>。在推荐系统领域<sup>[29-30]</sup>,GCN已被应用于增强用户和项目的表示,从而为推荐带来更强大的潜力。

Mei等<sup>[14]</sup>将GCN应用于用户-物品交互二部图,基于交互历史记录和物品知识信息构建了一个方面级用户-物品交互图,并提出了基于LightGCN的方面级协同过滤模型(LGC-ACF),利用多主体用户-物品交互信息,学习用户和物品的方面级表示。Li<sup>[31]</sup>提出了一种改进的用户密度聚类方法GDC-GCN,并通过优化的图卷积神经网络提取用户特征,提高了推荐效果。Tang等<sup>[32]</sup>针对推荐系统中数据稀疏的问题,提出了知识增强图卷积网络(KE-GCN)来挖掘知识图谱中项目间的关联属性,并改进了注意力机制,以更好地挖掘项目邻居的相关性。Wang等<sup>[8]</sup>提出了NGCF框架,利用GCN对用户-物品二部图中的高阶连接进行建模并传播特征嵌入。实验结果表明,GCN可以通过基于特征的学习来提高推荐准确率。然而,复杂的GCN模型对多样性的影响仍不确定。

图的高阶连通性使不同的项目更容易被访问,这为提高图的多样性提供了优势。文献<sup>[9]</sup>提出了DGCN模型,它在GCN的基础上结合了3种特殊设计来增强多样性,以满足用户的多样化需求。然而,DGCN并没有考虑模型学习到的不同图卷积层的嵌入对用户特征最终嵌入的不同影响。Zuo等<sup>[22]</sup>提出了基于图协同过滤的多样化标签推荐模型DT-GCF,该模型结合了个性化类别来提升负采样和对抗学习技术,以分别优化多样性和准确性。Yadav等提出了一种基于用户聚类和GCN的多样性推荐方法,通过聚类用户节点和基于邻域的学习来提高推荐的多样性,同时保持推荐的准确性。Yang等<sup>[23]</sup>针对基于GCN的推荐系统在聚合过程中忽略聚合邻居的冗余性,导致推荐列表多样性差的问题,通过利用GNN上的3个特殊子模块来关注长尾项目直接改进嵌入生成过程,提出了基于GNN的推荐多样化方法DGRec。

以上尝试证明了在图上提升多样性的有效性,但图神经网络的冗余设计、多用户行为类型的贡献和层间特征的重要性区别并未得到有效关注。

为了更直观地展示基于GCN的多样性推荐工作,表2列出了上述工作的主要思路、使用的数据集和优缺点。

表2 基于图卷积的推荐方法

Table 2 GCN-based diversity recommendation

方法	思想	数据集	缺点
DGCN <sup>[9]</sup>	在GCN上执行再平衡邻居发现、类别增强负采样和对抗学习提升多样性	Taobao Beibei	忽略用户隐性反馈 对层间特征进行均值聚合
DTGCF <sup>[22]</sup>	利用物品的标签信息构建多样性推荐模型	ML-10M ML-20M	忽略用户隐性反馈 对层间特征进行均值聚合
DGRec <sup>[23]</sup>	利用子模块邻居选择、层注意力机制和损失权重来关注长尾类别	Taobao Beauty	忽略用户隐性反馈

### 3.3 简化GCN适用于推荐

GCN是协同过滤领域的一种新技术,已被广泛应用于推荐系统中,由于其能够利用用户与项目之间的高阶联系,因此在性能方面取得了令人印象深刻的改进。GCN的主要思想是堆叠多层,并在每层迭代时执行3个步骤:节点嵌入、邻域聚合以及由神经网络参数化的节点嵌入的非线性变换。

图形卷积网络(GCN)最初是为图形分类任务而开发的,由于其广泛使用神经网络操作,因此在训练方面存在固有的挑战:当把基于GCN的模型应用于大型图时,就会产生效率和可扩展性方面的问题。但目前基于图形卷积网络的CF模型<sup>[8-9,14,22-23,31-32]</sup>往往倾向于寻求越来越复杂的模型,以更好地捕捉高阶协作信号。Wang等提出的NGCF<sup>[8]</sup>明确地将用户与项目的交互注入到GCN嵌入过程中,但在大型数据集上效率特别低。因此,许多研究人员开始推测目前基于GCN的推荐模型设计过于繁琐,并开始简化用于推荐的GCN。Chen等<sup>[33]</sup>提出了一种基于线性GCN的推荐系统模型LR-GCCF,LR-GCCF是简化GCN用于推荐的首次尝试,它通过去除非线性激活和使用残差网络结构来解决GCN训练和建模的复杂和困难问题,从而达到缓解过度平滑问题的目的。He等<sup>[5]</sup>提出了简化GCN的LightGCN,使其更适用于推荐,并提供了全面的消融分析。LightGCN去掉了特征变换和非线性激活,只包含邻域聚合部分,通过在用户-物品交互图上线性传播用户和物品嵌入来学习和提高推荐性能,实现更简单地训练GCN模型。Mao等<sup>[6]</sup>提出的UltraGCN在LightGCN的基础上,通过约束损失直接逼近无限层图卷积的极限,提高了推荐性能,实现了显著的提速。

然而,上述方法仍然试图堆叠无限层图卷积进行信息传递,这不仅会增加引入过多高阶噪声的风险,还会带来节点特征过平滑问题。这显然不利于推荐系统产生多样化的推荐。受此启发,本文重点对基于GCN的多样性推荐模型的训练过程进行进一步的实证分析,去掉非线性激活和特征变换,并跳过无限层消息传递机制,搜寻最适合多样性推荐模型的GCN层数。

本文总结了上述尝试的主要思路和使用的数据集,如表3所列。图2给出了上述模型在提升推荐性能NDCG@20(归一化折损累计增益,用于评估排名结果的相关性得分。该值越高,推荐准确性表现越好)的同时,在Amazon-book和Gowalla数据集上推荐@20时所花费的时间成本<sup>[6]</sup>。图2表明,在尽可能保持所有参数和环境的一致条件下,简化的GCN可以带来更好、更快的推荐。

表3 简化GCN以适用推荐

Table 3 Simplifying GCN for recommendation

方法	思想	数据集
NGCF <sup>[8]</sup>	在GCN特征嵌入过程中注入协作信号,提高推荐性能	Gowalla Amazon-Book Yelp2018
LR-GCCF <sup>[33]</sup>	消除GCN的非线性激活,提高推荐性能	Amazon-Book Gowalla
LightGCN <sup>[5]</sup>	消除GCN的非线性激活和特征转换,提高推荐性能	Gowalla Amazon-Book Yelp2018
UltraGCN <sup>[6]</sup>	通过约束损失直接逼近无限层图卷积的极限,实现高效推荐	Gowalla Amazon-Book Yelp2018 ML-1M

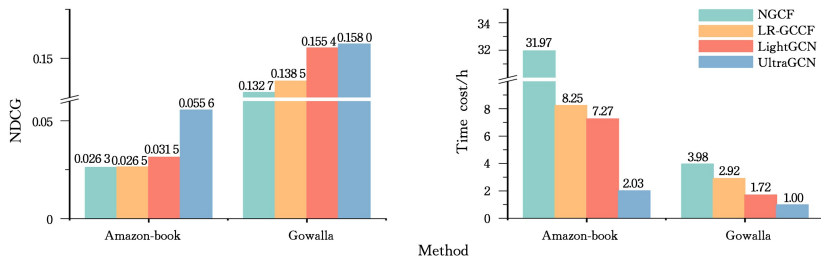


图 2 简化 GCN 以实现更好更快的推荐

Fig. 2 Simplified GCN for better and faster recommendations

## 4 DLGCRec

### 4.1 总览

本文将推荐列表的多样化整合到了 LGCN 匹配过程中,目标是提供符合用户兴趣的项目,同时保持它们之间的多样性。DLGCRec 的整体结构如图 3 所示。对于用户节点的邻域,用不同的颜色来表示项目节点的类型多样性,并使用多样性增强的负采样来进行采样聚合;对于项目节点的邻域,用灰色来代表平等对待每个用户节点,以

保留完整的项目嵌入。在用户-项目二部图上,使用简化后的轻量级图卷积神经网络 LGCN 来准确模拟协同过滤效果。为了使 DLGCRec 模型更适应真实数据集上的多样化推荐问题,精心设计了以下 3 个组件来优化 DLGCRec: 1)轻量级图卷积网络(Light Graph Convolution Networks, LGCN);2)多样性增强负采样(Diversity-boosted Negative Sampling);3)多层特征融合(Multi-layer Feature Fusion)。下文将依次介绍针对为改善准确性-多样性困境的 3 种具体设计。

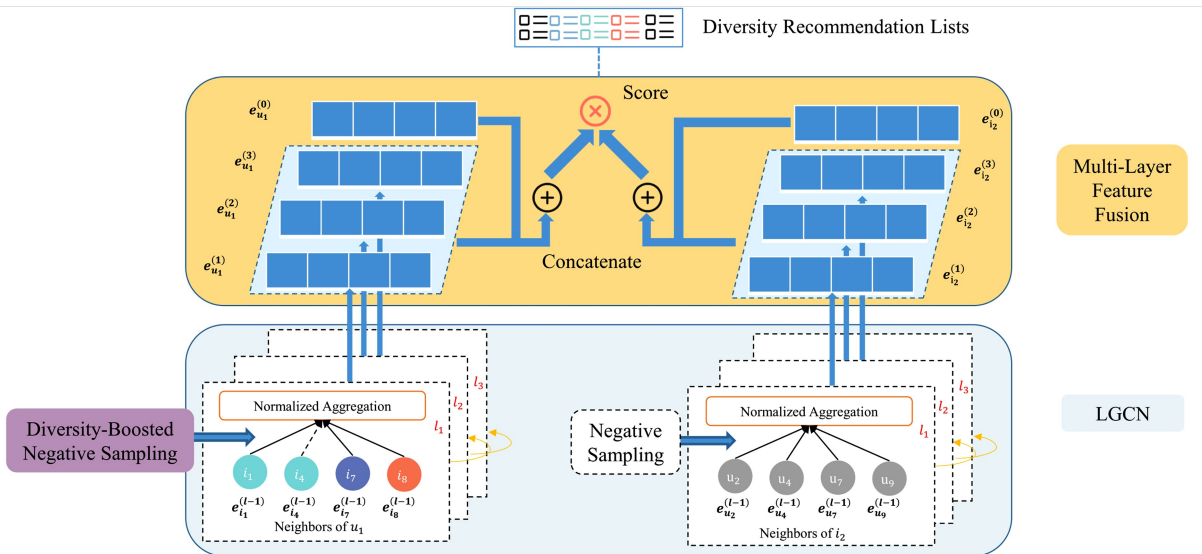


图 3 DLGCRec 架构示意图

Fig. 3 Illustration of DLGCRec architecture

### 4.2 轻量级图卷积

GCN 的本质是通过聚合图上相邻节点的特征来学习目标节点的特征表示。为实现这一目标,它反复执行图卷积,将相邻节点的特征聚合为目标节点的新表示<sup>[34]</sup>。这种邻域聚合可以抽象地表示为:

$$e_u^{(k+1)} = \text{AGG}(e_u^{(k)}, \{e_i^{(k)}; i \in \mathcal{N}_u\}) \quad (1)$$

其中,AGG 是聚合函数,即图卷积的核心。GCN 中的特征变换和非线性激活组件在节点分类和图分类任务中表现出色,但对于基于协同过滤的推荐任务来说却是一种负担<sup>[5-6]</sup>。因此,DLGCRec 不含特征变换和非线性激活组件,并进一步降低了网络深度,以防止潜在的节点特征过拟合问题,并将实验中得到的最优三层的 GCN 模型用于节点特征学习。

#### 4.2.1 嵌入层

在文献[35]发现的词向量组合方法的基础上,LGCN 的输入特别包含了用户和项目特征。为此,采用将单点特征转换为密集向量表示的嵌入策略,从而方便后续的嵌入过程。

$$E = [e_{u_1}, \dots, e_{u_K}, e_{i_1}, \dots, e_{i_S}] \quad (2)$$

其中, $K$  表示用户数量, $S$  表示项目数量。初始嵌入可视为 0 层的节点特征。

#### 4.2.2 卷积层

卷积层采用了一种直接的加权求和方法来汇总与目标节点相连的邻近节点。这种方法专为协同过滤任务定制,无需进行特征转换和非线性激活。图卷积操作(也称为嵌入传播法)的定义如下:

$$e_u^{(k+1)} = \sum_{i \in \mathcal{N}_u} \frac{1}{\sqrt{|\mathcal{N}_u|} \sqrt{|\mathcal{N}_i|}} e_i^{(k)} \quad (3)$$

$$e_i^{(k+1)} = \sum_{u \in \mathcal{N}_i} \frac{1}{\sqrt{|\mathcal{N}_i|} \sqrt{|\mathcal{N}_u|}} e_u^{(k)} \quad (4)$$

通过利用对称归一化项  $1/\sqrt{|\mathcal{N}_i|} \sqrt{|\mathcal{N}_u|}$ ,可以避免嵌入大小随图卷积操作次数的增加而增加,从而简化计算过程。利用最终的用户和项目嵌入来估算交互概率模型预测值。

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

在实验中,使用全连接层作为分类器,并使用对数似然损失函数对其进行优化。以单个训练样本 $(u, i, y, c)$ 为例,其中 $y$ 等于0或1表示用户与物品的实际交互, $c$ 是与物品 $i$ 相关的类别, $\hat{y}$ 表示本文的多样性推荐模型的预测值。下面是推荐损失函数的表达式:

$$L_r(u, i, y) = -[y \times \log \sigma(\hat{y}) + (1 - y) \times \log \sigma(1 - \hat{y})] \quad (6)$$

而物品类别分类的损失函数如式(7)所示:

$$L_c(i, c) = -\mathbf{W}e_i[c] + \log(\sum_j \exp(\mathbf{W}e_i[j])) \quad (7)$$

其中, $\mathbf{W}$ 是可学习的 $d \times C$ 权重矩阵,损失函数的第一项表示用项目嵌入向量 $e_i$ 和类别标签嵌入向量 $c$ 之间的点积来衡量它们的相似性。第二项是预测标签与真实标签之间的交叉熵损失。因此,DLGCRec总的损失函数如式(8)所示:

$$L(u, i, y, c) = L_r(u, i, y) + L_c(i, c) \quad (8)$$

#### 4.2.3 多样性增强负采样

近年来,许多研究人员致力于研究和改进图中负样本的设计<sup>[36-38]</sup>,以提高推荐的准确性。然而,很少有文献研究负采样在多样化方面的潜力。传统的推荐模型无法捕捉用户的隐含类别偏好,导致更多正面类别的类似项目被重复推荐,限制了向用户展示更多样化项目的机会。此外,这些研究大多将用户与商品关系的模拟局限于单一类型的显式交互,通常是“购买”操作,而忽略了包括点击、添加到购物车、标记为收藏夹等各种隐式交互反馈。纳入多种类型的互动,尤其是用户的隐性反馈,对于理解用户偏好和捕捉广泛的边信息具有巨大的潜力。

因此,本文强调用户与商品之间关系的重要性,并探索多种类型的用户行为对推荐多样性的特殊贡献,因此改进了传统负采样的采样过程,旨在进一步实现样本集多样性与准确性之间的权衡。在传统只利用了购买这一单一类型的显式交互负采样算法中,用户潜在兴趣(图4中红色背景的所有项目)被视为负样本推离推荐系统,只留下购买过项目的类似“过剩”项目。因此,多样性增强负采样(Diversity-boosted negative sampling)的目标是利用用户隐式行为扭曲训练样本分布来探究多样性。传统负采样中正类别和正样本一一对应,而多样性增强负采样从负面类别中选择更多的具有用户隐性反馈的伪负面项目为正样本,并且还从正面类别中采样负样本(即图4中的深蓝色背景项目)。文献[11,39]表明,利用用户的隐式行为并不一定会导致准确率降低,但这为提高多样性奠定了基础。因此伪负面项目在多样性和准确性之间取得了平衡,从而使模型在生成候选项目时避免了多样性和准确性之间的两难选择。多样性增强负采样将使得正面类别中的冗余项目能够被采样为负样本推离推荐系统,而伪负面项目被视为正样本将被进一步采样到GCN中以实现推荐。项目样本集空间示意图如图4所示。

多样性增强负采样使得学习到的表征能够熟练地捕捉用户对各种类别的兴趣,从而增加对不同类别的项目的推荐。随着推荐的进行,更多来自正类别的项目会被视为负样本,从而提高了在推荐过程中从负类别中推荐正面项目的概率。此外,由于同一类别中的负面项目不太可能被推荐,这增加了来自其他类别的项目的被推荐可能性,从而进一步使候选列表更加多样化。

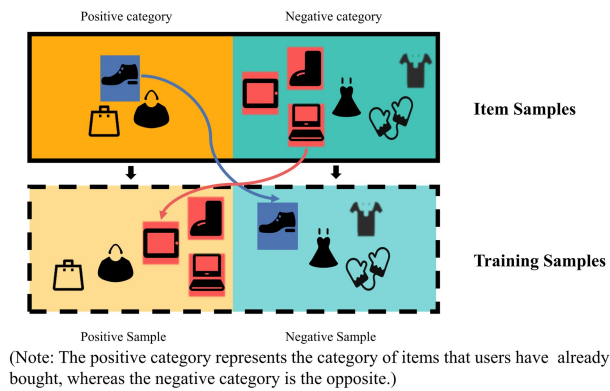


图4 多样性增强负采样的原理

Fig. 4 Principle of diversity-boosted negative sampling

通过对模型DLGCRec的训练,可以在更精细的层次上学习用户和项目表征,从而使推荐系统能够更细粒度地捕捉用户兴趣。通过利用精心设计的多样性增强负采样,DLGCRec可以在不影响相关性的情况下提供更广泛的更具多样性的项目。此外,算法1中的超参数 $\alpha$ 的加入有助于控制采样比例,在多样性和准确性之间取得平衡。多样性增强负采样算法的伪代码如算法1所示。

#### 算法1 多样性增强负采样算法

输入:Item set I; positive samples P; negative item sample rate R; item category list L; diversity sample weight  $\alpha$

输出: Training samples T

1.  $T \leftarrow P$  /\* 初始化 \*/
2. for all positive sample  $(u, i, \text{true}) \in P$  do
3.  $M \leftarrow I_{D_{L(i)}}$ , BehaviorType  $\in \{\text{fav}, \text{cart}, \text{pv}\} \setminus i$
4.  $N \leftarrow I \setminus i$
5. for  $t \leftarrow 1$  to R do
6.  $r \leftarrow \text{RandomFloat}(0, 1)$
7. If  $r \leq \alpha$  then
8.  $i_t \leftarrow \text{Sample}(M)$
9. else
10.  $i_t \leftarrow \text{Sample}(N)$
11. end if
12.  $T \leftarrow T + (u, i_t, \text{false})$
13. end for
14. end for
15. return T

#### 4.2.4 多层特征融合

该模型所设计的多层特征融合策略(Multi-layer Feature Fusion)可以带权整合3个不同深度的特征层,通过拼接从DLGCRec不同层学习到的特征嵌入,进一步提高DLGCRec的细粒度表征能力。中间特征介于浅层结构特征和深层语义特征之间,直接影响下一层的特征提取效果,这三者对最终的推荐效果都有重要影响。因此,为了进一步提高推荐性能,每个用户/项目的嵌入式输出结果可以同时获得LGCN 3个不同深度的特征信息,充分利用LGCN强大的建模能力。我们建议将层组合系数 $\alpha_K$ 统一设置为 $1/K + 1$ ,其中 $K$ 代表层数,层组合系数 $\alpha_K$ 表示第 $K$ 层嵌入在最终嵌入形成中的重要性,可以过滤掉特征层上的无用信息,从而提高网络性能,有效增强特征表达能力。层组合系数倾向于认为图上越紧邻的节点对其自身的嵌入更重要(当 $K$ 为1时,层组合系数最

大),这与经验相符。

在给出初始嵌入后,可以通过式(9)和式(10)中定义的嵌入传播来计算更高层次的嵌入。将层组合系数 $\alpha_K$ 统一设置为 $1/K+1$ ,其合理性将在后续的消融实验中得到验证。在 $K$ 层图卷积之后,将合并从各层获得的嵌入,以创建用户(项目)的最终表示:

$$\mathbf{e}_u = \sum_{k=0}^K \alpha_k \mathbf{e}_u^{(k)} = \alpha_1 \mathbf{e}_u^{(1)} \oplus \alpha_2 \mathbf{e}_u^{(2)} \oplus \dots \oplus \alpha_k \mathbf{e}_u^{(k)} \quad (9)$$

$$\mathbf{e}_i = \sum_{k=0}^K \alpha_k \mathbf{e}_i^{(k)} = \alpha_1 \mathbf{e}_i^{(1)} \oplus \alpha_2 \mathbf{e}_i^{(2)} \oplus \dots \oplus \alpha_k \mathbf{e}_i^{(k)} \quad (10)$$

## 5 实验

### 5.1 数据集

Taobao 是阿里巴巴为研究隐式反馈推荐问题而提供的淘宝用户行为开放数据集。该数据集记录了用户的所有行为(行为包括点击(pv)、购买(buy)和加入购物车(cart)、标记为喜爱(fav))。

Beibei 是从中国最大的母婴平台之一收集的涉及用户的页面点击、加入购物车和购买 3 种交互行为。以上的购买行为均是显式行为,其余构成隐式反馈。数据集的详细信息如表 4 所列。

表 4 数据集的统计  
Table 4 Statistics of datasets

Dataset	Taobao	Beibei
# Users	82633	21716
# Items	136710	7977
# Categories	3108	281
Interaction Behavior Type	{Page View, Cart, Favorite, Buy}	{Page View, Cart, Buy}

### 5.2 评估指标

#### 5.2.1 准确性

推荐结果的准确性非常重要,直接决定了用户的满意度。本文使用常用的 F1 指标来衡量推荐列表的准确性。

Precision: 精确率指预测为阳性的样本数中,真阳性样本数所占的比例。

$$precision = \frac{TP}{TP + FP} \quad (11)$$

Recall: 召回率是在阳性样本中被正确预测为阳性样本的比率。

$$recall = \frac{TP}{TP + FN} \quad (12)$$

F1-score: F1 分数是对分类问题的衡量标准。一些针对分类问题的机器学习方法通常使用 F1 分数作为最终衡量标准。它是精确率和召回率的调和平均值,最大值为 1,最小值为 0。

$$F1 = \frac{2 \times precision \times recall}{precision + recall} \quad (13)$$

#### 5.2.2 多样性

本文旨在提高用户内部层面的多样性,因此测量每个用户推荐列表的多样性。推荐多样性使用以下指标进行衡量。

Category coverage(CC): 类别覆盖度指标表示每个推荐结果中推荐项目的类别数量。

Gini index: 基尼指数最初来源于经济学,被广泛应用于推荐系统中。它量化了某一特定类别中的项目数量,作为该类别丰富程度的指标。

$$Gini\ index = 1 - \frac{1}{n} (2 \sum_{i=1}^{n-1} W_i + 1) \quad (14)$$

Diversity index: 多样性指数由余弦相似度(Cosine Similarity)的补数定义,指两个推荐项目之间的差异程度。余弦相似度计算的是两个项目嵌入向量之间夹角的余弦值,用来量化项目之间的相似程度。

$$cosine\ sim(e_i, e_j) = \cos(\vec{e}_i, \vec{e}_j) = \frac{\vec{e}_i \cdot \vec{e}_j}{\|\vec{e}_i\| \|\vec{e}_j\|} \quad (15)$$

$$diversity\ index(e_1, \dots, e_n) = \frac{\sum_{i=1, \dots, n} \sum_{j=i, \dots, n} (1 - cosine\ sim(e_i, e_j))}{\frac{n}{2} * (n-1)} \quad (16)$$

对于类别覆盖度、基尼指数和多样性指数,其值越高,表明多样性越高。

#### 5.2.3 整体推荐质量

受文献[40]的启发,提出了一种新的推荐质量度量方法,它能捕捉到推荐列表的多样性和相关性之间的权衡,可以代表推荐系统在多样性和相关性之间的整体推荐质量。

Recommendation Quality(RQ): 它是以项目间欧氏距离的均值和多样性指数的调和平均值来计算的,其与推荐整体质量呈正相关。

$$RQ = 2 / \left( \frac{1}{euclidean\ distance} + \frac{1}{diversity\ index} \right) \quad (17)$$

### 5.3 基准方法

为了验证 DLGCRec 的有效性,将其性能与以下基准多样化推荐方法进行了比较:MMR 和概率模型 DPP 都是重排序算法,MMR 和 DUM 都是贪婪多样化推荐算法,PMF +  $\alpha + \beta$  是一种多目标优化方法。最后两条基线 DGCN 和 DGRec 是最先进的基于图神经网络的多样化推荐优化方法。

1) MMR<sup>[19]</sup>: 最大边际相关性(MMR)已被用于使推荐系统的结果列表多样化,并利用贪婪方法对内容重新排序以减少冗余。

2) DPP<sup>[15]</sup>: 行列式点过程(DPP)起源于数学和量子物理学,最近在机器学习研究中得到了利用,可以从更大的项目集合中选出多样化子集,并生成相关的多样化推荐。

3) DUM<sup>[21]</sup>: 一种增强多样化的贪婪方法,旨在最大限度地提高项目多样化的效用。

4) PMF +  $\alpha + \beta$ <sup>[13]</sup>: 多样性推荐问题被其表述为一个多目标优化问题,包含 3 个目标:项目相关性、用户兴趣覆盖率和多样性。为了平衡这些要素,引入了  $\alpha$  和  $\beta$  两个超参数。

5) DGCN<sup>[9]</sup>: DGCN 是在 GCN 的基础上融合 3 种为多样化独特设计的多样化推荐模型,有效缓解了准确性-多样性困境。

6) DGRec<sup>[23]</sup>: DGRec 旨在利用 GNN 进行子模块邻居选择、分层注意力机制和损失再加权 3 个模块直接改进嵌入生成过程,以关注长尾项目,提升推荐的多样性。

### 5.4 实验配置

在 RTX 2080Ti 11GB 上部署了所有方法并以 6:2:2 的比例随机分配训练集、验证集和测试集。验证集用于超参数调整和提前停止训练。DLGCRec 使用 Adam 优化器变种 AMSGrad 算法<sup>[41]</sup>进行优化。具体来说,对于 DGCN 和 DLGCRec,配置的负采样率为 4。嵌入维度和批量大小分别统一设置为 64 和 1024。本文将测试集的所有用户的平均结果作为最终结果。

## 5.5 结果及分析

在 Taobao 和 Beibei 数据集上比较了 DLGCRc 和上述基线,实验结果如表 5 和表 6 所列。基于多样化贪婪算法的基线(MMR, DUM)都存在不同程度的多样性-准确性两难问题,整体推荐质量(RQ)较低。MMR 算法由于是在准确性候选项目的重排序算法,其多样性提升微弱。而在多样性方面, DUM 性能最好,但这是以不顾推荐结果的准确性为代价的,故其 RQ 最低。基于概率模型的 DPP 比同为后处理的 MMR 取得了更加多样化的结果,但两者的准确率却始终差别不大。基于多目标优化方法的  $PMF+\alpha+\beta$  在多样性和准确性方面都表现较为出色,可见将多样性-准确性权衡问题转化为多目标优化的两个方向,是一种可行的研究方案。研究的关键是如何寻找最合适的权衡参数。

表 5 Taobao 数据集上的对比实验(@400)

Table 5 Comparative experiments on Taobao dataset(@400)

Metrics	Adversity			Accuracy	Trade-off
	CC	gini index	diversity index	F1	RQ
MMR <sup>[19]</sup>	86.1342	0.5714	0.0054	0.0498	0.0032
DPP <sup>[12]</sup>	134.1142	0.6912	0.0067	0.0503	0.0053
DUM <sup>[21]</sup>	<b>252.1324</b>	<b>0.7414</b>	<b>0.0102</b>	0.0405	0.0014
$PMF+\alpha+\beta$ <sup>[13]</sup>	151.1435	0.6515	0.0075	0.0544	0.0092
DGCN <sup>[9]</sup>	157.1012	0.6152	0.0074	<u>0.0605</u>	<u>0.0103</u>
DGRec <sup>[23]</sup>	159.2546	0.6717	0.0063	0.0506	0.0099
DLGCRc	<u>162.8605</u>	<u>0.7028</u>	<u>0.0084</u>	<b>0.0657</b>	<b>0.0133</b>

表 6 Beibei 数据集上的对比实验(@400)

Table 6 Comparative experiments on Beibei dataset(@400)

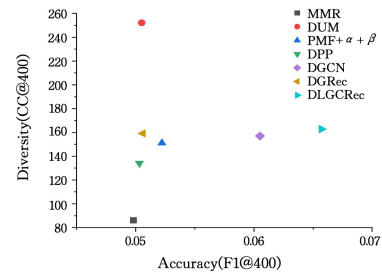
Metrics	Adversity			Accuracy	Trade-off
	CC	gini index	diversity index	F1	RQ
MMR <sup>[19]</sup>	47.2546	0.1563	0.0034	0.0256	0.0015
DPP <sup>[12]</sup>	77.1532	0.1759	0.0037	0.0311	0.0022
DUM <sup>[21]</sup>	<b>103.1256</b>	<b>0.2447</b>	<b>0.0071</b>	0.0265	0.0019
$PMF+\alpha+\beta$ <sup>[13]</sup>	79.5466	0.1862	0.0032	0.0293	0.0036
DGCN <sup>[9]</sup>	82.4645	0.1755	0.0041	0.0301	<u>0.0047</u>
DGRec <sup>[23]</sup>	80.2466	0.1588	0.0051	<u>0.0332</u>	0.0051
DLGCRc	<u>85.2351</u>	<u>0.2246</u>	<u>0.0063</u>	<b>0.0325</b>	<b>0.0053</b>

同为基于图的模型 DGCN 在多样性-准确性权衡方面表现良好,但在所有指标上都逊色于 DLGCRc,这可能是因为其简单的建模策略和层间特征融合策略阻碍了推荐性能。DGRec 在 Taobao 数据集上提高了多样性,但在多样性-准确性权衡方面却不尽如人意,相反,在 Beibei 数据集上 DGRec 在准确性和权衡方面表现更佳,我们推断可能是因为 DGRec 专注于挖掘 Taobao 数据集的长尾项目而失去了准确性,而在 Beibei 数据集中项目的长尾分布并不明显。除单考量多样性时,DLGCRc 始终不如多样化贪婪算法 DUM 外,DLGCRc 在两个真实数据集上均优于所有基线,且在多样性-准确性权衡方面最佳,然而 DLGCRc 并不是以前的解耦设计推荐模型,在根本上与 DUM 等不同。

本文对 DLGCRc 针对解决准确性-多样性困境的特殊设计,使得 DLGCRc 在提升多样性的同时并未损失准确性,并在多样性-准确性权衡方面达到了最佳效果。而在简化 GCN 使其更适合推荐系统方面,在第 5.6 节的(4)中比较了 DLGCRc 和 DLGCRc 相关变体模型的推荐速度和质量。

为了更清楚地比较所有方法,图 5 给出了相关方法在 Taobao 数据集上对准确性和多样性的权衡。准确度和多样

性分别以 F1@400 和 CC@400 度量。DLGCRc 位于图 5 的最右上方,这表明 DLGCRc 实现了最佳的准确性和多样性权衡。传统的多样化推荐方法(MMR, DPP 和 DUM)是以牺牲一定的准确性为代价实现多样性的。 $PMF+\alpha+\beta$  通过搜寻合适的超参数达到了两个目标的平衡,在 RQ 指标上也表现良好,甚至优于 DGRec,可见合适的参数和算法使得多目标优化是一种可行的研究方案。与 DLGCRc 相比,所有其他基于图的多样化推荐模型(DGCN, DGRec)的准确率都有所下降。与最先进的 DGRec 相比,DLGCRc 在保持相当水准的准确性的同时提高了多样性,DLGCRc 在 RQ 指标上表现最佳,取得了最佳的多样性-准确性权衡,进一步缓解了多样性-准确性困境。



注:右上方为 DLGCRc。

图 5 各模型在 Taobao 数据集上准确性-多样性权衡的比较

Fig. 5 Accuracy-Diversity trade-off comparison on Taobao dataset

## 5.6 消融实验

本节将从图卷积层数、多样性增强负采样中的  $\alpha$  的影响、用户隐式行为、多层特征融合策略以及拟提出的组件的必要性 5 个方面对 DLGCRc 进行消融实验,以验证 DLGCRc 设计的合理性和有效性。所有的消融实验是在 Taobao 数据集上进行的。

### 1) 图卷积层数的影响

为了验证 DLGCRc 在约束图中卷积层数为 3 时的有效性,并研究它是否能从多个嵌入式传播层中受益。DLGCRc 探索了 {1, 2, 3, 4, 5, 6} 范围内的层数,旨在改变图卷积深度并评估其对模型性能的相应影响。如图 6 所示,  $n$  Layer(s) 表示有  $n$  个内嵌传播层的模型。可以得出以下结论:

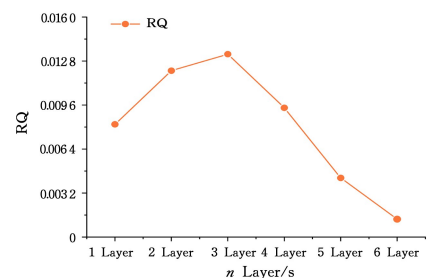


图 6 DLGCRc 在不同层数下的消融实验

Fig. 6 Ablation experiments of DLGCRc at different layers

开始时,增加层数可以提高性能,但随着层数的进一步增加,所带来的收益会逐渐减少。随着  $n$  的增加,性能首先得到改善,我们将这一现象归因于依赖于长距离的正信号和引入噪声的负信号之间的平衡。当  $n=3$  时,性能最佳,之后性能开始下降,当  $n=4$  时,性能迅速下降,此后一直下降。这归因于 LGCN 的过拟合特性会导致模型深度过深时节点特征趋于平滑,甚至丢失特征的问题。同时,此时深度网络引入的高

阶噪声远大于有用信号。因此,对于 Taobao 数据集,层数为 3 时,DLGCRc 模型的性能最佳。

2) 多样性增强负采样中  $\alpha$  的影响

图 7 给出了不同  $\alpha$  在准确性和多样性方面的表现: $\alpha$  越大,多样性越高但准确度越低。从图 7 中可以看出,最佳  $\alpha$  设置为 0.2,此时准确性指数 F1 和多样性指数 diversity index 都较高。

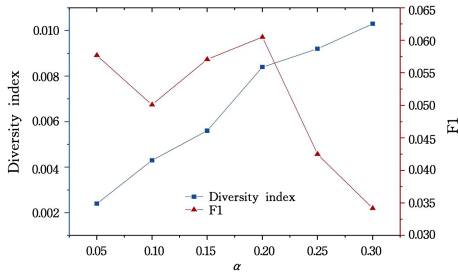


图 7 不同  $\alpha$  对多样性和准确性的影响

Fig. 7 Effect of different  $\alpha$  on diversity and accuracy

3) 用户隐式反馈行为的影响

为了验证在用户侧使用具有用户隐式反馈的多样性增强负采样方法的有效性,项目侧固定使用负采样方法而用户侧使用不同采样方法,从而得到的两组项目侧+用户侧组合进行对比实验。用户侧采样方法包括传统负采样方法(Negative sampling)和引入用户隐式反馈的多样性增强负采样方法(Diversity-boosted Negative Sampling)

实验结果如图 8 所示。F1,CC 和 RQ 指标分别提高了 0.007,35.1578,0.0062,可见用户侧的多样性增强负采样方法不仅提高了模型的多样性,还提高了准确性,并在多样性-准确性权衡方面也表现更佳,这与增加多样性并不一定会导致更高精度损失的说法是一致的<sup>[16,42]</sup>。

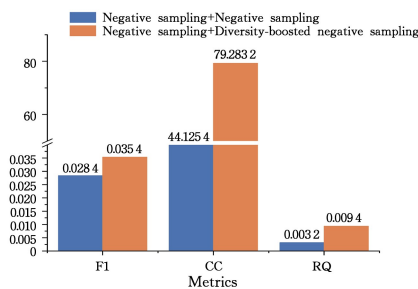


图 8 DLGCRc 在不同负采样下的消融实验

Fig. 8 Ablation experiments of DLGCRc at different negative sampling

4) 多层特征融合策略的影响

设计多层特征融合模块整合各层的嵌入,原因有两点:首先,层数的增加会导致嵌入平滑和引入高阶噪声;其次,不同层对最终嵌入的贡献不同,应该加以区别。因此,设置层组合系数,从而兼顾各层的特征嵌入。

图 9 给出了 DLGCRc 设置层组合系数的合理性。多层特征融合策略使得 DLGCRc 在 F1,CC 和 RQ 指标上的性能分别提升了 0.0123,58.5354,0.0036,反之,如果简单地、无差别地(平均地)拼接 LGCN 在不同层次上学习到的嵌入,DLGCRc 学习到的特征将无法准确地捕捉用户(项目)的特征,DLGCRc 的性能也随之会下降。

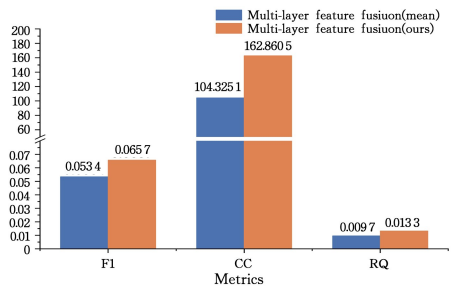


图 9 DLGCRc 在不同特征融合策略下的消融实验

Fig. 9 Ablation experiments of DLGCRc at different feature fusion

5) 各组件的影响

为了验证每个所提组件的必要性,进行了必要的实验,实验结果如表 7 和表 8 所列。

表 7 中,通过依次添加每个设计模块,对 Taobao 数据集进行了消融研究。以 LGCN 为基础,在对用户侧增加 Diversity-boosted negative sampling 后,模型的多样性显著提高,但仍丢失了一定的准确性。再加入使用了层组合系数的多层特征融合策略后,DLGCRc 充分挖掘了不同层次间潜在的语义信息,学习到了用户(项目)更细粒度的特征表示,提高了模型的表现力和性能。F1,CC 和 RQ 均有所提高,证明多层特征融合模块可以提高推荐多样性和性能。

表 7 所提组件的消融实验

Table 7 Ablation experiments of proposed components

LGCN	Diversity-boosted negative sampling	Multi-layer feature fusion	F1	CC	RQ
✓			0.1274	12.3257	0.0064
✓	✓		0.0534	104.3251	0.0097
✓	✓	✓	<b>0.0657</b>	<b>162.8605</b>	<b>0.0133</b>

从表 8 中不难看出,在简化 GCN 以适用于推荐方面,本文提出的 DLGCRc 与其他变异模型相比,显著提高了模型的收敛速度和推荐性能,这是由于 DLGCRc 直接舍弃了与复杂的协同过滤任务无关的非线性激活和特征变换部分,以及对高阶噪声信号与有用信号之间比例的权衡。

表 8 简化图卷积的消融实验

Table 8 Ablation experiments of simplified GCN

Model	F1	CC	RQ	Time Cost
DLGCRc(w/o both)	<b>0.0657</b>	<b>162.8605</b>	<b>0.0133</b>	<b>1 h 35 min</b>
w/ feature transformation	0.0428	135.2408	0.0086	2 h 01 min
w/ non-linear activation	0.0378	144.1586	0.0092	1 h 49 min
w/ both	0.0236	105.4624	0.0077	2 h 27 min

结束语

本文研究并整理了现有推荐系统多样性方法的局限性。面对现有研究中多样化过程和匹配过程的解耦设计,DLGCRc 利用图卷积将多样化过程和匹配模型相结合。面对图卷积的冗余组件,对图卷积的特征变换、非线性激活和多层信息传播进行了改进和限制,以满足协同过滤任务的需要,并进行了相关的消融实验来验证简化 GCN 的合理性。面对传统负采样过程会使正样本更加主流、多样性无法保证的问题,有效利用用户隐式反馈,提出了多样性增强负采样,从而提高推荐的多样性并在准确性和多样性之间取得平衡。

此外,面对准确性-多样性困境,引入了一种名为 RQ 的新型评价指标,用于评估多样性与准确性之间的权衡以及推

荐结果的整体质量。此外,还开发了多层特征融合模块,通过层组系数将各层节点嵌入加以区别地拼接起来,以提高模型的表现力。在真实数据集上进行了广泛的实验,实验结果表明了 DLGCRc 在提高多样性以及简化图卷积适用于推荐的有效性。进一步的消融研究再次证明了本文为改善准确性-多样性困境精心设计的所提组件的必要性。最终,DLGCRc 提供了多样化的相关内容,满足了用户对多样性的要求并显著改善了准确性-多样性困境。

未来,随着图数据的普及和图神经网络越来越多地应用于协同过滤任务,基于图的多样化推荐模型日益重要。基于图的多样化推荐系统的研究将为多样化推荐模型的未来发展提供有价值的启示。本文未考虑不同用户的不同多样化需求,因此未来的研究还将侧重于用户自适应多样化的探究。

## 参 考 文 献

- [1] WU L, HE X, WANG X, et al. A Survey on Accuracy-oriented Neural Recommendation: From Collaborative Filtering to Information-rich Recommendation [C] // IEEE Transactions on Knowledge and Data Engineering, 2022.
- [2] HU R, PU P. Helping Users Perceive Recommendation Diversity[C]// DiverRS@RecSys. Chicago, USA: ACM, 2011: 43-50.
- [3] JIANG Z, LIU H, FU B, et al. Recommendation in heterogeneous information networks based on generalized random walk model and bayesian personalized ranking[C] // Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. Marina Del Rey CA USA: ACM, 2018: 288-296.
- [4] PAUDEL B, BERNSTEIN A. Random Walks with Erasure: Diversifying Personalized Recommendations on Social and Information Networks [C] // Proceedings of the Web Conference 2021. Ljubljana Slovenia: ACM, 2021: 2046-2057.
- [5] HE X, DENG K, WWANG X, et al. LightGCN: Simplifying and Power-ing Graph Convolution Network for Recommendation [M]. arXiv, 2020.
- [6] MAO K, ZHU J, XIAO X, et al. UltraGCN: Ultra Simplification of Graph Convolutional Networks for Recommendation [M]. arXiv, 2021.
- [7] WANG H, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems [C] // The World Wide Web Conference on WWW '19. San Francisco, CA, USA: ACM Press, 2019: 3307-3313.
- [8] WANG X, HE X, WANG M, 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.
- [9] ZHENG Y, GAO C, CHEN L, et al. DGCN: Diversified Recommendation with Graph Convolutional Networks [C] // Proceedings of the Web Conference 2021. New York, NY, USA: Association for Computing Machinery, 2021: 401-412.
- [10] LIANG Y, QIAN T, LI Q, et al. Enhancing Domain-Level and User-Level Adaptivity in Diversified Recommendation [C] // Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, NY, USA: Association for Computing Machinery, 2021: 747-756.
- [11] LIU Y, XIAO Y, WU Q, et al. Diversified Interactive Recommendation with Implicit Feedback [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2020: 4932-4939.
- [12] ZHOU T, KUSCSIK Z, LIU J G, et al. Solving the apparent diversity-accuracy dilemma of recommender systems [J]. Proceedings of the National Academy of Sciences of the United States of America, 2010, 107(10): 4511-4515.
- [13] SHA C, WU X, NIU J. A framework for recommending relevant and diverse items [C] // Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence. New York, USA: AAAI, 2016: 3868-3874.
- [14] MEI D, HUANG N, LI X. Light Graph Convolutional Collaborative Filtering With Multi-Aspect Information [J]. IEEE Access, 2021, 9: 34433-34441.
- [15] CHEN L, ZHANG G, ZHOU E. Fast Greedy MAP Inference for Determinantal Point Process to Improve Recommendation Diversity [C] // Advances in Neural Information Processing Systems, 31. Curran Associates, Inc., 2018.
- [16] DEREZIŃSKI M. Fast determinantal point processes via distortion-free intermediate sampling [M]. arXiv, 2019.
- [17] GAN L, NURBAKOVA D, LAPORTE L, et al. Enhancing Recommendation Diversity using Determinantal Point Processes on Knowledge Graphs [C] // Proceedings of the 43rd International Acm Sigir Conference on Research and Development in Information Retrieval (sigir '20). New York: Assoc Computing Machinery, 2020: 2001-2004.
- [18] ABDOLLAHPOURI H, BURKE R, MOBASHER B. Managing popularity bias in recommender systems with personalized reranking [J]. arXiv: 1901. 07555, 2019.
- [19] CARBONELL J, GOLDSTEIN J. The use of MMR, diversity-based reranking for reordering documents and producing summaries [C] // Proceedings of the 21st Annual International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR '98). Melbourne, Australia: ACM Press, 1998: 335-336.
- [20] CHENG P, WANG S, MA J, et al. Learning to Recommend Accurate and Diverse Items [C] // Proceedings of the 26th International Conference on World Wide Web. Perth Australia: International World Wide Web Conferences Steering Committee, 2017: 183-192.
- [21] ASHKAN A, KVETON B, BERKOVSKY S, et al. Optimal Greedy Diversity for Recommendation [C] // Twenty-Fourth International Joint Conference on Artificial Intelligence. 2015.
- [22] ZUO Y, LIU S, ZHOU Y. DTGCF: Diversified Tag-Aware Recommendation with Graph Collaborative Filtering [J]. Applied Sciences, 2023, 13(5): 2945.
- [23] YANG L, WANG S, TAO Y, et al. DGRc: Graph Neural Network for Recommendation with Diversified Embedding Generation [C] // Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining. 2023: 661-669.
- [24] ABADAL S, JAIN A, GUIRADO R, et al. Computing Graph Neural Networks: A Survey from Algorithms to Accelerators [J]. ACM Computing Surveys, 2022, 54(9): 1-38.
- [25] WAIKHOM L, PATGIRI R. Graph Neural Networks: Methods, Applications, and Opportunities [M]. arXiv, 2021.
- [26] ZHOU Y, ZHENG H, HUANG X, et al. Graph Neural Networks: Taxonomy, Advances and Trends [J]. ACM Transactions

- on Intelligent Systems and Technology,2022,13(1):1-54.
- [27] KIPF T N,WELLING M. Semi-supervised classification with graph convolutional networks[J]. arXiv:1609.02907,2016.
- [28] LI Z,LIU Z,HUANG J,et al. MV-GCN:Multi-View Graph Convolutional Networks for Link Prediction[J]. IEEE Access, 2019,7:176317-176328.
- [29] GAO X,FENG F,HUANG H,et al. Food recommendation with graph convolutional network[J]. Information Sciences, 2022, 584:170-183.
- [30] KIM J Y,CHO S B. A systematic analysis and guidelines of graph neural networks for practical applications[J]. Expert Systems with Applications,2021,184:115466.
- [31] LI Y. A graph convolution network based on improved density clustering for recommendation system[J]. Information Technology and Control,2022,51(1):18-31.
- [32] TANG X,YANG J,XIONG D,et al. Knowledge-enhanced graph convolutional network for recommendation [J]. Multimedia Tools and Applications,2022,81(20):28899-28916.
- [33] CHEN L,WU L,HONG R,et al. Revisiting Graph Based Collaborative Filtering: A Linear Residual Graph Convolutional Network Approach[J]. Proceedings of the AAAI Conference on Artificial Intelligence,2020,34(1):27-34.
- [34] WU F,ZHANG T,SOUZA Jr. A H de,et al. Simplifying Graph Convolutional Networks[M]. arXiv,2019.
- [35] MIKOLOV T,SUTSKEVER I,CHEN K,et al. Distributed Representations of Words and Phrases and their Compositionality [M]. arXiv,2013.
- [36] YANG Z,DING M,ZHOU C,et al. Understanding Negative Sampling in Graph Representation Learning[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Virtual Event CA USA: ACM,2020: 1666-1676.
- [37] ZHU Y,XU Y,LIU Q,et al. An Empirical Study of Graph Contrastive Learning[M]. arXiv,2021.
- [38] ZHU Y,XU Y,YU F,et al. Graph Contrastive Learning with Adaptive Augmentation[C]//Proceedings of the Web Conference 2021. 2021:2069-2080.
- [39] WEI Y,WANG X,NIE L,et al. Graph-Refined Convolutional Network for Multimedia Recommendation with Implicit Feedback[C]//Proceedings of the 28th ACM International Conference on Multimedia. New York, NY, USA: Association for Computing Machinery,2020:3541-3549.
- [40] ADOMAVICIUS G,KWON Y. Improving Aggregate Recommendation Diversity Using Ranking-Based Techniques[J]. IEEE Transactions on Knowledge and Data Engineering,2012,24(5): 896-911.
- [41] REDDI S J,KALE S,KUMAR S. On the Convergence of Adam and Beyond[M]. arXiv,2019.
- [42] WILHELM M,RAMANATHAN A,BONOMO A,et al. Practical Diversified Recommendations on YouTube with Determinantal Point Processes[C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management. Torino Italy:ACM,2018:2165-2173.



**HUANG Chungan**, born in 1998, post-graduate. His main research interests include graph neural networks, recommendation systems and big data analysis.



**WANG Guiping**, born in 1982, Ph.D, associate professor. His main research interests include graph theory algorithm, large-scale graph data analysis and processing.