



研究与开发

基于霍克斯过程的动态异质网络表征学习方法

陈蕾^{1,2,3}, 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. 浙江师范大学计算机科学与技术学院 (人工智能学院), 浙江 金华 321004;
3. 嘉兴大学浙江省医学电子与数字健康重点实验室, 浙江 嘉兴 314001)

摘要: 现有的异质网络表征学习方法主要关注静态网络, 忽略了时间属性对节点表示的重要影响。然而, 真实的异质信息网络极具动态性, 节点和边的微小变化都可能影响整个结构和语义。鉴于此, 提出了基于霍克斯过程的动态异质网络表征学习方法。首先, 利用关系旋转编码方式和注意力机制, 学习相邻节点的注意力系数, 获得节点的向量表示。其次, 学习不同元路径的最优加权组合以更好捕获网络的结构和语义信息。最后, 基于时间衰减效应, 通过邻域形成序列将时间特征引入节点表示中, 得到节点的最终嵌入表示。在多种基准数据集上的实验结果表明, 所提方法在性能上显著优于对比模型。在节点分类任务中, Macro-F1 平均提高了 0.15%~3.45%, 在节点聚类任务中, 归一化互信息 (normalized mutual information, NMI) 值提高了 1.08%~3.57%。

关键词: 网络表征学习; 动态异质信息网络; 注意力机制; 元路径; 霍克斯过程

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024195

Dynamic heterogeneous network representation learning method based on Hawkes process

CHEN Lei^{1,2,3}, 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 Normal University, Jinhua 321004, China
3. Key Laboratory of Medical Electronics and Digital Health of Zhejiang Province, Jiaxing University, Jiaxing 314001, China

Abstract: Existing methods for heterogeneous network representation learning mainly focus on static networks, overlooking the significant impact of temporal attributes on node representations. However, real heterogeneous informa-

收稿日期: 2024-04-02; 修回日期: 2024-08-05

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)

tion networks are very dynamic, and even minor changes in nodes and edges can affect the entire structure and semantics. In this context, a dynamic heterogeneous network representation learning method based on Hawkes process was proposed. Firstly, the vector representation of nodes was obtained by utilizing the relational rotation encoding method and attention mechanism, where the attention coefficients of adjacent nodes were learned. Secondly, the optimal weighted combination of different meta-paths was learned to better captures the structural and semantic information of the network. Finally, leveraging the time decay effect, time features were introduced into node representations through the formation of neighborhood sequences, resulting in the ultimate embedding representation of nodes. Experimental results on various benchmark datasets indicate that the proposed method significantly outperforms baseline methods. In node classification tasks, Macro-F1 average is increased by 0.15% to 3.45%, and NMI value in node clustering tasks is improved by 1.08% to 3.57%.

Key words: network representation learning, dynamic heterogeneous information network, attention mechanism, meta-path, Hawkes process

0 引言

现今信息驱动时代,网络图模型已成为各类数据的核心表达形式,广泛应用于社交网络^[1]、引文网络^[2]和交通网络^[3]等多个领域。网络表征学习作为近年来的研究焦点,通过挖掘网络结构内在规律和节点属性信息,将高维稀疏的结构数据转化为低维稠密的向量表示,推动了社区检测^[4]、链接预测^[5]、节点分类^[6]等下游任务的性能提升。尽管目前静态同质网络表征学习、静态异质网络表征学习、动态同质网络表征学习大多已取得显著成果,但动态异质网络表征学习仍待探索,近年来因其能同时捕获结构语义信息和动态性信息而备受相关领域的关注。

现有的静态异质信息网络(heterogeneous information network, HIN)表征学习方法,如异质图注意力网络(heterogeneous graph attention network, HAN)^[7]、与文本相关的深度游走(text-associated deepwalk, TADW)方法^[8]、用于推荐的异质信息网络嵌入(heterogeneous information network embedding for recommendation, HERec)方法^[9]等,在处理静态HIN时虽表现出色,但无法有效应对动态HIN中节点和边的时变特性,且存在忽略节点内容特征、舍弃元路径上的所有中间节点或仅依赖单个元路径进行信息提取的局限

性。为应对这一挑战,近年来研究者们开始探索动态网络表征学习方法,如动态高阶邻近性保持嵌入(dynamic high-order proximity preserved embedding, DHPE)表示^[10]、连续时间动态网络嵌入(continuous-time dynamic network embedding, CTDNE)表示^[11]、带有微观和宏观动态的时序网络嵌入(temporal network embedding with micro- and macro-dynamics, M²DNE)表示^[12]等。然而,这些方法大多未充分考虑网络的异质性,若直接应用于动态HIN中,将不可避免地导致一些结构和语义的丢失,进而影响下游任务的性能。

鉴于此,动态异质网络表征学习成了一个亟待解决且极具挑战性的课题。其核心挑战主要体现在以下3个方面:如何在捕捉网络结构动态变化的同时,保留关键的网络结构信息;如何全面捕获HIN中多类型的语义信息;如何在HIN中有效体现网络的动态演化特性。

针对上述挑战,本文提出了一种基于霍克斯过程的动态异质网络表征学习方法(dynamic heterogeneous network representation learning method based on Hawkes process, DHNRHP),主要贡献包括如下3点:(1)引入关系旋转编码器,对元路径实例中的所有节点进行编码,通过注意力机制融合多种语义信息,捕获HIN中更丰富的结构



和语义信息；(2) 基于时序网络，引入霍克斯过程，利用其时间衰减特性和邻域形成序列，准确建模动态 HIN 的演化特性；(3) 在 3 个真实数据集上进行了全面实验，以验证模型的有效性，实验结果显示，所提方法在节点分类、聚类、可视化等任务上相较于对比模型有明显的性能提升。

1 相关工作

为更清晰地说明本文所提方法的目标任务，在此描述与 DHNRHP 方法密切相关的网络表征学习的 3 个研究分支，即静态异质网络表征学习方法、动态同质网络表征学习方法以及动态异质网络表征学习方法。

1.1 静态异质网络表征学习方法

现实世界的网络多为包含多种节点和边的异质信息网络，现有静态 HIN 表征学习方法大多通过元路径捕获结构语义并聚合邻居信息以获取节点表示。例如，Li 等^[13]提出基于元路径上下文在异质信息网络中进行分类的方法 (leveraging meta-path contexts for classification in heterogeneous information network, Con CH)，结合半监督与自监督学习，通过元路径和图卷积网络融合图结构信息。Yang 等^[14]提出可解释的高效异构图卷积网络 (interpretable and efficient heterogeneous graph convolutional network, ie-HGCN)，动态选择元路径以优化节点表征。Jia 等^[15]提出互信息与多条元路径融合的异质网络表示学习方法，最大化局部和全局互信息以捕获信息联系。上述方法虽均考虑了节点特征和不同关系类型间的关联性，但都过度依赖人工设定的元路径，结构和语义信息的保留仍有待提升。

1.2 动态同质网络表征学习方法

目前动态网络表征学习主要聚焦于动态同质网络，即节点和边类型单一但随时间演化的网络。例如，Zhou 等^[16]提出模拟三元闭包过程的动态网络嵌入 (dynamic network embedding by

modeling triadic closure process, DynamicTriad)，基于三元闭合过程保留快照网络结构与演化信息。Zuo 等^[17]提出基于霍克斯过程的时序网络嵌入 (Hawkes process based temporal network embedding, HTNE)，通过霍克斯过程建模邻域形成序列以捕捉动态性。Yin 等^[18]提出基于霍克斯点过程的动态网络表示学习 (dynamic network representation learning based on Hawkes point process, MHNE) 方法，建模历史结构与演化机制训练节点表示。然而，这些方法虽能有效处理动态网络演化，但面对动态 HIN 时可能忽略异质信息，导致信息损失。

1.3 动态异质网络表征学习方法

动态异质网络因其能充分兼顾结构语义和动态性而备受关注。当前基于时间快照的动态异质网络表征学习方法通过捕捉时间快照分析其动态变化。例如，Xue 等^[19]提出一种基于时间 RNN 的分层关注动态异构网络链路预测建模 (modeling dynamic heterogeneous network for link prediction using hierarchical attention with temporal RNN, DyHATR)，使用分层注意力和循环神经网络学习异质信息，捕获进化模式。Wang 等^[20]提出基于元路径邻近度的动态异构信息网络嵌入 (dynamic heterogeneous information network embedding with meta-path based proximity, DyHNE)，通过元路径和广义特征值学习节点嵌入，捕捉动态效应。Fan 等^[21]提出异质时序图神经网络 (heterogeneous temporal graph neural network, HTGNN)，通过分层聚合机制捕获时间快照中的节点表示。尽管上述方法大多取得较好效果，但主要关注特定时间点，忽略了时序交互性，导致对网络动态演化过程的理解有所欠缺。

基于时序的动态异质网络表征学习方法关注节点和边的时间演变，捕获网络异质信息和时序交互。例如，Guo 等^[22]提出基于非递减时序随机游走的动态异质网络嵌入 (dynamic heteroge-

neous network embedding based on non-decreasing temporal random walk, TNDE), 引入时间约束增量式随机游走, 兼顾网络的异质性与时间戳问题。Qin 等^[23]提出基于元路径与层次注意力的时序异质信息网络表示学习 (meta-path and hierarchical attention based temporal heterogeneous information network representation learning, MA-THNRL) 方法, 利用元路径和时间衰减注意力, 探索不同时间下元路径实例对目标节点的影响。Liu 等^[24]提出基于元路径的动态异质网络表示方法 (dynamic heterogeneous network representation method based on meta-path, DHNR), 结合时间加权元路径与门控循环单元归纳网络演化规律。这些方法虽能在一定程度上反映动态性, 但在保留关键网络结构信息方面仍有不足。目前该领域研究尚处于起步阶段, 挑战与机遇并存。

现有的动态异质网络表征学习方法在学习过程中无法兼顾异质性与动态性, 且极大地忽视了元路径中间节点和时序交互, 容易丢失结构语义等关键信息。基于此, 本文提出基于霍克斯过程的动态异质网络表征学习方法, 通过时间衰减效应和注意机制捕获时序信息, 学习邻域形成序列, 从而学习更丰富的节点表示。

2 基本定义

本节主要给出与异质信息网络相关的一些重要术语的定义。

定义 1 (异质信息网络^[25]) 给定异质信息网络 $G=(V,E)$, 其中, V 为节点集, $v \in V$ 表示网络中的一个实体, E 为边集, $e \in E$ 表示网络中两个实体之间的关系。异质信息网络存在节点类型映射函数 $\psi: V \rightarrow A$ 和边类型映射函数 $\phi: E \rightarrow R$ 。 A 和 R 分别表示预定义的节点类型集合和边类型集合, 其中 $|A|+|R|>2$ 。

定义 2 (元路径^[25]) 异质信息网络的一条

元路径 Φ 定义为 $A_1 \xrightarrow{R_1} A_2 \xrightarrow{R_2} \cdots \xrightarrow{R_l} A_{l+1}$ (缩写 $A_1 A_2 \cdots A_{l+1}$), 它描述了节点类型 A_1 到 A_{l+1} 之间的复合关系 $R=R_1 \circ R_2 \cdots \circ R_l$ 。其中, $\circ$ 表示关系上的组合运算符。

定义 3 (基于元路径的邻居^[26]) 在异质信息网络中, 给定一个节点 v 和一条元路径 Φ , 每个节点都存在一组基于元路径的邻居。基于元路径的邻居节点 N_v^Φ 是在元路径 Φ 下与节点 v 相连接的节点集。

定义 4 (邻域形成序列^[17]) 在动态网络 $G=<V,E,T>$ 中, V 表示节点集, E 表示边集, T 表示时间戳。若存在节点 $x \in X$, 则节点 x 的邻域是 $N(x)=\{y_i | i=1,2,\cdots\}$, 节点 x 邻域形成序列为 $\{x: (y_1, t_1) \rightarrow (y_2, t_2) \rightarrow \cdots \rightarrow (y_n, t_n)\}$ 。其中, 每个元组代表 y_i 在时间 t_i 成为节点 x 的邻居。

定义 5 (基于时序的动态异质信息网络) 给定一个基于时序的动态异质信息网络记为 $G=<V,E,B,T>$, 其中, $|V|+|E|>2$, V 表示节点集, E 表示边集, B 表示每个节点的邻居形成序列, T 表示时间戳。

以学术网络为例, 动态异质信息网络示意图如图 1 所示, 图 1 (a) 是该学术网络的结构图, 是一个基于时序的动态异质信息网络, 包含 A (Author)、 P (Paper)、 C (Conf) 3 种节点类型。图 1 (b) 展示了网络中两条元路径 APA 和 APCPA。图 1 (c) 展示了以节点 A_4 为起点, APA 为元路径, 节点 A_4 的邻居为 A_2, A_3, A_5, A_6 , 形成时间依次为 t_1, t_1, t_2, t_3 。图 1 (d) 进一步将 A_4 的邻居及其形成时间进行组合, 得出 A_4 的邻域形成序列。

问题定义 动态异质网络表征学习。给定一个基于时序的动态异质信息网络 $G=<V,E,B,T>$ 作为输入, 对于任意节点 $v \in V$, 通过学习异质时序网络嵌入, 旨在学习映射函数 $N: v \rightarrow N_v \in \mathbb{R}^d$, 将网络 G 中的节点 v 映射为低维空间中的一个向




图1 动态异质信息网络示意图

量 N_v , 其中, d 为学习到的低维稠密嵌入向量维度, $d \ll |V|$, 使得学习到的低维稠密向量, 能够全面保存对应动态异质信息网络中的结构、语义信息和动态性变化。

3 基于霍克斯过程的动态异质网络表征学习框架及实现

本文提出的 DHNRHP 方法总体框架如图 2 所示。该方法由 3 个分层注意力构成: 节点级注意、语义级注意和时间级注意。在节点级注意部分, 采用关系旋转编码和注意力机制的方式对元路径内部进行编码, 学习相邻节点的注意力系数, 并加权聚合得到该元路径下的节点嵌入; 在语义级注意部分, 学习不同元路径的最优加权组合, 以全面地捕获异质信息网络中丰富的结构和语义信

息; 在时间级注意部分, 通过霍克斯过程建模邻域形成序列将时间特征引入节点表示中, 得到节点最终嵌入表示。

3.1 节点级注意

3.1.1 节点内容转换

在异质信息网络中, 不同节点类型的节点, 其特征空间通常不同。因此, 需要设计特定的变换矩阵 M_{ϕ_v} , 以便将各类节点的特征有效地映射到统一的向量空间中, 具体操作如下。

$$h'_v = M_{\phi_v} \cdot h_v \quad (1)$$

其中, h_v 为节点 v 的初始特征, h'_v 为节点 v 的投影潜在向量。

3.1.2 元路径实例编码

给定元路径 ϕ_p , 利用元路径内部聚合编码方式对元路径内部节点进行建模, 通过编码将




图2 DHNRHP方法总体框架

元路径实例中所有节点的特征转化为对应的向量表示:

$$\mathbf{h}_{\Phi_{p(v,u)}} = f_{\theta}(\Phi_{p(v,u)}) = f_{\theta}(\mathbf{h}'_v, \mathbf{h}'_u, \{\mathbf{h}'_i, \forall i \in \{m^{\Phi_{p(v,u)}}\}\}) \quad (2)$$

其中, $\Phi_{p(v,u)}$ 为单个实例, 中间节点定义为 $\{m^{\Phi_{p(v,u)}}\} = \Phi_{p(v,u)} / \{u, v\}$, f_{θ} 表示元路径实例编码方式, 如门控循环单元 (gate recurrent unit, GRU) 编码、长短期记忆 (long short-term memory, LSTM) 编码、平均值编码、线性编码器等。

本文采用的是一个基于复杂空间中关系旋转的元路径实例编码器^[27], 即 RotatE 编码方式, 既考虑节点固有的属性, 又同时兼顾它们在顺序结构中的相对关系信息, 具体操作如下。

$$\mathbf{O}_0 = \mathbf{h}'_{x_0} = \mathbf{h}' \quad (3)$$

$$\mathbf{O}_i = \mathbf{h}'_{x_i} + \mathbf{O}_{i-1} \odot \mathbf{r} \quad (4)$$

$$\mathbf{h}_{\Phi_{p(v,u)}} = \frac{\mathbf{O}_n}{n+1} \quad (5)$$

其中, $\Phi_{p(v,u)} = (x_0, x_1, \dots, x_n)$, $x_0 = v$, $x_n = u$, 设定 $\mathbf{r}_i$ 为节点 x_{i-1} 和 x_i 之间的关系向量, $\mathbf{r}_i$ 和 $\mathbf{h}'_{x_i}$ 均为复数向量, $\odot$ 表示两个向量之间的元素内积。

对于目标节点 v , 考虑给定元路径 Φ_p 引导下的多个元路径实例, 每个实例都有相应的时间标记, 即 $v \rightarrow \{(\Phi_{p(v,u)_1, t_1}), (\Phi_{p(v,u)_2, t_2}), \dots, (\Phi_{p(v,u)_l, t_l})\}$, 这些时间标记需要根据具体情况进行分析。

设所有节点的形成时间长度为 L , 则节点时间范围 $[t_0, t_L]$ 。基于元路径 Φ_p 的节点 v 的邻居节点按时间分组, 节点 v 在 t_l 时刻的邻居则为 (v, u_{t_l}) , 可通过自注意力机制学习获得这些邻居节点的权重系数。

$$e_{v, u_{t_l}}^{\Phi_p} = \text{Leaky ReLU}(\mathbf{a}_{\Phi_p}^T \cdot [\mathbf{h}'_v || \mathbf{h}_{\Phi_{p(v,u), t_l}}]) \quad (6)$$

其中, $\mathbf{a}_{\Phi_p}^T$ 为注意力向量, $||$ 表示拼接组合, $\mathbf{h}_{\Phi_{p(v,u), t_l}}$ 为 t_l 时刻元路径实例 $\Phi_{p(v,u), t_l}$ 的向量表示, $e_{v, u_{t_l}}^{\Phi_p}$ 表示元路径实例 $p(v, u)$ 在 t_l 时刻对节点 v 的重要性。

归一化得到最终的注意力系数权重。

$$\alpha_{v, u_{t_l}}^{\Phi_p} = \text{soft max}(e_{v, u_{t_l}}^{\Phi_p}) \quad (7)$$

加权聚合子节点信息, 同时聚合 t_l 时刻以来的节点信息, 得到相应嵌入表示:

$$\mathbf{Z}_v^{\Phi_p} = \sigma \left(\sum_{L=0}^L \sum_{u \in S_v^{\Phi_p}} \alpha_{v, u_{t_l}}^{\Phi_p} \cdot \mathbf{h}_{\Phi_{p(v,u), t_l}} \right) \quad (8)$$

引入多头注意力, 重复 K 次节点级注意过程, 对结果取平均, 并基于元路径 Φ_p 连接所学嵌入。

$$\mathbf{Z}_v^{\Phi_p} \leftarrow \left\| \sum_{k=1}^K \mathbf{Z}_v^{\Phi_p} \right\| \quad (9)$$

3.2 语义级注意

为获得更全面的节点嵌入表示, 需要融合不同元路径揭示的语义信息, 即使用元路径聚合器合并每个元路径的信息。将节点级注意学习到的嵌入表示作为输入, 为每个元路径赋予重要性权重 w_{Φ_p} , 表达式如下。

$$w_{\Phi_p} = \frac{1}{|V_{A_i}|} \sum_{v \in V_{A_i}} \mathbf{q}_{A_i}^T \cdot \tanh(\mathbf{M}_{A_i}^z \mathbf{Z}_v^{\Phi_p} + \mathbf{b}_{A_i}) \quad (10)$$

其中, $\mathbf{q}_{A_i}^T$ 为语义注意向量, $\mathbf{M}_{A_i}^z$ 为权重矩阵, $\mathbf{b}_{A_i}$ 为偏差向量, 三者都是可学习的参数。在获得每个元路径的重要性后, 通过 softmax 函数得到归一化后的重要性权重 β_{Φ_p} , β_{Φ_p} 值越大, 元路径 Φ_p 越重要。

$$\beta_{\Phi_p} = \frac{\exp(w_{\Phi_p})}{\sum_{p=1}^P \exp(w_{\Phi_p})} \quad (11)$$

将学习的重要性权重作为系数, 融合这些语义特定的嵌入, 以获得节点 v 最终的嵌入 $\mathbf{Z}_v$, 表达式如下。

$$\mathbf{Z}_v = \sum_{p=1}^P \beta_{\Phi_p} \cdot \mathbf{Z}_v^{\Phi_p} \quad (12)$$

3.3 时间级注意

本文使用霍克斯过程^[17]的时间衰减特性建模和解决异质图的动态网络问题。假设时间 t 之前的历史事件会影响当前事件, 且影响程度会随时间流逝而逐渐减弱。霍克斯过程是通过上述假设



对离散序列事件建模的典型时间点过程, 其衰减特性非常适合于建模邻域形成序列, 因此, 将时间级注意机制定义如下。

$$\tilde{\lambda}_{u|v}(t) = \mu_{v,u} + \sum_{t_h < t} \alpha_{h,u} k(t - t_h) \quad (13)$$

其中, $\tilde{\lambda}_{u|v}$ 为在霍克斯过程中定义的条件强度函数, 表示节点 v 和 u 之间的距离。 $\mu_{v,u}$ 表示在 v 和 u 之间形成边缘的事件的基本速率, 即源节点 v 和目标节点 u 的接近程度, 通过负平方欧氏距离作为相似性度量进行表示。 h 为时间 t 之前节点 v 的邻居, $\alpha_{h,u}$ 表示历史邻居 h 激发当前邻居 u 的程度, 使用相同的相似性度量方法。 $k(\cdot)$ 是用于刻画时间衰减效应的核函数, 用指数函数的形式表示。

$$\mu_{v,u} = -\|\mathbf{Z}_v - \mathbf{Z}_u\|^2 \quad (14)$$

$$\alpha_{h,u} = w_{h,v} f(\mathbf{Z}_h, \mathbf{Z}_u) = w_{h,v} (-\|\mathbf{Z}_h - \mathbf{Z}_u\|^2) \quad (15)$$

$$k(t - t_h) = \exp(-\delta_s(t - t_h)) \quad (16)$$

其中, δ 为源相关参数, 表明对于每个源节点, 历史邻居可以以不同的强度影响当前邻居的形成。

$$w_{h,v} = \frac{\exp(-\|\mathbf{Z}_v - \mathbf{Z}_h\|^2)}{\sum_{h'} \exp(-\|\mathbf{Z}_v - \mathbf{Z}_{h'}\|^2)} \quad (17)$$

由于引入的相似性度量值为负值, 需要应用指数函数将条件强度值转换为正实数。

$$\lambda_{u|v}(t) = \exp(\tilde{\lambda}_{u|v}(t)) \quad (18)$$

3.4 模型优化

目标函数是基于给定节点 v 和邻域形成序列的霍克斯过程, 以生成节点 u 的条件概率, 如式 (19) 所示。

$$p(u|v, H_v(t)) = \frac{\lambda_{u|v}(t)}{\sum_{u'} \lambda_{u'|v}(t)} \quad (19)$$

其中, $H_v(t)$ 为时间 t 之前节点 v 的邻域形成序列。对没有出现的负节点进行采样, 最终目标函数为:

$$L = \log \sigma(\tilde{\lambda}_{u|v}(t)) + \sum_{k=1}^K E_{i^k \sim P_n(i)} [-\log \sigma(\tilde{\lambda}_{i^k|v}(t))] \quad (20)$$

其中, K 为根据 $P_n(i)$ 采样的负节点数, $P_n(i) \propto d_i^{\frac{3}{4}}$ 为基于经验值, d_i 为节点 i 的度数。

4 实验与结果分析

4.1 数据集

本文采用异质网络表征学习领域中常用的3种数据集进行实验, 数据集描述见表1。

表1 数据集描述

数据集	节点	边	元路径	目标节点	类别
IMDb	Movie (M): 4 278	M-D: 4278	M-D-M	Movie	3
	Director (D): 2 081	M-A: 12828	M-A-M		
	Actor (A): 5 257				
ACM	Paper (P): 4 019	P-A: 13407	P-A-P	Paper	3
	Author (A): 7 167	P-S: 4019	P-S-P		
	Subject (S): 60				
DBLP	Author (A): 4 057	A-P: 19645	A-P-A	Author	4
	Paper (P): 14 328	P-T: 85810	A-P-T-P-A		
	Term (T): 7 723	P-V: 14328	A-P-V-P-A		
	Venue (V): 20				

(1) 互联网电影数据库 (Internet movie database, IMDb): 一个电影和电视节目的在线数据库, 该数据集涵盖 11 616 个节点, 其中包括 4 278 部电影、2 081 位导演和 5 257 名演员。电影按其类型进行标记, 分为动作片、喜剧和戏剧3类。

(2) 国际计算机学会 (Association for Computing Machinery, ACM): 一个引文网络数据集, 实验抽取 ACM 子集, 该数据集涵盖 11 246 个节点, 其中包括 4 019 篇论文、7 167 位作者和 60 个主题, 论文按其所属领域划分为数据库、无线通信和数据挖掘3类。

(3) 数字目录学和图书馆项目 (Date Base Systems and Logic Programming, DBLP): 一个引文网络数据集, 该数据集涵盖 26 128 个节点, 包括 4 057 位作者、14 328 篇论文、7 723 个术语

和 20 个出版地点，作者按研究领域划分为 4 类，即数据库、数据挖掘、人工智能和信息检索。

4.2 评价指标

实验中节点分类任务的评价指标采用 Macro-F1 和 Micro-F1，其具体定义如式 (21) 和式 (22) 所示。

$$\text{Macro-F1} = 2 \frac{\text{Recall}_{\text{ma}} \times \text{Precision}_{\text{ma}}}{\text{Recall}_{\text{ma}} + \text{Precision}_{\text{ma}}} \quad (21)$$

$$\text{Micro-F1} = 2 \frac{\text{Recall}_{\text{mi}} \times \text{Precision}_{\text{mi}}}{\text{Recall}_{\text{mi}} + \text{Precision}_{\text{mi}}} \quad (22)$$

两个 F1 值评价指标中包含了准确率 (Precision) 和召回率 (Recall)，其具体定义如式 (23) 所示。

$$\left\{ \begin{array}{l} \text{Recall}_{\text{ma}} = \frac{1}{|M|} \sum_{i \in M} \frac{\text{TP}_i}{\text{TP}_i + \text{FN}_i} \\ \text{Precision}_{\text{ma}} = \frac{1}{|M|} \sum_{i \in M} \frac{\text{TP}_i}{\text{TP}_i + \text{FP}_i} \end{array} \right. , \quad \left\{ \begin{array}{l} \text{Recall}_{\text{mi}} = \frac{\sum_{i \in M} \text{TP}_i}{\sum_{i \in M} (\text{TP}_i + \text{FN}_i)} \\ \text{Precision}_{\text{mi}} = \frac{\sum_{i \in M} \text{TP}_i}{\sum_{i \in M} (\text{TP}_i + \text{FP}_i)} \end{array} \right. \quad (23)$$

其中， M 为类别集合；TP 为预测正确的正样本；FP 为预测错误的正样本；FN 为预测错误的负样本。

对于节点聚类任务，采用归一化互信息 (normalized mutual information, NMI) 和调整兰德指数 (adjusted rand index, ARI) 作为节点聚类结果的评价指标，NMI 定义如式 (24) 所示。

$$\text{NMI}(x, y) = 2 \frac{\sum_x \sum_y p(x, y) \log \frac{p(x, y)}{p(x)p(y)}}{-\sum_i p(x_i) - \sum_i p(y_i)} \quad (24)$$

其中， $p(x, y)$ 为 x 和 y 的联合概率分布，NMI 取值范围为 $[0, 1]$ 。

ARI 的定义如式 (25) 所示。

$$\text{ARI} = \frac{\text{RI} - E|\text{RI}|}{\max(\text{RI}) - E|\text{RI}|} \quad (25)$$

其中， $\text{RI} = \frac{a+b}{C_2^{n_{\text{samples}}}}$ ， a 表示被划分为同一簇的实例对数量， b 表示被划分为不同簇的实例对数量，ARI 取值范围为 $[-1, 1]$ 。

4.3 对比模型

为了更全面地评估 DHNRHP 的性能，将其与当前网络表征学习领域的多种前沿方法进行对比。这些对比模型不仅涵盖了从同质网络到异质网络、从静态网络到动态网络的多样化研究方向，也体现了网络表征学习技术的最新演进，有助于从不同角度、不同方向的网络表征学习方法中挖掘差异与共性，更准确地评估 DHNRHP 的优势、局限性以及潜在应用场景。本文选择了如下 6 种具有代表性的对比模型。

(1) 图注意力网络 (graph attention network, GAT) [28]: 一种静态同质网络表征学习方法，该方法使用注意力机制来计算目标节点与其单跳邻居之间的注意力，将计算出的注意力作为权重来聚合其邻域信息，旨在通过对比传统图注意力模型，突出 DHNRHP 在表征学习过程中对结构洞察、语义理解及时间动态捕捉的深刻价值。

(2) M^2DNE [12]: 一种动态同质网络表征学习方法，该方法从宏观和微观动力学角度捕捉网络演变，学习节点表示，旨在通过对比传统时间模型，突出 DHNRHP 在处理动态网络时兼顾异质特性，效果更优。

(3) HAN [7]: 一种静态异质网络表征学习方法，该方法扩展了 GAT 模型，采用分层注意力机制为不同邻居节点和元路径分配不同注意力系数，继而聚合邻居节点信息和多条元路径上的信息，学习节点嵌入表示，旨在通过对比传统异质图注意力模型，突出 DHNRHP 结合分层注意力机制，引入时间级注意的优越性。

(4) 异质图树注意力网络 (heterogeneous



graph tree attention network, HetGTAN)^[29]: 一种静态异质网络表征学习方法, 该方法使用特定于边缘类型的图树注意力网络层和特定于目标的聚合器, 有效融合单跳邻居信息, 获得节点的嵌入表示, 旨在通过对比异质图树注意力模型, 突出 DHNRHP 基于元路径和分层注意力机制的形式更能充分捕获节点丰富的结构语义信息。

(5) 简单高效的异质图神经网络 (simple and efficient heterogeneous graph neural network, SeHGNN)^[30]: 一种静态异质网络表征学习方法, 该方法通过预计算邻居聚合、轻量级均值聚合器、单层结构和长元路径扩展感知域, 结合 Transformer 融合多元路径特征, 进而学习节点嵌入表示, 旨在通过对比融合多元路径特征的异质网络表征模型, 突出 DHNRHP 引入关系旋转编码器的优越性, 有效学习中间被忽略节点的信息, 使得学习到的嵌入表示更为丰富。

(6) 原始图和子图聚合图神经网络 (original graph and subgraph aggregated graph neural network, OSGNN)^[31]: 一种静态异质网络表征学习方法, 该方法通过分解异质图为子图并加权组合成同质图, 进而学习目标节点的一阶和高阶信息, 融合为最终的节点表示, 旨在通过对比新的异质网络表征模型, 突出 DHNRHP 通过霍克斯过程理论技术引入时间特征考虑异质网络中动态变化信息的必要性。

4.4 实验设置

本方法模型所有实验均在 Intel(R) Xeon(R) Gold 6330(2.00 GHz) CPU, RTX 3090(24 GB) GPU, 60 GB 内存的硬件环境下完成训练, 所涉及代码使用 Python 和 PyTorch 框架实现。

DHNRHP 模型通过实验反复优化, 确定以下参数设置: 学习率设置为 0.005, 丢失率设置为 0.5, 权重衰减设置为 0.001, 批处理大小 Batch-size 设置为 8, 注意力头数 K 设置为 8, 历史长度 h 设置为 3, 负样本数量设置为 10。关于嵌入维

度, IMDb 为 512, ACM 和 DBLP 均为 128。为降低模型的过拟合现象, 本文采用早停机制, 并设置耐心值为 10。对于所有对比模型的参数选择, 本文参考原始论文中作者所采用的参数设置。

4.5 节点分类

在节点分类实验中, 本文采用支持向量机对嵌入节点进行分类, 并将实验过程中训练集的比例设置为 20%、40%、60%、80%, 设置多个实验组, 每个实验重复 10 次, 并将最终结果取平均值。本文使用 Macro-F1 和 Micro-F1 这两个评价指标来评估上述模型在节点分类任务上的性能, 实验结果见表 2。

由表 2 可知, DHNRHP 在 3 个不同的数据集上均展现出了优于所有对比模型的性能。与目前主流表征学习方法的最优结果相比, DHNRHP 的 Macro-F1 和 Micro-F1 指标在 IMDb 数据集上分别提高了 3.45% 和 3.29%; 在 ACM 数据集上分别提高了 0.15% 和 0.37%; 在 DBLP 数据集上分别提高了 0.30% 和 0.18%。

实验对比发现, GAT 作为同质网络表征学习方法, 难以处理异质网络中不同类型的节点和边, 未能有效地捕获异质网络的结构, 导致了节点特征的混淆, 而无法区分不同类型的信息, 因此, 在异质信息网络中算法性能较差; M^2DNE 算法同样适用于同质网络, 难以捕获不同节点类型之间的演化以及边类型随时间的变化, 且其主要关注宏观和微观动力学, 在多跳信息传播方面可能较为受限, 故性能也并非很好。

反观异质网络表征学习相关方法, HAN、SeHGNN、HetGTAN 和 OSGNN 较同质网络表征方法有明显提升, 但与本文所提方法 DHNRHP 相比, 仍稍有不足, 分析其主要原因: HAN 将注意力机制应用于异质信息网络中; SeHGNN 使用轻量级均值聚合器捕捉结构信息, 降低了复杂性, 同时引入基于 Transformer 的语义融合模块, 融合来自不同元路径的特征; HetGTAN 通过特定

表2 节点分类结果

数据集	评价指标	训练集比例	GAT	M ² DNE	HAN	HetGTAN	SeHGNN	OSGNN	DHNRHP
IMDb	Macro-F1	20%	54.81%	51.88%	57.61%	60.19%	60.33%	60.91%	65.33%
		40%	55.09%	52.39%	57.75%	60.92%	61.69%	60.77%	66.54%
		60%	55.71%	53.67%	57.66%	61.18%	62.51%	60.34%	66.71%
		80%	55.40%	53.98%	57.23%	61.25%	63.13%	60.79%	66.58%
	Micro-F1	20%	55.02%	54.72%	57.82%	60.23%	60.53%	61.13%	65.41%
		40%	55.56%	55.43%	57.98%	60.90%	61.95%	61.03%	66.57%
		60%	55.91%	55.82%	57.87%	61.51%	62.70%	60.58%	66.79%
		80%	55.67%	55.91%	57.46%	61.72%	63.38%	61.01%	66.67%
	ACM	20%	89.59%	87.41%	90.01%	90.05%	91.46%	93.04%	93.11%
		40%	89.77%	87.53%	90.82%	90.62%	91.61%	93.29%	93.29%
		60%	89.72%	87.95%	91.51%	91.89%	91.78%	93.39%	94.45%
		80%	89.42%	88.02%	91.71%	92.36%	92.18%	93.40%	93.55%
	Micro-F1	20%	89.47%	87.46%	89.89%	90.01%	91.38%	93.12%	93.16%
		40%	89.65%	87.62%	90.73%	91.32%	91.59%	93.19%	93.33%
		60%	89.60%	87.83%	91.37%	91.85%	91.68%	93.29%	94.57%
		80%	89.29%	87.97%	91.56%	92.21%	92.19%	93.31%	93.68%
DBLP	Macro-F1	20%	66.92%	90.48%	91.69%	93.64%	94.45%	94.76%	94.80%
		40%	73.23%	90.65%	91.84%	93.89%	94.32%	94.88%	95.02%
		60%	77.17%	90.92%	92.01%	94.15%	94.41%	94.83%	95.28%
		80%	78.20%	91.34%	92.15%	94.42%	94.57%	94.95%	95.25%
	Micro-F1	20%	76.98%	91.09%	92.30%	94.32%	94.53%	95.05%	95.21%
		40%	79.61%	91.22%	92.46%	94.56%	94.61%	95.15%	95.37%
		60%	81.62%	91.49%	92.65%	94.69%	94.87%	95.23%	95.56%
		80%	82.22%	91.71%	92.78%	94.76%	94.93%	95.31%	95.49%

于节点和边缘类型的变换和聚合器来处理异质性，深入合并高阶邻域的信息；OSGNN则将原始异质图分解为多个子图，进而充分学习目标节点的一阶和高阶信息。这4种方法虽在捕获网络结构信息和节点语义信息上有所创新，性能改善较多，但均忽略了网络中的动态性变化。DHNRHP则采用关系旋转编码和注意力机制学习节点表示，充分捕捉节点间的复杂关系，在兼具异质网络结构和语义信息的同时，引入了时间特征以考虑节点属性和关系的动态变化，这也使得DHNRHP在处理动态网络节点分类任务时表现出色，成为其性能最优的主要原因。

此外，相较于ACM和DBLP数据集，IMDb数据集的表现不佳，IMDb数据集中的特征分布相对稀疏，导致模型难以从中提取有效信息。

4.6 节点聚类

在节点聚类实验中，本文使用K-means执行

节点聚类任务，并使用归一化互信息NMI和调整兰德指数ARI作为节点聚类结果的评价指标，以此评估DHNRHP的算法有效性，节点聚类结果见表3。

由表3可知，所提方法DHNRHP在节点聚类任务中取得最优的效果。DHNRHP与当前对比模型中的最优结果相比，评价指标NMI和ARI在IMDb数据集上分别提升了3.57%和1.19%；在ACM数据集上分别提升了1.08%和0.43%；在DBLP数据集上分别提升了2.81%和3.19%。这进一步说明在兼具异质网络结构和语义信息的同时，基于时间衰减效应，引入时间特征是必要的，能使算法性能得到更好的提升。

4.7 消融实验

本节通过设计一些变体实验进一步验证DHNRHP方法部分操作的有效性，分别在ACM和DBLP这两个数据集上进行了相关的变体实验。



表3 节点聚类结果

数据集	评价指标	GAT	M ² DNE	HAN	HetGTAN	SeHGNN	OSGNN	DHNRHP
IMDb	NMI	7.84%	8.87%	10.79%	13.91%	13.21%	15.75%	19.32%
	ARI	8.87%	8.95%	11.11%	13.25%	14.89%	17.48%	18.67%
ACM	NMI	—	—	—	71.56%	65.34%	73.43%	74.51%
	ARI	—	—	—	75.32%	67.79%	77.76%	78.19%
DBLP	NMI	70.73%	75.08%	77.49%	79.63%	81.20%	79.69%	84.01%
	ARI	76.04%	76.52%	82.95%	84.58%	85.03%	84.21%	88.22%

(1) DHNRHP_gru表示元路径实例编码方式选择的是GRU方式。

(2) DHNRHP_lstm表示元路径实例编码方式选择的是LSTM方式。

(3) DHNRHP_linear表示元路径实例编码方式选择的是Linear方式。

(4) DHNRHP_avg表示元路径实例编码方式选择的是average方式。

(5) DHNRHP_haw表示该方法处理异质信息网络时，主要关注的是通过注意力机制来整合不同的元路径实例，并未将网络中的时间特征纳入考量。

ACM和DBLP数据集上消融研究的节点分类和节点聚类结果分别如图3、图4所示。由图3、图4可以看出，在几种编码方式的选择上，RotatE编码方式表现最佳。其优越性原因分析如下：(1) GRU和LSTM主要在处理有序信息序列时表现出色，而对于本文涉及的无序信息序列，适用性受到限制，优势受限；(2) 在处理元路径内部节点信息时，Linear方法和average方法易丢失信息。相比之下，RotatE编码方式能更全面地捕捉元路径内部节点信息的细微差别，为模拟节点间复杂潜在关系提供有力支持。特别是在异质信息网络的建模过程中，这种全面的信息考虑对于提升模型性能至关重要。此外，可以发现，引入时间特征，使用霍克斯过程的时间衰减特性来建模邻域形成序列，可以更好地解决异质信息网络的动态网络问题。




图3 ACM和DBLP数据集上消融研究的节点分类结果

4.8 参数敏感性

本节研究了参数敏感性，主要针对模型训练中学习率 (Learning_rate)、丢失率 (Dropout_rate)、嵌入维度 Z 和历史长度 h 这4个重要的参数在DBLP数据集上进行分析，具体的两个F1值如下所示。




图4 ACM和DBLP数据集上消融研究的节点聚类结果

4.8.1 学习率和丢失率

学习率和丢失率敏感性分析分别如图5、图6所示。学习率控制参数更新步长,影响梯度下降速度。较大的学习率虽能加速收敛,但易导致训练过程不稳定,甚至无法收敛;较小的学习率虽收敛缓慢,但有助于维持稳定训练。因此,合适的学习率选择有助于模型训练更好地收敛到全局最优解。由图5可以看出,算法模型在学习率为0.005时,模型效果最佳。




图5 学习率敏感性分析

丢失率是指在训练中随机丢弃神经网络节点,以防止过拟合。一般地,较小的丢失率有助于保留更多信息,但可能增加过拟合风险,而较

大的丢失率则有助于正则化,但可能导致模型欠拟合。因此,需要在实践中不断调整丢失率以找到适当的平衡。由图6可以看出,算法模型在丢失率为0.5时,模型效果最佳。




图6 丢失率敏感性分析

4.8.2 嵌入维度 Z 和历史长度 h

嵌入维度 Z 和历史长度 h 敏感性分析如图7、图8所示。模型对数据的表示能力和表达复杂性受到网络嵌入维度的影响。因此,需要找到适当的维度以平衡过拟合和欠拟合。由图7可以看出,随着嵌入维度 Z 的增大,F1值逐渐提升,当嵌入维度 Z 为128时,效果最佳,但当维度过高时,模型效果却出现下滑。究其原因,一方面,过高



的维度会导致计算成本增加,需要更多计算资源和训练时间;另一方面,随着嵌入维度的增加,模型更容易过拟合,引入更多噪声。




图7 嵌入维度 Z 敏感性分析

图8反映的是特定时刻相邻形成序列中节点的最大历史长度 h 对F1指标的影响。一般地,较大的历史长度可以提供更多信息,但也可能增加计算开销和引入噪声;较小的历史长度更灵活,但可能丢失长期依赖的信息,导致欠拟合。设置最大历史长度 h 旨在权衡历史长度和计算开销,找到一个适当的平衡点,降低计算复杂度的同时,优化泛化性能。由图8可以看出,当 $h=3$ 时,算法模型的效果最佳。

4.9 网络可视化

本节进行可视化实验,以直观地显示模型学




图8 历史长度 h 敏感性分析

习到的节点嵌入的分布和支持下游任务的能力。首先使用t-SNE将节点嵌入投影到二维空间中,然后将其可视化显示。HetGTAN、OSGNN和本文所提方法DHNHRP在ACM数据集上的可视化结果如图9所示,图9中不同的颜色深度表示节点类别。从图9可以直观地看出,所有方法学习的嵌入的空间分布都能反映出与节点类别的相关性。

然而,HetGTAN获得的不同类别的嵌入之间的边界并不明显,并且每个类别之间存在大量的交叉节点。其中,浅灰色和黑色节点簇能较为清楚地分开,但深灰色节点和浅灰色节点混杂一起,存在较多交叉节点。

与上述两种方法相比,OSGNN与DHNHRP展现出更为出色的嵌入分布性能,不仅节点的空




图9 ACM数据集上的可视化结果

间分布与类别标签高度相关,而且不同类别的节点很少出现交叉现象,相同类簇之间的节点聚集更为紧密。但两者相比,DHNRHP效果更佳,仅在浅灰色和深灰色节点簇边界处存在部分交叉节点,交叉节点较OSGNN更少,且所有不同节点集群间的边界也更显而易见。这表明该方法对不同类型的节点具有良好的判别能力,将非常有利于下游分类任务和聚类任务的泛化。上述结果足以表明,DHNRHP方法所学习的低维节点嵌入不仅具有高度的判别性,而且为下游任务提供了坚实的基础。通过有效地降低节点间的交叉现象和增强同类节点的聚集度,DHNRHP方法为各类任务提供了强大的支持,进一步提升了模型在复杂场景下的性能表现。

5 结束语

本文提出了一种基于霍克斯过程的动态异质网络表征学习方法,该方法在克服现有方法忽略节点内容特征、未能全面考虑元路径所有中间节点以及忽视节点间时序性交互的局限性方面取得了显著进展。本文引入关系旋转编码、注意力机制和霍克斯点过程等技术并进行创新融合,DHNRHP不仅充分考虑了节点、语义和时间这3个维度的关联,还实现了对动态异质网络中节点嵌入表示的精准捕捉。该方法首先通过元路径内部编码方式和注意力机制,获得节点表示,有效捕捉了相邻节点的关联;其次,学习不同元路径的最优加权组合,以聚合异质信息网络的结构和语义信息;最后,引入时间衰减效应,通过邻域形成序列将时间特征引入节点表示中,有力地解决了动态网络中节点的演化问题,使得节点嵌入表示更贴近实际动态演化。在IMDb、ACM和DBLP这3个真实数据集上进行实验,结果验证了本文所提方法DHNRHP相较于对比模型在节点分类和聚类等任务上的优越性,体现了其深厚的理论基础和

实际应用价值。

未来的研究将主要聚焦以下两个方面持续优化和拓展动态异质网络表征学习方法:研究如何在大规模动态异质网络上高效学习表征,包括针对动态异质网络结构的特殊优化策略、处理大规模数据的技术手段以及关注采样策略的设计等,以便能够应对实际网络的规模;研究如何引入关系演化模型,即节点边的演化机制表达,考虑不同类型边的时间依赖性,以更全面准确地捕捉异质信息网络中的动态变化,深入理解其演化规律,更好地应对实际应用中的时序性问题。

参考文献:

- [1] DAI S J, YU Y W, FAN H, et al. Spatio-temporal representation learning with social tie for personalized POI recommendation[J]. *Data Science and Engineering*, 2022, 7(1): 44-56.
- [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] CHANG L, MA C, SUN K, et al. Enhanced road information representation in graph recurrent network for traffic speed prediction[J]. *IET Intelligent Transport Systems*, 2023, 17(7): 1434-1453.
- [4] HE L, GUO W Z, CHEN Y Z, et al. Discovering overlapping communities in dynamic networks based on cascade information diffusion[J]. *IEEE Transactions on Computational Social Systems*, 2022, 9(3): 794-806.
- [5] SONG R, GIUNCHIGLIA F, ZHAO K, et al. Topological enhanced graph neural networks for semi-supervised node classification[J]. *Applied Intelligence*, 2023, 53(20): 23538-23552.
- [6] WANG W, SUO X Y, WEI X Y, et al. HGATE: heterogeneous graph attention auto-encoders[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(4): 3938-3951.
- [7] WANG X, JI H Y, SHI C, et al. Heterogeneous graph attention network[C]//*Proceedings of the World Wide Web Conference*. New York: ACM, 2019: 2022-2032.
- [8] YANG C, LIU Z Y, ZHAO D L, et al. Network representation



- learning with rich text information[C]//Proceedings of the 24th International Conference on Artificial Intelligence. Menlo Park: AAAI Press, 2015: 2111-2117.
- [9] SHI C, HU B B, ZHAO W X, et al. Heterogeneous information network embedding for recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2019, 31(2): 357-370.
- [10] ZHU D Y, CUI P, ZHANG Z W, et al. High-order proximity preserved embedding for dynamic networks[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 30(11): 2134-2144.
- [11] NGUYEN G H, LEE J B, ROSSI R A, et al. Continuous-time dynamic network embeddings[C]//Proceedings of the Companion of the The Web Conference 2018. New York: ACM Press, 2018: 969-976.
- [12] LU Y F, WANG X, SHI C, et al. Temporal network embedding with micro- and macro-dynamics[C]//Proceedings of the Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2019: 469-478.
- [13] LI X, DING D H, KAO B, et al. Leveraging meta-path contexts for classification in heterogeneous information networks[C]//Proceedings of the 2021 IEEE 37th International Conference on Data Engineering (ICDE). Piscataway: IEEE Press, 2021: 912-923.
- [14] 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.
- [15] 贾霄生, 赵中英, 李超, 等. 互信息与多条元路径融合的异质网络表示学习方法[J]. 软件学报, 2023, 34(7): 3256-3271.
- JIA X S, ZHAO Z Y, LI C, et al. Heterogeneous network representation learning method fusing mutual information and multiple meta-paths[J]. Journal of Software, 2023, 34(7): 3256-3271.
- [16] ZHOU L K, YANG Y, REN X, et al. Dynamic network embedding by modeling triadic closure process[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1): 571-578.
- [17] ZUO Y, LIU G N, LIN H, et al. Embedding temporal network via neighborhood formation[C]//Proceedings of the Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2018: 2857-2866.
- [18] 尹赢, 张建朋, 吉立新, 等. 基于霍克斯点过程的动态网络表示学习方法[J]. 电子学报, 2020, 48(11): 2154-2161.
- YIN Y, ZHANG J P, JI L X, et al. Dynamic network representation learning based on hawkes point process[J]. Acta Electronica Sinica, 2020, 48(11): 2154-2161.
- [19] XUE H S, YANG L W, JIANG W, et al. Modeling dynamic heterogeneous network for link prediction using hierarchical attention with temporal RNN[C]//HUTTER F, KERSTING K, LIJFFIJT J, et al. Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer, 2021: 282-298.
- [20] WANG X, LU Y F, SHI C, et al. Dynamic heterogeneous information network embedding with meta-path based proximity[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(3): 1117-1132.
- [21] FAN Y J, JU M X, ZHANG C X, et al. Heterogeneous temporal graph neural network[M]//Proceedings of the 2022 SIAM International Conference on Data Mining (SDM). Philadelphia, PA: Society for Industrial and Applied Mathematics, 2022: 657-665.
- [22] 郭佳雯, 白淇介, 林铸天, 等. 基于非递减时序随机游走的动态异质网络嵌入[J]. 计算机研究与发展, 2021, 58(8): 1624-1641.
- GUO J W, BAI Q J, LIN Z T, et al. Dynamic heterogeneous network embedding based on non-decreasing temporal random walk[J]. Journal of Computer Research and Development, 2021, 58(8): 1624-1641.
- [23] 秦海盈, 赵中英, 李建晖, 等. 基于元路径与层次注意力的时序异质信息网络表示学习方法[J]. 模式识别与人工智能, 2021, 34(12): 1093-1102.
- QIN H Y, ZHAO Z Y, LI J H, et al. Meta-path and hierarchical attention based temporal heterogeneous information network representation learning[J]. Pattern Recognition and Artificial Intelligence, 2021, 34(12): 1093-1102.
- [24] 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.
- [25] LIANG X X, MA Y, CHENG G Q, et al. Meta-path-based heterogeneous graph neural networks in academic network[J]. In-

- ternational Journal of Machine Learning and Cybernetics, 2022, 13(6): 1553-1569.
- [26] 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.
- [27] SUN Z Q, DENG Z H, NIE J Y, et al. RotatE: knowledge graph embedding by relational rotation in complex space[J]. arXiv preprint, arXiv: 1902.10197, 2019.
- [28] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks[J]. arXiv preprint, arXiv: 1710.10903, 2017.
- [29] WU N, WANG C F. Heterogeneous graph tree networks[J]. arXiv preprint, arXiv: 2209.00610, 2022.
- [30] 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.
- [31] 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.

[作者简介]



陈蕾 (2000-), 女, 浙江师范大学计算机科学与技术学院 (人工智能学院) 硕士生, 主要研究方向为社会网络分析和异质网络表征学习。



邓琨 (1980-), 男, 博士, 嘉兴大学信息科学与工程学院、嘉兴大学浙江省医学电子与数字健康重点实验室副教授、硕士生导师, 主要研究方向为网络结构分析、数据挖掘、异质网络分析等。



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。