

语义调制的异构图对比学习

马林慧¹, 谢志鹏¹, 梁迩耀¹, 刘娟², 黄金贵¹

(1. 湖南师范大学信息科学与工程学院; 2. 长沙民政职业技术学院, 湖南长沙 410081)

摘要: 异构图对比学习在刻画复杂图结构方面展现出良好潜力。然而, 现有方法在构造对比视图时往往难以体现不同视图间的重要性差异, 从而弱化了关键语义路径的作用。同时, 主流方法普遍以节点级对比为核心, 使视图级信息未能得到充分建模。为缓解上述问题, 提出一种语义调制的异构图对比学习方法 SM-HGCL, 通过引入语义调制机制与视图优化策略, 实现更具协同性的多视图表示学习。具体而言, 该方法首先在基于元路径划分的多个视图上, 采用视图优化策略生成具有区分度且语义稳定的对比视图; 其次, 设计语义感知平衡模块, 自适应调整不同元路径对最终表示的贡献, 增强模型对关键关系的捕捉能力; 最后, 提出语义一致性对比损失, 兼顾局部细节与全局上下文, 以提升多层级特征的一致性与表达能力。在多个基准数据集上的实验结果表明, 所提方法在节点分类和聚类任务中的性能均优于现有方法, 尤其是在 AMiner 数据集上的 Macro-F1 和 ARI 相较最优基线分别提升了 2.92% 和 10.29%, 验证了其有效性与泛化能力。

关键词: 异构图; 图神经网络; 图对比学习; 视图优化; 元路径

DOI: 10.11907/rjtk.251783

中图分类号: TP181

文献标识码: A

文章编号: 1672-7800(XXXX)0XX-0001-08



扫描二维码阅读全文:

Semantic-Modulated Heterogeneous Graph Contrastive Learning

MA Linhui¹, XIE Zhipeng¹, LIANG Eryao¹, LIU Juan², HUANG Jingui¹

(1. College of Information Science and Engineering, Hunan Normal University;
2. Changsha Social Work College, Hunan Normal University, Changsha 410081, China)

Abstract: Heterogeneous Graph Contrastive Learning (HGCL) has demonstrated good potential in capturing complex graph structures. However, existing methods often struggle to reflect the importance differences between different views when constructing contrastive views, thereby weakening the role of key semantic paths. Meanwhile, mainstream methods generally focus on node-level contrast, failing to fully model view-level information. To alleviate the above issues, we propose a Semantic Modulation-based Heterogeneous Graph Contrastive Learning (SM-HGCL) method. By introducing a semantic modulation mechanism and a view optimization strategy, it achieves more collaborative multi-view representation learning. Specifically, the method first generates contrastive views with distinguishability and semantic stability on multiple views based on meta-path partitioning, using a view optimization strategy. Secondly, a semantic-aware balancing module is designed to adaptively adjust the contributions of different meta-paths to the final representation, enhancing the model's ability to capture key relationships. Finally, a semantic consistency contrastive loss is proposed, which considers both local details and global context to improve the consistency and expressiveness of multi-level features. Experimental results on multiple benchmark datasets show that the proposed method outperforms existing methods in both node classification and clustering tasks. Especially on the AMiner dataset, it achieves a 2.92% improvement in Macro-F1 and a 10.29% improvement in ARI compared to the optimal baseline, validating its effectiveness and generalization ability.

Key Words: heterogeneous graph; graph neural network; graph contrastive learning; view optimization; meta-path

收稿日期: 2025-11-25

基金项目: 湖南省自然科学基金青年学生基础研究项目 (2025JJ60879)

作者简介: 马林慧 (2002-), 女, CCF 学生会会员, 湖南师范大学信息科学与工程学院硕士研究生, 研究方向为图神经网络、计算机视觉; 谢志鹏 (2001-), 男, 湖南师范大学信息科学与工程学院硕士研究生, 研究方向为计算机视觉; 梁迩耀 (2003-), 男, 湖南师范大学信息科学与工程学院学生, 研究方向为计算机视觉; 刘娟 (1990-), 女, 硕士, 长沙民政职业技术学院讲师, 研究方向为机器视觉、深度学习、电气自动化技术及其应用; 黄金贵 (1964-), 男, 博士, 湖南师范大学信息科学与工程学院教授、博士生导师, 研究方向为 NP 难问题的精确算法、近似算法及参数算法理论、深度学习、图神经网络与大模型等及其应用。本文通讯作者: 刘娟、黄金贵。

0 引言

图结构数据在复杂现实网络的表示与分析中发挥着关键作用^[1-3]。其中,异构图或异构信息网络(Heterogeneous Information Networks, HINs)因能同时建模多类型实体及其多重关系,已成为理解和刻画复杂系统的重要工具^[4-5]。近年来,异构图神经网络(Heterogeneous Graph Neural Network, HGNN)凭借强大的表示学习能力和端到端建模优势,已逐渐成为处理 HIN 数据的主流方法^[6-8]。然而, HGNN 的性能高度依赖充足且高质量的标注数据。在现实场景中,标注工作通常昂贵且耗时,严重限制了模型的可扩展性与泛化能力。

为缓解对标注数据的依赖,自监督学习(Self-supervised Learning, SSL)在图学习领域受到广泛关注。SSL 通过挖掘数据的结构或语义先验自动生成监督信号,使模型能够在无标签条件下学习鲁棒的特征表示。借鉴自然语言处理和计算机视觉领域的成功经验,研究者将 SSL 引入 HGNN,以增强模型对结构模式与语义关系的建模能力^[9]。对比学习作为其中极具影响力的方向,通过拉近正样本、拉远负样本,显著提升了表示空间的判别性,从而推动了异构图对比学习(Heterogeneous Graph Contrastive Learning, HGCL)的发展^[10-16]。

然而,现有方法在对比视图构建和语义信息处理方面仍存在不足,主流方法通常依赖特征或结构扰动生成视图^[12,17]。例如,文献[10]提出的 DGI 通过随机掩蔽节点特征与嵌入重排来构造视图,这类随机增强虽然能在一定程度上提升模型的鲁棒性,但难以保证语义结构的完整性,可能导致视图间出现语义偏移。还有一些方法通过元路径构建视图。例如,文献[12]提出的 AdaMEOW 基于不同元路径生成粗粒度与细粒度视图,以捕获节点间关联和局部内部结构。然而,不同视图之间缺乏有效的协调机制,导致关键语义难以被突出,而弱相关语义可能被过度放大,从而削弱特征判别性。

对比损失函数的设计也仍有进一步提升的空间。例如,文献[11]提出的 HeCo 和文献[18]提出的 STENCIL 直接沿用其他领域的通用对比损失,无法充分利用图数据中蕴含的高阶结构与复杂语义特性。文献[17]提出的 HGC-ML 从元路径内外开展多层次对比,以挖掘语义互补性。文献[19]提出的 NCLA 通过引入邻居级对比,为锚点节点提供多个正样本,从而增强局部一致性建模。然而,这些方法大多局限于节点级对比,缺乏对全局拓扑和多尺度语义的系统建模,因此难以有效捕获复杂语义依赖和全局结构模式。

针对上述问题,本文提出一种语义调制的异构图对比学习方法(Semantic-Modulated Heterogeneous Graph Contrastive Learning, SM-HGCL)。其从视图构建、语义平衡和

对比优化 3 个方面系统提升异构图的表示能力。首先, SM-HGCL 基于元路径构建语义视图,并引入结构保持型视图优化机制(Structure-preserving View Mechanism, SPVM)来生成对比视图。该机制在进行数据增强的同时能够筛选并修正扰动导致的信息偏移,从而在保持关键拓扑结构的前提下提升模型的鲁棒性与泛化性能;其次,本研究设计了语义感知平衡模块(Semantic-aware Balance Module, SABM),分别在路径和视图两个层面建立语义关联,并根据关联强度动态调整不同视图的权重。通过甄别语义的重要性,该模块能够在多种关系间实现更精确的语义筛选与特征整合,从而强化关键模式并抑制冗余信息;最后,提出语义一致性对比损失(Semantic Consistency Contrastive Loss, SCCL),通过联合建模局部关系结构与全局语境模式,实现多层次语义的一致性对齐与整体优化。

1 理论基础

1.1 HGNN

HGNN 在处理多类型节点与多重关系的复杂场景中展现出独特优势,因而围绕其语义建模方式的研究不断涌现^[20-22]。例如, Wang 等^[6]在图注意力网络(Graph Attention Network, GAT)^[7]的基础上,将多头注意力扩展至异构图结构,并在节点层与语义层同时建模,以整合不同类型关系的特征。然而,该方法在计算元路径权重时主要依赖目标节点特征,对路径中其他节点的贡献考虑不足。Hu 等^[8]提出互注意力机制,在评估元路径重要性的同时刻画节点与边的异质性,从而实现更细致的语义聚合。然而,由于该机制主要依据元关系进行权重调整,在捕获语义的细粒度变化方面仍存在一定局限。Yang 等^[23]提出的 SeH-GNN 通过引入更长的元路径来扩大模型的感受野,并采用基于 Transformer 的语义融合模块整合多视图信息,以增强语义表达能力。Chen 等^[24]提出的 AMOGCN 通过多阶邻接矩阵构建丰富的结构表示,从而显著提升节点表示能力,但在实际应用中往往依赖较多标注数据。

1.2 图对比学习

对比学习作为自监督学习的重要方向,通过拉近语义相近样本并区分不相似样本,从而获得判别性表示^[9]。将该理念引入图神经网络后形成的图对比学习在无监督条件下显著提升了图表示的表达能力。早期提出的 DGI 通过最大化节点级与图级的互信息,使编码器能够同时捕获局部结构与整体图语义^[10]。然而,由于该方法主要面向同构图,其在多类型实体与关系共存的异构场景中性能有限。为此, Ren 等^[25]提出 HDGI,其在 DGI 框架的基础上结合元路径与注意力机制聚合语义信息,并通过全局互信息约束增强整体结构一致性,但该方法在高阶拓扑依赖的建模方面仍相对不足,且随机特征掩蔽的增强策略可能破坏关键语义结构。Wang 等^[11]从网络模式出发构建局部结构

视图, 并与元路径视图进行跨视图对比, 以强化异构语义建模。然而, 该方法直接采用 InfoNCE 损失, 未结合图结构特性进行针对性优化。在此基础上, Yu 等^[12]对 InfoNCE 进行加权扩展, 并引入原型对比以提升语义聚合能力。但该方法仍聚焦于节点级对比, 对全局拓扑特征的利用相对有限。此外, 该方法完全依赖元路径生成视图, 使模型对元路径的选择较为敏感。Chen 等^[26]提出的 CACL 引入社区结构来指导视图构建, 以提升跨社区节点的辨识能力, 但在结构分布差异较大的图上仍面临稳定性问题。总体来看, 现有方法多依赖随机扰动或固定策略构建对比视图, 对浅层关键结构与语义敏感区域的保护仍然不足。




Fig. 1 Overall framework of SM-HGCL

图1 SM-HGCL 整体框架

2.1 视图构建

2.1.1 语义视图构建

不同的元路径能够刻画 HIN 中不同层面的语义依赖与结构特征, 从而使基于多元路径生成的视图在语义上具备互补性。设异构图 $G=(V, E, A, T)$ 中, A 与 T 分别表示节点类型与边类型集合。定义元路径集合 $\{\theta_1, \theta_2, \dots, \theta_M\}$, 其中每条元路径 θ_m 表示一种复合关系, 如 $A_1 \xrightarrow{R_1} A_2 \xrightarrow{R_2} \dots \xrightarrow{R_k} A_{k+1}$ 。基于元路径 θ_m 可从原始图中提取相应的子图 $G_m^s = (V_m^s, E_m^s, A_m^s, T_m^s)$, 从而得到语义视图集合 $\{G_1^s, G_2^s, \dots, G_M^s\}$ 。

2.1.2 SPVM

在异构图的语义建模中, 节点与边的特征信息共同构成浅层结构特征, 是理解图拓扑关系与语义分布的基础。然而, 单纯依赖随机增强策略可能导致关键节点或重要边被误删, 从而破坏图的连通性与语义一致性, 降低表示质量。为此, 本文提出 SPVM, 在执行增强操作的同时引入重要性筛选策略, 以实现图结构多样性与语义完整性的平衡。具体来说, 在关键节点与边的保护方面进行: ①节点保护。通过节点的度中心性衡量其重要性, 度越高的节点在信息传递中承担的作用越显著; ②边保护。边的重要性通过两端节点度值的和进行量化, 关键边在维持图连通性与信息流动中起核心作用。在数据增强方面进行: ①特征

2 方法构建

SM-HGCL 的整体框架如图 1 所示。首先, 模型基于元路径构建多个语义视图, 并结合数据增强与视图优化生成兼具区分度和语义稳定性的对比视图; 其次, 引入 SABM 自适应建模不同元路径的语义关联, 动态调整其对最终表示的贡献, 以更有效地捕捉关键关系; 最后, 采用 SCCL 综合对齐局部结构细节与全局语境模式, 进一步强化多层次特征的一致性与表达能力。

掩蔽。对部分节点特征进行随机掩蔽, 从而模拟信息缺失场景, 引导模型从上下文中推断潜在语义。保留重要节点特征, 以确保核心语义信息不被破坏; ②边扰动。对边进行随机删除, 以提升视图结构多样性, 并增强对局部拓扑变化的鲁棒性。同时, 通过对关键边实行保护机制, 避免破坏重要语义传播路径和核心结构信息。

通过上述增强与结构保护策略, 生成的视图在保留原始语义结构的同时引入适度扰动, 提升了模型对局部变化的适应能力。由此得到的视图既具备足够的区分度, 又保持了稳定的语义一致性, 为后续学习提供了更可靠多样的输入。

2.2 SABM

为实现多元语义关系的自适应融合, 本文设计了 SABM。该模块由路径级注意力模块 (Path Attention Module, PAM) 和多元语义聚合模块 (Multi-Semantic Aggregation Module, MAM) 两部分组成。PAM 用于刻画元路径内部的语义结构, 侧重于捕获单条路径所携带的局部语义模式; MAM 则进一步建模不同元路径之间的全局依赖关系, 实现跨关系的特征聚合与语义整合。通过 PAM 与 MAM 的协同作用, SABM 能够自适应地融合不同元路径所携带的多元语义特征, 提升模型对关键关系模式的捕获能力。SABM 结构如图 2 所示。




Fig. 2 Structural of SABM

图2 SABM结构

2.2.1 PAM

在异构图中,不同元路径对应不同类型的语义关系。对于路径 p 中的节点 i 及其邻居节点 j ,分别以特征表示 h_i 与 h_j 描述其语义信息。PAM通过计算节点对之间的语义相关性权重来建模路径内部的语义差异。其注意力得分定义为:

$$e_{ij}^{(p)} = \alpha_p \sigma(\mathbf{W}_p [\mathbf{h}_i \parallel \mathbf{h}_j]) \quad (1)$$

式中: $\mathbf{W}_p$ 为路径特定的线性变换矩阵; α_p 为可学习的注意力向量; $\sigma(\cdot)$ 为非线性激活函数; $[\cdot \parallel \cdot]$ 表示特征拼接操作。该公式可显式比较路径内节点特征的差异,有助于捕获细粒度的语义变化模式。

为保证不同邻居节点的贡献具有可比性,需对注意力得分进行归一化处理,从而得到路径内的注意力权重。表示为:

$$\alpha_{ij}^{(p)} = \frac{\exp(e_{ij}^{(p)})}{\sum_{k \in \mathcal{N}_i^{(p)}} \exp(e_{ik}^{(p)})} \quad (2)$$

式中: $\mathcal{N}_i^{(p)}$ 表示节点 i 在路径 p 下的邻居集合。

最终,节点 i 的路径级语义嵌入表示为:

$$\mathbf{z}_i^{(p)} = \sum_{j \in \mathcal{N}_i^{(p)}} \alpha_{ij}^{(p)} \mathbf{W}_p \mathbf{h}_j \quad (3)$$

基于式(3)得到的加权聚合,PAM能够在路径层面建模节点间的语义依赖,实现路径内部的差分式特征提取。这一机制有助于更准确地刻画语义信息的传播与交互,为后续的全局语义融合提供细粒度的表示支撑,从而增强模型在多元关系场景下的特征表达能力与判别性。

2.2.2 MAM

不同元路径所承载的语义类型及其重要性存在较大差异。如果直接对各元路径的输出进行平均聚合,可能引入语义冲突或累积噪声,从而削弱整体表示能力。为解决这一问题,MAM在全局层面实现多元语义关系的自适应融合。其通过计算每条元路径的语义显著性得分,并采用软注意力机制对其输出进行动态加权,从而增强全局语义空间中更具判别力的特征表示。具体而言,为刻画每条元

路径在全局语义空间中的分布特性,定义路径 p 的全局语义中心为:

$$\bar{\mathbf{z}}^{(p)} = \frac{1}{|\mathcal{V}|} \sum_{i \in \mathcal{V}} \mathbf{z}_i^{(p)} \quad (4)$$

式中: $\mathcal{V}$ 表示节点集合。该式反映了 p 的整体语义特征分布,为后续的重要性估计提供了统计基础。

基于全局语义中心计算各元路径的语义显著性得分。公式为:

$$s^{(p)} = q \tanh(\mathbf{W}_m \bar{\mathbf{z}}^{(p)}) \quad (5)$$

式中: $\mathbf{W}_m$ 为可学习的线性变换矩阵; q 为可学习的查询向量。该过程通过将非线性映射与向量相似度计算相结合,对不同元路径在全局语义空间中的相对重要性进行衡量,从而实现多元语义特征的自适应加权聚合。

随后,将所有元路径的显著性得分归一化,得到路径级注意力权重。公式为:

$$\beta^{(p)} = \frac{\exp(s^{(p)})}{\sum_{p'} \exp(s^{(p')})} \quad (6)$$

归一化操作保证了所有元路径权重之和为1,从而实现不同语义关系的自适应平衡。最终,节点的全局语义融合表示为:

$$\mathbf{z}_i = \sum_p \beta^{(p)} \mathbf{z}_i^{(p)} \quad (7)$$

式(7)通过对不同语义路径进行加权融合,实现了全局层面的语义动态平衡与互补增强。该机制不仅能够抑制冗余语义带来的噪声干扰,而且能突出全局语义中判别性较强的关键特征,从而提升节点表示的鲁棒性与表达能力。

SABM在语义建模中显式刻画路径内部节点特征的差异,从而捕获细粒度的语义变化模式。该模块采用双层语义聚合结构,通过路径内与路径间的层次化注意力机制来实现局部—全局语义的有效融合。此外,通过PAM与MAM的联合训练,SABM能够动态自适应地分配多元语义权重,从而实现特征的互补增强,进一步提升模型的表达能力与判别性。

2.3 SCCL

为确保多语义视图间的表示一致性与判别性,本研究设计了SCCL,从局部特征聚合、层次语义对齐与全局分布一致性3个层面共同优化节点表示。SCCL由语义内聚对比(Semantic Cohesion Contrast, SCC)、跨层语义对齐对比(Cross-level Alignment Contrast, CAC)和全局语义一致性对比(Global Semantic Consistency Contrast, GSCC)三部分组成。

2.3.1 SCC

SCC在锚点与其正负样本之间进行对比,实现同语义节点间聚合的强化,同时拉开不同语义节点间的距离。该机制能够在节点层面实现特征的精细区分,从而提升局部

节点表示的判别能力。其目标函数定义为:

$$L_{SCC}^{(i,j)}(v) = -\log \frac{\sum_{u \in P_v^+} \exp(\sigma(z_v^i, z_u^j)/\tau) s_{(i,j)}(v, P_v^+)}{\sum_{u \in P_v^+} \exp(\sigma(z_v^i, z_u^j)/\tau) + \sum_{u \in P_v^-} \exp(\sigma(z_v^i, z_u^j)/\tau) + \sum_{u \in P_v^+} \exp(\sigma(z_v^i, z_u^i)/\tau)} \quad (8)$$

式中: z_v^i 与 z_u^j 分别表示节点 v 和 u 在对比视图 G_i^c 和 G_j^c 中的表示; P_v^+ 与 P_v^- 分别表示 v 的正样本集合和负样本集合; $\sigma(\cdot)$ 为相似性函数; τ 为可学习的温度参数。

通过最小化该损失函数, 模型能够增强语义相似节点之间的聚合效应, 实现局部语义空间的结构优化, 提高特征的判别性与鲁棒性。

2.3.2 CAC

不同语义视图反映异构图中的不同语义层面。为实现局部与全局语义的协调一致, 本文引入跨层语义对齐对比, 通过比较节点表示与全局图摘要实现跨层语义融合。其损失定义为:

$$L_{CAC}^{(i,j)}(v) = -\log(f(z_v^i, g_i)) - \log(1 - f(z_v^j, g_j)) \quad (9)$$

式中: g_i 表示对比视图 G_i^c 的全局语义摘要; $f(\cdot, \cdot)$ 由双层线性映射与 Sigmoid 函数组成。该项用于促进节点语义与全局语义的一致性, 提升多层语义表示的连贯性。

2.3.3 GSCC

由于在数据增强过程中引入了特征掩蔽与边扰动, 不同对比视图可能在结构上产生偏移。为确保多视图的全局语义分布保持一致, 本文设计 GSCC 损失, 其在视图间建立分布约束, 以保证全局一致性。表示为:

$$L_{GSCC}^{(i,j)} = -\log \frac{\exp(\sigma(\gamma_i^c, \gamma_j^s)/\tau)}{\exp(\sigma(\gamma_i^c, \gamma_j^s)/\tau) + \exp(\sigma(\gamma_i^c, \gamma_j^c)/\tau)} \quad (10)$$

式中: γ_i^c 和 γ_j^s 分别表示对比视图 G_i^c 和语义视图 G_j^s 的全局嵌入; $\varphi(\cdot, \cdot)$ 用于衡量两者的语义相似度。

2.3.4 总体对比损失

SCCL 的总体优化目标综合三部分损失, 表示为:

$$L_{SCCL} = \alpha L_{SCC} + \beta L_{CAC} + \gamma L_{GSCC} \quad (11)$$

式中: α, β, γ 为可学习平衡系数, 用于调节各项损失的贡献。该优化目标在局部—全局—跨视图三层语义空间上保持特征的一致性与判别性, 从而实现多语义信息的统一建模与增强。

3 实验方法与分析

3.1 实验环境与参数设置

所有实验均在 NVIDIA RTX 4090 GPU 上开展。采用 GNN 作为对比视图的编码器, 并使用 Adam 优化器对网络参数进行更新。训练过程中采用早停法, 最大训练轮数为 300, 耐心值为 50。节点特征维度设为 128, 在节点分类和聚类实验中, 特征遮蔽与边扰动率设置为 0.3, 关键信息保留率设置为 0.07。对于基于元路径的方法, 元路径集合设置: 在 AMiner 数据集上为 {PAP, PRP}, 在 FreeBase 数据集上为 {MAM, MDM, MWM}, 在 DBLP 数据集上为 {APA, AP-

CPA, APTPA}, 在 IMDB 数据集上为 {MAM, MDM}, 在 ACM 数据集上为 {PAP, PSP}。

3.2 数据集

为评估 SM-HGCL 的性能, 选择 5 个广泛使用的异构图数据集, 分别为 AMiner、FreeBase、DBLP、IMDB 和 ACM。其中, AMiner 包含 6 564 个论文节点 (P)、35 890 个作者节点 (A) 以及 13 329 个参考文献节点 (R); FreeBase 包含 3 492 个电影节点 (M)、33 401 个演员节点 (A)、2 502 个导演节点 (D) 以及 4 459 个编剧节点 (W); DBLP 包含 4 057 个作者节点 (A)、20 个会议节点 (C)、14 328 个论文节点 (P) 以及 7 723 个术语节点 (T); IMDB 包含 4 278 个电影节点 (M)、5 257 个演员节点 (A) 以及 2 081 个导演节点 (D); ACM 包含 4 019 个论文节点 (P)、7 167 个作者节点 (A) 以及 60 个主题节点 (S)。每个数据集随机选取 20% 的样本作为训练集。

3.3 基线方法

采用 GCN^[27]、GAT、HAN^[6]、GCA^[28]、HeCo、SimGRACE^[29]、STEN-CIL^[14]、HGCML、AdaMEOW 和 Diff-Graph^[30] 作为基线方法, 与 SM-HGCL 进行比较。

3.4 节点分类实验

在节点分类实验中, 采用支持向量机作为分类器, 使用 Macro-F1 与 Micro-F1 指标评估模型性能, 其值越接近 1, 表示分类效果越好。如表 1 所示, 在所有数据集上, SM-HGCL 的 Macro-F1 和 Micro-F1 两项指标均优于其他基线方法, 展现出最佳性能。这是由于其在节点分类任务中能充分利用多视图特征和语义增强机制, 实现更稳健和高效的表示学习。

3.5 节点聚类实验

采用 K-Means 算法对模型生成的节点嵌入进行聚类实验。聚类性能通过归一化互信息 (Normalized Mutual Information, NMI) 与调整兰德指数 (Adjusted Rand Index, ARI) 进行评估, 其值越接近 1, 表明聚类效果越好。节点聚类结果如表 2 所示。可以看出, SM-HGCL 取得最佳表现, 主要原因在于其引入了 SCCL, 在对比学习过程中不仅强化了不同视图间的语义关联, 而且兼顾了各视图的特征差异, 从而有效增强了聚类表示的判别性和一致性。

3.6 消融实验

为验证 SM-HGCL 各组件的必要性, 在 AMiner 和 FreeBase 两个数据集上进行两级消融实验, 结果如表 3 所示。可以看出, 完整模型在所有评价指标上均优于其他变体, 表明模型各核心组件对整体性能均具有重要贡献。具体而言, 性能提升主要源于以下几点: ① 关键浅层结构的保留具有核心价值。SPVM 能有效维护扰动后视图的结构与语义完整性, 在实现数据增强的同时保留关键浅层信息;

Table 1 Results of node classification

表1 节点分类结果

(%)

方法	AMiner		DBLP		IMDB		FreeBase		ACM	
	Ma-F1	Mi-F1	Ma-F1	Mi-F1	Ma-F1	Mi-F1	Ma-F1	Mi-F1	Ma-F1	Mi-F1
GCN	73.29	85.04	88.40	88.64	58.14	58.33	61.41	68.92	88.41	89.57
GAT	72.83	84.97	88.63	89.02	56.82	56.99	62.87	69.12	87.98	88.42
HAN	73.70	85.43	89.35	89.70	54.19	54.48	62.58	70.29	89.11	89.33
GCA	73.27	85.18	87.10	87.92	57.01	57.22	61.06	68.87	87.13	88.52
HeCo	75.01	85.31	90.83	91.08	52.67	52.55	62.99	69.33	88.42	89.05
SimGRACE	74.01	85.88	88.42	89.05	57.12	57.33	61.29	69.01	87.91	89.09
STENCIL	73.02	84.72	92.01	92.33	57.16	57.52	60.63	68.33	87.55	88.42
HGCML	<u>75.40</u>	<u>86.43</u>	89.16	89.73	60.70	61.35	64.74	71.30	90.71	<u>90.89</u>
AdaMEOW	72.05	84.21	91.32	91.51	61.00	61.75	62.33	69.58	90.06	89.92
DiffGraph	71.88	80.51	<u>92.91</u>	<u>92.85</u>	<u>61.37</u>	<u>62.06</u>	<u>66.05</u>	<u>72.11</u>	<u>91.59</u>	90.11
SM-HGCL	78.32	87.36	93.02	93.50	64.47	64.74	67.42	72.76	92.03	91.02

注:Ma-F1表示Macro-F1,Mi-F1表示Micro-F1。

Table 2 Results of node clustering

表2 节点聚类结果

(%)

方法	AMiner		DBLP		IMDB		FreeBase		ACM	
	NMI	ARI	NMI	ARI	NMI	ARI	NMI	ARI	NMI	ARI
GCN	36.74	32.05	71.99	77.53	8.07	8.11	15.56	17.14	58.41	57.13
GAT	37.02	32.88	73.13	<u>79.25</u>	8.55	8.52	15.63	17.04	61.29	60.53
HAN	35.54	31.19	73.22	77.89	7.23	7.58	16.37	17.28	60.43	64.11
GCA	<u>38.21</u>	33.66	<u>74.41</u>	79.23	8.89	8.79	15.33	17.22	60.99	61.42
HeCo	31.44	30.04	70.21	76.32	7.95	8.04	13.27	15.53	56.73	54.11
SimGRACE	37.92	33.28	73.03	79.11	6.99	6.67	15.52	17.33	58.97	57.72
STENCIL	30.66	29.22	71.44	77.58	8.58	8.44	13.22	15.27	56.92	56.11
HGCML	36.09	31.46	73.28	78.19	10.79	10.76	16.99	17.54	<u>65.17</u>	64.35
AdaMEOW	34.02	<u>33.74</u>	71.82	76.34	10.05	10.24	14.33	16.02	63.21	61.59
DiffGraph	37.15	32.44	70.33	77.82	<u>12.05</u>	<u>12.43</u>	<u>18.35</u>	<u>17.58</u>	63.78	<u>64.41</u>
SM-HGCL	45.63	44.03	75.61	81.46	14.09	14.70	19.62	21.31	65.69	66.72

②不同视图的重要性需加以区分。各元路径所携带的语义侧重点不同,SABM对视图差异性的建模与权重调节能使模型有效利用不同视图;③SCCL提供了更全面的语义一致性约束。与传统InfoNCE相比,SCCL不仅能强化语义相近节点的聚合,而且强调视图间互补语义的保持,从而获得更具判别性的多层次表示。

Table 3 Results of ablation experiment

表3 消融实验结果

(%)

SPVM	SABM		SCCL		GSCC	AMiner		FreeBase	
	PAM	MAM	SCC	CAC		Ma-F1	Mi-F1	Ma-F1	Mi-F1
×	√	√	√	√	√	76.68	86.53	66.09	71.73
√	×	√	√	√	√	77.64	86.59	66.38	71.59
√	√	×	√	√	√	77.68	86.47	65.42	71.57
√	×	×	√	√	√	77.56	86.42	65.12	71.51
√	√	√	×	√	√	<u>78.25</u>	<u>87.29</u>	66.78	<u>72.66</u>
√	√	√	√	×	√	78.11	86.98	66.92	72.53
√	√	√	√	√	×	78.19	86.85	<u>67.29</u>	72.09
√	√	√	×	×	×	78.03	86.71	66.63	72.03
√	√	√	√	√	√	78.32	87.36	67.42	72.76

3.7 参数实验

在AMiner与FreeBase数据集上对SM-HGCL在节点分类任务中的参数敏感性进行系统分析。将特征掩蔽与边缘丢弃的概率(P)分别设为0.1、0.3、0.5、0.7,关键信息保

留率(R)分别设为0.00、0.02、0.04、0.06、0.08,系统评估不同扰动强度与保留比例下的模型性能。如图3所示,实验结果可归纳为以下4点:①适量的扰动强度至关重要。适量的特征遮蔽与边扰动能够为模型提供足够的视图差异性,从而获得更稳定且更优的性能;②扰动过弱时易出现过拟合。当 P 较小时,虽然模型仍能捕获部分不变特征,但由于大量关键语义与结构信息被过度保留,模型更容易依赖浅层特征,从而导致泛化能力下降;③扰动过强会破坏结构语义。当 P 过大时,尽管少量浅层关键信息仍得以保留,但整体结构关系与语义模式被大幅破坏,使模型难以从噪声较重的视图中提取稳健的不变特征,最终造成性能退化;④中等扰动范围最为有效。实验结果表明,当 P 取值在0.3~0.5区间, R 取值在0.06~0.08区间时,保留关键信息与构造有效扰动之间取得良好平衡,不仅提升了模型对扰动的鲁棒性,而且增强了其对不变特征的捕获能力,整体性能最为突出。

3.8 元路径有效性分析

本研究在DBLP数据集上分析不同元路径组合对SM-HGCL性能的影响。如表4所示,分别使用元路径组合{APA, APCPA}, {APA, APTPA}, {APCPA, APTPA}, {APA, APCPA, APTPA}进行实验,其中A、C、P、T分别表示作者、会议、论文以及术语节点。可以看出,{APA, APCPA, APTPA}组合取得最高精度,去掉APA的{APCPA, APTPA}组合次之,仅保留APA与APTPA的组合精度最低,说明同时引入“APC”与“APT”两种语义上下文可产生互补效应。此外,对于A而言,C带来的增益高于T。

3.9 复杂度分析

对SM-HGCL的训练时间复杂度进行分析。设异构图中的目标节点数为 n ,元路径条数为 M ,每个节点的平均邻居数为 e ,隐藏特征维度为 d ,每节点对比采样对数为 C 。在视图创建中,对 M 条元路径分别执行一次广度优先采样,复杂度为 $O(MnLe)$ 。在SPVM中,度中心性计算复杂度为 $O(ne)$,保护性掩码与边扰动遍历全图节点,复杂度为 $O(n)$ 。在SABM中,PAM对每条元路径下的邻居进行线




Fig. 3 Results of parameter experiments

图3 参数实验结果

Table 4 Results of meta-path validity analysis

表4 元路径有效性分析结果 (%)		
元路径组合	Ma-F1	Mi-F1
{APA, APCPA}	91.44	92.19
{APA, APTPA}	90.42	90.33
{APCPA, APTPA}	<u>92.61</u>	<u>92.45</u>
{APA, APCPA, APTPA}	93.02	93.50

性变换及注意力计算,复杂度为 $O(Mnd^2)$;MAM求全局中心与路径注意力,复杂度分别 $O(Mnd)$ 与 $O(Md^2)$ 。在SCCL中,SCC中每个节点采集 C 个样本进行比较,复杂度为 $O(Cd^2)$,全图复杂度为 $O(nCd^2)$;CAC全局摘要与对齐的复杂度为 $O(nd+d^2)$;GSCC视图间对比的复杂度为 $O(d^2)$ 。由于元路径条数 M 、每个节点的平均邻居数 e 、每节点对比采样对数 C 均远小于图中的目标节点数 n ,SM-HGCL的时间复杂度可表示为 $O(nd^2)$ 。

4 结语

本文提出的SM-HGCL根据语义重要性动态调整不同

视图的贡献,实现了对关键语义模式的精准捕获。具体而言,其首先对基于元路径构建的视图进行特征遮蔽与边扰动操作,同时通过SPVM保留图中的关键结构信息;其次,SABM对各视图进行权重分配,以突出关键信息;最后,设计SCCL融合局部与全局上下文信息,以指导对比学习。实验结果显示,SM-HGCL在5个公开异构图数据集(AMiner、DBLP、IMDB、FreeBase、ACM)上的性能全面优于现有主流方法。

尽管SM-HGCL在图表示学习方面取得了一定进展,但仍存在以下不足:首先,对比学习依赖负样本构建,训练过程中易将语义相近样本误判为负样本,导致嵌入空间分布不够合理;其次,模型对图结构中的噪声数据较为敏感,无关信息易通过消息传播机制污染节点表示;最后,当前框架主要针对静态图设计,难以有效建模动态演化场景下的时序依赖关系。未来工作将围绕以下方向展开:一是优化负采样策略,引入困难负样本挖掘与去偏机制,提升对比学习质量;二是增强噪声过滤能力,降低冗余信息干扰;三是将模型扩展至动态图场景,引入时间编码模块以捕获节点与边的演化规律,增强对时变数据的适应性。

参考文献:

- [1] ZHOU X Y, CAO R, DING P J, et al. Research on online malicious user identification based on graph neural network[J]. Software Guide, 2025, 24(7): 67-72.
周昕元, 曹冉, 丁培锦, 等. 基于图神经网络的在线恶意用户识别研究[J]. 软件导刊, 2025, 24(7): 67-72.
- [2] XIE C X, SONG Q Y, HUANG J G, et al. Multi-level feature subgraph aggregation graph neural network[J]. Information Fusion, 2025, 121: 103141.
- [3] WU Z X, GE Y S. Graph neural network social recommendation algorithm based on attention mechanism[J]. Software Guide, 2025, 24(9): 75-81.
吴郑霞, 葛云生. 基于注意力机制的图神经网络社交推荐算法[J]. 软件导刊, 2025, 24(9): 75-81.
- [4] XIAO W, ZHU Z Y, ZENG L, et al. Research on 3D embedding model based on heterogeneous symbolic graph neural network[J]. Software Guide, 2025, 24(9): 26-33.
肖伟, 朱振宇, 曾浪, 等. 基于异构符号图神经网络的3D嵌入模型研究[J]. 软件导刊, 2025, 24(9): 26-33.
- [5] LIU J, ZHAO X, JIA Y, et al. HGGN: prediction of microRNA-mediated drug sensitivity based on interpretable heterogeneous graph global-attention network[J]. Future Generation Computer Systems, 2024, 160: 274-282.
- [6] WANG X, JI H, SHI C, et al. Heterogeneous graph attention network[C]//Proceedings of the Web Conference (WWW), 2019: 2022-2032.
- [7] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks[DB/OL]. <https://arxiv.org/abs/1710.10903>, 2017.
- [8] HU Z, DONG Y, WANG K, et al. Heterogeneous graph transformer[C]//Proceedings of the Web Conference (WWW), 2020: 2704-2710.
- [9] SONG Q Y, HU J, XIAO L, et al. DiffCL: a diffusion-based contrastive learning framework with semantic alignment for multimodal recommendations[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(10): 18587-18597.
- [10] YOU Y, CHEN T, SUI Y, et al. Graph contrastive learning with augmentations[C]//Advances in Neural Information Processing Systems (NeurIPS), 2020: 5812-5823.
- [11] WANG X, LIU N, HAN H, et al. Self-supervised heterogeneous graph neural network with co-contrastive learning[C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD), 2021: 1726-1736.
- [12] YU J X, GE Q Q, LI X, et al. Heterogeneous graph contrastive learning with meta-path contexts and adaptively weighted negative samples[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(10): 5181-5193.
- [13] WANG Y, SANG L, ZHANG Y, et al. Generative-contrastive heterogeneous graph neural network[J]. IEEE Transactions on Big Data, 2025, 11(6): 3061-3073.
- [14] JIANG R B, LI Y C, LIU H B, et al. Incorporating attributes and multi-scale structures for heterogeneous graph contrastive learning[J]. Information Fusion, 2025, 122: 103220.
- [15] RAO X, JIANG R H, SHANG S, et al. Next point-of-interest recommendation with adaptive graph contrastive learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2025, 37(3): 1366-1379.
- [16] XIE Y Z, YU C Y, JIN X Z, et al. Heterogeneous graph contrastive learning for cold start cross-domain recommendation[J]. Knowledge-Based Systems, 2024, 299: 112054.
- [17] WANG Z, LI Q, YU D, et al. Heterogeneous graph contrastive multi-view learning[C]//SIAM International Conference on Data Mining (SDM), 2023: 136-144.
- [18] ZHU Y, XU Y, CUI H, et al. Structure-enhanced heterogeneous graph contrastive learning[C]//SIAM International Conference on Data Mining (SDM), 2022: 82-90.
- [19] SHEN X, SUN D, PAN S, et al. Neighbor contrastive learning on learnable graph augmentation[C]//AAAI Conference on Artificial Intelligence (AAAI), 2023: 9782-9791.
- [20] QIN Z L, ZHU Y F, DENG K, et al. Heterogeneous graph neural network algorithm with path optimization fusion[J]. Microcomputer Systems, 2025, 46(3): 627-635.
秦志龙, 朱一峰, 邓琨, 等. 融合路径优化的异构图神经网络算法[J]. 小型微型计算机系统, 2025, 46(3): 627-635.
- [21] TAN X Y, PEI S W. Research on heterogeneous graph neural network model with high-order neighbor aggregation[J]. Microcomputer Systems, 2023, 44(9): 1954-1960.
谭鑫媛, 裴颂文. 聚合高阶邻居节点的异构图神经网络模型研究[J]. 小型微型计算机系统, 2023, 44(9): 1954-1960.
- [22] HOU H M, CHEN C F, GUO J B. Design of graph neural network algorithm based on heterogeneous feature aggregation[J]. Software Guide, 2025, 24(8): 49-58.
侯浩民, 陈昌奉, 郭建邦. 基于异构特征聚合的图神经网络算法设计[J]. 软件导刊, 2025, 24(8): 49-58.
- [23] YANG X, YAN M, PAN S, et al. Simple and efficient heterogeneous graph neural network[C]//AAAI Conference on Artificial Intelligence (AAAI), 2023: 10816-10824.
- [24] CHEN Z, WU Z, ZHONG L, et al. Attributed multi-order graph convolutional network for heterogeneous graphs[J]. Neural Networks, 2024, 174: 1-11.
- [25] REN Y, LIU B, HUANG C, et al. Heterogeneous deep graph infomax[DB/OL]. <https://arxiv.org/abs/1911.08538>, 2019.
- [26] CHEN S, FENG S, LI S S, et al. ACL: community-aware heterogeneous graph contrastive learning for social media bot detection[C]//Findings of the Association for Computational Linguistics: ACL 2024, 2024: 10349-10360.
- [27] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[C]//International Conference on Learning Representations, 2017: 1-14.
- [28] ZHU Y, XU Y, YU F, et al. Graph contrastive learning with adaptive augmentation[C]//Proceedings of the Web Conference (WWW), 2021: 2069-2080.
- [29] XIA J, WU L, CHEN J, et al. Simgrace: a simple framework for graph contrastive learning without data augmentation[C]//Proceedings of the ACM Web Conference (WWW), 2022: 1070-1079.
- [30] LI Z, XIA L, HUA H, et al. DiffGraph: heterogeneous graph diffusion model[C]//Proceedings of the 18th ACM International Conference on Web Search and Data Mining (WSDM), 2025: 40-49.

(责任编辑:尹晨茹)