

基于特征网络对比学习的图协同过滤模型研究

吴鹏远, 方伟

引用本文

吴鹏远, 方伟. 基于特征网络对比学习的图协同过滤模型研究[J]. 计算机科学, 2025, 52(5): 139-148.

WU Pengyuan, FANG Wei. [Study on Graph Collaborative Filtering Model Based on FeatureNet Contrastive Learning](#) [J]. Computer Science, 2025, 52(5): 139-148.

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)

[基于超图卷积和多角度拓扑细化的骨骼行为识别方法](#)

Hypergraph Convolutional Network with Multi-perspective Topology Refinement for Skeleton-based Action Recognition

计算机科学, 2025, 52(5): 220-226. <https://doi.org/10.11896/jsjcx.240600125>

[基于对比学习的大气湍流退化图像复原方法](#)

Restoration of Atmospheric Turbulence-degraded Images Based on Contrastive Learning

计算机科学, 2025, 52(5): 171-178. <https://doi.org/10.11896/jsjcx.240200020>

[基于图熵理论的图数据增强研究](#)

Study on Graph Data Augmentation Based on Graph Entropy Theory

计算机科学, 2025, 52(5): 149-160. <https://doi.org/10.11896/jsjcx.240200016>

[面向在线问诊平台的医生推荐方法及应用研究综述](#)

Review of Doctor Recommendation Methods and Applications for Consultation Platforms

计算机科学, 2025, 52(5): 109-121. <https://doi.org/10.11896/jsjcx.240600149>

[基于双分支小波卷积自编码器和数据增强的深度聚类方法](#)

Deep Clustering Method Based on Dual-branch Wavelet Convolutional Autoencoder and Data Augmentation

计算机科学, 2025, 52(4): 129-137. <https://doi.org/10.11896/jsjcx.240100111>

基于特征网络对比学习的图协同过滤模型研究

吴鹏远 方伟

江南大学人工智能与计算机学院 江苏 无锡 214122

(6213113122@stu.jiangnan.edu.cn)

摘要 基于图协同过滤的推荐技术因能高效处理大规模交互数据而备受关注,但现实场景中的数据稀疏性问题限制了其有效性。对比学习应用于图协同过滤可以增强其在数据稀疏性上的性能,但现有方法通常通过随机抽样方式构建对比对,未能充分发挥对比学习在推荐系统中的潜力。为此,提出一种基于特征网络对比学习的图协同过滤模型(FeatureNet Contrastive Learning, FCL)。该模型通过计算特征向量之间的余弦相似度和概率归一化策略建立节点特征相似度矩阵,再使用对比学习对节点特征相似度矩阵进行影响力分析以捕捉节点间的高阶连接性,还引入随机扰动来增强模型的鲁棒性。在多个数据集上进行大量实验,验证了所提模型的有效性,尤其在处理高稀疏度数据集时,效果更为明显。

关键词: 推荐算法; 对比学习; 协同过滤; 图神经网络; 数据增强

中图分类号 TP183

Study on Graph Collaborative Filtering Model Based on FeatureNet Contrastive Learning

WU Pengyuan and FANG Wei

School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi, Jiangsu 214122, China

Abstract Graph-based collaborative filtering recommendation techniques have gained significant attention for their ability to efficiently process large-scale interaction data. However, the effectiveness of these techniques is limited by the sparsity of data in real-world scenarios. Recent research has started to apply contrastive learning to graph collaborative filtering to enhance its performance. Nonetheless, existing methods often construct contrastive pairs through random sampling, failing to fully explore the potential of contrastive learning in recommendation systems. To address these issues, this paper introduces a collaborative filtering model based on FeatureNet Contrastive Learning (FCL). The model establishes a node feature similarity matrix by computing the cosine similarity between feature vectors and applying a probabilistic normalization strategy. Using contrastive learning to perform influence analysis on the node feature similarity matrix, the model captures high-order connectivity between nodes, particularly demonstrating significant effectiveness in handling datasets with high sparsity. Extensive experiments conducted on multiple datasets prove the effectiveness of the proposed model.

Keywords Recommendation algorithm, Contrastive learning, Collaborative filtering, Graph neural networks, Data augmentation

1 引言

在信息爆炸的时代,推荐系统对于识别用户偏好和高效提供在线服务起着至关重要的作用^[1]。推荐系统技术的进步为学术界、商业界以及工业界带来了显著的影响,它们在多个领域得到了广泛应用,包括社交网络(如QQ)、音乐平台(如网易云音乐)、视频服务(如Bilibili)、电子商务(如亚马逊)、旅游服务(如携程)以及在线订餐(如饿了么)等。特别是在电子商务领域,推荐系统为亚马逊带来了35%的销售额^[2],Netflix^[3]则有高达75%的收益来源于推荐。推荐系统之所以能够广泛应用,归功于学术界对其进行不断的深入探索和研究。协同过滤(Collaborative Filtering, CF)^[4-5]作为推荐系统的一种经典方法,通过分析用户的隐式反馈(如表达、点击、交易等)来产生有效推荐。近来,有研究通过结合图神经网络

(Graph Neural Networks, GNN)^[6-7],显著提升了协同过滤方法的效率。这种方法将交互数据构建成图(如用户-物品交互图),并利用GNN学习节点的有效表示,进而用于推荐。这一过程被称为图协同过滤。

尽管此方法取得了显著成效,但现有的图协同过滤方法仍面临问题。用户-物品交互数据通常是稀疏或含有噪声的,然而基于图的方法对数据的稀疏性特别敏感^[8],这就导致图协同过滤无法学习到可靠的表示。如果能够将高阶关系或相似性用于强化图信息,即在图结构中添加这些高阶关系和相似性作为新的边或对图结构中原有的边进行加权,则对推荐任务大有裨益,如文献[4,9-10]。这强调了在推荐系统中,除了用户与物品之间的直接交互外,用户-物品间的高阶关系和相似性也是至关重要的。近期一些研究^[8,11-12]已尝试通过对比学习来解决数据稀疏性的问题,包括随机选择节点或扰动

子图结构。然而,这些方法并未充分探索如何构建更有针对性、专为推荐系统设计的对比学习方法。

为了解决上述问题,本文提出了一种基于特征网络对比学习的图协同过滤模型(FCL),该模型通过计算特征向量之间的余弦相似度并采用概率归一化策略,建立了一个揭示用户与物品间潜在联系的节点特征相似度矩阵,并基于该相似度矩阵,提出了一种节点分类方法,使得该模型在使用对比学习时可以得到更精确的正负样本,从而提升了模型对用户-物品间高阶关系的理解力。尤其在处理高稀疏度数据集时,效果更为明显。该模型还引入随机扰动,增强了模型的鲁棒性。实验结果表明,该模型相较于原有基于 GNN 的推荐方法和现有对比学习方法,展现出了更优越的性能。本文的主要贡献如下:

1)提出了一种基于特征网络对比学习的图协同过滤模型。该模型通过余弦相似度计算得到了节点特征相似度矩阵,帮助模型更好地捕捉用户与物品间的潜在联系;还加入了随机扰动,以增强模型的鲁棒性。与现有的方法相比,该模型将相似度矩阵转换为图进行分析,更有效地利用了图结构,可解释性更强。

2)设计了一种适用于本模型的节点分类方法,使得模型能在对比学习过程中更准确地识别出关键节点,从而提高正负样本对的质量,更有效地捕获用户-物品间的高阶关系。

3)在4个公开数据集上进行了广泛的实验,结果表明 FCL 优于许多有竞争力的基准线,包括最新的基于 GNN 和对比学习的推荐方法。

2 相关工作

2.1 图协同过滤

近年来,基于图的协同过滤(Graph-based Collaborative Filtering, GCF)因在捕捉用户行为和物品特性方面的有效性而在推荐系统中备受关注。图神经网络(GNN)由于具有卓越的图数据表示能力^[13-14],已成为 GCF 方法的核心。传统的 GCF 方法,如矩阵分解(Matrix Factorization, MF)^[15-16],主要通过用户-物品交互矩阵学习隐藏特征。随着深度学习的发展,NGCF(Neural Graph Collaborative Filtering)^[17]开始利用 GNN 层来揭示用户与物品之间的复杂关系,实现了对用户偏好更深层次的理解。此外,简化的 GNN 模型,如 LightGCN^[6],通过降低模型复杂度,实现了更高效的推荐效果。尽管现有的 GCF 方法取得了显著成就,但在处理大规模且高度稀疏的数据集方面,它们仍然面临挑战。这些方法往往只关注直接的用户-物品交互,忽略了用户或物品间可能存在的潜在的、间接的相似性关系。

2.2 对比学习

对比学习已经在计算机视觉^[17]和自然语言处理^[18-19]等领域取得显著成果。在计算机视觉中,如 SimCLR, MoCo 和 BYOL 等方法^[20-22],通过增强图像及其变体之间相似性的学习,被广泛应用于无监督和自监督学习。在自然语言处理中,如 BERT^[23]及其变体,通过对比性预测任务,深入学习文本表示。其他方法,如 Contrastive Tension^[24]和 InfoNCE^[25],通过对比句子嵌入,增强对文本语义的理解。在图数据处理中,

对比学习同样有效,例如 GraphSAGE^[26]通过对比节点表示来深化对图结构的理解。跨模态对比学习,如 CLIP 和 ViL-BERT 等^[27-29],通过对比不同模态(如文本和图像)的表示,学习更通用和鲁棒的特征表示。这些研究展示了对比学习在学习高质量特征表示方面的潜力与灵活性。

在推荐系统领域,对比学习通过强化模型对正负样本对的区分能力,帮助推荐系统更深入地挖掘和理解用户与物品之间的高阶关系。不同于传统图协同过滤方法仅依赖于直接交互数据构建用户-物品关系,对比学习引入的自监督机制能够探索和利用用户与物品间未直接表达的潜在联系。通过构建正负样本对,并让模型学习区分这些样本,对比学习不仅增强了模型对已有交互的理解,而且还能捕捉到那些通过传统方法难以直接发现的复杂模式和隐藏信息。虽然 SGL^[8], NCL^[30]等研究已应用对比学习,但这些方法在构建对比学习正负样本对、捕捉用户或物品间深层次的联系时仍有不足。

3 基本概念

协同过滤(CF)作为推荐系统的基础,旨在基于用户的隐式反馈(如表达、点击和交易)来推荐他们可能感兴趣的物品。考虑用户集合 $U = \{u\}$ 和物品集合 $I = \{i\}$,隐式反馈矩阵表示为 $R \in \{0, 1\}^{|U| \times |I|}$ 。在这个矩阵中,若用户 u 与物品 i 之间存在互动,则对应的矩阵元素 $R_{u,i} = 1$;如果没有互动,则 $R_{u,i} = 0$ 。基于这些交互数据,推荐系统可以预测用户可能感兴趣的物品。传统的协同过滤方法尽管能够有效地捕捉用户与物品之间的直接交互,但在处理复杂的用户行为模式和物品之间的关系时存在局限性。为了突破这些限制,进一步提升推荐系统的性能,学者们展开了对 GNN 的研究。

基于图神经网络(GNN)的协同过滤方法^[6-7, 31]将交互数据 R 构建成为一个交互图 $G = (V, E)$,其中 $V = U \cup I$ 是节点集合, $E = \{(u, i) | u \in U, i \in I, R_{u,i} = 1\}$ 是边的集合。通过以下两个阶段产生信息丰富的用户和物品表示。

1)传播阶段:定义传播函数 $f_{\text{propagate}}(\cdot)$,对于用户 u ,该函数聚合其邻居在 $(l-1)$ 层的表示,形成 l 层的表示 $z_u^{(l)}$ 。这里 $z_u^{(0)}$ 通常由可学习的嵌入向量 e_u 初始化,并且 N_u 表示用户 u 在交互图 G 中的邻居集合。

$$z_u^{(l)} = f_{\text{propagate}}(z_u^{(l-1)}, N_u), \text{ for all } l = 1, \dots, L \quad (1)$$

2)阅读阶段:定义阅读函数 $f_{\text{readout}}(\cdot)$,用于整合用户 u 经过 L 层传播后所有层次的表示,从 $[z_u^{(0)}, z_u^{(1)}, \dots, z_u^{(L)}]$ 中得出用户 u 的最终推荐表示。

$$z_u = f_{\text{readout}}([z_u^{(0)}, z_u^{(1)}, \dots, z_u^{(L)}]) \quad (2)$$

经过 L 次迭代传播后,用户的 L 跳邻居信息被编码进 $z_u^{(L)}$ 中。物品的表示 z_i 可以通过类似的方式获得。以上过程体现了 GNN 在推荐系统中的应用,通过结合用户-物品之间的直接交互以及用户和物品的结构化邻域信息, GNN 能够产生高度信息化的表示,这些表示对于提高推荐的准确性和效果至关重要。通过这样的传播和聚合机制,用户和物品的 L 跳邻居的信息被有效地编码进它们的最终表示,为后续的推荐任务提供了丰富的信息。

4 基于特征网络对比学习的图协同过滤模型研究

本章将详细介绍 FCL,其主要步骤如下:首先通过计算

特征向量之间的余弦相似度并采用概率归一化策略,建立揭示用户与物品间潜在联系的节点特征相似度矩阵;通过引入随机扰动,增强模型的鲁棒性;其次,使用对比学习对节点特征相似度矩阵进行影响力分析;最后,结合多任务学习策略,优化节点间的对比学习,提升了推荐的准确性和效率。其整体流程如算法 1 所示。

算法 1 FCL 模型整体流程

输入:用户-物品交互数据

输出:推荐列表

1. /* 初始化 */;
2. 从用户-物品交互数据中构建初始图结构;
3. 初始图结构输入到 LightGCN,获得节点的特征嵌入;
4. 计算这些特征嵌入之间的余弦相似度,得到相似度矩阵 \mathbf{simM} ;
5. /* 随机扰动 */;
6. 生成一个随机权重矩阵 \mathbf{W} ,维度与 \mathbf{simM} 相同;
7. 使用元素对应乘法计算加权相似度矩阵 $\mathbf{M}=\mathbf{W}\odot\mathbf{simM}$;
8. /* 概率归一化 */;

9. 对加权相似度矩阵 \mathbf{M} 的每一行应用 Sigmoid 函数得到变换矩阵 \mathbf{H} ;
10. 对变换矩阵 \mathbf{H} 的每一行应用 Softmax 函数计算概率分布,得到影响力矩阵 \mathbf{P} ;
11. /* 节点分类 */;
12. 计算影响力矩阵 \mathbf{P} 每一行的和,以此作为节点的影响力得分;
13. 根据影响力得分选出影响力最大的 n 个节点作为关键节点;
14. 除关键节点外的其他节点,基于其在影响力矩阵 \mathbf{P} 中的值,找到与其最相关的关键节点;
15. /* 对比学习 */;
16. 选择关键节点作为正样本,并将与这些关键节点匹配的其他节点视为负样本,利用对比学习得到对比学习损失;
17. /* 模型优化和生成推荐列表 */;
18. 采用多任务学习策略,同时训练 BPR 损失与对比学习损失;
19. 通过期望最大化(EM)算法进一步优化,并更新节点嵌入;
20. 基于更新后的嵌入,为每个用户生成推荐列表。

算法 1 展示了 FCL 的完整流程,其核心流程如图 1 所示,包括随机扰动、概率归一化、节点分类和对比学习。

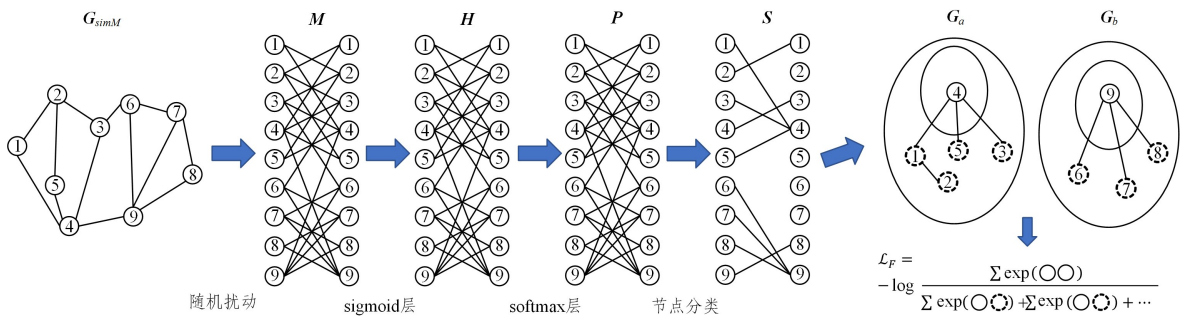


图 1 FCL 核心流程

Fig. 1 FCL core process

观察图 1 可知,图 G_{simM} 包含编号为 1-9 的 9 个节点,由特征矩阵经余弦相似度计算得到的相似度矩阵 \mathbf{simM} 构建而成。 G_{simM} 中每个用户或物品是一个节点,节点间的边的权重由相似度给出。先将相似度矩阵 \mathbf{simM} 加入随机扰动得到加权相似度矩阵 \mathbf{M} ,再将加权相似度矩阵 \mathbf{M} 通过 sigmoid 得到变换矩阵 \mathbf{H} ;然后在 \mathbf{H} 上应用 softmax 得到影响力矩阵 \mathbf{P} ,通过 argmax 得到分类矩阵 \mathbf{S} ;最后将矩阵 \mathbf{S} 转换为图 G_a 和图 G_b 。通过以上步骤,将图 G_{simM} 拆分成了 G_a 和 G_b 。根据图 G_a 和 G_b 可以明显看出节点 4 和节点 9 为相似度矩阵 G_{simM} 中最具影响力的两个节点,即网络中的关键节点。由图 G_a 中节点 4 为关键节点,节点 1,2,3,5 和节点 4 具有连接关系,因此将节点 4 视为对比学习的正样本,节点 1,2,3,5 视为对比学习的负样本,计算得到其对比学习损失;图 G_b 同理。上述核心流程将在 4.2 节中进行更详细的介绍。

4.1 基于 GNN 的 CF 方法

如第 2 章所述,基于图神经网络(GNN)的方法通过在交互图 G 上应用传播和预测函数,生成用户和物品的表示。具体地,遵循 LightGCN^[6] 的策略,在传播函数中省去非线性激活和特征转换:

$$z_u^{(t+1)} = \sum_{i \in N_u} \frac{1}{\sqrt{|\mathcal{N}_u|} \|\mathcal{N}_i\|} z_i^{(t)} \quad (3)$$

$$z_i^{(t+1)} = \sum_{u \in N_i} \frac{1}{\sqrt{|\mathcal{N}_i|} \|\mathcal{N}_u\|} z_u^{(t)} \quad (4)$$

经过 L 层传播后,使用加权求和函数作为聚合函数,将所有层的表示合并,从而得到以下最终表示:

$$z_u = \frac{1}{L+1} \sum_{l=0}^L z_u^{(l)} \quad (5)$$

$$z_i = \frac{1}{L+1} \sum_{l=0}^L z_i^{(l)} \quad (6)$$

其中, z_u 和 z_i 分别表示用户 u 和物品 i 的最终表示。使用这些最终表示,采用内积来预测用户 u 与物品 i 交互的可能性。

$$\widehat{y}_{u,i} = z_u^T z_i \quad (7)$$

其中, $\widehat{y}_{u,i}$ 是用户 u 和物品 i 的预测得分。

为了更直接地捕捉交互信息,采用贝叶斯个性化排序(Bayesian Personalized Ranking, BPR)^[6] 计算损失,可以确保观察到的交互的预测得分高于未观察到的、随机抽样的交互。BPR 损失的目标函数如下:

$$\mathcal{L}_{BPR} = \sum_{(u,i,j) \in O} -\log \sigma(\widehat{y}_{u,i} - \widehat{y}_{u,j}) \quad (8)$$

其中, $\sigma(\cdot)$ 是 sigmoid 函数, $O = \{(u, i, j) | R_{\{u, i\}} = 1, R_{\{u, j\}} = 0\}$ 表示成对的训练数据集,而 j 表示用户 u 未进行交互的抽样物品。

通过优化 BPR 的损失 \mathcal{L}_{BPR} , 能够有效地建模用户与物品之间的直接交互。然而,在推荐系统中,关键之一是理解并利用用户或物品之间的高阶邻居关系,如用户之间的相似购买行为或物品间的相似特性。利用这些高阶邻居关系可以使推荐系统更准确地预测用户偏好,生成更个性化的推荐。本文

接下来将介绍邻域增强对比学习(NCL^[30])——一种对用户和物品间交互建模的方法。NCL提出了两种对比学习目标:结构邻居和语义邻居。

4.1.1 NCL的结构邻居

关于结构邻居,在图协同过滤模型中,通过GNN层级传播,用户或物品的初始嵌入 $z^{(0)}$ 被用来捕捉和聚合多跳邻居的信息。特别关注偶数层输出(如第2,4,6层),这些层自然地聚合了同质结构邻居(即用户间或物品间的邻居)的信息。基于这些信息,模型使用结构对比学习目标来优化用户或物品及其同质结构邻居之间的嵌入,以捕获和模拟它们之间的关系。具体来说,在结构对比学习目标中,把用户自身的嵌入和与之对应的偶数层GNN输出的嵌入看作一对正样本,然后最小化这两种嵌入之间的距离。具体实现方式如下:

$$\mathcal{L}_s^U = \sum_{u \in U} -\log \frac{\exp((z_u^{(k)} \cdot z_u^{(0)} / \tau))}{\sum_{v \in U} \exp((z_u^{(k)} \cdot z_v^{(0)} / \tau)} \quad (9)$$

在该模型中, $z^{(0)}$ 代表用户或物品的初始特征或可学习嵌入,而 $z^{(l)}$ 是基于图神经网络的第 l 层输出,表示经过 l 跳传播后节点的累积邻居信息, $z^{(k)}$ 是第 k 层图神经网络的标准化输出,且 k 为偶数。 τ 是softmax函数的温度超参数。采用同样的方法,可以得到物品方面的结构对比损失 \mathcal{L}_s^I :

$$\mathcal{L}_s^I = \sum_{i \in J} -\log \frac{\exp((z_i^{(k)} \cdot z_i^{(0)} / \tau))}{\sum_{j \in J} \exp((z_i^{(k)} \cdot z_j^{(0)} / \tau)} \quad (10)$$

结构邻居的对比学习损失函数是上述两个损失的加权和。

$$\mathcal{L}_s = \mathcal{L}_s^U + \alpha \mathcal{L}_s^I \quad (11)$$

其中, α 是一个超参数,用于平衡结构对比学习中两个损失的权重。

4.1.2 NCL的语义邻居

语义邻居指在交互图上不直接可达但具有相似特征或偏好的节点。通过学习每个用户和物品的潜在原型,就能够识别出这些语义邻居。将它们整合到对比学习中,从而更好地捕获协同过滤中用户和物品的语义特性。具体而言,相似的用户或物品倾向于聚集在相邻的嵌入空间中,而原型代表了一组语义邻居的聚集中心。对于用户和物品的嵌入,应用K-means聚类算法来获取用户或物品的原型。从形式上来说,图神经网络(GNN)模型的目标是最大化以下对数似然函数:

$$\sum_{u \in U} \log p(e_u | \Theta, \mathbf{R}) = \sum_{u \in U} \log \sum_{c_i \in C} p(e_u, c_i | \Theta, \mathbf{R}) \quad (12)$$

其中, Θ 是模型参数的集合, \mathbf{R} 是交互矩阵。而 \bar{u} 是用户 u 的潜在原型。类似地,也可以为物品定义优化目标,即根据所提出的原型对比学习目标来最小化以下函数:

$$\mathcal{L}_p^U = \sum_{u \in U} -\log \frac{\exp(e_u \cdot c_i)}{\sum_{c_j \in C} \exp(e_u \cdot c_j)} \quad (13)$$

其中, c_i 是用户 u 的原型,通过对所有用户嵌入应用K-means算法进行聚类获得,整体上将所有用户分为 k 个簇。同理,物品的目标也是相同的:

$$\mathcal{L}_p^I = \sum_{i \in J} -\log \frac{\exp(e_i \cdot c_j / \tau)}{\sum_{c_l \in C} \exp(e_i \cdot c_l / \tau)} \quad (14)$$

其中, c_j 是物品 i 的原型。

语义邻居的对比学习损失函数是上述两个损失的加权和:

$$\mathcal{L}_p = \mathcal{L}_p^U + \alpha \mathcal{L}_p^I \quad (15)$$

4.2 基于特征网络的对比学习模型

在推荐系统中,准确评估节点的影响力至关重要。虽然传统的K-means聚类方法在节点分类上有其应用价值,但在处理个性化推荐需求时,它存在一些局限。鉴于此,本文提出了一种新的基于特征相似度的影响力分析方法,旨在通过精细化的特征分析来识别网络中的关键影响力节点,从而弥补K-means在某些方面的不足。本文方法不仅考虑了节点间的直接关系,还通过构建相似性矩阵并结合随机权重矩阵,提高了模型的泛化能力。相较于K-means聚类,本文方法在每次迭代中通过随机权重生成,能更好地适应和揭示网络中的动态变化,这对于捕捉复杂的用户行为模式至关重要。

与传统分类方法相比,本文方法更加适用于推荐领域。通过每次迭代中的随机权重矩阵引入随机扰动,能更精确地捕捉复杂的用户行为模式。利用sigmoid和softmax函数对相似度矩阵进行非线性转换和概率化处理,实现了更细粒度的影响力评估。这样的处理不仅有助于捕捉更精确的用户-物品关系,还能识别潜在的、非显式的相似关系,为个性化推荐提供更丰富的信息,从而更全面地捕捉网络中的潜在交互模式,为个性化推荐提供更丰富的信息。

4.2.1 关键节点识别

本文构建了一个相似度矩阵图 G_{simM} ,其中的节点代表用户或物品,节点间的连接通过余弦相似度矩阵 $simM \in R^{N \times N}$ 表示。这个相似度矩阵是基于用户特征嵌入计算得到的,其中 N 表示图中的节点数量,即用户或物品的总数。

为了增强模型的泛化能力并放大用户间的潜在影响力,加入了随机扰动。具体地,在每一轮迭代 t 中生成一个 $N \times N$ 的随机权重矩阵 W^t ,其元素从区间 $[0,1]$ 的均匀分布 $U(0,1)$ 中独立抽取。然后,这个随机矩阵 W^t 与相似度矩阵 $simM$ 进行逐元素乘法,这一过程在 T 轮迭代中重复进行,并将每一轮的结果累加,形成了扰动后的相似度矩阵 M 。这样不仅考虑了用户间的直接相似性,还通过引入随机扰动来探索了潜在的间接影响,具体计算式如下:

$$W^t \sim U(0,1)^{N \times N} \quad (16)$$

$$M = \sum_{t=0}^T W^t \odot simM \quad (17)$$

然后,对相似度矩阵 M 应用Sigmoid函数进行非线性变换,得到变换矩阵 H :

$$H_k = \sigma(M_k) = \frac{1}{1 + e^{-M_k}} \quad (18)$$

其中, H_m 和 M_m 分别表示矩阵 H 和矩阵 M 的第 m 行。

对于变换矩阵 H ,将 H_m 通过Softmax函数转换为概率分布,并将节点自连接的概率设置为零,以防止自身影响计算:

$$P_m = \text{softmax}(H_m) = \frac{e^{H_m}}{\sum_{j=1}^N e^{H_m[j]}} \quad (19)$$

$$P_m[m] = 0 \quad (20)$$

由此,构建了节点的影响力矩阵 P ,使得能够从中提取出每个节点 c_i 的综合影响力得分 $Score_i$ 。

$$Score_i = \sum_{m=0}^N P_i[m] \quad (21)$$

基于该得分可以进一步筛选出总影响力最高的 n 个节点

c_j ,将它们标定为关键节点,并在对比学习中作为正样本使用。

4.2.2 节点分类和对比学习

在成功识别出总影响力最高的 n 个关键节点 c_j 后,专注于将网络中的其他节点有效地分配给这些关键节点,即分析剩余节点如何受到这些关键节点的影响。此过程旨在揭示网络中每个节点与关键节点之间的联系,从而为后续的基于对




图2 节点分类

Fig. 2 Nodes classification

根据图2可以看出,通过分析热力度矩阵中的 Score 列,可以明确地识别出关键节点为 c_4 和 c_9 。以节点 c_1 为例,对比其与节点 c_4 和 c_9 的得分,可以发现 c_4 的得分更高。因此,将节点 c_1 与节点 c_4 归为一类。

根据上述方法,对于用户 u ,从关键节点 c_j 出发,得到分组后的 c_i 。在对比学习中,将 c_j 视为正样本,将 c_i 视为负样本,物品 i 同理。基于 InfoNCE,对比学习的目标旨在最小化这些节点间的距离。用户和物品的具体实现方式如下:

$$\mathcal{L}_F^U = \sum_{u \in U} -\log \frac{\exp(e_u \cdot c_j)}{\sum_{c_j \in U} \exp(e_u \cdot c_j)} \quad (22)$$

$$\mathcal{L}_F^I = \sum_{i \in I} -\log \frac{\exp(e_i \cdot c_k)}{\sum_{c_i \in I} \exp(e_i \cdot c_i)} \quad (23)$$

其中, c_j 是用户 u 的关键节点, c_k 是物品 i 的关键节点。对比学习的损失是上述两个损失的加权和。

$$\mathcal{L}_L = \mathcal{L}_F^U + \alpha \mathcal{L}_F^I \quad (24)$$

其中, α 是一个超参数,用于平衡结构对比学习中两个损失的权重。

4.3 模型优化

本节详细介绍了对比学习目标的整体损失函数,以及采用期望最大化 (Expectation-Maximization, EM)^[32] 算法进行优化的过程。

4.3.1 训练目标

在整体训练目标中,鉴于协同过滤的核心在于建模用户与物品之间的交互关系,将所提出的对比学习损失作为辅助性的增强。因此,采取了一种多任务学习策略,将传统的排名损失与新提出的对比损失同时训练,实现更全面和有效的学习过程。

$$\mathcal{L} = \mathcal{L}_{\text{BPR}} + \lambda_1 \mathcal{L}_S + \lambda_2 \mathcal{L}_F + \lambda_3 \|\Theta\|_2 \quad (25)$$

其中, λ_1 , λ_2 和 λ_3 为超参数,用于调节所提出的对比学习目标以及正则化项的权重,而 Θ 代表整个 GNN 模型的参数集合。

4.3.2 EM 算法

在期望步骤 (E-step) 中,计算每个用户嵌入 e_u 与聚类中心

对比学习的图协同过滤方法提供基础。

基于关键节点在网络中影响力的间接关系,节点分类方法如下:对于每个节点 c_i ,寻找其在影响力矩阵 P 中与每个关键节点 c_j 的影响力分数;然后,将每个非关键节点与其影响力分数最高的关键节点进行配对。这样就实现了网络中节点的分类,其具体过程如图2所示。

c_i 之间的概率 $P(c_i | e_u)$,这一步骤通过概率模型实现,其中参数 α 不仅调节着边界的硬度,而且还决定了识别关键节点过程的灵活性与严格性,这样能够根据数据的特性,灵活地优化边界。 $P(c_i | e_u)$ 的表达式如下:

$$P(c_i | e_u) = \frac{\exp(-\alpha |e_u - c_i|^2)}{\sum_{c_j \in C} \exp(-\alpha |e_u - c_j|^2)} \quad (26)$$

进入最大化步骤 (M-step) 时,目标转向优化每个关键节点的位置,以增强整体数据的对数似然性。确保它们能够更准确地反映用户群体的核心特征,有助于揭示用户行为的深层次模式。

$$c_i^{\text{new}} = \frac{\sum_{u \in U} P(c_i | e_u) \cdot e_u}{\sum_{u \in U} P(c_i | e_u)} \quad (27)$$

其中, c_i^{new} 表示更新后的聚类中心,它是根据 $P(c_i | e_u)$ 作为权重的用户嵌入的加权平均。

目标函数 L_F^U 被用于量化用户 (或物品) 与其所属关键节点之间的总体距离,这一目标的最小化过程是至关重要的,因为它直接影响着聚类的质量和用户群体划分的准确性。

$$L_P^U = \sum_{u \in U} \sum_{c_i \in C} -P(c_i | e_u) \cdot \log \left(\frac{\exp(-\beta |e_u - c_i|^2)}{\sum_{c_j \in C} \exp(-\beta |e_u - c_j|^2)} \right) \quad (28)$$

其中,参数 β 起到正则化作用,通过调节模型对于用户 (或物品) 与关键节点之间的敏感度,确保了模型在捕捉用户行为和偏好时的精细度与平衡。

4.4 生成推荐列表

FCL 基于已有的用户与项目之间的交互,预测用户对其其他项目的交互,用式(7)计算用户对项目的偏好程度并进行降序排序,取 Top-N 生成推荐列表。

4.5 模型讨论

4.5.1 模型特点

通过特征分析,FCL 准确识别出网络中的关键影响力节点,特别是在处理高度稀疏的数据集时,展现出更高的适应性

和灵活性。在节点间互动编码方面,模型通过构建图 G_{simM} 和影响力矩阵 \mathbf{P} ,加上随机权重矩阵,在捕捉用户(或物品)间的细微关系方面表现优异。

此外,通过对相似度矩阵的非线性变换和概率化处理,本文为推荐系统提供了更精细的影响力评估,强化了用户-物品直接交互,并能识别和利用潜在的非显式相似关系。同时,在对比学习应用上,结合影响力矩阵,提出了更适合本文模型的节点分类方法,构建了更精确的正负样本对,帮助模型深入理解网络中节点间的联系。

4.5.2 时间复杂度

在提出的对比学习目标中,假设抽取 S 个用户或物品作为负样本。该方法的时间复杂度大致为 $O(N \cdot (S+n) \cdot d)$,其中 N 代表用户和物品总数, n 为定义的关键节点数, d 为嵌入向量维度。当设置 $S \ll N$ 时,总时间复杂度整体上与用户和物品的数量线性相关。特别地,FCL在空间使用上比其他自监督方法(如SGL^[8])节省近一半,因为它利用了用户和物品内部的关系,而非显式数据增强。总体而言,提出的FCL是一种高效的推荐系统模型,适用于协同过滤任务。

5 实验设置与分析

5.1 实验数据集

为了评估所提出的FCL模型的性能,使用4个常用公共数据集进行实验,包括MovieLens-1M(ML-1M)^[33],Yelp,Amazon-Books^[34]以及Gowalla^[35]。

这些数据集在领域、规模和密度上都不同。对于Yelp和Amazon Books数据集,过滤掉互动少于15次的用户和物品,以确保数据质量。数据集的统计信息如表1所列。对于每个数据集,随机选择80%的互动作为训练数据,10%的互动作为验证数据,剩余的10%互动用于性能比较。并为每个正例均匀地抽样一个负例物品,以形成训练集。

表1 数据集的统计信息

Table 1 Statistics of datasets

数据集	用户数量	项目数量	交互总数
ML-1M	6041	3629	836478
Yelp	45478	30709	1777765
Amazon-Books	58145	58052	2517437
Gowalla	29859	40989	1027464

5.2 评价指标

为了评估Top-N的推荐性能,采用了两种广泛使用的指标,即召回率@N(Recall@N)和归一化折扣累积增益@N(ND-CG@N),其中 N 分别设置为10,20和50。为保持一致性,

采用全排名策略^[36],对用户尚未互动过的所有候选项进行排名。

5.3 对比算法

将本文方法与以下base-line方法进行比较。

1)BPRMF^[16]:通过矩阵分解(MF)框架优化BPR损失,学习用户和物品的潜在表示。

2)NeuMF^[5]:用多层感知机取代了MF模型中的点积,学习用户和物品的匹配函数。

3)NGCF^[7]:采用用户-物品二分图来纳入高阶关系,并利用GNN增强协同过滤方法。

4)MultiGCCF^[9]:除了用户-物品二分图,还传播高阶相关用户(和物品)间的信息。

5)DGCF^[31]:为用户和物品生成解耦的表示,以提高推荐性能。

6)LightGCN^[6]:简化了GCN的设计,使其更加简洁且适用于推荐。

7)NCL^[30]:通过结合图协同过滤和对比学习,利用结构性和语义邻居提升性能。

5.4 实验参数设置

为确保实验的公平性,对比较模型的参数进行了统一配置。具体而言,将嵌入维度统一设置为64,采用Adam作为优化器。学习率在0.0001~0.005范围内选择,L2正则化系数则在 $10^{-5} \sim 10^{-3}$ 之间进行调整,dropout比率设置在0~0.8范围内。此外,模型的层数设定在1~4层。

5.5 实验结果分析

表2列出了FCL与其他base-line方法在4个数据集上的性能比较。可以得出以下结论:

1)与传统方法(如BPRMF)相比,基于GNN的方法由于能够将双分图的高阶信息编码进表示中而表现更好。在所有图协同过滤基线模型中,LightGCN在大多数数据集上表现最佳,显示出简化架构的有效性和鲁棒性。但Multi-GCCF在ML-1M数据集上的表现不如NGCF,可能是因为直接从用户-物品图构建的投影图过于密集。此外,解耦表示学习方法DGCF的表现不如LightGCN,尤其是在稀疏数据集上。

2)对于自监督方法,NCL^[30]在5个数据集上都优于其他监督方法,显示了对比学习在改善推荐性能方面的有效性。然而,NCL忽略了推荐系统中的某些潜在关系,如用户物品的相似性。

3)可以看到,FCL在各数据集上都优于基线方法。这一优势来自于其对关键节点的寻找和与其对应的对比学习目标。

表2 FCL与基线方法的性能比较

Table 2 Performance comparison between FCL and baseline methods

Dataset	Metric	BPRMF	NeuMF	NGCF	MultiGCCF	DGCF	LightGCN	NCL	FCL	Improvement/%
MovieLens-1M	Recall@10	0.1799	0.1657	0.1844	0.1832	0.1885	0.1876	0.1978	0.2128	7.05
	NDCG@10	0.2466	0.2298	0.2524	0.2512	0.2521	0.2510	0.2711	0.2851	4.91
	Recall@20	0.2716	0.2518	0.2740	0.2761	0.2778	0.2792	0.2928	0.3075	4.78
	NDCG@20	0.2569	0.2403	0.2611	0.2615	0.2619	0.2616	0.2761	0.2884	4.26
	Recall@50	0.4299	0.4124	0.4342	0.4361	0.4419	0.4465	0.4465	0.4711	5.22
	NDCG@50	0.3010	0.2850	0.3057	0.3055	0.3078	0.3092	0.3115	0.3297	5.52

(续表)										
Dataset	Metric	BPRMF	NeuMF	NGCF	MultiGCCF	DGCF	LightGCN	NCL	FCL	Improvement/%
Yelp	Recall@10	0.0639	0.0526	0.0630	0.0650	0.0722	0.0735	0.0903	0.0935	3.42
	NDCG@10	0.0462	0.0377	0.0450	0.0455	0.0514	0.0519	0.0659	0.0682	3.37
	Recall@20	0.1041	0.0886	0.1026	0.1055	0.1132	0.1158	0.1367	0.1416	3.46
	NDCG@20	0.0576	0.0486	0.0564	0.0577	0.0636	0.0654	0.0817	0.0843	3.08
	Recall@50	0.1866	0.1649	0.1864	0.1887	0.1984	0.2013	0.2181	0.2261	3.54
	NDCG@50	0.0791	0.0686	0.0786	0.0795	0.0860	0.0877	0.1033	0.1076	4.00
Amazon-Books	Recall@10	0.0604	0.0511	0.0619	0.0621	0.0740	0.0796	0.0913	0.0944	3.28
	NDCG@10	0.0433	0.0354	0.0423	0.0435	0.0518	0.0564	0.0679	0.0704	3.55
	Recall@20	0.0957	0.0820	0.0974	0.0994	0.1201	0.1207	0.1379	0.1411	2.27
	NDCG@20	0.0541	0.0442	0.0539	0.0544	0.0642	0.0686	0.0802	0.0821	2.31
	Recall@50	0.1682	0.1447	0.1618	0.1689	0.1905	0.2012	0.2166	0.2193	1.23
	NDCG@50	0.0725	0.0613	0.0723	0.0729	0.0838	0.0900	0.1016	0.1033	1.65
Gowalla	Recall@10	0.1154	0.1034	0.1187	0.1104	0.1254	0.1359	0.1456	0.1527	4.65
	NDCG@10	0.0828	0.0734	0.0851	0.0791	0.0900	0.0871	0.1077	0.1121	3.93
	Recall@20	0.1693	0.1538	0.1757	0.1621	0.1825	0.1976	0.2084	0.2165	3.74
	NDCG@20	0.0988	0.0870	0.1012	0.0935	0.1070	0.1152	0.1209	0.1321	8.48
	Recall@50	0.2757	0.2515	0.2813	0.2635	0.2876	0.3047	0.3110	0.3256	4.48
	NDCG@50	0.1453	0.1110	0.1267	0.1188	0.1324	0.1409	0.1485	0.1536	3.32

5.6 模型收敛性分析

为了全面评估所提模型的性能稳定性,在 ML-1M 和 Yelp 数据集上展示了模型的收敛曲线,记录了每个训练轮次(Epoch)的损失函数值(Loss),以监控模型训练过程的稳定性和收敛速度。本文模型展现出了良好的收敛性,可视化结果如图 3 所示。




图 3 收敛曲线

Fig. 3 Convergence curve

5.7 消融实验

为了验证所提出的特征网络邻居方法的有效性,本文通过消融实验来深入分析其对整体性能贡献。实验结果如图 4 所示。实验中比较了完整的 FCL 模型与去除特征网络对比学习后的 FCL 变体(标记为“w/o”),以观察它们之间的性能差异。结果表明,去除特征网络对比学习会导致整体性能的显著下降,这说明了特征网络对比学习在提升图协同过滤方法中的重要性。在模型中整合这些特征网络邻居不仅丰富了用户和物品之间的关系建模,而且在处理复杂的交互模式和提高推荐系统的准确性方面发挥了关键作用。




图 4 FCL 的消融实验结果

Fig. 4 Ablation experimental results of FCL

5.8 数据稀疏度实验

为了深入验证提出的 FCL 模型在缓解数据稀疏性方

面的有效性,本节专注于评估 FCL 在不同稀疏水平用户群体上的性能表现。具体而言,根据用户的互动频率将所有用户划分为 4 个不同的组别 G1, G2, G3 和 G4,并确保每组中的总互动次数保持一致。随后,对比了 FCL 与 LightGCN 在这 4 组用户上的推荐效果,结果如图 5 所示。从图 5 中明显可以看出,FCL 的表现在所有情况下都优于 LightGCN。值得注意的是,随着用户互动次数的减少,FCL 带来的性能提升更加显著。这一结果表明,FCL 在用户交互较少的情况下仍然能够提供高质量的推荐,很大程度上归功于其独特的特征网络邻居分析方法。这种方法能够有效捕捉用户行为中的微妙模式,进而在稀疏数据环境中提升推荐的准确性和相关性。




图 5 FCL 的稀疏实验结果

Fig. 5 Sparse experimental results of FCL

5.9 模型参数分析

1) 温控参数 τ

如先前研究^[20,37]所述,式(22)和式(23)中定义的温度 τ 在对比学习中起着重要作用。为了分析温度对 FCL 的影响,将 τ 的范围设置为 0.05~0.15,结果如图 6(a)所示。可以观察到,当 τ 设置过高时,模型性能会下降,这一现象与先前研究^[37]中的发现一致。这可能是因为在优化过程中引入了更大的噪声,从而影响了学习的准确性和效率。

2) 关键节点数 n

为了探讨关键节点数量对对比学习目标的影响,将关

键节点数量设置在数百至数千之间。这一设置旨在评估不同数量的关键节点对 FCL 模型整体表现的影响。实验结果如图 6(b) 所示。从图中可见, 无论关键节点数量如何变化, FCL 的表现始终优于传统的基线模型。这一发现表明, 引入更多的关键节点有助于减小由特征网络邻居带来的噪声影响, 提升了模型在处理复杂数据环境中的稳健性。

3) 随机权重矩阵扰动次数 N

为了探究随机权重矩阵采样次数对 FCL 性能的影响, 设

置了不同的扰动次数, 从数十次到数百次不等, 并通过将 N 设置为零来移除随机权重矩阵。这些不同次数的设置旨在评估随机扰动在模型中的作用和重要性。结果如图 6(c) 所示。不同的扰动次数会对模型的稳定性和抗噪能力产生影响, 从而反映在最终的推荐性能上。适当的扰动次数可能会提高模型对稀疏数据和复杂用户行为模式的适应性, 而过多或过少的次数可能会导致性能下降或过度拟合, 尤其是当次数为零时, 性能显著下降。这表明引入随机扰动提高 FCL 的推荐性能非常有效。

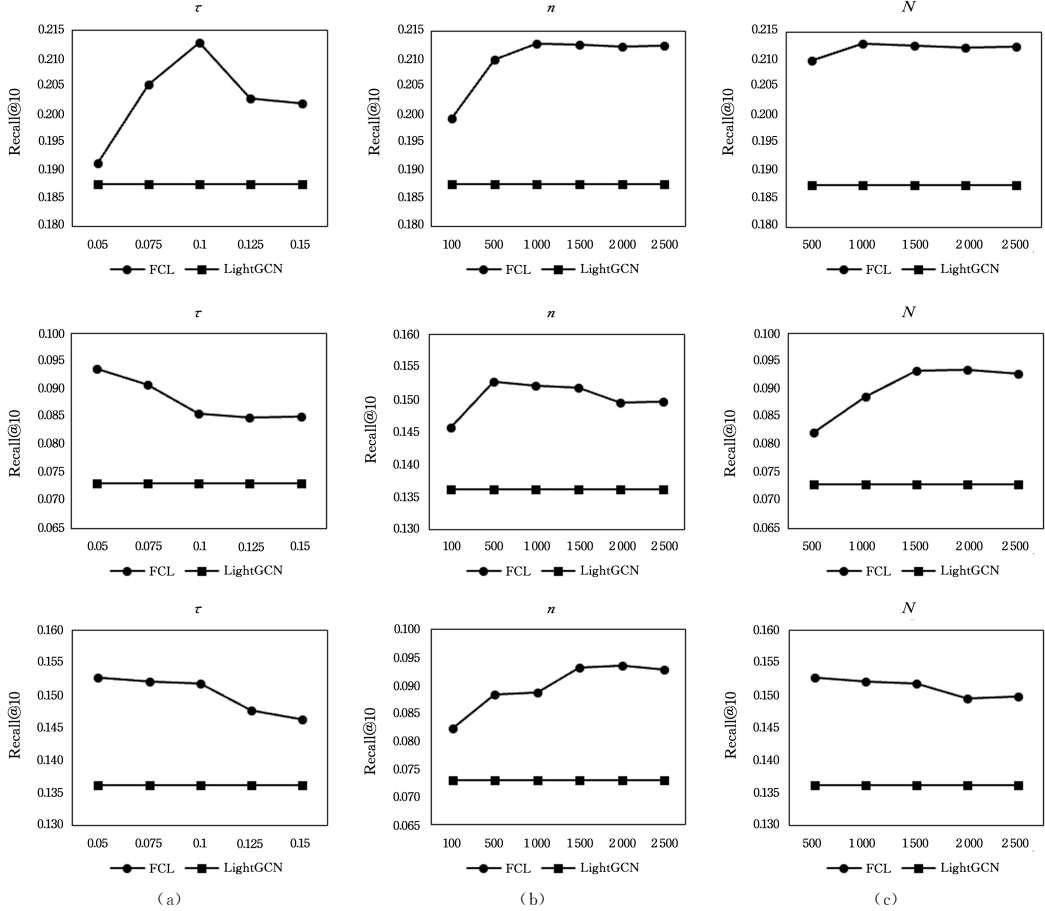


图 6 不同参数的性能比较

Fig. 6 Performance comparison of different parameters

5.10 将 FCL 应用于其他图神经网络推荐模型

对 FCL 与其他 GNN 架构的推荐模型性能进行了进一步的测试, 结果如表 3 所列。从表 3 可以看出, 所提出的 FCL 模型能够提升 NGCF, DGCN 和 LightGCN 的表现, 这验证了 FCL 模型的有效性。特别地, 虽然 FCL 对 NGCF 和 DGCN 的性能提升也是显著的, 但相比之下, 对 LightGCN 的改进更

为突出。原因是 LightGCN 在层传播中去除了额外的参数和非线性激活功能, 使得不同层的输出都保持在同一表示空间中, FCL 能够有效地利用 LightGCN 的这一优势, 加强对用户和物品间复杂交互模式的理解。这种紧密的融合使得 FCL 与 LightGCN 的结合在性能提升方面表现出色, 优于与 NGCF 和 DGCN 的结合。

表 3 FCL 结合不同 GNN 架构的推荐模型的性能比较

Table 3 Performance comparison of FCL combined with different GNN backbones


Method	ML-1M		Yelp		Gowalla	
	Recall@10	NDCG@10	Recall@10	NDCG@10	Recall@10	NDCG@10
NGCF	0.1844	0.2524	0.0630	0.0450	0.1187	0.0851
+FCL	0.1850	0.2539	0.0659	0.0459	0.1194	0.0867
DGCN	0.1885	0.2521	0.0722	0.0514	0.1254	0.0902
+FCL	0.1901	0.2542	0.0744	0.0529	0.1268	0.0917
LightGCN	0.1876	0.2510	0.0735	0.0519	0.1359	0.0871
+FCL	0.2128	0.2851	0.0935	0.0682	0.1527	0.1121

结束语 本文提出了一种基于特征网络对比学习的图协同过滤模型(FeatureNet Contrastive Learning, FCL),通过结合基于图的推荐系统与对比学习,旨在解决传统推荐系统在处理大规模和高度稀疏数据集时的问题。该方法通过引入基于特征相似度的影响力分析,有效地识别并利用用户和物品间的潜在相似性,从而提升推荐的精准度和鲁棒性。实验结果显示,FCL在多个公共数据集上均优于现有的基线方法。此外,通过深入的消融研究和性能分析,进一步验证了特征网络邻居方法对提升推荐性能的重要作用。总体而言,本文不仅提出了一个有效的推荐模型,还为未来推荐系统的研究提供了新的视角和可能的研究方向。

参 考 文 献

- [1] RICCI F, ROKACH L, SHAPIRA B. Introduction to Recommender Systems Handbook [M] // Recommender Systems Handbook. Boston, MA: Springer, 2011: 1-35.
- [2] LINDEN G, SMITH B, YORK J. Amazon. com recommendations: item-to-item collaborative filtering [J]. IEEE Internet Computing, 2003, 7(1): 76-80.
- [3] GOMEZ-URIBE C A, HUNT N. The Netflix Recommender System: Algorithms, Business Value, and Innovation [J]. ACM Trans Manage Inf Syst, 2016, 6(4): 1-19.
- [4] 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, 2001: 285-295.
- [5] HE X, LIAO L, ZHANG H, et al. Neural Collaborative Filtering [C] // Proceedings of the 26th International Conference on World Wide Web, 2017: 173-182.
- [6] HE X, 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, 2020: 639-648.
- [7] 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.
- [8] 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, 2021: 726-735.
- [9] SUN J, ZHANG Y, MA C, et al. Multi-graph convolution collaborative filtering [C] // 2019 IEEE International Conference on Data Mining (ICDM), 2019: 1306-1311.
- [10] WU L, SUN P, FU Y, et al. A Neural Influence Diffusion Model for Social Recommendation [C] // Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2019: 235-244.
- [11] YU L, DU Q H, YUE B Y, et al. Survey of Reinforcement Learning Based Recommender Systems [J]. Computer Science, 2021, 48(10): 1-18.
- [12] LIN Z, TIAN C, HOU Y, et al. Improving Graph Collaborative Filtering with Neighborhood-enriched Contrastive Learning [C] // Proceedings of the ACM Web Conference 2022, 2022: 2320-2329.
- [13] GORI M, PUCCI A. ItemRank: a random-walk based scoring algorithm for recommender engines [C] // Proceedings of the 20th International Joint Conference on Artificial Intelligence, 2007: 2766-2771.
- [14] BALUJA S, SETH R, SIVAKUMAR D, et al. Video suggestion and discovery for youtube: taking random walks through the view graph [C] // Proceedings of the 17th International Conference on World Wide Web, 2008: 895-904.
- [15] KABBUR S, NING X, KARYPIS G. FISM: factored item similarity models for top-N recommender systems [C] // Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2013: 659-667.
- [16] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback [C] // Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence, 2009: 452-461.
- [17] LI J, ZHOU P, XIONG C, et al. Prototypical contrastive learning of unsupervised representations [J]. arXiv: 2005.04966, 2020.
- [18] LIANG M X, WANG S, ZHU J W, et al. Survey of Knowledge-enhanced Natural Language Generation Research [J/OL]. <https://www.jsjx.com/CN/article/openArticlePDF.jsp?id=21572>.
- [19] GIORGI J, NITSKI O, WANG B, et al. Declutr: Deep contrastive learning for unsupervised textual representations [J]. arXiv: 2006.03659, 2020.
- [20] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C] // Proceedings of the 37th International Conference on Machine Learning, 2020.
- [21] GRILL J B, STRUB F, ALTCHÉ F, et al. Bootstrap your own latent—a new approach to self-supervised learning [J]. Advances in neural information processing systems, 2020, 33: 21271-21284.
- [22] HE K M, FAN H Q, WU Y X, et al. Momentum Contrast for Unsupervised Visual Representation Learning [C] // Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020: 9726-9735.
- [23] CESAR L B, CALLEJO M Á M, CIRA C I. Bidirectional Encoder Representation from Transformers (BERT) Variants for Procedural Long-Form Answer Extraction [J]. Engineering Proceedings, 2022, 39(1): 71-76.
- [24] CARLSSON F, GYLLENSTEN A C, GOGOULOU E, et al. Semantic Re-tuning with Contrastive Tension [C] // International Conference on Learning Representations, 2021: 157-169.
- [25] OORD A V D, LI Y, VINYALS O. Representation Learning with Contrastive Predictive Coding [J]. arXiv: 8070.3748, 2018.
- [26] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs [C] // Proceedings of the 31st International Conference on Neural Information Processing Sys-

- tems. 2017;1025-1035.
- [27] RADFORD A, KIM J W, HALLACY C, et al. Learning Transferable Visual Models From Natural Language Supervision [C]//Proceedings of the 38th International Conference on Machine Learning. 2021;8748-8763.
- [28] LU J, BATRA D, PARIKH D, et al. ViLBERT: Pretraining Task-Agnostic Visiolinguistic Representations for Vision-and-Language Tasks [C]//Neural Information Processing Systems. 2019;13-23.
- [29] CHEN D, SONG H Z, ZHANG J, et al. Entity Recognition Fusing BERT and Memory Networks[J]. Computer Science, 2021, 48(10): 91-97.
- [30] LIN Z, TIAN C, HOU Y, et al. Improving Graph Collaborative Filtering with Neighborhood-enriched Contrastive Learning [C]//Proceedings of the ACM Web Conference. 2022; 2320-2329.
- [31] WANG X, JIN H, ZHANG A, et al. Disentangled Graph Collaborative Filtering [C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2020;1001-1010.
- [32] MOON T K. The expectation-maximization algorithm [J]. IEEE Signal processing magazine, 1996, 13(6): 47-60.
- [33] HARPER F M, KONSTAN J A. The MovieLens Datasets [J]. ACM Transactions on Interactive Intelligent Systems (TIIS), 2015, 5(4): 1-19.
- [34] MCAULEY J, TARGETT C, SHI Q, et al. Image-Based Recommendations on Styles and Substitutes [C]//Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2015;43-52.
- [35] CHO E, MYERS S A, LESKOVEC J. Friendship and mobility: user movement in location-based social networks [C]//Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2011;1082-1090.
- [36] ZHAO W X, CHEN J, WANG P, et al. Revisiting Alternative Experimental Settings for Evaluating Top-N Item Recommendation Algorithms [C]// Proceedings of the 29th ACM International Conference on Information & Knowledge Management. 2020;2329-2332.
- [37] YOU Y, CHEN T, SUI Y, et al. Graph contrastive learning with augmentations [C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. 2020.



WU Pengyuan, born in 1999, master, is a member of CCF (No. R7041G). His main research interests include graph neural networks and recommendation algorithm.



FANG Wei, born in 1980, Ph.D, professor, Ph.D supervisor, is a member of CCF(No. 39532M). His main research interests include evolutionary algorithm and swarm intelligence.

(责任编辑:何杨)