

基于数据增强的多视图对比学习图异常检测

李一凡^{1,2}, 李家印^{1,2}, 林兴澎^{1,2}, 戴远飞³, 许力^{1,2}

(1. 福建师范大学计算机与网络空间安全学院, 福建 福州 350000; 2. 福建省网络安全与密码技术重点实验室, 福建 福州 350000;
3. 南京工业大学计算机与信息工程学院, 江苏 南京 210000)

摘要: 图异常检测在预防金融欺诈、网络入侵等有害事件上具有重要价值。基于对比的异常检测方法尽管能够根据异常节点实例对的不一致性有效挖掘异常信息, 避免因采用自编码架构导致模型需要全图训练的弊端, 但是现有的大多数基于对比的图异常检测方法仅关注节点-子图的对比模式, 忽略了采样的节点-子图实例对中只包含目标节点的局部信息, 同时没有考虑各子图对目标节点的重要性, 导致节点全局信息缺失和对比模式过于泛化的问题。为解决上述问题, 提升图异常检测的准确度, 提出了一种基于数据增强的多视图对比学习图异常检测 (data augmentation based multi-view contrastive learning graph anomaly detection, DAMC-GAD) 方法。具体地, 提出了一种用于异常检测的图数据增强方法, 通过目标节点的相对局部结构和自身属性关联距离较远的节点, 以构建全局信息丰富的增强视图。引入逐层采样结合节点-子图对比, 根据子图重要性制定对比模型的优化策略。通过互补的融合策略构建基于数据增强的多视图对比学习模型, 在合成异常与真实异常数据集上进行大量实验, 实验结果表明, DAMC-GAD在两类数据集上均优于目前先进的基线模型。

关键词: 数据增强; 多视图对比学习; 图神经网络; 图异常检测

中图分类号: TP393

文献标志码: A

DOI: 10.11959/j.issn.2096-109x.2024075

Data augmentation based multi-view contrastive learning graph anomaly detection

LI Yifan^{1,2}, LI Jiayin^{1,2}, LIN Xingpeng^{1,2}, DAI Yuanfei³, XU Li^{1,2}

1. College of Computer and Cyber Security, Fujian Normal University, Fuzhou 350000, China

2. Fujian Provincial Key Laboratory of Network Security and Cryptology, Fuzhou 350000, China

3. College of Computer and Information Engineering, Nanjing University of Technology, Nanjing 210000, China

收稿日期: 2024-04-22; **修回日期:** 2024-07-19

通信作者: 许力, xuli@fjnu.edu.cn

基金项目: 国家自然科学基金 (62471139, U1905211, 62202221); 国家科技项目备案-中央引导地方科技发展专项 (2023L3007); 江苏省自然科学基金青年项目 (BK20220331); 福建省自然科学基金 (2023J05128); 福建省科技创新重点项目 (2022G02003)

Foundation Items: The National Natural Science Foundation of China(62471139, U1905211, 62202221), The National Science and Technology Project Record-Centralized Guided Local Science and Technology Development Special Project(2023L3007), The Natural Science Foundation of Jiangsu Province(BK20220331), The Natural Science Foundation of Fujian Province (2023J05128), Science and Technology Projects in Fujian Province (2022G02003)

引用格式: 李一凡, 李家印, 林兴澎, 等. 基于数据增强的多视图对比学习图异常检测[J]. 网络与信息安全学报, 2024, 10(5): 163-174.

Citation Format: LI Y F, LI J Y, LIN X P, et al. Data augmentation based multi-view contrastive learning graph anomaly detection[J]. Chinese Journal of Network and Information Security, 2024, 10(5): 163-174.

Abstract: Graph anomaly detection is valuable in preventing harmful events such as financial fraud and network intrusion. Although contrast-based anomaly detection methods could effectively mine anomaly information based on the inconsistency of anomalous node instance pairs, avoiding the drawback of using self-coding architecture that led to the need for full graph training for the model. However, most existing contrast-based graph anomaly detection methods focused only on node-subgraph contrast patterns, ignoring the fact that the sampled node-subgraph instance pairs contained only the local information of the target node, and at the same time did not take into account the importance of each subgraph to the target node, which led to the lack of global information about the node and the emergence of the problem that the contrast patterns were too generalized. In order to solve the problems mentioned above and to improve the accuracy of graph anomaly detection, a graph anomaly detection by data augmentation and multi-view contrastive learning (DAMC-GAD) was proposed. Specifically, a graph data augmentation method for anomaly detection was proposed, in which the relative local structure of target nodes and their own attributes were used to correlate distant nodes in order to construct an augmented view that was rich in global information. Layer-by-layer sampling combined with node-subgraph contrast was introduced, and optimization strategies for the contrast model were developed based on the importance of the subgraph. A multi-view contrastive learning model with data augmentation was constructed through a complementary fusion strategy, and extensive experiments were conducted on synthetic anomaly and real anomaly datasets, which show that DAMC-GAD outperforms the current state-of-the-art baseline model on both types of datasets.

Keywords: data augmentation, multi-view contrastive learning, graph neural network, graph anomaly detection

0 引言

图异常检测是图学习中的代表性任务^[1],旨在从图中发现偏离大多数节点的异常节点,即具有可疑结构关系或可疑属性的节点。由于挖掘这些可疑节点在预防有害事件上具有重要价值,如金融欺诈检测^[2]、网络入侵检测^[3]和社交垃圾邮件发送者检测^[4]等,图异常检测受到了很多研究人员的关注。随着深度学习的发展,图神经网络(graph neural network, GNN)^[5]概念被提出,并在图任务上取得优秀的成果。而后一系列GNN被提出用于解决各种不同的任务。因此,图神经网络作为一种适用于图结构的深度学习方法,被广泛应用于属性图上的异常检测。例如, Dominant^[6]是首个使用图神经网络进行图异常检测的模型,它采用图自编码器来重建网络结构和节点属性,通过重建误差评估每个节点的异常分数,是经典的基于图自编码器^[7]的异常检测方法。而后,各种方法如 AnomalyDae^[8]和 GDAE^[9]以及 SpaceAE^[10]等分别从不同方面进行进一步优化,并取得了优秀成果。然而,这些基于重建误差的方法在其学习目标中没有直接针对异常检测问题,导致检测结果未达到最优^[11],并且它们需要采用全图训练机制,因此无法进行小批量训练,从而在大规模图上对于设备要求更高。

为了避免基于重建误差的全图训练机制,出现了很多采用对比式自监督学习的方法,主要关注 GAD (graph anomaly detection) 的各种对比策略,即节点-节点、节点-子图对比。通过输入节点-子图模式的正负实例对,让模型通过节点与其邻域的关系学习异常得分。例如, Cola^[11]作为第一个将对比学习应用于图异常检测的框架,它通过学习节点与局部子图的一致性来捕获异常信息。而后 ANEMONE^[12]、GRADE^[13]则分别引入节点-节点和子图-子图对比模式到模型中,形成了多尺度对比模型,进一步完善了基于对比学习的异常检测方法。然而,尽管基于对比的图异常检测算法有了更大的突破,但仍然存在一些缺点。现有的对比模型通常忽略了邻域子图中缺乏节点的全局信息,现有研究表明,全局信息对于节点表示极为重要^[14]。但是节点的邻域子图中只包含了其局部信息,如果想要聚合节点全局信息,则通常需要聚合多跳邻居,这会导致节点特征过平滑。其次这些方法由于随机游走^[15]的采样模式无法区分各个子图对目标节点的重要性。由于这些问题,现有的异常检测方法结果未达到最优。

为了解决这些问题,本文引入数据增强模块并在多尺度对比网络中结合逐层采样,提出新的 GAD 方法——DAMC-GAD (data aug-

mentation based multi-view contrastive learning graph anomaly detection) 方法。具体地, 本文以原始图作为原视图, 通过节点的子图信息进行重构, 形成一个增强视图, 以此作为一种数据增强^[16]的方法。在增强视图中, 节点之间的相似度决定它们之间的距离, 越相似的节点距离越近, 而这些连接的节点可能在原始视图中的距离较远。因此与原始图中节点邻域子图只有节点的局部信息不同, 在增强视图中进行子图采样可以获得节点的全局信息; 然后在原视图和增强图中进行多尺度对比, 即节点-节点对比和节点-子图对比, 挖掘节点存在的各类异常信息, 计算每个节点的异常分数。不同于现有工作使用随机游走进行子图采样, 本文根据节点实例对的对比模式结合逐层采样, 分别采样目标节点的各层邻居^[17], 其中, 层指基于目标节点规定跳数的所有节点集合, 如一层则指代目标节点所有一跳邻居的集合。经过研究发现, 当层数超过3层时, 采样的子图对于节点的异常判断帮助不大。因此本文采样目标节点的一、二、三跳邻居节点, 分别形成对应的子图, 距离越近的子图, 其对比的重要性越高, 以此进一步细化了对比方案。最后, 本文通过实验证明了数据增强和逐层采样的有效性。

综上, 本文的主要贡献如下。

1) 本文创新性地提出一种图异常检测的数据增强方法, 根据节点的相对局部信息构建增强视图以聚合节点的全局信息。

2) 本文首次将多尺度对比方法和逐层采样策略相结合, 不仅优化了采样的对比实例对, 而且细化了对比模型, 同时研究了在基于对比的异常检测模型中采样子图的重要性对目标节点检测产生的影响。

3) 本文基于互补融合的策略提出了一种新的基于数据增强的多视图对比学习图异常检测方法。在包含真实异常与合成异常的5个基准数据集上证明了该方法用于图异常检测的有效性以及它与目前最先进方法相比的优越性。

1 相关工作

1.1 图异常检测

图异常检测因具有预防有害事件的重要价值成为图学习中的重要问题。然而标签的稀疏和图

数据的非线性导致图上的异常检测是困难的并且往往要求是无监督的。起初, 研究者采用了基于自我网络、社区分析^[18]或子空间选择^[19]的浅层学习方法。然而, 浅层学习方法无法捕捉图数据之间的复杂交互, 导致性能不佳。随着深度学习发展并应用于图数据, 很多基于图神经网络的方法开始被用于异常检测, 并取得较好的成果。其中, 大部分基于图神经网络的异常检测方法, 可以分为两类: 一类是生成式的自监督学习; 另一类是对比式的自监督学习。

生成式的自监督异常检测大多基于重建误差来发现异常节点。例如, Dominant^[6]是其中一种经典的方法, 它通过图自动编码器来重建网络结构和节点属性。在此基础上, AnomalyDAE^[8]使用两个图自动编码器将结构重建和属性重建过程分开, 优化模型结构, 提升异常检测性能。此外, SpaceAE^[10]在学习节点嵌入后首次引入高斯混合模型用于检测异常。CONAD^[20]则通过人为构建异常图来优化节点嵌入, 并在嵌入空间使其远离异常节点表示。然而, 这些基于重建误差的方法, 一方面其学习目标不直接针对异常, 导致性能未达到最优, 另一方面由于全图训练机制, 在大规模图上对设备要求较高。

因此, 现在很多研究者开始关注对比式自监督的异常检测方法, 这些方法通常基于对比实例对来捕捉异常。例如, Cola^[11]是经典的基于对比的异常检测方法, 它对比节点与其子图之间的信息, 通过节点-子图的正负实例对来捕捉异常。在它的基础上, ANEMONE^[12]加入了节点-节点的对比, 通过多尺度对比学习来捕获异常节点。GRADTAE^[13]引入数据增强和子图-子图对比, 以此优化节点和子图嵌入。然而, 这些方法都忽略了节点的全局信息, 受到图数据的限制, 仅对比了节点的邻域子图, 它们通过随机游走来采样子图, 无法区分子图对目标节点的重要性。针对这些问题, 本文提出了基于数据增强的多视图对比学习图异常检测方法。不仅通过提出的数据增强方法获得节点全局信息, 并且结合逐层采样的方法优化对比实例对。

1.2 图对比学习

由于标签珍贵, 很多问题需要采用无监督方

法,而对比学习是无监督学习中的一种重要范式。近年来,对比学习作为一种有效的自监督学习手段引起了越来越多学者的研究兴趣,其目的是从数据本身衍生的监督信号中学习表征。其核心思想是为同一数据实例构建合理的正负样本,而模型则起到拉近正样本和推远负样本的作用。

随着对比学习在计算机视觉和自然语言处理中获得了理想的结果^[21],研究者开始将其应用在图学习领域,并将这一系列算法称为图对比学习。例如,DGI通过最大化节点和图之间的互信息^[22],以获得有用的监督信息。而后GMI^[23]根据节点特征和拓扑直接最大化图神经编码器输入和输出之间的互信息来改进DGI。GCA^[24]提出生成两个数据视图并将两个视图中同一节点的节点表示拉近距离,将所有其他节点的表示推远。BGRL^[25]则应用暹罗网络从两个角度获取丰富的信息。

2 问题定义

针对图异常检测问题,为了与广泛采用的惯例保持一致,本文遵循Ding等的工作^[6],对具有

属性特征的图数据及其异常检测做以下定义。

1) 属性图/网络

本文对属性图的定义如下:属性网络可以表示为 $\mathcal{G}=\{\mathcal{V},\mathcal{E}\}=\{\mathbf{A},\mathbf{X}\}$,其中, $\mathcal{V}=\{v_1,v_2,\cdots,v_n\}$ 和 $\mathcal{E}=\{e_1,e_2,\cdots,e_m\}$ 分别表示图中节点数为 n 的节点集合和边数为 m 的边集合。而 $\mathbf{A}$ 和 $\mathbf{X}$ 则分别是图的邻接矩阵与属性矩阵,其中如果节点 v_i 和 v_j 之间存在连接,则 $A_{ij}=1$,否则 $A_{ij}=0$ 。

2) 图异常检测

对于节点为 $v_1,v_2,\cdots,v_n$ 的给定属性图 $\mathcal{G}$,需要学习一个异常评分函数 $f()$,计算出每个节点的异常评分,如 $s_i=f(i)$,其异常评分 s_i 表示节点 v_i 的异常程度,而后根据评分对所有节点进行排序,从而检测出异常节点。

3 模型框架

本文所提出的DAMC-GAD框架如图1所示。框架主要分为两个部分(图增强模块、多视图对比学习模块),通过异常检测部分确定每个节点的异常分数。




图1 DAMC-GAD 框架

Figure 1 The DAMC-GAD framework

3.1 图增强

图增强包含图扩充与图采样两个部分，不仅避免模型学习中数据过少的问题，同时帮助模型挖掘更深层次的语义信息，因此常被用在对比自监督学习中。本文基于图增强来聚合节点的全局信息，首先通过图扩充来构建全局信息丰富的增强图，然后通过逐层采样的方式提取子图，优化节点-子图的对比实例对。

3.1.1 图扩充

针对异常检测模型中节点全局信息缺失问题，本文提出一种图扩充方法，旨在从节点局部信息去获取其全局信息。具体来说，本文首先从原始图出发构建一幅增强图，并通过采样增强图获取节点的全局信息，在增强图中，节点应该与其相关或者近似的节点相连（这些节点在原始图中可能距离较远）。因此通过节点局部信息（局部结构和节点属性）作为依据来判断节点之间的相似程度，以发现图中那些隐藏的相似节点。值得注意的是，节点之间的属性和局部结构应该分开，并且局部结构之间的相似程度应与其节点的所在位置无关，为了不被节点的绝对位置干扰，在聚合子图信息时将所有节点的子图平移至同一原点来进行比较，确保比较每个节点的相对局部结构。节点局部结构比较样例如图2所示， $\mathcal{G}_1$ 、 $\mathcal{G}_2$ 分别为相比较的两个节点在嵌入空间中的局部结构表示， $\mathcal{G}'_1$ 、 $\mathcal{G}'_2$ 则分别对应 $\mathcal{G}_1$ 、 $\mathcal{G}_2$ 平移至相同空间后的嵌入表示，通过集中化子图表示比较节点的相对局部结构，避免原始图中节点绝对位置的影响。




图2 节点局部结构比较样例

Figure 2 Sample comparison of local structure of nodes

然后，本文提取出每个节点的一邻居子图作为节点的局部结构信息并采用 W (Weisfeiler-

Lehman)^[26]方案将子图中的每个节点映射在向量空间，再通过平均池化所有的节点嵌入，得到这个子图对于目标节点的相对表示，即节点的局部结构信息。具体地说，本文通过 WL 方案聚合节点之间的相对表示并迭代更新当前节点向量，再通过平均池化利用邻域节点得到当前节点的局部结构信息。计算方式如下。

$$x'_i = \frac{1}{2} \left(x_i + \frac{1}{\deg(v_i)} \sum_{j \in N(v_i)} x_j \right) \quad (1)$$

$$s_a = \sum_{i=1}^n x'_i \quad (2)$$

其中， v_i 是子图中任意节点， x_i 和 $\deg(v_i)$ 分别为节点 v_i 的属性和度数， $N(v_i)$ 是该节点的邻居节点集合， s_a 则是此子图的特征表示，也是该节点的局部结构表示。而节点的属性则是其本身特征表示，将两者连接得到最后的节点表示，即

$$x_i = [s_a, x_i] \quad (3)$$

最后，本文使用余弦相似性来计算节点嵌入之间的相似程度，以构建增强图。余弦相似性可以有效计算两个嵌入之间的相似程度。两个嵌入越相似，它们之间的余弦值就越接近 1。相反，两个嵌入越不相似，其值会接近 -1。为了计算简单，本文让节点和与它高度相似的节点进行连接，以此类推，最后得到的增强图，对于任意一个节点，与它越接近，则相似度越高，而这些节点之间的连接与原图结构并不相关。因此，相比原始图，在增强图中进行子图采样，可以捕捉到原本无法发现的全局信息。

3.1.2 逐层采样

本文采用在图对比异常检测模型中使用逐层采样的方法来提取子图。相比目前大多数方法采用的重启随机游走或者随机游走，逐层采样一方面可以根据距离确定子图对于目标节点的重要性，细化对比策略；另一方面，对于按照节点相似度构建的增强图，逐层采样将更适用，因为每层的邻居节点对于目标节点的相似程度不同。本文对于目标节点分别在一、二、三层中采样固定数量的节点作为对应的 3 个子图，而在越小层中采样的子图对于目标节点的重要性更高。

3.2 多视图对比学习

多视图对比学习从多个方面研究异常节点实例对的不一致性^[11]，不仅在原始图与增强图中分

别挖掘节点的局部信息与全局信息，还在每个视图分别进行多尺度的对比，即节点-子图对比和节点-节点对比。前者通过节点的邻域信息捕获异常，后者则针对节点的自身属性检测异常。

3.2.1 节点-子图对比

对于目标节点 v_i ，分别在原始视图与增强视图进行逐层采样，获取 3 个正对子图，并且与另一随机节点 v_j 的对应层子图形成负实例对。

以原始视图的第一层子图为例，首先使用 GCN (graph convolution network) 将子图中的节点映射到向量空间，而后通过 Readout 模块来计算子图的最后表示，并使用平均池化作为 Readout 函数。值得注意的是，对于子图中的目标节点需要进行掩码操作。子图的最后表示可以定义为

$$H_i^l = \sigma(\hat{D}_i^{-\frac{1}{2}} \hat{A}_i \hat{D}_i^{-\frac{1}{2}} H_i^{(l-1)} W^{(l-1)}) \quad (4)$$

$$e_i = \text{readout}(H_i^l) = \sum_{j=1}^{n_i} \frac{H_i^l[j,:]}{n_i} \quad (5)$$

其中， H^l 和 H^{l-1} 分别指 l 层和 $l-1$ 层的隐藏表示， $\hat{D}_i^{-\frac{1}{2}} \hat{A}_i \hat{D}_i^{-\frac{1}{2}}$ 指子图邻接矩阵的归一化， W 指 GCN 的参数， n_i 指节点 i 的子图中的节点数， e_i 指目标节点 i 对应子图的最后表示。而目标节点将通过 GCN 的权重矩阵和激活函数进行转换，可以认为使用了一层的 MLP (multilayer perceptron) 层。即

$$z_i^l = \sigma(z_i^{(l-1)} W^{(l-1)}) \quad (6)$$

通过判别器来对比节点-子图实例对中两个元素的嵌入，并预测最终得分。通常，节点和其对应子图的表示是相似的，因此，正对得分会接近 1，而负对得分会接近 0。在此，本文遵循 Liu 等^[11] 的研究，使用一个简单的双线性评分函数来预测得分，并使用二进制交叉熵损失、利用目标节点与对应子图的表示来训练对比度，具体计算如下。

$$s_{i-ns}^1 = \tau(z_i, e_i) = \sigma(z_i W e_i^T) \quad (7)$$

其中， z_i 和 e_i 为当前实例对的节点与子图表示， W 为模型的参数， s_{i-ns}^1 为该节点与此时对应子图的判别分数。第一层的节点-子图对比损失为

$$L_{ns}^1 = - \sum_{i=1}^N (y_i \log(s_{i-ns}^1) + (1 - y_i) \log(1 - s_{i-ns}^1)) \quad (8)$$

与得分对应， y 在正对中等于 1，在负对中等于 0。

与此相同，使用同样的方法可以分别得到第

2 层和第 3 层的子图，根据实验，当采样层数为 3 时效果最好，这代表超过 3 层后的节点与目标节点关联并不大，并且随着距离增加，其对应的子图对于目标节点的重要程度也减少了。因此在这个视图中的节点-子图对比度损失为

$$L_{ns} = \sum_{i=1}^3 \chi^i L_{ns}^i \quad (9)$$

其中， χ^i 和 L_{ns}^i 分别为各层的平衡参数和对比损失。同样地，可以计算在增强视图中的预测得分 $\hat{s}_i$ 和对比损失度 $\hat{L}_{ns}$ 。两个视图下的两个网络使用相同的架构并且共享参数。因此，最终的节点-子图对比损失为

$$L_{NS} = \alpha L_{ns} + (1 - \alpha) \hat{L}_{ns} \quad (10)$$

其中， $\alpha \in (0,1)$ 是两个视图之间的平衡参数。

3.2.2 节点-节点对比

节点-节点对比的思想与节点-子图相同，因此使用类似的架构进行节点-节点的对比，在每个视图中，目标节点与对应的同一节点为正对，与另一节点为负对。值得注意的是，目标节点所对应的节点之前进行了掩码，因此它的表示是从邻居节点聚合而来的。与式 (4) 类似，在此使用 GCN 聚合邻域信息并迭代更新节点表示，具体计算如下。

$$H_i^{(l)} = \sigma(\hat{D}_i^{-\frac{1}{2}} \hat{A}_i \hat{D}_i^{-\frac{1}{2}} H_i^{(l-1)} W^{(l-1)}) \quad (11)$$

而后使用 MLP 将目标节点映射到相同特征空间。

$$z_i^{(l)} = \sigma(z_i^{(l-1)} W^{(l-1)}) \quad (12)$$

最后，与节点-子图类似，定义节点-节点对比损失函数为

$$L_{nn}^1 = - \sum_{i=1}^N (y_i \log(s_{i-nn}^1) + (1 - y_i) \log(1 - s_{i-nn}^1)) \quad (13)$$

由于采样了 3 层，因此在这个视图中的节点-节点对比度损失为

$$L_{nn} = \sum_{i=1}^3 \chi^i L_{nn}^i \quad (14)$$

又因为存在两个视图，因此，最终的对比损失为

$$L_{NN} = \alpha L_{nn} + (1 - \alpha) \hat{L}_{nn} \quad (15)$$

其中，两个平衡参数 χ^i 和 α 与式 (9)、式 (10) 是共享的， χ^i 的平衡参数根据其重要程度随层数递减固定为 (0.5, 0.4, 0.1)，而视图的平衡参数则根据数据集进行调整。

3.3 异常检测

由于异常的稀疏性, 模型会更倾向学习正样本的匹配模式, 而负样本的学习则比较困难, 因此理想情况下, 正对的分数趋近1, 负对的分数趋近0。对于异常节点, 由于模型不能很好地区分其匹配模式, 因此其正对和负对的预测分数的判别性较差。根据Liu等^[11]提出的工作, 定义异常评分为其正负对得分的差值。

$$s_i = s_i^p - s_i^n \quad (16)$$

然后, 基于两种视图和两种对比模式对异常分数进行综合融合。异常评分进一步表示为

$$\begin{aligned} s_i &= \alpha \sum_{j=1}^3 s_{i-ns}^j + (1-\alpha) \sum_{j=1}^3 s_{i-nn}^j \\ \hat{s}_i &= \alpha \sum_{j=1}^3 \hat{s}_{i-ns}^j + (1-\alpha) \sum_{j=1}^3 \hat{s}_{i-nn}^j \\ S_i &= \beta s_i + (1-\beta) \hat{s}_i \end{aligned} \quad (17)$$

最后, 通过多轮检测计算出每个节点的异常分数。

$$\bar{S}_i = \frac{\sum_{r=1}^R S_i}{R} \quad (18)$$

该节点异常分数越高, 则认为其是异常节点的可能性越大。

4 实验

4.1 实验设置

4.1.1 数据集

本文在5个基准数据集上进行了大量的实验, DAMC-GAD表现出了优异性能, 验证了数据增强和分层采样对GAD的有效性。本文使用了3个合成异常数据集(EAT^[13]、UAT^[13]、Cora^[13])和两个真实异常数据集(Books^[27]和Reddit^[27]), 数据集统计信息如表1所示。

表1 数据集统计信息
Table 1 Dataset statistics

数据集	节点/个	连接边/个	属性维度/维	异常数量/个
EAT	399	5 993	203	30
UAT	1 190	13 599	239	60
Cora	2 708	5 429	1 433	150
Books	1 418	3 695	21	28
reddit	10 984	168 016	64	366

4.1.2 基线模型

为了检验DAMC-GAD模型的性能, 本文将其与以下6种流行的异常检测方法进行了比较。

(1) LOF^[28]

该方法在上下文级别检测异常, 只考虑节点属性。

(2) ANOMALOUS^[29]

该方法基于残差分析的原理, 提出结合了CUR分解和残差分析的异常检测框架。

(3) DOMINANT^[6]

该方法是经典的无监督异常检测方案。它利用图卷积自编码器对节点属性和网络结构进行联合重构, 最后通过每个节点的重构误差检测异常。

(4) COLA^[11]

该方法是首个基于对比自监督学习的自监督异常检测框架。它通过比较学习子图和目标节点的模式来检测异常节点。

(5) AMEMONE^[12]

该方法采用多尺度对比学习检测异常。利用具有多尺度对比学习目标的图形神经网络来从多个角度评估节点异常。

(6) GRADATE^[13]

该方法是目前先进的自监督图异常检测框架, 在多尺度对比的基础上引入了多视图对比, 进一步增强异常检测的性能。

4.1.3 评价指标

本文使用ROC-AUC作为评估指标来衡量提出的框架和基线的性能^[30]。ROC-AUC是以往异常检测方法中广泛使用的评价指标^[6,11-14]。ROC曲线描述了根据地基真值异常标签和异常检测结果, 真阳性率(正确识别的异常)和假阳性率(被错误识别为异常的正常实例)之间的关系。AUC值对应于ROC曲线下的面积, 表示随机选择的异常实例比正常实例获得更高排名的可能性^[31]。当AUC值接近1时, 说明该方法具有较高的性能。

4.1.4 参数设置

本文在Pytorch中实现DAMC-GAD模型架构, 模型的嵌入维度为64, 批处理大小设置为300, 抽样次数为256, 子图大小设置为4。具体参数设置如表2所示。

表2 参数设置
Table 2 Parameter settings

数据集	学习率	轮次	相似度	α	β
EAT	7×10^{-2}	500	-0.1	0.1	0.3
UAT	7×10^{-3}	600	-0.1	0.3	0.5
Cora	3×10^{-3}	300	-0.3	0.9	0.7
Books	1×10^{-3}	400	0.5	0.1	0.5
Reddit	1×10^{-3}	400	0.5	0.9	0.3

4.2 实验结果与分析

本节将提出的 DAMC-GAD 方法与各种基线方法在相同数据集下进行实验对比, 对 5 个数据集进行 10 次实验, 以平均值作为最终结果评估模型异常检测性能, 给出模型在各数据集边界值及误差范围, 并对模型进行边界值分析, 各方法在 5 种数据集上的 AVC 值对比如表 3 所示。

表3 各方法在 5 种数据集上的 AUC 值对比
Table 3 AUC value comparison of different methods on five datasets

方法	EAT	UAT	Cora	Books	Reddit
LOF	52.55	49.06	35.38	36.52	57.21
ANOMALOUS	41.09	33.56	31.98	52.82	54.93
DOMINANT	60.23	65.03	89.29	50.18	56.06
COLA	67.62	65.38	88.47	<u>57.36</u>	58.63
ANEMONE	77.26	80.87	91.22	45.22	56.84
GRADATE	<u>79.80</u>	<u>84.51</u>	<u>92.37</u>	47.99	<u>58.65</u>
DAMC-GAD	84.09	84.60	92.44	58.01	63.29

从实验结果可以看出, LOF 以及 ANOMLOUS 由于浅层学习机制, 对高维数据的处理有一定困难, 结果不够理想。DOMINANT 和 COLA 分别作为基于重建和基于对比的深度学习异常检测经典模型, 相比前面的方法取得了较大的进步, 而 ANEMONE 以及 GRADATE 则基于对比的异常检测方案, 考虑了多种角度的对比方案, 进一步提升了异常检测的性能, 然而一方面全局信息缺乏或不够针对于异常检测, 另一方面随机游走进行采样的子图无法区别其对于目标节点的重要程度, 导致异常检测的结果并不理想。

而本文中提出的 DAMC-GAD 方法在 5 个基准数据集上的表现均优于其他 6 种基线方法, 这主要得益于该模型不仅通过目标节点的局部信息

来寻找全局信息获得增强图, 并且首次采用逐层采样来结合对比模型, 以此获取子图并区分重要性, 细化对比方法, 从而提高异常检测的性能。

针对模型边界值分析, 本文以 5 个数据集 (3 个合成异常数据集、2 个真实异常数据集) 作为模型不同的输入, 对模型在两类数据集上总体的边界值与各个数据集单独的边界值进行分析。首先是模型在两类数据集上的表现, 在合成异常数据集中, 表现最差与最好的分别为 EAT 和 Cora 数据集, 模型在合成异常数据集中 AUC 值的边界值为 84.09 与 92.44。在真实异常数据集中, 表现最差与最好的分别为 Books 和 Reddit 数据集, 故模型在真实异常数据集中 AUC 值的边界值为 58.01 与 63.29。虽然 DAMC-GAD 在两类数据集中边界值不同, 然而造成边界值上升的数据集特性一致, 根据表 1 中数据集统计信息可知, DAMC-GAD 与以往基于对比的异常检测模型 (ANOMONE、GRADATE) 相同, 在两类数据集中模型边界值均随着数据集节点数量与属性维度的增加而提升, 表明更多的节点样本与更高的属性维度可能更利于对比模型的检测性能。其中合成异常数据集效果普遍高于真实异常数据集, 表明合成异常更易被模型检测。

在最优参数下, 模型分别在 5 个数据集上 AUC 值的边界范围及误差如表 4 所示, 括号中数值为针对平均值的上下误差值, 可知 DAMC-GAD 在 5 个数据集的检测误差范围较小, 所有数据集上下边界误差范围均小于 0.1, 具有良好的稳定性。

表4 5 个数据集上 AUC 值的边界及误差范围
Table 4 Boundaries and margins of error for AUC values on the five datasets

数据集	最大值	最小值
EAT	84.49(+0.04)	83.59(-0.05)
UAT	84.66(+0.06)	84.57(-0.03)
Cora	92.51(0.07)	92.37(-0.02)
Books	59.01(+0.10)	57.90(-0.11)
Reddit	63.33(0.04)	63.24(-0.05)

4.3 消融实验

对于 DAMC-GAD 模型, 本文通过消融实验

研究了数据增强模块以及分层采样对于模型的影响。其实验结果如图3、表5所示。

本文在5个数据集上进行三组实验，分别为完整的DAMC-GAD模型以及去除数据增强（增强视图）或逐层采样的模型框架。可以发现，当去除其中任意一部分后，都会导致模型在所

有数据集上的性能下降，因此，本文提出的数据增强方式和逐层采样能有效提高各个数据集上的异常检测结果。其中，数据增强的效果最为明显，这得益于通过局部信息去连接距离更远的节点来构建增强视图，可以有效采样节点的全局信息来帮助异常检测模型。其中以EAT




图3 5个数据集上的消融实验ROC曲线比较

Figure 3 Comparison of ROC curves for ablation experiments on five datasets

数据集和 Cora 数据集最为显著, 分别降低了 8% 和 6%, 表明这两个数据集中节点的全局信息对异常检测的提升更为有效。另外, 逐层采样对各个数据集都有着一定的提升, 这得益于多角度对比模块中对采样子图的细化。同时表明根据采样子图的距离来判断其对于目标节点的重要性是可行的。

表 5 5 个数据集上的消融实验结果

Table 5 Results of ablation experiments on five datasets

方法	EAT	UAT	Cora	Books	Reddit
无数据增强	76.17	78.54	86.08	54.56	58.35
无逐层采样	79.73	80.21	89.73	54.65	56.96
DAMC-GAD	84.09	84.60	92.44	58.01	63.29

完整的 DAMC-GAD 模型结构实现了最佳性能, 验证了本文提出的基于数据增强的多角度对比图异常检测方案的有效性。

4.4 采样层数分析

为研究不同采样层数对模型的影响程度, 探究不同层子图对目标节点的重要性, 本文针对不同采样层数在 5 个数据集上分别进行实验。5 个数据集上的不同采样层数 AUC 值比较如图 4 所示。




图 4 5 个数据集上的不同采样层数 AUC 值比较

Figure 4 Comparison of AUC values for different sampling layers on five datasets

根据实验结果可知, 采样层数不大于 3 层时, 检测能力随着层数增加而增强, 且上升幅度依次下降。而当采样层数超过 3 层后, 检测能力逐渐降低, 表明子图重要程度随着采样层数增加而逐渐减少, 其中 3 层之内的子图对目标节点具

有一定重要性, 能帮助目标节点挖掘对应的相关子图信息, 超过 3 层的子图由于其重要性过低, 对目标节点的异常检测并没有帮助, 反而会使模型混淆重要信息, 造成性能下降。因此当采样层数超过 3 层时, 模型普遍无法取得最优性能。同时, 第一层采样子图在模型对目标节点的检测中最为重要, 这表明节点的异常程度大部分取决于节点与其邻域的相似程度, 这与以往基于对比的异常检测模型通过节点与其邻域的互信息进行异常检测相符。

5 结束语

为提高图异常检测的准确度, 本文聚焦以往基于对比的图异常检测模型在节点全局信息缺失和忽视子图对节点重要性不同的弊端, 提出一种基于数据增强的多视图对比图异常检测模型。本文首先提出一种根据局部信息去连接距离更远的相关节点构造增强视图的方法来获取全局信息, 然后首次结合对比模型和逐层采样并根据采样距离来划分子图对目标节点的重要性, 对多个数据集进行有效提升。完整的 DAMC-GAD 模型在 5 个数据集上与 6 种基线模型进行对比, 均取得了最优的结果, 验证了提出模型的有效性。

参考文献:

- [1] 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.
- [2] ZHAO T, JIANG T W, SHAH N, et al. A synergistic approach for graph anomaly detection with pattern mining and feature learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(6): 2393-2405.
- [3] 李忠, 靳小龙, 庄传志, 等. 面向图的异常检测研究综述[J]. 软件学报, 2021, 32(1): 167-193.
- [4] LI Z, JIN X L, ZHUANG C Z, et al. Overview on graph based anomaly detection[J]. Journal of Software, 2021, 32(1): 167-193.
- [5] 高国鹏, 房耀东, 韩彦芳, 等. 面向虚假新闻检测的社交媒体多模态数据集构建[J]. 网络与信息安全学报, 2023, 9(4): 144-154.
- [6] GAO G P, FANG Y D, HAN Y F, et al. Construction of multi-modal social media dataset for fake news detection[J]. Chinese Journal of Network and Information Security, 2023, 9(4): 144-154.
- [7] GORI M, MONFARDINI G, SCARSELLI F. A new model for learn-

- ing in graph domains[C]//Proceedings of 2005 IEEE International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2005: 729-734.
- [6] DING K Z, LI J D, BHANUSHALI R, et al. Deep anomaly detection on attributed networks[M]//Proceedings of the 2019 SIAM International Conference on Data Mining. Philadelphia, PA: Society for Industrial and Applied Mathematics, 2019: 594-602.
- [7] 袁非牛, 章琳, 史劲亭, 等. 自编码神经网络理论及应用综述[J]. 计算机学报, 2019, 42(1): 203-230.
- YUAN F N, ZHANG L, SHI J T, et al. Theories and applications of auto-encoder neural networks: a literature survey[J]. Chinese Journal of Computers, 2019, 42(1): 203-230.
- [8] FAN H Y, ZHANG F B, LI Z Y. Anomalydae: dual autoencoder for anomaly detection on attributed networks[C]//Proceedings of the ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE Press, 2020: 5685-5689.
- [9] SHAO M L, LIN Y J, PENG Q Y, et al. Learning graph deep autoencoder for anomaly detection in multi-attributed networks[J]. Knowledge-Based Systems, 2023, 260: 110084.
- [10] LI Y, HUANG X, LI J, et al. Specae: spectral autoencoder for anomaly detection in attributed networks[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. 2019: 2233-2236.
- [11] LIU Y X, LI Z, PAN S R, 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.
- [12] JIN M, LIU Y, ZHENG Y, et al. Anemone: graph anomaly detection with multi-scale contrastive learning[C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. 2021: 3122-3126.
- [13] DUAN J C, WANG S W, ZHANG P, et al. Graph anomaly detection via multi-scale contrastive learning networks with augmented view[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(6): 7459-7467.
- [14] ZHUANG Z, TING K M, PANG G S, et al. Subgraph centralization: a necessary step for graph anomaly detection[M]//Proceedings of the 2023 SIAM International Conference on Data Mining (SDM). Philadelphia, PA: Society for Industrial and Applied Mathematics, 2023: 703-711.
- [15] TONG H H, FALOUTSOS C, PAN J Y. Fast random walk with restart and its applications[C]//Proceedings of the Sixth International Conference on Data Mining (ICDM'06). Piscataway: IEEE Press, 2006: 613-622.
- [16] DING K Z, XU Z, TONG H H, et al. Data augmentation for deep graph learning[J]. ACM SIGKDD Explorations Newsletter, 2022, 24(2): 61-77.
- [17] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[EB]. arXiv Preprint arXiv: 1706.02216, 2017.
- [18] 张欣欣, 许力, 周赵斌. 社会网络中基于路径的社团划分方法[J]. 福建师范大学学报(自然科学版), 2023, 39(2): 35-40.
- ZHANG X X, XU L, ZHOU Z B. Path-based community detection method in social networks[J]. Journal of Fujian Normal University (Natural Science Edition), 2023, 39(2): 35-40.
- [19] SÁNCHEZ P I, MÜLLER E, LAFORET F, et al. Statistical selection of congruent subspaces for mining attributed graphs[C]//Proceedings of the 2013 IEEE 13th International Conference on Data Mining. Piscataway: IEEE Press, 2013: 647-656.
- [20] XU Z M, HUANG X, ZHAO Y, et al. Contrastive attributed network anomaly detection with data augmentation[C]//Proceedings of Pacific-Asia Conference on Knowledge Discovery and Data Mining. Cham: Springer, 2022: 444-457.
- [21] LI X W, SUN A T, ZHAO M K, et al. Multi-intention oriented contrastive learning for sequential recommendation[C]//Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2023: 411-419.
- [22] ZHAO W T, XU G P, CUI Z, et al. Deep graph structural infomax [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(4): 4920-4928.
- [23] PENG Z, HUANG W B, LUO M N, et al. Graph representation learning via graphical mutual information maximization[EB]. arXiv Preprint arXiv: 2002.01169, 2020.
- [24] ZHU Y Q, XU Y C, YU F, et al. Graph contrastive learning with adaptive augmentation[C]//Proceedings of the Web Conference 2021. New York: ACM, 2021: 2069-2080.
- [25] THAKOOR S, TALLEC C, AZAR M G, et al. Bootstrapped representation learning on graphs[C]//Proceedings of ICLR 2021 Workshop on Geometrical and Topological Representation Learning, 2021.
- [26] TOGNINALLI M, GHISU E, LLINARES-LÓPEZ F, et al. Wasserstein weisfeiler-Lehman graph kernels[EB]. arXiv Preprint arXiv: 1906.01277, 2019.
- [27] 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.
- [28] BREUNIG M M, KRIEGER 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.
- [29] PENG Z, LUO M N, LI J D, et al. ANOMALOUS: a joint modeling approach for anomaly detection on attributed networks[C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2018: 3513-3519.
- [30] LIU F Z, MA X X, WU J, et al. DAGAD: data augmentation for

graph anomaly detection[C]//Proceedings of the 2022 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE Press, 2022: 259-268.

- [31] LI X, XIAO C J, FENG Z L, et al. Controlled graph neural networks with denoising diffusion for anomaly detection[J]. Expert Systems with Applications, 2024, 237: 121533.

[作者简介]



李一凡 (2000-), 男, 湖南邵阳人, 福建师范大学硕士生, 主要研究方向为异常检测、图神经网络。



李家印 (1990-), 男, 山东济宁人, 博士, 福建师范大学讲师, 主要研究方向为安全联邦学习、人工智能安全。



林兴澎 (2001-), 男, 福建三平人, 福建师范大学硕士生, 主要研究方向为谣言检测、图神经网络。



戴远飞 (1992-), 男, 山东荣成人, 博士, 南京工业大学讲师, 主要研究方向为自然语言处理、知识图谱。



许力 (1970-), 男, 福建福州人, 博士, 福建师范大学教授、博士生导师, 主要研究方向为网络与信息安全、复杂系统建模与分析。