

融合自适应图生成与去噪机制的社交推荐算法研究

王则林, 刘轩宇, 季嘉越, 周建美*

南通大学人工智能与计算机学院, 江苏 南通

收稿日期: 2026年1月9日; 录用日期: 2026年1月22日; 发布日期: 2026年2月28日

摘要

本研究旨在优化协同过滤推荐算法在面对数据稀疏性时, 引入社交网络所带来的噪声干扰问题。现有的图神经网络社交推荐方法虽然能够利用社交辅助信息, 但往往忽略了社交关系中的无效连接(如兴趣不一致的表面社交), 且现有的随机数据增强方法容易破坏图的内在语义结构。为此, 本文提出了一种融合自适应图生成与去噪机制的对比学习推荐框架。该框架通过在用户侧与物品侧同时部署自适应增强策略: 一方面, 利用变分图自编码器(VGAE)重构用户社交视图以补充潜在语义, 并结合交互信号引导的去噪模块剔除无效社交边; 另一方面, 在物品侧对交互图本身进行自适应去噪, 以增强物品表示的鲁棒性。通过跨视图对比学习, 模型实现了辅助信息与主交互任务的有效对齐。在Yelp、CiaoDVD两个公开数据集上的实验结果表明, 本研究提出的模型在Recall@20和NDCG@20指标上均显著优于LightGCN、MF等主流基线模型。进一步的分析显示, 该模型在处理高噪声比例及稀疏场景下表现出更强的鲁棒性与泛化能力。

关键词

对比学习, 自适应去噪, 图神经网络

Research on Social Recommendation Algorithm Integrating Adaptive Graph Generation and Denoising Mechanism

Zelin Wang, Xuanyu Liu, Jiayue Ji, Jianmei Zhou*

College of Artificial Intelligence and Computer Science, Nantong University, Nantong Jiangsu

Received: January 9, 2026; accepted: January 22, 2026; published: February 28, 2026

*通讯作者。

文章引用: 王则林, 刘轩宇, 季嘉越, 周建美. 融合自适应图生成与去噪机制的社交推荐算法研究[J]. 电子商务评论, 2026, 15(2): 932-940. DOI: 10.12677/ecl.2026.152233

Abstract

This study aims to optimize the issue of noise interference introduced by social networks when collaborative filtering recommendation algorithms encounter data sparsity. Although existing graph neural network-based social recommendation methods can utilize social auxiliary information, they often overlook invalid connections in social relationships (such as superficial social ties with inconsistent interests), and the current random data augmentation methods tend to disrupt the intrinsic semantic structure of the graph. To this end, this paper proposes a contrastive learning recommendation framework that integrates an adaptive graph generation and denoising mechanism. This framework deploys adaptive enhancement strategies on both the user side and the item side: on the one hand, it uses a variational graph autoencoder (VGAE) to reconstruct the user social view to supplement latent semantics and combines a denoising module guided by interaction signals to eliminate invalid social edges; on the other hand, it performs adaptive denoising on the interaction graph itself on the item side to enhance the robustness of item representations. Through cross-view contrastive learning, the model achieves effective alignment between auxiliary information and the main interaction task. Experimental results on the public datasets Yelp and CiaoDVD show that the model proposed in this study significantly outperforms mainstream baseline models such as LightGCN and MF in terms of Recall@20 and NDCG@20 metrics. Further analysis indicates that this model demonstrates stronger robustness and generalization ability in handling scenarios with high noise ratios and sparsity.

Keywords

Contrastive Learning, Adaptive Denoising, Graph Neural Network

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在当前的大数据时代，推荐系统已广泛应用于电商、金融等平台。传统的协同过滤方法[1]主要依赖于用户与物品的历史交互数据，但在面对交互数据稀疏和冷启动问题时表现不佳。为了解决这一问题，研究者们开始引入社交网络和知识图谱作为辅助视图，利用图神经网络强大的高阶连通性建模能力来丰富用户和物品的表示。

然而，直接聚合多源数据面临着严峻的挑战。首先是噪声问题：如 Junliang Yu [1]等人指出了图卷积网络中的噪声问题，并提出了一种基于特征噪声的简单对比学习方法。Shijie Tian [2]等人在他们的研究中也提出现有的 GNN 推荐容易受到噪声干扰，且随机数据增强可能破坏图结构。而社交网络中存在大量与消费兴趣无关的连接(如仅是同事关系但购物偏好迥异)，现有的研究如 Chao Huang [3]等人提出的 KCGN 已经意识到了区分社交关系重要性的必要性。其次是交互主导问题：在监督学习下，稀疏的交互信号往往主导了模型训练，导致丰富的辅助信息未能被有效编码。现有的方法如 SGL [4]通过随机丢边进行数据增强，但这可能会破坏图的内在语义结构，甚至引入更多噪声。

目前，已有多篇论文为解决数据噪声、稀疏性等问题提出多种框架，例如，Xuheng Cai [5]等人提出了利用奇异值分解(SVD)进行对比增强。Yangqin Jiang 等人[6]提出 Adaptive Graph Contrastive Learning (AdaGCL)框架。该框架通过两个可训练的自适应视图生成器——图生成模型(基于变分图自编码器 VGAE)

和图去噪模型来提升模型鲁棒性与泛化性。

此外 Tianle Wang 等人[7]提出去噪自增强学习范式(DSL), 通过双视图神经网络分别编码用户-物品交互图与用户社交图的高阶关系, 结合跨视图去噪自监督模块, 来解决社交推荐中社交信息噪声。更进一步, M. Gao [8]等人证明了多视图协同训练在社交推荐中的有效性, 提出了 Co-Training (协同训练)的框架, 让两个视图互相学习, 旨在解决社交推荐的鲁棒性问题。

这些研究从多个角度改进现有推荐系统的性能, 为本研究提供了坚实的理论基础。本研究通过进一步探索这些模型的核心去噪与增强机制提出了一种新的推荐方法。该方法的核心思想不再依赖人工定义的增强规则, 而是通过参数化的网络自动学习哪些边该保留, 哪些边该剔除。具体而言, 我们在用户侧引入社交视图, 并设计了自适应图生成与去噪模块, 通过跨视图的对比学习任务, 利用交互数据作为监督信号来指导辅助视图的去噪过程。本研究的主要贡献在于改进了当前的去噪增强机制, 提升了推荐系统在噪声环境下的鲁棒性。

2. 方法

2.1. 数据来源与预处理

数据集选用推荐系统领域常用的公开数据集: Yelp、CiaoDVD。这些数据集涵盖了本地服务、电子商务和音乐流媒体三个不同的领域, 且具备不同程度的数据稀疏性与辅助信息类型。其中, Yelp 包含约 16.1 万名用户、11.4 万个物品、111.8 万条交互记录以及 214 万条社交关系。CiaoDVD 包含约 6672 名用户、9.8 万个物品、19.8 万条交互记录以及 10.9 万条社交信任关系。

2.2. 模型介绍与参数设置

2.2.1. 模型总体框架图

如图 1 所示, 本文提出的融合自适应图生成与去噪机制的社交推荐框架包含四个核心层级: 输入层、自适应增强层、图编码层以及目标与损失层。该框架通过多视图对比学习, 解决社交推荐中的数据稀疏与噪声干扰问题。

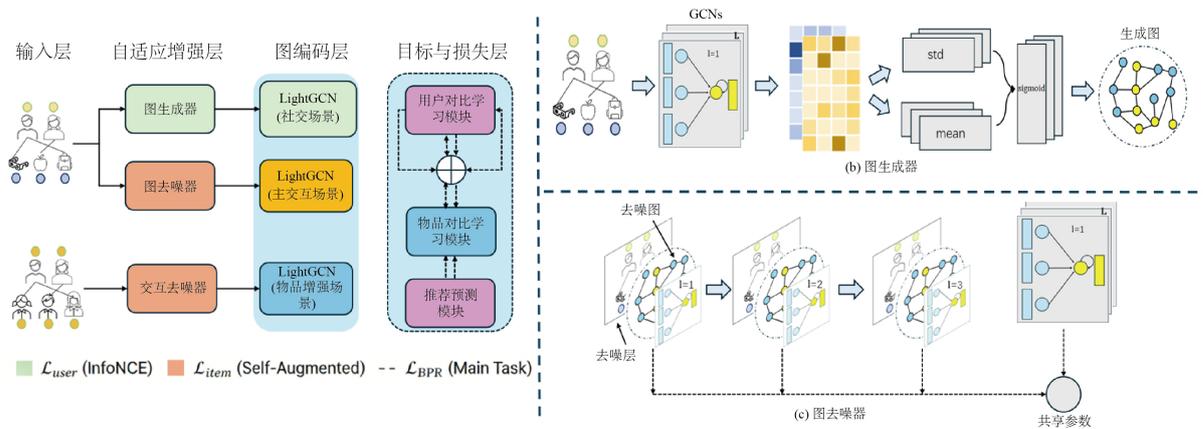


Figure 1. Overall structure diagram of the model
图 1. 模型总体结构图

2.2.2. 自适应视图生成器(Adaptive View Generators)

为了克服随机数据增强破坏图结构的缺陷, 近期的研究如 GGD (Generative Graph Denoising) [9]开始

尝试利用扩散模型进行生成式图去噪，虽然效果显著，但扩散模型的推理开销巨大。受到 AdaGCL [4] 的启发，本研究使用了两种参数化的视图生成器，分别用于生成增强视图和去噪视图。

针对数据稀疏性问题，当用户交互极少时，仅凭有限的交互记录可能会错误地将某些潜在有益的社交关系判定为噪声。因此本框架引入了变分图自编码器(VGAE)作为互补机制。VGAE 可以利用图结构的潜在分布重构社交连接，能够在结构层面补充语义信息，相当于为稀疏的社交网络进行了平滑处理。同时，在去噪模块中，通过可学习的软权重结合对比学习的温度系数，允许模型在训练初期保留一定的探索性，随着训练进行逐渐聚焦于高置信度的社交边，有效平衡了稀疏场景下的偏差问题。因此采用变分图自编码器来重构图结构，重构图分布以补充潜在的语义连接。以社交图为例，该模块包含推断网络(Encoder)和生成网络(Decoder)。

在推断网络中，使用两层图卷积网络(GCN)来编码图结构信息，将节点映射到低维潜在空间分布。给定原始邻接矩阵 A 和节点特征矩阵 X ，首先计算节点的隐藏层表示：

$$H = \text{GCN}(X, A) = \text{ReLU}\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} X W_0\right) \quad (1)$$

其中 H 是 GCN 层输出的节点隐藏层特征矩阵，ReLU 是激活函数， X 是节点的初始特征矩阵， W_0 是 GCN 层的可学习权重矩阵， $\tilde{A} = A + I$ 是加入自环(Self-loop)后的邻接矩阵， \tilde{D} 是 \tilde{A} 的度矩阵。

随后，通过两个独立的多层感知机(MLP)分别预测潜在分布的高斯均值 μ 和方差 $\log \sigma$ ：

$$\mu = \text{MLP}_\mu(H), \quad \log \sigma = \text{MLP}_\sigma(H) \quad (2)$$

其中 μ 是潜在高斯分布的均值矩阵， $\log \sigma$ 是潜在高斯分布的对数标准差矩阵， $\text{MLP}_\mu, \text{MLP}_\sigma$ 是两个独立的双层多层感知机。

为了保证梯度可以通过采样过程反向传播，引入重参数化技巧生成潜在变量 Z ：

$$Z = \mu + \epsilon \odot \exp\left(\frac{1}{2} \log \sigma\right), \quad \text{where } \epsilon \sim \mathcal{N}(0, I) \quad (3)$$

其中 ϵ 是从标准正态分布中采样的噪声向量。这一步骤引入了随机性，使得生成的视图具有多样性，能够作为高质量的对比增强视图。

在生成网络中，通过计算潜在变量 Z 中节点对的内积，重构边存在的概率，从而生成增强后的邻接矩阵 A^{gen} ：

$$p(A_{ij}^{gen} = 1 | z_i, z_j) = \sigma(z_i^\top z_j) \quad (4)$$

其中， A_{ij}^{gen} 是生成视图中节点 i 和节点 j 之间存在连边的预测状态。 z_i, z_j 是矩阵 Z 中第 i 行和第 j 行的向量，分别代表节点 i 和 j 的潜在向量。 σ 是 Sigmoid 激活函数。

针对社交网络中的无效连接和知识图谱中的无关实体，需要一个参数化的去噪网络。对于图中的任意一条边 (i, j) ，其重要性权重 w_{ij} 计算如下：

$$w_{ij} = \text{MLP}(e_i^{(0)} \oplus e_j^{(0)}) \quad (5)$$

其中 w_{ij} 是边 (i, j) 对推荐任务的重要性评分， $e_i^{(0)}, e_j^{(0)}$ 是节点 i 和 j 的初始 ID 嵌入。

为了实现端到端的离散采样优化，我们利用 Gumbel-Softmax 技术。边 (i, j) 被保留的概率 p_{ij} 计算为：

$$p_{ij} = \text{Sigmoid}\left(\frac{\log w_{ij} - \log(1 - w_{ij}) + g}{\tau}\right) \quad (6)$$

其中, p_{ij} 是近似二值的掩码, 指示边是否保留。 $g \sim \text{Gumbel}(0,1)$ 是噪声项, τ 是温度系数。基于 p_{ij} , 生成了稀疏且去噪后的社交视图 \mathcal{G}_{soc}^{den} 。

最终生成去噪视图的邻接矩阵 A_{soc}^{den} :

$$A_{soc}^{den} = A \odot P \tag{7}$$

其中, A 是原始含噪声的邻接矩阵, P 是由所有 p_{ij} 组成的掩码矩阵。

2.2.3. 双视图图编码(Dual-View Graph Encoding)

本研究使用 LightGCN 作为骨干编码器, 分别在交互视图和去噪社交视图上独立传播信息。

在交互视图(Interaction View)中, 在 \mathcal{G}_{int} 上进行传播, 捕捉用户的主偏好和物品特性。第 1 层聚合公式为:

$$u_{int}^{(l+1)} = \sum_{v \in \mathcal{N}_u^{int}} \frac{1}{\sqrt{|\mathcal{N}_u^{int}| |\mathcal{N}_v^{int}|}} v_{int}^{(l)} \tag{8}$$

其中, $u_{int}^{(l+1)}$ 为用户 u 在第 $l+1$ 层的交互视图表示。 \mathcal{N}_u^{int} 为用户 u 的交互邻居; \mathcal{N}_v^{int} 为物品 v 的交互邻居。 $v_{int}^{(l)}$ 为物品 v 在第 l 层的交互视图表示。

经过 L 层聚合后, 得到用户交互表示 U_{int} 和物品表示 V_{int} 。

在社交视图通道中: 在去噪后的社交图 \mathcal{G}_{soc}^{den} 上进行传播, 捕捉用户的社交同质性信息:

$$u_{soc}^{(l+1)} = \sum_{k \in \mathcal{N}_u^{soc}} \frac{M_{uk}}{\sqrt{\hat{d}_u \hat{d}_k}} u_{soc}^{(l)} \tag{9}$$

其中 M_{uk} 是来自公式(6)的去噪掩码权重; \mathcal{N}_u^{soc} 为用户的社交邻居; $u_{soc}^{(l+1)}$ 为用户 u 在第 l 层的社交视图表示。最终得到去噪后的用户社交表示 U_{soc} 。

2.2.4. 跨视图对比学习(Cross-View Contrastive Learning)

借鉴了 DSL 的核心机制。本研究利用用户的交互行为来指导社交网络的去噪过程, 虽然社交关系是客观存在的, 但在现实生活中, 例如, 用户可能与同事建立社交连接, 但二者的电影口味截然不同。因此, 只有那些与用户真实交互行为(即购物、点击)相一致的社交关系, 才对推荐任务具有正向增益。交互视图直接反映了用户的显式偏好, 因此可以直接鉴别社交关系有效性。

我们将同一用户 u 在交互视图下的表示 u_{int} 与在社交视图下的表示 u_{soc} 视为正样本对, 同一批次内的其他用户视为负样本。构建 InfoNCE 损失函数, 公式为:

$$\mathcal{L}_{SSL} = \sum_{u \in \mathcal{B}} -\log \frac{\exp(\text{sim}(u_{int}, u_{soc})/\tau_{cl})}{\sum_{u' \in \mathcal{B}} \exp(\text{sim}(u_{int}, u'_{soc})/\tau_{cl})} \tag{10}$$

其中, \mathcal{B} 为一个训练批次中的用户集合; u' 为同一批次 \mathcal{B} 中, 除了 u 以外的其他所有用户, 这些用户被视为负样本; sim 为相似度函数, 主要为了衡量两个向量相似程度。

该损失函数强迫社交视图的表示 u_{soc} 向交互视图的表示 u_{int} 靠拢。

2.2.5. 模型预测与多任务优化(Prediction & Optimization)

在预测层, 用户的最终表示由交互偏好和去噪后的社交偏好融合而成, 物品的最终表示直接采用交互视图表示:

$$u^* = u_{int} + \lambda_s u_{soc}, \quad v^* = v_{int} \tag{11}$$

其中, λ_s 为用于控制辅助视图信息权重的超参数。

预测得分采用内积形式，公式为：

$$\hat{y}_{uv} = u^{*\top} v^* \quad (12)$$

最后计算联合损失函数，首先，使用 BPR (Bayesian Personalized Ranking) 损失优化主推荐任务，公式为：

$$\mathcal{L}_{BPR} = \sum_{(u,i,j) \in \mathcal{D}} -\ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) \quad (13)$$

其中， (u, i, j) 为用户 u 交互过物品 i 但未交互过物品 j 的训练三元组。

总损失函数 \mathcal{L} 公式为：

$$\mathcal{L} = \mathcal{L}_{BPR} + \lambda_1 \mathcal{L}_{SSL} + \lambda_2 \mathcal{L}_{gen} + \lambda_3 \|\Theta\|_2^2 \quad (14)$$

其中， \mathcal{L}_{gen} 为 VGAE 的生成损失； $\|\Theta\|_2^2$ 为 L2 正则化项，防止过拟合； $\lambda_1, \lambda_2, \lambda_3$ 为用于平衡不同任务重要性的超参数。

3. 模型结果与分析

3.1. 总体性能比较

为了验证本研究在推荐性能、去噪能力及抗稀疏性方面的有效性，我们在两个真实世界数据集(Yelp, CiaoDVD)上进行了实验。评估指标采用 Recall@20 和 NDCG@20。

Table 1. A performance comparison of different models on the Yelp and CiaoDVD datasets

表 1. 不同模型在 Yelp 和 CiaoDVD 数据集上的性能对比

模型	Yelp (Recall@20)	Yelp (NDCG@20)	CiaoDVD (Recall@20)	CiaoDVD (NDCG@20)
LightGCN	0.2966	0.4126	0.1342	0.1058
Mf	0.3109	0.4472	0.0683	0.0909
Ours	0.3981	0.5424	0.2866	0.3635

表 1 展示了不同模型在 Yelp 和 CiaoDVD 数据集上的性能对比。实验结果表明，本文提出的模型在所有指标上均优于基线模型。

观察可知，在 Yelp 数据集上，由于交互与社交关系的极度稀疏，LightGCN 的表现略逊于传统的 MF 方法，这表明噪声和稀疏性严重限制了图神经网络的性能。然而，本模型通过引入 VGAE 生成潜在视图，Recall@20 相比次优模型(MF)提升了 28.0%。这证明了自适应生成机制有效缓解了冷启动问题，补充了稀疏图中的语义缺失。

在 CiaoDVD 数据集上，与 LightGCN 相比，本模型在 Recall@20 和在 NDCG@20 上提升显著。这种成倍的性能增长主要归功于模型的去噪模块：CiaoDVD 包含大量并不反映消费偏好的社交信任边，而本模型利用交互信号成功识别并剔除了这些噪声，从而学习到了更纯净的用户表示。

3.2. 不同噪声比例对模型的影响

为了评估本文所提框架的鲁棒性，我们在数据集中注入了 0% 到 30% 比例的随机噪声边，并记录了模型性能的变化。CiaoDVD 数据集上的实验结果如图 2 所示。

观察可知，在所有噪声水平下，本文模型(红线)的性能均显著优于 LightGCN 和 MF。即使在 30% 的高噪声环境下，本文模型的 Recall@20 依然保持在 0.24 以上，是基线模型性能的两倍多。

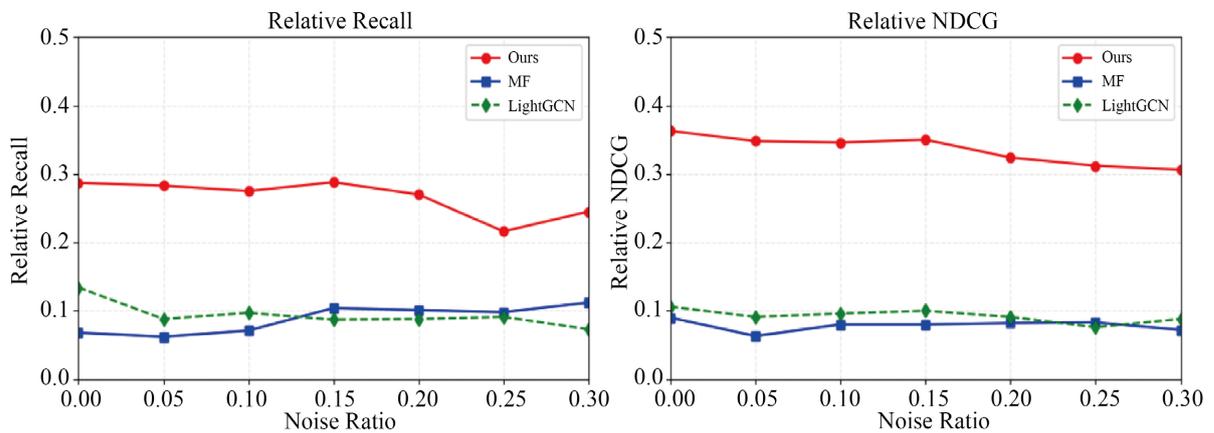


Figure 2. The performance degradation curves of the model under different noise ratios in the CiaoDVD dataset
图 2. CiaoDVD 数据集中不同噪声比例下模型性能衰减曲线

随着噪声比例的增加, LightGCN (绿线)由于图卷积操作导致噪声传播, 性能出现了较明显的下滑。相比之下, 本文模型表现出了极强的稳定性。这证明了自适应去噪模块和跨视图对齐机制能够有效识别并过滤掉与推荐任务无关的噪声连接, 防止模型拟合错误信息。

MF 模型(蓝线)由于不依赖图结构传播, 对结构性噪声不敏感, 表现较为平稳, 但受限于模型容量, 其整体性能处于较低水平。

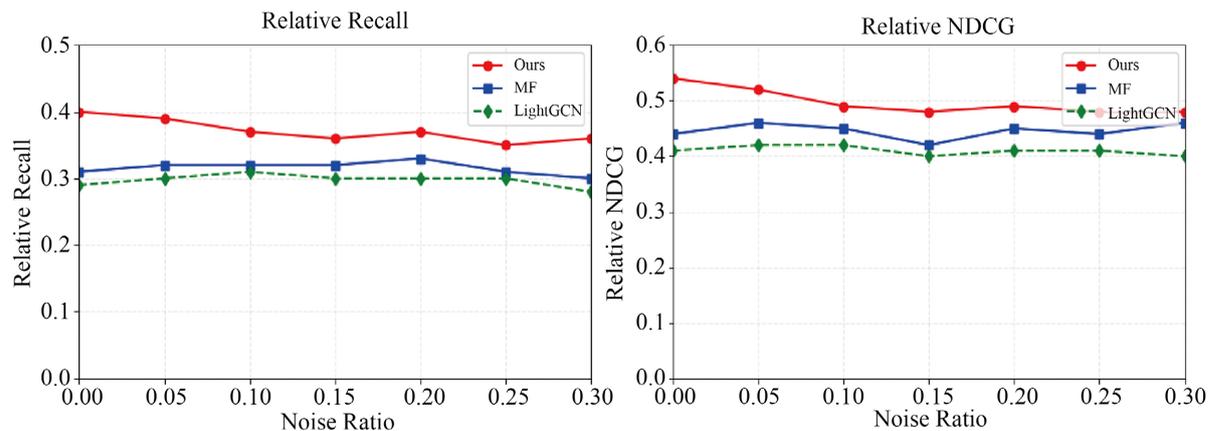


Figure 3. The performance degradation curves of the model under different noise ratios in the Yelp dataset
图 3. Yelp 数据集中不同噪声比例下模型性能衰减曲线

观察可知, 在 Recall@20 和 NDCG@20 两个指标上, 本文模型(红线)的性能的曲线始终位于最上方, 且与其他两个基线模型(MF 和 LightGCN)保持了较为明显的差距(图 3)。

在 Yelp 数据集上, 与 LightGCN 相比, 本文的模型在 Recall@20 指标上实现了约 15%~20%的相对提升。这表明我们的框架成功整合了社交信息以缓解数据稀疏性, 而跨视图对齐的机制确保了社交信号对主要推荐任务产生积极作用。

此外, 虽然基线模型的性能保持相对稳定, 这主要是由于它们没有充分利用社交结构, 但本文的模型即使在严重的噪声干扰下仍能保持较高性能。红色曲线的稳定性验证了我们的自适应图去噪模块的有效性。

3.3. 消融实验

为了验证本文提出的模型中各个核心组件的有效性，我们设计了一系列消融实验。具体而言，我们将完整模型与删减了特定模块的变体模型进行对比，以探究自适应去噪模块、跨视图对齐机制以及对比学习对最终推荐性能贡献(表 2)。

(1) w/o Denoise (去除去噪模块): 在此变体中，我们禁用了 SocialDenoisingNet 的生成功能。模型直接使用原始的、包含噪声的社交网络进行图卷积操作，而不进行任何边的筛选或重构。该变体用于验证去噪模块是否有效过滤了有害的社交连接。

(2) w/o Alignment (去除跨视图对齐): 在此变体中，我们移除了 DSL 模块中的对齐损失函数。此时，交互视图不再为社交视图的去噪过程提供指导信号，两个视图的学习相对独立。该变体用于验证利用交互信息指导社交去噪的必要性。

(3) w/o SSL (去除对比学习): 在此变体中，我们移除了 AdaGCL 的对比损失函数。模型不再通过最大化视图间的互信息来增强节点表示。该变体用于验证对比学习在提升特征鲁棒性方面的作用。

Table 2. Ablation study of key components on the Yelp dataset

表 2. Yelp 数据集上关键组件的消融研究

模型变体	Yelp (Recall@20)	Yelp (NDCG@20)	Drop (Recall)
Full Model (Ours)	0.3981	0.5424	-
w/o Denoise	0.3814	0.5333	↓4.19%
w/o Alignment	0.1732	0.2634	↓56.49%
w/o SSL	0.3701	0.5108	↓7.03%

综合分析上述消融实验各模块的实验结果，我们可以得出以下结论：

(1) 跨视图对齐机制的决定性作用：实验数据显示，当移除 DSL 模块中的对齐机制(w/o Alignment)时，模型性能会大幅度下降，Recall@20 从 0.3981 暴跌至 0.1732，下降幅度高达 56.49%。这一结果有力地证明了交互视图对社交视图的指导作用是不可或缺的。如果缺乏交互信号作为“伪标签”来对齐社交关系的表示，社交网络中的信息不仅无法有效辅助推荐，反而可能引入巨大的噪音和干扰，导致特征空间发生严重的偏移。这表明，单纯引入社交网络并不足以提升性能，如何将社交信号与交互偏好语义空间上对齐才是社交推荐成功的关键。

(2) 对比学习的鲁棒性增强：对比 w/o SSL 与完整模型，观察到 Recall@20 下降了约 7.03%。这表明 AdaGCL 引入的自监督对比任务在模型训练中起到了重要的正则化作用。通过拉近同一用户在不同增强视图(交互视图与去噪社交视图)下的嵌入表示，InfoNCE 损失函数有效地缓解了数据稀疏性问题，并增强了模型捕捉用户本质特征的能力，防止了过拟合。

(3) 自适应去噪的精细化提升：对比 w/o Denoise 变体，完整模型的性能提升了约 4.19%。这说明原始的社交网络中确实包含了一定比例的无关连接。如果直接使用原始图进行卷积(w/o Denoise)，这些噪声会传播并污染用户表示。本模型使用的自适应去噪模块通过学习边的重要性权重，成功剔除了部分有害连接，进一步净化了图结构，从而推高了模型的性能上限。

综上所述，本模型使用的跨视图对齐机制确保了社交信息能够正确地服务于推荐任务；对比学习和自适应去噪则分别从特征鲁棒性和图结构纯净度的角度，进一步提升了模型的表现。

4. 总结

本研究针对社交推荐系统中普遍存在的数据稀疏性与噪声干扰问题，通过融合自适应视图生成与跨视图对齐提出了一种新的推荐框架。与现有的依赖随机数据增强的对比学习方法不同，本研究通过引入可学习的参数化网络，实现了对图结构的“优胜劣汰”与“查漏补缺”。

在用户侧的跨视图协同去噪中，本研究融合了 DSL 机制，利用用户真实交互行为作为监督信号，指导社交网络的去噪过程。通过对比学习，模型成功识别并抑制了那些与消费偏好无关的无效社交连接。

在物品侧的自适应交互增强中，本研究借鉴 AdaGCL 的生成机制，在物品侧构建了基于交互图的自适应去噪视图。这使得物品表示不再仅仅依赖于原始的、可能包含误点击的交互记录，而是通过与去噪视图的对比，学习到了更加鲁棒的本质特征。

此外，本研究引入变分图自编码器(VGAE)，通过重构潜在连接，有效缓解了 Yelp 等大规模稀疏数据集中的冷启动问题。

通过在 Yelp、CiaoDVD 两个具有不同规模和社交密度的基准数据集上进行的实验，本研究所提出的推荐框架在 Recall@20 和 NDCG@20 指标上均一致优于 LightGCN 等基线模型。特别是在社交关系极其稀疏的 Yelp 数据集上，性能有较为明显的提升，验证了自适应图生成模块在补充语义信息方面的有效性。

尽管本研究改进了当前的推荐模型，但仍存在一定的局限性，例如目前的模型基于静态图结构，忽略了用户兴趣和社交关系随时间的动态演变。未来的工作将探索把自适应去噪机制扩展到动态图神经网络中，以捕捉时序上的噪声模式。而且当前的去噪仅基于结构信息。随着大语言模型的发展，未来可以尝试利用 LLM 提取用户评论和物品描述中的深层语义，作为辅助信号来进一步指导图结构的生成与去噪，实现结构与语义的双重增强。

参考文献

- [1] Yu, J., Yin, H., Xia, X., Chen, T., Cui, L. and Nguyen, Q.V.H. (2022) Are Graph Augmentations Necessary? Simple Graph Contrastive Learning for Recommendation. *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval*, Madrid, 11-15 July 2022, 1294-1303. <https://doi.org/10.1145/3477495.3531937>
- [2] Tian, S., Zhu, H., Fu, D., Caverlee, J. and Li, Q. (2022) Robust Graph Collaborative Filtering. *Proceedings of the AAAI Conference on Artificial Intelligence*, **36**, 4220-4228.
- [3] Huang, C., Xu, H., Xu, Y., Dai, P., Xia, L., Lu, M., et al. (2021) Knowledge-Aware Coupled Graph Neural Network for Social Recommendation. *Proceedings of the AAAI Conference on Artificial Intelligence*, **35**, 4115-4122. <https://doi.org/10.1609/aaai.v35i5.16533>
- [4] Wu, J., Wang, X., Feng, F., He, X., Chen, L., Lian, J., et al. (2021) Self-Supervised Graph Learning for Recommendation. *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 11-15 July 2021, 726-735. <https://doi.org/10.1145/3404835.3462862>
- [5] Cai, X., Huang, C., Xia, L. and Ren, X. (2023) LightGCL: Simple Yet Effective Graph Contrastive Learning for Recommendation. arXiv: 2302.08191.
- [6] Jiang, Y., Huang, C. and Huang, L. (2023) Adaptive Graph Contrastive Learning for Recommendation. *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, Long Beach, 6-10 August 2023, 4252-4261. <https://doi.org/10.1145/3580305.3599768>
- [7] Wang, T., Xia, L. and Huang, C. (2023) Denoised Self-Augmented Learning for Social Recommendation. *Proceedings of the Thirty-Second International Joint Conference on Artificial Intelligence*, Macao, 19-25 August 2023, 2324-2331.
- [8] Gao, M., Yu, J. and Yin, H. (2024) Self-Supervised Graph Co-Training for Robust Social Recommendation. *IEEE Transactions on Knowledge and Data Engineering*, **36**, 1589-1602.
- [9] Wei, W., Chen, L. and Mao, X. (2024) Generative Graph Denoising for Recommendation with Diffusion Models. *Proceedings of the ACM Web Conference 2024*, Singapore, 13-17 May 2024, 885-894.