



智能系统学报

CAAI TRANSACTIONS ON INTELLIGENT SYSTEMS

基于任务子图感知的少样本节点分类算法

郑文萍, 苏蕊, 刘扬

引用本文:

郑文萍, 苏蕊, 刘扬. 基于任务子图感知的少样本节点分类算法[J]. *智能系统学报*, 2026, 21(3): 666-674.

ZHENG Wenping, SU Rui, LIU Yang. Few-shot node classification based on task-aware subgraphs[J]. *CAAI Transactions on Intelligent Systems*, 2026, 21(3): 666-674.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202506037>

您可能感兴趣的其他文章

一种卷积神经网络集成的多样性度量方法

Diversity measuring method of a convolutional neural network ensemble

智能系统学报. 2021, 16(6): 1030-1038 <https://dx.doi.org/10.11992/tis.202011023>

一种基于2D时空信息提取的行为识别算法

A behavioral recognition algorithm based on 2D spatiotemporal information extraction

智能系统学报. 2020, 15(5): 900-909 <https://dx.doi.org/10.11992/tis.201906054>

图神经网络推荐研究进展

Research advances in graph neural network recommendation

智能系统学报. 2020, 15(1): 14-24 <https://dx.doi.org/10.11992/tis.201908034>

基于改进卷积神经网络的多标记分类算法

A multi-label classification algorithm based on an improved convolutional neural network

智能系统学报. 2019, 14(3): 566-574 <https://dx.doi.org/10.11992/tis.201804056>

关于深度学习的综述与讨论

Overview on deep learning

智能系统学报. 2019, 14(1): 1-19 <https://dx.doi.org/10.11992/tis.201808019>

多标记学习自编码网络无监督维数约简

Unsupervised dimensionality reduction of multi-label learning via autoencoder networks

智能系统学报. 2018, 13(5): 808-817 <https://dx.doi.org/10.11992/tis.201804051>

DOI: 10.11992/tis.202506037

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20260323.1649.003>

基于任务子图感知的少样本节点分类算法

郑文萍^{1,2,3}, 苏蕊¹, 刘扬¹

(1. 山西大学 计算机与信息技术学院, 山西 太原 030006; 2. 计算智能与中文信息处理教育部重点实验室(山西大学), 山西 太原 030006; 3. 山西大学 智能信息处理研究所, 山西 太原 030006)

摘要: 目前基于图神经网络的节点分类方法依赖大量标记数据, 且长尾标签分布降低了学习效率。在低资源场景下, 基于元学习的少样本学习是图表示学习的有效途径, 然而, 全局图学习会引入任务无关噪声, 且现有原型网络方法直接计算节点与类原型的相似性以对节点分类, 在少样本条件下难以准确计算类原型。针对此, 提出了基于任务子图感知的少样本节点分类算法 (few-shot node classification based on task-aware subgraphs, TAS-FNC)。该方法通过结构裁剪与拓扑增强, 为当前任务构建高连通性子图, 在其上学习特定任务的节点表示以减轻无关噪声影响; 进而学习查询节点与类原型的关系以进行节点分类。在 4 个数据集上与 11 种基线方法进行比较实验表明, TAS-FNC 能在标记样本稀缺的场景下有效提高节点分类的准确度。

关键词: 图神经网络; 节点分类; 图表示学习; 少样本学习; 元学习; 复杂网络; 原型网络; 深度学习

中图分类号: TP30 **文献标志码:** A **文章编号:** 1673-4785(2026)03-0666-09

中文引用格式: 郑文萍, 苏蕊, 刘扬. 基于任务子图感知的少样本节点分类算法 [J]. 智能系统学报, 2026, 21(3): 666-674.

英文引用格式: ZHENG Wenping, SU Rui, LIU Yang. Few-shot node classification based on task-aware subgraphs[J]. CAAI transactions on intelligent systems, 2026, 21(3): 666-674.

Few-shot node classification based on task-aware subgraphs

ZHENG Wenping^{1,2,3}, SU Rui¹, LIU Yang¹

(1. College of Computer and Information Technology, Shanxi University, Taiyuan 030006, China; 2. Key Laboratory of Computational Intelligence and Chinese Information Processing, Ministry of Education (Shanxi University), Taiyuan 030006, China; 3. Institute of Intelligent Information Processing, Shanxi University, Taiyuan 030006, China)

Abstract: Current graph neural network-based node classification methods rely on large amounts of labeled data and are limited by long-tailed label distributions. In low-resource settings, meta-learning-based few-shot learning is effective for graph representation. However, global graph learning introduces task-irrelevant noise, and current prototypical networks, which classify nodes by directly computing similarities between nodes and class prototypes, struggle to estimate accurate prototypes under few-shot conditions. To address these issues, we propose a task-aware subgraph-based few-shot node classification method (TAS-FNC). This method constructs high-connectivity subgraphs for each task through structural pruning and topological enhancement, enabling task-specific node representation learning and reducing noise. It then models the relationships between query nodes and class prototypes for classification. Experiments on four datasets against 11 baselines show that TAS-FNC effectively improves node classification accuracy in label-scarce scenarios.

Keywords: graph neural networks; node classification; graph representation learning; few shot learning; meta learning; complex network; prototypical network; deep learning

节点分类作为典型的图分析任务, 广泛应用于社交网络分析^[1]、蛋白质功能预测^[2]、金融欺诈检测^[3-4]等领域。现有节点分类方法大多遵循监

督或半监督范式, 依赖于每个类别都有足够数量的标记节点^[5-6]。然而, 现实中的图数据往往呈现出长尾分布, 即大多数节点集中在少数头部类别中, 而尾部类别的标记节点数量稀缺, 导致模型难以有效学习尾部类别节点表示, 限制了现有节点分类方法在多类别图数据中的应用效果。少

收稿日期: 2025-06-30. 网络出版日期: 2026-03-24.

基金项目: 国家自然科学基金项目 (62072292); 山西省 1331 工程项目。

通信作者: 郑文萍. E-mail: wzhang@sxu.edu.cn.

样本学习能够在仅有极少标记样本的情况下实现有效训练与快速泛化, 为应对节点分类中的标注稀缺问题提供了新的解决思路^[7-8]。

少样本节点分类方法通常采用元学习框架, 从包含大量标记数据的类别中采样元训练任务进行模型的训练和优化, 进而实现对只有少量标记样本类别的有效分类^[9-12]。这种元学习过程使模型能够从多个训练任务中学习先验知识, 并将其有效应用于只有少量标记样本的测试任务。相较于基于优化的方法需要大量迭代更新参数, 类原型方法通过直接比较查询样本与类原型的相似性进行分类, 显著降低了计算复杂度, 从而更好地满足少样本场景下对效率和可解释性的双重需求^[13]。

现有的少样本节点分类方法面临两大挑战。首先, 图数据规模庞大且每个元任务仅包含少量节点, 若利用全局图结构进行学习, 可能会引入任务无关的噪声。虽然为特定任务采样子图可以在一定程度上缓解这一问题, 但现有方法在采样过程中往往忽视类内拓扑的连通性, 限制了消息传播的范围。其次, 现有基于原型网络的方法通过计算查询集与类原型的相似性来确定查询节点类别, 然而, 在标签样本较少的情况下, 节点或类原型的表示可能缺乏判别性, 与其他非最近原型的嵌入距离中可能包含有关节点类别的额外信息, 直接计算二者的相似性难以提供有效的分类信息。

针对上述挑战, 本文提出基于任务子图感知的少样本节点分类算法 (few-shot node classification based on task-aware subgraphs, TAS-FNC), 为每个任务采样连通性强的任务子图, 并在其上优化关系学习模型, 以更准确地判定查询节点与类原型的关系。TAS-FNC 包括任务子图表示、原型学习、关系学习、节点分类 4 个模块。任务子图表示模块融合邻域采样与连通性采样, 筛选关键邻域和枢纽节点并补充高相似度边以增强类内连通性, 生成连通性好的子图以学习任务相关节点嵌入, 减少任务无关噪声并提升任务适应性; 原型学习模块通过评估支持节点对类原型的贡献程度, 加权构建类原型以减轻异常节点影响; 关系学习模块将查询节点与类原型的相对位置投影到关系学习空间, 学习二者之间关系, 以提升分类准确性; 节点分类模块基于学得的关系进行节点分类。

1 相关工作

在少样本节点分类中, 节点表示的质量直接影响分类准确率, 节点表示越优, 类原型的代表性越强, 分类效果越好。元学习框架则通过在极少标记

样本下实现跨任务的知识迁移, 进一步提升模型的泛化能力。本节将从图表示学习、少样本学习和图少样本节点分类 3 个关键方向梳理相关研究进展。

1.1 图表示学习

图神经网络作为图表示学习领域的前沿技术, 在节点分类任务中取得了显著成功, 逐渐成为少样本图学习的核心方法^[6,14-15]。基于图神经网络的节点分类方法主要分为谱域方法和空域方法。谱域方法通过卷积定理在频域定义谱滤波器, 利用图傅里叶变换实现特征提取, 典型模型如 GCN(graph convolutional network)^[16]、SGC (simplifying graph convolutional network)^[11] 等。空域方法则基于消息传递机制, 通过聚合邻域节点特征实现拓扑结构感知, 代表模型如 GraphSAGE(graph sample and aggregation)^[17]、GAT(graph attention network)^[18] 等。这些方法通常依赖监督或半监督学习范式, 需要大量的标记数据, 但在标注数据稀缺时性能显著下降, 暴露出对标签依赖性强的局限性。

1.2 少样本学习

少样本学习 (few-shot learning, FSL) 旨在通过极少量标记样本实现模型对新任务的快速适应^[19]。元学习是经典的少样本学习方法, 通过构建“元任务”模拟真实场景中的知识迁移过程, 以快速获取先验知识^[20]。现有方法可分为基于度量和基于优化两类。ProtoNet(prototypical networks)^[21] 作为典型的基于度量的方法, 通过元任务训练机制构建跨任务的特征嵌入空间, 将支持集样本映射为类别原型表示并计算查询样本与原型间的相似性实现分类; 而 MAML(model-agnostic meta-learning)^[22] 是基于优化的经典方法, 通过提取元知识优化模型初始化参数, 使得仅需少量训练样本的内部优化即可快速适应新的任务。

1.3 图少样本节点分类

传统少样本学习方法虽在图像视觉领域取得显著进展, 但由于其假设数据独立同分布且缺乏显式拓扑结构, 难以直接迁移至图数据任务。在基于优化的方法中, Meta-GNN(meta graph neural network)^[10] 将 MAML 与 GNN(graph neural network) 结合, 通过元训练阶段的梯度更新实现参数快速适应。AMM-GNN(attribute matching meta-learning graph neural network)^[7] 引入注意力机制强化元知识提取, 动态分配权重以捕捉任务间关联。TENT(task-adaptive few-shot node classification)^[23] 采用节点级特征对齐、类级原型对齐和任务级关系对齐的协同优化策略, 缓解元任务方差对泛化性能的影响。然而, 上述方法直接在全局

图上学习节点表示,易受任务无关噪声干扰,泛化能力受限。为缓解噪声问题,子图采样方法被提出, GLITTER(graph few-shot learning with task-specific structure)^[8]通过全局邻域采样与关键节点采样,为每个元任务构建特定子图结构以学习任务相关的节点表示。X-FNC(few-shot node classification with extremely weak supervision)^[24]通过随机采样任务节点的邻居与非任务节点构建任务子图用于下游任务。尽管这类子图采样策略旨在减少全局噪声,其采样过程往往缺乏对子图拓扑连通性的显式约束,可能导致类内节点间消息传播范围受限,影响表示学习效果。

在基于原型网络的方法中, GPN(graph posterior network)^[25]提出基于自注意力机制的节点重要性加权策略,评估节点重要性以构建鲁棒类原型。MetaTNE(meta transformed network embedding)^[26]设计嵌入转换函数,将通用节点表示映射至任务特定空间以增强原型区分度。UDPN(prototypical networks with unlabeled data for few-shot node classification)^[27]则利用未标记数据的对比学习为编码器和原型提供额外监督,细化类原型表示。虽然这些方法提升了类原型的鲁棒性,但其分类决策仍依赖于在原始表示空间中直接计算查询节点与类原型的相似度,而在少样本条件下类原型的判别性不足,这种相似度计算难以有效识别节点与类原型之间的关系,可能导致分类边界模糊。

2 预备知识

2.1 问题定义

将一个属性图记为 $G=(V, E, \mathbf{X}, \mathbf{A})$, 其中 $V=\{v_1, v_2, \dots, v_n\}$ 表示节点集, $E=\{e_1, e_2, \dots, e_m\}$ 表示边集, $\mathbf{X}=[\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_n] \in \mathbf{R}^{n \times d}$ 表示节点特征矩阵, \mathbf{x}_i 表示节点 v_i 的特征, $\mathbf{A} \in \{0, 1\}^{n \times n}$ 是邻接矩阵。

对属性图 G , 将其顶点集分为互不相交的训练集和测试集, 分别记作 V_{train} 和 V_{test} 。训练集 V_{train} 中的每个节点均属于标签集 C_{train} 的某一类,

而测试集中的节点属于标签集 C_{test} , 且 $C_{\text{train}} \cap C_{\text{test}} = \emptyset$ 。少样本节点分类问题是在节点集 V_{train} 上对模型进行训练, 利用测试集 V_{test} 上的少量带标记节点进行模型适应, 并预测 V_{test} 上的未标记节点的类别标签^[28]。

元学习是求解少样本分类问题的经典范式, 通过构建“元任务”模拟测试集分类情景以实现从已见类到未见类的知识迁移。若每个元任务包含 N 个类, 每个类有 K 个带标记节点, 则称为 N -way K -shot 节点分类。

2.2 情景学习

元学习通过情景学习框架^[12]进行, 包括元训练和元测试两个阶段。在元训练阶段, 在训练集上构建多个元训练任务进行模型训练; 在元测试阶段, 在元测试任务上利用少量标记节点进行任务内模型适应, 并预测未标记节点标签。具体地, 对于每个元训练任务 $T_i = \{S_i, Q_i\}$ ($1 \leq i \leq \mathcal{T}$), 其中支持集 S_i 从 N 个类别中各采样 K 个节点, 记作 $S_i = \{(v_1, y_1), (v_2, y_2), \dots, (v_{NK}, y_{NK})\}$, $v_i \in V_{\text{train}}, y_i \in C_{\text{train}}$; 查询集 Q_i 从剩余节点中为每个类采样 Q 个节点, 记作

$$Q_i = \{(q_1, y'_1), (q_2, y'_2), \dots, (q_{NQ}, y'_{NQ})\}, \\ q_i \in V_{\text{train}}, y'_i \in C_{\text{train}}.$$

3 任务子图感知的少样本节点分类

基于任务感知的高连通性子图构建与关系学习的核心思想, 设计了基于任务子图感知的少样本节点分类算法 (few-shot node classification based on task-aware subgraphs, TAS-FNC), 包括任务子图表示、原型学习、关系学习、节点分类 4 个模块, 如图 1 所示。任务子图表示模块构建高连通性任务子图; 原型学习模块获得节点关于任务的细粒度表示, 并对支持节点进行贡献度评估以构建类原型; 关系学习模块将查询节点与类原型投影到共享关系学习空间以获得二者关系表示; 节点分类模块预测查询节点的类别。

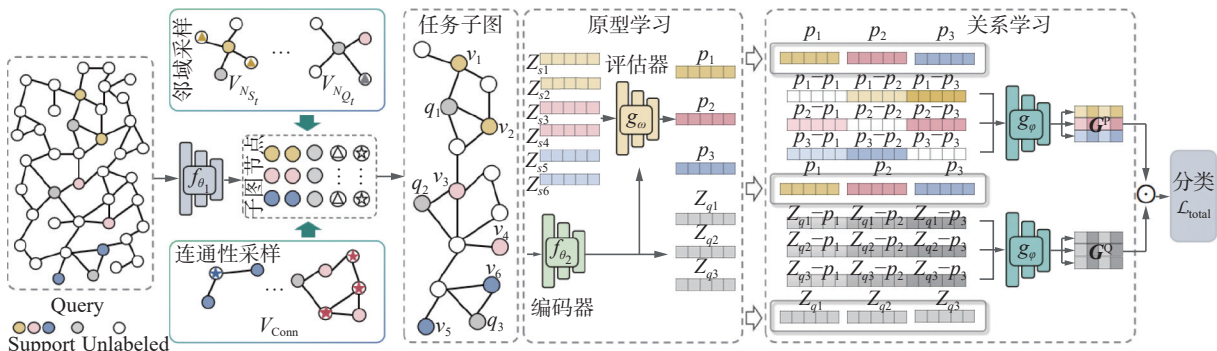


图 1 TAS-FNC 框架

Fig. 1 Framework of TAS-FNC

3.1 任务子图表示模块

使用一个预训练的 2 层图卷积网络 f_{θ_1} 学习节点在原始图上的粗粒度表示, 并在此基础上采样任务子图, θ_1 为网络参数。

3.1.1 粗粒度节点表示

首先采用 2 层图卷积网络 f_{θ_1} 对原始图 $G=(V,$

$$\mathcal{L}_{\text{contrast}} = -\frac{1}{|V|} \sum_{i=1}^{|V|} \log \frac{\sum_{j \in \Gamma(v_i)} \exp(\text{sim}(\mathbf{H}_{i,:}, \mathbf{H}_{j,:})/\tau)}{\sum_{j \in \Gamma(v_i)} \exp(\text{sim}(\mathbf{H}_{i,:}, \mathbf{H}_{j,:})/\tau) + \sum_{k \in S_{\text{neg}}^i} \exp(\text{sim}(\mathbf{H}_{i,:}, \mathbf{H}_{k,:})/\tau)} \quad (1)$$

式中: $\text{sim}(\mathbf{H}_{i,:}, \mathbf{H}_{j,:})$ 表示节点 v_i 与 v_j 的粗粒度嵌入的余弦相似度, S_{neg}^i 表示节点 v_i 的负样本集, $\Gamma(v_i)$ 是节点 v_i 在图 G 中的一阶邻居节点集。

3.1.2 任务子图采样

对任务 $T_t = \{S_t, Q_t\}$ ($1 \leq t \leq T$), 子图采样部分从原始图 G 上采样与 T_t 相关的节点构成任务子图 $G_t = (V_t, E_t, \mathbf{Z}_t, \mathbf{A}_t)$ 。为在 G_t 上进行有效的消息传递, 此处通过结构裁剪和拓扑增强以保证任务子图的高连通性。

1) 结构裁剪

首先通过邻域采样得到任务 T_t 的关键邻居集 Γ_t ; 再通过连通性采样得到影响类内节点连通性的枢纽节点集 C_t 。具体过程如下。

邻域采样: 在标签稀缺的情况下, 模型需依赖邻域结构信息增强节点表征能力, 而直接采样全部邻居会增大计算量且引入噪声。因此, 对每个节点 $v_i \in T_t$, 筛选与其关联紧密的邻居构成邻域结构。

对于节点 v_i , 提取它在 G 中的二跳闭邻域导出子图 $G_i = (V_i, E_i)$, 则 G_i 的随机游走概率矩阵 \mathbf{P} 可表示为

$$\mathbf{P} = \mathbf{D}_i^{-1} \mathbf{A}_i \quad (2)$$

式中: \mathbf{A}_i 是 G_i 的邻接矩阵, \mathbf{D}_i 是度矩阵。则矩阵 \mathbf{P}^m 的第 i 行元素 $\mathbf{P}_{i,:}^m$ 代表从中心节点 v_i 到其他节点的 m 步转移概率。从 G_i 中采样节点 v_i 的邻域结构, 各节点的采样概率:

$$\rho_i = \mu \mathbf{P}_{i,:} + (1 - \mu) \mathbf{P}_{i,:}^2 \quad (3)$$

式中: $\mu \in [0, 1]$ 是平衡因子, 默认取 0.5。按采样概率 ρ_i , 选取前 k 个节点构成 v_i 的邻域结构节点集 $\Gamma_t(i)$ 。则任务 T_t 的关键邻域集 $\Gamma_t = \cup_{i \in T_t} \Gamma_t(i)$ 。

连通性采样: 为有效进行消息传递, 任务子图中同类节点间应有良好的连通性。受文献 [8] 启发, 从原始图 G 中采样必要的枢纽节点以使得任务子图支持集中同类节点间通过最短路径连通。假设支持集 S_t 中类 c 的节点集为 $S_t^c = \{s_1, s_2, \dots, s_k\}$,

$E, \mathbf{X}, \mathbf{A}$) 上的节点特征进行聚合, 以得到节点关于原始图的粗粒度嵌入 $\mathbf{H} = f_{\theta_1}(\mathbf{A}, \mathbf{X})$ 。为减少节点特征中噪声的影响, 此处设计一个基于 InfoNCE 损失的对比学习任务, 以无监督的方式对 f_{θ_1} 进行预训练。将节点 v_i 的一阶邻居作为其正样本, 其他节点为负样本, 对比损失定义为

在图 G 上采用双向广度优先搜索算法计算 S_t^c 中所有节点对间 r 条独立的最短路径。则任务 T_t 枢纽节点集 C_t 由这些最短路径上的节点合并而成。

最终, T_t 的任务子图 G_t 的节点集为

$$V_t = S_t \cup Q_t \cup \Gamma_t \cup C_t。$$

2) 拓扑增强

接下来, 利用拓扑增强过程得到任务子图 G_t 的节点间的连接关系。基于第 3.1.1 节得到的粗粒度嵌入计算 G_t 中节点间的相似性:

$$\mathbf{M}_{\text{Sij}} = \frac{\mathbf{H}_{i,:} \cdot \mathbf{H}_{j,:}}{\|\mathbf{H}_{i,:}\| \times \|\mathbf{H}_{j,:}\|} \quad (4)$$

进一步, 将 \mathbf{M}_{Sij} 矩阵中值小于阈值 θ 的节点对之间的相似性置 0, 得到 G_t 中节点间的相似性矩阵 \mathbf{A}'' :

$$\mathbf{A}'' = \begin{cases} \mathbf{M}_{\text{Sij}}, & \mathbf{M}_{\text{Sij}} > \theta \\ 0, & \text{其他} \end{cases} \quad (5)$$

则 T_t 的任务子图 G_t 的邻接矩阵 \mathbf{A}_t 定义为

$$\mathbf{A}_t = \frac{\mathbf{A}'}{\|\mathbf{A}'\|} + \alpha \cdot \frac{\mathbf{A}''}{\|\mathbf{A}''\|} \quad (6)$$

式中: \mathbf{A}' 为节点集 V_t 在 G 中的导出子图的邻接矩阵, α 为超参数。

3.2 原型学习模块

首先使用一个 2 层图卷积网络 f_{θ_2} 得到节点关于任务 T_t 的细粒度表示 $\mathbf{Z}_t = f_{\theta_2}(\mathbf{A}_t, \mathbf{H}_t)$, θ_2 为网络参数; 再利用节点评估器 g_{ω} 学习支持节点对类原型的贡献度; 进而按照贡献度加权聚合支持集 S_t 中同类节点的细粒度表示以得到类原型表示。

支持节点对类原型的贡献度计算为

$$\mathbf{R} = \text{Sigmoid}(g_{\omega}(\mathbf{A}_t, \mathbf{H}_t) \cdot \mathbf{D}_t) \quad (7)$$

式中: \mathbf{D}_t 是任务子图 G_t 的度矩阵, \mathbf{R} 的第 i 个分量 R_i 表示节点 v_i 的贡献程度。对类别 $c \in C_{\text{train}}$ 内节点 v_i 的贡献度进行归一化为

$$\text{score}(v_i) = \frac{\exp(R_i)}{\sum_{v_j \in S_t^c} \exp(R_j)} \quad (8)$$

则类 c 的原型可表示为

$$p_c = \frac{1}{|S_c^i|} \sum_{v_i \in S_c^i} \text{score}(v_i) \cdot z_i \quad (9)$$

式中: S_c^i 是类 c 的支持集, z_i 是节点 v_i 的相对于任务 T_i 的细粒度表示。令 $P_i \in \mathbf{R}^{N \times d}$ 表示 C_{train} 关于任务 T_i 的原型表示矩阵, N 表示任务 T_i 的类别数。

3.3 关系学习模块

此模块通过计算查询节点与类原型在表示空间的相对位置, 学习查询节点与类之间的关系, 从而对查询节点进行分类。首先从任务 T_i 中提取查询节点的细粒度表示 $Z_i^Q = \mathbf{Z}_i[Q_i, :]$ ($\in \mathbf{R}^{|Q_i| \times d}$), 并通过关系投影层 $g_\varphi(\mathbf{Z}_i, P_i)$ 获取查询节点与所有类原型的相对位置关系表示矩阵 $G^Q (\in \mathbf{R}^{|Q_i| \times d'})$, 具体计算方式为

$$G^Q = g_\varphi(\mathbf{Z}_i, P_i) = \mathbf{W}_\varphi((\mathbf{Z}_i^Q \otimes \mathbf{1}_{N \times 1}) - (\mathbf{1}_{|Q_i| \times 1} \otimes P_i)) + \mathbf{b}_\varphi \quad (10)$$

式中: $P_i \in \mathbf{R}^{N \times d}$ 为任务 T_i 中类原型的表示, \otimes 为 Kronecker 积用于广播操作, \mathbf{W}_φ 和 \mathbf{b}_φ 是可学习参数。关系投影层 $g_\varphi(\mathbf{Z}_i, P_i)$ 将查询集节点的细粒度表示与类原型的相对位置关系映射到统一的关系学习空间。

进一步, 此处将类原型间的相对位置关系也映射到统一的关系学习空间中, 原型间的关系表示矩阵 $G^P (\in \mathbf{R}^{N \times d'})$ 的具体计算方式为

$$G^P = g_\varphi(P_i, P_i) = \mathbf{W}_\varphi((P_i \otimes \mathbf{1}_{|Q_i| \times 1}) - (\mathbf{1}_{|Q_i| \times 1} \otimes P_i)) + \mathbf{b}_\varphi \quad (11)$$

3.4 节点分类模块

节点分类模块利用学习到的节点与类原型的相对位置关系 G^Q 以及类原型之间的关系 G^P 对查询集节点进行分类。具体计算过程为

$$\mathbf{F} = \text{Softmax}(G^Q(G^P)^\top) \quad (12)$$

式中: $\mathbf{F} (\in \mathbf{R}^{|Q_i| \times N})$, 其元素 F_{ij} 表示在当前任务 T_i 中查询节点 i 对第 j 类的归属度, 将归属度最大的类别作为节点 i 的最终预测类别。

模型训练优化目标包括分类损失和原型分离正则项两部分。分类损失为分配正确类别标签的平均负对数似然概率:

$$\mathcal{L}_{\text{class}} = -\frac{1}{N \times Q} \sum_{i=1}^{N \times Q} \log(\mathbf{F}_{i, c_i}) \quad (13)$$

式中 c_i 表示查询节点 i 的真实类别标签。

原型分离正则项旨在增强嵌入空间中各类别原型之间的可分性, 从而提升表示的判别能力:

$$\mathcal{L}_{\text{sep}} = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j \neq i}^N \frac{1}{\|\mathbf{p}_i - \mathbf{p}_j\|_2 + \epsilon} \quad (14)$$

式中: \mathbf{p}_i 和 \mathbf{p}_j 分别表示第 i 类和第 j 类的原型表示, $\|\cdot\|_2$ 表示两个原型之间的欧氏距离, ϵ 是任意小的正常数。综上, 模型训练的优化目标为

$$\min \mathcal{L}_{\text{total}} = \min(\mathcal{L}_{\text{class}} + \lambda \cdot \mathcal{L}_{\text{sep}}) \quad (15)$$

式中 λ 是超参数, 控制原型分离正则项的权重。

3.5 算法框架

算法 1 给出了所提出的基于任务子图感知的少样本节点分类算法 (TAS-FNC) 的具体过程。

算法 1 TAS-FNC 算法。

输入 图 $G = (V, E, \mathbf{X}, \mathbf{A})$, 训练轮数 \mathcal{T} , 元任务类别数 N , 支持集实例数 K , 查询集实例数 Q , 元测试任务 $T_{\text{test}} = \{S_{\text{test}}, Q_{\text{test}}\}$ 。

输出 Q_{test} 中查询节点的标签。

1) 根据式 (1) 预训练图卷积网络 f_{θ_1} , 计算 G 中节点的粗粒度表示 \mathbf{H} ;

//元训练阶段

2) for $t = 1, 2, \dots, \mathcal{T}$ do

3) 采样元训练任务 $T_t = \{S_t, Q_t\}$;

4) 通过邻域采样获得关键邻居集 Γ_t , 通过连通性采样获得枢纽节点集 C_t , 令 $V_t = S_t \cup Q_t \cup \Gamma_t \cup C_t$;

5) 利用式 (4)~(6), 计算 V_t 中节点间的相似性, 得到带权邻接矩阵 \mathbf{A}_t ;

6) 计算节点的细粒度表示 $\mathbf{Z}_t = f_{\theta_2}(\mathbf{A}_t, \mathbf{H})$;

7) 对 $v \in S_t$, 利用式 (7) 和 (8) 计算节点贡献度 $\text{score}(v)$, 利用式 (9) 得到类原型表示矩阵 P_t ;

8) 利用式 (10) 和 (11) 计算 G^P 与 G^Q ;

9) 利用式 (12) 预测节点 $v (\in Q_t)$ 的类别归属度;

10) 利用 Adam 优化器根据式 (15) 优化模型参数 $\theta_2, g, \omega, \mathbf{W}_\varphi, \mathbf{b}_\varphi$;

11) end for

//元测试阶段

12) 构建 T_{test} 的任务子图 G_{test} , 并获得细粒度节点表示 $\mathbf{Z}_{\text{test}} = f_{\theta_2}(\mathbf{A}_{\text{test}}, \mathbf{H}_{\text{test}})$;

13) 计算 $v (\in S_{\text{test}})$ 的贡献得分, 获得类原型表示矩阵 P_{test} ;

14) 计算关系矩阵 G^P 与 G^Q ;

15) 利用式 (12) 计算节点归属度矩阵 \mathbf{F} , 并取最大归属度对应的类别作为预测结果。

//结束

4 实验与结果分析

4.1 数据集

使用 Amazon-C^[29]、Amazon-E^[29]、DBLP^[30]、OGBN-arxiv^[31] 等 4 个真实数据集进行对比实验, 基本信息如表 1 所示。Amazon-C 和 Amazon-E: 分别是亚马逊“服装、鞋类和珠宝”类和“电子产品”类的购买网络, 节点为产品, 属性为产品描述, 边为“共同查看”和“共同购买”关系, 标签为产品类别。DBLP: 引文网络, 节点为论文, 边为引用关系, 属性通过论文摘要生成, 标签是论文的

发表场所。OGBN-arxiv: 引文网络, 节点为论文, 边为引用关系, 属性通过标题和摘要生成, 标签是论文的主题。

表 1 数据集的基本信息
Table 1 Basic information of datasets

数据集	节点数	边数	特征维度	标签数	类别划分
Amazon-C	24919	91680	9034	77	40/17/20
Amazon-E	42318	43556	8669	167	90/37/40
DBLP	40672	288270	7204	137	80/27/30
OGBN-arxiv	169343	1166243	128	40	15/5/20

4.2 实验设置

参数设置: 所有算法均基于 PyTorch 框架实现, 训练过程中采用 Adam 优化器进行参数更新。算法 TAS-FNC 中, 预训练图编码器 f_{θ_1} 、子图图编码器 f_{θ_2} 、节点评估器 g_{ω} 均采用 2 层 GCN, 关系投影层 g_{φ} 为一个多层感知机 MLP(multilayer perceptron)。过滤相似度边的阈值 θ 设置为 0.5。

基线设置: 选取了 11 个算法进行对比实验, 包括图嵌入方法 SGC^[11]、GCN^[16], 少样本方法 PN^[21]、MAML^[22], 少样本节点分类方法 Meta-GNN^[10]、GPN^[25]、AMM-GNN^[7]、TENT^[23]、GLITTER^[8]、X-FNC^[24]、UDPN^[27]。

4.3 实验结果

对每个数据集进行 4 种实验设置: 5-way 3-shot (5w 3s)、5-way 5-shot(5w 5s)、10-way 3-shot(10w 3s) 和 10-way 5-shot(10w 5s)。将查询集实例数设置为 20, 训练轮数设置为 1000, 评估标准为准确率。采用 10 次随机抽样的 50 个元测试任务的平均准确率作为最终结果, 具体见表 2~5。

表 2 Amazon-C 数据集对比实验结果
Table 2 Comparative results of Amazon-C

方法	5w 3s	5w 5s	10w 3s	10w 5s
SGC ^[11]	56.8	62.2	43.1	46.3
GCN ^[16]	54.3	59.3	41.3	44.8
PN ^[21]	53.7	63.5	41.5	44.8
MAML ^[22]	55.2	66.1	45.6	46.8
Mate-GNN ^[10]	74.1	77.3	61.4	64.2
GPN ^[25]	75.4	78.6	65.0	67.7
AMM-GNN ^[7]	79.7	81.7	67.8	69.6
TENT ^[23]	80.7	82.3	70.1	73.0
GLITTER ^[8]	80.4	82.0	66.8	67.6
X-FNC ^[24]	77.6	79.6	66.3	68.5
UDPN ^[27]	81.5	82.7	71.4	72.9
TAS-FNC	82.6	82.9	72.8	74.4

注: 加粗表示最优结果。

表 3 Amazon-E 数据集对比实验结果
Table 3 Comparative results of Amazon-E

方法	5w 3s	5w 5s	10w 3s	10w 5s
SGC ^[11]	54.6	60.8	43.2	50.0
GCN ^[16]	53.8	59.6	42.3	47.4
PN ^[21]	53.5	59.7	39.9	45.0
MAML ^[22]	53.3	59.0	37.4	43.4
Mate-GNN ^[10]	63.2	67.9	58.2	60.8
GPN ^[25]	64.6	70.9	60.3	62.4
AMM-GNN ^[7]	70.1	72.7	63.5	67.9
TENT ^[23]	74.2	76.8	65.7	68.6
GLITTER ^[8]	72.4	75.1	59.4	63.7
X-FNC ^[24]	68.8	73.2	60.0	61.6
UDPN ^[27]	74.3	79.5	66.8	71.5
TAS-FNC	76.8	81.6	67.6	73.7

注: 加粗表示最优结果。

表 4 DBLP 数据集对比实验结果
Table 4 Comparative results of DBLP

方法	5w 3s	5w 5s	10w 3s	10w 5s
SGC ^[11]	57.3	65	40.2	50.3
GCN ^[16]	59.6	68.3	43.9	51.2
PN ^[21]	37.2	43.4	26.2	32.6
MAML ^[22]	39.7	45.5	30.8	34.7
Mate-GNN ^[10]	70.9	78.2	60.7	68.1
GPN ^[25]	74.5	80.1	62.6	69.0
AMM-GNN ^[7]	76.5	80.4	65.8	69.9
TENT ^[23]	79.6	80.3	68.5	72.2
GLITTER ^[8]	75.2	76.0	68.4	71.6
X-FNC ^[24]	79.1	72.5	71.9	70.2
UDPN ^[27]	78.6	81.5	72.0	72.4
TAS-FNC	80.1	83.0	70.5	74.3

注: 加粗表示最优结果。

表 5 OGBN-arxiv 数据集对比实验结果
Table 5 Comparative results of OGBN-arxiv

方法	5w 3s	5w 5s	10w 3s	10w 5s
SGC ^[11]	41.4	47.0	32.5	36.4
GCN ^[16]	44.6	47.3	35.8	37.8
PN ^[21]	42.9	49.71	34.6	35.7
MAML ^[22]	43.0	42.14	34.1	36.8
Mate-GNN ^[10]	48.8	45.4	35.0	37.3
GPN ^[25]	55.3	53.0	36.3	43.3
AMM-GNN ^[7]	53.6	55.4	37.5	41.6
TENT ^[23]	55.6	62.9	41.1	44.7
GLITTER ^[8]	54.5	60.3	39.3	41.4
X-FNC ^[24]	57.1	62.7	45.3	46.5
UDPN ^[27]	58.7	62.5	47.7	48.2
TAS-FNC	60.2	62.3	46.9	48.5

注: 加粗表示最优结果。

结果表明,所提方法 TAS-FNC 在两个共同购买网络上取得了最好结果,在两个引文网络上取得了较好的分类结果。由于标记数据稀缺,图嵌入方法的性能最差;而少样本方法 PN 和 MAML 由于未考虑节点之间的拓扑关系,在节点分类问题上表现不佳;少样本节点分类方法均优于上述 4 种方法,表明将 GNN 与元学习范式结合可有效提升少样本节点分类性能。然而, Mate-GNN、GPN、AMM-GNN、TENT 等方法直接在全局图结构上学习节点表示,易受任务无关噪声干扰,导致模型泛化能力受限; GLITTER、X-FNC 在进行子图采样时忽略了子图连通性约束,导致消息传播范围受限; GPN、UDPN 直接计算查询节点与类原型的相似性以对查询节点分类,忽视了判别性维度对分类的潜在影响。本文方法 TAS-FNC 通过构建连通性强的任务子图以获得任务相关的节点表示,并学习查询节点与类原型的关系以进行节点分类,提高了分类性能。

4.4 消融实验

为了验证本方法中各个模块的有效性,以 Amazon-C 数据集为例在 5-way 3-shot 任务上设计了 3 个消融实验,分别移除任务子图表示模块 (TAS-FNC w/o TS)、关系学习模块 (TAS-FNC w/o G),以及同时移除两个模块 (TAS-FNC w/o TSG)。实验结果见表 6。

表 6 消融实验结果
Table 6 Results of ablation study

实验设置	准确率/%
TAS-FNC w/o TS	78.67(14.76)
TAS-FNC w/o G	79.45(13.81)
TAS-FNC w/o TSG	76.07(17.46)
TAS-FNC	82.60

实验结果表明,移除任务子图表示模块将导致模型准确率下降 4.76%,移除关系学习模块则使准确率下降 3.81%,同时移除两个模块时准确率下降幅度达 7.46%。这充分说明两个模块在模型性能中的重要作用。具体而言,结构裁剪可过滤掉任务无关信息,拓扑增强可促进语义相似节点之间的信息传递,从而提升模型对任务的适应能力。而关系学习模块则能够精准建模查询节点与类原型之间的关系,进一步提升分类性能。

4.5 参数分析

4.5.1 原型分离正则项的权重参数 λ

以 Amazon-C 数据集为例,在 5-way 3shot 设置下,查询集实例数为 10,对控制原型分离正则项 $\lambda = \{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0\}$ 的情况进行实验,如图 2 所示。当 λ 取 0.7 时,准确率最高。




图 2 参数 λ 分析对比结果

Fig. 2 Comparative results of parameter λ analysis

4.5.2 支持集类别数 N

支持集类别数表示每个元任务中类的个数。为了分析 N 的变化对实验结果的影响,固定 $K=5$ 、 $Q=20$,设置了 $N=\{5,6,7,8,9\}$ 进行实验。实验结果如图 3 所示。随着 N 的增大,准确率逐渐下降,主要原因是随着任务中类别数的增多,节点分类的难度增加。




图 3 参数 N 分析对比结果

Fig. 3 Comparative results of parameter N analysis

4.5.3 支持集实例数 K

支持集实例数表示元任务中每个类采样的有标记节点的个数。为了分析 K 的变化对实验结果的影响,固定 $N=5$ 、 $Q=20$,设置了 $K=\{3,4,5,6,7\}$ 进行实验。实验结果如图 4 所示。随着 K 的增大,准确率逐渐升高。主要原因是随着支持集节点个数的增多,类原型的代表性就越有效,查询节点与类原型的关系也就学习得越好。




图 4 参数 K 分析对比结果

Fig. 4 Comparative results of parameter K analysis

4.5.4 查询集实例数 Q

查询集实例数是每个元任务中需要预测的节点个数。为了分析 Q 的变化对实验结果的影响,

固定 $N=5$ 、 $K=5$, 设置了 $Q=\{5,10,15,20\}$ 进行实验。实验结果如图 5 所示。随着 Q 的增大, 准确率逐渐升高。主要原因是查询集实例数越多越有利于模型学习到跨任务的元知识, 从而提升模型的泛化性能。




图 5 参数 Q 分析对比结果

Fig. 5 Comparative results of parameter Q analysis

5 结束语

针对少样本节点分类任务中任务无关信息干扰与低资源环境制约模型性能的问题, 本文提出了一种基于任务子图感知的少样本节点分类算法 TAS-FNC。通过邻域采样与连通性采样对原图进行结构裁剪, 并结合拓扑增强策略构建高连通性的任务子图, 有效抑制噪声干扰信息的影响。在此基础上, 设计了关系学习模块以更精确地建模查询节点与类别原型之间的关系, 提升模型在低资源场景下的判别能力。在 4 个基准数据集上的实验结果表明, TAS-FNC 在分类准确率上优于对比算法, 说明其在任务感知建模与泛化能力方面的有效性。

未来考虑将本文方法推广至动态图或时序图环境, 以更好地适应现实场景中节点属性与结构关系随时间演化的动态特性; 此外, 还将探索多模态图结构的建模方式, 融合节点所携带的文本、图像等非结构化信息, 以增强模型对复杂语义模式的理解与表达能力。

参考文献:

- [1] WANG Weiqing, YIN Hongzhi, DU Xingzhong, et al. Online user representation learning across heterogeneous social networks[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2019: 545–554.
- [2] FOUT A, BYRD J, SHARIAT B, et al. Protein interface prediction using graph convolutional networks[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 6533–6542.
- [3] 于浩森, 刘炜, 孟流畅, 等. RWK-GNN: 基于特征增强与子核分解的非平衡图欺诈检测算法[J]. 电子学报, 2024, 52(10): 3382–3391.
YU Haomiao, LIU Wei, MENG Liuchang, et al. RWK-GNN: fraud detection for imbalanced graphs with feature enhancement and subkernel decomposition[J]. Acta electronica sinica, 2024, 52(10): 3382–3391.
- [4] 刘晓光, 李梅. 基于深度学习的药物-靶标相互作用预测研究综述[J]. 智能系统学报, 2024, 19(3): 494–524.
LIU Xiaoguang, LI Mei. A survey of deep learning-based drug-target interaction prediction[J]. CAAI transactions on intelligent systems, 2024, 19(3): 494–524.
- [5] DING Kaize, WANG Jianling, CAVERLEE J, et al. Meta propagation networks for graph few-shot semi-supervised learning[J]. Proceedings of the AAAI conference on artificial intelligence, 2022, 36(6): 6524–6531.
- [6] DONG Chuanqi, LI Wenbin, HUO Jing, et al. Learning task-aware local representations for few-shot learning[C]//Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence. New York: ACM, 2021: 716–722.
- [7] WANG Ning, LUO Minnan, DING Kaize, et al. Graph few-shot learning with attribute matching[C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York: ACM, 2020: 1545–1554.
- [8] WANG Song, CHEN Chen, LI Jundong. Graph few-shot learning with task-specific structures[C]//Proceedings of the 36th International Conference on Neural Information Processing Systems. New York: ACM, 2022: 38925–38936.
- [9] LIU Zemin, FANG Yuan, LIU Chenghao, et al. Relative and absolute location embedding for few-shot node classification on graph[J]. Proceedings of the AAAI conference on artificial intelligence, 2021, 35(5): 4267–4275.
- [10] ZHOU Fan, CAO Chengtai, ZHANG Kunpeng, et al. Meta-GNN: on few-shot node classification in graph meta-learning[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM, 2019: 2357–2360.
- [11] WU F, ZHANG Tianyi, DE SOUZA A H, et al. Simplifying graph convolutional networks[C]//International Conference on Machine Learning. Long Beach: PMLR, 2019: 6861–6871.
- [12] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: ACM, 2016: 3637–3645.
- [13] YU Xingtong, FANG Yuan, LIU Zemin, et al. A survey of few-shot learning on graphs: from meta-learning to pre-training and prompt learning[EB/OL]. (2024–03–15)[2025–12–22]. <https://arxiv.org/abs/2402.01440>.
- [14] 刘美麟, 李华, 郑文萍. 模体感知的多视图协同聚类优化算法[J]. 计算机研究与发展, 2026, 63(2): 324–337.

- LIU Meilin, LI Hua, ZHENG Wenping. Motif-aware multi-view cooperative clustering optimization algorithm[J]. *Journal of computer research and development*, 2026, 63(2): 324–337.
- [15] 郑文萍, 王英楠, 杨贵. 基于双监督网络嵌入的社区发现算法[J]. *模式识别与人工智能*, 2022, 35(3): 283–290. ZHENG Wenping, WANG Yingnan, YANG Gui. Dual supervised network embedding based community detection algorithm[J]. *Pattern recognition and artificial intelligence*, 2022, 35(3): 283–290.
- [16] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[EB/OL]. (2016–09–09) [2025–12–22]. <https://arxiv.org/abs/1609.02907>.
- [17] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. New York: ACM, 2017: 1025–1035.
- [18] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[C]//*Proceedings of the 6th International Conference on Learning Representations*. Vancouver: ICLR, 2018: 1–12.
- [19] 周凯锐, 刘鑫, 景丽萍, 等. 概念驱动的小样本判别特征学习方法[J]. *智能系统学报*, 2023, 18(1): 162–172. ZHOU Kairui, LIU Xin, JING Liping, et al. Concept-driven discriminative feature learning for few-shot learning[J]. *CAAI transactions on intelligent systems*, 2023, 18(1): 162–172.
- [20] GHAROUN H, MOMENIFAR F, CHEN Fang, et al. Meta-learning approaches for few-shot learning: a survey of recent advances[J]. *ACM computing surveys*, 2024, 56(12): 1–41.
- [21] SNELL J, SWERSKY K, ZEMEL R S. Prototypical networks for few-shot learning[C]//*Neural Information Processing Systems*. Red Hook: Curran Associates, 2017: 4077–4087.
- [22] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//*Proceedings of the 34th International Conference on Machine Learning-Volume 70*. Sydney: PMLR, 2017: 1126–1135.
- [23] WANG Song, DING Kaize, ZHANG Chuxu, et al. Task-adaptive few-shot node classification[C]//*Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2022: 1910–1919.
- [24] WANG Song, DONG Yushun, DING Kaize, et al. Few-shot node classification with extremely weak supervision [C]//*Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining*. New York: ACM, 2023: 276–284.
- [25] DING Kaize, WANG Jianling, LI Jundong, et al. Graph prototypical networks for few-shot learning on attributed networks[C]//*Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. New York: ACM, 2020: 295–304.
- [26] LAN L, WANG P, DU X, et al. Node classification on graphs with few-shot novel labels via meta transformed network embedding[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 16520–16531.
- [27] WANG Ningrui, LAI Yujing, CHEN Chuan, et al. Prototypical networks with unlabeled data for few-shot node classification[J]. *Engineering applications of artificial intelligence*, 2025, 145: 110088.
- [28] 刘鑫磊, 冯林, 廖凌湘, 等. 基于元学习的图卷积网络少样本学习模型[J]. *电子学报*, 2024, 52(3): 885–897. LIU Xinlei, FENG Lin, LIAO Lingxiang, et al. Few-shot learning on graph convolutional network based on meta learning[J]. *Acta electronica sinica*, 2024, 52(3): 885–897.
- [29] MCAULEY J, PANDEY R, LESKOVEC J. Inferring networks of substitutable and complementary products[C]//*Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2015: 785–794.
- [30] TANG Jie, ZHANG Jing, YAO Limin, et al. ArnetMiner: extraction and mining of academic social networks[C]//*Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2008: 990–998.
- [31] HU W, FEY M, ZITNIK M, et al. Open graph benchmark: datasets for machine learning on graphs[C]//*Proceedings of the 34th International Conference on Neural Information Processing Systems*. Red Hook: Curran Associates, 2020: 1–12.

作者简介:



郑文萍, 教授, 博士生导师, 主要研究方向为网络数据分析、生物信息学。发表学术论文 30 余篇。E-mail: wzpeng@sxu.edu.cn。



苏蕊, 硕士研究生, 主要研究方向为复杂网络分析。E-mail: 3257549994@qq.com。



刘扬, 博士研究生, 主要研究方向为复杂网络分析。E-mail: yliu0522@163.com。