

# 基于超球面对偶学习的双通道图异常检测方法

李 青<sup>1</sup>, 钟 将<sup>2</sup>, 倪 航<sup>1</sup>

(1. 西北工业大学计算机学院, 陕西西安 710072; 2. 重庆大学计算机学院, 重庆 400044)

**摘要:** 图异常检测作为一项重要的数据挖掘任务, 专注于识别与大多数节点显著偏离的异常节点。随着无监督图神经网络技术的进步, 现已开发出了基于密度估计、对抗生成网络等多种高效识别图数据中潜在异常的方法。然而, 这些方法更注重无监督图异常检测生成高质量的表征, 而往往忽略了图异常的特性。因此, 本文提出了一个双通道异构图异常检测模型(Dual-channel Heterogeneous Graph Anomaly Detection, HD-GAD)。其模型基础架构包括双通道的图神经网络: 全局子结构感知的图神经网络和局部子结构感知的图神经网络, 用于图异常检测捕获全局和局部子结构属性。同时, 基于对偶推断引入了多超球体学习目标(Multi-Hypersphere Learning, MHL), 从宏观和介观超球体角度, 分别测量在整个图/社区结构中偏离的异常节点。HD-GAD模型利用相似度函数EmbSim优化训练目标, 以缓解多超球体学习中的模型坍缩问题。最后, 在五种不同的数据集上进行了全面的实验。其AUC(Area Under Curve)值在大多数情况下均超过了0.9, 达到了行业领先水平, 进一步证明了HD-GAD模型在图异常检测任务上的高效性与性能优势。

**关键词:** 图异常检测; 图神经网络; 超球面学习; 双通道图神经网络; 无监督学习; 对偶学习

**基金项目:** 国家自然科学基金(No. 62102316, No. 62171382); 中央高校基本科研业务费资助项目(No. G2021KY05114); “十四五”共用信息系统装备预先研究项目(No. 315197202); 航空科学基金(No. 20200051053002)

中图分类号: TP311.1

文献标识码: A

文章编号: 0372-2112(2024)07-2212-07

电子学报URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20231106

## Anomaly Detection with Dual-Channel Heterogeneous Graph Neural Network Based on Hypersphere Dual Learning

LI Qing<sup>1</sup>, ZHONG Jiang<sup>2</sup>, NI Hang<sup>1</sup>

(1. School of Computer Science, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China;

2. College of Computer Science, Chongqing University, Chongqing 400044, China)

**Abstract:** Graph anomaly detection, as a crucial data mining task, focuses on identifying anomalous nodes that significantly deviate from the majority of the nodes. With the advancement of unsupervised graph neural network techniques, various efficient methods have been developed to detect potential anomalies in graph data, including those based on density estimation and generative adversarial networks. However, these methods often focus on generating high-quality representations for unsupervised graph anomaly detection and tend to overlook the characteristics of graph anomalies. Consequently, this paper proposes a dual-channel heterogeneous graph anomaly detection model (HD-GAD). Its architecture includes two graph neural networks, i.e. a global substructure-aware GNN (Graph Neural Network) and a local substructure-aware GNN, designed to capture global and local substructural properties for graph anomaly detection. Additionally, the model introduces a multi-hypersphere learning (MHL) objective based on dual inference, which measures anomalies deviating from the overall graph/community structure from macro and meso hypersphere perspectives. The HD-GAD model utilizes the similarity function EmbSim to optimize the training objective, mitigating model collapse issues in multi-hypersphere learning. Comprehensive experiments conducted on five different datasets demonstrated that the AUC (Area Under Curve) values exceeded 0.9 in most cases, achieving industry-leading levels and further proving the HD-GAD model's efficiency and performance advantages in graph anomaly detection tasks.

**Key words:** graph anomaly detection; graph neural network; hypersphere learning; dual-channel graph neural network; unsupervised learning; dual learning

**Foundation Item(s):** National Natural Science Foundation of China (No.62102316, No.62171382); Fundamental Re-

search Funds for Central Universities (No.G2021KY05114); “14th Five-Year Plan” Shared Information System Equipment Preliminary Research Project (No.315197202); Aviation Science Foundation (No.20200051053002)

## 1 引言

自 1969 年 Grubbs 首次提出异常的概念以来<sup>[1]</sup>,异常检测一直致力于发现那些明显偏离数据中大多数其他样本的对象.传统的同构图异常检测方法通常通过非欧几里得空间中利用图的结构信息来进行异常检测<sup>[2]</sup>.然而,异构图具有多种类型的特征,无法直接在欧几里得特征空间中表示.将传统的同构图异常检测技术直接应用于异构图的异常检测是不可行的.其检测方法是往往专门针对关系数据进行设计,需要同时考虑图的属性信息和结构信息<sup>[3]</sup>.因此,异构图检测方法严重依赖于手工制作的特征工程或由领域专家构建的统计模型<sup>[4]</sup>,如矩阵分解<sup>[5]</sup>和支持向量机<sup>[6]</sup>.这类统计模型往往使用与每个节点相关的统计特征,如入/出度,来检测异常节点.

随着图数据规模和复杂性的增加,传统的检测技术已经无法直接处理具有丰富结构信息的图数据.为了弥补这一差距,基于深度学习的方法获得了广泛关注.许多现有的工作将异常检测视为一个有监督的二分类任务,并采用各种方法来实现.但因异常本身很难被明确定义,现有的异常数据标签往往存在不准确与不完整的问题.这使得有监督的异常检测在实际应用中面临着较大的挑战<sup>[7]</sup>.现有无监督异常检测方法并非专门针对图数据设计,在应用到图数据时存在一定的局限性.部分方法只考虑节点及其一阶邻居的特征,缺乏全局的图结构信息.而另一些方法则侧重于比较全图的统计特征或构建代表数据分布的超球面,这些方法忽略了节点间关键的细微差异.

总体来看,国内外图异常检测技术的研究主要包括以下五个方面:(1)密度估计方法<sup>[8,9]</sup>,可通过特定概率密度函数描述异常程度,设计特殊概率模型进行异常估计.例如,DAGMM<sup>[9]</sup>在自编码器的基础上构建评估网络来计算样本的似然概率,训练后异常样本将具有较低的似然概率.(2)基于自编码器的方法,可以通过压缩重构原始数据的结构或属性信息来检测异常.Dominant<sup>[10]</sup>和 Anomalydae<sup>[11]</sup>都利用图神经网络重新构建自编码器的编/解码器网络,实现图异常检测.(3)基于生成对抗网络的方法<sup>[12]</sup>,往往通过生成器产生虚假属性信息,使用判别器区分真实和生成的结构信息.最后,根据判别器预测的负类得分,以及生成器生成的属性偏离真实属性的程度,来判断样本是否异常.(4)基于对比学习的方法<sup>[7]</sup>,通过对比正常样本的表征与其周围子图的表征间差异来检测异常.CoLA<sup>[7]</sup>首次将对比学习用于图异常检测,通过使用图神经网络学习节点

表征.ANEMONE-FS在CoLA的基础上改进了对比学习目标.(5)超球面学习方法<sup>[13,14]</sup>,旨在通过得到一个半径最小的超球面,在表示空间中将所有训练样本的表征压缩到该超球面内部.若某测试样本的表征位于超球面外部,则被检测为异常.然而,这些方法往往由于权重调参或额外的模型复杂度导致资源浪费.同时,受限于单个超球面,难以扩展到多个超球面.

因此,本研究旨在利用双通道全局和局部子结构信息,通过一个多超球体学习目标(Multi-Hypersphere Learning, MHL)从宏观和介观角度检测异常,提出一个用于无监督图异常检测的全新模型(Dual-channel Heterogeneous Graph Anomaly Detection, HD-GAD)

## 2 HD-GAD 模型

### 2.1 双通道图学习

#### 2.1.1 全局子结构感知图神经网络

如图 1 所示,在全局层面上,利用图形度量向量构建了新图  $G'$ ,并对于每个节点  $v_i$  计算其 GDV 特征  $r_i, i = 1, 2, \dots, N$ .使用余弦相似度  $\text{Sim}(r_i, r_j)$  计算两两节点对间相似度,进一步表示每个节点对之间存在一条边的概率.为了确保稀疏性,只保留具有高相似性的节点对,并在每对节点之间构造一条边.由于 GDV 特征的相似性对子结构的大小不敏感,将  $G'$  的非加权邻接矩阵  $A'$  扩展为以下加权形式:

$$\hat{A}'_{i,j} = \begin{cases} |N'_i| + |N'_j|, & A'_{i,j} = 1 \\ 0, & A'_{i,j} = 0 \end{cases} \quad (1)$$

$$\tilde{A}'_{i,j} = \frac{\hat{A}'_{i,j}}{\sum_{j \in N'_i} \hat{A}'_{i,j}} \quad (2)$$

其中,  $\tilde{A}'$  是加权邻接矩阵,  $N'_i$  是结构  $A'$  中节点  $v_i$  的邻居集合.使用 GAT 作为主干模型时,注意层公式为

$$\alpha_{i,j} = \frac{\exp(\text{ReLU}(a^{(t)} \cdot (\mathbf{W}_G^{(t)} \hat{\mathbf{h}}_i^{(t,g)}, \mathbf{W}_G^{(t)} \hat{\mathbf{h}}_j^{(t,g)})))}{\sum_{j' \in N'_i} \exp(\text{ReLU}(a^{(t)} \cdot (\mathbf{W}_G^{(t)} \hat{\mathbf{h}}_i^{(t,g)}, \mathbf{W}_G^{(t)} \hat{\mathbf{h}}_{j'}^{(t,g)})))} \quad (3)$$

$$\mathbf{h}_i^{(t,g)} = \sum_{j \in N'_i} \alpha_{i,j} \cdot \mathbf{W}_G^{(t)} \hat{\mathbf{h}}_j^{(t,g)} \quad (4)$$

其中,  $\mathbf{W}_G^{(t)}, a^{(t)}$  为可训练参数,  $\mathbf{h}_i^{(t,g)} \in \mathbb{R}^d$  为全局通道中第  $t$  层节点  $v_i$  的隐向量表示.

#### 2.1.2 局部子结构感知图神经网络

在局部层面上,异常节点周围的子结构形状通常偏离正常模式,现采用图曲率作为边权重,以反映局部子结构的稀疏性或密度.计算节点  $v_i$  和  $v_j$  间每条边的

图曲线:

$$m_i(o) = \begin{cases} \tau, & v_o = v_i \\ (1-\tau) / |N_i|, & v_o \in N_i \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

$$K(i, j) = 1 - W(m_i, m_j) \quad (6)$$

其中,  $o = 1, 2, \dots, N$ ;  $\tau$  是属于  $[0, 1]$  区间中的一个权重参数;  $W(\cdot)$  是 Wasserstein 距离度量函数. 对边的权值的定义如下:

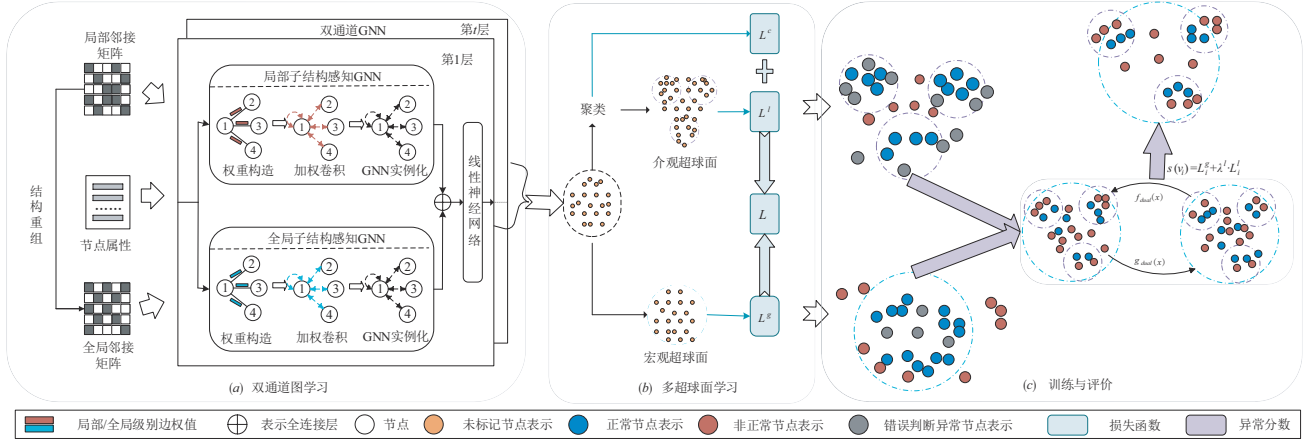


图1 HD-GAD模型框架

$$\hat{A}_{i,j} = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(K(i,j) - \mu)^2}{2\sigma^2}\right) \cdot |N_i \cap N_j|, & A_{i,j} = 1 \\ 0, & A_{i,j} = 0 \end{cases} \quad (7)$$

$$\tilde{A}_{i,j} = \frac{\hat{A}_{i,j}}{\sum_{j \in N_i} \hat{A}_{i,j}} \quad (8)$$

其中,  $K(i, j)$  表示节点  $v_i$  和  $v_j$  之间的边曲率,  $\mu$  和  $\sigma$  是所有边曲率的平均值和标准差. 通过加权卷积获取局部通道中的隐向量表示  $\hat{h}_i^{(l)}$ . 采用跨通道学习在线性层将两个通道的表示融合, 即  $\mathbf{h}_i^{(l)} = \mathbf{W}_L^{(l)}(\mathbf{h}_i^{(l,g)}, \mathbf{h}_i^{(l,l)}) + \mathbf{b}^{(l)}$ .

## 2.2 对偶多超球面学习

### 2.2.1 宏观视图超球面学习

在异常检测中, 宏观和介观视图具有互补性. 通过宏观视图超球体学习 MHL, 以约束正常节点的嵌入表征. 即

$$L^g = \frac{1}{|V^{\text{train}}|} \sum_{v_i \in V^{\text{train}}} \|\mathbf{z}_i - \mathbf{c}_0\|_2^2 \quad (9)$$

其中,  $\mathbf{c}_0$  是宏观视图超球体中心,  $\mathbf{z}$  是节点表征.

### 2.2.2 介观视图超球面学习

对每个节点  $v_i$  学习节点级分配概率向量:  $\mathbf{p}_i = \text{softmax}(\Phi_c(\mathbf{z}_i))$ ,  $\Phi_c(\cdot)$  为赋值编码器, 每个分量  $\mathbf{p}_i(k)$  表示  $v_i$  属于集群  $C_k$  的概率. 假设有  $K$  社区, 且  $\mathbf{p}_i \in \mathbb{R}^K$ . 通过 GNN 实例化  $\Phi_c$  捕获局部结构信息, 然后堆叠所有节点级分配概率向量, 并将分配概率矩阵表示为  $\mathbf{P} \in \mathbb{R}^{N \times K}$ .  $\mathbf{P}$  的各列都被定义为  $\mathbf{q}_k \in \mathbb{R}^N, k = 1, 2, \dots, K$ , 这

是社区级分配概率向量. 利用基于数据增强的对比学习目标对比社区级分配概率向量:

$$L^c = -\frac{1}{K} \sum_{k=1}^K \log \frac{\exp(\text{Sim}(\mathbf{q}_k, \mathbf{q}_k^+))}{\sum_{k'=1}^K \exp(\text{Sim}(\mathbf{q}_k, \mathbf{q}_{k'}^+))} \quad (10)$$

其中,  $\text{Sim}(\cdot, \cdot)$  为余弦相似度函数,  $\mathbf{q}_k^+$  为增强样本. 对各节点分配向量做数据增强, 以获得高置信度的节点级分配概率向量, 使节点表示更接近它们的集群中心:

$$\hat{\mathbf{p}}_i(k) = \frac{\mathbf{p}_i(k)^2}{\sum_{i=1}^N \mathbf{p}_i(k)} \quad (11)$$

$$\mathbf{p}_i^+ = \text{softmax}(\hat{\mathbf{p}}_i) \quad (12)$$

其中,  $\sum_{i=1}^N \mathbf{p}_i(k)$  表示簇  $C_k$  的频率. 其社区表征为

$$\mathbf{c}_k = \frac{\sum_{i=1}^N \mathbf{p}_i(k) \cdot \mathbf{z}_i}{\sum_{i=1}^N \mathbf{p}_i(k)} \quad (13)$$

再利用基于聚类的方法将每个社区视为一个介观视角的超球体, 通过特定的学习目标 MHL 从多个角度约束社区表征, 即

$$L^l = \frac{1}{K \cdot |V^{\text{train}}|} \sum_{v_i \in V^{\text{train}}} \|\mathbf{z}_i - \mathbf{c}_{k_i^*}\|_2^2 \quad (14)$$

其中,  $k_i^* = \text{argmax}_k \mathbf{p}_i(k), k = 1, 2, \dots, K$ .

### 2.2.3 对偶推断

在本工作中利用对比损失进行聚类, 改进了聚类目标将 MHL 模块的总体目标表述为

$$L = L^g + \lambda^l \cdot L^l + \lambda^c \cdot L^c \quad (15)$$

其中,  $\lambda^l$  和  $\lambda^c$  为权重参数. 每个节点的异常评分定义为

$$s(v_i) = L_i^s + \lambda^l \cdot L_i^l = \|\mathbf{z}_i - \mathbf{c}_0\|_2^2 + \lambda^l \cdot \|\mathbf{z}_i - \mathbf{c}_{k_i}\|_2^2 \quad (16)$$

通过对偶推断用  $f: X \mapsto Y$  代表原始任务的模型, 其能够实现从  $X$  空间到  $Y$  空间的映射  $g: X \mapsto Y$  是对偶任务的模型. 本文用  $l_f(x, y)$  和  $l_g(x, y)$  代表  $f$  和  $g$  的损失函数. 进而将结构对偶性应用到训练阶段, 以提升模型性能. 其对偶推断的基本表示为

$$f_{\text{dual}}(x) = \arg \min_{y' \in Y} \{ \alpha l_f(x, y') + (1 - \alpha) l_g(x, y') \} \quad (17)$$

$$g_{\text{dual}}(y) = \arg \min_{x' \in X} \{ \beta l_g(x', y) + (1 - \beta) l_f(x', y) \} \quad (18)$$

### 2.3 嵌入感知相似度

利用对比损失进行聚类, 改进了聚类目标提出了一个新的相似度函数 EmbSim 来代替等式中的标准余弦相似度  $\text{Sim}(\cdot, \cdot)$ , 通过嵌入矩阵  $\mathbf{Z} \in \mathbb{R}^{N \times d}$  转换每个社区的分配  $\mathbf{q}_k$ , 嵌入矩阵由所有表征  $\mathbf{z}_i, i = 1, 2, \dots, N$  堆叠所得.  $\mathbf{q}_k$  和  $\mathbf{q}_{k'}$  的嵌入感知相似性 EmbSim 被表述为

$$\text{EmbSim}(\mathbf{q}_k, \mathbf{q}_{k'}) = \frac{\mathbf{q}_k^T \mathbf{Z} \cdot \mathbf{Z}^T \mathbf{q}_{k'}}{\|\mathbf{Z}^T \mathbf{q}_k\|_2 \cdot \|\mathbf{Z}^T \mathbf{q}_{k'}\|_2} \quad (19)$$

本质上,  $\text{EmbSim}(\mathbf{q}_k, \mathbf{q}_{k'}) = \text{Sim}(\mathbf{Z}^T \mathbf{q}_k, \mathbf{Z}^T \mathbf{q}_{k'})$ . 用 EmbSim 代替余弦相似度, 此处可以重新表述式(10)为

表1 数据集超参数设置

| 数据集      | 异常注入类型  | $\lambda^l$ | $\lambda^c$ | $K$ | $c_0$  | $d$ |
|----------|---------|-------------|-------------|-----|--------|-----|
| Cora     | Struct  | 0.1         | 1           | 8   | update | 32  |
|          | Syn     | 1           | 0.1         | 8   | train  | 32  |
| CiteSeer | Struct  | 0.1         | 0.1         | 8   | train  | 32  |
|          | Syn     | 0.01        | 10          | 6   | update | 32  |
| ML       | Struct  | 10          | 0.1         | 4   | train  | 256 |
|          | Syn     | 0.001       | 10          | 10  | train  | 128 |
| PubMed   | Struct  | 10          | 10          | 10  | update | 16  |
|          | Syn     | 0.001       | 10          | 6   | update | 32  |
| Reddit   | Organic | 1           | 0.001       | 4   | init.  | 32  |

### 3.2 主实验结果

如表2所示, 展示了本研究在各数据集及异常注入类型下的性能, 粗体字为最优结果, 下横线为次优结果. 其实验结果表明:

(1) HD-GAD 方法的卓越性能: 在所有数据集和异常类型上均表现优异, 证明其在检测节点级图异常的能力.

(2) 深度学习的优越性: 深度学习方法在图异常检测任务中明显优于非深度学习或非图方法, 如 LOF、SCAN 和 Radar. 这凸显了结构信息的关键性.

(3) AUC 和 AUPR 的多角度分析: 尽管 AUC 值在大多数情况下均超过了 0.9, 但 AUPR 值部分相对较低 (小于 0.6). 是因为 AUC 主要关注异常评分在正常和异常

$$L^c = -\frac{1}{K} \sum_{k=1}^K \log \frac{\exp(\text{Sim}(\mathbf{c}_k, \mathbf{c}_k^+))}{\sum_{k'=1}^K \exp(\text{Sim}(\mathbf{c}_k, \mathbf{c}_{k'}^+))} \quad (20)$$

## 3 实验结果分析

### 3.1 实验基准

为了分析 HD-GAD 方法的优劣势, 对比九种方法并在五个数据集 (Cora<sup>[15]</sup>、CiteSeer<sup>[15]</sup>、ML<sup>[15]</sup>、PubMed<sup>[15]</sup> 和 Reddit<sup>[16]</sup>) 上进行性能评估比较<sup>[17]</sup>. 包括: 两种传统方法 (包括基于密度估计的方法 LOF<sup>[4]</sup> 和聚类方法 SCAN<sup>[18]</sup>)、基于残差估计的方法 Radar<sup>[5]</sup>、对比学习方法 CoLA<sup>[7]</sup>、基于自编码器的方法 ComGA<sup>[19]</sup>、基于超球面学习的方法 (OCGNN<sup>[13]</sup>、AAGNN<sup>[14]</sup>、MHGL<sup>[20]</sup> 和 OCGTL).

本文采用 GAT 模拟所有基于 GNN 的基准模型, 并将数据集划分为训练集、验证集和测试集, 比例为 6:1:3. 确保训练数据仅包含正常节点, 以避免异常干扰, 有效评估异常检测性能. 本文引入自适应学习率的 Adam 优化器, 设定学习率为 0.001, 权重衰减为 0.0005, 以优化模型. 并测试了对几个重要参数的敏感性, 包括损失权重  $\lambda^l, \lambda^c$ 、簇数  $K$ 、全局超球体中心的设置和隐向量大小  $d$ , 如表1所示.

样本之间的排序, 而 AUPR 则更加敏感于正样本. 因此, 这两个指标从不同的角度评估性能.

(4) HD-GAD 的普适性: 与注入数据集的基线结果相比, HD-GAD 在结构和合成设置下都表现出色, 可有效地捕捉结构信息和上下文信息.

(5) 难以检测的真实世界异常: 与注入的异常数据相比, 在有机数据集 Reddit 上获得良好的结果相对较为困难. 这提示了现实世界中异常的隐蔽性, 难以仅凭结构和上下文信息进行准确检测.

### 3.3 异常边泛化性实验

本文通过设置异常边比例  $P$  (从 0.2 调整至 0.8) 来进行泛化性实验, 以探究模型在不同级别的数据扰动

下的性能变化。

如表3所示,随着异常边的比例增加,模型性能逐渐下降,在边数与节点数比例差异较大的数据集ML中尤为显著.表明与其他数据集相比,ML数据集的边数与节点

数比例差异较大,使得模型在面对较高比例的数据扰动时性能显著下降.同时,这一观察结果凸显了HD-GAD模型对数据扰动的高度敏感性,为未来研究提供了重要方向,即进一步优化模型以增强其面对数据扰动时的鲁棒性.

表2 异常检测结果

单位:%

| 方法         | 指标   | Cora         |              | CiteSeer     |              | ML           |              | PubMed       |              | Reddit       |
|------------|------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|            |      | Struct       | Syn          | Struct       | Syn          | Struct       | Syn          | Struct       | Syn          | Organic      |
| LOF        | AUC  | 56.71        | 69.58        | 53.88        | 68.67        | 53.91        | 46.58        | 47.64        | 20.98        | 51.77        |
|            | AUPR | 9.66         | 24.28        | 11.56        | 26.96        | 10.13        | 18.44        | 8.65         | 4.81         | 3.51         |
| SCAN       | AUC  | 42.47        | 43.02        | 36.56        | 37.17        | 60.54        | 59.97        | 73.39        | 72.17        | 50.49        |
|            | AUPR | 7.69         | 5.31         | 8.91         | 4.92         | 9.87         | 5.93         | 15.58        | 8.25         | 3.28         |
| Radar      | AUC  | 55.43        | 76.58        | 52.33        | 71.43        | 55.02        | 97.99        | 48.71        | 76.04        | 50.78        |
|            | AUPR | 9.10         | 21.47        | 11.94        | 10.20        | 10.33        | 57.72        | 8.60         | 25.64        | 3.47         |
| CoLA       | AUC  | 65.73        | 64.82        | 66.28        | 73.71        | 60.08        | 48.33        | 79.73        | 76.98        | 58.34        |
|            | AUPR | 13.04        | 16.30        | 19.19        | 13.11        | 11.55        | 4.35         | 29.30        | 14.30        | <u>5.08</u>  |
| ComGA      | AUC  | <u>98.95</u> | <u>97.27</u> | <u>99.68</u> | <u>99.34</u> | <u>97.90</u> | 95.64        | 99.69        | <u>98.34</u> | 51.37        |
|            | AUPR | <u>74.88</u> | <u>70.01</u> | <u>91.12</u> | <u>75.70</u> | <u>63.48</u> | 40.20        | 91.78        | 68.15        | 3.34         |
| OCGNN      | AUC  | 78.27        | 89.00        | 83.32        | 76.82        | 80.58        | <u>98.66</u> | 83.62        | 96.79        | 58.23        |
|            | AUPR | 19.95        | 42.55        | 21.45        | 10.88        | 19.42        | <u>73.15</u> | 26.10        | 51.55        | 3.79         |
| AAGNN      | AUC  | 91.72        | 83.81        | 82.53        | 80.31        | 94.77        | 86.45        | <u>99.88</u> | 95.91        | 49.20        |
|            | AUPR | 35.87        | 17.66        | 20.60        | 11.15        | 52.24        | 21.47        | <u>99.12</u> | <u>82.35</u> | 3.06         |
| MHGL       | AUC  | 94.74        | 90.38        | 96.12        | 93.95        | 84.82        | 97.33        | 97.12        | 92.78        | 58.65        |
|            | AUPR | 59.46        | 50.92        | 87.99        | 69.19        | 44.71        | 53.55        | 81.80        | 52.86        | 3.99         |
| OCGTL      | AUC  | 87.61        | 89.42        | 86.48        | 87.12        | 77.06        | 95.84        | 97.77        | 95.68        | <u>58.76</u> |
|            | AUPR | 34.37        | 24.71        | 34.72        | 30.29        | 26.20        | 50.88        | 78.35        | 47.95        | 4.01         |
| HD-GAD-MHL | AUC  | <b>99.15</b> | <b>98.34</b> | <b>99.79</b> | <b>99.45</b> | <b>98.16</b> | <b>98.73</b> | <b>99.90</b> | <b>98.89</b> | <b>62.72</b> |
|            | AUPR | <b>98.71</b> | <b>96.85</b> | <b>98.44</b> | <b>99.24</b> | <b>87.15</b> | <b>94.23</b> | <b>99.89</b> | <b>92.11</b> | <b>5.08</b>  |

表3 异常边泛化性实验结果

单位:%

| 异常边比例 $P$      | Cora   |       | CiteSeer |       | ML     |       | PubMed |       | Reddit  |
|----------------|--------|-------|----------|-------|--------|-------|--------|-------|---------|
|                | Struct | Syn   | Struct   | Syn   | Struct | Syn   | Struct | Syn   | Organic |
| AUC( $P=0.2$ ) | 98.97  | 98.12 | 99.58    | 99.28 | 97.00  | 97.59 | 99.77  | 98.74 | 62.54   |
| AUC( $P=0.4$ ) | 98.79  | 97.98 | 99.47    | 99.05 | 96.95  | 97.49 | 99.68  | 98.70 | 62.46   |
| AUC( $P=0.6$ ) | 97.74  | 95.57 | 98.62    | 98.03 | 95.72  | 96.37 | 98.53  | 97.20 | 61.13   |
| AUC( $P=0.8$ ) | 95.56  | 95.66 | 96.35    | 97.34 | 94.53  | 94.99 | 97.20  | 96.05 | 60.82   |

### 3.4 敏感性分析实验

(1)中间层维度:从2改变到512,如图2所示.当 $d < 8$ 时,性能随着 $d$ 的增加普遍提高,当 $d$ 较大时,性能将达到峰值.总体来看,当 $d > 256$ 时,会存在轻微的性能下降,主要是参数量过大数引起的过拟合问题和维数诅咒引发欧氏距离失效.

(2)簇数: $K$ 从2变化到10,如图3所示.当 $K \geq 6$ 时,性能将达到峰值,并且在峰值之前有上升趋势.对

于数据集CiteSeer,当 $K > 8$ 时,AUC值会下降,这表明设置太多的社区可能会带来多余的信息并损害性能.

(3)中心模式:本文改变了定义中心 $c_0$ 的操作,如图4所示对于大多数数据集,初始化和训练模式的结果是相似的,更新模式将呈现出明显的性能区别.由此得出,神经网络很难学习到一个比初始化和固定的中心更好的中心.然而,每个训练轮次后更新中心将显著地改变中心并影响性能.




图2 中间层维度的参数敏感性分析

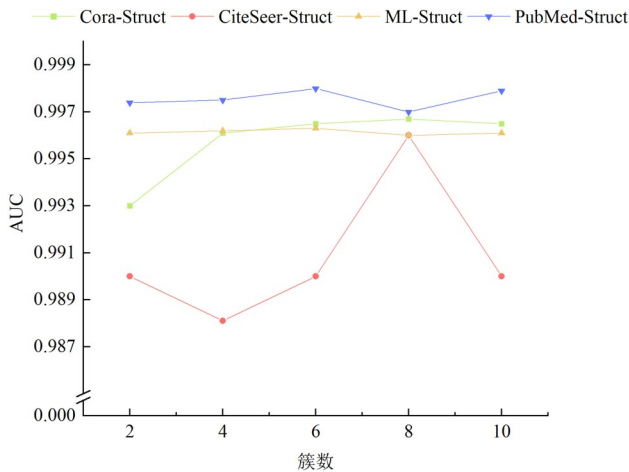


图3 簇数的参数敏感性分析




图4 中心模式的参数敏感性分析

### 4 结论与展望

本文提出了一种名为HD-GAD的模型用于图异常检测任务. 通过一系列实验证明,HD-GAD在性能上超越了所有最近的性能最优方法. 未来在图异常检测领域可更关注于异常边、子图和图检测、动态图中的异常检测、多模态数据的异常检测的发展.

### 参考文献

[1] GRUBBS F E. Procedures for detecting outlying observations in samples[J]. *Technometrics*, 1969, 11(1): 1-21.

[2] 金明, 丁蓉. 一种联合时域和空域残差的网络异常检测与节点定位方法[J]. *电子学报*, 2023, 51(5): 1172-1178.

JIN M, DING R. Detection and localization of outlier nodes in wireless sensor networks via jointing temporal and spatial residuals[J]. *Acta Electronica Sinica*, 2023, 51(5): 1172-1178. (in Chinese)

[3] 严莉, 张凯, 徐浩, 等. 基于图注意力机制和Transformer的异常检测[J]. *电子学报*, 2022, 50(4): 900-908.

YAN L, ZHANG K, XU H, et al. Abnormal detection based on graph attention mechanisms and Transformer[J]. *Acta Electronica Sinica*, 2022, 50(4): 900-908. (in Chinese)

[4] BREUNIG M M, KRIEDEL H P, NG R T, et al. LOF: Identifying density-based local outliers[C]//*Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*. New York: ACM, 2000: 93-104.

[5] LI J, DANI H, HU X, et al. Radar: Residual analysis for anomaly detection in attributed networks[C]//*International Joint Conferences on Artificial Intelligence*. San Francisco: Curran Associates Inc, 2017: 2152-2158.

[6] ERFANI S M, RAJASEGARAR S, KARUNASEKERA S, et al. High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning[J]. *Pattern Recognition*, 2016, 58(C): 121-134.

[7] LIU Y, LI Z, PAN S, et al. Anomaly detection on attributed networks via contrastive self-supervised learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(6): 2378-2392.

[8] LI Y N, HUANG X, LI J D, et al. SpecAE: Spectral auto-encoder for anomaly detection in attributed networks[C]//*Proceedings of the 28th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2019: 2233-2236.

[9] LIU K, DOU Y, ZHAO Y, et al. Bond: Benchmarking unsupervised outlier node detection on static attributed graphs[J]. *Advances in Neural Information Processing Systems*

- tems, 2022, 35: 27021-27035.
- [10] DING K Z, LI J D, BHANUSHALI R, et al. Deep anomaly detection on attributed networks[C]//Proceedings of the 2019 SIAM International Conference on Data Mining. Philadelphia: Society for Industrial and Applied Mathematics, 2019: 594-602.
- [11] FAN H Y, ZHANG F B, LI Z Y. Anomalydae: Dual auto-encoder for anomaly detection on attributed networks[C]//ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE, 2020: 5685-5689.
- [12] CHEN Z X, LIU B, WANG M Q, et al. Generative adversarial attributed network anomaly detection[C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York: ACM, 2020: 1989-1992.
- [13] WANG X H, JIN B H, DU Y, et al. One-class graph neural networks for anomaly detection in attributed networks[J]. Neural Computing and Applications, 2021, 33 (18): 12073-12085.
- [14] ZHOU S, TAN Q Y, XU Z M, et al. Subtractive aggregation for attributed network anomaly detection[C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. New York: ACM, 2021: 3672-3676.
- [15] MA X X, WU J, XUE S, et al. A comprehensive survey on graph anomaly detection with deep learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(12): 12012-12038.
- [16] LIU K, DOU Y T, ZHAO Y, et al. BOND: Benchmarking unsupervised outlier node detection on static attributed graphs[J]. Advances in Neural Information Processing Systems, 2022, 35: 27021-27035.
- [17] 李康和, 黄震华. 基于噪声过滤与特征增强的图神经网络欺诈检测方法[J]. 电子学报, 2023, 51(11): 3053-3060.  
LI K H, HUANG Z H. Noise filtering and feature enhancement based graph neural network method for fraud detection[J]. Acta Electronica Sinica, 2023, 51(11): 3053-3060. (in Chinese)
- [18] XU X W, YURUK N, FENG Z D, et al. SCAN: A structural clustering algorithm for networks[C]//Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2007: 824-833.
- [19] LUO X X, WU J, BEHESHTI A, et al. ComGA: Community-aware attributed graph anomaly detection[C]//Pro-

ceedings of the Fifteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2022: 657-665.

- [20] ZHOU S, HUANG X, LIU N H, et al. Unseen anomaly detection on networks via multi-hypersphere learning[C]//Proceedings of the 2022 SIAM International Conference on Data Mining (SDM). Philadelphia: Society for Industrial and Applied Mathematics, 2022: 262-270.

#### 作者简介



李青女, 1989年5月出生于陕西省西安市. 现为西北工业大学计算机学院副教授、硕士生导师, 主要研究方向为图数据挖掘与自然语言处理. 在国内外发表学术论文40余篇.

E-mail: qingli@nwpu.edu.cn



钟将男, 1974年4月出生于河南省南阳市. 1995年毕业于重庆大学计算机学院, 现为重庆大学教授, 从事大数据分析与挖掘方面的研究工作.

E-mail: zhongjiang@cqu.edu.cn



倪航男, 2001年11月出生于江苏省南通市. 2023年毕业于西北工业大学教育实验学院. 主要研究方向为深度学习.

E-mail: nihang@mail.nwpu.edu.cn