面向图社交推荐的鲁棒偏好引导去噪

Yuhan Quan 清华大学电子工程系，北京，中国

Jingtao Ding*清华大学电子工程系，北京，中国

Chen Gao 清华大学电子工程系，北京，中国

Lingling Yi 微信，腾讯，深圳，中国

Depeng Jin 电子工程系 清华大学 中国北京

Yong Li 清华大学电子工程系，中国北京

arXiv:2303.08346v1 [cs.IR] 15 Mar 2023

摘要

基于图神经网络（GNN）的社交推荐模型通过利用图神经网络挖掘社交关系中蕴含的偏好相似性，提高了用户偏好的预测准确率。然而，从推荐的有效性和效率来看，大量社交关系可能是冗余的，甚至带有噪声，例如，好友在某个领域没有共同偏好是很常见的。现有模型并未充分解决关系冗余和噪声这一问题，因为它们直接对整个社交网络中的社交影响进行建模。本文提出，仅保留信息丰富的社交关系，以确保影响力传播高效且有效，从而改进基于图的社交推荐，即对图进行去噪。我们设计的去噪方法以偏好为引导，对社交关系置信度进行建模；同时，通过为推荐模型提供一个经过去噪且信息更丰富的社交图，反过来促进用户偏好学习。此外，为避免噪声社交关系的干扰，该方法设计了一个自校正课程学习模块和一种自适应去噪策略，两者均优先考虑高置信度样本。在三个公开数据集上的实验结果表明，该方法能够稳定地提升两种最先进的社交推荐模型的性能，并稳健地移除原始关系中的 10-40%。我们在 https://github.com/tsinghua-fib-lab/Graph-Denoising-SocialRec 发布了源代码。

关键词

社交推荐、图去噪、偏好学习

ACM 引用格式：

Yuhan Quan、Jingtao Ding、Chen Gao、Lingling Yi、Depeng Jin 和 Yong Li。2023。《面向图社交推荐的鲁棒偏好引导去噪》。载于*ACM Web Conference 2023*（*WWW '23*），*2023*年*5*月*1*日至*5*日，美国得克萨斯州奥斯汀。ACM，纽约，纽约州，美国，12页。https://doi.org/10.1145/3543507.3583374

*通讯作者（dingjt15@tsinghua.org.cn）

允许免费为个人或课堂用途制作本作品全部或部分内容的数字或纸质副本，但不得为营利或商业利益而制作或分发副本，且副本首页必须保留本声明及完整引文。本作品中由作者以外人员拥有版权的组件，必须予以尊重。注明出处后允许摘录。若要以其他方式复制、重新发布、上传至服务器或分发至列表，须事先获得具体许可和／或支付费用。请向 permissions@acm.org 申请许可。*WWW '23，2023*年*5*月*1*日至*5*日，美国得克萨斯州奥斯汀© 2023 版权所有归所有者／作者所有。出版权已授权给 ACM。
ACM ISBN 978-1-4503-9416-1/23/04...$15.00
https://doi.org/10.1145/3543507.3583374

1 引言

如今，社交推荐已成为个性化推荐系统中的重要场景，在这些平台中，用户-物品交互和用户间社交连接均可获得 [40]。以往关于人类行为的研究建立了描述用户间社交关系影响的两项基本理论：1）具有社交连接的用户往往拥有相似的偏好，这被称为社交同质性 [33]，；2）用户的行为可能受到其好友的影响，例如共同购买同一件物品，这被称为社交影响 [32]。近期在广告 [2]、电子商务 [6, 54] 等领域的应用已验证了上述关于社交关系对推荐影响的理论。

为刻画上述社交关系对用户偏好的影响，研究人员提出了许多社交推荐方法，例如通过社交正则化实现偏好相似性 [31]，、增强信任关系带来的影响 [18]，，以及利用具有强关系或弱关系的不同关系 [46]。图机器学习（ML）中图神经网络（GNN）的最新进展进一步推动了基于图的社交推荐的发展 [15]，，因为GNN广泛采用的消息传递机制非常适合刻画社交情境中的影响力传播 [13, 41, 51]。此外，借助自监督学习技术，基于GNN的社交推荐（简称GSocRec）模型能够从大量观测到的社交关系中提取更具信息量的信号 [58, 60]。

然而，与GSocRec模型的广泛应用形成对比的是，在基于图的社交推荐中，冗余甚至带有噪声的社交关系这一问题几乎尚未得到研究。如图1(a)所示，大多数用户只有少数好友与自己具有相似偏好。具体而言，在两个实证数据集中，拥有共同交互的好友比例中位数分别约为30%和20%。因此，其余社交关系可能是冗余的，甚至会损害社交推荐，因为好友之间在某些领域很可能具有不同的偏好。因此，以往直接在整个社交网络上刻画社交影响的GSocRec模型存在两个缺点。其一是在完整的用户-用户图上训练图神经网络会带来巨大的计算和存储负担，因为在Facebook和微信等当前商业社交推荐平台上，社交关系的规模很容易达到数千亿条（两者的用户数均超过十亿）。这种效率问题进一步阻碍了基于图结构学习的方法

。这类方法旨在通过在节点的笛卡尔积空间上进行操作，学习信息量更丰富的图。其二是可能对推荐准确率产生负面影响。尽管此前一些研究提出通过注意力机制或期望最大化方法来处理社交影响的多样性，但它们仍缺乏真实标签，因此无法有效学习社交影响的程度。

为彻底解决上述问题，我们提出通过对社交网络进行去噪来改进基于图的社交推荐，即从原始图中移除冗余或带噪声的社交关系，仅保留信息丰富的关系，从而更高效、更有效地学习GSocRec模型。然而，由于以下两项挑战，GSocRec模型的图去噪并非易事：

• 如何克服识别对推荐有用的信息丰富的社交关系这一难题？用户建立社交关系的原因错综复杂，并不一定会带来相似的用户偏好，这增加了识别有用关系的难度。

• 在存在噪声标签的情况下，如何实现稳健的图去噪？在社交推荐中，很大一部分用户关系对提升用户偏好学习毫无用处，甚至会产生负面影响。因此，这些关系可视为噪声信号，并对图去噪的鲁棒性提出了要求。

本文提出了一种面向 GSocRec 模型的新型去噪增强推荐框架，如图1(b)所示。该框架的核心是用于社交推荐的图去噪方法（简称 GDMSR），它利用用户偏好从海量候选关系中识别信息丰富的社交关系，并将其保留为去噪后的社交图，从而支持下游 GSocRec 模型采用任意结构。为解决关系置信度刻画这一首要挑战，GDMSR 通过两种方式更好地利用偏好指导，即显式偏好关系建模，以及通过推荐损失进行隐式协同监督。针对稳健去噪这一第二项挑战，GDMSR 配备了自校正课程学习模块和自适应去噪策略，两者都倾向于选择高置信度样本（即对偏好学习有用的社交关系）。总而言之，我们的主要贡献如下。

• 我们重新审视了基于图的社交推荐情境下社交网络的可靠性，并从图去噪的角度提出一种全新的改进思路。

• 我们设计了一种偏好引导的图去噪框架，用于建模社交关系置信度，并反过来促进用户偏好学习；该框架兼容通用的GSocRec模型。

• 在三个公开数据集上的实验结果表明，与最先进的基线方法相比，我们的 GDMSR 在赋能一系列 GSocRec模型方面表现更优。在真实数据集和合成数据集上进行的消融研究进一步证实了特定方法设计的合理性。此外，借助稳健的偏好引导图去噪能力，GDMSR 能够在不损害推荐准确率的前提下，将社交图的规模缩减 10%–40%，同时在效率和可扩展性方面保持较高的实用性。

2 预备知识

2.1 基于图神经网络的社交推荐模型

通常，典型的基于图神经网络的社交推荐（简称GSocRec）模型包含两个关键部分：社交影响传播和用户偏好学习。具体而言，前者刻画好友偏好对特定用户的影响，后者则是基于用户-物品交互数训练预测模型，这是推荐系统中的常见步骤。从数学上讲，由 N用户构成的社交网络表示为用户-用户图G_s(U、E)，其中U $=\{u\}$和R $=\{(u、v)|r_{uv}=1、\forall u、v\in U\}$分别表示用户集合和社交关系集合。此外，还有另一个二部图G_r({U $\cup$ I}、P)，表示用户U与物品I之间的交互数P。为表示用户和物品，GSocRec模型通常使用 F维潜在嵌入矩阵，即$\mathbf{E}_1\in\mathbb{R}^{N\times D}$和$\mathbf{E}_2\in\mathbb{R}^{M\times D}$；这些矩阵可通过ID（用户或物品）的独热编码、连续特征值、离散特征ID或它们的拼接进行学习。

为了解耦社交影响和用户自身偏好，GSocRec模型进一步采用两种不同的用户偏好表示，即$\mathbf{E}_{1,\ s}$和$\mathbf{E}_{1,\ r}$，分别刻画上述两种影响。对于社交影响传播，GSocRec模型利用图神经网络的消息传递机制来建模用户 u的好友（记作 $R_u=\{v|r_{uv}=1\}$）对u偏好的影响传播。具体而言，经过K跳社交影响传播后，u的偏好表示为

$$\mathbf{E}_{1,s}^{(K)}(u)=\mathrm{GNN}\left(\mathbf{E}_1^{(K-1)}(u),\left\{\mathbf{E}_1^{(K-1)}(v)|\forall v\in\mathcal{R}_u\right\}\right),\quad(1)$$

其中，图神经网络模块可以是任意图神经网络模型，例如图卷积网络 [23], 图注意力网络 [44], GraphSAGE [19] 等。另一方面，给定 u的交互历史 $P_u=\{i|p_{ui}=1\}$（即 u此前交互过的物品集合），经过K跳偏好传播后，u的偏好表示为

$$\mathbf{E}_{1,r}^{(K)}(u)=\mathrm{GNN}\left(\mathbf{E}_1^{(K-1)}(u),\left\{\mathbf{E}_2^{(K-1)}(i)|\forall i\in\mathcal{P}_u\right\}\right),\quad(2)$$

其中，另一个图神经网络模块用于更新$\mathbf{E}_{(K)\ 1,\ r}$。综合考虑社交影响传播和用户偏好学习后，用户偏好的完整表示为

$$\mathbf{E}_1^{(K)}(u)=\mathrm{Combine}\left(\mathbf{E}_{1,s}^{(K)}(u),\mathbf{E}_{1,r}^{(K)}(u)\right),\quad(3)$$

其中 $E_{(0)\ 1}(u)=E_1(u)$，Combine 模块可以是均值池化操作 [13, 41] 或注意力聚合操作 [50]。至于物品表示，其计算方式也采用类似的消息传递方式：

$$\mathbf{E}_2^{(K)}(i)=\mathrm{GNN}\left(\mathbf{E}_2^{(K-1)}(i),\left\{\mathbf{E}_1^{(K-1)}(u)|\forall u\in\mathcal{P}_i\right\}\right),\quad(4)$$

该方式会聚合从物品 i 的邻居 $P_i=\{u|p_{ui}=1\}$ 传播而来的信息，即与 i发生过交互的用户集合。

然后，基于上述 $2\times(K+1)$ 对 u 和 i的表示，计算 u 对 i 的偏好预测分数，记为 $\hat{}\ p_{ui}$，如下所示

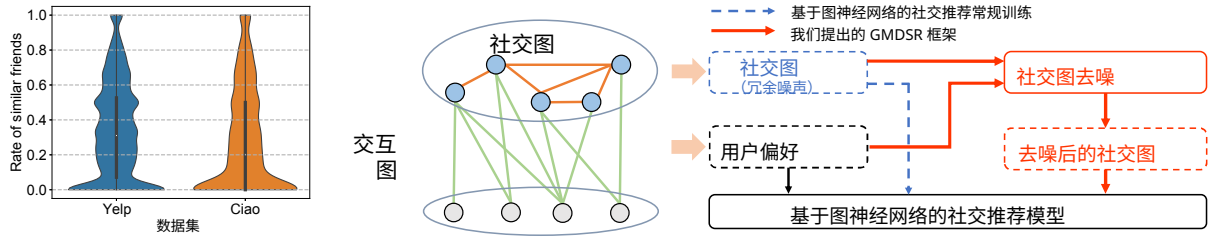

（a）经验数据统计　　（b）所提框架

图 1：（a）好友共同交互比例的分布图。（b）我们提出的去噪增强型社交推荐框架。

$$\hat{p}_{ui} = \mathbf{E}_1^*(u) \cdot \mathbf{E}_2^*(i),$$
$$\text{where } \mathbf{E}_1^*(u) = \frac{\sum_{k=0}^{K} \mathbf{E}_1^{(k)}(u)}{K+1}, \mathbf{E}_2^*(i) = \frac{\sum_{k=0}^{K} \mathbf{E}_2^{(k)}(i)}{K+1}. \quad (5)$$

为了训练推荐模型，一种广泛采用的方法是最小化以下贝叶斯个性化排序（BPR）损失函数 [34]:

$$\mathcal{L}^{BPR} = \sum_{(u,i,j)\in\overline{\mathcal{P}}} -\ln \sigma(\hat{p}_{ui} - \hat{p}_{uj}), \quad (6)$$

其中，σ是Sigmoid激活函数，$\mathrm{P} = \{(u, i, j) | (u, i) \in \mathrm{P}, (u, j) \notin \mathrm{P}\}$包含训练三元组（$u$, i, j），这些三元组由一个观测到的用户-物品交互和另一个未观测到的交互组成。学习上述贝叶斯个性化排序目标，等价于最大化观测到此类成对排序关系$\hat{p}_{ui} > \hat{p}_{uj}$的似然。

2.2 缺点讨论

以往关于 GSocRec模型的研究通常遵循上述范式，着重利用社交影响来增强用户偏好学习。因此，GSocRec模型的关键在于对社交影响传播进行建模，旨在识别与目标用户兴趣相似的好友，并有效地将其影响传播给该用户。为此，GSocRec模型通过消息传递中的注意力机制来刻画社交影响的多样性，即，在公式 (1) 中使用图注意力网络 [50, 53, 55]。然而，所有这些方法都必须基于完整的 G_s学习推荐模型，这意味着弱连接用户之间会进行大量无用的消息传递操作，从而造成严重的效率问题。此外，由于用户之间的社交关系是出于各种原因形成的，u和 v很可能没有共同兴趣，或在某个领域存在相悖的兴趣。因此，保留 (u, v) 甚至会因引入噪声信息而降低推荐准确率。在这种情况下，除了冗余问题，GSocRec模型还应解决噪声问题。

3 提出的方法

为解决冗余和噪声社交关系阻碍社交推荐模型有效学习的问题，我们提出了GDMSR方法。该方法可作为一种通用框架，通过对原始社交图进行去噪，增强任意基于图神经网络的社交推荐模型。另一方面，GDMSR利用用户偏好信号引导图去噪过程，从而有助于识别社交推荐场景中的信息丰富的社交关系。另一方面，为了在包含噪声关系的原始社交图上实现鲁棒学习，GDMSR进一步引入了一种自我纠正的课程学习机制，使模型较少受到这些含噪标注数据的影响。经过上述有效且鲁棒的图去噪训练过程后，所得模型将以自适应方式对社交网络进行去噪。

3.1 去噪增强社交推荐框架

不同于直接在整个社交网络 G_s上训练社交推荐模型，我们提出的 GDMSR 首先学习对 G_s 进行去噪，得到一个规模小得多但信息量更丰富的图 G_s^d。随后，基于图神经网络的社交推荐模型将 G_s^d用作社交图，以利用交互图 G_r增强用户偏好学习。

面向社交推荐的用户关系去噪。给定一个包含冗余或噪声用户关系（即边）的原始用户连接图，去噪任务被定义为一种类似链接预测的任务 [27]，旨在为每对用户生成一个边形成的置信度分数 $\hat{r}_{uv}$ (u, v)。不同的是，在去噪过程中，只检查观测到的用户关系，并根据 $\{\hat{r}_{uv}\}$ 排序。最后，通过移除 $\hat{r}_{uv}$ 较低的 (u, v) 边，得到去噪图 G_s^d。

使用去噪图训练社交推荐模型。给定 G_s^d 和 G_r，任何社交推荐模型都可以不受其结构限制地融入 GDMSR。此外，由于去噪和推荐这两个训练阶段彼此解耦，特定的 G_s^d 可以与多种类型的推荐模型以统一的方式协同工作。

由于 GDMSR 通常适用于第 2 节讨论的所有基于图神经网络的社交推荐模型，因此本节其余部分将重点介绍图去噪网络的设计，该设计也已在图2中展示。

3.2 偏好引导图去噪网络

为推荐任务对用户关联的社交网络进行去噪，关键挑战之一是缺乏冗余社交关系的真实标签，因此在训练模型时，每条现有链接都被同等对待，

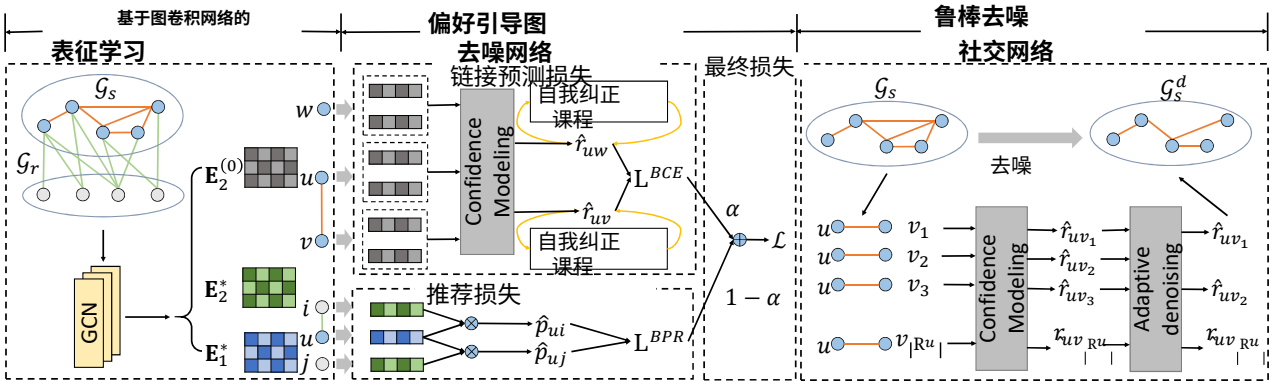

图2：GDMSR 中图去噪过程的细节。

这使得模型难以从海量数据中识别信息丰富的链接。当前的社交推荐模型希望通过可学习的消息传递机制（如图注意力网络）自动捕捉多样化的社交影响，但由于推荐损失提供的是间接监督，这种方法可能效果不佳。鉴于去噪的目的是获得一个更稀疏、但信息更丰富的社交图，以进行用户偏好学习，我们提出设计一种偏好引导图去噪网络，以解决社交推荐场景中的社交关系冗余问题。

基于图卷积网络的表征学习。 与基于图神经网络的社交推荐模型类似，我们在 GDMSR 中设计的偏好引导图去噪网络也采用基于图神经网络的模型结构，其输入同样为社交图 G_s 和交互图 G_r。具体而言，经过 K 跳传播后的用户和物品表征，即 $\{\mathbf{E}(k)_1\}_{k=0}^{K}$ 和 $\{\mathbf{E}(k)_2\}_{k=0}^{K}$，按照公式 (1) 至 (4) 计算。由于我们的目标是通过注意力机制改进先前的学习方法，因此具体的图神经网络模块采用图卷积网络，而非图注意力网络。

链接预测训练。 给定两个用户 u 和 v 之间置信度分数的预测值即 $\hat{r}_{uv}$，链接预测问题旨在最小化以下类似二元交叉熵（BCE）的损失函数：

$$\mathcal{L}^{BCE} = -\sum_{(u,v)\in\mathcal{R}} \log(\sigma(\hat{r}_{uv})) - \sum_{(u,w)\notin\mathcal{R}} \log(1-\sigma(\hat{r}_{uw})). \quad (7)$$

在利用用户偏好作为社交图去噪的指导信号方面，GDMSR 采用了以下两种设计，以更好地利用上述有用知识。

基于偏好的关系置信度建模。 计算关系置信度 $\hat{r}_{uv}$ 的一种常见做法是设计一个评分函数 $\phi(\cdot)$，即，

$$\hat{r}_{uv} = \phi\left(\{\mathbf{E}_1^{(k)}(u)\}_{k=0}^{K}, \{\mathbf{E}_1^{(k)}(v)\}_{k=0}^{K}\right), \quad (8)$$

其中，$\phi(\cdot)$ 可以是可学习的神经网络（如多层感知机），也可以是非参数操作（如内积）。然而，我们认为这种关系置信度建模方式并不精确，因为输入 $\{\mathbf{E}(k)_1\}_{k=0}^{K}$ 可能包含无关信息。为了在社交推荐场景中找出有影响力的好友，直接比较他们的交互历史是很直观的，因为交互历史能够体现他们偏好的相似度。然而，上述基于图卷积网络的用户表示 $\{\mathbf{E}(k)_1\}_{k=0}^{K}$ 提供了更全面的用户特征视图，包括用户档案（即，$\mathbf{E}(0)_1$）、用户偏好与社交影响的融合（即，$\mathbf{E}(1)_1$）以及更高阶的特征。为确保用户偏好能够提供简单而有效的指导，我们提出的 GDMSR 仅使用交互历史来刻画两个好友之间的关系置信度。数学上，$\hat{r}_{uv}$ 的计算方式如下：

$$\hat{r}_{uv} = \mathrm{Trf}\left(S_L\left(\left\{\mathbf{E}_2^{(0)}(i)|\forall i \in \mathcal{P}_u\right\}\right) \oplus S_L\left(\left\{\mathbf{E}_2^{(0)}(j)|\forall j \in \mathcal{P}_v\right\}\right)\right), \quad (9)$$

其中，鉴于 Transformer 模块 [43]，在建模两个用户交互历史序列之间的相似度方面表现出色，我们将其记为 Trf。具体而言，输入是两个序列嵌入（记为 $S_L(\cdot)$）的拼接，分别表示 u 和 v 的交互历史，每个序列的长度固定为 L。由于关系置信度建模无需位置信息，因此这里不在 Transformer 中使用位置编码。对于输出，我们在输入序列末尾添加一个类似“CLS”的标记，并使用对应的 Transformer 编码嵌入向量，通过多层感知机计算 $\hat{r}_{uv}$。

与推荐损失协同优化。 除了设计上述基于偏好的关系置信度建模结构外，我们还通过将去噪模型与推荐损失协同优化，进一步强化偏好指导。如公式 (9) 所示，物品嵌入的质量对于刻画用户之间的关系置信度至关重要。受利用自监督学习提升表示质量这一思路的启发，我们提出加入推荐损失（公式 (6) 中的 L^{BPR}），同时训练物品嵌入以预测用户偏好，从而反过来促进其在图去噪中的应用。因此，最终损失函数如下：

$$\mathcal{L} = \alpha\mathcal{L}^{BCE} + (1-\alpha)\mathcal{L}^{BPR}, \quad (10)$$

其中，$\alpha \in [0,1]$ 是一个超参数，用于控制链接预测损失和推荐损失的相对重要性。

总而言之，我们提出的 GDMSR 能够通过双重方式利用用户偏好来对社交关系进行去噪，即：显式偏好关系建模，以及来自偏好学习的隐式协同监督；二者均有助于解决社交关系冗余问题。

3.3 社交网络的鲁棒去噪

对社交网络进行去噪以用于推荐的另一个关键挑战是去噪模型学习难度增加的一个原因是存在噪声社交关系（即没有共同偏好的好友）。例如，假设两个相连的用户 $\{u, v\}$偏好不同，且拥有两组彼此相关性较低的交互物品 $\{\mathrm{P}u, \mathrm{P}v\}$，通常很难使方程（9）中的 $\hat{r}_{uv}$取较大值；这可能会导致模型产生偏差，不得不记住这个难处理的样本 [1]。

因此，所提出的 GDMSR 设计了一种自我纠正课程学习机制和一种自适应去噪策略，以减轻这种噪声影响，从而实现鲁棒图去噪。

自我纠正课程学习机制。在 GDMSR 的学习过程中，当前去噪模型预测为噪声关系的概率较高（即置信度分数相当低）的关系会被移除；每经过若干训练轮次，被移除的关系集合便会随模型动态更新。这相当于遵循一种基于难度的课程，倾向于选择较容易的样本，以便在噪声环境下实现鲁棒学习；同时，根据当前模型，用较容易的样本替换较难的样本，不断修正课程 [64]。具体而言，对于用户 u，将按 $\hat{r}_{uv}$ 排序后其好友中最后 η_u 个视为噪声关系，并从训练中移除。该集合每经过 D 个训练轮次便更新一次，其中 D 是一个超参数，表示上述自我纠正课程中每个周期的长度。

自适应去噪策略。如图2所示，训练好的去噪模型在最后阶段用于社交网络去噪，即预测每条现有社交关系的置信度分数，并移除置信度较低的关系。一方面，由于带有噪声标签的训练过程可能不稳定，通过沿训练过程平滑预测结果 [5, 22]，进一步增强GDMSR的鲁棒性。具体而言，在第 k个课程周期结束时，即第 kD个训练轮次，$\hat{r}_{uv}$通过上一周期的结果进行平滑处理。数学上，$\hat{r}_{uv}$按如下方式更新：

$$\hat{r}_{uv}(t = kD) = \beta \cdot \hat{r}_{uv}(t = (k-1)D) + (1-\beta) \cdot \hat{r}_{uv}(t = kD), \quad (11)$$

其中，超参数 β控制平滑程度。另一方面，受邓巴数理论 启发，该理论指出用户的亲密好友数量 [12], 存在上限，因此我们提出根据用户的好友数量自适应地对用户 u的社交图进行去噪，即，$|\mathrm{R}_u|$。具体而言，对于每位用户 u，从原始图G_s中移除 u的好友中的 η_u，其中使用与上述课程设计相同的超参数 η_u。数学上，去噪率η_u 按如下方式计算：

$$\eta_u = \begin{cases} 0, & \text{if } |\mathcal{R}_u| < \epsilon, \\ \left\lfloor \lfloor \log_{10}(|\mathcal{R}_u|) \rfloor \right\rfloor^{\gamma} \times R, & \text{else}, \end{cases} \quad (12)$$

其中，ϵ、γ和 R是三个超参数。该公式的核心思想是，稀疏连接用户（$|\mathrm{R}_u| < \epsilon$）可以保留所有关系，而稠密连接用户则会在去噪图 G_s^d中删除更多关系；与不考虑好友数量、统一删除关系相比，这种方式更加稳健。

总而言之，通过在训练过程中遵循上述自我纠正课程，并采用自适应去噪方式，我们提出的 GDMSR 能够基于用户偏好稳健地对社交关系进行去噪。至此，我们已完成了整个去噪过程，完整算法见附录 A。

4 实验

4.1 实验设置

数据集。我们在三个开放的社交推荐数据集上开展实验，包括 Ciao、Yelp 和豆瓣。这些数据集已广泛应用于社交推荐相关研究[50, 60]。更多数据集预处理细节见附录 B。各数据集的统计信息见表1。

基线方法。我们的 GDMSR 能够生成去噪社交网络，并适用于任意社交推荐模型。对于社交推荐模型，我们选择 Diffnet++ [50] 和 MHCN [60] 作为基线方法。对于去噪方法，我们将 GDMSR 与基于规则的方法、NeuralSparse [63] 和 ESRF [59]进行比较。最后，我们还加入 LightGCN [20] 作为基线方法，它只使用交互数据，不使用社交关系数据。关于基线方法的更多信息见附录 B。

评估。为了评估所有方法的性能，我们使用 *Recall@K* 和 *NDCG@K* 作为指标，其中 K={1,3}。根据 [62], 的建议，我们使用 *real-plus-N* [3, 35] 来计算这些指标。对于测试集中的每位用户，我们随机抽取 100 个该用户未交互过的物品，并将它们与测试集中的正样本一起排序。

更多实现细节见附录 B。

4.2 总体性能

我们将 GDMSR 的性能与未进行社交网络去噪的原始社交推荐模型以及两种去噪方法进行了比较。结果如表2所示。所有去噪方法的总体平均去噪比约为 5% 到 10%，具体取决于超参数。所有结果均为五次重复实验后的平均值。我们对 GDMSR 的结果与性能最佳的基线方法进行了配对 t 检验。当 $\mathrm{p} < 0.01$ 时，所有改进在统计上均显著。可以观察到，GDMSR 在所有实验中都取得了最佳性能，且在一个数据集（即 Ciao）上的最大提升达到 10%。

此外，我们还有以下发现。**首先**，与直接使用原始社交网络相比，通过不同方法对社交网络进行去噪后，所有实验中的性能均有所提升。这表明，在社交推荐中，社交网络中普遍存在不可靠的社交关系，并非所有社交关系都能反映用户的同质性或社交影响。即使是简单的基于规则的去噪方法，也能提升性能。**其次**，与同时使用用户交互信息和社交信息进行去噪的 NeuralSparse 相比，GDMSR 的性能更好。这表明，在复杂社交网络中，仅使用用户偏好进行去噪，比使用社交关系和用户偏好进行去噪更有效。**最后**，所提出的 GDMSR 在不同模型的基础上都能提升性能。例如，在豆瓣数据集上，无论使用 Diffnet++还是 MHCN，GDMSR 相较于表现最佳的基线方法，性能提升均超过 2%，这意味着 GDMSR 无需依赖

表1：数据集的基本信息。

数据集	#用户数	#物品数	#交互数	#关系	交互密度	关系密度
Ciao	7,355	17,867	140,628	111,679	0.11%	0.21%
Yelp	32,827	59,972	598,121	964,510	0.03%	0.09%
豆瓣	2,669	15,940	535,210	32,705	1.26%	0.46%

表2：我们提出的方法在不同推荐方法上的总体性能 **ds.**

数据集		Ciao			Yelp			豆瓣		
基础模型	方法	R@1	R@3	N@3	R@1	R@3	N@3	R@1	R@3	N@3
LightGCN	-	0.2298	0.0785	0.2071	0.5861	0.2774	0.5804	0.4321	0.1696	0.4156
Diffnet++	不进行去噪	0.2742	0.1109	0.2639	0.6031	0.3072	0.5897	0.5165	0.2156	0.4988
	基于规则	0.2860	0.1123	0.2677	0.6230	0.3228	0.5996	0.5358	0.2489	0.5172
	NeuralSparse	0.2869	0.1153	0.2734	0.6383	0.3289	0.6054	0.5470	0.2226	0.5102
	ESRF	0.2864	0.1197	0.2736	0.6184	0.3124	0.5958	0.5374	0.2393	0.5194
	GDMSR	**0.3020**	**0.1244**	**0.2821**	**0.6449**	**0.3291**	**0.6102**	**0.5614**	**0.2540**	**0.5297**
	Δ	5.26%	3.93%	3.11%	1.03%	0.06%	0.79%	2.63%	2.05%	1.98%
MHCN	不进行去噪	0.2330	0.0884	0.2297	0.6991	0.3252	0.6364	0.6198	0.3167	0.5933
	基于规则	0.2301	0.0916	0.2311	0.6966	0.3234	0.6347	0.6082	0.3372	0.5980
	NeuralSparse	0.2461	0.1034	0.2540	0.7012	0.3288	0.6352	0.6206	0.3349	0.6011
	ESRF	0.2495	0.1028	0.2568	0.6927	0.3298	0.6344	0.6194	0.3244	0.5995
	GDMSR	**0.2618**	**0.1138**	**0.2632**	**0.7036**	**0.3405**	**0.6434**	**0.6396**	**0.3496**	**0.6137**
	Δ	4.93%	10.06%	2.50%	0.34%	3.24%	1.10%	3.06%	3.68%	2.10%

针对特定模型，并且能够更广泛地适配不同的社交推荐模型。

4.3 消融研究

协同优化提供的偏好引导。我们提出在去噪训练过程中联合优化推荐损失和链接预测损失，从而提高关系置信度建模的准确性。我们测试了不同权重(α)下协同优化的效果，结果如图3(a)(b)所示。可以发现，在不同的社交推荐模型上，随着α从0增至1，性能先升后降。具体而言，在Ciao数据集上，当$\alpha = 0.5$时，三个社交推荐模型分别达到了各自的最佳性能。在豆瓣数据集上，$\alpha = 0.3$或0.5的效果最好。这证明，我们的协同优化模块能够通过推荐损失获得更好的物品表示，并进一步提高链接预测任务的准确性。同时，当$\alpha = 0$时，与表2中的不进行去噪方法相比，模型性能没有明显优势，这表明仅对用户偏好进行建模是不够的，去噪模型还需要链接预测任务的引导。

仅利用偏好建模关系置信度。在关系建模任务中，我们提出仅利用用户的反馈来衡量用户之间关系的置信度，也就是该用户交互过的物品表示。为验证这一想法的效果，我们将提出的基于Transformer的关系置信度建模模块与另外三种采用不同信息的方案进行比较，包括使用用户表示或直接对物品表示进行池化。结果如图3(c)-(d)所示。“User-0”和“User-1”分别表示使用图卷积网络卷积前和第一层卷积后的用户节点表示。我们可以观察到，仅使用物品表示的效果最好，这证明了所提出的关系建模结构是有效的，因为它能确保用户偏好（交互历史）提供简单而有效的指导。与此同时，与使用用户表示相比，仅使用物品表示进行池化也能取得相近的结果。这再次表明，当去噪模型整合包含用户个人资料（即，$\mathbf{E}^{(0)}{}_1$）和社交影响（即，$\mathbf{E}^{(1)}{}_1$）在内的用户侧信息时，无法有效地对用户的社交关系置信度进行建模。

去噪鲁棒性。在鲁棒去噪模块中，我们提出了一种自适应去噪策略，使好友较多的用户具有更高的去噪率。为了验证这一策略的效果，我们将其与对所有用户采用相同去噪率（η_u）的策略进行比较。如图4和附录B.8所示，在不同情况下，关于*Recall*@1的性能始终呈现先升后降的趋势，这表明适当地对社交网络进行去噪可以增强社交影响的效果，进而提升推荐性能。同时，与非自适应去噪相比，所提出的GDMSR在几乎所有不同去噪率的情况下都显著优于其他方法。更重要的是，我们提出的GDMSR能够在不损害原有推荐准确率的前提下进一步实现稀疏化，从而生成一种内存高效的社交图，这对实际应用至关重要。具体而言，GDMSR与Diffnet++结合后，可在保持准确率提升的同时减少20-40%的关系。相比之下，与MHCN结合时，关系减少比例降至约10%，但在商业推荐系统中仍具有很大的实际价值。

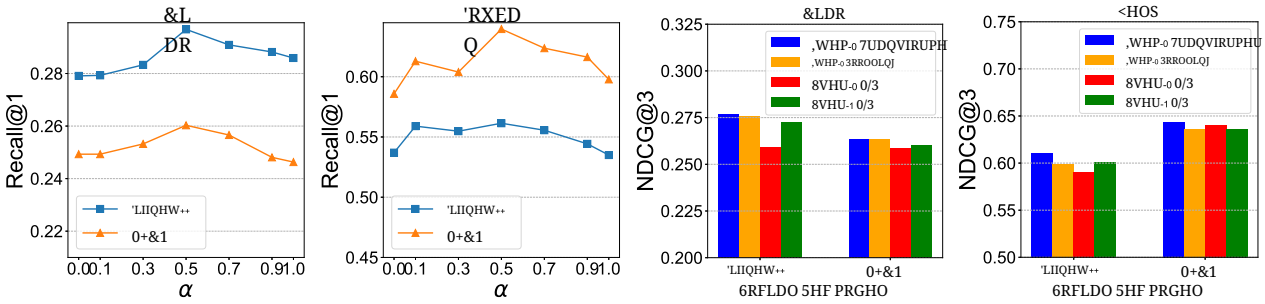

(a) 协同优化权重　(b) 协同优化权重　(c) 关系置信度建模　(d) 关系置信度建模

图 3：(a)-(b) 不同 α 下的协同优化性能。(c)-(d) 不同关系置信度建模结构的性能比较。

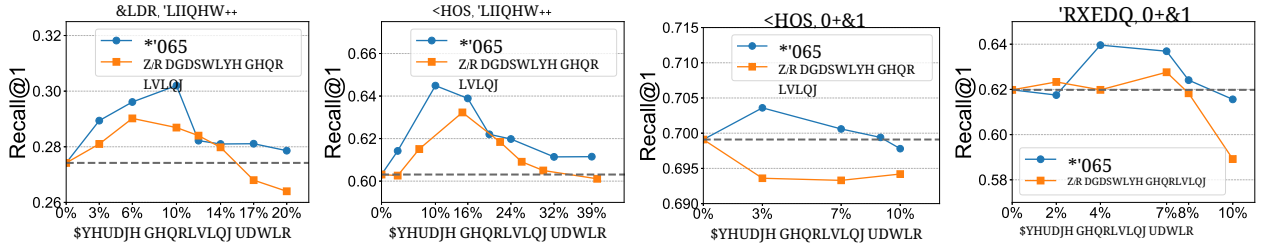

(a)　(b)　(c)　(d)

图4：分析不同去噪率下，去噪鲁棒性对推荐准确率的影响。

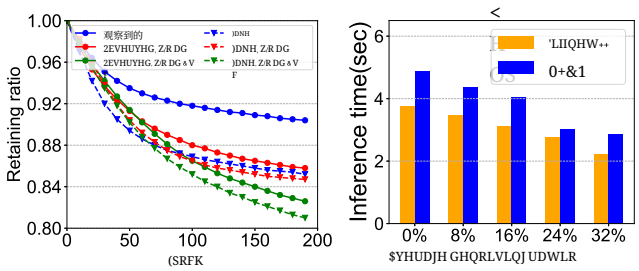

(a) 去噪能力　(b) 推理效率

图5：(a) 采用不同去噪策略时社交关系的保留比例（合成数据）。(b) 社交图相关推理时间的效率比较，关于 （Yelp）。

系统中。由于 MHCN 依赖挖掘社交模体并利用超图卷积模型刻画其影响，图去噪可能会因结构变化而对 MHCN 产生更大的影响。此外，我们还比较了选择不同超参数 γ 取值的效果。受篇幅限制，详情请参阅附录 B.8。

4.4 合成数据上的去噪能力

为了进一步评估我们提出的 GDMSR 的去噪能力，我们构建了一个合成数据集（基于 Ciao），其中包含观测到的社交关系和伪造的社交关系（即，我们随机将一些未连接的用户对设为已连接），并评估 GDMSR 是否能够学习一个强大的图去噪模型，从而有效地区分给定的关系标签。具体而言，我们注入与观测到的社交关系数量相同的伪造社交关系，并进一步将这些被污染的关系数据与原始交互数据结合起来训练 GDMSR。随后，我们记录去噪过程中关系数据各部分的保留比例，并在图5(a)中展示结果。这里我们还比较了两个变体：即，不使用自适应去噪（简称“w/o ad”），以及不使用自适应去噪和自校正课程学习（简称“w/o ad & sc”）。结果清楚地表明，即使面对关系标签被污染所造成的显式噪声，GDMSR 仍能通过移除更多伪造关系（16%）而非观测到的关系（9%），保持学习的鲁棒性。换言之，由于我们注入了相当强的噪声（50% 的关系标签遭到污染），GDMSR 仍取得了中等偏好的准确率（64%（16/(16+9)））；而另外两种方案在这种标签噪声水平下无法构建出可用的去噪模块。

4.5 实用性评估

计算效率。我们提出的 GDMSR 能够生成稀疏得多的社交图（例如，在 Yelp 数据集上规模缩小了 20%–40%），从而提高推理阶段的计算效率。图5(b)展示了社交图相关计算（社交网络侧图神经网络）的推理时间分析，该分析是在 Yelp 数据集上通过推理 $50w$ 条记录完成的。结果清楚地表明，随着去噪率增大，计算效率持续提升。

表 3：基于 30% 交互数据的 GDMSR 总体性能。

数据集		Ciao			Yelp			豆瓣		
基础模型	方法	R@1	R@3	N@3	R@1	R@3	N@3	R@1	R@3	N@3
Diffnet++	不进行去噪	0.2742	0.1109	0.2639	0.6031	0.3072	0.5897	0.5165	0.2156	0.4988
	GDMSR	**0.2899**	**0.1175**	**0.2755**	**0.6305**	**0.3189**	**0.6021**	**0.5490**	**0.2497**	**0.5295**
	Δ	5.73%	5.95%	4.40%	4.54%	3.81%	2.10%	6.29%	15.82%	6.15%
MHCN	不进行去噪	0.2330	0.0884	0.2297	0.6991	0.3252	0.6364	**0.6198**	0.3167	0.5933
	GDMSR	**0.2616**	**0.1093**	**0.2638**	**0.7005**	**0.3438**	**0.6445**	0.6148	**0.3360**	**0.6012**
	Δ	12.27%	23.64%	14.85%	0.20%	5.72%	1.27%	-0.81%	6.09%	1.33%

无需频繁训练的零样本去噪。在工业实践中，鉴于社交关系数据规模庞大（Facebook 和微信上的数据量多达数亿），频繁更新图去噪模型既耗时又几乎不可行。因此，GDMSR 需要支持以较低频率进行去噪训练，即无需使用新产生的交互数据进行训练，也能生成高质量的蒸馏社交图 [28]。为评估这一实用性，我们设计了另一项实验：仅使用 30% 的交互数据训练 GDMSR 的去噪模块，然后将全部交互数据作为输入，对社交图进行去噪。这一设置模拟了 GDMSR 在实践中无法及时更新的情况。此时，我们可以使用旧版 GDMSR 模型和新的交互数据，以类似零样本的方式直接对当前社交图进行去噪。随后，我们使用去噪图训练社交推荐模型，结果见表3。可以看出，即使仅使用 30% 的训练样本，GDMSR 仍能有效地对社交网络进行去噪。在大多数情况下，与不进行去噪相比，推荐准确率均有所提高，最高提升达 23%，这表明 GDMSR 在工业实践中具有很强的可扩展性。事实上，这主要得益于我们设计的仅基于交互的偏好引导去噪方法，该方法更加稳健，也较少受到其他上下文变化的影响。

5 相关工作

5.1 面向社交推荐的图去噪

早期研究使用共同交互数等简单统计指标 [31]来表示社交关系的置信度，但由于数据稀疏性 [40]，这种方法通常效果不佳。为了捕捉社交影响的观测多样性，可以利用注意力机制 [50, 55]、细粒度上下文信息 [14]、期望最大化方法 [47] 或强化学习 [11]，学习不同好友之间的自适应权重。尽管上述技术可应用于当前主流的 GSocRec 模型，但由于缺乏真实标签，它们通常难以有效学习社交影响程度。从通用图机器学习的角度来看，图稀疏化方法 [7, 63] 通过从通用图中删除边来实现稳健学习，但没有考虑社交推荐的特定情境。此外，图结构学习方法 [29, 30, 61] 不仅会删除边，还会添加边；由于这类方法通常在用户之间的笛卡尔积所形成的巨大空间中运行，因此用于社交推荐时耗时过长。作为一种针对社交情境的特定扩展，有一系列研究提出，不仅要移除质量较低的观测社交关系，还要添加少量潜在关系 [24, 56, 57, 59]。这一思路也被应用于会话推荐等动态推荐场景：从观测到的社交关系出发，并在训练过程中更新关系 [38, 49]。此外，使用上下文特征 [26]或多视图学习 [25]也能提升社交推荐的效果。与上述研究不同，我们提出的 GDMSR方法能够生成蒸馏社交图，该图不仅更加稀疏，而且包含的信息也更加丰富，因此更适用于现实世界的社交推荐系统。在实验中，我们还与上述一种具有竞争力的方法 [59] 进行了比较，以证明 GDMSR的有效性。

5.2 推荐去噪

在通用推荐系统中，另一个热门研究方向是反馈去噪，它能够实现更稳健的偏好学习 [21, 42]。由于用户表达偏好的方式存在异质性，为显式反馈或隐式反馈设置统一阈值并非最优。例如，用户对低评分物品的评判标准各不相同 [45]，对于是否点击也是如此 [8–10]。还有一些研究通过因果推断来解决这一问题 [16]。为解决从噪声标签中学习的问题 [37],，现有研究采用了添加基于图的先验 [39],、跨模型一致性 [48] 以及图稀疏化 [17] 等技术，对观测到的用户-物品交互数据进行去噪。与上述研究不同，我们专注于对社交网络（即用户-用户关系数据）进行去噪，从而更有效、更高效地利用社交同质性和社交影响。

6 结论与未来工作

本文通过重新审视社交网络对学习图神经网络推荐模型的可靠性，探讨了基于图的社交推荐问题。由于缺乏可靠标注的数据，我们选择利用能够反映用户偏好的用户-物品反馈来过滤噪声社交关系，从而改进偏好学习。在三个公开基准数据集和不同社交推荐模型上的实验不仅证明了该去噪方法的有效性，也表明我们提出的解决方案可以作为一种通用框架。具体而言，性能提升稳定且显著，最高可达 10%。

关于未来的计划，一个有趣的方向是借助社会网络理论 [4]，深入分析原始社交网络与去噪后社交网络之间的差异。

致谢

本研究部分得到国家重点研发计划（项目编号：2020AAA0106000）以及国家自然科学基金（项目编号：61971267、U1936217、61972223、62272262）的资助。

参考文献

[1] Devansh Arpit、Stanisław Jastrzębski、Nicolas Ballas、David Krueger、Emmanuel Bengio、Maxinder S Kanwal、Tegan Maharaj、Asja Fischer、Aaron Courville、Yoshua Bengio 等。2017。深入探究深度网络中的记忆化。载于 ICML。233–242。[2] Eytan Bakshy、Dean Eckles、Rong Yan 和 Itamar Rosenn。2012。社交广告中的社交影响：现场实验的证据。载于 ACM电子商务会议。146–161。[3] Alejandro Bellogin、Pablo Castells 和 Ivan Cantador。2011。面向精准度的推荐系统评估：算法比较。载于 Recsys。333–336。[4] Damon Centola。2010。在线社交网络实验中的行为传播。《科学》329，5996（2010），1194–1197。[5] Pengfei Chen、Junjie Ye、Guangyong Chen、Jingwei Zhao 和 Pheng-Ann Heng。2021。超越类别条件假设：应对实例依赖标签噪声的初步尝试。载于 AAAI，第35卷。11442–11450。[6] Renata Gonçalves Curty 和 Ping Zhang。2011。社交商务：回顾与展望。美国信息科学与技术学会论文集48，1（2011），1–10。[7] Enyan Dai、Wei Jin、Hui Liu 和 Suhang Wang。2022。面向稀疏标签噪声图的鲁棒图神经网络。载于 WSDM。181–191。[8] Jingtao Ding、Yuhan Quan、Xiangnan He、Yong Li 和 Depeng Jin。2019。利用曝光数据进行推荐的强化负采样。载于国际人工智能联合会议。澳门，2230–2236。[9] Jingtao Ding、Yuhan Quan、Quanming Yao、Yong Li 和 Depeng Jin。2020。简化并增强隐式协同过滤的负采样。神经信息处理系统大会33（2020），1094–1105。[10] Jingtao Ding、Guanghui Yu、Xiangnan He、Fuli Feng、Yong Li 和 Depeng Jin。2019。利用浏览数据设计贝叶斯个性化排序采样器。IEEE 知识与数据工程汇刊33，2（2019），667–681。[11] Qihan Du、Li Yu、Huiyuan Li、Youfang Leng、Ningrui Ou 和 Junyao Xiang。2022。社交推荐中的去噪引导的深度强化学习。载于 IEEE声学、语音与信号处理国际会议。4113–4117。[12] Robin Dunbar。2010。一个人需要多少朋友？邓巴数及其他进化奇闻。Faber & Faber。[13] Wenqi Fan、Yao Ma、Qing Li、Yuan He、Eric Zhao、Jiliang Tang 和 Dawei Yin。2019。用于社交推荐的图神经网络。载于 WWW。417–426。[14] Bairan Fu、Wenming Zhang、Guangneng Hu、Xinyu Dai、Shujian Huang 和 Jiajun Chen。2021。用于社交推荐的双侧深度上下文感知调制。载于 WWW。2524–2534。[15] Chen Gao、Yu Zheng、Nian Li、Yinfeng Li、Yingrong Qin、Jinghua Piao、Yuhan Quan、Jianxin Chang、Depeng Jin、Xiangnan He 等。2022。推荐系统中的图神经网络综述：挑战、方法与方向。《ACM推荐系统汇刊》（2022）。[16] Chen Gao、Yu Zheng、Wenjie Wang、Fuli Feng、Xiangnan He 和 Yong Li。2022。推荐系统中的因果推断：综述与未来方向。arXiv 预印本 arXiv:2208.12397（2022）。[17] Yunjun Gao、Yuntao Du、Yujia Hu、Lu Chen、Xinjun Zhu、Ziquan Fang 和 Baihua Zheng。2022。面向鲁棒推荐的自引导去噪学习。arXiv 预印本 arXiv:2204.06832（2022）。[18] Guibing Guo、Jie Zhang 和 Neil Yorke-Smith。2015。Trustsvd：结合用户信任的显式与隐式影响以及物品评分的协同过滤。载于 AAAI，第29卷。[19] Will Hamilton、Zhitao Ying 和 Jure Leskovec。2017。大型图上的归纳式表示学习。NIPS 30（2017）。[20] Xiangnan He、Kuan Deng、Xiang Wang、Yan Li、Yongdong Zhang 和 Meng Wang。2020。LightGCN：简化并增强用于推荐的图卷积网络。载于 SIGIR。639–648。[21] Yue He、Yancheng Dong、Peng Cui、Yuhang Jiao、Xiaowei Wang、Ji Liu 和 Philip S Yu。2021。净化与生成：从含噪用户-物品交互行为中学习忠实的物品间图。载于 KDD。3002–3010。[22] Lang Huang、Chao Zhang 和 Hongyang Zhang。2020。自适应训练：超越经验风险最小化。神经信息处理系统大会33（2020），19365–19376。[23] Thomas N Kipf 和 Max Welling。2016。基于图卷积网络的半监督分类。arXiv 预印本 arXiv:1609.02907（2016）。[24] Adit Krishnan、Hari Cheruvu、Cheng Tao 和 Hari Sundaram。2019。用于社交推荐的模块化对抗方法。载于第 28 届 ACM 信息与知识管理国际会议论文集。1753–1762。[25] Adit Krishnan、Mahashweta Das、Mangesh Bendre、Fei Wang、Hao Yang 和 Hari Sundaram。2022。通过残差函数实现的多任务知识图谱表示。载于《知识发现与数据挖掘进展：第 26 届亚太会议（PAKDD 2022）论文集》，中国成都，2022 年 5 月 16—19 日，第一部分。施普林格，262–275。[26] Adit Krishnan、Mahashweta Das、Mangesh Bendre、Hao Yang 和 Hari Sundaram。2020。利用上下文不变量进行迁移学习，实现一对多跨域推荐。载于第 43 届国际 ACM 信息检索研究与发展会议论文集。1081–1090。[27] David Liben-Nowell 和 Jon Kleinberg。2007。社交网络中的链接预测问题。《美国信息科学与技术学会期刊》58，7（2007），1019–1031。[28] Dandan Lin、Shijie Sun、Jingtao Ding、Xuehan Ke、Hao Gu、Xing Huang、Chong- gang Song、Xuri Zhang、Lingling Yi、Jie Wen 等。2022。PlatoGL：面向图增强实时推荐的高效可扩展深度图学习系统。载于第 31 届 ACM 信息与知识管理国际会议论文集。3302–3311。[29] Nian Liu、Xiao Wang、Lingfei Wu、Yu Chen、Xiaojie Guo 和 Chuan Shi。2022。通过互信息压缩实现紧凑图结构学习。载于 WWW。1601–1610。[30] Yixin Liu、Yu Zheng、Daokun Zhang、Hongxu Chen、Hao Peng 和 Shirui Pan。2022。迈向无监督深度图结构学习。arXiv 预印本 arXiv:2201.06367（2022）。[31] Hao Ma、Dengyong Zhou、Chao Liu、Michael R Lyu 和 Irwin King。2011。采用社交正则化的推荐系统。载于 WSDM。287–296。[32] Peter V Marsden 和 Noah E Friedkin。1993。社交影响的网络研究。《社会学方法与研究》22，1（1993），127–151。[33] Miller McPherson、Lynn Smith-Lovin 和 James M Cook。2001。物以类聚：社交网络中的同质性。《社会学年度评论》27，1（2001），415–444。[34] Steffen Rendle、Christoph Freudenthaler、Zeno Gantner 和 Lars Schmidt-Thieme。2009。贝叶斯个性化排序：基于隐式反馈的贝叶斯个性化排序。载于 UAI。452–461。[35] Alan Said 和 Alejandro Bellogín。2014。推荐系统比较评估：推荐框架的基准测试。载于 Recsys。129–136。[36] Chijun Sima、Yao Fu、Man-Kit Sit、Liyi Guo、Xuri Gong、Feng Lin、Junyu Wu、Yongsheng Li、Haidong Rong、Pierre-Louis Aublin 等。2022。Ekko：采用{大规模}深度学习和{低延迟}模型更新的推荐系统。载于第 16 届 USENIX 操作系统设计与实现研讨会（OSDI 22）。821–839。[37] Hwanjun Song、Minseok Kim、Dongmin Park、Yooju Shin 和 Jae-Gil Lee。2022。利用深度神经网络从噪声标签中学习：综述。IEEE TNNLS。[38] Liqiang Song、Ye Bi、Mengqiu Yao、Zhenyu Wu、Jianming Wang 和 Jing Xiao。2020。Dream：用于社交推荐的动态关系感知模型。载于 CIKM。2225–2228。[39] Jonathan Strahl、Jaakko Peltonen、Hirsohi Mamitsuka 和 Samuel Kaski。2020。采用基于图的先验的可扩展概率矩阵分解。载于 AAAI，第 34 卷。5851–5858。[40] Jiliang Tang、Xia Hu 和 Huan Liu。2013。社交推荐：综述。《社交网络分析与挖掘》3，4（2013），1113–1133。[41] Ye Tao、Ying Li、Su Zhang、Zhirong Hou 和 Zhonghai Wu。2022。重新审视基于图的社交推荐：蒸馏增强社交图网络。载于 WWW。2830–2838。[42] Changxin Tian、Yuexiang Xie、Yaliang Li、Nan Yang 和 Wayne Xin Zhao。2022。学习对不可靠交互进行去噪，以实现图协同过滤。载于 SIGIR。122–132。[43] Ashish Vaswani、Noam Shazeer、Niki Parmar、Jakob Uszkoreit、Llion Jones、Aidan N Gomez、Łukasz Kaiser 和 Illia Polosukhin。2017。注意力机制就是你所需要的一切。NIPS 30（2017）。[44] Petar Veličković、Guillem Cucurull、Arantxa Casanova、Adriana Romero、Pietro Lio 和 Yoshua Bengio。2017。图注意力网络。arXiv 预印本 arXiv:1710.10903（2017）。[45] Wenjie Wang、Fuli Feng、Xiangnan He、Liqiang Nie 和 Tat-Seng Chua。2021。为推荐任务对隐式反馈进行去噪。载于 WSDM。373–381。[46] Xin Wang、Wei Lu、Martin Ester、Can Wang 和 Chun Chen。2016。利用强关系与弱关系进行社交推荐。载于 CIKM。5–14。[47] Xin Wang、Wenwu Zhu 和 Chenghao Liu。2019。利用最优有限注意力进行社交推荐。载于 KDD。1518–1527。[48] Yu Wang、Xin Xin、Zaiqiao Meng、Joemon M Jose、Fuli Feng 和 Xiangnan He。2022。通过跨模型一致性学习鲁棒推荐系统。载于 WWW。2015–2025。[49] Chunyu Wei、Bing Bai、Kun Bai 和 Fei Wang。2022。GSL4Rec：结合集体图结构学习与下一次交互预测的基于会话的推荐。载于 WWW。2120–2130。[50] Le Wu、Junwei Li、Peijie Sun、Richang Hong、Yong Ge 和 Meng Wang。2020。Diffnet++：用于社交推荐的神经影响力与兴趣扩散网络。《IEEE 知识与数据工程汇刊》（2020）。[51] Le Wu、Peijie Sun、Yanjie Fu、Richang Hong、Xiting Wang 和 Meng Wang。2019。用于社交推荐的神经影响力扩散模型。载于 SIGIR。235–244。

[52] Le Wu、Peijie Sun、Richang Hong、Yanjie Fu、Xiting Wang 和 Meng Wang。2018。Socialgcn：一种用于社交推荐的高效图卷积网络模型。*arXiv* 预印本 *arXiv:1811.02815*（2018）。[53] Qitian Wu、Hengrui Zhang、Xiaofeng Gao、Peng He、Paul Weng、Han Gao 和 Guihai Chen。2019。用于推荐系统中多方面社交效应深度潜在表示的双图注意力网络。载于 *WWW*。2091–2102。[54] Fengli Xu、Zhenyu Han、Jinghua Piao 和 Yong Li。2019。“我觉得你会喜欢它”：对社交电子商务中在线购买行为的建模。*ACM* 人机交互论文集 3，CSCW（2019），1–23。[55] Liangwei Yang、Zhiwei Liu、Yingtong Dou、Jing Ma 和 Philip S Yu。2021。Consisrec：通过一致的邻居聚合增强用于社交推荐的图神经网络。载于 *SIGIR*。2141–2145。[56] Junliang Yu、Min Gao、Jundong Li、Hongzhi Yin 和 Huan Liu。2018。面向社交推荐的异构网络自适应隐式好友识别。载于 *CIKM*。357–366。[57] Junliang Yu、Min Gao、Hongzhi Yin、Jundong Li、Chongming Gao 和 Qinyong Wang。2019。通过对抗训练生成可靠好友，以改进社交推荐。载于 *ICDM*。768–777。[58] Junliang Yu、Hongzhi Yin、Min Gao、Xin Xia、Xiangliang Zhang 和 Nguyen Quoc Viet Hung。2021。面向推荐的社交感知自监督三重训练。载于 *KDD*。2084–2092。[59] Junliang Yu、Hongzhi Yin、Jundong Li、Min Gao、Zi Huang 和 Lizhen Cui。2020。利用对抗图卷积网络增强社交推荐。*IEEE* 知识与数据工程汇刊（2020）。[60] Junliang Yu、Hongzhi Yin、Jundong Li、Qinyong Wang、Nguyen Quoc Viet Hung 和 Xiangliang Zhang。2021。用于社交推荐的自监督多通道超图卷积网络。载于 *WWW*。413–424。[61] Jianan Zhao、Xiao Wang、Chuan Shi、Binbin Hu、Guojie Song 和 Yanfang Ye。2021。面向图神经网络的异构图结构学习。载于 *AAAI*。[62] Wayne Xin Zhao、Junhua Chen、Pengfei Wang、Qi Gu 和 Ji-Rong Wen。2020。重新审视评估 Top-N 项目推荐算法的替代实验设置。载于 *CIKM*。2329–2332。[63] Cheng Zheng、Bo Zong、Wei Cheng、Dongjin Song、Jingchao Ni、Wenchao Yu、Haifeng Chen 和 Wei Wang。2020。通过神经稀疏化实现鲁棒图表示学习。载于 *ICML*。PMLR，11458–11468。[64] Songzhu Zheng、Pengxiang Wu、Aman Goswami、Mayank Goswami、Dimitris Metaxas 和 Chao Chen。2020。噪声标签的误差有界校正。载于 *ICML*。PMLR，11447–11457。

GDMSR的训练过程

GDMSR的整体流程如算法1所示。

算法1： GDMSR的训练过程

需要： 社交关系集 R，交互集 P

对于 $epoch = 1$ 至 MAX_训练轮次 **执行**
  从 P 生成训练批次 B
  对 (u, i) 在 $\mathcal{B}$ **中执行**
    使用 $j \notin \mathrm{P}u$、 $v \in \mathrm{R}u$ 和，对 (u, j)、(u, v) 以及 (u, w) 进行采样 $w \notin \mathrm{R}u$
    根据公式 6 计算推荐损失 L^{BPR}
    根据公式7计算链接预测损失 L^{BCE}
    根据公式9计算最终损失 L 并更新参数
  结束循环
  如果 $epoch\%D == 0$，**则**
    对于 (u, v) in $\mathcal{R}$，**执行**
      根据公式8和公式10计算 $\hat{r}_{uv}(t = kD)$
    结束循环
    对 u 中的 $\mathcal{U}$ **执行**
      根据公式11计算 η_u
      移除 u的好友中按$\hat{r}_{uv}(t = kD)$排序后的最后 η_u 个
    结束循环
  结束条件判断
结束

B 实验详情

B.1 数据集预处理

对于所有数据集，我们仅保留评分为 4 或 5 的样本作为正样本。此外，我们根据交互数以及用户好友数筛选用户和物品，仅保留与活跃度较高的用户和物品相关的样本。对于 Yelp 数据集，我们保留用户属性；由于其他两个数据集的原始数据不包含用户属性，因此我们仅使用用户 ID 作为特征。

B.2 基线方法

下面介绍我们使用的基线方法

Diffnet++。该模型使用图注意力网络来建模不同好友之间多样的社交影响。

MHCN。该模型使用超图卷积方法，捕捉社交模体对好友间偏好学习的不同影响。

基于规则的方法。基于社交同质性假设，可以根据用户互动过的物品来衡量用户之间的相似度。因此，我们会移除那些用户共同互动过的物品较少的关系。

NeuralSparse。这是一种端到端的自适应图稀疏化方法，通过使用 Gumbel softmax 从经验数据中学习可微采样器。

ESRF。该端到端社交推荐框架利用生成对抗网络（GAN），为社交推荐生成连接更密集的社交图。

B.3 运行环境

实验在一台 Linux 服务器上进行，该服务器配备 AMD Ryzen Threadripper 2990WX@3.0GHz、128G 内存和 3 块 NVIDIA GeForce RTX 2080TI-11GB。我们提出的 GDMSR 使用 PyTorch 1.10 和 Python 3.7 实现。社交推荐模型和基线方法（包括 SocialGCN、Diffnet++、MHCN 和 NeuralSparse）使用 Tensorflow 1.14 和 Python 3.7 实现。

B.4 资源

我们提出的 GDMSR 代码包含在补充材料中。Diffnet++[1]、MHCN[2] 和 NeuralSparse[3] 均基于开源代码实现。需要指出的是，NeuralSparse 并非官方实现。Social-GCN 基于 Diffnet++实现。我们移除了注意力模块，并根据原论文 [52]进行了相应修改。

B.5 实现细节。

在所有实验中，嵌入维度和批次大小分别设为 8 和 1024，且均使用 Adam优化器。所有社交推荐模型均采用 BPR损失。学习率和 dropout 等超参数通过网格搜索确定。搜索范围如下：学习率为 {0.005, 0001, 0.0005, 0.0001}，dropout 为 $[0, 1]$, , GDMSR 中协同优化的权重（α）为 {0.1, 0.3, 0.5, 0.7, 0.9}。对于自适应去噪策略，阈值（

ϵ 5, γ R 0 5, 1 0, ）2 0 0 01, 0 015, 0 02, 0 025, 0 03

的搜索范围设为，分别为 { . . . } 和 { . . . . . }。对于 NeuralSparse，每个节点采样的邻居数量从 {30, 50, 100} 中搜索。对于 GDMSR 的所有实验，我们训练去噪模型 200 个训练轮次，此时 L^{BCE} 基本趋于稳定。对于所有数据集，每个用户的交互历史均经过预处理，调整为固定长度：较短的序列进行填充 L，超出部分则截断。截断时依据数据集中物品流行度按降序进行。

B.6 去噪训练的损失曲线

在去噪训练中，对于所有数据集，我们训练 200 轮，以使 L^{BCE} 保持稳定，损失曲线如图6所示。我们可以观察到，经过 200 轮训练后，损失函数基本趋于稳定，这表明去噪训练已完成。

B.7 实验详情

在实验中，我们分别通过为 GDMSR 和基线方法设置不同的超参数，控制最终移除的社交关系数量。具体而言，对于 GDMSR，我们控制 ϵ、 γ 和 R。对于基于规则的方法，我们控制每位用户移除好友的比例。对于 NeuralSparse，我们控制超参数 K，即每个节点可接收消息的邻居数量上限。对于 ESRF，我们也控制每个节点使用的邻居数量；在源代码中，该值设为 100，且未提供可供调整的超参数。我们直接修改了源代码。

[1] https://github.com/PeiJieSun/diffnet/tree/master/Diffnet%2B%2B [2] https://github.com/Coder-Yu/RecQ [3] https://github.com/flyingdoog/PTDNet/tree/main/NeuralSparse

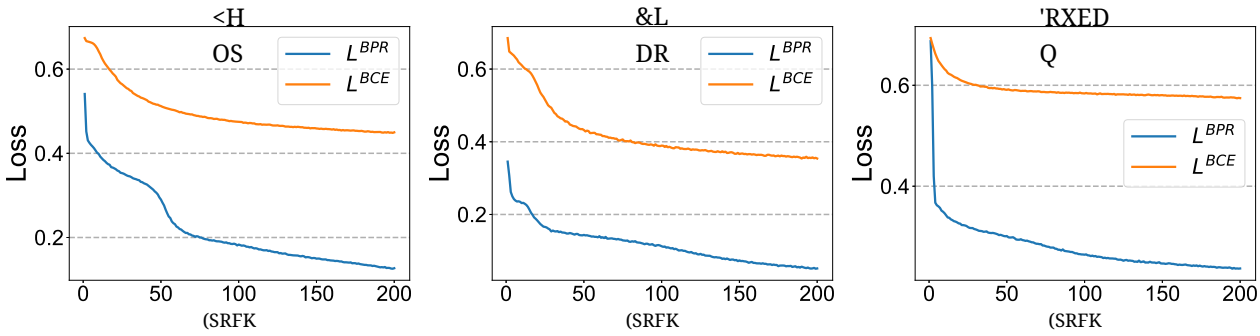

图6：去噪训练的损失曲线

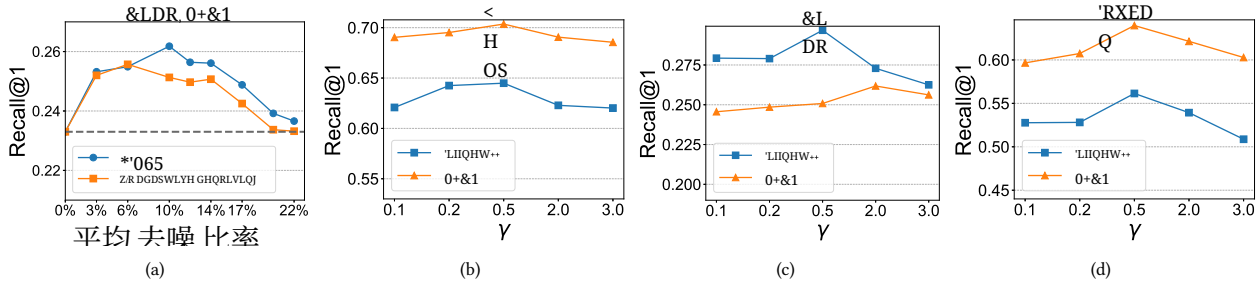

图7：(a)不同去噪策略的性能比较。(b)自适应去噪在不同 γ 下的性能比较

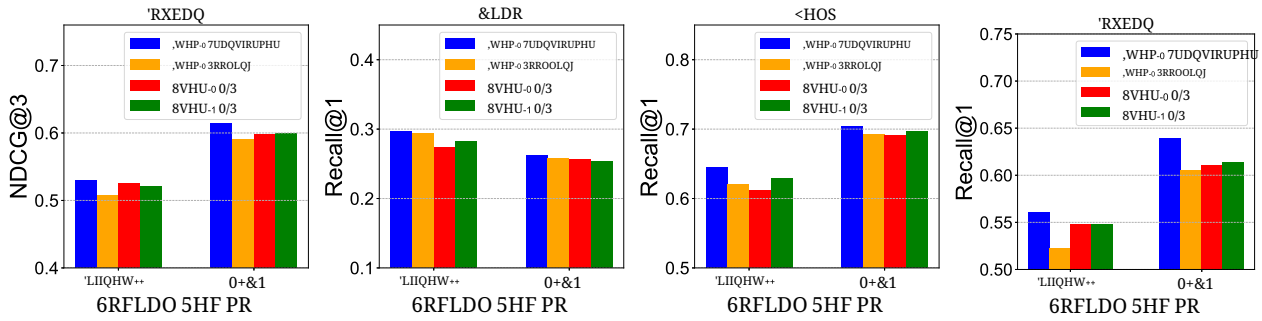

图8：不同关系置信度建模结构的性能比较。

B.8 Yelp上的去噪鲁棒性

为了验证自适应去噪策略的鲁棒性，我们将该策略与为所有用户分配相同去噪率的方法进行了比较，并研究了不同 γ 对.....的影响性能。结果如图7(b)-(d)所示。当 $\gamma = 0.5$时，总体性能最佳。这意味着，除了好友数量极少的用户外，大多数用户都被赋予了更高的去噪率，从而获得更好的性能。