



XXXX

# 一种融合属性补全与层次对比的异质图神经网络模型

汪祖伟<sup>1,2,3</sup>, 许聪源<sup>1</sup>, 吴桐<sup>1,3</sup>, 邓琨<sup>1,3</sup>

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

**摘要:** 针对现有异质图神经网络模型难以兼顾异质图中节点属性缺失及标签信息稀缺的问题, 提出一种融合属性补全与层次对比的异质图神经网络模型。该模型首先借助编码器-解码器架构对缺失属性进行端到端重建; 其次分别在网络模式低阶视图与元路径高阶视图中编码目标节点, 其中低阶聚合引入槽结构以缓解类型语义混叠; 随后构建元路径视图内与高低阶视图间的层次化对比目标以协同对齐多尺度表征, 并结合细粒度的语义-属性双感知正样本采样策略提升对比信号质量, 最终生成高判别性节点嵌入。在多个公开数据集上开展了广泛实验, 并与多个基线模型进行对比分析。实验结果表明, 节点分类任务中 Macro-F1 值平均提升 0.35%~1.99%, 节点聚类任务中归一化互信息(normalized mutual information, NMI)值平均提升 1.2%~2.1%, 验证了模型的有效性。

**关键词:** 异质图; 图神经网络; 属性补全; 图对比学习; 注意力机制

**中图分类号:** TP391

**文献标志码:** A

**doi:** 10.11959/j.issn.1000-0801.

## Heterogeneous Graph Neural Network Model Integrating Attribute Completion and Hierarchical Contrastive Learning

WANG Zuwei<sup>1,2,3</sup>, XU Congyuan<sup>1</sup>, WU Tong<sup>1,3</sup>, DENG Kun<sup>1,3</sup>

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:** To address the challenge that existing heterogeneous graph neural network models face in simultaneously handling missing node attributes and limited label availability in heterogeneous graphs, this paper proposes a novel heterogeneous graph neural network model that integrates attribute completion with hierarchical contrastive learning. The model first employs an encoder-decoder architecture to achieve end-to-end reconstruction of missing node attributes. Next, it encodes target nodes by capturing both low-order structural neighborhoods and high-order meta-path semantics, where slot-enhanced aggregation is introduced in the low-order representation to reduce type-related se-



mantic ambiguity. To align multi-scale representations effectively, hierarchical contrastive objectives are established within the meta-path space and across low-order and high-order views, enabling collaborative representation learning. Moreover, a fine-grained semantic-attribute dual-aware strategy is applied for positive sample selection to enhance the quality of contrastive signals, leading to highly discriminative node embeddings. Extensive experiments on multiple public datasets, compared against various baseline models, demonstrate that the proposed method achieves average improvements of 0.35% to 1.99% in Macro-F1 score for node classification and 1.2% to 2.1% in Normalized Mutual Information (NMI) for node clustering, thereby validating its effectiveness.

**Key words:** heterogeneous graph, graph neural network, attribute completion, graph contrastive learning, attention mechanism

## 1 引言

异质图由多种类型节点及关系组成,能够自然地刻画如引文网络<sup>[1]</sup>、交通网络<sup>[2]</sup>和社交网络<sup>[3]</sup>等多种复杂场景。图表征学习旨在保留拓扑结构与语义关联的同时,将节点映射至低维连续向量空间中,从而为节点分类<sup>[4]</sup>、节点聚类<sup>[5]</sup>及链路预测<sup>[6]</sup>等下游任务提供有效表征。近年来,异质图神经网络(heterogeneous graph neural network, HGNN)在图表征学习中取得了显著进展,但仍面临诸多挑战。

一方面,受隐私约束、采集成本高昂及数据标注不完备等因素影响,节点属性在实际异质图中存在普遍缺失,使得属性补全成为HGNN领域中一项关键议题。如Jin<sup>[7]</sup>等提出基于属性补全的异质图神经网络(heterogeneous graph neural network via attribute completion, HGNN-AC),借助预训练拓扑嵌入对缺失属性进行补全,但其表现受预训练模型质量制约,泛化能力不足。Yu<sup>[8]</sup>等提出基于知识属性补全的异质图节点分类(knowledge based attribute completion for heterogeneous graph node classification, HGNN-KAC),利用构建的外部知识库与原始图之间的关联补全节点缺失属性。Zhu<sup>[9]</sup>等提出异质图神经网络属性自动补全研究(towards automated attribute completion for heterogeneous graph neural network, AutoAC),将

缺失属性补全形式化为节点级补全算子的自动搜索问题,在包含拓扑相关与无关操作的搜索空间中,通过可微双层优化学习最优补全策略。Zhao<sup>[10]</sup>等提出基于剩余注意机制的异质图神经网络属性补全(attribute completion of heterogeneous graph neural networks based on residual attention mechanism, RA-HGNN),以原始异质图中的拓扑嵌入为引导并结合残差注意机制完成属性重建,但未充分利用高阶语义信息。

另一方面,现有多数HGNN采用半监督范式,训练过程高度依赖高质量节点标签信息,而真实场景中高质量标签往往难以规模化获取,进而限制了模型的适用性。在此背景下,图对比学习作为一种不依赖标签的自监督范式,在异质图表征学习中日益引发关注。其核心思想是构建多视图并通过对比目标拉近正样本、推远负样本,从而学习节点高质量表征。如Wang<sup>[11]</sup>等提出异质图对比多视图学习(heterogeneous graph contrastive multi-view learning, HGCML),基于元路径诱导子图构建多视图,并在视图对之间联合开展节点级与图级对比学习,以促进跨元路径语义一致性。Yu<sup>[12]</sup>等提出具有元路径上下文与自适应负样本加权的异质图对比学习(heterogeneous graph contrastive learning with meta-path contexts and adaptively weighted negative samples, AdaM-EOW),基于元路径构建粗粒度连通视图与细粒度上下文视图,并引入可学习的负样本权重以动

态调节负样本贡献。但其对比视图主要由高阶元路径诱导，对关键局部邻域信息与跨层互补融合考虑不足。Wang<sup>[13]</sup>等提出具有共同对比学习的自监督异质图神经网络(self-supervised heterogeneous graph neural network with co-contrastive learning, HeCo)，构建低阶结构视图与高阶元路径语义视图并进行跨视图对比约束。然而其低阶视图聚合仅依赖注意力加权，缺乏显式的类型语义分离，易引发语义混叠。Li<sup>[14]</sup>等提出多尺度异质图对比学习(multi-scale heterogeneous graph contrastive learning, MHGCL)，通过多尺度反向解码实现跨粒度表征映射，并在多尺度下进行跨视角对比与尺度加权融合。但其正样本采样偏粗粒度，仅依赖元路径连通性进行判定，缺少对元路径权重、语义强度及属性信息的联合刻画，致使对比信号受限。

为更好地应对上述挑战，本文提出一种融合属性补全与层次对比的异质图神经网络模型(heterogeneous graph neural network model integrating attribute completion and hierarchical contrastive learning, HGNN-AH)，在端到端属性补全的基础上，引入高低阶视图层次对比，并结合细粒度的正样本采样策略以提升节点表征质量。主要贡献如下：(1)构建编码器-解码器架构属性补全框架，通过多层邻域编码联合建模高低阶语义交互，并以属性重建约束提升补全质量；(2)设计高低阶视图协同的层次对比学习机制，结合槽结构缓解类型语义混叠，并构建层次化对比目标增强跨视角表征一致性；(3)提出语义-属性双感知的正样本采样策略，融合元路径权重、实例语义强度与属性相似性筛选高质量正样本对，提升对比信号质量；(4)在3个基准数据集进行的实验表明，与当前主流模型相比，该模型在节点分类等任务中均有明显性能提升。

## 2 基本定义

在介绍HGNN-AH模型前，在此给出本文所用异质图相关定义：

**定义1 (异质图<sup>[15]</sup>)** 给定一个图结构  $G=(V, E, \mathcal{A}, \mathcal{R}, \varphi, \phi)$ ，其中  $V$  代表节点集合， $E$  代表边集合， $\mathcal{A}$  表示节点类型集合， $\mathcal{R}$  表示边类型集合。设  $\varphi$  为节点类型映射函数， $\phi$  为边类型映射函数，满足  $\varphi(v) \in \mathcal{A} (v \in V)$ 、 $\phi(e) \in \mathcal{R} (e \in E)$ 。当  $|\mathcal{A}| + |\mathcal{R}| > 2$  时，图  $G$  为异质图，否则为同质图。

为更清晰地描述异质图，在此以图1为例进行说明。如图1(a)所示为计算机引文网络(association for computing machinery, ACM)示例，该异质图中包含作者(A)、论文(P)、主题(S)和术语(T)4类节点，以及论文-作者、论文-主题以及论文-术语3种边。

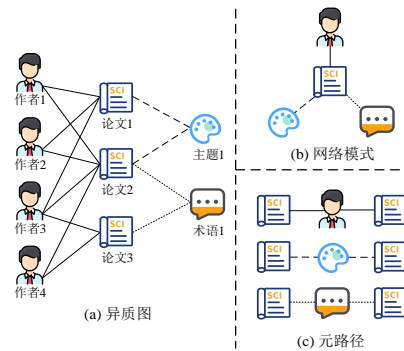


图1 异质图相关定义示例

**定义2 (属性缺失异质图)** 给定一张异质图  $G=(V, E, \mathcal{A}, \mathcal{R}, \varphi, \phi)$ ，属性缺失异质图表示在图  $G$  中，若存在一个节点类型子集  $\mathcal{A}' \subseteq \mathcal{A}$ ，对于节点类型属于  $\mathcal{A}'$  的每个节点  $v \in V$ ，其初始属性为空，则  $G$  为属性缺失异质图。

**定义3 (网络模式)** 网络模式作为异质图的元模板，可表示为  $T_G=(\mathcal{A}, \mathcal{R})$ ，其中  $\mathcal{A}$  为节点类型集合， $\mathcal{R}$  为边类型集合。它抽象描述了异质图中不同类型节点之间的连接结构。

图1(b)给出了ACM数据集中的网络模式示



例, 从中可获知论文与作者、主题及术语之间的关联。因此, 网络模式可用于指导异质图中节点的局部异质邻域建模。

**定义 4 (元路径<sup>[16]</sup>)** 给定一张异质图  $G=(V, E, \mathcal{A}, \mathcal{R}, \varphi, \phi)$ , 则图  $G$  中的元路径  $P$  是由节点类型构成的有序序列:  $P=A_1, A_2, \dots, A_n (A_i \in \mathcal{A} (1 \leq i \leq n))$ , 其中  $n$  为元路径长度。

图 1(c) 为 ACM 中 3 条元路径示例, 其中 PAP 表示同一作者撰写论文之间的关系, PSP 表示同一主题下论文之间的关系, PTP 表示同一术语下论文之间的关系。因此, 不同元路径下隐含着不同语义信息。

**问题定义(异质图表征学习)** 给定一张异质图  $G=(V, E, \mathcal{A}, \mathcal{R}, \varphi, \phi)$  作为输入, 对于  $G$  中的任一节点  $v \in V$ , 异质图表征学习的目标是学习一个映射函数  $f: v \rightarrow z_v \in \mathbb{R}^d$ , 其中  $z_v$  为节点  $v$  学习到的低维稠密向量,  $d$  为嵌入维度,  $d \ll |V|$ 。函数  $f$  旨在使  $z_v$  同时保存异质图中的拓扑信息和多类型特征。

### 3 一种融合属性补全与层次对比的异质图

### 神经网络模型

本文提出的一种融合属性补全与层次对比的异质图神经网络模型(HGNN-AH)总体框架如图 2 所示, 主要由以下四部分构成: (1)属性补全模块, 采用编码器-解码器架构高效完成属性缺失节点的属性补全; (2)网络模式视图模块, 设计槽结构有效捕获节点低阶邻域信息, 从而缓解异质邻域聚合时的语义混叠问题; (3)元路径高阶视图模块, 利用元路径卷积聚合语义丰富的高阶邻域信息; (4)层次对比学习模块, 基于获得的高低阶邻域嵌入构建元路径视图内与高低阶视图间的层次化对比约束, 同时引入细粒度的语义-属性双感知正样本采样策略, 提升对比信号质量。最终, 模型通过联合优化属性重建损失与层次对比损失, 实现对异质图节点的高效表示学习。

#### 3.1 属性补全

异质图中节点属性存在普遍缺失, 已有研究表明<sup>[7,17]</sup>, 属性缺失会削弱异质图表征学习的可靠性, 并导致模型在下游任务中的性能波动。为此, 本文设计了一种基于编码器-解码器架构的属性补全机制。具体而言, 通过编码器将节点原

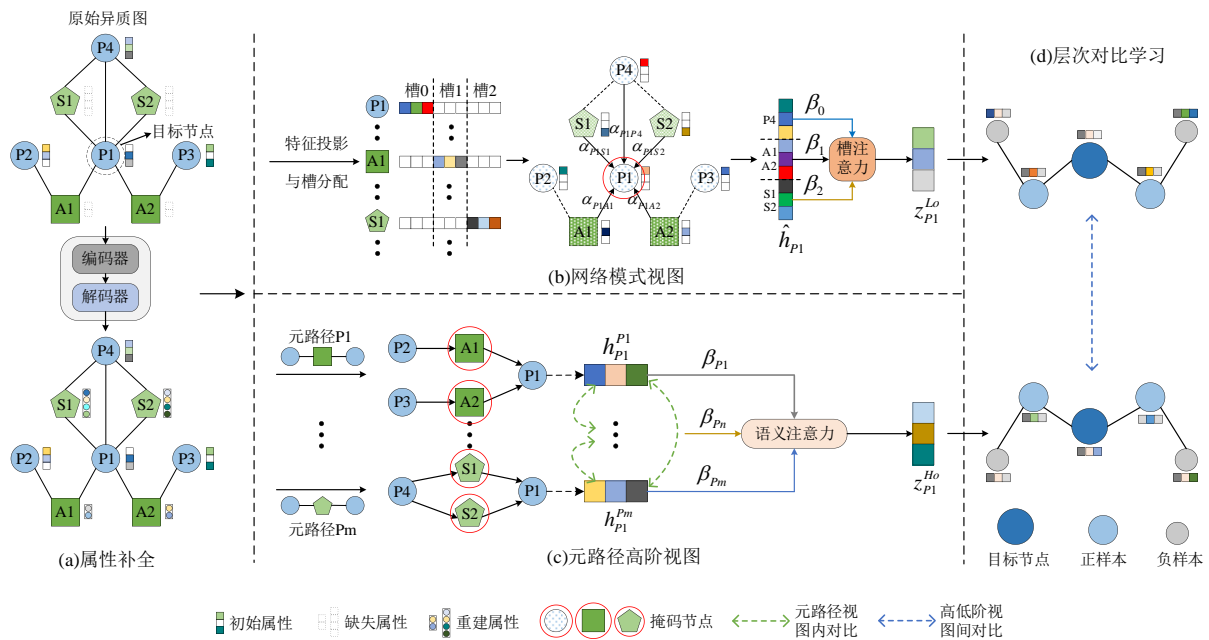


图 2 HGNN-AH 模型框架图

始特征映射到低维嵌入空间中，并利用解码器重建节点的完整属性，在保留图结构信息的同时，有效地补全缺失的节点属性。

RGCN<sup>[18]</sup>是传统GCN<sup>[19]</sup>的扩展，其通过为不同关系类型设置独立的变换矩阵以建模异质关系语义。然而，标准RGCN在同一关系下通常对邻居信息进行平均聚合，难以刻画邻居贡献差异。为此，本文在标准RGCN的聚合过程中引入关系内注意力权重 $\mu$ ，对同一关系下的不同邻居进行细粒度加权，从而突出关键邻居、抑制噪声信息，提升关系内聚合的精度，并将其作为属性补全模块的编码器。为适应编码器输入需求，首先采用类型特定的线性映射对节点特征进行语义对齐，定义为：

$$\mathbf{h}_i = \mathbf{M}_{\varphi_i} \cdot \mathbf{x}_i \quad (1)$$

其中 $\mathbf{x}_i$ 为节点 $i$ 初始属性， $\mathbf{M}_{\varphi_i}$ 为对应于 $i$ 节点类型的变换矩阵， $\mathbf{h}_i$ 为对齐后的节点属性。对于无属性节点，本文将one-hot向量作为其初始属性。随后，将对齐后的节点表示输入编码器：

$$\mathbf{h}_i^{(l+1)} = \sigma \left( \sum_{r \in R_j \in N_i^r} \mu_j^{(l)} \cdot \mathbf{W}_r^{(l)} \cdot \mathbf{h}_j^{(l)} + \mathbf{W}_0^{(l)} \cdot \mathbf{h}_i^{(l)} \right) \quad (2)$$

其中 $R$ 表示关系类型集合， $N_i^r$ 表示节点 $i$ 在关系 $r$ 下的所有邻居节点集合， $\mathbf{W}_r^{(l)}$ 为第 $l$ 层对应于关系 $r$ 的可训练参数矩阵， $\mathbf{W}_0^{(l)}$ 为第 $l$ 层的可训练自连接矩阵， $\mu_j^{(l)}$ 表示第 $l$ 层对应于邻居节点 $j$ 的关系内注意力权重， $\sigma(\cdot)$ 为激活函数， $\mathbf{h}_i^{(l+1)}$ 为节点 $i$ 在第 $(l+1)$ 层学习到的嵌入表示。其中，每一层的 $\mu_j$ 计算过程如下：

$$\mathbf{h}_j'' = L2Norm(\mathbf{h}_j) \quad (3)$$




图3 编码器示意图

$$\mathbf{h}_r'' = L2Norm \left( \frac{1}{|N_i^r|} \sum_{j \in N_i^r} \mathbf{h}_j \right) \quad (4)$$

$$e_j = \mathbf{att} \mathbf{n}^r * [\mathbf{h}_j || \mathbf{h}_r''] \quad (5)$$

$$\mu_j = \mathit{soft} \max(e_j) = \frac{\exp(e_j)}{\sum_{k \in N_i^r} \exp(e_k)} \quad (6)$$

其中 $L2Norm$ 表示 $L2$ 归一化， $\mathbf{att} \mathbf{n}^r$ 为对应于关系 $r$ 的可学习注意力参数向量， $*$ 表示向量点积操作， $||$ 为向量拼接， $\mathit{soft} \max(\cdot)$ 为归一化函数。编码器示意图如图3所示。

通过 $l$ 层编码器的逐层聚合与节点嵌入表示更新，节点 $i$ 已学习到聚合丰富语义信息的节点表示，记作 $\tilde{\mathbf{h}}_i$ 。为避免引入不必要的复杂性，本文采用简单的线性解码器将节点嵌入映射回原始特征空间，以重建节点属性。该设计既保持了模型的简洁性，也有效避免了解码器过度拟合，从而保证了属性补全结果的质量。其计算公式如下：

$$\tilde{\mathbf{x}}_i = \tilde{\mathbf{M}}_{\varphi_i} \cdot \tilde{\mathbf{h}}_i \quad (7)$$

其中 $\tilde{\mathbf{h}}_i$ 为节点 $i$ 通过编码器学习到的嵌入结果， $\tilde{\mathbf{M}}_{\varphi_i}$ 为将 $i$ 节点类型映射回原始特征维度的可学习权重矩阵， $\tilde{\mathbf{x}}_i$ 为节点 $i$ 补全属性后的特征向量。

至此，完成了节点缺失属性的补全，此时异质图中所有节点的属性可定义为 $\bar{\mathbf{X}} = \{\mathbf{x}_i, \tilde{\mathbf{x}}_j | \forall i \in V^+, \forall j \in V^-\}$ 。其中 $V^+$ 表示具有初始属性的节点集合， $\mathbf{x}_i$ 为对应原始属性； $V^-$ 表示不具有初始属性的节点集合， $\tilde{\mathbf{x}}_j$ 为对应属性补全后的节点属性，且有 $V = V^+ \cup V^-$ 。同时， $\bar{\mathbf{X}}$ 将用于后续模块的输入。



此外，为使补全过程能够在监督信号的引导下实现更精确的属性重建，定义属性重建损失  $\mathcal{L}_{Rec}$ 。该损失通过最小化具有原始属性节点的真实属性与其重建属性之间的均方误差，对模型参数进行约束与优化，从而提升重建结果对真实属性的拟合程度。其表达式如下：

$$\mathcal{L}_{Rec} = \frac{1}{|V^+|} \sum_{i \in V^+} \|\mathbf{x}_i - \tilde{\mathbf{x}}_i\|^2 \quad (8)$$

其中  $V^+$  为具有初始属性的节点集合， $\mathbf{x}_i$  与  $\tilde{\mathbf{x}}_i$  分别表示节点  $i$  的原始真实属性与重建属性。

### 3.2 网络模式视图

网络模式视图用于捕获目标节点的局部异质邻域信息，并为层次对比学习提供低阶表示输入。由于局部邻域的异质性，不同类型节点的特征往往位于不同语义空间当中，难以直接进行统一聚合。为此，在邻域聚合之前，首先采用特定类型的投影矩阵将节点特征统一至同一维度空间中：

$$\mathbf{h}_i^t = \mathbf{W}_{\varphi_i} \cdot \tilde{\mathbf{x}}_i + \mathbf{b}_{\varphi_i} \quad (9)$$

其中  $\mathbf{W}_{\varphi_i}$  为对应于节点  $i$  类型的变换矩阵， $\tilde{\mathbf{x}}_i$  为节点  $i$  属性补全后的特征向量， $\mathbf{b}_{\varphi_i}$  为偏置向量， $\mathbf{h}_i^t$  为维度统一后的节点特征向量。

上述投影操作为异质邻域聚合提供了统一的表示空间。然而，若在统一空间内直接对异质邻域进行混合聚合，容易弱化节点间的类型差异，从而引发语义混叠问题<sup>[20]</sup>。为此，本文设计了一种基于槽结构的网络模式视图聚合策略：将投影后不同类型节点的属性分配至不同槽位中，以显式保留节点类型信息并提升聚合过程中的语义一致性。具体地，为每个节点创建  $|\mathcal{A}|$  个特定类型的槽位，对于节点类型为  $\varphi(i)$  的节点  $i$ ，其槽位分配规则如下：

$$\mathbf{h}_i^t = \begin{cases} \mathbf{h}_i^t & \text{if } t = \varphi(i) \\ \mathbf{0} & \text{if } t \neq \varphi(i) \end{cases} \quad (10)$$

其中，若第  $t$  个槽位的类型不属于  $\varphi(i)$ ，则以零向

量填充该槽位，否则以投影后的表示  $\mathbf{h}_i^t$  填充。在此基础上，考虑到不同邻居节点对目标节点的贡献存在差异，本文进一步引入注意力机制自适应学习邻居重要性权重  $\alpha_{ij}$ ，其计算公式如下：

$$\alpha_{ij} = \frac{\exp(\text{Leaky Re lu}(\mathbf{a}^T \cdot [\mathbf{h}_i^s \| \mathbf{h}_j^s]))}{\sum_{k \in N_i} \exp(\text{Leaky Re lu}(\mathbf{a}^T \cdot [\mathbf{h}_i^s \| \mathbf{h}_k^s]))} \quad (11)$$

其中  $\mathbf{h}_i^s$  表示槽位分配完毕后节点  $i$  的属性向量， $\mathbf{a}^T$  为可学习的权重向量， $N_i$  表示节点  $i$  的异质邻域集合。随后，基于重要性权重  $\alpha_{ij}$  进行加权聚合：

$$\hat{\mathbf{h}}_i = \sigma\left(\sum_{j \in N_i} \alpha_{ij} \cdot \mathbf{h}_j^s\right) \quad (12)$$

其中  $\hat{\mathbf{h}}_i$  为节点  $i$  聚合局部异质邻域信息得到的节点嵌入， $\sigma(\cdot)$  为激活函数。值得注意的是，槽结构使不同类型节点在聚合过程中自动映射至不同槽位，从而在统一维度空间内显式区分类型语义，有助于缓解特征传播过程中的语义混叠。其示意图如图4所示。




图4 基于槽结构的邻域聚合示意图

进一步地，不同槽位对目标节点表征的贡献亦存在差异。因此为获得网络模式视图下节点  $i$  的最终嵌入表示，本文引入槽注意力机制对不同槽位的聚合结果进行自适应加权融合，其计算过程如下：

$$w_t = \frac{1}{|V|} \sum_{i \in V} \mathbf{a}_{Lo}^T \cdot \tanh(\mathbf{W}_{Lo} \cdot \hat{\mathbf{h}}_i^t + \mathbf{b}_{Lo}) \quad (13)$$

$$\beta_t = \frac{\exp(w_t)}{\sum_{n=0}^N \exp(w_n)} \quad (14)$$

$$\mathbf{z}_i^{Lo} = \sum_{n=0}^N \beta_n \cdot \hat{\mathbf{h}}_i^t \quad (15)$$

其中  $\hat{h}_i^t$  表示节点  $i$  在第  $t$  个槽位下的类型嵌入,  $W_{Lo}$  为可学习的权重矩阵,  $b_{Lo}$  与  $a_{Lo}$  为可学习权重向量,  $T$  为向量转置,  $N$  为  $|A|$  的值,  $\beta_t$  为第  $t$  个槽位的重要性权重。最终, 得到节点  $i$  在网络模式视图下的低阶嵌入表示  $z_i^{Lo}$ 。

### 3.3 元路径高阶视图

元路径高阶视图旨在利用元路径所刻画的不同语义可达性, 从多种高阶语义关系中提取目标节点的语义增强表示, 并作为后续层次对比学习的高阶视图输入。给定元路径集合  $P = \{P_1, P_2, \dots, P_m\}$ , 其中  $m$  为元路径数量。对于任意一条元路径  $P_u$ , 本文在其定义的可达邻域上执行归一化图卷积聚合, 以编码由该元路径引入的高阶语义依赖。相较于仅依赖局部类型交互的网络模式视图, 元路径高阶视图更侧重于建模跨类型的高阶语义关联, 采用归一化聚合可在保证表达能力的同时提升传播过程的稳定性与计算效率。其计算公式如下:

$$h_i^{P_u} = \frac{W_{P_u} \cdot \bar{x}_i}{d_i^{P_u} + 1} + \sum_{j \in N_i^{P_u}} \frac{W_{P_u} \cdot \bar{x}_j}{\sqrt{(d_i^{P_u} + 1)(d_j^{P_u} + 1)}} \quad (16)$$

其中  $\bar{x}_i$  与  $\bar{x}_j$  分别表示节点  $i$  与  $j$  属性补全后的属性向量,  $W_{P_u}$  为对应于元路径  $P_u$  的可学习权重矩阵,  $N_i^{P_u}$  为节点  $i$  在元路径  $P_u$  下的邻居节点集合,  $d_i^{P_u}$  为集合  $N_i^{P_u}$  的基数 ( $d_i^{P_u} = |N_i^{P_u}|$ ),  $h_i^{P_u}$  为节点  $i$  在元路径  $P_u$  下学习到的嵌入表示。

不同元路径往往强调不同类型的语义关联, 其所提供的高阶信息具有互补性。为获得节点  $i$  在元路径高阶视图下的最终表示, 本文借助语义注意力机制对各元路径表示进行自适应加权融合, 其计算过程如下:

$$w_{P_u} = \frac{1}{|V|} \sum_{i \in V} a_{Ho}^T \cdot \tanh(W_{Ho} \cdot h_i^{P_u} + b_{Ho}) \quad (17)$$

$$\beta_{P_u} = \frac{\exp(w_{P_u})}{\sum_{i=1}^m \exp(w_{P_i})} \quad (18)$$

$$z_i^{Ho} = \sum_{u=1}^m \beta_{P_u} \cdot h_i^{P_u} \quad (19)$$

其中  $W_{Ho}$  为可学习的参数矩阵,  $b_{Ho}$  与  $a_{Ho}$  为可学习权重向量,  $T$  为向量转置,  $\beta_{P_u}$  为元路径  $P_u$  的重要性权重, 最终获得节点  $i$  的高阶视图嵌入表示  $z_i^{Ho}$ 。

### 3.4 层次对比学习

基于前述两类视图, 本文从两种互补视角学习到了节点嵌入表示  $z_i^{Lo}$  及  $z_i^{Ho}$ 。然而, 仅依赖上述表征学习过程可能引入视图内与视图间的不一致: 一方面, 不同元路径的语义侧重点不同, 且元路径实例中的噪声传播与路径偏置会导致同一节点在不同元路径视图下的高阶表示出现分散, 产生语义分裂; 另一方面,  $z_i^{Lo}$  更强调局部邻域结构与类型交互信息, 而  $z_i^{Ho}$  更依赖高阶语义关系, 二者在感受野与信息聚合粒度上存在天然差异, 若缺乏有效对齐, 易产生跨视图语义偏移, 进而削弱嵌入表示的一致性与判别性。

为此, 本文引入层次对比学习对两类不一致进行联合约束: 首先进行元路径视图内对比, 拉近同一节点在不同元路径下的表示, 以在多元路径语义间建立一致性约束并保持语义连贯; 其次进行高低阶视图间对比, 通过跨视图对齐促使局部结构信息与高阶语义信息相互校准, 并结合细粒度正样本采样策略, 降低跨视图偏移并提升表征的判别性与稳定性。

#### 3.4.1 元路径视图内对比

在元路径视图内对比部分, 为简化训练过程, 本文对所有目标类型节点统一施加一致性约束, 而不引入额外的节点筛选策略, 从而避免由采样策略或阈值设定引入的超参数敏感性。其对比损失  $\mathcal{L}_{Intra}$  计算公式如下:

$$\mathcal{L}_{Intra} = \frac{1}{|V_{tar}|} \sum_{i \in V_{tar}} \left( 1 - \frac{h_i^{P_m} \cdot h_i^{P_n}}{\|h_i^{P_m}\| \cdot \|h_i^{P_n}\|} \right)^\eta \quad \eta \geq 1 \quad (20)$$

其中  $V_{tar}$  表示目标类型节点集合,  $h_i^{P_m}$  与  $h_i^{P_n}$  分别



表示节点  $i$  在元路径  $P_m$  与  $P_n$  下的嵌入表示,  $*$  为向量点积,  $\eta$  为幂指数, 用于控制相似度惩罚强度。

### 3.4.2 高低阶视图间对比

元路径视图内对比主要约束同一节点在不同元路径视图下的表示一致性, 因此可在目标节点集合上直接计算一致性损失而无需显式构造正负样本。相比之下, 高低阶视图间对比的目标是对齐局部结构视角与高阶语义视角的表示, 并进一步增强跨视图表示的判别性, 即模型不仅应拉近跨视图语义一致的节点对, 还需显式区分与之无关的节点对。为此, 本文引入一种融合语义-属性双感知的正样本采样策略, 其示意图如图 5 所示。

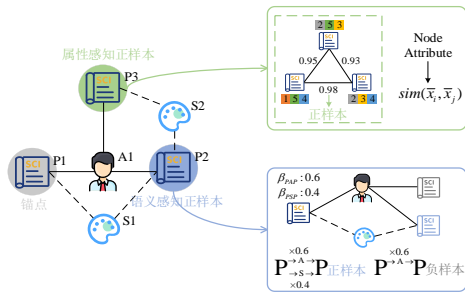


图 5 语义-属性双感知的正样本采样策略示意图

具体而言, 首先进行语义感知的正样本采样。鉴于元路径蕴含丰富的语义信息, 本文基于元路径进行语义感知正样本采样。不同于以往论文中仅依据节点间是否存在元路径实例而进行的二值采样<sup>[13-14]</sup>, 本文进一步利用节点对间元路径实例数量执行更细致化的采样, 并融入元路径重要性权重, 使采样结果更具区分性与动态性。节点对  $(i, j)$  间的语义相关性得分  $C(i, j)$  定义如下:

$$C(i, j) = \sum_{u=1}^m \beta_{P_u} \cdot Inst(j \in N_i^{P_u}) \quad (21)$$

其中  $\beta_{P_u}$  表示在元路径高阶视图中学到的元路径重要性权重,  $N_i^{P_u}$  表示节点  $i$  在元路径  $P_u$  下的邻居集合,  $Inst(j \in N_i^{P_u})$  表示节点对  $(i, j)$  在元路径

$P_u$  下元路径实例的数量, 用于刻画其语义关联强度。最后, 选择得分最高的前  $k$  个节点作为节点  $i$  的语义感知正样本集, 记作  $\mathbb{P}_i^s$ 。

随后进行属性感知的正样本采样。许多现有的采样策略<sup>[11-12]</sup>主要依赖于图结构, 而忽略了嵌入在节点属性中的丰富语义信息。为充分利用补全后的节点属性, 本文以余弦相似度  $S_{ij}$  来衡量节点之间的属性相似性:

$$S_{ij} = \frac{\bar{\mathbf{h}}_i * \bar{\mathbf{h}}_j}{\|\bar{\mathbf{h}}_i\| \cdot \|\bar{\mathbf{h}}_j\|} \quad (22)$$

其中  $\bar{\mathbf{h}}_i$  与  $\bar{\mathbf{h}}_j$  表示节点  $i$  与节点  $j$  补全属性后的节点特征向量,  $*$  表示向量点积,  $\|\cdot\|$  为向量模长。类似地, 选取与节点  $i$  相似度最高的前  $k$  个节点作为其属性感知正样本集, 记作  $\mathbb{P}_i^a$ 。最终将两类正样本集合进行融合以获得节点  $i$  最终的正样本集:

$$\mathbb{P}_i = \mathbb{P}_i^s \cup \mathbb{P}_i^a \quad (23)$$

对于所有未包含在  $\mathbb{P}_i$  中的节点, 将其作为节点  $i$  的负样本集, 记作  $\mathbb{N}_i$ 。通过此策略获得的正样本集可以整合拓扑语义结构及补全后的节点属性信息, 从而提升对比对构造质量。

在获得正负样本集合后, 进行高低阶视图间对比学习, 其损失函数  $\mathcal{L}_{Inter}$  如下:

$$\mathcal{L}_{Inter}^1 = -\log \frac{\sum_{j \in \mathbb{P}_i} \exp(\text{sim}(z_i^{Lo}, z_j^{Ho})/\tau)}{\sum_{k \in \{\mathbb{P}_i \cup \mathbb{N}_i\}} \exp(\text{sim}(z_i^{Lo}, z_k^{Ho})/\tau)} \quad (24)$$

其中  $\text{sim}(i, j)$  为余弦相似度,  $\tau$  为温度系数。高低阶视图间对比利用两种视图的相互对比来实现协同过程, 其中元路径高阶视图相对于网络模式视图的对比损失为  $\mathcal{L}_{Inter}^2$ , 因此总体对比损失为:

$$\mathcal{L}_{Inter} = \frac{1}{|V_{tar}|} \sum_{i \in V_{tar}} [\lambda \cdot \mathcal{L}_{Inter}^1 + (1 - \lambda) \cdot \mathcal{L}_{Inter}^2] \quad (25)$$

其中  $\lambda$  为控制每个视图对权重的平衡系数。

此外, 为增强两类视图的互补性并抑制信息泄露, 本文在生成高低阶嵌入时引入视图掩码机制: 在网络模式视图中, 来自节点自身的消息被屏蔽; 而在元路径高阶视图中, 消息仅沿元路径

诱导的高阶同类邻居节点传递，而元路径中间类型节点仅用于定义语义通路，不作为聚合对象。该机制可避免两类视图因共享冗余信息而产生表征退化，降低表示塌缩风险。同时，通过互补式建模，跨视图对齐过程得以在局部结构与高阶语义之间实现更有效的相互校准。

至此，综合属性重建约束与层次对比约束，本文模型的总体损失  $\mathcal{L}$  如下：

$$\mathcal{L} = \lambda_{Rec} \cdot \mathcal{L}_{Rec} + \lambda_{Intra} \cdot \mathcal{L}_{Intra} + \lambda_{Inter} \cdot \mathcal{L}_{Inter} \quad (26)$$

其中  $\lambda_{Rec}$ 、 $\lambda_{Intra}$  与  $\lambda_{Inter}$  分别表示平衡属性重建损失、元路径视图内对比损失与高低阶视图间对比损失贡献的超参数。通过反向传播对上述目标进行联合优化，模型能够学习到更具一致性与判别性的节点嵌入表示，从而为下游任务提供有效支撑。

### 3.5 复杂度分析

设异质图中节点总数为  $n$ ，目标节点数量为  $t$ ，边数量为  $e$ ，关系数量为  $r$ ，节点类型数量为  $s$ ，元路径数量为  $m$ ，元路径下邻居数量平均为  $a$ ，编码器层数为  $L$ ，正样本采样数为  $k$ ，节点投影前后特征维度分别为  $d$  与  $d'$ ，模型复杂度分析过程如下：

本模型的时间复杂度主要分为4部分：(1)属性补全模块，语义对齐为  $O(ndd')$ ， $L$ 层改进RGCN聚合为  $O(L(ed'+nd'^2))$ ，总计  $O(ndd'+L(ed'+nd'^2))$ ；(2)网络模式视图模块，投影为  $O(ndd')$ ，槽分配与注意力聚合为  $O(ed')$ ，槽注意力聚合为  $O(nsd'^2)$ ，总计  $O(ndd'+ed'+nsd'^2)$ ；(3)元路径高阶视图模块，卷积聚合为  $O(amtd'^2)$ ，语义融合为  $O(mtd'^2)$ ，总计为  $O(amtd'^2+mtd'^2)$ ；(4)层次对比学习模块，视图内对比为  $O(amtd')$ ，语义感知采样为  $O(amkt)$ ，属性感知采样为  $O(t \log tkd)$ ，跨视图对比为  $O(t^2d')$ ，总计为  $O(amtd'+amkt+t \log tkd+t^2d')$ 。由于  $s, m, a, L, k$  相对  $t^2$  可视作常数，因此HGNN-AH整体时间复杂度

由主导项近似为  $O(t^2d')$ 。本模型的空间复杂度分析如下：图结构存储占  $O(n+e)$ ，节点原始特征存储占  $O(nd)$ ；属性补全模块中语义对齐权重矩阵占  $O(ndd')$ ，编码器权重与中间表示共占  $O(L(rd'^2+nd'))$ ；网络模式视图模块中投影权重与槽注意力参数共占  $O(ndd'+sd'^2)$ ，特征矩阵为  $O(nd')$ ；元路径高阶视图中，可达邻域邻接矩阵与嵌入矩阵共占  $O(me+mt d')$ ；层次对比模块正负样本索引存储需  $O(kt)$ 。由于  $r, L, s, m$  相对  $n$  可视作常数，因此HGNN-AH整体空间复杂度由主导项近似为  $O(ndd')$ 。

## 4 实验结果与分析

### 4.1 数据集

为验证本文所提HGNN-AH的有效性，选取三个常用异质图基准数据集开展实验，包括互联网电影资料库(internet movie database, IMDB)、ACM和数字参考书目和图书馆项目(digital bibliography and library project, DBLP)。在上述数据集中，本文分别进行节点分类与聚类任务评估。数据集的统计信息汇总见表1：

表1 数据集描述

数据集	节点类型	边类型	元路径	类别数
IMDB	Movie(M):4278	M-D:4278	M-D-M	3
	Director(D):2081	M-A:12828	M-A-M	
	Actor(A):5257			
ACM	Paper(P):4019	P-P:9615	P-A-P	3
	Author(A):7167	P-A:13407	P-S-P	
	Subject(S):60	P-S:4019		
DBLP	Author(A):4057	A-P:19645	A-P-A	4
	Paper(P):14328	P-T:85810	A-P-T-P-A	
	Term(T):7723	P-V:14328	A-P-V-P-A	
	Venue(V):20			

### 4.2 基准模型

为全面评估HGNN-AH在节点分类与聚类任务中的性能，本文选取8种具有代表性的图神经



网络模型作为对比基线，覆盖同质图半监督学习、异质图半监督学习、属性缺失处理及自监督对比学习等不同范式。具体而言，GCN<sup>[19]</sup>与GAT<sup>[21]</sup>作为经典同质图半监督模型，分别通过卷积聚合与注意力加权实现邻域信息融合，用于检验HGNN-AH在多类型节点与复杂关系场景下的建模优势；HAN<sup>[22]</sup>代表元路径驱动的半监督异质图模型，侧重多元路径语义聚合与融合，用于对比HGNN-AH在网络模式视角下对局部异质交互刻画的有效性；HGNN-AC<sup>[7]</sup>面向属性缺失引入属性补全机制，并以MAGNN<sup>[23]</sup>模型进行异质图表征学习，用于评估HGNN-AH基于编码器-解码器的属性补全与端到端联合优化带来的优势；此外，MEOW<sup>[24]</sup>、HeMuc<sup>[25]</sup>、AHGCL<sup>[26]</sup>与HGNN-DB<sup>[27]</sup>均为自监督异质图对比学习模型，分别从元路径双视图构造、互补视图对齐与采样、图增强以及深广邻域双视图等角度学习无标签表示，用于验证HGNN-AH的层次对比及语义-属性双感知正样本采样策略在提升节点表示鲁棒性方面的优势。

### 4.3 实验设置

模型的训练均在AMD Ryzen 5 7500F CPU，RTX 4060Ti GPU，32GB内存的硬件环境中进行，代码部分采用Python与PyTorch框架实现。实验中使用随机搜索模型进行100次实验获得最优参数，配置如下：学习率设置为0.005，丢失率设置为0.5。关于编码器层数 $L$ 、正样本采样个数 $k$ 及嵌入维度，IMDB分别为2、130和64；ACM分别为3、13和128；DBLP分别为3、350和128。模型训练采用Adam优化器，最多训练1000个批次，并使用早停策略缓解过拟合。所有基准模型的超参数均按原论文推荐设置。

### 4.4 节点分类

节点分类用于评估节点嵌入的表示能力。本文在IMDB、ACM和DBLP数据集上开展分类实验，采用Macro-F1与Micro-F1作为评价指标。

HGNN-AH在预训练阶段仅利用图结构与节点属性进行自监督表示学习，不使用任何类别信息，预训练后固定节点嵌入，并训练SVM分类器进行下游评估。为保证可比性，所有方法采用相同的数据划分，SVM训练节点占比设为20%、40%、60%与80%，其余用于测试。实验重复10次取平均以提升结果可靠性。分类结果如表2所示，最佳结果以粗体标注，次优结果以下划线标识。

由分类结果可知，HGNN-AH在3个不同异质图场景中均表现出色。与基准模型中最优结果相比，其Macro-F1和Micro-F1指标在IMDB数据集上分别提高了1.99%和2.01%；在ACM数据集上分别提高了0.61%和0.69%；在DBLP数据集上分别提高了0.35%和0.32%。

实验结果表明，GCN与GAT在异质图上的性能受限，主要由于其同质化聚合难以区分不同类型节点与关系所对应的结构模式与语义差异。相比之下，HAN与HGNN-AC通过异质语义建模获得提升：HAN依赖元路径的分层注意力聚合高阶邻域信息，但对网络模式刻画的关键局部异质交互覆盖不足；HGNN-AC在MAGNN上引入属性补全框架，但其主要利用直连邻域重建缺失属性，对高阶信息利用有限且对预训练模型质量较为敏感。进一步地，上述半监督模型普遍依赖标签监督，而真实异质图中标签往往稀缺，限制了其适用性。自监督异质图对比学习通过多视图构造与对比目标在无标签条件下学习节点表征，但现有方法仍存在不足：MEOW以元路径双视图进行跨视图对齐，但难以同时兼顾低阶结构与高阶语义；HeMuc正样本采样依赖静态规则，在语义稀疏或噪声场景下鲁棒性受限；AHGCL的增强视图高度依赖属性相似性估计，易受特征噪声影响；HGNN-DB强化跨尺度对齐但未显式缓解属性缺失引起的表征偏差。相比之下，HGNN-AH在显式属性补全的基础上联合建模网络模式低阶

表2 在IMDB、ACM和DBLP数据集上的节点分类结果(%)

数据集	指标	训练集比例	GCN	GAT	HAN	HGNN-AC	MEOW	HeMuc	AHGCL	HGNN-DB	HGNN-AH
IMDB	Macro-F1	20%	46.45	48.36	57.96	59.72	55.62	57.19	60.48	<u>61.01</u>	<b>63.15</b>
		40%	47.89	50.48	59.24	60.91	55.93	57.58	60.71	<u>61.42</u>	<b>63.42</b>
		60%	49.12	51.65	59.88	61.46	56.18	57.57	61.11	<u>61.71</u>	<b>63.61</b>
		80%	51.73	53.02	60.01	61.67	56.51	58.12	61.49	<u>61.95</u>	<b>63.87</b>
	Micro-F1	20%	49.48	52.05	58.03	59.91	55.76	57.21	60.64	<u>61.23</u>	<b>63.31</b>
		40%	51.56	53.42	59.36	61.23	56.01	57.64	60.97	<u>61.42</u>	<b>63.58</b>
		60%	52.12	53.94	59.91	61.68	56.22	57.88	61.38	<u>61.96</u>	<b>63.92</b>
		80%	53.49	54.13	60.12	61.89	56.39	58.02	61.87	<u>62.31</u>	<b>64.16</b>
ACM	Macro-F1	20%	86.62	86.01	89.66	91.64	90.56	91.32	92.12	<u>92.88</u>	<b>93.49</b>
		40%	87.39	86.89	89.82	91.73	90.71	91.51	92.31	<u>92.94</u>	<b>93.56</b>
		60%	87.89	87.31	91.01	92.79	91.32	91.63	92.45	<u>93.19</u>	<b>93.78</b>
		80%	88.06	87.13	91.13	92.92	91.46	91.85	92.68	<u>93.31</u>	<b>93.93</b>
	Micro-F1	20%	86.54	85.83	89.49	91.38	90.48	91.26	92.06	<u>92.67</u>	<b>93.36</b>
		40%	87.49	86.64	89.81	91.64	90.61	91.50	92.31	<u>92.82</u>	<b>93.48</b>
		60%	87.92	87.12	91.02	92.76	91.23	91.64	92.47	<u>93.09</u>	<b>93.75</b>
		80%	88.13	87.01	91.26	92.88	91.42	91.77	92.60	<u>93.15</u>	<b>93.87</b>
DBLP	Macro-F1	20%	88.66	88.97	92.46	92.74	92.52	91.69	92.61	<u>92.92</u>	<b>93.29</b>
		40%	89.25	89.24	92.91	93.18	93.01	92.21	93.14	<u>93.39</u>	<b>93.72</b>
		60%	89.83	88.95	93.25	93.56	93.36	92.54	93.47	<u>93.67</u>	<b>94.08</b>
		80%	90.35	89.76	93.72	93.98	93.68	93.02	93.81	<u>94.16</u>	<b>94.47</b>
	Micro-F1	20%	89.72	89.96	93.06	93.33	93.15	92.31	93.32	<u>93.55</u>	<b>93.91</b>
		40%	90.25	90.15	93.51	93.77	93.64	92.73	93.77	<u>93.96</u>	<b>94.29</b>
		60%	90.58	89.81	93.82	94.02	93.85	92.98	94.01	<u>94.28</u>	<b>94.56</b>
		80%	91.01	90.55	94.21	94.43	94.26	93.37	94.38	<u>94.61</u>	<b>94.92</b>

视图与元路径高阶视图，并通过层次化对比约束实现跨视图对齐与互补融合，从而显著提升节点分类性能。

#### 4.5 节点聚类

节点聚类实验采用K-means与高斯混合模型(gaussian mixture model, GMM)两种算法，并以NMI和ARI评估聚类质量，用以检验HGNN-AH的嵌入效果。为保证公平对比，两种算法的簇数均设为数据集真实类别数。其中K-means为硬划分，而GMM为软划分并可刻画更一般的簇形态。为减小随机初始化影响，实验重复10次取平均值。聚类结果如表3所示，最优结果以粗体标注，次优结果以下划线标识。

由表3可知，在K-means与GMM两种设置

下，HGNN-AH在3个异质图数据集集中的节点聚类任务中均取得最优结果。相较次优方法，K-means下HGNN-AH的NMI与ARI在IMDB、ACM及DBLP数据集上分别提升1.6%与1.8%、1.5%与1.7%、1.2%与0.7%；GMM下分别提升2.0%与2.1%、2.1%与1.9%、1.8%与1.4%。这表明HGNN-AH学到的嵌入具有更强的相似性刻画与类别区分能力，并对不同聚类算法具有良好适应性。总体来看，GCN与GAT的同构化聚合易混合异质语义，导致类间边界不清；HAN与HGNN-AC虽增强语义建模，但前者对网络模式下的局部异质交互覆盖不足，后者属性补全偏向直连信息且受预训练质量影响，均限制了聚类可分性提升；自监督对比基线MEOW、HeMuc、



表3 节点聚类结果(%)

聚类算法	数据集	指标	GCN	GAT	HAN	HGNN-AC	MEOW	HeMuc	AHGCL	HGNN-DB	HGNN-AH
K-means	IMDB	NMI	7.9	8.2	11.6	11.8	8.6	9.7	11.2	<u>12.1</u>	<b>13.7</b>
		ARI	8.3	8.7	12.2	12.5	9.2	10.5	11.9	<u>12.7</u>	<b>14.5</b>
	ACM	NMI	59.4	60.1	64.1	66.8	64.7	<u>68.1</u>	66.5	67.4	<b>69.6</b>
		ARI	62.6	63.7	67.5	68.3	67.9	<u>71.0</u>	69.4	70.3	<b>72.7</b>
	DBLP	NMI	68.4	70.7	79.7	80.4	76.5	77.9	79.7	<u>80.7</u>	<b>81.9</b>
		ARI	74.2	76.1	84.7	85.6	82.2	83.3	84.6	<u>85.9</u>	<b>86.6</b>
GMM	IMDB	NMI	9.3	9.1	12.2	12.7	10.4	11.1	12.3	<u>12.8</u>	<b>14.8</b>
		ARI	9.8	9.5	12.7	13.3	10.8	11.6	12.9	<u>13.6</u>	<b>15.7</b>
	ACM	NMI	61.6	61.4	65.4	67.9	66.4	69.2	67.9	<u>69.4</u>	<b>71.5</b>
		ARI	63.8	64.7	68.9	69.5	69.3	72.3	70.9	<u>72.5</u>	<b>74.4</b>
	DBLP	NMI	71.5	72.4	81.3	82.2	77.8	79.4	81.4	<u>82.5</u>	<b>84.3</b>
		ARI	77.1	77.9	86.2	86.9	83.6	85.1	86.4	<u>87.3</u>	<b>88.7</b>

AHGCL 及 HGNN-DB 在无标签条件下表现较好，但对视图构造、采样或增强策略较敏感，在语义稀疏或噪声场景下易引入不稳定样本或连接。相比之下，HGNN-AH 在显式属性补全基础上联合建模网络模式低阶结构与元路径高阶语义，并通过层次化对比约束实现跨视角对齐与互补融合，从而学习到更利于聚类划分的判别性表示。

#### 4.6 消融实验

为进一步验证 HGNN-AH 各模块设计的有效性，本小节开展消融实验并构造 6 种变体模型进行对比：HGNN-AH\_ac 表示去除属性补全模块；HGNN-AH\_slot 表示在网络模式视图以 GAT 替代槽结构进行低阶邻域聚合；HGNN-AH\_intra 表示去除元路径视图内对比；HGNN-AH\_inter 表示去除高低阶视图间对比；HGNN-AH\_fea 表示去

除属性感知的正样本采样；HGNN-AH\_sem 表示去除语义感知的正样本采样。各变体的实验结果如图 6 所示，其中 Macro-F1 与 Micro-F1 为训练节点占比 20%、40%、60% 和 80% 四种设置下测试结果的平均值。

由消融实验结果可知：(1)HGNN-AH\_ac 的性能明显低于 HGNN-AH，且在特征分布较为稀疏的 IMDB 数据集上下降更为明显，表明显式属性补全能够为后续邻域聚合及对比学习提供更充分、可靠的特征输入；(2)HGNN-AH\_slot 的性能低于 HGNN-AH，表明槽结构引导的类型感知聚合有助于在局部异质邻域聚合中抑制语义混叠、强化关系区分，从而带来一定程度的性能提升；(3)HGNN-AH\_intra 的表现较 HGNN-AH 也有不小幅度的下降，表明元路径视图内的一致性约束有




图6 消融实验结果

助于拉近同一节点跨元路径视图的表示，抑制语义分裂并增强高阶语义表示的稳定性；(4) HGNN-AH\_inter的性能下降最明显，表明跨高低阶视图间的层次化对齐是提升性能的关键因素，可有效促进低阶结构信息与高阶语义依赖的互补融合；(5)HGNN-AH\_fea与HGNN-AH\_sem的性能均低于HGNN-AH，且移除语义感知的正样本采样的影响普遍大于移除属性感知的正样本采样，说明基于语义感知的动态正样本筛选对对比目标更为敏感，两者结合可进一步提升训练的稳定性与表示的判别性。

#### 4.7 属性补全有效性分析

为评估本文所提属性补全策略在异质图表征学习中的有效性与泛化能力，本小节设计对比实验并选取三类代表性补全机制作为基线：(1)邻域均值补全(neighbor mean completion, NMC)：对无属性节点以其直连有属性邻居的属性均值进行补全(SHGNN<sup>[28]</sup>)；(2)预训练拓扑先验引导补全(pretrained topology guided completion, PTGC)：利用预训练模型得到的拓扑嵌入作为先验完成补全(HGNN-AC)；(3)端到端嵌入引导邻域补全(end-to-end embedding guided neighbor completion, EGNC)：在模型内部生成拓扑表示并据此引导补全，而不依赖预训练先验(HetReGAT-FC<sup>[29]</sup>)。本文补全策略记为编码器-解码器重建式补全(encoder-decoder reconstruction completion, EDRC)。为系统分析不同补全机制对模型性能的影响，将上述策略分别集成至RGCN与MAGNN中进行节点分类评估，其中无补全的原始模型对

无属性节点统一采用one-hot作为初始特征(记为NONE)。分类结果见表4，其中Macro-F1与Micro-F1为训练比例20%、40%、60%与80%下测试结果的平均值，实验重复10次取均值。表中最优结果加粗，次优结果以下划线标识。

由表4可知：(1)相较原始RGCN与MAGNN，引入属性补全后整体分类性能均有提升，说明属性补全能够有效增强异质图表征学习效果。(2)在两类骨干模型中，EDRC均优于NMC与PTGC，表明两者存在局限：NMC仅对直连邻域属性取均值，未区分异质关系语义与节点类型差异且难以利用高阶信息；PTGC将拓扑嵌入学习与补全过程解耦，且补全阶段仍以直连邻域为主，对高阶语义注入不足。(3)相较同为端到端补全的EGNC，EDRC仍取得更优结果，说明编码器-解码器式补全更有效：编码器在异质聚合中引入跨关系高阶上下文以学习潜在属性表征，解码器通过属性重建及重建损失约束表征与属性空间一致性，从而生成更高质量的补全属性并带来显著性能增益。

#### 4.8 效率分析

本小节进行模型训练效率对比分析。为保证结果可比性，所有模型均在统一硬件平台及训练配置下运行。图7给出了ACM数据集中各模型单个epoch的平均耗时及Macro-F1均值，模型下方数字表示相对最短耗时模型的时间倍率(如4.6X)。结果显示，半监督模型HAN训练耗时最短，主要因其结构轻量且无需额外对比学习计算，但其训练依赖标签信息且分类性能较弱。在自监督对

表4 不同属性补全策略集成至HGNN模型后的节点分类结果(%)

数据集	评价指标	RGCN					MAGNN				
		NONE	NMC	PTGC	EGNC	<b>EDRC</b>	NONE	NMC	PTGC	EGNC	<b>EDRC</b>
ACM	Macro-F1	86.71	87.41	88.96	<u>89.24</u>	<b>90.26</b>	89.67	90.41	92.03	<u>92.56</u>	<b>93.18</b>
	Micro-F1	86.65	87.35	88.87	<u>89.18</u>	<b>90.18</b>	89.61	90.33	91.94	<u>92.48</u>	<b>93.12</b>
IMDB	Macro-F1	55.18	56.41	56.88	<u>57.59</u>	<b>58.71</b>	59.13	60.35	61.21	<u>61.73</u>	<b>62.56</b>
	Micro-F1	55.41	56.63	57.11	<u>57.84</u>	<b>58.95</b>	59.36	60.59	61.43	<u>61.96</u>	<b>62.81</b>



比模型方法中，HGNN-AH训练时间最短且取得最优性能，主要得益于属性补全采用简洁的RGCN，高低阶聚合基于单层GAT与GCN，且对比学习在低维嵌入空间中进行从而进一步降低开销。相比之下，HGNN-AC训练耗时最高，主要由于其依赖的MAGNN需对大量元路径中间节点进行独立聚合。

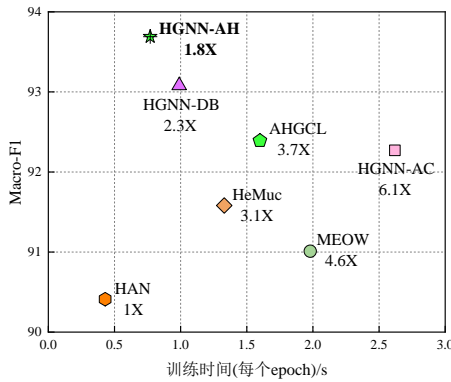


图7 训练时间与评分对比

在图7所示的单轮训练耗时对比的基础上，本文进一步统计了各模型在IMDB、ACM及DBLP数据集中的峰值显存占用与端到端训练总耗时，结果如表5所示。表中最佳结果以黑体标出，次优结果以下划线标识。由表5可知，半监督模型HAN在三个数据集上显存占用与训练总耗时最低，主要因其结构轻量且不涉及额外对比计算，但其分类性能相对较弱。在自监督对比学习模型中，HGNN-AH在三个数据集上均保持较低的显存与总耗时，训练总耗时分别为315s、

225s与246s，显著低于MEOw、HeMuc、AHGCL等模型，并较HGNN-DB进一步降低约8%~9%。这主要得益于其属性补全采用结构简洁的RGCN，高低阶邻域聚合使用单层策略以避免多层堆叠开销，且层次对比仅在低维嵌入空间计算相似度，从而在保证嵌入表示质量的同时有效控制训练成本。

#### 4.9 参数敏感性分析

本小节进行参数敏感性研究，在ACM数据集中针对嵌入维度、属性补全模块中编码器层数 $L$ 、正样本采样数 $k$ 、属性重建损失系数 $\lambda_{Rec}$ 、层次对比损失系数 $\lambda_{Intra}$ 与 $\lambda_{Inter}$ 这5类关键参数进行分析，相应Macro-F1及Micro-F1值取测试集20%、40%、60%和80%结果的平均值。

如图8(a)-(d)所示，前四类参数对模型性能的影响总体均呈“先升后降”趋势。嵌入维度过小时表征能力不足，随维度增大模型性能提升并在128处达到最优，继续增大则因冗余表征与优化难度增加导致性能回落；编码器层数从较浅增至3层可更充分建模缺失属性与邻域结构的高阶关联以提升补全质量，但过深易引发过度平滑现象从而削弱补全效果；正样本采样个数从较小增大可增强跨视图对齐的稳定性，并在采样数为13时表现最佳，但继续增大可能引入弱相关甚至伪正样本，从而稀释对齐信号并带来噪声；属性重建损失权重由小到大能强化重建约束并在0.2处达到最优，但过大将使优化目标过度偏向属性重

表5 模型峰值显存占用与训练总耗时对比

指标	数据集	模型						
		HAN	HGNN-AC	MEOw	HeMuc	AHGCL	HGNN-DB	HGNN-AH
峰值显存占用(GB)	IMDB	<b>1.86</b>	4.15	3.25	2.52	2.66	2.24	<u>2.13</u>
	ACM	<b>1.62</b>	4.63	2.76	2.21	2.41	2.12	<u>1.97</u>
	DBLP	<b>2.36</b>	5.21	3.12	2.82	3.07	2.86	<u>2.65</u>
训练总耗时(s)	IMDB	<b>262</b>	945	625	446	421	343	<u>315</u>
	ACM	<b>160</b>	636	432	324	306	246	<u>225</u>
	DBLP	<b>213</b>	741	478	365	335	271	<u>246</u>

建, 进而削弱对于层次对比目标的关注并放大重建噪声传播, 导致性能下降。

图9反映了层次对比损失权重系数 $\lambda_{Intra}$ 与 $\lambda_{Inter}$ 对节点分类性能的影响。总体来看, 模型在较宽参数范围内性能波动较小, 但对 $\lambda_{Inter}$ 更为敏感: 当其取值偏小时性能明显下降, 说明跨高低阶视图对齐是性能提升的关键; 相比之下,  $\lambda_{Intra}$ 呈“先升后降”趋势, 在中等取值附近达到最优, 表明适度的视图内一致性约束有助于稳定高阶语义表示, 而过强约束可能削弱不同元路径的互补性并引起性能回落。

### 4.10 可视化

为更直观地展示HGNN-AH在节点嵌入中的表现, 在DBLP数据集上使用t-SNE<sup>[30]</sup>对作者节点进行可视化展示, 其中作者节点根据其标签分为4类。并与MEOW、HAN及HGNN-DB模型进行比较, 可视化结果如图10所示。

由图10(a)可知, MEOW学习到的嵌入在类内分布相对松散, 部分类簇之间存在明显交叠与

混杂, 导致类间边界不够清晰; 图10(b)中HAN借助分层注意力对异质语义进行聚合后, 类别结构较为成形, 类间分离度有所提升, 但仍可观察到部分簇边缘区域存在交叉, 表明仅依赖元路径语义聚合难以充分刻画节点的局部异质邻域交互; 进一步地, 图10(c)表明HGNN-DB通过深度-广度视图的协同学习增强了跨尺度信息融合, 类内紧致性与类间间隔继续改善, 但个别类别在边界处仍存在少量散点与邻近簇粘连现象。相比之下, 图10(d)中本文所提HGNN-AH的四个类簇分布更为紧凑、边界更清晰, 且不同类别之间保持更大的间隔, 散点与混叠现象显著减少, 体现出更强的类别区分能力。

## 5 结束语

本文提出一种融合属性补全与层次对比的异质图神经网络模型。针对现有方法难以同时应对异质图中节点属性缺失与标签信息稀缺的问题, 该模型首先在编码器-解码器框架下对缺失属性




图8 嵌入维度、编码器层数、采样数与重建损失系数敏感性分析

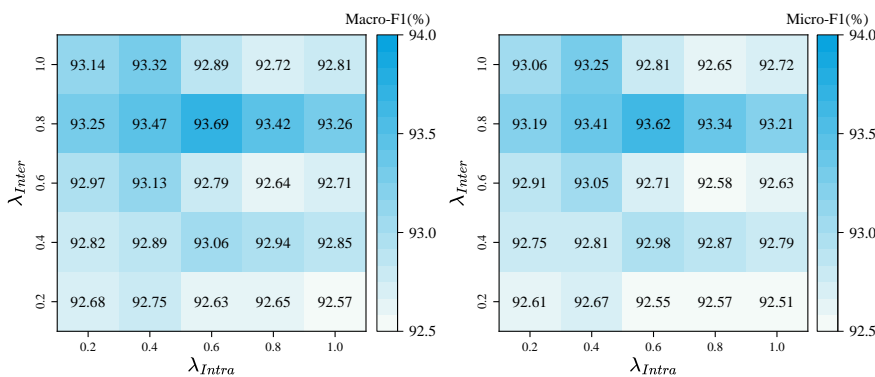


图9 层次对比损失系数敏感性分析




图10 节点分类结果可视化

进行端到端重建，以获得信息更完备的节点初始表征；其次分别在网络模式低阶结构视图与元路径高阶语义视图中编码目标节点，并引入槽结构聚合以缓解类型语义混叠；同时构建元路径视图内与高低阶视图间的层次化对比约束以增强跨视角一致性；最后结合语义-属性双感知的细粒度正样本采样策略提升对比信号质量，从而学习更具判别性的节点表征。在多个公开数据集上开展了节点分类与聚类实验，结果证明了所提方法的有效性，并进一步通过消融与可视化实验分别验证了各模块的有效性及生成的节点低维嵌入的高度判别性。此外，效率分析结果表明，HGNN-AH在训练耗时与显存占用方面具有较好的资源可控性。

未来的研究工作可从以下两个方面展开：(1) 进一步提升属性补全的可靠性，可针对类型缺失、维度缺失及属性噪声等情形，引入补全置信度建模，抑制误补全信息的累积传播；(2) 面向动态演化的异质图场景，未来可进一步研究拓扑与属性交互随时间变化的联合表示学习机制，发展能够在时序演变中持续更新属性补全与对比约束的训练范式，以提升模型在动态开放环境下的适应性与泛化能力。

## 参考文献：

[1] 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. Convolutional Network of Edge

Learning Graph Based on Multi-channel[J]. Telecommunications Science, 2022, 38(9): 95-104.

[2] WANG J C, ZHANG Y, WANG L X, et al. Multitask hypergraph convolutional networks: a heterogeneous traffic prediction framework[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 18557-18567.

[3] 刘亚, 林明洁, 曲博. 图表示学习在网络安全领域的应用研究综述[J]. 小型微型计算机系统, 2023, 44(3): 616-628.  
LIU Y, LIN M J, QU B. Survey on graph representation learning in cybersecurity domain[J]. Journal of Chinese Computer Systems, 2023, 44(3): 616-628.

[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] 安俊秀, 柳源, 杨林旺. 超越同质性假设的双通道属性图聚类[J]. 电信科学, 2025, 41(01): 111-124.  
AN J X, LIU Y, YANG L W. Dual-channel attribute graph clustering beyond the homogeneity assumption[J]. Telecommunications Science, 2025, 41(01): 111-124.

[6] 宋凌云, 刘至臻, 张炆, 等. 基于异构图中多层次图结构的级联图卷积网络[J]. 软件学报, 2024, 35(11): 5179-5195.  
SONG L Y, LIU Z Z, ZHANG Y, et al. Cascade Graph Convolution Network Based on Multi-level Graph Structures in Heterogeneous Graph[J]. Journal of Software, 2024, 35(11): 5179-5195.

[7] JIN D, HUO C, LIANG C, et al. Heterogeneous graph neural network via attribute completion[C]//Proceedings of the Web Conference 2021. Ljubljana: ACM, 2021: 391-400.

[8] YU H, ZHENG Z, XUE Y, et al. Knowledge based attribute completion for heterogeneous graph node classification[J]. Neurocomputing, 2025, 619: 129023.

[9] ZHU G, ZHU Z, WANG W, et al. Autoac: Towards automated attribute completion for heterogeneous graph neural network

- [C]//2023 IEEE 39th International Conference on Data Engineering (ICDE). Anaheim: IEEE, 2023: 2808-2821.
- [10] ZHAO Z, LIU Z, WANG Y, et al. RA-HGNN: Attribute completion of heterogeneous graph neural networks based on residual attention mechanism[J]. *Expert Systems with Applications*, 2024, 243: 122945.
- [11] WANG Z, LI Q, YU D, et al. Heterogeneous graph contrastive multi-view learning[C]//Proceedings of the 2023 SIAM International Conference on Data Mining (SDM). Minneapolis: SIAM, 2023: 136-144.
- [12] YU J, GE 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 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 & Data Mining. Virtual: ACM, 2021: 1726-1736.
- [14] LI M, MENG L, YE Z, et al. Multi-scale Heterogeneous Graph Contrastive Learning[C]//2023 IEEE International Conference on Big Data (BigData). Sorrento: IEEE, 2023: 4432-4441.
- [15] YANG X, YAN M, PAN S, et al. Simple and efficient heterogeneous graph neural network[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Washington: AAAI Press, 2023, 37(9): 10816-10824.
- [16] LI S, GONG J, KE S, et al. Graph Transformer-based Heterogeneous Graph Neural Networks enhanced by multiple meta-path adjacency matrices decomposition[J]. *Neurocomputing*, 2025, 629: 129604.
- [17] WANG K, YU Y, HUANG C, et al. Heterogeneous graph neural network for attribute completion[J]. *Knowledge-Based Systems*, 2022, 251: 109171.
- [18] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks[C]//European Semantic Web Conference. Heraklion: Springer, 2018: 593-607.
- [19] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[J]. *arXiv preprint arXiv: 1609.02907*, 2016.
- [20] ZHAO Z, GE Q, CHENG A, et al. HetCAN: A Heterogeneous Graph Cascade Attention Network with Dual-Level Awareness [C]//Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Vilnius: Springer, 2024: 57-73.
- [21] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks[J]. *arXiv preprint arXiv: 1710.10903*, 2017.
- [22] WANG X, JI H, SHI C, et al. Heterogeneous graph attention network[C]//The World Wide Web Conference. San Francisco: ACM, 2019: 2022-2032.
- [23] FU X, ZHANG J, MENG Z, et al. Magnn: Metapath aggregated graph neural network for heterogeneous graph embedding [C]//Proceedings of the Web Conference 2020. Taipei: ACM, 2020: 2331-2341.
- [24] YU J, LI X. Heterogeneous graph contrastive learning with meta-path contexts and weighted negative samples[C]//Proceedings of the 2023 SIAM International Conference on Data Mining (SDM). Minneapolis: SIAM, 2023: 37-45.
- [25] ZHANG Q, ZHAO Z, ZHOU H, et al. Self-supervised contrastive learning on heterogeneous graphs with mutual constraints of structure and feature[J]. *Information Sciences*, 2023, 640: 119026.
- [26] ZHAO Z, ZHU Z, LIU Y, et al. Heterogeneous graph contrastive learning with augmentation graph[J]. *IEEE Transactions on Artificial Intelligence*, 2024, 5(10): 5100-5109.
- [27] WANG Z, YU D, LI Q, et al. SR-HGN: Semantic-and relation-aware heterogeneous graph neural network[J]. *Expert Systems with Applications*, 2023, 224: 119982.
- [28] XU W, XIA Y, LIU W, et al. SHGNN: Structure-aware heterogeneous graph neural network[J]. *arXiv preprint arXiv: 2112.06244*, 2021.
- [29] LI C, YAN Y, FU J, et al. Hetregat-fc: Heterogeneous residual graph attention network via feature completion[J]. *Information Sciences*, 2023, 632: 424-438.
- [30] MAATEN L, HINTON G. Visualizing data using t-sne[J]. *Journal of Machine Learning Research*, 2008, 9(11): 2579-2605.