



研究与开发

基于元路径卷积的异构图神经网络算法

秦志龙^{1,2}, 邓琨^{1,3}, 刘星妍¹

(1. 嘉兴大学信息科学与工程学院, 浙江 嘉兴 314001;

2. 浙江理工大学计算机科学与技术学院 (人工智能学院), 浙江 杭州 310018;

3. 嘉兴大学浙江省全省多模态感知与智能系统重点实验室, 浙江 嘉兴 314001)

摘要: 现有异构图嵌入方法在多层图卷积计算中, 通常将每个节点表示为单个向量, 使得高阶图卷积层无法区分不同关系和顺序的信息, 导致信息在传递过程中丢失。为解决该问题, 提出了基于元路径卷积的异构图神经网络算法。该方法首先利用特征转换自适应调整节点特征; 其次, 设计了元路径内卷积挖掘节点高阶间接关系, 捕获目标节点在单元路径下与其他类型节点之间的交互关系; 最后, 通过自注意力机制探索语义之间的相互性, 融合来自不同元路径的特征。在ACM、IMDB和DBLP数据集上进行广泛实验, 并与当前主流算法进行对比分析。实验结果显示, 节点分类任务中Macro-F1平均提高0.5%~3.5%, 节点聚类任务中ARI值提高了1%~3%, 证明该算法是有效、可行的。

关键词: 异构图; 图嵌入; 图神经网络; 元路径; 图卷积

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024078

Meta-path convolution based heterogeneous graph neural network algorithm

QIN Zhilong^{1,2}, DENG Kun^{1,3}, LIU Xingyan¹

1. College of Information Science and Engineering, Jiaxing University, Jiaxing 314001, China

2. School of Computer Science and Technology (School of Artificial Intelligence),
Zhejiang Sci-Tech University, Hangzhou 310018, China

3. Provincial Key Laboratory of Multimodal Perceiving and Intelligent Systems,
Jiaxing University, Jiaxing 314001, China

Abstract: In the multilayer graph convolution calculation, each node is usually represented as a single vector, which makes the high-order graph convolution layer unable to distinguish the information of different relationships and sequences, resulting in the loss of information in the transmission process. To solve this problem, a heterogeneous graph

收稿日期: 2024-01-08; 修回日期: 2024-03-15

通信作者: 邓琨, dengkun@hrbeu.edu.cn

基金项目: 教育部人文社会科学研究专项任务项目 (No.22JDSZ3023); 教育部产学研合作协同育人项目 (No.220603372015422, No.220604029012441)

Foundation Items: The Humanity and Social Science Research Project of Ministry of Education of China (No.22JDSZ3023), The Ministry of Education's Industry-University Collaboration Education Project (No.220603372015422, No.220604029012441)



neural network algorithm based on meta-path convolution was proposed. Firstly, the feature transformation was used to adaptively adjust the node features. Secondly, the high-order indirect relationship between the nodes was mined by convolution within the meta-path to capture the interaction between the target node and other types of nodes under the element path. Finally, the reciprocity between semantics was explored through the self-attention mechanism, and the features from different meta-paths were fused. Extensive experiments were carried out on ACM, IMDB and DBLP datasets, and compared with the current mainstream algorithms. The experimental results show that the average increase of Macro-F1 in the node classification task is 0.5%~3.5%, and the ARI value in the node clustering task is increased by 1%~3%, which proves that the algorithm is effective and feasible.

Key words: heterogeneous graph, graph embedding, graph neural network, meta-path, graph convolution

0 引言

异构图是包含多种类型对象和连接的图结构数据,不仅可以表达丰富、复杂的语义信息以及结构信息,而且可以表征真实世界许多现实场景,如社交网络^[1]、引文网络^[2]和交通网络^[3]等。图嵌入旨在将拓扑空间中的网络节点转化到低维向量空间,同时最大限度地保持网络结构特征,广泛应用于如节点分类^[4]、链路预测^[5]、个性化推荐^[6]等任务中。图神经网络作为一种有效的图表示学习工具,因其强大的特征捕获能力,近年来受到众多研究者的关注。目前,大多图神经网络^[7-8]往往仅局限应用于只包含一种节点类型与一种边类型的同构图上学习节点表示,无法在学习过程中区分异构图中多类型节点与边,因此不能直接将同构模型应用于异构图表示学习中。为将图神经网络扩展至异构图,用于抽取多类型复杂网络中的潜在特征,研究人员提出了异构图神经网络(heterogeneous graph neural network, HGNN),并在异构图表示学习中取得较好效果,为复杂网络提供新的知识分析技术。

现有 HGNN 模型,如异构图注意力网络(heterogeneous graph attention network, HAN)^[9]以及元路径聚合图神经网络(metapath aggregated graph neural network, MAGNN)^[10],使用注意力机制加权聚合目标节点类型内以及类型间的邻域节点特征,并将聚合特征作为目标节点的

更新表征。在基于消息传递的 HGNN 模型^[11-12]中,消息传递根据原始图中的交互关系执行,即目标节点表征由原始图结构所决定的相关节点表征聚合得到。在现实复杂交互中构建的异构图,通常由于人为采集数据过程中的不规范操作或采集标准不统一等因素,构建的异构图中存在与实际情况不相符的噪声连接并缺失必要属性特征,造成节点间邻域信息丢失问题。

图卷积模型通过邻接矩阵建模节点邻域信息,进行卷积运算能够有效学习节点间结构关系。如 Ren 等^[13]提出元图卷积网络(meta-graph convolutional network, MGCN),通过设计元图卷积获取图异构性,将多条元路径上的图结构设计为元图,挖掘节点间的语义信息。Yu 等^[5]提出多重异构图卷积网络(multiplex heterogeneous graph convolutional network, MHGCN),通过多层图卷积自动学习多重异构图中不同长度的元路径交互,将多关系结构信号和属性信息集成到节点嵌入中。但是现有图卷积模型无法补全图中的缺失交互,不能正确聚合元路径下的邻域特征,导致学习到的节点表征存在特征偏差。

为改进现有图卷积方法的不足,本文提出一种基于元路径卷积的异构图神经网络(meta-path convolution based heterogeneous graph neural network, MCHGNN)算法,主要贡献有以下几点:提出异构图内卷积编码,基于元路径的邻接矩阵,挖掘不同类型节点的高阶间接关系,在元路

径上保留图的拓扑信息及异构信息,避免在目标对象的邻域中进行大规模节点聚合;通过自注意力机制融合多条元路径上的语义信息,进一步探索每对语义之间的相互关系;将元路径内卷积与自注意力机制结合,利用图卷积中的交互操作抑制原始图的噪声信息,并与自注意力机制补全缺失交互,实现图结构优化。

1 相关工作

为更清晰地说明本文所提算法的目标任务,在此描述与MCHGNN算法密切相关的3个研究领域,分别为异构图神经网络、图卷积神经网络以及自注意力网络模型。

1.1 异构图神经网络

为将深层神经网络应用于异构图的表示学习,研究人员提出异构图神经网络。现有异构图神经网络,通过元路径捕获异构图特定的高阶语义,并通过聚合节点的元路径邻居更新节点表征。例如,Jin等^[14]提出属性补全的异构图神经网络(heterogeneous graph neural network via attribute completion, HGNN_AC)通过节点之间的拓扑关系,对无属性节点进行加权聚合,完成无属性节点的属性补全,将节点属性与图学习过程融合,使节点属性信息更有效。Xu等^[15]提出结构感知异构图神经网络(structure-aware heterogeneous graph neural network, SHGNN),通过结构感知模块获取中间节点局部结构信息,进一步学习异构图结构信息。Zhan和Jia^[16]提出均衡采样的异构信息网络(heterogeneous information network embedding with balanced network sampling, CoarSAS2hvec),利用基于自回避行走的短序列采样和优化损失函数,提高异构图嵌入性能。虽然基于元路径的图神经网络在图嵌入上取得了较好效果,但这些模型依赖于人为设定的元路径,且由于过度使用邻居注意力,重复的邻居聚合造成了信息冗余。

1.2 图卷积神经网络

图卷积神经网络因其高效利用图结构数据的能力而受到研究者广泛关注,通过卷积运算提取图像信息,并将其从二维结构化数据推广到图领域。如Yun等^[17]提出图变换网络(graph transformer network, GTN),并设计一种可自动学习元路径的异构图卷积模型。该模型首先根据交互类型,将异构图划分为多个关系子图,并使用多通道卷积网络学习每种关系的重要度,然后组合每一层网络中重要度最高的关系。Yang等^[18]提出可解释的高效异构图卷积网络(interpretable and efficient heterogeneous graph convolutional network, ie-HGCN),设计了针对异构图的图卷积网络,通过对象级聚合和类型级聚合识别节点的有效元路径。Chen等^[19]提出基于局部影响的异构图卷积网络(heterogeneous graph convolutional network based on local influence, HIGCN),通过基于元路径的元图,将异构图转换为同构子图捕获节点的高阶信息。该类方法将点积注意力机制引入异构图学习中,可以学习隐含的元路径,但每个节点表示为一个单独向量,混淆了来自不同关系和顺序的信息,导致结构信息丢失。

1.3 自注意力网络模型

自注意力机制在捕获全局信息上的优秀表现,使其成为深度学习的主流方法与讨论热点。Lyu等^[20]提出异构图基准(heterogeneous graph benchmark, HGB),以多层图注意力网络为基础,利用注意力机制融合节点特征和可学习的边类型嵌入,并结合残差连接生成节点表示。Du等^[21]提出序列节点表示的异构图神经网络(heterogeneous graph neural network with sequential node representation, Seq-HGNN),通过一种顺序节点表示学习机制,并利用基于transformer的消息传递机制融合异构语义信息。Wang等^[22]提出多视角信息交互的图卷积神经网络(multi-view interaction graph convolutional network, MIGCN),



通过在不同视角上训练的图卷积层之间引入 transformer 编码器模块, 使得样本在训练阶段通过注意力机制在不同视角间获取互补性信息, 加强模型训练效果。现有基于自注意力机制模型通过自适应地从输入中提取相关信息, 得到更好的特征表达, 然而在自适应过程中无法准确表达节点元路径的拓扑特征。

现有异构图神经网络模型在网络学习过程中忽视噪声交互问题以及无法捕获节点间的有效交互, 导致结构信息丢失。基于此, 本文提出一种基于元路径卷积的异构图神经网络算法, 在图卷积过程中利用图数据自身蕴含的潜在特性有效传递节点信息。

2 基本定义

本节介绍了异构图的一些定义和示例, 并进一步对基于元路径卷积的异构图神经网络算法上的问题做定义。

定义1 (异构图^[23]) 给定图 $G=(V, E, \mathcal{A}, R, \phi, \varphi)$, 其中 V 是节点集合, E 是边集合, $\mathcal{A}$ 表示节点类型集合, R 表示边类型集合, ϕ 为节点类型映射函数, φ 为边类型映射函数, 满足 $\phi(v) \in \mathcal{A} (v \in V)$ 、 $\varphi(e) \in \mathcal{R} (e \in E)$ 。当 $|\mathcal{A}|+|\mathcal{R}|>2$ 时, 该图称为异构图。

以图1异构图相关概念示例进行说明。如






图1 异构图相关概念示例

图1(a)所示为计算机引文网络 (association for computing machinery, ACM) 示例, 该网络节点包括作者 (A)、论文 (P) 和主题 (S) 3种节点类型, 边包括论文-作者、论文-主题两种边类型。

定义2 (元路径^[24]) 给定一个异构图 $G=(V, E, \mathcal{A}, R, \phi, \varphi)$, 图 G 上的元路径 P 是由节点类型组成的有序序列, 可表示为 $P=A_1, A_2, \dots, A_l (A_i \in \mathcal{A} (1 \leq i \leq l))$, 其中 l 为元路径长度。在本文中, 处于节点类型 A_1 位置的对象被称为起始节点, 处于类型 A_l 位置的节点被称为终止节点。

图1(b)为ACM网络中的3条元路径示例, 分别包含不同的语义信息, PAP表示同一作者完成论文之间的关系, PSP表示同一主题下论文之间的关系, PAPSP表示同一作者相关主题下论文之间的关系。因此, 不同元路径下隐含着不同的语义信息。

定义3 (元路径子邻接矩阵) 给定异构图 $G=(V, E, \mathcal{A}, R, \phi, \varphi)$, 一个元路径 $P=A_1, A_2, \dots, A_l$, 设矩阵 C_{A_i, A_j} 为节点类型 A_i 与 A_j 之间的邻接矩阵。则该元路径下的节点类型 $A_i (i \in 1, 2, \dots, l)$ 与起始节点之间元路径的子邻接矩阵可表示为:

$$\begin{aligned} \hat{C}_{A_i \rightarrow A_1} &= \hat{C}_{A_1, A_2} \otimes \hat{C}_{A_2, A_3} \otimes \dots \otimes \\ &\hat{C}_{A_{j-1}, A_j} \otimes \hat{C}_{A_j, A_{j+1}} \otimes \dots \otimes \hat{C}_{A_{l-1}, A_l} \end{aligned} \quad (1)$$

其中, 符号 $\otimes$ 表示矩阵的乘积, $\hat{C}_{A_j, A_{j+1}} (j \in \{1, 2, \dots, i-1\})$ 表示为节点类型 A_j 和 A_{j+1} 之间邻接矩阵 $C_{A_j, A_{j+1}}$ 的行归一化形式。

图1(c)为ACM网络中元路径PAP下的元路径子邻接矩阵邻居示例。对于论文1, 作者类型节点子邻居有作者1、作者2、作者3, 论文类型节点子邻居有论文1、论文2。可以揭示在PAP语义下与论文1相关联的作者及衍生论文之间的结构关系。

问题定义 (异构图嵌入) 给定一个异构图 $G=(V, E, \mathcal{A}, R, \phi, \varphi)$ 作为输入, 对于 G 中任意节点 $v \in V$, 异构图嵌入目标是学习一个映射函数 $f: v \rightarrow h_v \in \mathbf{R}^d$, 其中 h_v 为节点 v 学习得到的低维稠密向量, d 为学习嵌入的维度, $d \ll |V|$ 。函数 f 的目的是使向量同时保留异构图中的拓扑信息和多类型特征。

3 基于元路径卷积的异构图神经网络算法

本文提出了MCHGNN算法。MCHGNN算法框架如图2所示, 由3部分构成: 第1部分为节点特征转换, 通过节点映射将不同类型节点的节点特征投影到相同特征空间; 第2部分为元路径内卷积编码, 通过基于元路径的子邻接矩阵聚合节点邻域特征及图异构性, 并用卷积操作进行正向传播; 第3部分为语义融合, 通过自注意力机制学习并调整不同元路径的语义权重, 融合不同元

路径下的语义信息, 得到节点最终嵌入。

3.1 节点特征转换

异构图中不同类型节点特征往往在不同的语义空间中, 难以在元路径下处理不同类型节点信息。因此对特定类型节点进行特征转换, 并通过投影矩阵将节点低维特征空间转换到同等维度空间, 能够更加详细地描述节点信息。对节点类型为 $A_i \in \mathcal{A}$ 进行线性变换, 将特征向量投影到相同特征空间中:

$$X^{IA_i} = W^{A_i} X^{A_i} + b_{A_i} \quad (2)$$

其中, $X^{A_i} \in \mathbf{R}^{d_{A_i}}$ 为节点类型的初始特征向量, $X^{IA_i} \in \mathbf{R}^d$ 为节点类型 A_i 线性映射后的向量, W^{A_i} 为节点类型 A_i 的参数化权重矩阵, b_{A_i} 表示节点类型 A_i 对应的偏置参数。与以往方法^[9-10]不同的是, 通过设置偏置参数调整节点特征属性, 将节点属性特征进行调整, 并通过节点特征转换投影至相同维度的向量空间, 以便进行后续操作。

3.2 元路径内卷积编码

在异构图中, 节点彼此之间连接分布不均匀, 导致部分节点拥有大量邻居节点, 部分节点邻居节点非常稀少, 进而使邻接矩阵内部元素差值非常巨大。因此为正确学习节点在元路径下与各类节点之间的内部联系, 提出元路径内卷积, 对元路径中的节点类型进行图卷积操作。

现有基于元路径的方法^[16,25], 在构建元路径邻居图时, 预处理步骤中为每个元路径枚举所有




图2 MCHGNN算法框架



基于元路径的邻居，元路径实例数量随着元路径长度呈指数级增长，带来巨大开销。为避免过度使用邻居注意力聚合造成信息冗余，使用基于元路径的邻接矩阵逐层传播计算每个节点对目标的贡献权重，并通过卷积操作弥补节点缺失的属性信息。具体而言，对异构邻接矩阵进行归一化，降低异构图中节点邻居数量不一致的影响。对于元路径 $P_u = A_1, A_2, \dots, A_l \in M$ ， M 为元路径集合，节点类型 $A_i \in \mathcal{A} (1 \leq i \leq l)$ 与起始节点 A_1 之间的元路径内卷积表示为：

$$\mathbf{X}_{A_i \rightarrow A_1}^{P_u} = \sigma(\mathbf{C}_{A_i \rightarrow A_1}^{P_u} \mathbf{X}^{A_i} \mathbf{W}_{A_i \rightarrow A_1}^{P_u}) \quad (3)$$

其中， $\mathbf{C}_{A_i \rightarrow A_1}^{P_u}$ 表示元路径下的子邻接矩阵， $\mathbf{X}^{A_i}$ 为节点类型 A_i 的特征映射向量， $\mathbf{W}_{A_i \rightarrow A_1}^{P_u}$ 为参数化权重矩阵， $\sigma(\cdot)$ 为激活函数。在同一元路径下，对于节点类型 A_{i+1} ，其子邻接矩阵可由 $\mathbf{C}_{A_{i+1} \rightarrow A_1}^{P_u} = \mathbf{C}_{A_i \rightarrow A_1}^{P_u} \otimes \hat{\mathbf{C}}_{A_i, A_{i+1}}$ 得到，因此仅需要计算元路径终止节点类型 A_l 元路径的子邻接矩阵即可得到元路径下所有节点类型的子邻接矩阵。DBLP (Digital Bibliography and Library Project, DBLP) 数据集元路径子邻接矩阵示例如图3所示，对于所有元路径中的起始节点，通过由元路径下不同类型节点之间的邻接矩阵相乘得到各个子邻接矩阵，目标节点可以获得其高阶邻居的信息。相较于现有图卷积方法，元路径内卷积逐层传播元路径内部邻域信息，进一步捕获图的异构信息及拓扑结构信息。

由于不同节点类型对目标节点表示做出不同的贡献，因此采用注意力层^[26]对与起始节点相关

的节点类型卷积信息进行加权求和。通过学习元路径下每个节点类型对于起始节点的归一化重要性权重 $a_{A_i \rightarrow A_1}^{P_u}$ ，学习节点结构信息：

$$e_{A_i}^{P_u} = \sigma(\mathbf{q}^T [\mathbf{X}_{A_i \rightarrow A_1}^{P_u} \parallel \mathbf{X}_{A_1 \rightarrow A_1}^{P_u}]) \quad (4)$$

$$a_{A_i \rightarrow A_1}^{P_u} = \frac{\exp(e_{A_i}^{P_u})}{\sum_{j=1}^l \exp(e_{A_j}^{P_u})} \quad (5)$$

其中， $\sigma(\cdot)$ 为激活函数， $\mathbf{q}^T$ 为节点类型参数化向量， l 为元路径长度，得到每个节点类型的权重系数 $a_{A_i \rightarrow A_1}^{P_u}$ 后，计算元路径下每个节点类型对起始节点的贡献信息，执行注意力聚合。将注意力权重作为系数，对元路径内卷积聚合向量进行融合，由此得到起始节点在元路径上的潜在表示：

$$\mathbf{Z}^{P_u} = \sigma(\sum_{i=1}^l a_{A_i \rightarrow A_1}^{P_u} \cdot \mathbf{X}_{A_i \rightarrow A_1}^{P_u}) \quad (6)$$

其中， $a_{A_i \rightarrow A_1}^{P_u}$ 为节点类型 A_i 在元路径 P_u 下对于起始节点的权重系数， $\mathbf{X}_{A_i \rightarrow A_1}^{P_u}$ 为节点类型 A_i 在元路径 P_u 下对于起始节点的元路径内卷积向量。为稳定学习过程，将注意力融合机制扩展到多头。具体而言，对 k 个独立的注意力机制同时执行式 (6)，并将 k 个注意力机制得到的特征连接，作为节点结构输出特征表示：

$$\mathbf{Z}^{P_u} = \parallel_{k=1}^k \sigma(\sum_{i=1}^n [a_{A_i \rightarrow A_1}^{P_u}]_k \cdot \mathbf{X}_{A_i \rightarrow A_1}^{P_u}) \quad (7)$$

其中， $[a_{A_i \rightarrow A_1}^{P_u}]_k$ 表示节点类型 A_i 在元路径 P_u 下第 k 个注意力头的归一化重要性， $\parallel$ 为向量连接操作。给定节点特征映射向量 $\mathbf{X}^{A_i}$ 以及元路径集合 $M = \{P_1, P_2, \dots, P_m\}$ ，元路径内卷积编码即起始节




图3 DBLP数据集元路径子邻接矩阵示例

点生成 m 个针对特定元路径的向量表示, 记为 $\{\mathbf{Z}^{P_1}, \mathbf{Z}^{P_2}, \dots, \mathbf{Z}^{P_m}\}$, m 为元路径数量。

3.3 基于自注意力机制的语义融合

节点在不同元路径下有着各自的元路径内卷积编码, 因此使用语义融合模块聚合在不同元路径下的卷积编码, 融合节点语义特征向量, 并生成最终的嵌入向量。MCHGNN 算法与以往语义向量^[8-10]进行语义融合的算法操作方式不同, 通过自注意力机制语义融合模块, 能够自动学习节点在不同元路径下的重要性权重, 并聚合来自前一步骤的相应卷积表示, 以进一步探索每对语义之间的相互关系。

自注意力机制将节点特征表示通过查询以及键值对方式映射到输出向量。将查询、键和值分别表示为 3 个矩阵, 具体在元路径 $P_i \in M$ 下, 对每个卷积编码 $\mathbf{Z}^{P_i}$ 映射为查询向量 $\mathbf{q}^{P_i}$ 、关键值向量 $\mathbf{k}^{P_i}$ 、内容向量 $\mathbf{v}^{P_i}$:

$$\mathbf{q}^{P_i} = \mathbf{W}_Q \mathbf{Z}^{P_i} + b_Q; \mathbf{k}^{P_i} = \mathbf{W}_K \mathbf{Z}^{P_i} + b_K; \mathbf{v}^{P_i} = \mathbf{W}_V \mathbf{Z}^{P_i} + b_V \quad (8)$$

其中, $\mathbf{W}_Q$ 、 $\mathbf{W}_K$ 、 $\mathbf{W}_V$ 为所有元路径共享可学习参数矩阵, b_Q 、 b_K 、 b_V 为所有元路径共享可学习偏置参数。通过对查询向量与关键值向量进行注意力融合, 得到元路径之间的相互注意力权重。用注意力权重进行最终的语义融合, 得到节点每条元路径下的特征:

$$\alpha(P_i, P_j) = \frac{\exp(\mathbf{q}^{P_i} \cdot \mathbf{k}^{P_j \top})}{\sum_{P_u \in M} \exp(\mathbf{q}^{P_i} \cdot \mathbf{k}^{P_u \top})} \quad (9)$$

$$\mathbf{h}^{P_i} = \beta \left(\sum_{P_j \in M} \alpha(P_i, P_j) \mathbf{v}^{P_j} + \mathbf{Z}^{P_i} \right) \quad (10)$$

其中, β 为可学习参数, 每个节点最终嵌入向量是所有输出向量的连接, 将每条元路径下的语义向量进行拼接得到最终语义融合特征:

$$\mathbf{h} = \mathbf{h}^{P_1} \parallel \mathbf{h}^{P_2} \parallel \dots \parallel \mathbf{h}^{P_m} \quad (11)$$

其中, $\parallel$ 表示向量连接操作, 将各个元路径下的节点表示进行连接得到节点最终向量表示。尽管

式 (9) 与以往方法^[12,20]中的聚合思想相似, 但本文通过对元路径内卷积编码进行自注意力语义融合, 线性地聚合来自高阶元路径邻居的信息, 提升节点嵌入效果。此外, 本文在训练循环中随机摒弃了每个节点序列表示的一些片段, 帮助模型学习更有意义的节点表示, 以增强模型稳定性。综上, MCHGNN 算法具体描述如算法 1 所示。

算法 1 MCHGNN 算法

输入 异构图 $G=(V, E, \mathcal{A}, R, \phi, \varphi)$, 元路径集合 $M \parallel V$ 是节点集合, E 是边集合, $\mathcal{A}$ 表示节点类型集合, R 表示边类型集合, ϕ 为节点类型映射函数, φ 为边类型映射函数

输出 节点嵌入 $\mathbf{h} = \{\mathbf{h}_v, \forall v \in V\}$

(1) begin

(2) for $v \in V$ do

(3) 对节点 v 进行特征转换得到 $\mathbf{X}^{A_i}$;

(4) end for

(5) for $v \in V$ do

(6) for $P_i \in M$ do

(7) 计算节点元路径内卷积向量 $\mathbf{X}_{A_j \rightarrow A_i}^{P_i}$;

(8) 计算节点 v 的元路径内编码 $\mathbf{Z}^{P_i}$;

(9) 将节点 v 的元路径内编码映射为查询向量 $\mathbf{q}^{P_i}$, 关键值向量 $\mathbf{k}^{P_i}$, 内容向量 $\mathbf{v}^{P_i}$;

(10) end for

(11) 计算节点 v 单条元路径下的自注意力向量 $\mathbf{h}^{P_i}$;

(12) 连接节点 v 的所有元路径语义向量得到节点嵌入 $\mathbf{h}$;

(13) end for

(14) return $\mathbf{h}$

从算法 1 中可知, 第 2~4 行遍历节点, 对节点进行特征转换; 第 6~10 行计算节点元路径下的元路径内编码, 并映射为查询向量、关键值向量及内容向量; 第 11~12 行对节点进行自注意力



语义融合，融合多条元路径下的语义向量；第13行代表网络中的节点都已被训练完毕，最终得到节点嵌入集合。

3.4 时间复杂度分析

设异构图元路径数量为 m ，元路径长度为 l ，总节点数为 n ，以下为算法复杂度具体分析过程。

从算法1中可知，节点特征转换需遍历所有节点进行特征投影，因此时间复杂度为 $O(n)$ ；元路径内卷积编码需要在元路径下对所有节点类型进行图卷积操作，因此时间复杂度为 $O(nml)$ ；自注意力机制需要对各个元路径直接计算注意力权重，因此时间复杂度为 $O(nl^2)$ 。最终，MCHGNN算法的时间复杂度约为 $O(n(m+1)l)$ ，由于元路径数量 m 、元路径长度 l 远小于图中的总节点数 n ，MCHGNN算法的时间复杂度可表示为 $O(n)$ 。

4 实验及结果分析

4.1 数据集

为评估MCHGNN算法的有效性和优越性，采用3种广泛使用的数据集：互联网电影资料库（Internet movie database，IMDB）、ACM和DBLP，并对其进行节点分类以及节点聚类实验。3个数据集相关统计信息见表1。

表1 3个数据集相关统计信息

数据集	节点类型	边类型	元路径
IMDB	M: 4 287	M-D: 4 278	M-D-M
	D: 2 081	M-A: 12 828	M-A-M
	A: 5 257		
ACM	P: 4 287	P-P: 9 615	P-A-P
	A: 7 167	P-A: 13 407	P-S-P
	S: 60	P-S: 4 019	
DBLP	A: 4 057	A-P: 19 645	A-P-A
	P: 14 328	P-T: 85 810	A-P-T-P-A
	T: 7 723	P-V: 14 328	A-P-V-P-A
	V: 20		

(1) IMDB

IMDB是一个关于电影、电影演员和电影导演的在线数据库，包括影片内容介绍、评论、分

级等信息。使用4 287部电影（M），包括喜剧电影、动作电影和戏剧电影3种类型，5 257名演员（A）和2 081名导演（D）。每个电影节点特征是描述情节关键词特征向量。使用元路径为{MDM, MAM}。

(2) ACM

ACM是一个关于期刊、书籍以及会议记录的出版物集合。使用包括4 019篇论文（P）、7 167个作者（A）以及60个主题（S）。其中论文具有3种标签：数据挖掘、数据库和无线通信。使用元路径为{PAP, PSP}。

(3) DBLP

DBLP是计算机领域的文献集成网站，使用包括4 057名作者（A）、14 328篇论文（P）、7 723个术语（T）以及20个会议（V）。其中作者分为数据挖掘、数据库、信息检索和人工智能4个研究领域。每个作者节点特征是其发表论文关键词特征向量。使用的元路径为{APA, APTA, APVPA}。

4.2 评价指标

本文以节点分类实验验证模型有效性，使用Macro-F1和Micro-F1作为分类性能的评价指标。Macro-F1和Micro-F1为衡量多分类模型精确度的一种指标，式（12）给出了Macro-F1和Micro-F1的定义：

$$\text{Macro-F1} = \sum_{i=1}^n \frac{2 \times \text{TP}_i}{2 \times \text{TP}_i + \text{FN}_i + \text{FP}_i};$$

$$\text{Micro-F1} = \frac{\sum_{i=1}^n 2 \times \text{TP}_i}{\sum_{i=1}^n [2 \times \text{TP}_i + \text{FN}_i + \text{FP}_i]} \quad (12)$$

其中， TP_i 、 FN_i 以及 FP_i 分别表示第 i 个类别下的预测正确的正样例（true positive）、预测错误的负样例（false negative）以及预测错误的正样例（false positive）的数量。

在节点聚类任务中，本文选择归一化互信息

(NMI) 与调整兰德指数 (ARI) 作为评价指标, 以验证本文模型在聚类任务上的有效性。NMI 如式 (13) 所示。

$$\text{NMI}(\mathbf{X}, \mathbf{Y}) = \frac{I(\mathbf{X}, \mathbf{Y})}{\sqrt{H(\mathbf{X})H(\mathbf{Y})}} \quad (13)$$

其中, $\mathbf{X}$ 为真实标签向量, $\mathbf{Y}$ 为预测标签向量, $I(\mathbf{X}, \mathbf{Y})$ 表示 $\mathbf{X}$ 与 $\mathbf{Y}$ 的互信息, $H(\mathbf{X})$ 与 $H(\mathbf{Y})$ 分别为 $\mathbf{X}$ 与 $\mathbf{Y}$ 的信息熵。ARI 如式 (14) 所示。

$$\text{ARI} = \frac{\text{RI} - E(\text{RI})}{\max(\text{RI}) - E(\text{RI})} \quad (14)$$

其中, RI 表示兰德指数, $E(\text{RI})$ 为期望值。RI 如式 (15) 所示。

$$\text{RI} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}} \quad (15)$$

其中, TP 为两个同类样本点在同一类中的情况数量, FP 为两个非同类样本点在同一类中的情况数量, FN 表示两个同类样本点分别在两个类中的情况数量, TN 表示两个非同类样本点分别在两个类中的情况数量。

4.3 基准

为客观说明 MCHGNN 算法的性能, 对比 7 种不同类型图嵌入方法在节点分类和节点聚类任务上的性能, 包括传统经典算法、同构网络模型以及异构图模型算法。

(1) metapath2vec^[27]: 一种异构图嵌入模型, 通过元路径进行随机游走, 使用 skim-gram 将节点映射为低维嵌入向量。该模型需要指定的单个元路径, 因此测试各个元路径, 取最优结果作为对比值。

(2) GCN^[7]: 一种同构图神经网络模型, 使用图谱卷积学习节点嵌入表示, 在不同元路径下测试并使用最优结果。

(3) HAN^[9]: 异构图神经网络算法, 从不同元路径学习特定节点信息, 然后利用注意力机制将其组合成节点嵌入表示。

(4) MAGNN^[10]: 异构图神经网络算法, 通过元路径内聚合和元路径间聚合, 并融合节点内

容特征信息, 学习节点嵌入表示。

(5) HGNN_AC^[14]: 异构图神经网络算法, 通过结构感知模块聚合邻居节点, 补全节点属性, 并通过损失函数优化属性补全机制, 得到更好的节点嵌入。

(6) HGB^[20]: 异构图神经网络算法, 通过添加边类型嵌入训练节点类型, 并使用残差连接和输出正则化获得节点嵌入。

(7) OSGNN^[28]: 异构图神经网络算法, 通过设计元路径诱导子图, 并结合原图结构信息得到节点嵌入表示。

4.4 实验设置

实验过程中, 对比算法参数设置是根据原作者文献中给出的建议参数值。本文所提 MCHGNN 算法由随机搜索模型 100 次测试结果选择最优的参数值所得。其中学习率设置为 0.001, 丢失率设置为 0.1, 多头注意力设置为 8。训练时用 Adam 优化器对网络进行训练优化。训练批次 (epoch) 设置为 100, 并使用早停法防止模型过拟合, 耐心值设置为 20。

本文所提算法 MCHGNN 实验运行环境为 AMD EPYC 7T83 CPU+RTX 4090 GPU, 内存为 90 GB, 操作系统为 Ubuntu 18.04, 开发工具为 Python 3.8、PyTorch 2.0.0 及 cuda 11.8。

4.5 节点分类

节点分类是评估学习节点嵌入性能的传统任务。本次实验中, 在不同模型下对 3 个数据集进行节点分类任务, 使用 Macro-F1 值以及 Micro-F1 值作为评估指标对各个算法节点分类效果进行比较。

实验采用相同的训练集、验证集及测试集。训练集比例为 20%、40%、60% 和 80%。使用支持向量机 (SVM) 模型在测试集上应用节点分类任务, 得到实验指标, 并将过程重复 10 次, 报告平均指标, 保证实验结果稳定性。在 IMDB、DBLP 和 ACM 数据集上的节点分类结果见表 2, 最佳结果以粗体突出显示。



表2 在IMDB、DBLP和ACM数据集上的节点分类结果

	指标	训练集比例	metapath2vec	GCN	HAN	MAGNN	HGNN_AC	HGB	OSGNN	MCHGNN
IMDB	Macro-F1	20%	46.3%	45.0%	57.4%	57.9%	59.7%	60.7%	59.5%	61.2%
		40%	47.7%	45.4%	57.5%	59.1%	60.2%	61.2%	60.4%	63.8%
		60%	48.2%	46.8%	57.7%	59.6%	60.6%	62.6%	60.8%	65.1%
		80%	48.9%	47.2%	57.8%	59.8%	60.8%	63.2%	61.0%	66.6%
	Micro-F1	20%	48.2%	46.3%	57.2%	58.0%	59.8%	60.8%	59.5%	61.2%
		40%	49.5%	48.1%	57.6%	59.3%	60.4%	61.4%	60.4%	63.8%
		60%	50.2%	48.5%	57.7%	59.7%	60.8%	62.8%	60.8%	65.0%
		80%	50.8%	48.6%	57.8%	60.0%	61.0%	63.2%	61.0%	66.6%
ACM	Macro-F1	20%	70.0%	70.2%	90.1%	88.9%	89.2%	91.1%	92.6%	92.0%
		40%	71.3%	70.7%	90.2%	89.7%	90.7%	92.4%	93.3%	92.2%
		60%	71.8%	70.6%	91.4%	90.2%	91.5%	92.6%	93.7%	93.0%
		80%	72.3%	68.4%	91.5%	90.3%	91.9%	92.9%	93.8%	94.0%
	Micro-F1	20%	72.3%	73.2%	89.9%	88.7%	89.1%	90.2%	92.6%	92.2%
		40%	73.5%	73.6%	90.3%	89.2%	90.7%	91.3%	93.1%	92.3%
		60%	73.9%	74.2%	91.4%	90.3%	91.5%	91.5%	93.6%	93.7%
		80%	74.2%	73.9%	91.7%	90.8%	91.9%	92.3%	93.7%	93.8%
DBLP	Macro-F1	20%	91.6%	90.1%	91.6%	92.4%	94.2%	94.0%	94.0%	94.8%
		40%	92.8%	90.2%	91.6%	93.5%	94.4%	94.1%	94.3%	95.0%
		60%	93.0%	90.4%	92.1%	93.9%	94.4%	94.2%	94.5%	94.8%
		80%	93.2%	90.7%	92.2%	93.9%	94.6%	94.3%	94.8%	95.3%
	Micro-F1	20%	92.2%	90.4%	92.3%	92.9%	94.6%	94.2%	94.4%	95.3%
		40%	93.2%	90.9%	92.5%	93.0%	94.7%	94.5%	94.7%	95.4%
		60%	93.9%	91.0%	92.6%	93.4%	94.8%	94.5%	94.9%	95.2%
		80%	94.0%	91.1%	92.8%	93.9%	95.0%	94.6%	95.2%	95.6%

由表2可知, MCHGNN算法取得较优效果, IMDB数据集上最高基线提升1%~3%,这是由于IMDB数据特征较为稀疏,并且导演和演员节点类型存在属性缺失,元路径内卷积编码能够更好地弥补节点属性信息丢失问题,同时用图拓扑信息作为补充,提高其嵌入表示性能。DBLP和ACM数据集上提升0.5%~1%,这是由于数据集原始标签更能体现节点类别,因此需要更优的语义信息处理方式提升其嵌入效果,自注意力机制能够更好地处理元路径内卷积得到的单元路径节点表示,通过权值矩阵聚合来自先前步骤的相应卷积表示。

4.6 节点聚类

为进一步比较不同图嵌入模型在数据集上的

性能,在IMDB、DBLP和ACM数据集上进行节点聚类实验。将测试集中的节点嵌入放入 K 均值聚类模型,IMDB中电影节点,DBLP中作者节点及ACM中论文节点。由于对异构模型进行无监督聚类,因此用NMI和ARI作为评价指标进行对比。将每个模型聚类结果运行10次并记录平均指标。

节点聚类结果见表3,可以看出MCHGNN优于MAGNN、HGNN_AC及OSGNN,在3个数据集上均取得最优指标,IMDB数据集提升1%,ACM和DBLP数据集提升2%~3%。相较于MAGNN以及HGNN_AC消息传递模型,MCHGNN通过元路径内卷积增强节点之间的内部联系,使聚类性能得到明显提升。MCHGNN

通过自注意力语义融合聚合元路径内部图卷积信息,相较于OSGNN仅利用元图处理异构图语义信息,在性能上表现更优。

表3 节点聚类结果

算法	IMDB		ACM		DBLP	
	NMI	ARI	NMI	ARI	NMI	ARI
MAGNN	13.3%	11.6%	65.5%	69.3%	79.2%	84.6%
HGNN_AC	13.6%	14.4%	64.9%	68.5%	79.6%	84.9%
OSGNN	15.9%	18.1%	72.4%	74.5%	81.6%	86.4%
MCHGNN	16.8%	19.4%	74.5%	77.1%	83.1%	87.4%

4.7 消融实验

为进一步研究算法的有效性,本节对MCHGNN算法进行消融研究,分别测试算法的3种变体,具体如下。

- MCHGNN_fea表示不使用特征转换。
- MCHGNN_con表示不使用元路径内卷积编码,使用节点级注意力^[9]聚合向量作为节点潜在特征。
- MCHGNN_att表示不使用自注意力融合语义信息,使用语义级注意力^[9]聚合多元路径信息。

MCHGNN_fea、MCHGNN_con以及MCHGNN_att各个变体在节点分类任务上的消融实验结果如图4所示,分别表示节点特征转换、元路径内卷积编码以及自注意力机制的语义融合模块对于

MCHGNN性能提升的必要性。图4中Macro-F1及Micro-F1取测试集20%、40%、60%和80%上结果的平均值。

由实验结果可得出以下结论。

(1) 节点特征转换能够有效调整节点特征信息,一定程度上增加节点嵌入效果。使用自注意力模块能够更好地融合不同元路径下的语义,对节点嵌入效果有着重要影响。

(2) 元路径内卷积编码能够有效学习图的高阶邻域信息,并将其表达在元路径向量中,提升节点特征的结构性信息,对原始节点属性特征稀疏的数据集能够更好地提升其嵌入表达效果。

(3) 基于自注意力机制的语义融合能够更好地处理不同元路径之间的相互关系,并与元路径内卷积编码共同处理图的异构性信息,成为模型性能提升的关键因素。

(4) MCHGNN_fea与MCHGNN实验结果相近,表明特征传播模块能够在一定程度上提升模型性能。在IMDB数据集中,MCHGNN_att效果较好,表明在数据属性特征稀疏的数据集中,元路径内卷积编码对算法效果影响程度更大。在ACM数据集中,MCHGNN_con效果较好,表明在数据属性信息丰富的数据集中,自注意力语义融合模块对算法影响程度更大。

(5) MCHGNN可以利用数据集信息的不同




图4 消融实验结果



特征,通过元路径内卷积编码以及自注意力语义融合共同作用提升算法有效性。

4.8 效率分析

为测试模型稳定性,通过改变IMDB原始数据集规模,测试模型性能。具体将不同电影联系的8个异构图组成不同的数据集,用(电影,导演,演员)元组表示规模。该异构图数据集包括:(500, 267, 846), (1 000, 482, 1 469), (1 500, 674, 2 032), (2 000, 870, 2 537), (2 500, 1 097, 3 009), (3 000, 1 343, 3 490), (3 500, 1 606, 4 068), (4 278, 2 081, 5 257)。稳定性结果如图5所示,对所有方法在GPU上运行10次,结果取平均运行时间(单位为s)。运行时间分析如图5(a)所示,由于MCHGNN元路径内卷积计算与元路径长度线性相关,因此时间成本相对于HGNN标度线性增加。OSGNN和HAN收敛速度较慢,需要构建非常密集的基于元路径的图,效率较低。MAGNN和MAGNN_AC通过大量聚合邻域注意力实现对象级聚合操作,因此时间成本较大。

为分析元路径长度对模型性能的影响,通过元路径长度对Macro-F1及Micro-F1值的影响分析算法有效性。结果取测试集20%、40%、60%和80%结果的平均值。结果如图5(b)所示,在IMDB数据集中元路径长度为2时,不能有效提取图异构性信息,无法正确进行元路径卷积运算导致效果较差。元路径长度为3时精确度最高,并随着元路径长度增加精确度下降。过长的元路径会使节点信息在计算过程中丢失,且长元路径会线性增加模型的运行时间和空间,因此在不同数据集选择表现最优的元路径长度。

进一步分析MCHGNN算法的性能对于嵌入维度 d 的参数敏感性实验,在其他超参数固定的情况下,将 d 从16逐渐增加到1 024,并报告Macro-F1与Micro-F1的值,结果取20%、40%、60%和80%的平均值。参数分析结果如图6所




图5 稳定性结果

示, Macro-F1与Micro-F1对于参数的敏感性趋势相似,并随着维数 d 的增加,精度值上升,在64得到最优,然后性能开始下降。说明MCHGNN算法需要一定维数大小来保证其元路径卷积有效性,随着维度增加,图卷积中噪声信息增加,性能降低。因此,本文嵌入维度 d 选择为64。

4.9 有效性分析

MCHGNN算法的一个显著特征是能够评估所有元路径上节点类型的重要性,在特定任务中利用有效的图结构信息。在IMDB数据集上展示节点分类任务中各个元路径子邻接矩阵重要性,识别不同节点类型在元路径内卷积中的重要性。首先,计算每个元路径中的节点类型注意力分布,再计算元路径间的注意力权值,元路径子邻接矩阵重要性权值见表4。




图6 参数分析结果

表4 元路径子邻接矩阵重要性权重

元路径	节点类型	重要性权重
MDM	M	$0.11 \times 0.61 = 0.0671$
	MD	$0.37 \times 0.61 = 0.2257$
	MDM	$0.52 \times 0.61 = 0.3172$
MAM	M	$0.20 \times 0.39 = 0.0780$
	MA	$0.42 \times 0.39 = 0.1638$
	MAM	$0.38 \times 0.39 = 0.1482$

由表4可知,在元路径内卷积过程中,为每个节点类型进行图卷积计算是必要的。对于目标电影节点而言,除了导演与演员邻居对其贡献外,他们之间共同创作的电影占有部分权重。元路径内卷积编码能够捕获目标节点所有高阶语义信息,使节点嵌入信息更加丰富,并通过自注意力机制语义融合,挖掘重要的传播路径,为现实世界的应用场景提供深入见解和可解释性。

为更直观地比较各个模型在节点嵌入上的效果,在DBLP数据集上使用t-SNE^[29]对论文节点进行可视化,并根据其标签分为4类。DBLP数据集可视化结果如图7所示,MAGNN通过重复

邻居注意力导致信息丢失,使节点中间区域区分较为混乱,HGNN_AC中间区域有部分节点聚集,OSGNN节点类别区分较不明显。MCHGNN通过元路径内卷积挖掘节点间的内部联系,增强节点间的相关性,并通过自注意力机制探索各个语义间的交互关系,能够较好地将节点分为4类,且聚集错误节点较少。

5 结束语

为解决节点在元路径中高阶信息无法被有效利用的问题,本文提出基于元路径卷积的异构图神经网络算法。该模型首先通过节点特征转换将节点投影至相同潜在空间,并自动调整其属性特征;其次设计元路径内卷积编码在单条元路径下进行图卷积操作,获取节点邻域结构信息;最后使用自注意力机制融合不同元路径下的语义信息,学习元路径间的全局相关性。3个数据集上的实验结果表明,本文所提出的基于元路径卷积




图7 DBLP数据集可视化结果



的异构图神经网络算法能够有效提升节点嵌入效果,在元路径下的内卷积操作有效弥补了节点的属性特征,加强节点分类效果。利用自注意力聚合探索节点间的交互关系,使聚类实验得到最优指标,提升可视化效果,验证了本算法的优异性和各个模块的必要性。

在未来的工作中,可以从以下两个方面继续深入研究异构图嵌入学习:通过边的异构性进一步提升结构信息表达能力;优化节点特征弥补节点特征空间不一致问题,提高节点初始信息表达能力。

参考文献:

- [1] WEI Y C, FU X C, SUN Q Y, et al. Heterogeneous graph neural network for privacy-preserving recommendation[C]//Proceedings of the 2022 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE Press, 2022: 528-537.
- [2] 杨帅,王瑞琴,马辉.基于多通道的边学习图卷积网络[J].电信科学,2022,38(9):95-104.
YANG S, WANG R Q, MA H. Multi-channel based edge-learning graph convolutional network[J]. Telecommunications Science, 2022, 38(9): 95-104.
- [3] WANG J C, ZHANG Y, WANG L X, et al. Multitask hyper-graph convolutional networks: a heterogeneous traffic prediction framework[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 18557-18567.
- [4] 刘群,谭洪胜,张优敏,等.基于元路径的动态异质网络表示学习[J].电子学报,2022,50(8):1830-1839.
LIU Q, TAN H S, ZHANG Y M, et al. Dynamic heterogeneous network representation method based on meta-path[J]. Acta Electronica Sinica, 2022, 50(8): 1830-1839.
- [5] YU P Y, FU C F, YU Y W, et al. Multiplex heterogeneous graph convolutional network[C]//Proceedings of the Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2022: 2377-2387.
- [6] 陶涛,李珍,王冀彬,等.基于图神经网络的权益推荐技术方案研究[J].电信科学,2023,39(8):91-101.
TAO T, LI Z, WANG J B, et al. Research on the graphical convolution neural network based benefits recommendation system strategy[J]. Telecommunications Science, 2023, 39(8): 91-101.
- [7] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[J]. arXiv preprint, arXiv: 1609.02907, 2016.
- [8] VELIKOVI P, CUCURULL G, CASANOVA A, et al. Graph attention networks[J]. arXiv preprint, arXiv:1710.10903, 2017.
- [9] WANG X, JI H Y, SHI C, et al. Heterogeneous graph attention network[C]//Proceedings of the WWW '19: The World Wide Web Conference. New York: ACM, 2019: 2022-2032.
- [10] FU X Y, ZHANG J N, MENG Z Q, et al. MAGNN: metapath aggregated graph neural network for heterogeneous graph embedding[C]//Proceedings of the Proceedings of The Web Conference 2020. New York: ACM, 2020: 2331-2341.
- [11] YANG X C, YAN M Y, PAN S R, et al. Simple and efficient heterogeneous graph neural network[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(9): 10816-10824.
- [12] ZHAO T Y, YANG C, LI Y B, et al. Space4HGNN: a novel, modularized and reproducible platform to evaluate heterogeneous graph neural network[C]//Proceedings of the Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022: 2776-2789.
- [13] 任嘉睿,张海燕,朱梦涵,等.基于元图卷积的异质网络嵌入学习算法[J].计算机研究与发展,2022,59(8):1683-1693.
REN J R, ZHANG H Y, ZHU M H, et al. Embedding learning algorithm for heterogeneous network based on meta-graph convolution[J]. Journal of Computer Research and Development, 2022, 59(8): 1683-1693.
- [14] JIN D, HUO C Y, LIANG C D, et al. Heterogeneous graph neural network via attribute completion[C]//Proceedings of the Proceedings of the Web Conference 2021. New York: ACM, 2021: 391-400.
- [15] XU W T, XIA Y C, LIU W Q, et al. Shgnn: structure-aware heterogeneous graph neural network[J]. arXiv preprint, arXiv: 2112.06244, 2021.
- [16] ZHAN L, JIA T. CoarSAS2hvec: heterogeneous information network embedding with balanced network sampling[J]. Entropy, 2022, 24(2): 276.
- [17] YUN S, JEONG M, KIM R, et al. Graph transformer networks[J]. Advances in neural information processing systems, 2019, 32.
- [18] YANG Y M, GUAN Z Y, LI J X, et al. Interpretable and efficient heterogeneous graph convolutional network[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(2): 1637-1650.
- [19] CHEN K J, LU H, LIU Z, et al. Heterogeneous graph convolutional network with local influence[J]. Knowledge-Based Systems, 2022(236): 107699.
- [20] LYU Q S, DING M, LIU Q, et al. Are we really making much

- progress? : Revisiting, benchmarking and refining heterogeneous graph neural networks[C]//Proceedings of the Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: ACM, 2021: 1150-1160.
- [21] DU C G, YAO K C, ZHU H S, et al. Seq-HGNN: learning sequential node representation on heterogeneous graph[J]. arXiv preprint, arXiv:2305.10771, 2023.
- [22] 王悦天, 傅司超, 彭勤牧, 等. 半监督场景下多视角信息交互的图卷积神经网络[J]. 软件学报, 2023: 1-18.
- WANG Y T, FU S C, PENG Q M, et al. Multi-view interaction graph convolutional network for semi-supervised classification[J]. Journal of Software, 2023: 1-18.
- [23] WANG X, BO D Y, SHI C, et al. A survey on heterogeneous graph embedding: methods, techniques, applications and sources[J]. IEEE Transactions on Big Data, 2023, 9(2): 415-436.
- [24] GUAN W L, JIAO F K, SONG X M, et al. Personalized fashion compatibility modeling via metapath-guided heterogeneous graph learning[C]//Proceedings of the Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022: 482-491.
- [25] WU Z Y, LIANG Q Y, ZHAN Z H. Course recommendation based on enhancement of meta-path embedding in heterogeneous graph[J]. Applied Sciences, 2023, 13(4): 2404.
- [26] CHEN H, HONG P F, HAN W, et al. Dialogue relation extraction with document-level heterogeneous graph attention networks[J]. Cognitive Computation, 2023, 15(2): 793-802.
- [27] DONG Y X, CHAWLA N V, SWAMI A. metapath2vec: scalable representation learning for heterogeneous networks[C]//Proceedings of the Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2017: 135-144.
- [28] YAN Y Y, LI C, YU Y W, et al. OSGNN: original graph and subgraph aggregated graph neural network[J]. Expert Systems with Applications, 2023(225): 120115.
- [29] VAN DER M L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008(9): 2579-2605.

[作者简介]



秦志龙 (1999-), 男, 浙江理工大学计算机科学与技术学院 (人工智能学院) 硕士生, 主要研究方向为异构图神经网络和深度学习等。



邓琨 (1980-), 男, 博士, 嘉兴大学浙江省全省多模态感知与智能系统重点实验室、嘉兴大学信息科学与工程学院副教授、硕士生导师, 主要研究方向为网络结构分析、数据挖掘、异构网络分析等。



刘星妍 (1980-), 女, 嘉兴大学信息科学与工程学院高级工程师, 主要研究方向为数据挖掘、网络结构分析等。