

基于双通道异质超图神经网络的引文推荐方法^{*}

李瑞红, 李晓红, 姚 锦, 王闪闪

(西北师范大学计算机科学与工程学院, 甘肃 兰州 730070)

摘 要: 针对现有引文推荐方法侧重于使用图结构建模二元关系, 对节点类型和交互关系的多元化及多样性表示不足的问题, 提出了基于双通道异质超图神经网络的引文推荐方法。首先, 构建异质图, 利用卷积神经网络和 Transformer 分别编码异质图中各个节点的局部和全局语义特征, 获得异质图通道上关于目标节点的结构表征。其次, 设计多种类型的超边, 扩展异构数据信息。再次, 使用超图编码节点间的交互, 并利用超图神经网络捕获超图中潜在的复杂高阶语义关系, 获得超图通道上关于目标节点的语义表征。最后, 聚合 2 个通道上的信息, 得到目标节点的最终语义表示, 并计算目标论文节点与候选论文节点间的相关性, 生成引用文献推荐列表。在 DBLP 和 PubMed 数据集上的实验结果表明, 所提出的方法能有效提升引文推荐的质量, 获得较好的推荐结果。

关键词: 引文推荐; 异质图; 超图神经网络; 信息融合

中图分类号: TP391

文献标志码: A

doi: 10. 3969/j. issn. 1007-130X. 2025. 02. 018

A citation recommendation method based on dual-channel heterogeneous hypergraph neural networks

LI Ruihong, LI Xiaohong, YAO Jin, WANG Shanshan

(College of Computer Science & Engineering, Northwest Normal University, Lanzhou 730070, China)

Abstract: Addressing the issue that existing citation recommendation methods primarily focus on modeling binary relationships using graph structures, and lack sufficient representation of the diversity and variety of node types and interaction relationships, a citation recommendation method based on dual-channel heterogeneous hypergraph neural networks is proposed. Firstly, a heterogeneous graph is constructed, convolutional neural networks (CNNs) and Transformers are utilized to encode the local and global semantic features of each node in the heterogeneous graph, respectively, obtaining structural representations of the target node on the heterogeneous graph channel. Secondly, multiple types of hyperedges are designed to expand heterogeneous data information. Thirdly, a hypergraph is used to encode interactions between nodes, and a hypergraph neural network is employed to capture potential complex high-order semantic relationships in the hypergraph, obtaining semantic representations of the target node on the hypergraph channel. Finally, information from the two channels is aggregated to obtain the final semantic representation of the target node. The correlation between the target paper node and candidate paper nodes is calculated to generate a citation recommendation list. Experimental results on the DBLP and PubMed datasets demonstrate that the proposed method can effectively improve the quality of citation recommendations and achieve better recommendation outcomes.

^{*} 收稿日期: 2023-07-03; 修回日期: 2024-05-06

基金项目: 国家自然科学基金(61862058); 甘肃省科技计划(20JR5RA518); 甘肃省自然科学基金(20JR10RA076); 西北师范大学科研项目(NWNU-LKQN2022-03)

通信作者: 李晓红(xiaohongli@nwnu.edu.cn)

通信地址: 730070 甘肃省兰州市安宁东路 967 号西北师范大学计算机科学与工程学院。

Address: College of Computer Science & Engineering, Northwest Normal University, 967 An'ning East Road, Lanzhou 730070, Gansu, P. R. China

Key words: citation recommendation; heterogeneous graph; hypergraph neural network; information fusion

1 引言

在互联网技术革命的推动下,学术信息的数量在网络上快速增长,导致研究人员难以高效、准确地从海量文献数据库中检索到最合适的文献。因此,如何高效地从互联网上找到合适的引用文献,从而高质量地进行学术写作成为每一个科研人员面临的问题^[1]。

引文推荐旨在利用目标论文中蕴含的元数据信息设计模型,帮助研究人员快速有效地找到与他们的信息需求和研究兴趣相匹配的相关引用文献。引文推荐方法主要有基于内容的推荐、基于协同过滤的推荐、基于图(网络)的推荐以及混合方式的推荐。基于内容的引文推荐根据目标论文的元数据探索与候选论文的相关性,并推荐相似的文献给研究人员。DU 等人^[2]使用基于注意力机制的卷积神经网络计算查询目标论文与候选论文之间的相关性,以解决个性化引文推荐问题。基于协同过滤的引文推荐根据目标论文及其相似论文的评分或反馈推荐引文。比如 DeepCite^[3]利用 BERT(Bidirectional Encoder Representations from Transformers)提取文本中的高级语义表示向量,然后利用多尺度卷积神经网络模型和 BiLSTM(Bidirectional Long Short-Term Memory)模型获取句子中上下文的局部信息和序列信息,对文本向量进行深度匹配生成候选集,用协同过滤方法生成论文推荐列表。CNCRec(Collaborative filtering with Network representation learning framework for Citation Recommendation)^[4]同时考虑了论文内容和网络拓扑结构,利用基于属性的引文网络表示学习创建论文评级矩阵,其中属性是从论文文本信息中提取的主题。

异质信息网络由于能够自然地表征推荐系统中复杂的对象和丰富的关系,已成为引文推荐任务中一个新的研究方向。YANG 等人^[5]提出将引文推荐问题视为学术论文异质信息网络中的隐藏链接预测问题,基于论文、作者和发表期刊信息进行引文推荐。CHEN 等人^[6]将学术论文异质信息网络中除论文节点之外的其他节点作为辅助信息,学习语义更加丰富的目标节点嵌入,完成引文推荐任务。段震等人^[7]构建包含语义链接的异质信息网络,通过对每个论文节点分别进行基于元路径的游

走和随机游走生成混合随机游走序列,进而使用 skip-gram 模型学习节点嵌入,计算相似性获得相应全局引文推荐列表。ALI 等人^[8]从共享嵌入和基本嵌入 2 个角度学习异质信息网络节点嵌入表示,利用注意力机制捕捉与每个语义关系相关的最具影响力的特征,从而有效利用网络的异质性缓解数据稀疏问题,生成个性化的引文推荐列表。MA 等人^[9]提出基于异质信息网络的个性化引文推荐方法,采用 2 种基于元路径的邻近性度量来查找邻居的相似性,并基于目标论文特征向量和候选论文特征向量生成推荐列表。异质图虽然可以建模多类型的节点和关系,却无法体现论文元数据关系的多元化,捕获复杂的高阶交互存在局限性。

随着图神经网络的发展,研究人员开始利用网络表示学习方法实现引文推荐。TANG 等人^[10]提出一种新的网络嵌入方法 LINE(Large-scale Information Network Embedding),将大型信息网络嵌入到低维向量空间,同时保持网络的局部结构和全局结构。LONG 等人^[11]将标题视为相对于论文内容的总结性和信息性的句子,基于双向门控循环单元和注意力机制集成论文标题和引文上下文建模目标论文表示实现局部引文推荐任务。YU 等人^[12]基于用户与论文间的复杂关系构建学术论文关系超图,基于超图卷积神经网络挖掘论文间的高阶相似度,向正在撰写论文的研究人员提供可引用的高质量的文献列表。

上述方法存在对节点类型和交互关系二者的多元化及多样性表示不足的问题。为此,本文尝试研究异质图和超图在引文推荐场景中的应用,提出了一种基于双通道异质超图神经网络的引文推荐方法 DHCR(Dual channel heterogeneous Hypergraph neural network for global Citation Recommendation)。在异质图通道中使用 Transformer 和 CNN(Convolutional Neural Network)编码节点的局部和全局语义关系,在超图通道中利用超图神经网络学习节点间的高阶关系模式。有机结合上述 2 个通道上的信息,得到目标节点的最终语义表示。最后,与候选论文节点进行相关性匹配,生成引用文献推荐列表。在 DBLP 和 PubMed 数据集上的实验结果表明,本文提出的方法能有效提升引文推荐的质量,获得较好的推荐结果。

2 问题描述

异质图表示为 $HetG = (V, E, T, R)$, 其中, V 表示节点集合, E 表示边集合, T 表示节点类型集合, R 表示边类型集合。 p^b 表示目标论文节点的初始嵌入。基于异质图通道的目标节点的表示为 p^s 。超图表示为 $HG = (V, \zeta, \epsilon)$, 超边类型集合 $HT = \{e_1, e_2, e_3\}$, e_j^i 表示第 i 条 e_j 类型的超边, $j \in \{1, 2, 3\}$ 。基于超图通道的目标节点表示为 p^h 。本文提出的 DHCR 方法如图 1 所示。该方法分为异质图通道节点表示和超图通道的节点嵌入 2 个部分。异质图通道通过 CNN 和 Transformer 分别捕获节点的局部语义和全局语义, 融合以后得到该通道上节点的表示; 超图通道利用超图神经网络学习节点在 3 种超边类型下的表示, 并将其融合起来; 最后将 2 个通道上的节点表示以及节点初始特征进行组合, 获得节点的最终嵌入, 进而实现引文推荐的目标。

3 引文推荐方法

3.1 基于异质图通道的节点表示

3.1.1 异质图构建

在全局引文推荐场景中存在着作者、论文、期刊、关键词等多种信息, 且它们之间存在着错综复杂的关系, 如何定义及表示它们之间的多元关系和复杂交互对于引文推荐有重要作用。同质图只能表示单一类型的节点及节点之间单一类型的关系, 不适合现实生活中的全局引文推荐任务。而异质

图包含多种类型的节点和关系, 适合捕获不同类型节点间的复杂交互。因此, 本节考虑构建异质图建模全局引文推荐场景, 以学习目标节点的结构表征和语义表示。

图 2 所示为异质图及其网络模式, 其中图 2b 是图 2a 的网络模式。图 2b 包含 4 种类型的节点, 分别是作者(A)、论文(P)、发表期刊(J)和论文所含关键词(K), 此外, 还有 3 种类型的关系: $\{A-P, P-J, P-K\}$, 其中, $A-P$ 表示作者与论文之间的写作关系, $P-J$ 表示论文与期刊之间的发表关系, $P-K$ 表示论文和关键词之间的包含关系。基于上述信息构建异质图 $HetG = (V, E, T, R)$, $V = \{v_1, \dots, v_n\}$ 表示节点集合, E 表示边集, $T = \{A, P, J, K\}$, $R = \{A-P, P-J, P-K\}$, 且 $|T| + |R| > 2$ 。节点类型映射函数 $\varphi: V \rightarrow T$ 和边类型映射函数 $\psi: E \rightarrow R$ 。 $HetG$ 的邻接矩阵记为 A , 当节点 v_p 与 v_r 之间存在边时, 记 $A_{pr} = 1$, 否则 $A_{pr} = 0$ 。




Figure 2 Heterogeneous graphs and their network patterns

图 2 异质图及其网络模式

3.1.2 基于异质图的特征捕获

为了挖掘异质图中存在的结构信息, 捕获目标




Figure 1 Structure of DHCR method

图 1 DHCR 方法结构

节点邻域集合节点间的局部和全局相关性,本文设计基于 Transformer 和 CNN 的交互模块,学习目标节点在结构层面上的特征表示。

设节点 v_p 的邻域集合为 $N(v_p) = \{A(v_p), J(v_p), K(v_p)\}$, 其中, $A(v_p) = \{a_1, \dots, a_m\}$ 表示论文节点相关的作者, $J(v_p) = \{j\}$ 表示论文节点发表的期刊, $K(v_p) = \{k_1, \dots, k_q\}$ 表示论文节点包含的关键词。

首先,分别将 $A(v_p)$ 、 $J(v_p)$ 和 $K(v_p)$ 通过嵌入层进行处理,得到初始嵌入 $(a'_1, \dots, a'_m), (j'), (k'_1, \dots, k'_q)$ 。值得注意的是,若 v_p 是目标论文节点,则 $N(v_p) = \{A(v_p), K(v_p)\}$ 。由于节点的异质性,不同类型的节点具有不同的特征空间。因此,将 $(a'_1, \dots, a'_m), (j'), (k'_1, \dots, k'_q)$ 分别投影到统一的特征空间,得到 $\{a_1, \dots, a_m\}, \{j\}, \{k_1, \dots, k_q\}$, 如式(1)所示:

$$x = M_\varphi \cdot x' \quad (1)$$

其中, M_φ 为节点类型 φ 特定的转换矩阵。将节点的邻域信息堆叠,作为目标节点的初始嵌入 $E \in \mathbf{R}^{d \times (m+q+1)}$, 如式(2)所示:

$$E = a_1 \parallel \dots \parallel a_m \parallel j \parallel k_1 \parallel \dots \parallel k_q \quad (2)$$

其次,异质图中节点间的边可以描述论文与作者、期刊、关键词之间的交互。目标节点的邻居节点之间虽然没有连边,但它们之间的局部相关性对于目标节点的表示有着重要影响。而 CNN 能有效提取局部上下文特征,是对局部上下文信息建模的理想原语,可以提取目标节点的邻域集合中节点间的相关性,因此本文考虑使用 TextCNN 获取目标节点的局部特征表示。

TextCNN 的输入是目标节点初始嵌入 E ,通过卷积建模节点之间的语义关系,如式(3)所示:

$$c = \sigma(E * f + b_1) \quad (3)$$

其中, f 为卷积核, b_1 为偏置, $\sigma(\cdot)$ 为 Sigmoid 函数, c 是通过卷积核捕获的特征向量。 F 个卷积核从不同角度提取目标节点的特征,并采用最大池化策略进行信息聚合,获得目标节点的局部特征表示向量 p^{loc} , 如式(4)所示:

$$p^{\text{loc}} = \sigma(W \cdot [c_1, \dots, c_F] + b_2) \quad (4)$$

其中, W 为权重, b_2 为偏置。

最后,目标节点的邻居节点之间虽然没有连边,但并不意味着它们之间就没有语义关系。卷积的局部性限制其无法捕获节点间长距离的依赖关系。因此,本文使用 Transformer 建模全局上下文信息,全局特征表示向量 p^{glo} 的计算过程如式(5)所示:

$$p^{\text{glo}} = \text{Transformer}(E) \quad (5)$$

3.1.3 异质图特征融合

由于局部特征和全局特征各自包含非常丰富的信息,对它们进行聚合将极大提高特征表示的质量。因此,本文在异质图中,将 CNN 捕获的局部特征与 Transformer 学习到的全局依赖进行融合,获得目标节点基于异质图通道上的特征表示 p^s , 计算过程如式(6)所示:

$$p^s = p^{\text{loc}} + p^{\text{glo}} \quad (6)$$

3.2 基于超图通道的节点嵌入

3.2.1 超图构建

虽然异质图可以建模多种类型的节点及多种类型的关系,但是仅限于二元关系建模。而引文推荐场景中论文、作者、期刊和关键词之间的复杂交互超越了异质图能捕获到的成对关系。因超图不限制超边中的节点数,适合捕获多个节点间的高阶关联,且受文献[12]的启发,本节考虑目标论文与作者、期刊、关键词、候选论文之间的关系,设计以下3种类型的超边:

1) 基于论文间共同期刊关系的超边。若2篇以上的论文发表在同一期刊上,则它们构成的集合定义为超边,类型为 e_1 。

2) 基于论文间共同关键词关系的超边。若2篇论文包含相同的关键词,则它们构成的集合定义为超边,类型为 e_2 。

3) 基于论文间共同作者关系的超边。若作者撰写了2篇或2篇以上的论文,则它们构成的集合定义为超边,类型为 e_3 。

在异质图基础上构建超图 $HG = (V, \zeta, \epsilon)$, 其中, V 表示超图的节点集合, ζ 表示超边集合, ϵ 表示权重集合,将超边权重统一设置为1。超图 HG 的关联矩阵表示为 H , 当节点 $v_p \in \zeta_s$ 时, H 中元素 $H_{ps} = 1$, 否则 $H_{ps} = 0$ 。超图 HG 通过嵌入层处理后得到节点的初始属性矩阵 $X^{(0)}$ 。超边类型集合 $HT = \{e_1, e_2, e_3\}$, 用 e_j^i 表示第 i 条 e_j 类型的超边, $j \in \{1, 2, 3\}$ 。

3.2.2 基于超图神经网络的节点表示

图神经网络通过建模节点间的成对链接学习图中节点的表示,超图中的超边可包含多对多的高阶关系,不同类型的超边又体现不同的语义信息,适合捕获引文推荐场景下节点间的复杂交互。因此,本文设计3个独立的超图神经网络分别学习节点在3种超边类型下的表示,每个超图神经网络均

以两阶段方式聚合并更新超边及节点表示。若节点是目标论文节点,则只考虑 e_2 和 e_3 这 2 种类型的超边。

第 1 阶段聚合超边所含各节点的信息,将其更新为超边的嵌入,如式(7)所示:

$$\mathbf{B}_j^{(l)} = \mathbf{H}^T \cdot \mathbf{D}_v^{-1/2} \cdot \mathbf{X}_j^{(l)} \cdot \boldsymbol{\Theta}^{(l)} \quad (7)$$

其中, $\mathbf{B}_j^{(l)}$ 表示第 l 层超图神经网络上 e_j 类型超边的嵌入, $\mathbf{D}_v$ 表示节点度矩阵, $\mathbf{X}_j^{(l)}$ 表示超边 e_j 类型下第 l 层超图神经网络上的节点嵌入, $\boldsymbol{\Theta}^{(l)}$ 表示第 l 层超图神经网络的可训练的参数矩阵。如图 3a 所示,若超边 $e_1^1 = \{p_1, p_2, p_3, a_1\}$,则可用式(7)将 p_1, p_2, p_3, a_1 的属性信息聚合起来,用于表示超边 e_1^1 的嵌入。




Figure 3 Legend of hypergraph convolutional neural network
图 3 超图卷积神经网络图例

第 2 阶段聚合每个节点所属超边的信息,将其更新为节点的向量表示,如式(8)所示:

$$\mathbf{X}_j^{(l+1)} = \sigma(\mathbf{D}_e^{-1/2} \cdot \mathbf{H} \cdot \mathbf{W} \cdot \mathbf{D}_e^{-1} \cdot \mathbf{B}_j) \quad (8)$$

其中, $\mathbf{D}_e$ 表示超边度矩阵, $\sigma(\cdot)$ 表示 Sigmoid 激活函数。如图 3b 所示,若节点 $p_1 \in e_1^1, p_1 \in e_1^3, p_1 \in e_1^5$,则可用式(8)将超边 e_1^1, e_1^3, e_1^5 的信息聚合起来,用于表示节点 p_1 的嵌入。

迭代上述 2 个阶段,在每次迭代过程中更新传递高阶消息。经过 L 层超图神经网络传递后,得到 e_j 类型的超边下节点的语义表示 $\mathbf{p}_j$, 如式(9)所示:

$$\mathbf{p}_j = \sum_{l=1}^L \mathbf{X}_j^{(l)} \quad (9)$$

融合不同超边类型下的节点表示得到基于超图通道的节点嵌入 $\mathbf{p}^h$, 如式(10)所示:

$$\mathbf{p}^h = \sum_{j=1}^3 \mathbf{p}_j \quad (10)$$

3.3 双通道特征融合及推荐

异质图可以建模多种类型的节点及多种类型的关系,超图因其不限制超边中的节点数适合捕获多个节点间的高阶关联,将这 2 部分学习到的表示进行双通道特征融合,能够极大地增强节点表示的质量。至此,已经学习到目标节点在异质图通道的

特征表示 $\mathbf{p}^s$ 和超图通道的特征表示 $\mathbf{p}^h$, 接下来将它们与目标节点的初始嵌入 $\mathbf{p}^b$ 拼接起来,得到目标节点的最终嵌入表示 $\mathbf{p}_t$, 如式(11)所示:

$$\mathbf{p}_t = \mathbf{W}_m (\mathbf{p}^b \parallel \mathbf{p}^s \parallel \mathbf{p}^h) + \mathbf{b}_m \quad (11)$$

其中, $\mathbf{W}_m$ 和 $\mathbf{b}_m$ 分别表示权重与偏置项。

至此,已捕获目标论文节点的语义信息。为了计算目标论文节点与候选论文节点之间的相关性,本文将目标论文节点的最终嵌入记为 $\mathbf{p}_t$, 候选论文节点的嵌入记为 $\mathbf{p}_c$, 计算目标论文引用候选论文的概率 $\hat{y}$, 如式(12)所示:

$$\hat{y} = \mathbf{p}_t \cdot \mathbf{p}_c \quad (12)$$

4 损失函数的设计

受图上自监督学习成功的启发,本文在异质图和超图的 2 个通道之间设计自监督信号,将推荐任务(主任务)和自监督任务(辅助任务)合并到一个主辅学习框架中,共同学习提高引文推荐的性能。推荐任务选取交叉熵损失函数作为目标函数。在自监督任务中,可将 DHCR 的 2 个通道认为是 2 个视图,通过 2 个视图的节点表示对比学习目标节点嵌入,将样本实际引用的论文作为正样本,将损坏的样本作为负样本,利用二元交叉熵损失函数学习正负样本间的损失,如式(13)~式(15)所示:

$$L_r = - \sum_{n=1}^N \mathbf{y}_n \log(\mathbf{p}_t \cdot \mathbf{p}_c) - \sum_{n=1}^N (1 - \mathbf{y}_n) \log(1 - (\mathbf{p}_t \cdot \mathbf{p}_c)) \quad (13)$$

$$L_s = -\log \sigma(f_D(\mathbf{p}_t^r, \mathbf{p}_t^h)) - \log \sigma(1 - f_D(\tilde{\mathbf{p}}_t^r, \mathbf{p}_t^h)) \quad (14)$$

$$L = L_r + L_s \quad (15)$$

其中, L_r 表示主任务损失函数, L_s 表示辅助任务损失函数, $\mathbf{y}_n$ 表示第 n 个样本实际引用论文的 one-hot 编码向量, $\sigma(\cdot)$ 表示 Sigmoid 函数, 判别函数 $f_D(\cdot)$ 用于计算输入特征间的相关性, $(\mathbf{p}_t^r, \mathbf{p}_t^h)$ 表示正样本, $(\tilde{\mathbf{p}}_t^r, \mathbf{p}_t^h)$ 表示负样本。

5 实验与结果分析

本节通过实验验证本文 DHCR 方法在引文推荐任务中的有效性,基于 DHCR 的特性,设置了 3 个实验研究以下问题:

问题 1: 与基线方法相比, DHCR 是否提高了引文推荐的性能?

问题 2: DHCR 中的不同组件对引文推荐的性能有何种影响?

问题 3: DHCR 方法中超图神经网络层数如何

影响引文推荐的性能?

5.1 数据集和实验设置

为了评估 DHCR 方法的性能,本文选取引文推荐领域广泛使用的公开数据集:DBLP 和 PubMed 进行实验。DBLP 数据集中保存了计算机科学及相关领域的文章和书籍,本文从 DBLP V12 中提取了一个包含 35 081 篇论文、24 406 位作者和 907 种期刊的子集,将数据集按年份划分,训练集包括 2013 年之前的论文,将其他的论文归入测试集,平均每篇论文被引用 4 次。PubMed 数据集包含 47 347 篇医学领域的科学论文、42 441 位作者以及 855 种期刊,平均每篇论文引用 17 篇文献,数据集中包括标题、摘要、位置、作者、引用和关键词,使用 2010 年之前的论文作为训练集,2010~2013 年的论文作为测试集。表 1 描述了数据集相关信息。

Table 1 Statistics of DBLP and PubMed datasets

表 1 DBLP 和 PubMed 数据集信息

数据集	论文数	作者数	期刊数	关键词数
DBLP	35 081	24 406	907	8 615
PubMed	47 347	42 441	855	5 345

实验设置:参考原始论文中报告的基线方法的最佳参数设置,然后使用网格搜索对基线方法的所有超参数进行微调,以确保其性能最佳。对于所有模型的一般设置,嵌入的维数设置为 50,正则化因子 $\lambda=0.001$,批处理大小设置为 2 000。使用 Adam 来优化这些方法,在实验中将每种方法运行 10 次取平均值。

5.2 评价指标

在实验中,选择推荐系统中广泛使用的精确率 $precision@z$ 、召回率 $recall@z$ 和平均倒数排名 MRR (Mean Reciprocal Rank) 作为评价指标。精确率指样本中真实结果被方法预测为真的比例;召回率指方法预测为真的正例占全部正例的比率;平均倒数排名反映真实引用的论文在方法预测结果列表中的排名,强调位置关系。其计算分别如式(16)~式(18)所示:

$$precision@z = \frac{1}{Q} \sum_{b=1}^Q \frac{|R_b \cap T_b|}{|R_b|} \quad (16)$$

$$recall@z = \frac{1}{Q} \sum_{b=1}^Q \frac{|R_b \cap T_b|}{|T_b|} \quad (17)$$

$$MRR = \frac{1}{Q} \sum_{b=1}^Q \frac{1}{p_b} \quad (18)$$

其中, $precision@z$ 表示前 z 篇引文的精确率;

$recall@z$ 表示前 z 篇引文的召回率; Q 表示原文总数; R_b 表示第 b 篇原文的前 z 篇推荐引文集合; T_b 表示第 b 篇原文的实际引文集合; $|\cdot|$ 表示集合的基数; p_b 表示对于第 b 篇原文,推荐表中第 1 个在真值结果中的引文所在的排列位置。

5.3 基线方法

DeepWalk^[13]:通过截断的随机游走获得局部特征学习节点潜在的表示。

LINE^[10]:适用于大规模信息网络的网络嵌入方法,通过设计一阶邻近度和二阶邻近度,同时保留局部和全局网络结构。

metapath2vec^[14]:基于元路径进行随机游走构建节点邻域,通过 skip-gram 模型学习节点嵌入,可识别不同网络间的结构和语义相关性。

CRM-HIN (Citation Recommendation Method based on Heterogeneous Information Network representation learn)^[7]:在异质信息网络中先后进行元路径游走和随机游走学习异质信息网络中的节点嵌入,实现引文推荐。

GCR-GAN (Global Citation Recommendation employing Generative Adversarial Network)^[15]:利用去噪自动编码器捕获异质网络结构间的接近性和语义相关性,基于生成对抗网络学习论文表示,实现引文推荐。

L-HGCF (Light HyperGraph based Collaborative Filtering)^[12]:通过构建论文关系超图,使用超图神经网络实现多特征融合,挖掘论文间的高阶相似度,提供可信推荐。

DHCR-s:去除 DHCR 中的自监督学习任务,表示只利用推荐任务学习的引文推荐方法。

5.4 实验结果与分析

5.4.1 对比实验

DHCR 方法与基线方法进行对比实验的结果如表 2 和表 3 所示。

可以得到以下观察结果:DHCR-s 在引文推荐任务中表现出色,即使没有自监督学习,它也超过了所有基线方法,同时,自监督学习对进一步提高 DHCR 的推荐性能起到了较大作用;L-HGCF 是一个非常强的基线方法,在不考虑 DHCR 及其去除自监督变体的情况下,L-HGCF 在大多数情况下表现出最优的性能;对于引文网络,融合引文图中丰富的异质信息使它们表现出更好的性能。总体来说,由于 DHCR 分别从异质图和超图 2 个通道学习目标节点表示,和基线方法相比,在引文推

荐任务中取得了最好的结果。

Table 2 Comparative experiments of DHCR method with other baseline methods on DBLP dataset

表 2 DHCR 方法与其他基线方法在 DBLP 数据集上的对比实验

方法	<i>precision@20</i>	<i>recall@20</i>	<i>MRR</i>
LINE	0.391	0.452	0.695
DeepWalk	0.384	0.440	0.658
CRM-HIN	0.455	0.494	0.742
metapath2vec	0.417	0.475	0.729
L-HGCF	0.487	0.541	0.797
GCR-GAN	0.472	0.523	0.751
DHCR-s	0.476	0.538	0.807
DHCR	0.492	0.563	0.810

Table 3 Comparative experiments of DHCR method with other baseline methods on PubMed dataset

表 3 DHCR 方法与其他基线方法在 PubMed 数据集上的对比实验

方法	<i>precision@20</i>	<i>recall@20</i>	<i>MRR</i>
LINE	0.507	0.397	0.648
DeepWalk	0.483	0.402	0.624
CRM-HIN	0.524	0.463	0.738
metapath2vec	0.509	0.442	0.693
L-HGCF	0.558	0.507	0.746
GCR-GAN	0.537	0.489	0.734
DHCR-s	0.591	0.513	0.750
DHCR	0.605	0.529	0.752

5.4.2 消融实验

本节设计了 2 个消融实验,分别是双通道的消融实验和超边类型的消融实验,以验证 DHCR 中各模块对推荐性能的影响。

1) 双通道的消融实验。

①DHCR-HG 只包含异质图通道;

②DHCR-HeG 只包含超图通道;

③DHCR 包含异质图通道和超图通道。

从图 4 和图 5 的实验结果可以观察到,删除任何通道都会导致推荐性能下降。超图通道对最终性能的贡献最大,如果没有这个通道,DHCR 方法的性能将下降到表 2 和表 3 所示的 GCR-GAN 和 CRM-HIN 水平。相比之下,异质图通道对最终性能有影响,但是影响略小。

2) 超边类型的消融实验。

①DHCR-CA 包含论文间共同作者关系超边;

②DHCR-CAV 包含论文间共同作者关系超




Figure 4 Ablation experiment on DBLP dataset

图 4 DBLP 数据集上的消融实验




Figure 5 Ablation experiment on PubMed dataset

图 5 PubMed 数据集上的消融实验

边和论文间共同期刊关系超边;

③DHCR-CAK 包含论文间的共同作者关系和论文间共同关键词关系超边;

④DHCR 结合了所有 3 种类型超边。

从图 6 和图 7 的实验结果可以看出,由于 DHCR 建模的灵活性,本文提出的超边属性组合方法取得了优异的性能。DHCR 能够满足复杂关系描述和多特征融合的需要。DHCR-CA 只使用了论文间共同作者关系的超边,结果比其他几种方法差。DHCR-CAV 和 DHCR-CAK 分别在论文间共同作者关系的超边上增加了论文间共同期刊的超边和论文间共同关键词关系的超边。DHCR-CAV 得到了比 DHCR-CAK 更好的结果,说明论文间共关键词关系的超边对于引文推荐任务的重要性高于论文间共期刊关系的超边的。




Figure 6 Ablation experiment of hyperedge types on DBLP dataset

图 6 DBLP 数据集上超边类型的消融实验




Figure 7 Ablation experiment of hyperedge types on PubMed dataset

图7 PubMed数据集上超边类型的消融实验

5.4.3 超参数敏感度实验

本节研究超图神经网络层数 L 对引文推荐性能的影响,以找到最佳超图神经网络的深度,堆叠层数从1~5层不等。

如图8和图9所示,DHCR深度为2时性能最佳,层数持续增加时,DHCR性能下降。在所有数据集上的超参数敏感度实验中,较低层数的DHCR表现出更优秀的性能。一个可能的原因是DHCR聚集了来自远距离邻居的高阶信息,因此,由于过度平滑,随着深度的增加,更有可能遇到问题。同样基于超图建模的L-HGCF中也出现了这个问题。考虑到过度平滑表示可能是超图卷积网络模型中的一个常见问题,将在未来对其进行研究。




Figure 8 Hyperparameter sensitivity on DBLP dataset

图8 DBLP数据集上超参数敏感度实验




Figure 9 Hyperparameter sensitivity on PubMed dataset

图9 PubMed数据集上超参数敏感度实验

6 结束语

本文分别引入异质图、超图及超图神经网络捕

获多元高阶复杂关系,提出的基于双通道异质超图神经网络的引文推荐方法从异质图和超图2个通道中捕获丰富的领域节点特征信息,设计双图模型捕获复杂的高阶关系建模目标节点特征表示,在网络中生成高质量的引文推荐结果。实验结果验证了该方法的有效性。在未来,将探索异质超图中的元路径对引文推荐性能的影响,也将进一步探索强化学习在引文推荐任务中的应用。

参考文献:

- [1] PILLAI R S, R D L. A survey on citation recommendation system[C]//2022 3rd International Conference on Intelligent Computing, Instrumentation and Control Technologies, 2022: 423-429.
- [2] DU Z V, TANG J, DING Y H. Polar: Attention-based CNN for one-shot personalized article recommendation[C]//European Conference on Machine Learning and Knowledge Discovery in Databases, 2019: 675-690.
- [3] WANG L P, RAO Y, BIAN Q Y, et al. Content-based hybrid deep neural network citation recommendation method[C]//Proceedings of the 6th International Conference of Pioneering Computer Scientists, Engineers and Educators, 2020: 3-20.
- [4] WANG W, TANG T, XIA F, et al. Collaborative filtering with network representation learning for citation recommendation[J]. IEEE Transactions on Big Data, 2022, 8(5): 1233-1246.
- [5] YANG L B, ZHANG Z Q, CAI X Y, et al. Citation recommendation as edge prediction in heterogeneous bibliographic network: A network representation approach[J]. IEEE Access, 2019, 7: 23232-23239.
- [6] CHEN J, LIU Y, ZHAO S, et al. Citation recommendation based on weighted heterogeneous information network containing semantic linking[C]//2019 IEEE International Conference on Multimedia and Expo, 2019: 31-36.
- [7] 段震, 余豪, 赵妹, 等. 基于异质信息网络表示学习的引文推荐方法[J]. 小型微型计算机系统, 2021, 42(8): 1591-1597.
DUAN Zhen, YU Hao, ZHAO Shu, et al. Citation recommendation method based on heterogeneous information network representation learning[J]. Journal of Chinese Computer Systems, 2021, 42(8): 1591-1597.
- [8] ALI Z F, QI G L, MUHAMMAD K, et al. Global citation recommendation employing multi-view heterogeneous network embedding[C]//2021 55th Annual Conference on Information Sciences and Systems,

2021:Article No. :9400311.

- [9] MA X, WANG R R. Personalized scientific paper recommendation based on heterogeneous graph representation[J]. IEEE Access, 2019, 7: 79887-79894.
- [10] TANG J, QU M Z, WANG M, et al. LINE: Large-scale information network embedding[C]//Proceedings of the 24th International Conference on World Wide Web, 2015: 1067-1077.
- [11] LONG K H, LI S S, WANG P C, et al. Integrating title and citation context semantics of citing paper via weighted attentions for local citation recommendation[C]//2022 International Joint Conference on Neural Networks, 2022: Article No. : 9892003.
- [12] YU J, HE J C, XU L Y. Hypergraph-based academic paper recommendation[C]//The 15th International Conference on Knowledge Science, Engineering and Management, 2022: 449-462.
- [13] PEROZZI B, AL-RFOU R, SKIENA S. DeepWalk: Online learning of social representations[C]//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2014: 701-710.
- [14] DONG Y V, CHAWLA N V, SWAMI A. metapath2vec: Scalable representation learning for heterogeneous networks[C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2017: 135-144.
- [15] ALI Z, QI G L, MUHAMMAD K, et al. Global citation recommendation employing generative adversarial network[J]. Expert Systems with Applications, 2021, 180: Article No. : 114888.

作者简介:



李瑞红(1997—),女,甘肃会宁人,硕士生,研究方向为推荐系统。**E-mail:** 2021212111@nwnu.edu.cn

mendation system.

LI Ruihong, born in 1997, MS candidate, her research interest includes recom-



李晓红(1978—),女,甘肃兰州人,硕士,副教授,研究方向为数据挖掘和机器学习。**E-mail:** xiaohongli@nwnu.edu.cn

data mining and machine learning.

LI Xiaohong, born in 1978, MS, associate professor, her research interests include



姚锦(2000—),女,陕西西安人,硕士生,研究方向为推荐系统。**E-mail:** yaojiner21@163.com

tion system.

YAO Jin, born in 2000, MS candidate, her research interest includes recommenda-



王闪闪(1997—),女,河南商丘人,硕士生,研究方向为数据挖掘和推荐系统。**E-mail:** 2020211954@nwmu.edu.cn

ta mining and recommendation system.

WANG Shanshan, born in 1997, MS candidate, her research interests include da-