用于推荐的异构图对比学习

Mengru Chen 华南理工大学 中国广州 cmr777qyx@gmail.com

Chao Huang*香港大学 中国香港 chaohuang75 @gmail.com

Lianghao Xia 香港大学 中国香港 aka_ xia@foxmail.com

Wei Wei 香港大学 中国香港 w eiweics@connect.hku.hk

Yong Xu 华南理工大学 中国广州 yxu@scut.edu.cn

Ronghua Luo 华南理工大学 中国广州 rhluo@scut.edu.cn

arXiv:2303.00995v1 [cs.IR] 2 Mar 2023

摘要

图神经网络（GNNs）已成为推荐系统中对图结构数据进行建模的强大工具。然而，现实中的推荐场景通常涉及异构关系（例如，社交感知的用户影响、知识感知的物品依赖关系），其中包含丰富的信息，可用于增强用户偏好学习。本文研究推荐中的异构图增强关系学习问题。近年来，对比式自监督学习已成功应用于推荐。鉴于此，我们提出一种异构图对比学习（HGCL）方法，通过对比学习增强的知识迁移，在不同视图间将异构关系语义融入用户-物品交互建模。然而，异构侧信息对交互的影响可能因用户和物品而异。为进一步推进这一思路，我们在异构图对比学习中引入元网络，以实现具有自适应对比增强的个性化知识变换器。在三个真实世界数据集上的实验结果表明，HGCL 优于最先进的推荐方法。通过消融实验，我们验证了 HGCL 方法中的关键组件有助于提升推荐性能。该模型实现的源代码可通过以下链接获取：https://github.com/HKUDS/HGCL。

CCS概念

• **信息系统** →**推荐系统**。

关键词

推荐、自监督学习、对比学习、图神经网络、异构图表示

*Chao Huang 是通讯作者。

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，前提是这些副本不得用于或分发以获取利润或商业利益，并且副本须包含本声明和首页上的完整引文。对于本作品中非 ACM 所有的组件，必须尊重其版权。注明出处后允许摘录。若需以其他方式复制、重新发布、发布到服务器或分发给列表，则必须事先获得具体许可和/或支付费用。请通过 permissions@acm.org 申请许可。*WSDM '23，2023*年*2*月*27*日至*3*月*3*日，新加坡，新加坡© 2023 计算机协会。ACM ISBN 978-1-4503-9407-9/23/02...$ 15.00 https://doi.org/10.1145/3539597.3570484

ACM 参考格式：

MengruChen、Chao Huang、Lianghao Xia、WeiWei、Yong Xu 和 Ronghua Luo。2023。用于推荐的异构图对比学习。发表于第十六届*ACM*国际网络搜索与数据挖掘会议（*WSDM'23*），*2023*年*2*月*27*日至*3*月*3*日，新加坡，新加坡。ACM，华盛顿哥伦比亚特区，9页。https://doi.org/10.1145/3539597. 3570484

1 引言

近年来，图神经网络（GNNs）已成功应用于对推荐系统中用户与物品之间关系的编码 [31]。图神经网络的核心思想是通过在图传播层中聚合邻居的特征信息，学习节点（用户或物品）的表示。然而，许多基于图神经网络的协同过滤（CF）模型仅关注生成的用户—物品连接图中的同质交互关系 [4, 23, 29]。在现实世界的推荐系统中，异构关系信息无处不在，例如用户之间的社交网络连接，以及具有语义相关性的知识感知物品依赖关系。本文旨在解决如何将异构侧信息融入协同过滤，以提升推荐系统性能这一挑战。

受图神经网络在各种推荐任务中成功应用的启发，研究人员尝试设计异质图神经网络，将异构关系的丰富语义嵌入潜在表示中。然而，现有大多数研究的表示能力往往受到训练标签稀疏这一局限的制约。换言之，当前的异质图神经网络是依赖大量标签数据的学习模型，因此在交互标签稀疏的情况下，可能无法生成高质量的用户/物品嵌入，供推荐系统的模型优化使用 [15, 29]。

对比式自监督学习是一种新兴且前景广阔的表示技术，它利用未标注数据本身进行数据增强，以解决数据稀疏性问题。通过将对比学习与图神经网络相结合，图对比学习（GCL）已成为一种有效的方法，可在缺乏足够观测标签的情况下，增强图结构上学习得到的表示的鲁棒性 [38] 。GCL 的基本思想是研究由两个图对比表示视图编码得到的嵌入之间的对齐关系。在基于 GCL 的自监督学习中，正对比样本的表示之间的一致性将得到最大化，而嵌入之间的距离则

会将负样本对推远。受此启发，我们将 GCL 的优势引入异构关系学习，以提升推荐性能。

然而，要有效实现异构关系学习并非易事，因为侧信息与用户-物品交互建模之间的依赖关系通常并非同构，而是在本质上具有多样性。例如，由于用户具有个性化特征和多样的用户特定交互模式，用户之间的社会影响可能各不相同。在不考虑用户个体特征的情况下，盲目增强用户的偏好学习，很容易导致次优的表示。在本文中，我们通过学习一个对比增强器，研究用于推荐的异构图学习问题。从本质上讲，我们需要解决所设计推荐系统中的以下挑战：i）如何有效地跨不同视图传递侧知识；ii）如何通过个性化增强执行异构关系对比学习。

为应对上述挑战，我们提出了一个原理性框架，称为异构图对比学习（HGCL）。具体而言，我们首先利用异质图神经网络作为编码器，在编码后的嵌入中保留异构关系的丰富语义。为实现个性化增强，我们提出了一种定制的对比学习框架，通过设计元网络对用户和物品的个性化特征进行编码。该框架使我们能够执行用户特定和物品特定的增强，从而跨不同关系视图传递信息信号。

我们的工作贡献可总结如下：

• HGCL 通过异构图对比学习推进了推荐系统的发展，并提供了一个通用且普适的框架，可在图对比学习范式下将异构侧信息融入推荐系统。

• HGCL 将元网络与对比学习相结合，通过自适应增强实现面向特定用户和特定项目的知识迁移，从而解决了我们的问题。它通过定制化的跨视图增强推进了图对比学习。

• 我们在真实世界的推荐数据集上进行了大量实验，验证了我们的 HGCL 框架能够显著提升性能，优于其他强大的基线方法。

2 相关工作

2.1 基于图神经网络的推荐系统

总体而言，图神经网络（GNNs）遵循在不同图层之间进行消息传递的理念，由信息传播和聚合组成。在图神经网络架构下，已有许多基于图神经网络的推荐系统被提出，用于捕捉推荐中的各种图结构关系。例如，在 NGCF [23],LR-GCCF [4]和 SHT [33]中，采用图神经网络对用户-物品交互图进行建模，并通过跨层信息传播生成潜在表示。为增强用户之间受社会影响的协同关系学习，一些现有研究也基于图神经网络构建社会关系编码器，例如 GraphRec [6], KCGN [12] 和 MHCN [39]。此外，图神经网络已成为对物品序列中的序列模式进行编码的有效方案，适用于时间感知推荐包括 SURGE [1] 和 MA-GNN [16]。近年来，使用图神经网络建模多种图连接（例如，MBGCN [13]和 MGNN [41]）已受到广泛关注，可用于处理用户行为多样、情境更复杂的推荐场景。在这些基于图神经网络的多行为推荐系统中，行为感知消息传递被认为能够反映多行为数据中的多样化用户偏好。此外，还有一些基于图神经网络构建的多媒体推荐系统（例如，GRCN [28],DualGNN [21]），能够将多模态信息融入推荐。

2.2 推荐中的对比学习

近年来，对比式自监督学习受到了研究者的关注，因为生成的自监督信号可以用于丰富用户表示学习。在推荐系统中，对比学习是一种强大的工具，可通过对齐对比表示视图，将自监督信号融入数据增强。例如，许多研究旨在通过提出各种图增强方案来进行嵌入对比，以解决推荐系统中的数据稀疏问题，例如 SGL [29], 、HCCF [32] 和 NCL [14]。具体而言，SGL [29] 采用随机节点/边丢弃操作来生成图对比学习视图。HCCF [32], 则基于参数化超图结构，设计了局部-全局对比学习来进行自监督增强。在这些对比图协同过滤模型中，基于 InfoNCE 的对比学习能够提升嵌入均匀性。此外，还有一些研究将对比学习用于推荐系统中的知识图谱表示，例如 KGCL [37] 和 KGIC [43]。此外，对比学习还被应用于各种推荐场景，包括序列推荐 [26], 、多行为推荐 [27], 和多兴趣推荐 [40]。在本研究中，我们提出了一种新颖的异构图对比学习范式，以弥补推荐系统中的研究空白，即通过对比学习捕捉推荐中的异构关系。

2.3 异构图学习

异构图广泛存在于现实应用中，包含多种类型的节点和连接。异构图上的表示学习旨在编码节点嵌入，以充分保留关系异质性所蕴含的丰富语义 [35]。为实现这一目标，异构图神经网络已成为能够提供最先进表示结果的有前景技术。例如，HAN [24] 基于元路径构建，增强了图注意力网络处理异构类型节点和关系的能力。受Transformer框架启发，HGT [11]设计了一种图Transformer网络，通过自注意力计算节点间的传播权重，从而实现异构消息传递。此外，MAGNN [7] 同时考虑了元路径内和元路径间的聚合，以融合异构图中不同元路径的信息。在HGIB [36],中，信息瓶颈被扩展到异构图学习，并通过同构图之间的自监督进行学习。沿着这一

研究方向，本文探讨了异构图对比学习推荐这一重要但尚未得到研究的任务。

3 方法

本节详细介绍我们提出的 HGCL 框架的模型设计，该框架通过跨视图对比学习增强异构图上的推荐表示学习。HGCL 的整体框架如图 1 所示。

3.1 预备知识

现实中的推荐系统通常具有异质关系，以包含来自用户和物品的多样语义信息。我们使用图 $G_{ui} = \{V_u, V_i, E_{ui}\}$ 表示用户-物品交互数据，其中 V_u 和 V_i 分别表示用户集和物品集。在图 G_{ui} 中，若用户 u 选择了物品 i，则 u 与 i 之间存在一条边（$(u, i) \in E_{ui}$）。为表示用户之间的社交关系，我们定义图 $G_{uu} = \{V_u, E_{uu}\}$，其中包含用户之间的社交连接，边集为 E_{uu}。为纳入物品之间的关系，我们定义物品图 $G_{ii} = \{V_i, E_{ii}\}$，利用外部知识（例如物品类别）连接相关物品。对于这些定义的图，我们定义三个邻接矩阵 $A_{ui} \in \mathbb{R}^{m \times n}$、$A_{uu} \in \mathbb{R}^{m \times m}$ 和 $A_{ii} \in \mathbb{R}^{n \times n}$，分别对应图 G_{ui}、G_{uu} 和 G_{ii}。其中，m 和 n 分别表示用户数和物品数。本研究的目标是根据具有关系异质性的图，预测用户与物品之间未观测到的交互。

3.2 异质图关系学习

3.2.1 **关系感知嵌入初始化**。为了在建模高阶连接的同时编码异质协同关系，我们采用异质图神经网络，从用户-物品图 G_{ui}、用户-用户图 G_{uu} 和物品-物品图 G_{ii} 中学习嵌入。首先，我们分配与 ID 对应的嵌入 $\mathbf{e}_u, \mathbf{e}_i \in \mathbb{R}^d$，并使用 Xavier 初始化器 [8], 对其进行初始化，其中 d 表示隐藏维度。特定于节点的嵌入构成初始嵌入矩阵 $\mathbf{E}_u^0 \in \mathbb{R}^{m \times d}$ 和 $\mathbf{E}_i^0 \in \mathbb{R}^{n \times d}$。这些初始嵌入被输入到分别用于用户-物品域、用户-用户域和物品-物品域的不同图编码器中。为了突出这三种关系类型在交互模式上的差异，我们训练了一个自门控模块 [39]，从共同的初始嵌入空间中导出用户级社交连接和物品级语义关系的关系感知嵌入，如下所示：

$$\mathbf{E}_{uu}^0 = \mathbf{E}_u^0 \odot \sigma(\mathbf{E}_u^0 \mathbf{W}_g + \mathbf{b}_g); \quad \mathbf{E}_{ii}^0 = \mathbf{E}_i^0 \odot \sigma(\mathbf{E}_i^0 \mathbf{W}_g + \mathbf{b}_g) \tag{1}$$

其中，$\mathbf{E}_{uu}^0 \in \mathbb{R}^{m \times d}$ 和 $\mathbf{E}_{ii}^0 \in \mathbb{R}^{n \times d}$ 分别表示用于用户关系和物品关系的同构图 G_{uu} 和 G_{ii} 的嵌入。$\sigma(\cdot)$ 表示 Sigmoid 激活函数。$\odot$ 表示逐元素乘法操作。$\mathbf{W}_g \in \mathbb{R}^{d \times d}$ 和 $\mathbf{b}_g \in \mathbb{R}^{d \times 1}$ 分别表示变换和偏置参数。通过采用乘法跳跃连接的自门控机制，嵌入 $\mathbf{E}_{uu}^0, \mathbf{E}_{ii}^0$ 不仅与用户-物品交互的初始嵌入 $\mathbf{E}_u^0, \mathbf{E}_i^0$ 共享共同的语义，还能灵活地表征用户-用户和物品-物品关系。

3.2.2 **异质消息传播**。在上述初始嵌入矩阵中，$\mathbf{E}_u^0, \mathbf{E}_i^0$ 用作用户-物品视图的输入，$\mathbf{E}_{uu}^0$ 和 $\mathbf{E}_{ii}^0$ 分别用作用户-用户视图和物品-物品视图的输入。我们首先采用图卷积神经网络作为图结构三个视图的编码器。在不失一般性的前提下，我们以用户-物品关系图为例说明其建模过程。具体而言，给定用户-物品交互图 G_{ui}，HGCL通过以下消息传播迭代优化用户和物品嵌入：

$$\mathbf{e}_u^{l+1} = \sum_{i \in \mathcal{N}_u} \frac{1}{\sqrt{|\mathcal{N}_u|}\sqrt{|\mathcal{N}_i|}} \mathbf{e}_i^l; \quad \mathbf{e}_i^{l+1} = \sum_{u \in \mathcal{N}_i} \frac{1}{\sqrt{|\mathcal{N}_i|}\sqrt{|\mathcal{N}_u|}} \mathbf{e}_u^l \tag{2}$$

其中，$\mathcal{N}_u$ 和 $\mathcal{N}_i$ 分别表示目标节点 u 和 i 的邻居集合。$\mathbf{e}_u^l$，$\mathbf{e}_i^l \in \mathbb{R}^d$ 分别表示第 l 次迭代中用户 u 和物品 i 的嵌入向量。$\mathbf{e}_u^0$，$\mathbf{e}_i^0$ 分别是嵌入矩阵 $\mathbf{E}_u^0$，$\mathbf{E}_i^0$ 的行向量。受轻量级图卷积网络在协同过滤推荐中的有效性和高效性启发，我们的关系感知消息传递范式不包含变换和非线性激活。类似地，用户-用户图的嵌入 $\mathbf{E}_{uu}^l$ 和物品-物品图的嵌入 $\mathbf{E}_{ii}^l$ 遵循相同的图卷积网络模式进行迭代优化。

3.2.3 **异质信息聚合**。受 [11], 中软元路径设计的启发，每次迭代都会聚合来自异构关系的信息。经过多轮异质消息传播，高阶嵌入通过多跳连接保留异质语义。具体而言，用户和物品的嵌入通过以下定义的异质融合过程进行更新：

$$\widehat{\mathbf{E}}_u^{l+1} = f(\mathbf{E}_u^{l+1}, \mathbf{E}_{uu}^{l+1}); \quad \widehat{\mathbf{E}}_i^{l+1} = f(\mathbf{E}_i^{l+1}, \mathbf{E}_{ii}^{l+1}) \tag{3}$$

其中，$l+1$ 次迭代 $\widehat{\mathbf{E}}_u^{l+1} \in \mathbb{R}^{m \times d}, \widehat{\mathbf{E}}_i^{l+1} \in \mathbb{R}^{n \times d}$ 中的精炼嵌入融合了异质语义，并作为下一层的输入。f 表示异质信息融合函数。这里，为降低模型复杂度，我们使用逐元素平均池化作为融合函数 $f(\cdot)$。

为进一步聚合编码后的层特定表示（$1 \le l \le L$）中的异质信息，我们按如下方式生成用户和物品的整体嵌入：

$$\mathbf{E}_u = \mathbf{E}_u^0 + \sum_{l=1}^{L} \frac{\mathbf{E}_u^l}{||\mathbf{E}_u^l||}; \quad \mathbf{E}_i = \mathbf{E}_i^0 + \sum_{l=1}^{L} \frac{\mathbf{E}_i^l}{||\mathbf{E}_i^l||} \tag{4}$$

其中，L 表示图卷积网络迭代的最大次数。每个图卷积网络层的输出均经过归一化。我们通过跳跃连接添加初始嵌入 $\mathbf{E}_u^0$，$\mathbf{E}_i^0$。上述公式展示了用户-物品交互视图的层特定表示聚合。用户-用户社交视图（即 $\mathbf{E}_{uu}$）和物品-物品依赖视图（即 $\mathbf{E}_{ii}$）的嵌入则以类似方式通过多阶信息聚合获得。

3.3 跨视图元网络

我们的 HGCL 旨在通过融入来自用户社交连接和物品外部依赖的异构关系知识，增强协同过滤。然而，在现实的用户建模场景中，用户和物品侧

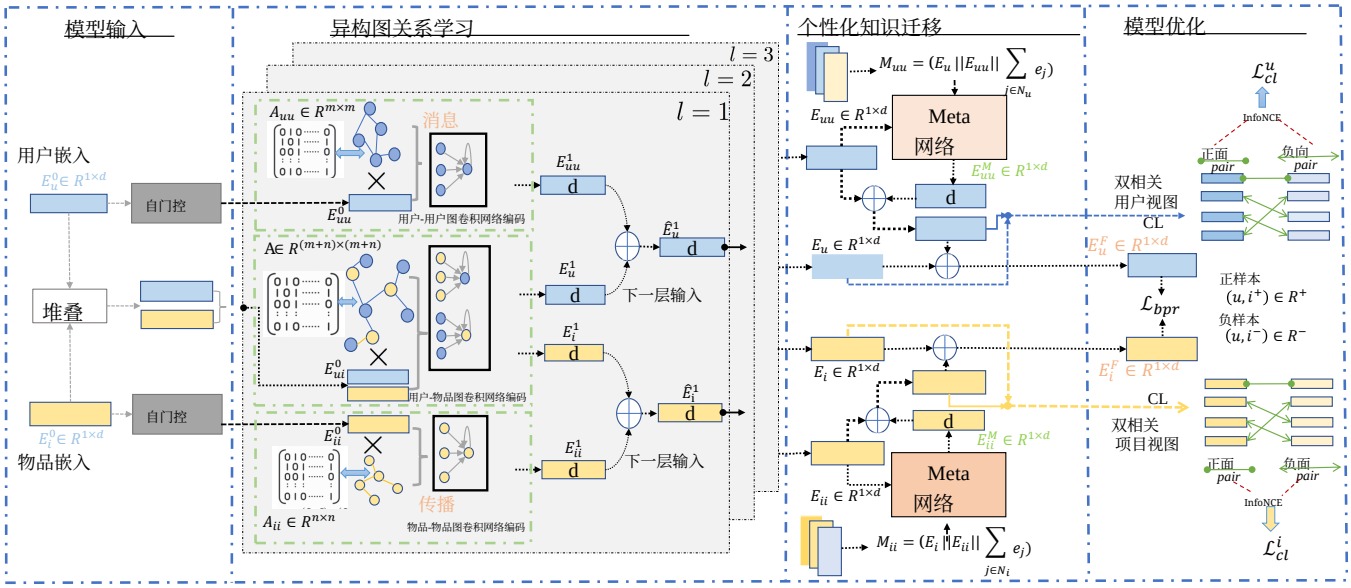

图 1：所提出的 HGCL框架的模型流程。HGCL 包含三个关键组件：(1) 通过异质图神经网络，在用户-用户图、用户-物品图和物品-物品图上提取并融合异构图表示。(2) 用于建模辅助视图与交互视图之间个性化跨视图依赖关系的元网络。(3) 通过异构关系视图之间的自适应对比学习进行联合参数优化。

信息对用户-物品交互模式的影响可能因用户而异。例如，有些用户更容易受到社交好友推荐的影响，而另一些用户则常根据自身偏好选择物品。因此，有必要从侧信息中进行个性化知识迁移，以指导用户特定偏好的学习。为此，我们设计了一种跨视图元网络，以便从用户侧和物品侧进行定制化知识蒸馏。

3.3.1 **元知识提取**。为了针对每个用户和每个物品，生成从辅助视图（用户和物品侧信息）到用户-物品交互编码的个性化映射，我们首先提取元知识，以保留用户和物品在辅助视图和交互视图中的重要特征*w.r.t*。具体而言，用户-用户关系视图和物品-物品关系视图的蒸馏元知识如下所示：

$$\mathbf{M}_{uu} = \mathbf{E}_u || \mathbf{E}_{uu} || \sum_{i \in \mathcal{N}_u} \mathbf{e}_i; \quad \mathbf{M}_{ii} = \mathbf{E}_i || \mathbf{E}_{ii} || \sum_{u \in \mathcal{N}_i} \mathbf{e}_u \tag{5}$$

其中，$\mathbf{M}_{uu} \in \mathbb{R}^{m \times 3d}$,$\mathbf{M}_{ii} \in \mathbb{R}^{n \times 3d}$ 分别表示元知识，用于编码上下文信息，从而为用户侧知识和物品侧知识生成个性化知识迁移函数。受 [34], 启发，元知识包含源域（*i.e.* 用户-用户视图和物品-物品关系视图）的节点表示$\mathbf{E}_{uu}$,$\mathbf{E}_{ii}$，以及目标用户-物品交互视图$\mathbf{E}_u$, $\mathbf{E}_i$的嵌入。此外，我们将邻域信息纳入元知识中。具体而言，辅助域的嵌入刻画了用户的社会影响和物品语义关联性。

用户-物品视图的嵌入捕获了用户与物品相关的交互模式。额外的邻域信息显式增强了对直接图连接的建模。通过综合考虑这三个维度的信息，元知识能够充分反映个性化跨视图知识迁移所需的重要上下文信号。

3.3.2 **个性化跨视图知识迁移**。在我们的 HGCL 中，提取的元知识用于生成一个带有定制变换矩阵的参数化知识迁移网络。所提出的元神经网络是

$$\begin{cases} f^1_{mlp}(\mathbf{M}_{uu}) \rightarrow \mathbf{W}^{M1}_{uu} \\ f^2_{mlp}(\mathbf{M}_{uu}) \rightarrow \mathbf{W}^{M2}_{uu} \end{cases} \tag{6}$$

其中，f^1_{mlp}, f^1_{mlp}是由两个全连接层和 PReLU激活函数组成的元知识学习器。这些函数以元知识$\mathbf{M}_{uu}$作为输入，并输出定制的变换矩阵$\mathbf{W}^{M1}_{uu} \in \mathbb{R}^{m \times d \times k}$, $\mathbf{W}^{M2}_{uu} \in \mathbb{R}^{m \times k \times d}$。这两个参数张量都包含 m 个矩阵，分别对应每个 m 用户。这些定制变换根据相应用户和物品的独特特征生成，以实现个性化知识迁移。这两组矩阵将变换的秩限制为 $k < d$，这不仅减少了元知识学习器的可训练参数数量，还增强了模型稳定性。受 [42], 中的个性化桥接函数启发，我们利用生成的参数矩阵和非线性映射函数构建定制的

迁移网络如下：

$$\mathbf{E}_{uu}^{M} = \sigma(\mathbf{W}_{uu}^{M1}\mathbf{W}_{uu}^{M2}\mathbf{E}_{uu}) \tag{7}$$

其中，$\sigma(\cdot)$表示参数化修正线性单元激活函数。$\mathbf{E}_{uu}^{M} \in \mathbb{R}^{m\times d}$包含通过定制映射函数转换得到的用户-用户社交视图嵌入。随后，利用这些定制嵌入增强从用户-物品交互中编码得到的用户嵌入。用户嵌入的融合过程通过以下加权求和实现：

$$\mathbf{E}_{u}^{F} = \alpha_u * \mathbf{E}_u + (1-\alpha_u) * (\mathbf{E}_{uu} + \mathbf{E}_{uu}^{M}); \tag{8}$$

其中，$\alpha_u \in \mathbb{R}$ 表示一个超参数，用于控制用户-物品交互视图嵌入与用户-用户社交视图嵌入之间的权重。此处也使用用户-用户关系视图的原始嵌入，以便更好地优化。$\mathbf{E}_{u}^{F} \in \mathbb{R}^{m\times d}$表示用于推荐主任务的最终嵌入。上述过程详细说明了跨视图用户嵌入定制的计算方法。跨视图物品嵌入$\mathbf{E}_{ii}^{M}$，$\mathbf{E}_{i}^{F}$也可以通过类似方式生成。

3.4 用于增强的异构关系对比学习

3.4.1 **跨视图对比学习**。为进一步通过更多监督信号增强HGCL 框架的表示学习，从而缓解数据稀疏性问题，我们设计了跨视图对比学习范式，通过自增强提升异构关系学习的鲁棒性。具体而言，将两个辅助视图（即 $\mathbf{E}_{uu}^{M}$和 $\mathbf{E}_{ii}^{M}$）的嵌入与用户-物品交互视图（即 $\mathbf{E}_u$ 和 $\mathbf{E}_i$）的嵌入对齐。通过这一设计，辅助视图的嵌入可作为有效的正则化项，利用自监督信号影响用户-物品交互建模。

为通过个性化的跨视图知识迁移捕捉多样化的用户偏好，我们在推荐系统中将个性化的跨视图知识迁移与对比学习相结合。具体而言，我们以自适应的方式在不同表示视图之间进行跨视图嵌入对齐。辅助视图特定的嵌入 $\mathbf{E}_{uu}$，$\mathbf{E}_{ii}$经过元网络生成的个性化映射函数处理后，得到个性化辅助嵌入 $\mathbf{E}_{uu}^{M}$，$\mathbf{E}_{ii}^{M}$。元网络经过训练，可过滤辅助视图中的噪声特征，使其与用户-物品交互视图相匹配。

3.4.2 **基于 InfoNCE 的对比损失**。借助异构图关系学习和跨视图元网络，我们为用户和物品分别获得了两组嵌入，*i.e.* $\mathbf{E}_{uu}^{M}$，$\mathbf{E}_u$表示用户的嵌入，$\mathbf{E}_{ii}^{M}$,$\mathbf{E}_i$表示物品的嵌入。这些嵌入通过编码用户-物品交互数据以及用户/物品侧的辅助知识获得。受近期对比式自监督学习在推荐领域取得成功的启发 [29, 32], ，我们提出在两个表示视图之间引入基于 InfoNCE 的对比学习损失，以增强 HGCL 方法中的用户/物品表示学习，具体如下：

$$\mathcal{L}_{cl}^{u} = \sum_{u\in\mathcal{V}_u} -\log \frac{\exp\left(s(\mathbf{e}_{uu}^{M}+\mathbf{e}_{uu},\mathbf{e}_u)/\tau\right)}{\sum_{u'\in\mathcal{V}_u}\exp\left(s(\mathbf{e}_{uu}^{M}+\mathbf{e}_{uu},\mathbf{e}'_u)/\tau\right)} \tag{9}$$

其中，$\mathbf{e}_{uu}^{M} \in \mathbb{R}^{d}$、$\mathbf{e}_u \in \mathbb{R}^{d}$分别是矩阵$\mathbf{E}_{uu}^{M}$和$\mathbf{E}_u$中的嵌入向量。$s(\cdot)$表示相似度函数，可以是内积或余弦相似度。这里我们使用余弦相似度作为 $s(\cdot)$。 τ表示温度系数，能够自动识别困难负样本。 u' 表示索引不同的负样本。类似地，我们可以得到物品方面的 InfoNCE 损失 L_{cl}^{i}。最终，总对比损失为 $\mathrm{L}_{cl} = \alpha_1 * \mathrm{L}_{cl}^{u} + \alpha_2 * \mathrm{L}_{cl}^{i}$，其中$\alpha_1$ 和 α_2 表示用于权重调整的两个超参数。

3.5 HGCL 的优化目标

利用融合后的嵌入 $\mathbf{E}_{u}^{F}$，$\mathbf{E}_{i}^{F}$，我们的 HGCL 通过点积预测用户 u 与物品 i 发生交互的可能性：$\hat{}y_{u,\ i} = \mathbf{e}_{u}^{F\top}\mathbf{e}_{i}^{F}$，其中 $\mathbf{e}_{u}^{F}$ 和 $\mathbf{e}_{i}^{F}$ 分别表示融合嵌入矩阵中用户 u 和物品 i 的最终嵌入向量。$\hat{}y_{u,\ i} \in \mathbb{R}$ 表示用户 u 与物品 i 发生交互的可能性得分。$\hat{}y_{u,\ i}$ 越大，表示发生交互的概率越高。为了针对推荐任务优化 HGCL，我们遵循近期研究，采用贝叶斯个性化排序（BPR）[17] 成对损失函数。具体而言，每个训练样本由一个用户 u、该用户曾交互过的一个正样本物品 i^{+}，以及该用户未交互过的一个负样本物品 i^{-} 构成。对于每个训练样本，我们通过以下方式最大化预测得分：

$$\mathcal{L}_{bpr} = \sum_{(u,i^{+},i^{-})\in O} -\ln(\mathrm{sigmoid}(\hat{y}_{u,i^{+}} - \hat{y}_{u,i^{-}})) + \lambda||\Theta||^{2} \tag{10}$$

其中，$\ln(\cdot)$ 和 $\mathrm{sigmoid}(\cdot)$ 分别表示对数函数和 Sigmoid 函数。λ 表示一个用于确定正则化项权重的超参数。将 BPR 损失函数与增强的跨视图对比学习损失结合起来，总体训练损失如下所示：

$$\mathcal{L} = \mathcal{L}_{bpr} + \beta * \mathcal{L}_{cl} \tag{11}$$

3.6 模型复杂度分析

我们对 HGCL 模型的时间复杂度进行了详细分析，以衡量本方法的效率。HGCL 的异构 GNN 模块采用轻量级网络结构，其时间复杂度为 $\mathrm{O}((|\mathbb{E}_{ui}| + |\mathbb{E}_{uu}| + |\mathbb{E}_{ii}|) \times d\times \mathrm{L})$。在跨视图元网络中，计算开销最高的部分是用于生成个性化映射函数的元网络，其时间复杂度为 $\mathrm{O}((m+n) \times d^{2} \times k)$。在异构关系对比学习组件中，每个批次（批量大小为 d）需要 $\mathrm{O}(b\times(m+n)\times d)$ 的时间复杂度来计算异构关系视图之间的 InfoNCE 损失。总体而言，上述第一和第三个组件的复杂度与当前最先进的自监督 GNN 推荐方法（*e.g.*，如 SGL [29]）相同。第二个模块的复杂度接近原始 GNN 的复杂度，因为 k 通常较小。

4 评估

本节中，我们对模型进行评估，以考察 HGCL 和基线方法的有效性。我们还分析了关键模块的影响及模型鲁棒性。我们的实验旨在回答以下研究问题：

表1：不同数据集上所有方法在归一化折损累计增益**和**命中率**方面的性能比较**。**

数据	指标	SAMN	DGRec	ETANN	NGCF	KGAT	MKR	GraphRec	DANSER	HERec	MCRec	HAN	HeCo	HGT	MHCN	SMIN	**HGCL**
Ciao	H@10	0.6576	0.6653	0.6738	0.6945	0.6601	0.6793	0.6825	0.6730	0.6800	0.6772	0.6589	0.6867	0.6939	0.7053	0.7108	**0.7376**
	N@10	0.4561	0.4953	0.4665	0.4894	0.4512	0.4589	0.4730	0.4521	0.4712	0.4708	0.4469	0.4867	0.4869	0.4928	0.5012	**0.5261**
Epinions	H@10	0.7592	0.7603	0.7650	0.7984	0.7510	0.7647	0.7723	0.7714	0.7642	0.7630	0.7505	0.7998	0.8150	0.8201	0.8179	**0.8367**
	N@10	0.5614	0.5668	0.5663	0.5945	0.5578	0.5669	0.5751	0.5741	0.5495	0.5326	0.5275	0.5910	0.6126	0.6158	0.6137	**0.6413**
Yelp	H@10	0.7910	0.7950	0.8031	0.8265	0.7881	0.8005	0.8098	0.8077	0.7928	0.7869	0.7731	0.8359	0.8364	0.8344	0.8478	**0.8712**
	N@10	0.5516	0.5593	0.5560	0.5854	0.5501	0.5635	0.5679	0.5692	0.5612	0.5590	0.5604	0.5847	0.5883	0.5799	0.5993	**0.6310**

表 2：实验数据集统计信息

数据集	用户 #	项目#	交互 #	稀疏性
Ciao	6776	101415	265308	99.9614%
Epinions	15210	233929	630391	99.9823%
Yelp	161305	114852	957923	99.9948%

• **RQ1**：与现有方法相比，HGCL 的表现如何?

• **RQ2**：在我们的 HGCL 中纳入关键组件是否有助于提升推荐性能?

• **RQ3**：在用户交互数据稀疏程度不同的环境中，HGCL 的表现如何?

• **RQ4**：关键超参数如何影响模型性能?

4.1 实验设置

4.1.1 **数据集**。 在我们的实验中，我们在来自在线平台的三个真实世界数据集上评估了 HGCL 框架。我们在表 2 中展示了数据统计信息，并介绍各数据集的详细情况。**Ciao 和 Epinions**。它们是两个基准推荐数据集，采集自在线评论系统，包含用户对不同物品的评分行为。这些异构关系由其中包含的用户和物品侧信息生成，例如用户信任关系和物品类别信息。**Yelp**。该数据集包含本地商家推荐场景中的异构关系（例如，用户社交关系、场所评分行为、商家属性），数据来自 Yelp 平台。

4.1.2 **基线方法**。 为评估我们所提出方法的有效性，我们将 HGCL 与多种系统进行比较，以全面评估性能。各基线方法的详情如下所述。

• **SAMN** [2]：该模型设计了基于注意力的记忆网络，以考虑用户之间社会影响的差异，从而改进用户-物品交互建模。

• **DGRec** [19]：该方法利用循环神经网络对用户的动态兴趣进行建模，并利用图注意力网络对社会影响进行建模，以用于推荐。

• **ETANN** [3]：该方法通过考虑用户-用户关系，设计了一种从社交领域迁移至用户-物品交互模式编码过程的自适应迁移方案。

• **NGCF** [23]：我们将用户之间的社交信息融入具有代表性的基于图神经网络的协同过滤模型中。其消息传递基于图卷积构建。

• **KGAT** [22]：在这个基线方法中，将基于项目知识的关系融入图注意力机制，以

增强推荐系统。

• **MKR** [20]：该方法利用知识图谱作为侧信息，通过多任务学习框架辅助推荐。不同任务通过交叉压缩单元关联。

• **GraphRec** [6]：该方法联合建模用户-用户社交图和用户-物品交互图，以反映推荐中的关系异质性。

• **DANSER** [30]：该推荐系统通过基于上下文的多臂老虎机估计用户特定的动态注意力权重，从两个方面学习社交影响。

• **HERec** [18]：该方法旨在基于元路径的随机游走，对推荐中的异质信息进行编码。

• **MCRec** [10]：该方法提出协同注意力机制，以捕捉推荐系统中的异构关系。

• **HAN** [24]：我们采用这一具有代表性的异质图神经网络，通过基于元路径的注意力编码器生成用户和物品表示。

• **HGT** [11]：该方法引入异质互注意力消息传递机制，沿着异质图结构中的多种关系细化用户/物品嵌入。

• **HeCo** [25]：这是一种自监督方法，它将对比学习与异质图神经网络相结合，以考量局部和高阶图结构。利用不同基于元路径的连接所编码的嵌入进行对比。

• **SMIN** [15]：这是一种自监督社交推荐系统，它将辅助图学习任务纳入主任务，以提升推荐性能。

• **MHCN** [39]：在该推荐系统中，设计了一种多通道超图卷积网络，基于模体考量用户之间的全局关系。

4.1.3 **超参数设置**。 我们的 HGCL 模型使用 PyTorch 实现。模型采用 Adam 进行参数学习优化。在模型实现中，批量大小和学习率分别从 {1024, 2048, 4096, 8192 2, 5 4 2, 4 5 2, 5 5 2, 6 2 } 和 { e- . e- e- . e- e- } 中搜索。嵌入维度在 {8, 16, 32, 64, 128} 范围内调整。图神经网络层数从 {1, 2, 3} 中选取。此外，对比损失的系数 β 从 {0.2, 0.25, 0.3, 0.35, 0.55, 0.6, 0.65} 中选取。元知识提取中低秩矩阵分解的维度从 {1, 2, 3, 4, 5} 中选取。

在我们的评估设置中，为每位用户采样一个正样本（交互过的）物品和 99 个负样本（未交互过的）物品，以进行性能评估。为了衡量推荐准确率

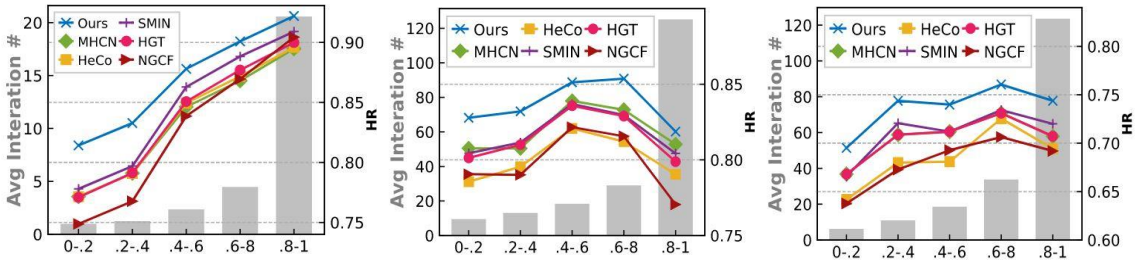

(a) Yelp HR@10 (b) Epinions HR@10 (c) Ciao HR@10

图 2：三个数据集在不同数据稀疏程度下的性能比较。

表 3：HGCL 关键组件的消融实验

Data	Ciao		Epinions		Yelp	
指标	HR	NDCG	HR	NDCG	HR	NDCG
不使用对比学习	0.7124	0.5015	0.8176	0.6166	0.8471	0.6030
不使用元信息	0.7215	0.5135	0.8247	0.6282	0.8585	0.6218
不使用物品-物品	0.7116	0.5055	0.8245	0.6317	0.8573	0.6188
不使用用户-用户	0.7149	0.5047	0.8285	0.6266	0.8533	0.6208
HGCL	**0.7376**	**0.5261**	**0.8367**	**0.6413**	**0.8712**	**0.6310**

，我们采用了两种广泛使用的指标：HR（命中率）和 NDCG（归一化折损累计增益）。

4.2 性能比较（RQ1）

表1报告了所有对比方法在不同数据集上进行物品推荐的性能。根据评估结果，我们总结出以下关键观察：

• 与当前最先进的方法相比，我们的HGCL始终实现了显著的性能提升。我们将这些改进归因于异构图对比学习的设计：（1）HGCL使推荐系统能够在异构关系之间进行有效的知识迁移，从而帮助建模用户偏好；（2）自适应对比学习能够利用异构关系视图之间的自监督信号，显著提升推荐性能。

• 基于异构图神经网络的方法（例如 HeCo、HGT、SMIN）通常比其他替代方法（例如 SAMN、KGAT、DANSER）表现更好，这证明了将来自用户侧和项目侧的社会影响与项目语义关联性等异构关系知识融入推荐系统的有效性。

• 如图所示，MHCN和SMIN表现出的优越性能表明，将用户-项目交互编码与自监督学习技术相结合是合理的。我们的HGCL与这些融入自监督学习的推荐器之间的性能差距验证了，自适应自监督信号蒸馏确实能够通过对比个性化知识迁移提升性能。

4.3 消融实验（RQ2）

我们通过消融实验验证，考虑定制化对比学习中的异构关系至关重要，并有助于提升性能，具体如下：

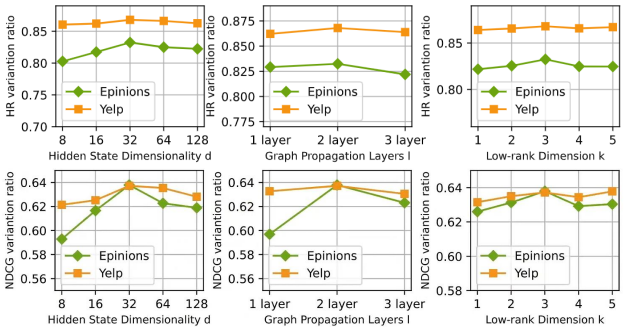

图 3：HGCL 的超参数研究。

• ***w/o-meta***：我们在 HGCL 中不引入元网络，以便在所开发的跨异构关系视图对比学习增强中实现个性化知识迁移。

• ***w/o-cl***：我们在模型中禁用对比学习，以捕捉辅助信息与用户-物品交互建模之间的跨视图依赖。

• ***w/o-ii***：在这一变体中，我们不纳入物品-物品图 G_{ii}，以捕捉物品之间的知识感知依赖，从而指导用户偏好的学习过程。

• ***w/o-uu***：在这一变体中，我们不纳入用户-用户图 G_{uu}，以考虑用户之间的社会影响，从而帮助编码用户-物品交互模式。

表 3 展示了 HGCL 框架及其对比变体的推荐性能。在所有情况下，HGCL 的性能均优于 w/o-cl，这体现了我们的异构图对比学习通过跨视图知识迁移进行有效增强的合理性。w/o-meta 在不同数据集上的表现均不如 HGCL。这一结果与我们的假设一致：用户/物品特定的定制化知识迁移有助于学习用户表示。HGCL 的表现始终优于 w/o-ii 和 w/o-uu，这表明有必要将异构侧信息纳入推荐系统，以指导用户偏好的编码。

4.4 不同数据稀疏性下的性能

在本节中，我们评估了用户交互数据的数据稀疏程度不同时，各种方法的性能。我们将用户划分为五个群体，以代表不同的

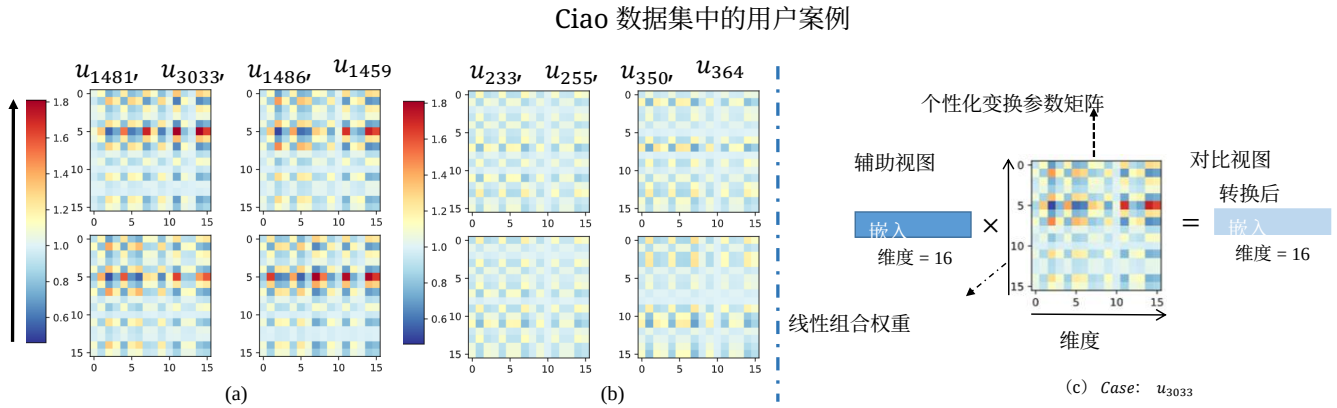

图 4：在 Ciao 数据集上进行案例研究，以可视化从不同用户中采样得到的已学习对比变换矩阵，反映多样化的社会影响。(a)：更容易受到其社会关系影响的四位用户；(b)：较少受到其社会关系影响的四位用户。(c)：由辅助视图生成的嵌入将经过变换，用于表征对比，从而为用户-物品交互建模提供自监督增强。

用户活跃度。图 2 展示了 HGCL 与几种基线方法的性能对比结果。各方法的推荐准确率以折线形式显示在纵轴右侧。纵轴左侧则通过柱状图表示每个用户群体的平均交互次数。显而易见，我们的方法在不同稀疏环境下都表现出优越的性能。HGCL 的性能提升可能源于对比学习增强的跨视图知识迁移，因为它能够有效捕捉用户特定的社会影响和物品特定的语义相关性。因此，通过所开展的实验可以看出，即使用户-物品交互较为稀疏，HGCL 仍能保持良好的性能。

4.5 超参数分析

我们进一步进行参数敏感性分析，以展示隐藏状态维度、图传播层数和低秩维度的影响。结果如图 3 所示。根据这些结果，我们得出以下结论。

• **隐藏状态维度**。隐藏状态维度 d 的取值范围为 8 到 128。我们可以观察到，当 $d = 32$时，模型性能先提升，随后趋于饱和。因此，适当增大嵌入维度可以提升推荐性能，但由于模型过拟合，并不总能带来性能增益。

• **图传播层数**。在图神经网络架构中，传播层数的搜索范围为 1 到 3。曲线表明，堆叠两层时模型的性能更好。这说明更多层能够捕获高阶邻居和语义信息。然而，更深的图神经网络架构可能导致模型过平滑，并为特征表示引入噪声。

• **低秩分解维度**。我们可以观察到，对低秩分解维度 k 的参数研究表明，当取值为 $k = 3$ 时，性能最佳。k 的值较小可能不足以学习复杂的变换信息。

4.6 定性评估

在评估中，我们在 Ciao 数据集上进行了案例研究，以可视化学习到的个性化对比变换矩阵（$\mathbb{R}^{16\times16}$），从而反映辅助视图（例如，社交关系）与用户-物品交互视图之间的不同影响。在图 4 中，我们抽取了四位用户：他们在选择物品时更容易（例如，u_{1481}、$u_{3}033$）或较不容易（例如，u_{233}、u_{255}）受到社交关系的影响。我们对不同用户对应的个性化对比变换矩阵进行了可视化，以捕捉社交视图与交互视图之间的多样化知识迁移。可以观察到，学习到的对比变换矩阵中的数值越大，该用户受到的社会影响越大。通过结合元网络与对比学习，可以根据用户的个性化特征实现自适应对比数据增强。

5 结论

本文研究了在考虑异构关系的情况下，用于推荐的图表示学习问题。为解决这一问题，我们提出了一种新颖的异构图对比学习模型（HGCL），以自适应的方式将侧信息中的知识迁移到用户-物品交互建模中。在HGCL中，我们提出识别具有信息量的异构关系，以增强协同过滤范式。在真实世界数据集上的实验验证了HGCL的性能大幅超越现有最先进方法。深入分析也验证了该模型在缓解数据稀疏性方面的鲁棒性。未来一个有趣的研究方向是，通过在推荐系统中融入异构关系，探索并分离真实兴趣与从众性，从而缓解用户噪声交互数据带来的流行度偏差。此外，未来也值得研究推荐系统中异构关系学习所面临的混杂效应。

参考文献

[1] Jianxin Chang、Chen Gao、Yu Zheng、Yiqun Hui、Yanan Niu、Yang Song、Depeng Jin 和 Yong Li。2021。基于图神经网络的序列推荐。发表于 *SIGIR*。378–387。[2] Chong Chen 、 Min Zhang 、 Yiqun Liu 和 Shaoping Ma。2019。社交注意力记忆网络：对推荐中的方面差异和好友级差异进行建模。发表于 *WSDM*。177–185。[3] Chong Chen、Min Zhang、Chenyang Wang、Weizhi Ma、Minming Li、Yiqun Liu 和 Shaoping Ma。2019。用于社交感知推荐的高效自适应迁移神经网络。发表于 *SIGIR*。225–234。[4] Lei Chen、Le Wu、Richang Hong、Kun Zhang 和 Meng Wang。2020。重新审视基于图的协同过滤：一种线性残差图卷积网络方法。发表于 *AAAI*，第34卷。27–34。[5] Yann N Dauphin、Angela Fan、Michael Auli 和 David Grangier。2017。基于门控卷积网络的语言建模。发表于 国际机器学习会议。PMLR，933–941。[6] 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。发表于 *WWW*。417–426。[7] Xinyu Fu、Jiani Zhang、Ziqiao Meng 和 Irwin King。2020。MAGNN：用于异构图嵌入的元路径聚合图神经网络。发表于 *WWW*。2331–2341。[8] Xavier Glorot 和 Yoshua Bengio。2010。理解深度前馈神经网络训练的困难。发表于 *AISTATS*。JMLR研讨会与会议论文集，249–256。[9] 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。发表于 *SIGIR*。639–648。[10] Binbin Hu、Chuan Shi、Wayne Xin Zhao 和 Philip S Yu。2018。利用基于元路径的上下文，通过神经协同注意力模型实现Top-N推荐。发表于 *KDD*。1531–1540。[11] Ziniu Hu、Yuxiao Dong、Kuansan Wang 等。2020。异构图Transformer。发表于 *WWW*。2704–2710。[12] Chao Huang、Huance Xu、Yong Xu、Peng Dai、Lianghao Xia、Mengyin Lu、Liefeng Bo、Hao Xing、Xiaoping Lai 和 Yanfang Ye。2021。用于社交推荐的知识感知耦合图神经网络。发表于 *AAAI*，第35卷。4115–4122。[13] Bowen Jin、Chen Gao、Xiangnan He、Depeng Jin 和 Yong Li。2020。基于图卷积网络的多行为推荐。发表于 *SIGIR*。659–668。[14] Zihan Lin、Changxin Tian、Yupeng Hou 和 Wayne Xin Zhao。2022。通过邻域增强对比学习改进图协同过滤。发表于 *WWW*。2320–2329。[15] Xiaoling Long、Chao Huang、Yong Xu、Huance Xu、Peng Dai、Lianghao Xia 和 Liefeng Bo。2021。基于自监督元图Informax网络的社交推荐。发表于 *CIKM*。1160–1169。[16] Chen Ma、Liheng Ma、Yingxue Zhang、Jianing Sun、Xue Liu 和 Mark Coates。2020。用于序列推荐的记忆增强图神经网络。发表于 *AAAI*，第34卷。5045–5052。[17] Steffen Rendle、Christoph Freudenthaler、Zeno Gantner 和 Lars Schmidt-Thieme。2012。BPR：基于隐式反馈的贝叶斯个性化排序。*arXiv*预印本 *arXiv:1205.2618*（2012）。[18] Chuan Shi、Binbin Hu、Wayne Xin Zhao 和 S Yu Philip。2018。用于推荐的异构信息网络嵌入。*TKDE* 31，2（2018），357–370。[19] Weiping Song、Zhiping Xiao、Yifan Wang、Laurent Charlin、Ming Zhang 和 Jian Tang。2019。通过动态图注意力网络实现基于会话的社交推荐。发表于 *WSDM*。555–563。[20] Hongwei Wang、Fuzheng Zhang、Miao Zhao、Wenjie Li、Xing Xie 和 Minyi Guo。2019。用于知识图谱增强推荐的多任务特征学习。发表于 *WWW*。2000–2010。[21] Qifan Wang、Yinwei Wei、Jianhua Yin、Jianlong Wu、Xuemeng Song 和 Liqiang Nie。2021。DualGNN：用于多媒体推荐的双图神经网络。Transactions on Multimedia（2021）。[22] Xiang Wang、Xiangnan He、Yixin Cao、Meng Liu 和 Tat-Seng Chua。2019。KGAT：用于推荐的知识图谱注意力网络。收录于 KDD。950–958。[23] Xiang Wang、Xiangnan He、Meng Wang、Fuli Feng 和 Tat-Seng Chua。2019。神经图协同过滤。收录于 SIGIR。[24] Xiao Wang、Houye Ji、Chuan Shi、Bai Wang、Yanfang Ye、Peng Cui 和 Philip S Yu。2019。异构图注意力网络。收录于 WWW。2022–2032。[25] Xiao Wang、Nian Liu、Hui Han 和 Chuan Shi。2021。基于协同对比学习的自监督异构图神经网络。收录于 KDD。1726–1736。[26] Ziyang Wang、Huoyu Liu、Wei Wei、Yue Hu、Xian-Ling Mao、Shaojian He、Rui Fang 和 Dangyang Chen。2022。用于序列推荐的多层次对比学习框架。收录于 CIKM。2098–2107。[27] Wei Wei、Chao Huang、Lianghao Xia、Yong Xu、Jiashu Zhao 和 Dawei Yin。2022。结合行为多样性的对比元学习推荐。收录于 WSDM。1120–1128。[28] Yinwei Wei、Xiang Wang、Liqiang Nie、Xiangnan He 和 Tat-Seng Chua。2020。结合隐式反馈的多媒体推荐图细化卷积网络。收录于 MM。3541–3549。[29] Jiancan Wu、Xiang Wang、Fuli Feng、Xiangnan He、Liang Chen、Jianxun Lian 和 Xing Xie。2021。用于推荐的自监督图学习。收录于 SIGIR。726–735。[30] 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会影响深层潜在表示的双图注意力网络。收录于 WWW。2091–2102。[31] Shiwen Wu、Fei Sun、Wentao Zhang、Xu Xie 和 Bin Cui。2022。推荐系统中的图神经网络：综述。Comput. Surveys 55, 5（2022），1–37。[32] Lianghao Xia、Chao Huang、Yong Xu、Jiashu Zhao、Dawei Yin 和 Jimmy Huang。2022。超图对比协同过滤。收录于 SIGIR。70–79。[33] Lianghao Xia、Chao Huang 和 Chuxu Zhang。2022。面向推荐系统的自监督超图Transformer。收录于 KDD。2100–2109。[34] Lianghao Xia、Yong Xu、Chao Huang、Peng Dai 和 Liefeng Bo。2021。用于多行为推荐的图元网络。收录于 SIGIR。757–766。[35] Carl Yang、Yuxin Xiao、Yu Zhang、Yizhou Sun 和 Jiawei Han。2020。异构网络表示学习：结合综述与基准的统一框架。Transactions on Knowledge and Data Engineering（2020）。[36] Liang Yang、Fan Wu、Zichen Zheng、Bingxin Niu、Junhua Gu、Chuan Wang、Xiaochun Cao 和 Yuanfang Guo。2021。异构图信息瓶颈。收录于 IJCAI。1638–1645。[37] Yuhao Yang、Chao Huang、Lianghao Xia 和 Chenliang Li。2022。用于推荐的知识图谱对比学习。收录于 SIGIR。[38] Yuning You、Tianlong Chen、Yongduo Sui、Ting Chen、Zhangyang Wang 和 Yang Shen。2020。结合增强的图对比学习。NeurIPS 33（2020），5812–5823。[39] 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。收录于 WWW。413–424。[40] Shengyu Zhang、Lingxiao Yang、Dong Yao、Yujie Lu、Fuli Feng、Zhou Zhao、Tat-seng Chua 和 Fei Wu。2022。Re4：学习重新对比、重新注意和重新构建，以实现多兴趣推荐。收录于 WWW。2216–2226。[41] Weifeng Zhang、Jingwen Mao、Yi Cao 和 Congfu Xu。2020。用于多行为推荐的多重图神经网络。收录于 CIKM。2313–2316。[42] Yongchun Zhu、Zhenwei Tang、Yudan Liu、Fuzhen Zhuang、Ruobing Xie、Xu Zhang、Leyu Lin 和 Qing He。2021。面向跨域推荐的用户偏好个性化迁移。arXiv 预印本 arXiv:2110.11154（2021）。[43] Ding Zou、Wei Wei、Ziyang Wang、Xian-Ling Mao、Feida Zhu、Rui Fang 和 Dangyang Chen。2022。通过多层次交互式对比学习改进知识感知推荐。收录于 CIKM。2817–2826。