解耦图社交推荐

Lianghao Xia[1, †], Yizhen Shao[2, †], Chao Huang[1, *], Yong Xu[2],Huance Xu[2],Jian Pei[3]
香港大学[1], 华南理工大学[2],杜克大学[3]aka xia@foxmail.com, chaohuang75@gmail.com, {csyzshao, cshuance.xu}@mail.scut.edu.cn yxu@scut.edu.cn, j.pei@duke.edu

arXiv:2303.07810v1 [cs.IR] 14 Mar 2023

摘要——**社交推荐系统因融合了用户间的社交信息，能够改善推荐结果，因此在许多在线网络服务中备受关注。尽管现有解决方案取得了显著进展，我们认为当前方法仍存在两方面不足：(1) 现有社交感知推荐模型仅考虑物品之间的协同相似性，而当前推荐范式对如何融入物品间语义相关性的探索较少。(2) 当前社交推荐系统忽视了异质关系（例如，社交连接、用户-物品交互）中潜在因子的纠缠。面对关系异质性，学习解耦表示给社交推荐带来了巨大挑战。在本研究中，我们设计了一种解耦图神经网络（DGNN），并将潜在记忆单元融入其中，使 DGNN 能够为不同类型的用户和物品连接维护因子化表示。此外，我们在图神经网络架构下设计了新颖的记忆增强消息传播与聚合方案，使模型能够以全自动的方式递归地将语义相关性提炼到用户和物品的表示中。在三个基准数据集上进行的大量实验验证了模型的有效性，其性能显著优于最先进的推荐技术。源代码已公开发布于：https://github.com/HKUDS/DGNN**。

I. 引言

推荐系统通过学习用户的个性化兴趣来推荐物品，已成为重要的网络服务（例如，电子商务网站 [23], 、在线评论系统 [29] 和广告平台 [27]），有助于缓解信息过载问题 [55]。为解决传统协同过滤模型的数据稀疏性问题，许多推荐范式利用用户之间的社交关系，通过外部信息源增强用户—物品交互建模。这些方法明确刻画了推荐中与用户交互偏好相关的跨用户影响 [20]。

受图神经网络（GNN）的广泛应用所启发，近期出现的社交推荐方法利用图神经编码器来突出社交连接的图结构建模，并迭代聚合局部邻域中的特征信息。例如，近期的一些研究（例如，DiffNet [50], MHCN [61]和 KCGN [19]）采用图卷积来捕捉社交感知的协同过滤信号，并指导用户表示学习。GraphRec [12] 和 DANSER [51] 基于图注意力机制开发，用于区分那些连接发生过交互的用户的关系。这类基于图神经网络的社交感知推荐系统通过对用户和物品之间的高阶连接进行建模，取得了最先进的性能。此外，另一种联合利用用户—用户和用户—物品关系结构的相关尝试，是将社交领域中的特征迁移到用户—物品交互编码过程中 [5], [53]。

尽管社交推荐系统效果显著，我们认为现有系统仍存在两方面不足：

（1）大多数现有学习方法尚未探索物品之间丰富的语义相关性。在真实推荐场景中，物品之间通常存在依赖关系，例如产品类别/功能、场所的空间相似性 [17], [37]。物品之间丰富的语义相关性有助于探索其潜在依赖关系，从而更好地理解用户的复杂兴趣 [42]–[56]。因此，用户对不同物品的偏好不仅可能受其社交连接影响，也可以从物品的细粒度关系知识中推断出来。尽管具有上述优势，但由于各种关系具有异质性，在社交推荐中纳入跨物品依赖关系颇具挑战。

(2) 目前大多数社交推荐系统忽略了这样一个事实：连接是由复杂因素驱动的。例如，用户与某件物品互动的意图（例如，点击或购买）可能会受到多种因素的影响，这些因素源于不同的物品特征，例如产品的品牌和颜色、电影的导演 [40], [46]。通过因子级表示学习来捕捉更细粒度用户兴趣的不足，可能导致推荐结果不够理想。此外，在现实生活中的社交推荐场景里，用户出于多种动机建立社交联系 [10], [26], 例如，兴趣各异的社群、同事或家庭成员。如果在表示用户层面影响时不对这种社交多义性进行解耦，学到的用户偏好就难以反映多个社交情境。因此，由复杂潜在因子驱动的异质关系迫切要求模型编码与类型特定关系语义相关的因子化嵌入。

目前最先进的推荐系统尝试将解耦表示学习融入用户-物品交互建模。然而，它们仅关注单一类型的关系解耦，因此难以将异构关系语义纳入推荐系统。换言之，推荐领域的一个重要事实

†同等贡献。*通讯作者：Chao Huang。

一直被忽视：具有关系异质性的多样化语义可以用于增强推荐系统中的用户偏好学习。因此，我们需要学习解耦的用户/物品因子化嵌入，并感知异构侧上下文，从而提升神经推荐模型在实际应用中的表示能力。

在社交推荐中建模异质关系的一种可行方法，是采用异质图学习方法 [11], [34], [45]。具体而言，这些方法将用户-用户关系和物品-物品关系的连接结构纳入图学习模型。然而，这些方法高度依赖于手动设计的用户/物品之间的元路径，并要求具备特定领域知识，因此很难适应多样化的推荐场景。它们要么仅在特征表示过程中，针对节点类型或边类型分别保留不同的变换权重。这使得它们无法全面捕捉用户侧和物品侧的异质关系上下文，以及用户级关系与物品级关系之间潜在的交互上下文。

尽管人们已经认识到在推荐中编码解耦的关系异质性至关重要，但这仍是一项非平凡的任务，原因在于以下关键挑战：i）学习具有关系异质性的解耦因子，对图神经网络提出了挑战。在我们的方法中，我们开发了一种依赖节点类型和边类型的记忆增强网络，以保留不同类型交互的专属语义表示，即例如，用户-用户、物品-物品和用户-物品关系。ii）捕捉不同编码后的解耦关系因子之间隐含的相互依赖关系。新设计的图神经网络应使推荐系统能够学习跨因子相互依赖关系，从而实现富有表现力的解耦表示学习。

鉴于这些局限与挑战，我们提出一种**D**解耦**G**图**N**神经**N**网络（DGNN），通过学习解耦的异质因子来研究社交推荐。为通过解耦关系建模处理关系异质性，我们开发了一种依赖于节点类型和边类型的记忆增强网络，为不同类型的交互（*i.e.*，用户-用户、物品-物品和用户-物品关系）保留专属特征表示。具体而言，DGNN 利用具有可微嵌入传播算子的外部记忆单元，使图神经网络架构能够显式捕获用于社交推荐的异构图关系。此外，我们引入的记忆神经层无需为每种关系单独设置参数，即可在解耦潜在表示空间中以全自动、交互式的方式实现关系异质性编码，而无需定制元路径。

总而言之，我们的贡献如下：

- 我们强调在社交推荐系统中，将异质关系与潜在因子解耦相结合的重要性。这使用户偏好表示范式能够从用户和物品领域中探索有吸引力的信息来源。
- 我们提出了一种解耦图神经网络 DGNN，通过维护关系感知的解耦表示，推广了关系异质性编码。我们提出的 DGNN 建立在异构图记忆增强消息传递的基础上。
- 在三个真实世界数据集上开展的大量实验表明，DGNN 的表现显著优于各种先进的推荐方法。此外，详尽的模型消融研究有助于验证模型的有效性，并分析各组件对性能提升的影响。

II. 相关工作

A. 社会感知推荐方法

为改善推荐结果，许多社交推荐方法应运而生，将用户之间的在线社交关系作为侧信息纳入推荐框架 [21], [24], [25]。大多数传统方法（例如，Sorec [30], TrustMF [58]）基于矩阵分解架构构建，将用户映射为潜在因子。这些方法背后的共同依据是，用户更有可能与社交关系密切的朋友在物品方面拥有相似的兴趣 [36]。

基于深度学习的社会推荐模型凭借神经网络在知识表示方面的能力，日益受到关注 [13], [60]。具体而言，一些研究着重于应用图卷积网络，同时对用户—用户和用户—物品关系进行建模，例如 DiffNet [50],RecoGCN [57] 和 KCGN [19]。此外，研究者引入注意力机制来区分用户之间的影响，以刻画其偏好，例如 SAMN [4] 和 GraphRec [12]。例如，GraphRec 在聚合来自社交图和用户—物品交互图的信息时，会区分社交关系的强度。受自监督学习的启发，近期的社交推荐系统 MHCN [61] 和 SMIN [28]采用了数据增强。然而，这些推荐方法大多忽视了异质关系背后的潜在因子。为弥补这一不足，本文旨在构建一种新的社交推荐系统，在图神经网络架构下融合解耦表示学习与异质语义。

B. 用于推荐的图神经网络

由于图结构数据表示学习方面的优势，一系列推荐研究致力于利用图神经网络架构增强用户—物品交互建模 [7], [16], [52]。受谱图卷积网络有效性的启发，NGCF [43]通过执行卷积操作来捕捉用户与物品之间的高阶关系。此外，另一类基于图神经网络的推荐系统则探索空间图神经网络，通过注意力机制聚合邻居节点的信息，例如 KGAT [42] 和 DGRec [35]。

此外，在图神经网络研究中，异构图表示已成为整合多样关系上下文的有前景的解决方案

，以融入节点表示中 [8], [14], [18], [45], [48]。例如，HERec [34]尝试利用生成的元路径连接，引入各种侧信息来增强用户偏好学习。多类型用户-物品交互（例如，点击、购买）被用于编码关系异质性 [15],[54]。然而，这些方法中的大多数，其准确预测结果在很大程度上依赖于所构建的基于元路径的连接的有效性，而这需要领域知识。与这些方法不同，我们的 DGNN 模型通过设计记忆增强消息传递方案，自动捕获用户和物品之间的异质关系。此外，在考虑异构上下文的现有推荐系统中，采用解耦表示的潜在因子编码在很大程度上尚未得到探索。

C. 推荐中的解耦学习

近期已有一些研究致力于从用户-物品交互中学习解耦表示，以提炼出驱动观测到的连接的潜在因子 [32]。例如，DGCF [46]设计了结合胶囊网络的路由机制，用于建模用户与物品之间的解耦关系。Chen 等人 [6] 提出了一种基于课程学习的方法，以解耦用户的多类型反馈。在多媒体推荐领域，多模态特征以弱监督的方式融入解耦表示学习 [41]。

尽管已有一些关于推荐中解耦学习的研究，但我们的新型推荐系统在以下两个方面有别于这些研究：i）其中大多数模型旨在建模推荐系统中的同质关系，由于异质关系具有不同的语义，这些模型难以适应解耦其背后的多样化因子。为弥补这一不足，我们设计了解耦图神经网络，以针对关系异质性维护定制的因子化表示，并以全自动的方式提炼关系知识。ii）大多数现有研究忽略了编码后潜在因子之间的复杂依赖关系。相比之下，我们的 DGNN 方法通过在多个潜在表示空间中设计的可微记忆网络，捕捉潜在因子之间的因子级相互依赖关系。通过这种方式，关系感知的潜在因子能够有效保留解耦的异构语义。

D. 上下文感知推荐系统

已有一些相关研究致力于开发上下文感知推荐系统，以考虑不同推荐场景中的各种上下文 [1], [22]。从用户维度来看，STARS [22]结合在线社交网络中的用户间关系与用户特定的上下文特征，以增强协同过滤。从物品内容维度来看，LBSNs [2]学习物品上下文特征到用户偏好标签的映射，用于兴趣点推荐。CARL [49]提出融合物品的文本上下文信息与基于交互的嵌入，以实现更好的表示学习。此外，知识图谱也被视为有用的上下文信号，可纳入推荐系统以提升知识感知推荐系统的性能，例如 KGIN [44], 、CASR [31] 和 KGCL [59]。

III. 预备知识

我们考虑一个场景，其中用户集合为 $\mathcal{U} = \{u_1, ..., u_i, ..., u_I\}$，物品集合为 $\mathcal{V} = \{v_1, ..., v_j, ..., v_J\}$。用户-物品交互由矩阵 $\mathbf{Y} \in \mathbb{R}^{I \times J} = \{y_{i,j} | u \in \mathcal{U}, v \in \mathcal{V}\}$ 表示，其中，如果观察到用户 u_i 与物品 v_j 之间的交互（例如，浏览或购买），则 $y_{i,j} = 1$；否则 $y_{i,j} = 0$。除了交互矩阵 Y，我们还有用户之间的社交连接，这些连接由定义的用户社交矩阵 $\mathbf{S} \in \mathbb{R}^{I \times I}$ 表示，其中，如果用户 u_i 与 $u_{i'}$ 之间存在社交关系，则每个条目 $s_{i,i'} = 1$，否则为零。在这项工作中，我们提出通过纳入物品关系来增强社交推荐。因此，给定一对物品 $(v_j, v_{j'})$，它们之间的关系定义为一个实体-关系-实体三元组 $(v_j, r, v_{j'})$，其中 $r \in \mathcal{R}$ 是跨物品元关系（例如，物品之间的类别关系）的中间关系节点，且 $v_j, v_{j'} \in \mathcal{V}$。我们使用物品-关系连接 (v_j, r) 构建物品关系矩阵 $\mathbf{T} \in \mathbb{R}^{J \times R}$，其中 R 表示关系的数量。

任务描述。根据上述定义，我们将包含物品关系的社交推荐任务定义如下：**输入**用户-物品交互历史记录**Y**、用户社交关系矩阵**S**和物品-关系矩阵**T**。**输出** 一个经过训练的模型 $\xi(\cdot)$，通过 $\hat{y}_{i,j} = \xi(u_i, v_j; \mathbf{Y}, \mathbf{S}, \mathbf{T})$ 预测每个用户 u_i 对未观测物品 v_j 的偏好。

IV. 方法论

本节将详细介绍我们的 DGNN 框架。我们提出的新方法由三个关键组件构成：i）记忆增强关系异构性编码器，将关系异质性参数化为依赖于顶点类型和边类型的嵌入。ii）融入关系异质性的解耦消息聚合，将来自交互模式和侧信息的解耦关系上下文融合起来。iii）模型预测阶段，将异质因子化嵌入纳入模型优化的推荐目标函数。我们提出的 DGNN 的整体架构如图 1 所示。

A. 协同异构图

为共同保留用户-物品交互**Y**、用户之间的社交连接**S**以及逐物品关系**T**，我们定义统一图结构 $\mathcal{G} = (\mathcal{D}, \mathcal{E}, \mathcal{A}, \mathcal{B})$，其中每个顶点 $d \in \mathcal{D}$ 和每条边 $e \in \mathcal{E}$ 都与其映射函数 $\mathcal{D} \rightarrow \mathcal{A}$ 及边 $\mathcal{E} \rightarrow \mathcal{B}$相关联。这里，$\mathcal{A}$ 和 $\mathcal{B}$ 分别表示顶点集和关系边类型集。在图 $\mathcal{G}$中，我们通过以下整合方式刻画用户与物品之间各种连接所体现的关系异质性：

$$\mathcal{D} = \mathcal{U} \cup \mathcal{V} \cup \mathcal{R}; \quad \mathcal{E} = \mathcal{S} \cup \mathcal{T} \cup \mathcal{Y} \tag{1}$$

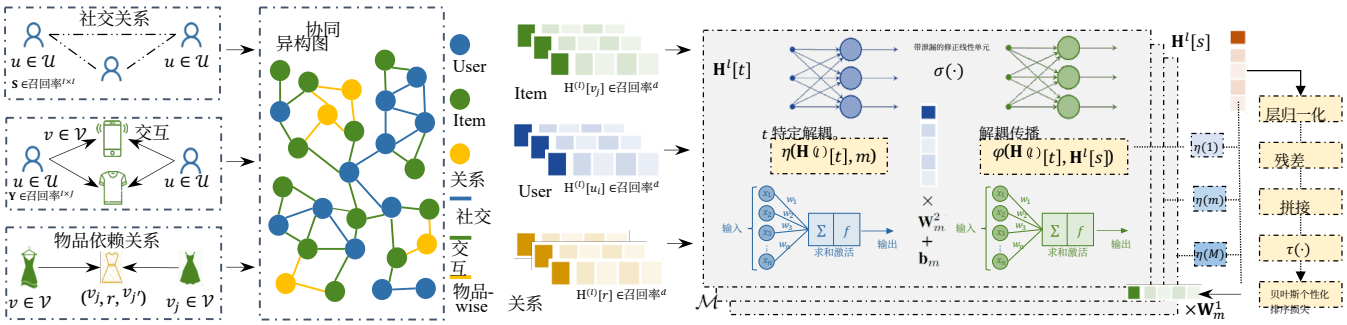

图 1. 所提出的 DGNN 架构的模型流程。将协同异构图与初始用户/物品/关系节点嵌入输入由解耦异质性编码器和异构图消息聚合器组成的 DGNN。$\eta(m)$ 表示与编码后的因子化嵌入对应的第 m 个记忆单元的学习重要性权重。

其中，$\mathcal{S}$，$\mathcal{T}$，$\mathcal{Y}$ 分别表示邻接矩阵**S**，**T**，**Y**中的观测边集（例如，$\mathcal{Y} = \{(u_i, v_j) : y_{i,j} = 1\}$）。通过整合三种关系构建统一异构图后，我们进一步设计了具有解耦因子表示的异构图神经网络架构。

*B. D*解耦异构图记忆网络 *work*

尽管取得了进展，大多数现有的异构图数据处理方法仍很少关注生成异构数据复杂语义的潜在因素。例如，HGT [45] 直接为每种节点/边类型分配一组独立参数。这妨碍了对异构数据的深入理解，例如对类型间潜在依赖关系的理解。受记忆神经网络在解耦表示学习 [4], [33], 方面优势的启发，我们的 DGNN 提出在多个潜在表示空间中加入可微记忆组件，以增强图神经网络。DGNN 自适应地学习节点/边类型与潜在因素之间的联系，从而更好地保留解耦的异构语义。

我们的 DGNN 将 $\mathcal{G}$ 作为信息传播的输入计算图。在消息传递过程中，我们首先执行局部特征变换和非线性激活，然后聚合关系感知的上下文表示。形式上，它可以表示为以下形式（从第（l）层到第（$l+1$）层）：

$$\mathbf{H}^{(l+1)}[t] \leftarrow \underset{\forall s \in \mathcal{N}(t)}{\text{Aggre}} \left(\varphi(\mathbf{H}^{(l)}[t], \mathbf{H}^{(l)}[s], e_{s,t}) \right) \tag{2}$$

其中，我们将$\mathbf{H}^{l}[t]$ 定义为目标节点 t 在第 l个图层的潜在表示。 $\mathcal{N}(t)$ 表示节点 t的邻居节点集合（*i.e.*，源节点 s）。边 $e_{s,t}$连接节点 s 和 t。在消息传递范式中，DGNN 包含两个关键算子：关系异构性编码器 $\varphi(\cdot)$和嵌入聚合函数 Aggre(·)。

1）记忆增强关系异构性编码器：为捕获知识增强型社交推荐中的异质性特征，我们提出对其进行参数化

通过外部记忆单元将关系异质性投影为依赖于顶点类型和边类型的嵌入（如图 2 所示）。具体而言，我们首先定义 $\mathcal{M}$ 为以下集合

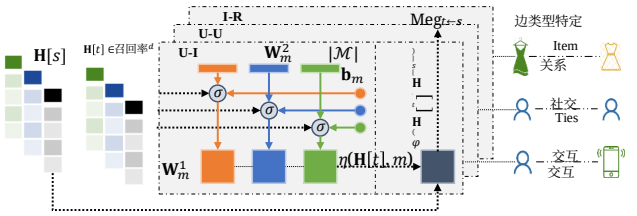

图 2. 基于我们提出的解耦异构图编码器，对不同用户和物品关系进行消息传递的示意图。

对应于类型特定关系语义因子原型学习的记忆单元 $\varphi(\cdot)$：

$$\varphi(\mathbf{H}^{(l)}[t], \mathbf{H}^{(l)}[s]) = \left(\sum_{m=1}^{|\mathcal{M}|} \eta(\mathbf{H}^{(l)}[t], m) \mathbf{W}_m^1 \right) \mathbf{H}^{(l)}[s]$$
$$\eta(\mathbf{H}^{(l)}[t], m) = \sigma(\mathbf{H}^{(l)}[t] \cdot \mathbf{W}_m^2 + \mathbf{b}_m) \tag{3}$$

其中，$\eta(\cdot)$ 表示目标节点特定嵌入函数。可训练的变换矩阵和偏置项分别表示为：$\mathbf{W}_m^1 \in \mathbb{R}^{d \times d}$、$\mathbf{W}_m^2 \in \mathbb{R}^d$ 和$\mathbf{b}_m \in \mathbb{R}$。源节点和目标节点编码后的特征嵌入分别表示为$\mathbf{H}^{(l)}[s] \in \mathbb{R}^d$ 和$\mathbf{H}^{(l)}[t] \in \mathbb{R}^d$。我们将带泄漏的修正线性单元用作激活函数 $\sigma(\cdot)$，*i.e.*，$\sigma(x) = \max(x, \alpha x)$。为更好地进行梯度反向传播，负斜率 α 设为 0.2。我们的记忆增强网络使图编码器能够学习具有层次化非线性特性的关系表示。为针对不同类型的节点（*e.g.*，用户、物品）和边（*i.e.*，交互、社交连接、物品间关系）保留专门的表示，我们还使用互不共享的超参数空间，对边类型特定关系进行编码。通过这种方式，学习得到的解耦表示能够保留协同异构图中与不同关系相关的多样化潜在因子 $\mathcal{G}$。

2）具有关系异质性的消息聚合：从$\mathbf{H}^{(l)}[v]$对局部邻居交互中的异质关系属性进行编码后，我们接下来聚合来自用户和物品领域的不同信息源的消息（如图3所示）。例如，我们将以下内容融合：

在用户（u_i）的消息聚合器中，融合来自交互模式和社交影响的关系上下文：

$$\mathbf{H}^{(l+1)}[u_i] = \frac{1}{|\mathcal{N}_{u_i}^S| + |\mathcal{N}_{u_i}^Y|}\Big(\sum_{u_i' \in \mathcal{N}_{u_i}^S} \varphi(\mathbf{H}^{(l)}[u_i'], \mathbf{H}^{(l)}[u_i]) + \sum_{v_j \in \mathcal{N}_{u_i}^Y} (\sum_{m=1}^{|\mathcal{M}|} \eta(\mathbf{H}^{(l)}[v_j], m)\mathbf{W}_{i\leftarrow j}^{m,1}\Big)\mathbf{H}^{(l)}[u_i]\Big) \quad (4)$$

其中，$|\mathcal{N}_{u_i}^S|$和 $|\mathcal{N}_{u_i}^Y|$分别表示用户-用户社交图和用户-物品交互图中 u_i的邻居节点数量。$\mathbf{W}_{i\leftarrow j}^{m\ 1} \in \mathbb{R}^{d\times d}$,表示用于将物品表示空间映射到用户表示空间的变换矩阵，对应于解耦因子的第 m个记忆单元。

引入知识感知的物品关系后，物品侧的嵌入传播过程可形式化表示如下：

$$\mathbf{H}^{(l+1)}[v_j] = \rho_{i,j}(\sum_{v_j \in \mathcal{N}_{v_j}^Y} \mathrm{Meg}_{v_j\leftarrow u_i}^{(l)} + \sum_{r\in N_{v_j}^T} \mathrm{Meg}_{v_j\leftarrow r}^{(l)}) \quad (5)$$

其中，$\rho_{i,j}$ 表示归一化项，即$\rho_{i,j}$ =1/(|$N_{v_j}^Y$| + |$N_{v_j}^T$|)。传播消息（$\mathrm{Meg}^{v_j\leftarrow u_i}$和$\mathrm{Meg}^{v_j\leftarrow r}$）由基于记忆的编码函数 φ(·)确定。此外，物品之间（*e.g.*， v_j）以及物品与元关系节点（r）之间的嵌入传播如下所示：

$$\mathbf{H}^{(l+1)}[r] = \frac{1}{|\mathcal{N}_r|} \sum_{v_j\in N_r} (\sum_{m=1}^{|\mathcal{M}|} \eta(\mathbf{H}^{(l)}[v_j], m)\mathbf{W}_{r\leftarrow j}^{m,1})\mathbf{H}^{(l)}[r] \quad (6)$$

其中，$\mathcal{N}_r$ 表示图结构中元关系节点 r 的邻居集合。$\mathbf{W}_{r\leftarrow j}^{m\ 1} \in \mathbb{R}^{d\times d}$,表示用于将物品空间映射到元关系节点空间的第 m个记忆单元专属变换。

我们进一步通过引入自传播和层归一化 [3]，对异构消息聚合进行推广，以稳定网络训练：

$$\widetilde{\mathbf{H}}^{(l+1)}[v] = \sigma(\omega_1 \odot \frac{\mathbf{H}^{(l+1)}[v] - \mu}{\sqrt{\sigma^2 + \epsilon}} + \omega_2) + \varphi(\mathbf{H}^{(l)}[v]) \quad (7)$$

其中，ω_1 和 ω_2 是学习得到的缩放因子和偏置项。μ 和 σ 分别表示输入向量$\mathbf{H}^{(l+1)}[v]$的均值和方差。 $\odot$ 表示逐元素乘法算子。对于自环，DGNN 不会直接添加上一次图神经网络迭代得到的嵌入，而是同样应用关系异构性编码器 ϕ(·)。为了充分利用多阶节点嵌入，我们进一步执行跨层（L）高阶嵌入聚合，具体如下：

$$\mathbf{H}^*[v] = \mathrm{LayerNorm}(\widetilde{\mathbf{H}}^{(0)}[v] \,\|\, \widetilde{\mathbf{H}}^{(1)}[v] \,\|\, ... \,\|\, \widetilde{\mathbf{H}}^{(L)}[v]) \quad (8)$$

其中$\mathbf{H}^*[v] \in \mathbb{R}^d$ 表示顶点 v 的最终节点嵌入。LayerNorm(·) 表示层归一化。

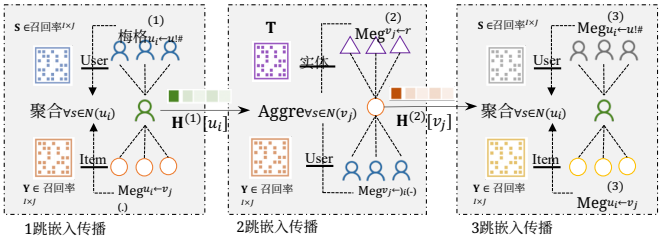

图3. 我们的模型在三层图层下，对用户和物品之间解耦的关系异质性进行消息传递的示意图。

C. 模型预测阶段

为了将社交影响注入 DGNN 的预测阶段，我们使用如下所示的表示重校准函数 τ(·) 对学习到的用户嵌入进行优化：

$$\tau(\mathbf{H}^*[u_i]) = \frac{1}{|\mathcal{N}_{u_i}^S| + 1}\Big(\sum_{u_i' \in \mathcal{N}_{u_i}^S} \mathbf{H}^*[u_i'] + \mathbf{H}^*[u_i] \Big) \quad (9)$$

该函数对社交关联用户的嵌入取均值，以便在后续预测阶段直接融入社交信息。具体形式如下：

$$\begin{aligned}\xi(u_i, v_j) &= (\mathbf{H}^*[u_i] + \tau(\mathbf{H}^*[u_i]))^\top \cdot \mathbf{H}^*[v_j] \\ &= \mathbf{H}^{*\top}[u_i] \cdot \mathbf{H}^*[v_j] \\ &+ \frac{\mathbf{H}^{*\top}[v_j]}{|N_{u_i}^S| + 1}\Big(\sum_{u_i' \in N_{u_i}^S} \mathbf{H}^*[u_i'] + \mathbf{H}^*[u_i] \Big)\end{aligned} \quad (10)$$

优化目标：我们通过以下公式，将成对 BPR 损失与权重衰减正则化项结合为综合损失，从而定义优化目标：

$$\mathcal{L} = \sum_{(i,j^+,j^-)\in O} -\log\ \delta(\xi(i,j^+) - \xi(i,j^-)) + \lambda \,\|\, \mathbf{\Theta}\|^2 \quad (11)$$

训练数据表示为 $O = \{(i,\ j^+,\ j^-)|(i,\ j^+) \in \mathbf{Y}^+, (u,\ j^-) \in \mathbf{Y}^-\}$ ($\mathbf{Y}^+$、$\mathbf{Y}^-$ 分别表示已观测交互和未观测交互。训练参数表示为 $\mathbf{\Theta}$， δ(·) 表示 sigmoid 激活函数。我们的 DGNN 的学习过程详见算法 1。

D. 模型效率分析

1）时间复杂度分析：为了计算记忆单元上每条边的注意力权重，DGNN 的时间复杂度为$O(|\mathcal{M}| \times |\mathcal{E}| \times d)$，其中 $|\mathcal{M}|$ 表示每个图的记忆单元数量（即用户-物品协同图、用户-用户社交图和物品-关系图）。利用注意力分数，获取每条边专属变换（即 $\sum_{m=1}^{|\mathcal{M}|} \eta(\mathbf{H}^{(l)}[t], m)\mathbf{W}_m^1$）的时间复杂度为 $O(|\mathcal{M}| \times |\mathcal{E}| \times d^2)$。然后，DGNN 需要 $O(|\mathcal{V}| \times d^2)$ 的时间复杂度来进行嵌入变换，并需要 $O(|\mathcal{E}|\times d)$的复杂度来沿异构边传播信息。通常，$|\mathcal{V}| \times d < |\mathcal{E}|$ 由于信息压缩的目的，因此在经验上有 $O(|\mathcal{V}| \times d^2) < O(|\mathcal{E}| \times d)$。总之，

算法 1：所提出的 DGNN 算法 输入：用户集合 $U = \{u_i\}$、物品集合 $V = \{v_j\}$、关系集合 $R = \{r\}$、用户-物品交互矩阵 Y $\in \mathbb{R}^{I \times J}$、用户-用户社交矩阵 S $\in \mathbb{R}^{I \times I}$、物品-物品关系矩阵 T $\in \mathbb{R}^{J \times |R|}$、学习率 η和训练轮数 E输出：训练后的模型参数 $\mathbf{\Theta}$1 初始化 $\mathbf{\Theta}$中的所有参数；2 根据关系矩阵 Y、S、T 构建协同异构图$\mathcal{G} = \{\mathcal{V}, \mathcal{E}\}$；3 对 $e = 1$ 至 E 执行 4 对 $l = 1$ 至 L 执行 5 对 $(s, t) \in \mathcal{E}$ 执行 6 基于记忆增强编码器计算传播信息$\varphi(\mathbf{H}^{(l)}[t], \mathbf{H}^{(l)}[s])$（公式 3）；7 结束 8 对 $u_i \in U$ 执行 9 从社交关系和物品关系中获取聚合信息 $\mathbf{H}^{(l+1)}[u_i]$（公式 4）；10 结束 11 对 $v_j \in V$ 执行 12 基于用户边和物品关系边计算物品嵌入 $\mathbf{H}^{(l+1)}[v_j]$（公式 5）；13 结束 14 对 $r \in R$ 执行 15 根据相连的物品更新关系嵌入 $\mathbf{H}^{(l+1)}[r]$（公式 6）；16 结束 17 结合层归一化和自传播，得到 $\tilde{\mathbf{H}}^{(l+1)}$（公式 7）；18 结束 19 对 $\mathbf{H}^*$进行跨层嵌入聚合；20 计算训练批次的损失 $\mathcal{L}$（公式 11）；21 对 $\theta \in \mathbf{\Theta}$ 执行 22 $\theta = \theta - \eta \cdot \partial\mathcal{L}/\partial\theta$；23 结束 24 结束 25 返回参数为 $\mathbf{\Theta}$的训练后模型。

DGNN 的总体时间复杂度为 $O(|\mathcal{M}| \times |\mathcal{E}| \times d^2)$。

2) 空间复杂度分析：尽管我们的 DGNN 使用潜在记忆块来增强异构关系建模，但额外参数仅需 $O(|\mathcal{M}| \times d^2)$ 的空间来存储可学习参数。DGNN 还需要额外的 $O(|\mathcal{E}| \times d^2)$ 内存空间来存储边特定变换矩阵（即., $\sum_{m=1}^{|\mathcal{M}|} \eta(\mathbf{H}^{(l)}[t], m)\mathbf{W}_m^1$）。相比之下，标准图神经网络模型需要 $O(|\mathcal{V}| \times d)$ 的空间来存储节点特征。此外，由于边特定参数定制，还需要 $O(|\mathcal{E}| \times d)$ 或 $O(|\mathcal{E}| \times d^2)$ 的额外空间（例如., GAT [39], HGT [45]）。

表I 实验数据集统计。

数据集	Ciao	Epinions	Yelp
用户数	1,925	18,081	99,262
物品数	15,053	251,722	10,5142
用户-物品交互数量	30,370	715,821	769,929
交互密度	0.1048%	0.0157%	0.0074%
社交关系数量	65,084	572,784	1,298,522
社交关系密度度	1.7564%	0.1752%	0.0132%

五、评估

本节中，我们在三个公开真实世界数据集上进行了广泛实验，通过回答以下研究问题来评估模型性能：

- **RQ1**：与各种先进模型相比，DGNN 在生成推荐方面的表现如何?
- **RQ2**：DGNN 中的主要组件会产生什么影响?
- **RQ3**：不同的关系类型（协同关系、社交关系和物品级关系）对 DGNN 的模型性能有何贡献?

- **RQ4**：在数据稀缺的情况下，与基线方法相比，DGNN 在用户偏好学习方面的表现如何?
- **RQ5**：DGNN 模型的关键超参数在不同设置下如何影响其性能?
- **研究问题6**：我们的 DGNN 在优化阶段和预测阶段的效率如何?
- **研究问题7**：通过嵌入可视化，集体编码关系异质性以及社交和知识增强的用户-物品交互模式，如何使学到的潜在表示受益?

A. 实验设置

1) **数据集：** 我们的实验基于三个真实世界的社交推荐基准数据集开展：*Ciao*、*Epinions* 和*Yelp*。这些数据集来自实际应用中的不同在线评论系统，用户可以在其中撰写关于不同产品的评论。此外，用户可以将他人添加到自己的信任列表中，从而建立社交关系。构建用户-用户连接网络时，如果用户 u_i 信任 u_j，则添加一条边 $e_{i,j}$，反之亦然。表I汇总了评估数据集的统计信息。按照 [42], [56], 中的设置，我们利用外部知识（*e.g.*，产品类别、商家类别）从物品侧生成逐物品关系。

*2)***对比基线：** 为全面评估模型的有效性，我们将 DGNN 与不同研究方向的先进方法进行比较，包括：i）注意力社交推荐模型（SAMN、EATNN）；ii）基于图神经网络的社交推荐系统（GraphRec、DiffNet、MHCN）；iii）融合时间上下文的社交推荐（DGRec）；iv）神经图协同过滤（NGCF、GCCF）；v）解耦图推荐系统（DGCF、DisenHAN）；vi）知识感知推荐模型（KGAT）；vii）面向推荐的异构图表示学习

表 II 所有方法在*HR@10* 和*NDCG@10*方面的性能比较。“IMP”表示我们的 DHGM 网络相较于各个对比基线的性能提升幅度。

数据集	指标	SAMN	EATNN	DiffNet	GraphRec	NGCF	GCCF	DGRec	KGAT	DGCF	DisenHAN	HAN		HGT	HERec	MHCN	DGNN
Ciao	HR	0.4677	0.4130	0.5202	0.4594	0.4843	0.4926	0.5086	0.4907	0.5189	0.4856	0.4856	0.4933	0.5298	0.5080	**0.5515**	
	Imp	17.92%	33.54%	6.02%	20.05%	13.88%	11.96%	8.43%	12.39%	6.28%	13.57%	13.57%	11.80%	4.10%	8.56%	–	
	NDCG	0.2838	0.2520	0.3201	0.2670	0.3088	0.3070	0.3113	0.2977	0.3166	0.2894	0.2608	0.3062	0.3104	0.3118	**0.3338**	
	Imp	17.62%	32.46%	4.28%	25.02%	8.10%	8.73%	7.23%	12.13%	5.43%	15.34%	27.99%	9.01%	7.54%	7.06%	–	
Epinions	HR	0.6390	0.6422	0.6323	0.6865	0.6944	0.6779	0.6268	0.6756	0.6635	0.6825	0.6673	0.7001	0.6767	0.6411	**0.7335**	
	Imp	14.79%	14.22%	16.01%	6.85%	5.63%	8.20%	17.02%	8.57%	10.55%	7.47%	9.92%	4.77%	8.39%	14.41%	–	
	NDCG	0.4259	0.4483	0.4160	0.4786	0.4763	0.4783	0.4127	0.4708	0.4594	0.4627	0.4371	0.4812	0.4572	0.4261	**0.5215**	
	Imp	22.45%	16.33%	25.36%	8.96%	9.49%	9.03%	26.36%	10.77%	13.52%	12.71%	19.31%	8.37%	14.06%	22.39%	–	
Yelp	HR	0.7971	0.7273	0.8222	0.8019	0.8204	0.8130	0.7830	0.7737	0.7956	0.8159	0.8169	0.8185	0.7047	0.8019	**0.8373**	
	Imp	5.04%	15.12%	1.84%	4.41%	2.06%	2.99%	6.93%	8.22%	5.24%	2.62%	2.50%	2.30%	18.82%	4.41%	–	
	NDCG	0.5293	0.5289	0.5524	0.5372	0.5651	0.5585	0.5386	0.5386	0.5410	0.5403	0.5511	0.5547	0.4990	0.5348	**0.5873**	
	Imp	10.96%	11.04%	6.32%	9.33%	3.93%	5.16%	9.04%	9.04%	8.56%	8.70%	6.57%	5.88%	17.70%	9.82%	–	

（HAN、HERec、HGT）。

注意力社交推荐系统：注意力机制一直是识别社交感知推荐中重要关系的有效技术。

•**SAMN** [4]：它设计了一种双阶段注意力模型，用于刻画用户层面影响并筛选相关好友，以建模用户偏好。该模型引入好友层面注意力，以探究用户之间的社交影响。

• **EATNN** [5]：这是一种迁移学习方法，通过注意力机制融合交互信息和社交信息。该方法设计了一种优化方案，以支持多任务学习框架。

基于图神经网络的社交推荐模型：图神经网络已被用于建模基于图的用户-物品关系和用户的社交关系，以实现推荐。

•**DiffNet** [50]：它采用图信息传播范式，通过面向用户的逐层扩散架构对社交关系进行建模。动态社交扩散模拟了递归式社交影响。

• **GraphRec** [12]：它基于图注意力网络，在社交网络中传播嵌入，从而增强用户表示。通过注意力组合，对社交连接和物品交互进行聚合，以获得用户潜在表示。

• **MHCN** [61]：这是一种自监督学习架构，利用多通道超图神经网络捕捉用户关系。节点级嵌入与子图级嵌入之间的互信息得到最大化，并作为辅助自监督学习任务，与推荐损失共同进行联合训练。

图协同过滤模型：图协同过滤技术通过展现其在用户-物品交互图上捕获协同效应方面的先进性能，成为有效的推荐解决方案。为进行公平比较，我们通过将多样化的上下文纳入交互图，增强图协同过滤基线方法。

• **GCCF** [7]：这是一个简化的基于图神经网络的协同过滤模型，采用基于卷积的消息传递。为了解决过拟合问题，该模型移除了图卷积网络中的非线性变换。

• **NGCF** [43]：这是一个先进的基于图卷积的协同过滤模型。在用户的表示过程中，该模型考虑了高阶连接，并通过递归应用图传播函数，将协同信号注入用户偏好学习范式。

时间感知社交推荐：社交推荐的另一条研究路线，是将时间上下文纳入用户层面社交影响的建模中。

• **DGRec** [35]：该方法通过整合循环单元和图神经网络，将时间上下文纳入社交推荐。社交连接被纳入用户的动态兴趣表示中。

解耦图推荐系统：我们的 DGNN 模型与采用解耦学习技术进行推荐的代表性解决方案相比，表现出有竞争力的性能。

• **DGCF** [46]：该方法首先将用户嵌入划分为互不相交的部分，以表示用户偏好中的解耦意图。随后，它在图卷积网络上执行意图感知的消息传递，以进行推荐。

• **DisenHAN** [47]：该模型基于图注意力模型构建，根据用户与物品之间的不同连接，对解耦嵌入进行编码并用于传播。

知识感知推荐系统：我们还将所提出的 DGNN 框架与一种推荐算法进行比较，该算法利用知识图作为物品侧信息来学习物品语义关联性。

• **KGAT** [42]：这是一种知识增强模型，使用注意力聚合来自用户-物品交互和物品知识图的信息。邻居节点和实体的权重通过注意力层学习。

推荐的异质图表示：在性能比较中，我们纳入了两种最先进的异构图嵌入技术，用于对推荐系统中的不同关系进行建模。

• **HAN** [45]：该方法采用由节点级和语义级注意力组成的元路径引导的层次注意力模型，对图的异质性进行编码。我们将此方法用于编码协同异构图 $\mathcal{G}$ 中的节点表示，以保留社交感知的用户依赖关系和知识感知的物品相关性。

• **HGT** [45]：该方法是一种用于异构图表示学习的图 Transformer 架构。它通过异质性编码，为图消息传递计算边特定变换和注意力。

•**HERec** [34]：这是一种异构网络嵌入方法，它结合多种融合函数与元路径随机游走策略，将各种侧信息融入用户偏好学习。

3) **评估指标：** 我们关注前N 个物品的推荐，并采用两种广泛使用的指标进行评估：命中率（HR）@N 和归一化折损累积增益（NDCG）@N，通过前N 个排名位置 [9], [43],来衡量各评估方法的推荐准确率。对于每位目标用户，我们选取100个未交互物品作为负样本，并在评估过程中将其与已交互物品（作为正样本）一同使用。具体而言，指标计算如下：

$$HR@N = \frac{\sum_{i=1}^{M}\sum_{j=1}^{N} r_{i,j}}{M}$$
$$NDCG@N = \sum_{i=1}^{M} \frac{\sum_{j=1}^{N} r_{i,j}/\log_2(j+1)}{M \cdot IDCG_i} \qquad (12)$$

其中， M 表示接受测试的用户数量。$r_{i,j}=1$ 若第 i位用户排名列表中的第j个物品是正样本物品，则取值为$j=1$；$r_{i,j}=0$ 否则取值为$j=0$。NDCG@N 的分子为折损累积增益（DCG）@N，而 $IDCG_i$ 表示第 i位受测用户可能达到的最大DCG@N 值。

4) **超参数设置：** 我们基于 PyTorch 实现了所提出的 DGNN 框架，并使用 Adam 对模型进行优化。对于 DGNN 方法，嵌入维度在范围 [4, 8, 16, 32] 内调优。学习率设为 0.01，批量大小在512至 4096之间搜索。正则化项的系数 λ 在 $\{10^{-3}, 10^{-4}, 10^{-5}\}$ 内调优。在实验中，我们将潜在记忆单元的数量设为 8。其他超参数的详细信息请参见我们发布的源代码。

B. 性能比较（*RQ1*）

表 II 报告了所有对比方法在三个不同数据集（即即，Ciao、Epinions 和 Yelp）上的实验结果。我们总结出以下主要观察结果：

与所有基线方法相比，我们的 DGNN 在三个不同数据集上均取得了最佳性能，这表明 DGNN 具有优越的性能。这些性能提升归因于以下模型设计：i）得益于异构图记忆网络，DGNN 能够通过潜在因子解耦保留全面的关系语义，从而

有效整合解耦后的社交感知与知识感知协同信号。i) 通过将知识感知的物品关系融入社会推荐框架，DGNN 能更好地刻画用户与物品之间的异质关系，从而增强其表示

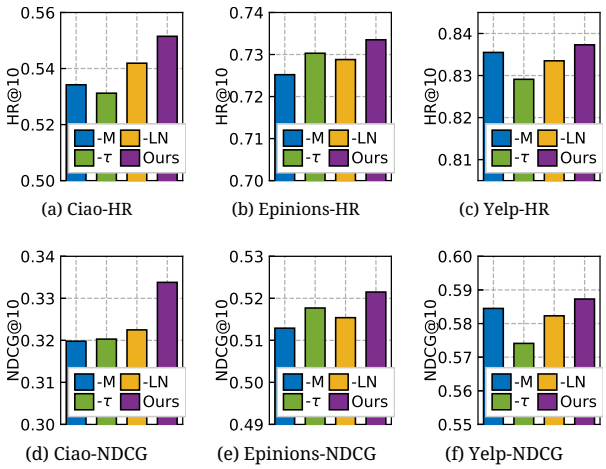

图 4. 在 Ciao、Epinions 和 Yelp 数据集上，针对 DGNN 框架中不同子模块进行的消融研究，评估指标为 HR@10 和 NDCG@10。

用户-物品交互范式。

基于图神经网络的社交推荐模型优于注意力方法，这表明使用多跳图结构进行嵌入传播，以实现社交关系变换是合理的。此外，尽管 HAN 和 HERec 设计了通过异构图编码器变换各种关系的方法，但它们受限于利用特定于数据的领域知识生成元路径引导的关系。为解决这一问题，DGNN 在关系异质性的嵌入函数中避免使用定制元路径，从而学习更强大的依赖节点类型和边类型的表示。

DGNN 与基于图神经网络的方法（例如 DiffNet、GraphRec 和 DGRec）之间的性能差距表明，若不利用知识感知的物品关系，将会限制社交感知推荐系统的性能。这一观察也表明，凭借所设计的记忆增强型图神经网络架构，DGNN 能够充分发挥从用户和物品领域学习潜在因子的潜力。从表 III 可以看出，与其他竞争方法相比，DGNN 在不同的前N 个排名位置上均取得了性能提升，这进一步证明了我们框架卓越的排序性能。随着 N 值增大，推荐准确率也会提高。

C. 模块消融分析（*RQ2*）

在本节中，我们考察 DGNN 框架中各子网络设计的合理性。为此，我们分别移除关键模块，并针对 DGNN 的三个技术要点实现了三个模型变体：i）“-M”：不包含解耦式记忆增强关系异质性编码器的 DGNN。ii）“-τ”：不使用表示重校准函数 $\tau(\cdot)$ 来整合用户特定社交影响的 DGNN。iii）“-LN”：在每个传播层中不进行层归一化，以实现稳定节点嵌入训练的 DGNN。

表 III 不同 Top-*N* 下的*HR@N* 和*NDCG@N*性能评估。

模型	Ciao@5		Ciao@20		Epinions@5		Epinions@20		Yelp@5		Yelp@20	
	HR	NDCG	HR	NDCG	HR	NDCG	HR	NDCG	HR	NDCG	HR	NDCG
SAMN	0.3468	0.2460	0.6251	0.3223	0.5176	0.3860	0.7491	0.4553	0.6359	0.4662	0.9009	0.5407
EATNN	0.2969	0.2124	0.5222	0.2819	0.5283	0.3924	0.7501	0.4557	0.6425	0.4866	0.8066	0.5468
DiffNet	0.3941	0.2816	0.6647	0.3573	0.5106	0.3820	0.7367	0.4476	0.6701	0.5127	0.9053	0.5701
GraphRec	0.3058	0.2235	0.5976	0.3042	0.5683	0.4325	0.8001	0.5011	0.6631	0.4903	0.8944	0.5650
NGCF	0.3570	0.2360	0.5937	0.3188	0.5612	0.4316	0.8010	0.5006	0.6748	0.5192	0.9011	0.5684
GCCF	0.3685	0.2668	0.6289	0.3414	0.5538	0.4161	0.7906	0.4852	0.6703	0.5130	0.9011	0.5503
DGRec	0.3724	0.2647	0.6219	0.3277	0.5053	0.3775	0.7308	0.4429	0.6511	0.4897	0.8824	0.5611
KGAT	0.3391	0.2422	0.6052	0.3326	0.5483	0.4139	0.7880	0.4837	0.6503	0.4901	0.8795	0.5521
DGCF	0.3871	0.2782	0.6775	0.3604	0.5479	0.4144	0.7770	0.4811	0.6565	0.4958	0.9010	0.5678
DisenHAN	0.3493	0.2482	0.6161	0.3248	0.5609	0.4247	0.7890	0.4911	0.6511	0.4944	0.9040	0.5650
HAN	0.2937	0.1897	0.6513	0.2821	0.5403	0.4106	0.7761	0.4802	0.6635	0.5080	0.8977	0.5529
HGT	0.3415	0.2372	0.6128	0.3229	0.5757	0.4360	0.8053	0.5029	0.6888	0.5136	0.9060	0.5802
HERec	0.3832	0.2679	0.6846	0.3641	0.5519	0.4179	0.7792	0.4839	0.5833	0.4501	0.8125	0.5034
MHCN	0.3864	0.2799	0.6321	0.3453	0.5199	0.3883	0.7496	0.4551	0.6607	0.4911	0.8958	0.5670
DGNN	**0.4120**	**0.2890**	**0.6942**	**0.3726**	**0.6142**	**0.4794**	**0.8281**	**0.5387**	**0.7052**	**0.5378**	**0.9293**	**0.6043**

我们在三组实验数据上评估上述变体以及 DGNN 的性能。结果如图 4 所示。与三个变体相比，DGNN 始终取得最佳性能。通过详细考察结果，我们得出以下观察：i）移除记忆增强关系异质性编码器（即例如，“- M”）会导致性能显著下降。这验证了解耦与各类关系相关的潜在因子的有效性。ii）“-τ”变体与 DGNN 之间的性能差距表明，使用局部结构

在社交关系中显式引入异构关系数据，有助于用户表示学习。iii）通过比较“-LN”与 DGNN，我们可以得出结论：层归一化技术有助于 DGNN 的模型训练。我们将性能提升归因于该技术通过归一化生成稳定梯度的能力。

D. 异质关系的影响（*RQ3*）

我们进一步研究了不同辅助关系数据（即 社交连接和逐物品相关性）对 DGNN 性能的影响。具体而言，我们考虑以下三种模型变体：i）“-T”：DGNN 移除了物品关系矩阵 $\mathbf{T} \in \mathbb{R}^{J\times|R|}$。ii）“-S”：DGNN 在联合邻接矩阵中不包含用户间社交关系矩阵 $\mathbf{S}\in \mathbb{R}^{I\times I}$。iii）“-ST”：从输入中移除用户级社交关系和物品级关系。

我们在 Ciao 和 Yelp 数据集上进行评估，并采用不同的 Top-N 设置。结果如图 5 所示。主要结论如下：1）辅助异质关系始终能提升模型性能，这可归因于将异质语义融入表示所带来的益处。2）“-S”的次优表现表明，利用社交上下文信号辅助用户偏好学习是有益的。3）在所有情况下，DGNN 的表现都优于“-T”。我们将性能提升归因于记忆增强关系异质性编码器挖掘丰富物品级依赖关系的能力。4）“-ST”变体在两个数据集上的表现始终最差，这进一步

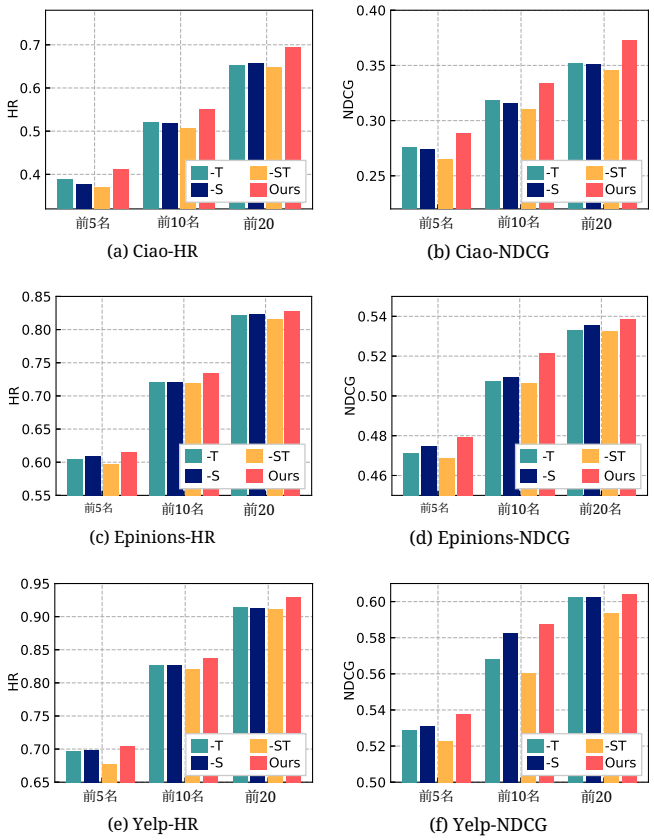

图 5. 从 HR@N 和 NDCG@N（N=5、10、20）的角度，对不同异构数据对模型性能的影响进行消融研究。

这表明，融入来自用户或物品领域的异质关系都能提高准确率。

E. 缓解数据稀疏性方面的性能（*RQ4*）

在本小节中，我们通过实验展示 DGNN 在融合用户域和物品域中的异质侧信息方面的优势，以缓解推荐中的稀疏性问题。我们首先根据所有用户的交互密度对其进行排序，并将其划分为

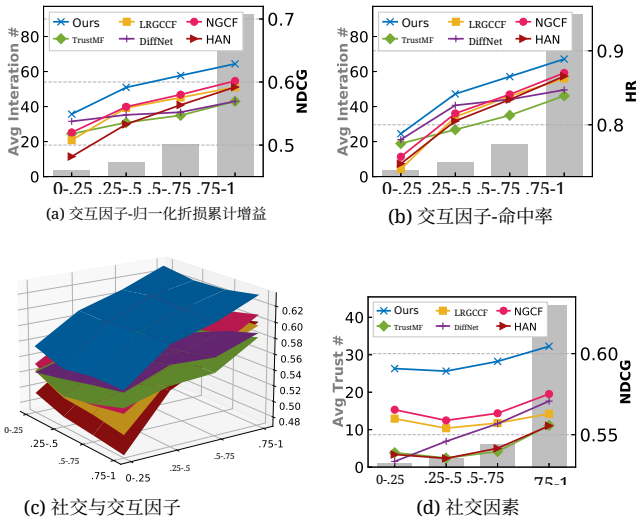

(a) 交互因子-归一化折损累计增益 (b) 交互因子-命中率

(c) 社交与交互因子 (d) 社交因素

图6. DGNN 与基线方法在 Yelp 上不同稀疏度下的用户交互和社交连接性能比较。

四个用户数量相同的不同组（如图6的 x 轴所示：0–25%；25%–50% 等）。在图6中，我们计算每组用户的平均交互次数，如 y 轴左侧所示。各对比方法的推荐性能则显示在 y 轴右侧。从结果中可以看出，在不同数据集上，DGNN 的表现均优于基线方法，这表明我们的推荐系统在应对用户行为数据稀疏性方面具有稳健性。这也进一步证实，在数据稀缺的情况下，DGNN 能够利用来自用户域和物品域的外部知识，通过跨关系上下文引导用户偏好嵌入，且效果显著。

我们进一步展示了关于两个不同因素（社交和交互维度）的评估结果。如图6所示，可以观察到，在不同的数据稀疏程度下，DGNN 始终优于具有竞争力的方法，这证明了 DGNN 从社交关系和用户-物品交互两个角度缓解稀疏问题的有效性。总体而言，DGNN 方法缓解数据稀疏问题的这一特性十分重要，尤其是在用户-物品交互相对于整个交互空间较少的推荐场景中。

F. 超参数研究（*RQ5*）

本节通过探究隐藏状态维度大小 d、图层数 L 和潜在记忆单元数 $\mathcal{M}$ 的影响，研究超参数设置如何影响性能。为节省篇幅，我们在同一张图中统一展示不同数据集上的评估结果（数值范围各不相同）。图7的纵轴表示相较于最佳准确率的性能下降比例。

隐藏状态大小 d。我们通过改变 d 的取值范围 $\{2^2, 2^3, 2^4, 2^5\}$，绘制了 DGNN 的性能曲线。融入来自用户和物品

表IV 不同模型每个训练轮次的运行时间（秒）。

模型	训练			测试		
	Ciao	Epinions	Yelp	Ciao	Epinions	Yelp
DGCF	2.56	63.52	81.15	0.87	14.77	66.57
HGT	4.21	525.94	728.23	0.77	13.55	79.74
DGNN	2.47	31.60	39.50	0.71	7.39	25.57

领域的语义相关性后，我们发现，嵌入维度为 16 已足以使 DGNN 框架取得良好性能。此外，嵌入维度越大，模型的性能下降越明显。总之，模型在较小的隐藏状态维度下仍能保持强劲性能，这有利于实际推荐系统的应用，因为模型的计算成本会直接受到嵌入维度的影响。

图层数 L。我们在协同异构图 $\mathcal{G}$上执行上下文感知的消息传递。现在，我们通过堆叠更多图层来考察模型的性能（$1 \leq L \leq 3$）。我们可以观察到，在两跳邻居节点之间传播嵌入能够提升性能。我们还将我们的方法与不进行传播的变体（$L = 0$）进行了比较。在三个数据集上的结果表明，对用户和物品之间的高阶关系进行编码是有效的。我们还发现，由于图神经网络的过平滑问题，堆叠更多图层会导致性能略有下降。

记忆单元数 $|\mathcal{M}|$。在我们的实验中，记忆单元的数量 $\mathcal{M}$ 在 $\{2^1, 2^2, 2^3, 2^4\}$范围内进行搜索。我们可以观察到，使用 8 个记忆单元来编码关系异质性时，能够取得最佳性能。我们的方法利用多维表示空间，通过解耦隐式因子来捕捉异构连接的语义。

G. 模型效率研究（研究问题*6*）

我们从两个方面评估模型效率：*ie.*，即运行时间衡量的计算成本，以及在训练轮次方面的收敛情况。我们通过实验比较了两种最先进的基线方法（*ie.*，DGCF 和 HGT）。

1）每轮训练的运行时间：如表IV所示，与解耦推荐系统（*ie.*，DGCF）和基于异构图神经网络的方法（*ie.*，HGT）相比，我们的 DGNN 能够实现更高的效率。具体而言，HGT 采用类 Transformer 多头点积注意力机制，耗时较长。图规模越大，HGT 的训练时间就会大幅增加。此外，对于 DGCF 方法，递归路由机制的设计成本很高，导致在多个用户嵌入之间进行传播时计算负担沉重。

2）性能与训练轮数的关系：我们在每个训练轮次后，根据 HR@10 和 NDCG@10 评估模型性能，以展示参数优化过程中性能的提升。我们展示了

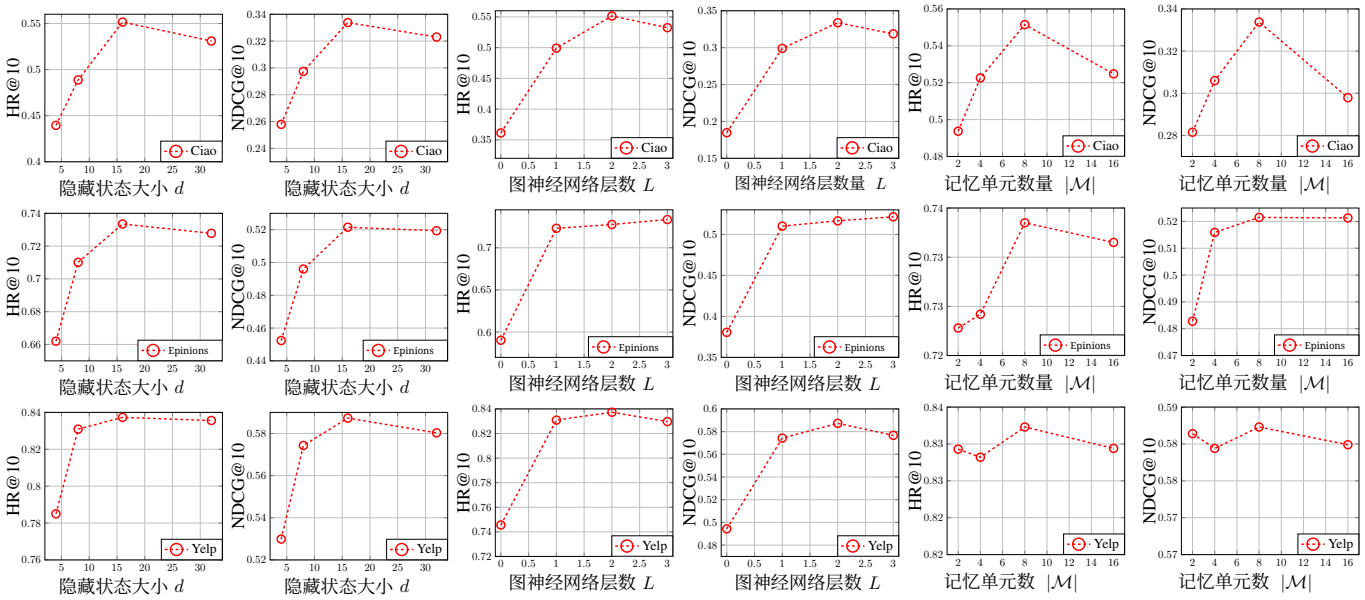

图7. 重要参数配置的超参数研究 DGNN 的重要参数配置（*i.e.* 隐藏状态维度 d、图神经网络迭代次数 L，以及记忆单元数量 $|\mathcal{M}|$ ），在 Ciao、Epinions 和 Yelp 数据集上的 HR@10 和 NDCG@10 表现。

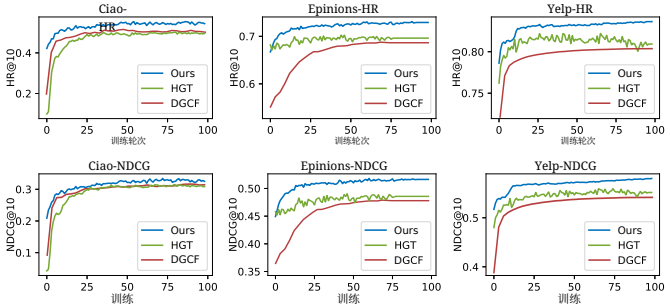

图8. 不同方法的模型性能对比，*w.r.t* 训练轮次数量，在三个数据集上的 HR@10 和 NDCG@10 表现。

图 8 中的结果，据此我们得出以下观察结论：i）在所有训练轮次中，与 HGT 和 DGCF 相比，DGNN 的性能最佳。这表明我们的模型优化方法在参数推断方面是有效的。DGNN 的架构不仅能提高推荐准确率，而且更易于优化。我们认为，这归功于在考虑关系异质性的基础上，将边关系映射到多个潜在空间。ii）与 DGCF 相比，HGT 在训练初期的性能提升更快。这表明，异构图变换器在处理异构图结构方面优于传统图卷积网络。其优势可能源于对异质语义的建模，以及多头点积注意力技术的应用。

H. 案例研究（研究问题7）

本节从两个方面进行案例研究，以考察 DGNN 使用解耦表示编码异构语义的表示能力。

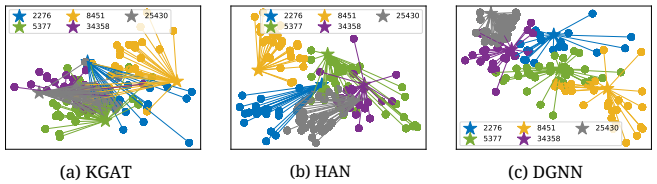

图 9. KGAT、HAN 和 DGNN 学得的用户（星形）及其交互物品（圆形）的嵌入可视化。请以彩色查看。

1）嵌入可视化：在这一部分，我们使用 t-SNE [38] 将学到的用户/物品特征向量投影到低维潜在空间中。嵌入可视化结果如图 9 所示。图中不同的颜色表示不同的用户（星形）及其交互过的物品（圆形）。图 9 (a)–(c) 分别展示了 KGAT、HAN 和我们提出的 DGNN 方法编码得到的用户嵌入。根据这些结果，我们总结出以下观察：

- 与知识感知推荐模型（KGAT）相比，异构图神经网络（HAN）呈现出更好的节点分离现象，这表明，探索具有社交效应的物品级关系将提升用户偏好嵌入的区分能力。

- 根据这些采样用户在不同物品上的交互模式可以明显看出，与其他基线方法相比，我们的 DGNN 能更好地区分用户。此外，颜色相同的物品节点通常分布在中心相关用户的周围。低维表示清楚地展现了 DGNN 在保留用户与物品之间关联方面的更强能力。这种出色的表示能力应归功于对用户-用户依赖关系和物品-物品依赖关系的联合建模，以及通过解耦图神经网络进行的多通道解耦投影。

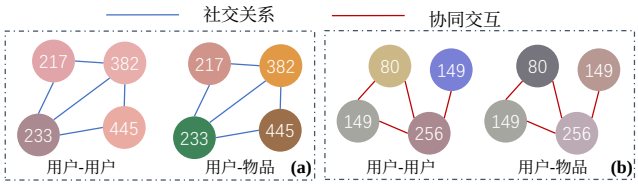

图 10. 由我们的记忆增强图编码器学习得到的用户记忆注意力向量可视化结果，同时保留了异质语义。

2）记忆注意力可视化：接下来，我们将不同异质关系对应的各记忆单元上的注意力权重进行可视化，以验证用户的边类型特定记忆注意力是否反映了相应的用户关系。具体而言，我们训练一个神经网络，将注意力向量$[\eta(\mathbf{H}^{(L)}[u_i],\ 1)..... \eta(\mathbf{H}^{(L)}[u_i],\ m)..... \eta(\mathbf{H}^{(L)}[u_i],\ M)]$映射为对应 RGB 颜色值的三维向量。该映射函数通过自判别任务进行训练，从而在保留原始用户—记忆连接的同时，可视化记忆注意力权重。我们从 Ciao 数据中随机选取两个紧密连接的用户关系子图，一个仅包含社交关系，另一个仅包含共同交互关系。图 10 展示了这些子图，其中圆圈表示用户，其颜色表示学习到的记忆注意力权重。线条表示异质的用户关系连接。我们分别对用户-用户关系和用户—物品关系进行了嵌入可视化。

从结果中，我们可以清楚地观察到，由社交关系连接的用户具有相近的用户-用户记忆单元权重，而其用户-物品记忆权重通常差异很大。这一模式在共同交互子图中同样成立：具有共同交互的用户，其用户-物品记忆权重相似，而用户-用户记忆权重差异很大。这种关系特定记忆权重与关系特定图结构之间的对应关系，验证了我们的 DGNN 中记忆增强异质性编码器能够通过解耦多种关系因素来捕捉节点/边类型特定语义。

VI. 结论

本文提出了一种新型解耦图神经网络（DGNN），通过对用户域和物品域中的异质关系进行解耦，提升社交推荐效果。具体而言，通过将潜在记忆单元整合到图神经网络中，DGNN 能够利用解耦表示自动捕获异质结构依赖关系。该模型在协同异构图中，对相关用户和物品之间的关系感知信息传播与聚合进行区分。实验结果表明，与当前最先进的方法相比，DGNN 在多个真实世界推荐数据集上取得了显著更好的性能。未来，我们希望赋予 DGNN 跨领域知识迁移能力，进一步提升模型在冷启动推荐中的性能——此外，另一个潜在方向是在预训练框架下探索异构关系数据，以增强侧知识学习。

参考文献

[1] G. Adomavicius、K. Bauman、A. Tuzhilin 和 M. Unger。上下文感知推荐系统：从基础到最新进展。载于《推荐系统手册》，第 211–250 页。Springer，2022 年。[2] M. Aliannejadi 和 F. Crestani。个性化情境感知兴趣点推荐。《*ACM*信息系统汇刊》（*TOIS*），36(4)：1–28，2018 年。[3] J. L. Ba、J. R. Kiros 和 G. E. Hinton。层归一化。*arXiv* 预印本 *arXiv:1607.06450*，2016 年。[4] C. Chen、M. Zhang、Y. Liu 和 S. Ma。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。载于国际网络搜索与数据挖掘会议（*WSDM*），第 177–185 页，2019 年。[5] C. Chen、M. Zhang、C. Wang、W. Ma、M. Li、Y. Liu 和 S. Ma。用于社交感知推荐的高效自适应迁移神经网络。载于国际信息检索研究与发展会议（*SIGIR*），第 225–234 页，2019 年。[6] H. Chen、Y. Chen、X. Wang、R. Xie、R. Wang、F. Xia 和 W. Zhu。结合噪声多反馈的课程式解耦推荐。神经信息处理系统进展（*NeurIPS*），34：26924–26936，2021 年。[7] L. Chen、L. Wu、R. Hong、K. Zhang 和 M. Wang。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。载于人工智能国际会议（*AAAI*），第 27–34 页，2020 年。[8] M. Chen、C. Huang、L. Xia、W. Wei、Y. Xu 和 R. Luo。用于推荐的异构图对比学习。载于国际网络搜索与数据挖掘会议（*WSDM*），第 544–552 页，2023 年。[9] X. Chen、H. Xu、Y. Zhang、J. Tang、Y. Cao、Z. Qin 和 H. Zha。结合用户记忆网络的序列推荐。载于*ACM*国际网络搜索与数据挖掘会议（*WSDM*），第 108–116 页，2018 年。[10] A. Epasto 和 B. Perozzi。单一嵌入是否足够？学习能够捕捉多种社交情境的节点表示。载于万维网大会（*WWW*），第 394–404 页，2019 年。[11] S. Fan、J. Zhu、X. Han、C. Shi、L. Hu、B. Ma 和 Y. Li。元路径引导的异构图神经网络，用于意图推荐。载于国际知识发现与数据挖掘会议（*KDD*），第 2478–2486 页，2019 年。[12] W. Fan、Y. Ma、Q. Li、Y. He、E. Zhao、J. Tang 和 D. Yin。用于社交推荐的图神经网络。载于万维网大会（*WWW*），第 417–426 页，2019 年。[13] B. Fu、W. Zhang、G. Hu、X. Dai、S. Huang 和 J. Chen。用于社交推荐的双侧深度上下文感知调制。载于万维网大会（*WWW*），第 2524–2534 页，2021 年。[14] X. Fu、J. Zhang、Z. Meng 和 I. King。MAGNN：用于异构图嵌入的元路径聚合图神经网络。载于万维网大会（*WWW*），第 2331–2341 页。ACM，2020 年。[15] T. Gu、C. Wang、C. Wu、Y. Lou、J. Xu、C. Wang、K. Xu、C. Ye 和 Y. Song。HybridGNN：学习用于多重异构网络推荐的混合表示。载于国际数据工程会议（*ICDE*），第 1355–1367 页。IEEE，2022 年。[16] X. He、K. Deng、X. Wang、Y. Li、Y. Zhang 和 M. Wang。LightGCN：简化并增强用于推荐的图卷积网络。载于国际信息检索研究与发展会议（*SIGIR*），第 639–648 页，2020 年。[17] B. Hu、C. Shi、W. X. Zhao 和 P. S. Yu。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。载于国际知识发现与数据挖掘会议（*KDD*），第 1531–1540 页，2018 年。[18] Z. Hu、Y. Dong、K. Wang 和 Y. Sun。异构图变换器。载于万维网大会（*WWW*），第 2704–2710 页，2020 年。[19] C. Huang、H. Xu、Y. Xu、P. Dai、L. Xia、M. Lu、L. Bo、H. Xing、X. Lai 和 Y. Ye。用于社交推荐的知识感知耦合图神经网络。载于*AAAI*人工智能会议（*AAAI*），第 4115–4122 页，2021 年。

[20] H. Ji、J. Zhu、X. Wang、C. Shi、B. Wang、X. Tan、Y. Li 和 S. He。你想与谁分享？社交电子商务中的分享推荐研究。载于人工智能国际会议（AAAI），第 35 卷，第 232–239 页，2021 年。[21] B. Jin、K. Cheng、L. Zhang、Y. Fu、M. Yin 和 L. Jiang。通过用于社交推荐的多通道编码方案实现部分关系感知的影响力传播。载于信息与知识管理国际会议（CIKM），第 585–594 页，2020 年。[22] S. Kulkarni 和 S. F. Rodd。上下文感知推荐系统：前沿技术综述。《计算机科学评论》，37：100255，2020 年。[23] Z. Li、X. Shen、Y. Jiao、X. Pan、P. Zou、X. Meng、C. Yao 和 J. Bu。分层二部图神经网络：面向大规模电子商务应用。载于国际数据工程会议（ICDE），第 1677–1688 页。IEEE，2020 年。[24] C.-Y. Liu、C. Zhou、J. Wu、Y. Hu 和 L. Guo。具有关键偏好空间的社交推荐。载于人工智能国际会议（AAAI），2018 年。[25] H. Liu、L. Jing、J. Yu 和 M. K.-P. Ng。通过学习个人和社交潜在因子实现社交推荐。《知识与数据工程汇刊》（TKDE），2019 年。[26] N. Liu、Q. Tan 等。单个向量是否足够？探索网络嵌入中的节点多义性。载于国际知识发现与数据挖掘会议（KDD），第 932–940 页，2019 年。[27] X. Liu、C. Yu、Z. Zhang、Z. Zheng、Y. Rong、H. Lv、D. Huo、Y. Wang、D. Chen、J. Xu 等。神经网络拍卖：端到端学习电子商务广告的拍卖机制。载于国际知识发现与数据挖掘会议（KDD），第 3354–3364 页，2021 年。[28] X. Long、C. Huang、Y. Xu、H. Xu、P. Dai、L. Xia 和 L. Bo。基于自监督元图 Infomax 网络的社交推荐。载于国际信息与知识管理会议（CIKM），第 1160–1169 页，2021 年。[29] Y. Lyu、H. Yin、J. Liu、M. Liu、H. Liu 和 S. Deng。结合评论级解释的可靠推荐。载于国际数据工程会议（ICDE），第 1548–1558 页。IEEE，2021 年。[30] H. Ma、H. Yang 等。Sorec：使用概率矩阵分解的社交推荐。载于信息与知识管理国际会议（CIKM），第 931–940 页。ACM，2008 年。[31] H. Mezni、D. Benslimane 和 L. Bellatreche。基于知识图谱嵌入的上下文感知服务推荐。《知识与数据工程汇刊》（TKDE），第 5225–5238 页，2021 年。[32] T. Qian、Y. Liang、Q. Li、X. Ma、K. Sun 和 Z. Peng。面向新颖推荐的意图解耦与特征自监督。《知识与数据工程汇刊》（TKDE），2022 年。[33] A. Santoro、S. Bartunov、M. Botvinick、D. Wierstra 等。结合记忆增强神经网络的元学习。载于国际机器学习会议（ICML），第 1842–1850 页，2016 年。[34] C. Shi、B. Hu、W. X. Zhao 和 S. Y. Philip。用于推荐的异构信息网络嵌入。《知识与数据工程汇刊》（TKDE），31(2)：357–370，2018 年。[35] W. Song、Z. Xiao、Y. Wang、L. Charlin、M. Zhang 和 J. Tang。通过动态图注意力网络实现基于会话的社交推荐。载于国际网络搜索与数据挖掘会议（WSDM），第 555–563 页，2019 年。[36] J. Tang、X. Hu 和 H. Liu。社交推荐：综述。《社交网络分析与挖掘》（SNAM），3(4)：1113–1133，2013 年。[37] M. M. Tanjim、C. Su、E. Benjamin、D. Hu、L. Hong 和 J. McAuley。用于下一物品推荐的潜在意图注意力序列模型。载于万维网大会（WWW），第 2528–2534 页，2020 年。[38] L. Van der Maaten 和 G. Hinton。使用 t-SNE 可视化数据。《机器学习研究期刊》（JMLR），9(11)，2008 年。[39] P. Veli ˇckovi ´c、G. Cucurull、A. Casanova、A. Romero、P. Li`o 和 Y. Bengio。图注意力网络。载于学习表征国际会议（ICLR），2018 年。[40] X. Wang、H. Chen、Y. Zhou、J. Ma 和 W. Zhu。用于推荐的解耦表示学习。《模式分析与机器智能汇刊》（TPAMI），第 408–424 页，2022 年。[41] X. Wang、H. Chen 和 W. Zhu。用于推荐的多模态解耦表征。载于多媒体与博览会国际会议（ICME），第 1–6 页。IEEE，2021 年。[42] X. Wang、X. He、Y. Cao、M. Liu 和 T.-S. Chua。Kgat：用于推荐的知识图注意力网络。载于 知识发现与数据挖掘国际会议（*KDD*），第 950–958 页，2019 年。[43] X. Wang、X. He、M. Wang、F. Feng 和 T.-S. Chua。神经图协同过滤。载于 国际信息检索研究与发展会议（*SIGIR*），第 165–174 页。ACM，2019 年。[44] X. Wang、T. Huang、D. Wang、Y. Yuan、Z. Liu、X. He 和 T.-S. Chua。利用知识图学习交互背后的意图，以用于推荐。载于 万维网大会（*WWW*），第 878–887 页，2021 年。[45] X. Wang、H. Ji、C. Shi、B. Wang、Y. Ye、P. Cui 和 P. S. Yu。异构图注意力网络。载于 万维网大会（*WWW*），第 2022–2032 页。ACM，2019 年。[46] X. Wang、H. Jin、A. Zhang、X. He 等。解耦图协同过滤。载于 国际信息检索研究与发展会议（*SIGIR*），第 1001–1010 页，2020 年。[47] Y. Wang、S. Tang、Y. Lei、W. Song、S. Wang 和 M. Zhang。Disenhan：用于推荐的解耦异构图注意力网络。载于 国际信息与知识管理会议（*CIKM*），第 1605–1614 页，2020 年。[48] W. Wei、C. Huang、L. Xia、Y. Xu、J. Zhao 和 D. Yin。结合行为多样性的推荐对比元学习。载于 国际网络搜索与数据挖掘会议（*WSDM*），第 1120–1128 页，2022 年。[49] L. Wu、C. Quan、C. Li、Q. Wang、B. Zheng 和 X. Luo。面向物品推荐的上下文感知用户—物品表示学习。*ACM*信息系统汇刊（*TOIS*），37(2)：1–29，2019 年。[50] L. Wu、P. Sun、Y. Fu、R. Hong、X. Wang 和 M. Wang。用于社交推荐的神经影响力扩散模型。载于 国际信息检索研究与发展会议（*SIGIR*），第 235–244 页，2019 年。[51] Q. Wu、H. Zhang、X. Gao、P. He、P. Weng、H. Gao 和 G. Chen。双图注意力网络：推荐系统中多方面社交影响的深层潜在表示。载于 万维网大会（*WWW*），第 2091–2102 页，2019 年。[52] L. Xia、C. Huang、Y. Xu、J. Zhao、D. Yin 和 J. Huang。超图对比协同过滤。载于 国际信息检索研究与发展会议（*SIGIR*），第 70–79 页，2022 年。[53] L. Xiao、Z. Min、Z. Yongfeng、L. Yiqun 和 M. Shaoping。为个性化推荐学习并迁移社交与物品可见度。载于 信息与知识管理国际会议（*CIKM*），第 337–346 页，2017 年。[54] T. Xie、Y. Xu、L. Chen、Y. Liu 等。动态异构信息网络上的序列推荐。载于 国际数据工程会议（*ICDE*），第 2105–2110 页。IEEE，2021 年。[55] X. Xie、F. Sun、Z. Liu、S. Wu、J. Gao、J. Zhang 等。用于序列推荐的对比学习。载于 国际数据工程会议（*ICDE*），第 1259–1273 页。IEEE，2022 年。[56] X. Xin、X. He、Y. Zhang、Y. Zhang 和 J. Jose。关系协同过滤：为推荐建模多种物品关系。载于国际信息检索研究与发展会议（*SIGIR*），第 125–134 页，2019 年。[57] F. Xu、J. Lian、Z. Han、Y. Li、Y. Xu 和 X. Xie。关系感知图卷积网络：用于代理发起的社交电商推荐。载于 信息与知识管理国际会议（*CIKM*），2019 年。[58] B. Yang、Y. Lei、J. Liu 和 W. Li。基于信任的社交协同过滤。*IEEE*模式分析与机器智能汇刊（*TPAMI*），39(8)：1633–1647，2016 年。[59] Y. Yang、C. Huang、L. Xia 和 C. Li。用于推荐的知识图对比学习。载于 国际信息检索研究与发展会议（*SIGIR*），第 1434–1443 页，2022 年。[60] J. Yu、H. Yin、J. Li、M. Gao、Z. Huang 和 L. Cui。利用对抗图卷积网络增强社交推荐。《知识与数据工程汇刊》（*TKDE*），2020 年。[61] J. Yu、H. Yin、J. Li、Q. Wang、N. Q. V. Hung 和 X. Zhang。用于社交推荐的自监督多通道超图卷积网络。载于 万维网大会（*WWW*），第 413–424 页，2021 年。