

极其弱监督场景下的小样本图异常检测

郑文捷¹⁾ 傅司超¹⁾ 陈嘉真²⁾ 彭勤牧¹⁾ 涂益群³⁾ 邹 斌⁴⁾
荆晓远⁵⁾ 尤新革¹⁾

¹⁾(华中科技大学电子信息与通信学院 武汉 430074)

²⁾(滑铁卢大学统计与精算系 滑铁卢 ON N2L G1 加拿大)

³⁾(华能武汉发电有限责任公司 武汉 430050)

⁴⁾(湖北大学数学与统计学学院 武汉 430062)

⁵⁾(武汉大学计算机学院 武汉 430072)

摘 要 近年来,小样本图异常检测在各个领域中引起了广泛的研究兴趣,其旨在少量有标记训练节点(支持集)的引导下去检测出大量无标记测试节点(查询集)中的异常行为。然而,现有的小样本图异常检测算法通常假设其可以从具有大量有标记节点的训练任务(元训练任务)中学习,从而有效地推广到具有少量标记节点的测试任务(元测试任务),这一假设并不符合真实世界的应用条件。在实际应用中,用于小样本图异常检测训练的元训练任务通常只包含极其有限的有标记节点,其标签占比通常不超过0.1%,甚至更低。由于元训练和元测试任务之间存在的巨大任务差异,现有的小样本图异常检测算法很容易出现模型的过拟合问题。除此之外,现有的小样本图异常检测算法仅利用节点间的一阶邻域(局部结构信息)来学习节点的低维特征嵌入,反而忽略了节点间的长距离依赖关系(全局结构信息),进而导致学习到的低维特征嵌入的不准确性和失真问题。针对上述挑战,本文提出了极其弱监督场景下的小样本图异常检测算法——EWS-FSGAD。具体来说,该方法首先提出了一个简单且有效的图神经网络框架——GLN(Global and Local Network),其能够同时有效地利用节点间的全局和局部结构信息,并进一步引入注意力机制实现节点间的信息交互,从而更加有效地学习节点鲁棒的低维特征嵌入;该方法还引入了图对比学习中的自监督重建损失,使得节点原始视图与其增强视图之间低维特征嵌入的互信息尽可能一致,为EWS-FSGAD模型的优化提供更多有效的自监督信息,进而提升模型的泛化性;为了提升模型在真实场景中小样本图异常检测任务的快速适应性,该方法引入跨网络元学习训练机制,从多个辅助网络学习可迁移元知识,为模型提供良好的参数初始化,从而能够在仅有很少甚至一个标记节点的目标网络上进行微调并有效泛化。在三个真实世界的数据集(Flickr、PubMed、Yelp)上的大量实验结果表明,本文所提方法的性能明显优于现有的图异常检测算法。特别是在PubMed数据集上,AUC-PR提升了28.8%~35.4%。这些实验结果强有力地证明了在极其有限标记的元训练任务引导下,本文所提方法能够更好地学习到异常节点本质特征,从而提升小样本图异常检测任务的有效性。

关键词 图异常检测;小样本学习;极其弱监督;图神经网络;图对比学习;长距离依赖关系

中图分类号 TP391

DOI号 10.11897/SP.J.1016.2025.00927

收稿日期:2024-08-19;在线发布日期:2025-02-19。本课题得到国家重点研发计划(2022YFF0712300)、中央高校基本科研业务费(YCJJ20241203)资助。郑文捷,博士研究生,主要研究领域为数据挖掘、图表示学习、小样本学习、类增量学习。E-mail: wenjie_zheng@zju.edu.cn。傅司超,博士研究生,主要研究领域为流形学习、图表示学习、小样本学习、类增量学习。E-mail: fusichao_hust@hust.edu.cn。陈嘉真,博士研究生,主要研究领域为数据挖掘、图表示学习、图异常检测。彭勤牧(通信作者),博士,副教授,主要研究领域为视觉计算、机器学习、医学图像分析。E-mail: pengqinmu@hust.edu.cn。涂益群,学士,主要研究领域为视觉计算、机器学习。邹斌,博士,教授,主要研究领域为统计学习理论、机器学习。荆晓远,博士,教授,中国计算机学会(CCF)专业会员,主要研究领域为机器学习、人工智能、软件工程。尤新革,博士,教授,中国计算机学会(CCF)高级会员,主要研究领域为模式识别、图像与信号处理、视觉计算、生物特征识别与智能防伪。

Few-Shot Graph Anomaly Detection with Extremely Weak Supervision

ZHENG Wen-Jie¹⁾ FU Si-Chao¹⁾ CHEN Jia-Zhen²⁾ PENG Qin-Mu¹⁾ TU Yi-Qun³⁾
ZOU Bin⁴⁾ JING Xiao-Yuan⁵⁾ YOU Xin-Ge¹⁾

¹⁾(School of Electronic Information and Communications, Huazhong University of Science and Technology, Wuhan 430074)

²⁾(Department of Statistics and Actuarial Science, University of Waterloo, Waterloo ON N2L 3G1, Canada)

³⁾(Huaneng Wuhan Power Generation Co. Ltd., Wuhan 430050)

⁴⁾(Faculty of Mathematics and Statistics, Hubei University, Wuhan 430062)

⁵⁾(School of Computer Science, Wuhan University, Wuhan 430072)

Abstract In recent years, few-shot graph anomaly detection (FS-GAD) has received extensive research interest across various applications, which aims to distinguish anomalous patterns of abundant unlabeled test nodes (query set) under the guidance of a few labeled training nodes (support set). Nevertheless, the existing FS-GAD methods often assume that they can learn meta-knowledge from training tasks (meta-training tasks) with abundant labeled nodes, and then effectively generalize to testing tasks (meta-test tasks) with a few labeled nodes. This assumption does not fit with real-world applications. In real-world applications, the meta-training tasks for FS-GAD training usually contain only extremely limited labeled nodes, whose proportion of labels usually does not exceed 0.1% or even less. Owing to the large task difference between meta-training and meta-testing tasks, the existing FS-GAD methods are more prone to overfitting problems. In addition, the existing FS-GAD methods only utilize the first-order neighborhood (local structure information) between nodes to learn their low-dimensional node feature embedding, while ignoring the long-range dependencies (global structure information) between nodes, leading to the inaccuracy and distortion of the learned low-dimensional node feature embeddings. In this paper, an effective few-shot graph anomaly detection framework with extremely weak supervision is proposed, termed EWS-FSGAD, to solve the above-mentioned issues. Specifically, a simple and effective graph neural network module~Global and Local Network (GLN) is first proposed to more effectively learn robust low-dimensional node feature embeddings, which simultaneously utilizes the global and local structural information between nodes and also introduces the attention mechanism to realize the information interaction between nodes. And then, we introduce self-supervised reconstruction loss in graph contrast learning to maximize the mutual information between low-dimensional node feature embeddings from the original view and the augmented view, which can provide more effective self-supervised information for model optimization and also further improve the generalization of the proposed EWS-FSGAD. To improve the effectiveness of the proposed EWS-FSGAD method in real-world applications, we introduce the cross-network meta-learning training mechanism to learn transferable meta-knowledge from multiple auxiliary networks and provide good parameters initialization for the proposed EWS-FSGAD model, so that it can quickly adapt to the target network by performing fine-tuning on a few or even one labeled node. Finally, extensive experiments on three real-world benchmarks (Flickr, PubMed, and Yelp) show that the proposed EWS-FSGAD achieves state-of-the-art performance in comparison to the existing graph anomaly detection models. For example, AUC-PR improves by 28.8%~35.4% on the PubMed dataset. These results strongly demonstrate that the proposed EWS-FSGAD can better learn the essential characteristics of abnormal nodes under the guidance of an extremely limited meta-training support set, and further improve the effectiveness of FS-GAD tasks.

Keywords graph anomaly detection; few-shot learning; extremely weak supervision; graph neural networks; graph contrastive learning; long-range dependency relationships

1 引言

随着互联网技术的飞速发展,世界万物互联互通,各种实体之间的多元化作用关系日益显现,图作为一种强大的数据结构,能够有效地建模这些复杂的关系。在许多实际应用场景中,图数据及其衍生的属性网络已广泛应用于社会各个领域。从社交网络^[1]到引文网络^[2],从金融风控^[3]到电子商务^[4],图数据已经深入到现实生活的方方面面。作为图数据的一种重要形式,属性网络不仅描述了节点之间的连接关系,还包含丰富的节点属性信息。这些属性信息可能包含用户兴趣、文章主题、金融交易金额等,为数据分析和挖掘提供了更加丰富的信息维度。

在实际应用的属性网络数据中,往往存在由少数异常节点引起的数据污染,这些节点在行为模式上与大多数节点存在显著差异,并受到网络静态结构的影响。这些异常节点在属性特征和连接模式上均表现出显著偏离正常节点的异常行为,可能涉及欺诈、恶意软件、网络攻击或系统故障等现象。以引文网络为例,有些论文可能会引用与其内容不符的虚假参考文献^[5];在社交网络中,可能存在伪装用户随机关注其他用户的现象^[6]。这些异常现象不仅威胁属性网络的可信度和稳定性,还可能带来严重的经济损失和社会不安。因此,图异常检测(Graph Anomaly Detection, GAD)在当今社会的重要性日益凸显。通过GAD,可以及时发现并处理这些异常,从而确保属性网络的健康发展与正常运行。

现有的GAD算法大致可以划分为三种主流范式:无监督GAD、半监督GAD和小样本GAD(Few-shot Graph Anomaly Detection, FS-GAD)。无监督GAD方法仅使用无标记数据进行训练,不依赖任何标记信息,旨在通过数据的模式和规律识别异常节点,进而有效地区分正常节点和异常节点。半监督GAD方法则结合少量标记数据和大量未标记数据,通过少量监督信息来指导模型并提升其对已知类的异常模式的检测能力。FS-GAD方法则专注于标记样本有限的场景,旨在通过有限样本快速适应并泛化到新的异常检测任务或类别上。

无监督GAD方法可划分为生成式和对比如式两大类。生成式GAD方法主要通过自编码器对图数

据进行重构,并根据节点的重构误差来计算异常分数^[7-9]。例如,DOMINANT^[7]结合图卷积网络(Graph Convolution Networks, GCN)^[10]和自编码器,通过节点的重构误差,从结构和属性两个角度计算异常分数,进行异常检测。对比式GAD方法则主要使用鉴别器来评估目标节点与其邻居之间的一致性,从而进行异常评估^[11-14]。例如,CoLA^[13]通过GCN学习节点嵌入,评估节点与邻居子结构之间的一致性,并基于多轮预测得分进行异常性评估。虽然无监督GAD方法简单有效,但是由于缺乏异常类的先验知识,其识别的异常可能是数据噪声或无意义的样本。解决这一问题的一个方案是,利用少量标记的异常数据作为先验知识来学习已知异常模式的模型。

半监督GAD方法的代表性工作如下所示: SemiGNN^[15]利用分层注意力机制关关节点的不同邻域和视图;DeepSAD^[16]通过无监督方式学习数据的分布,并利用少量有标记的异常样本指导模型学习异常模式;SADAG^[17]将正常节点和异常节点分别嵌入超球面内外,并通过计算节点嵌入与球面中心的距离来检测异常。尽管半监督GAD方法借助少量标记数据和大量无标记数据提升了GAD的准确性,但在标记样本极其有限的情况下,这些方法通常无法达到理想结果。这主要是因为它们往往依赖于相对较多的标记样本^[18]。

在实际应用中,标记异常数据的过程异常繁重且需要大量的专业领域知识,这使得大规模有标记训练样本的获取既昂贵又极具挑战性^[19],这也是基于有监督学习的传统异常检测方法难以应对的问题。在此背景下,FS-GAD应运而生。FS-GAD旨在通过利用少量标记训练节点(支持集)来训练模型,从而识别大量未标记测试节点(查询集)中的异常行为,进而解决标记获取困难和耗时的现实挑战,并能够应对数据稀疏、标签不平衡等实际应用中的挑战。近年来,FS-GAD已经引起了众多机器学习和深度学习研究者的广泛关注。由于我们通常只能获得包含有限监督信息的图数据,因此用于FS-GAD的元训练任务往往只包含有限数量的有标记节点。因此,如何设计出更加有效地适用于有限监督信息图数据的FS-GAD模型仍然是一个巨大挑战。

FS-GAD方法的代表性工作如下所示:Meta-GDN^[20]提出了图偏差网络(Graph Deviation Networks, GDN),其通过偏差损失实现端到端训练,并引入跨网络元学习的训练方式,通过在多个辅助网络上积累元知识,并将其迁移到目标网络,从而显著提升了异常检测的有效性。这一方法为本文的研究提供了启示。ANEMONE-FS^[21]则结合了局部级别和上下文级别的图对比学习损失,以捕获节点的异常模式,并引入有限的标记样本构成额外的正负样本对,充分利用了宝贵的监督信息。FMGAD^[22]通过自监督对比学习来捕获结构化表示,并利用Deep-GNN消息增强模块,利用少量标记节点的信息实现长距离传播,有效扩散监督信号,从而提升异常检测的性能。

尽管现有的FS-GAD算法取得了一定进展,但它们通常假设可以从包含大量有标记节点的训练任务(元训练任务)中学习可迁移的元知识,并将这些元知识应用于仅包含少量标记节点的测试任务(元测试任务)中。然而,在实际场景中,由于采集大规模标记训练样本极其困难,用于模型训练的元训练任务通常只包含极少量的标记节点。标记节点越多,异常模式越多样化,领域知识也越丰富。因此,现有的FS-GAD算法在具有大量有标记节点的元训练任务中积累的领域知识比元测试任务更加丰富。这种元训练和元测试任务之间巨大的差异(标记节点的数量和领域知识的丰富程度)严重影响了现有FS-GAD算法的性能。

基于上述分析,本文发现,无监督GAD方法过度依赖异常类分布的假设,缺乏对异常类的先验知识,导致其识别的异常行为不够准确。半监督GAD方法尽管能够利用有限的已知类异常,但其推广到未知类异常的能力受到标记样本数量的限制,需要较大比例的标记样本才能实现良好的泛化性能。相比之下,FS-GAD方法通过有限的标记样本获取异常类的先验知识,能够在有限标记样本的条件下实现未知类异常的高效适应和泛化,因此其更具优势。尽管现有的FS-GAD工作已有一定进展,但在模型训练时,通常假设训练任务(元训练任务)基于公开的、标记良好的图数据集,其包含大量有标记的节点。然而,这一假设在现实场景中往往难以成立。图数据的标注通常需要大量的人力、物力和领域专业知识,且异常节点本身极为稀少^①。因此,在实际场景中,能够获取的标记样本极其有限^[23]。例如,在网络攻击数据集UNSW-NB15^[23]中,某类攻

击的标记比例甚至低于0.05%。这一现象表明,在实际的FS-GAD场景中,可用于模型元训练的元训练任务通常仅包含极其有限的标记节点,其比例通常不超过0.1%,甚至更低,导致监督信息极其受限(极其弱监督场景)。由于每个元训练类别(异常节点和正常节点)的标记节点极其有限,这将严重影响元学习范式中学习可迁移元知识的有效性。除此之外,本文通过广泛调研发现,现有FS-GAD方法在学习节点低维特征嵌入的过程中,主干网络通常仅采用简单的GCN,且层数较少,通常仅为一到两层,导致模型在学习节点低维特征嵌入时仅仅考虑了节点间的局部结构信息,而未充分利用节点间的全局结构信息。由于异常节点通常在图数据中呈随机分布,长距离信息的传播对于FS-GAD至关重要。因此,如何在这些异常节点之间实现有效的信息交互,成为解决异常检测问题的另一个关键挑战。

为应对上述挑战,本文提出了一种适用于极其弱监督场景的小样本图异常检测算法,即EWS-FSGAD(Few-shot Graph Anomaly Detection with Extremely Weak Supervision),旨在更加有效地解决现实场景中的FS-GAD任务。具体而言,EWS-FSGAD首先设计了一种新颖且通用的图神经网络框架,称为全局-局部网络(Global and Local Network, GLN)。GLN采用两路并行策略来学习节点的低维特征嵌入。在每一层中,一路采用频率自适应的图扩散卷积(Frequency Adaptive Graph Diffusion Convolution, FA-GDC)专注于捕获节点间的全局结构信息,另一路则采用GCN专注于捕获节点间的局部结构信息。相比于现有的图扩散卷积(Graph Diffusion Convolution, GDC)^[24],本文所提出的FA-GDC模块能够自适应地生成适应于当前数据频率特性的图滤波器,从而更准确地捕获不同节点的高低频信息。接着,在不同的图卷积层之间,本文进一步引入了注意力机制,以实现节点间全局信息和局部信息的交互融合,进而更有效地学习节点鲁棒的低维特征嵌入。相比于现有的图表示学习方法,GLN能够自适应地实现节点全局和局部特征之间的信息交互,显著提升了融合特征的鲁棒性;为进一步克服标记样本稀缺性带来的困难,EWS-FSGAD还引入了图对比学习中的自监督重建损失。该损失促使节点在原始视图和经过图增强的增强视图上得到的节点低维特征

① <https://www.kaggle.com/datasets/mlg-ulb/creditcardfraud>

嵌入间的互信息尽可能最大化,从而为EWS-FSGAD模型提供更多有效的自监督信息,并使得模型学习到更具代表性的节点低维特征嵌入,进而提升其泛化能力;为进一步提升EWS-FSGAD在真实场景中执行FS-GAD任务的有效性,本文采用了跨网络元学习的训练方式,其能够从多个辅助网络中检测异常以提取全面的可迁移元知识,为模型提供良好的参数初始化,从而使得模型能够在极少量甚至仅有单个标记样本的情况下,经过少量训练轮次(Epoch)的微调,迅速适应目标

网络。在三个真实世界的数据集(Flickr、PubMed、Yelp)上的大量实验表明,相比于现有的GAD算法,EWS-FSGAD均取得了最优性能。具体而言,EWS-FSGAD在AUC-ROC指标上分别提升了3.3%、4.4%、5.7%。特别是在PubMed数据集上,AUC-PR值提升了28.8%~35.4%。这些实验结果证明了在极其有限的元训练任务的指导下,EWS-FSGAD能够更有效地学习异常节点的本质特征,从而显著提升FS-GAD任务的有效性。

表1 本文主要使用的专业术语汇总

中文名称	英文全称	英文缩写
图异常检测	Graph Anomaly Detection	GAD
小样本图异常检测	Few-shot Graph Anomaly Detection	FS-GAD
多层感知机	Multi-layer Perceptron	MLP
图神经网络	Graph Neural Networks	GNN
图偏差网络	Graph Deviation Networks	GDN
图卷积网络	Graph Convolution Networks	GCN
全局-局部网络	Global and Local Network	GLN
图扩散卷积	Graph Diffusion Convolution	GDC
自适应扩散卷积	Adaptive Diffusion Convolution	ADC
频率自适应的图扩散卷积	Frequency Adaptive Graph Diffusion Convolution	FA-GDC
有监督学习	Supervised Learning	—
弱监督学习	Weakly Supervised Learning	—
图弱监督学习	Graph Weakly Supervised Learning	—
缩放点积注意力	Scaled Dot-product Attention	—
偏差损失	Deviation Loss	—
图增强	Graph Augmentation	—
跨网络元学习	Cross-network Meta-learning	—

本文工作的主要贡献总结如下:

(1)根据我们所知,本文是首个尝试研究并解决在极其缺乏标注数据情况下的小样本图异常检测问题的的工作。

(2)本文在极其弱监督的场景下提出了一种简单且有效的小样本图异常检测算法。首先,设计了一个新颖且通用的图神经网络框架,结合图扩散卷积与图卷积网络,能够同时捕捉节点间的全局和局部结构信息,并进一步引入注意力机制以实现节点间的信息交互,从而更加有效地学习节点的低维特征嵌入;除此之外,本文还引入了图对比学习中的自监督重建损失,通过最大化节点在原始视图和经过图增强的增强视图上得到的节点低维特征嵌入的互信息,为模型优化提供更多有效的自监督信息,进一步提升了模型的泛化能力;最后,该方法采用跨网络元学习的训练模式,通过从多个辅助网络中学习可

迁移的元知识,使其能够通过微调快速适应目标网络。

(3)通过一系列实验,本文验证了所提方法的有效性,并设计了消融实验,以进一步验证在学习节点低维特征嵌入中利用全局和局部结构信息以及引入注意力机制进行信息交互的关键性。实验结果表明,这些因素与自监督重建损失相结合,显著提升了小样本图异常检测任务的性能。

本文的结构安排如下:第2节回顾了EWS-FSGAD的相关工作,包括图神经网络和图弱监督学习领域的概述。第3节详细介绍了本文提出的EWS-FSGAD模型的总体框架,以及各个模块的设计与功能。第4节深入分析了实验结果,探讨了本文方法的性能表现及其与现有方法的比较。最后,第5节总结了本文的研究工作。

2 相关工作

在本节中, 本文将从以下方面回顾 EWS-FSGAD 的相关工作: (1) 图神经网络、(2) 图弱监督学习。同时, 本文在表 1 中对主要使用的专业术语的中文名称、英文全称及英文缩写进行了汇总和说明。

2.1 图神经网络

近年来, 深度学习算法在多个实际应用中取得了显著成果, 如计算机视觉中的图像分类^[25], 自然语言处理中的机器翻译^[26], 医学影像分析^[27]以及智能推荐系统^[28]等。然而, 现有的深度学习方法在处理具有复杂交互关系的图数据时存在局限性, 主要原因是传统深度神经网络的特征提取方法不适用于图数据的非线性和不规则性。值得注意的是, 图数据广泛存在于社交网络、蛋白质互作网络、交通网络等实际场景中, 因此, 如何有效地处理图数据成为现实应用中的关键挑战。为应对这一挑战, 图神经网络(Graph Neural Networks, GNN)^[29-30]应运而生, 并因其强大的图数据建模能力而获得了广泛关注和成功应用。

现有的 GNN 算法大致分为两类: 基于谱域(Spectral-based)的方法和基于空域(Spatial-based)的方法。谱域方法利用图数据的特征值和特征向量设计信号滤波器, 有效分析图数据并实现节点和图的表示学习。代表性工作包括: ChebNet^[31]利用拉普拉斯矩阵特征值对角矩阵的 Chebyshev 多项式逼近图滤波器。CayleyNet^[32]应用参数化的 Cayley 多项式捕获节点的窄频带信息。GCN^[10]通过引入 ChebNet 的一阶近似, 简化了谱图卷积, 桥接了谱域和空域方法。AGCN^[33]通过学习图中的隐藏结构关系, 通过一个可学习的距离函数来构造残差图邻接矩阵。DualGCN^[34]引入双重图卷积架构, 包含两个并行的图卷积层。

空域方法则通过节点之间的邻居关系和局部信息传播来实现节点的表示学习, 并通过迭代聚合邻居节点信息完成各种任务。代表性工作包括: MPNN^[35]将图卷积视为消息传递过程, 使信息可以沿着边在节点间传播。GraphSAGE^[36]通过采样为节点获取固定数量的邻居节点。GAT^[37]集成了注意力机制^[38], 赋予邻居节点不同的权重。GIN^[39]通过求和聚合函数确保 GNN 与 Weisfeiler-Lehman 图同构检验相同的性能。Graph-BERT^[40]借鉴 BERT^[26]的注意力机制, 避免了传统图卷积操作, 简化了模型并提高学习效率。NGNN^[41]通

过局部子图池化来学习全图表示。CGNN^[42]利用图曲率量化节点对之间的结构连接强度, 增强局部自适应性能力。Ordered GNN^[43]通过树形层次结构嵌入节点, 解决了异质性和过度平滑问题。

2.2 图弱监督学习

尽管有监督学习(Supervised Learning)在多个领域取得了显著成功, 但在许多实际应用中, 由于数据标注成本高昂, 难以获得完整的标签信息。为解决这一问题, 弱监督学习(Weakly Supervised Learning)应运而生^[44]。传统的弱监督学习方法^[44]大致可分为三类: (1) 不完全监督(Incomplete Supervision), 即部分数据有标签。例如, 文献[45]通过教师模型为无标注数据生成伪标签, 并为不完全标注的数据补充缺失标签; (2) 不确切监督(Inexact Supervision), 即数据具有粗粒度标签。例如, 文献[46]通过定位图像上每个类别的峰值响应区域, 实现了自动标记实例分割; (3) 不精确监督(Inaccurate Supervision), 即数据的标签不完全准确。例如, 文献[47]将图像分割成一组超像素, 将有噪声的图像级标签传播到超像素级, 生成高噪声标签。

然而, 随着数据结构的日益复杂化, 传统弱监督学习方法面临着巨大的挑战。因此, 图弱监督学习(Graph Weakly Supervised Learning)领域的研究显得尤为重要。例如: GFL^[48]基于图迁移学习, 利用从辅助图中学习的先验知识来提升目标图数据的分类精度。Meta-GHN^[19]基于图标签去噪和元学习, 从弱标记数据中生成干净的节点表示, 并提取可迁移的元知识, 使模型能够快速适应包含少量标记样本的未知任务。Meta-PN^[49]基于图自训练, 通过标签传播策略, 在未标记的节点上推断伪标签, 增加了标记数据并扩展了感受野。X-FNC^[50]基于元学习, 通过泊松标签传播生成伪标签, 并应用信息瓶颈理论微调模型, 解决了极其弱监督场景下的小样本节点分类问题。

尽管现有的图弱监督学习方法已取得了一定进展, 但大多数方法无法直接应用于 FS-GAD 任务。因此, 在极其弱监督场景下, 如何设计更有效的图弱监督学习模型以解决 FS-GAD 任务, 仍然是一个亟待解决的问题。

3 方法

在本节中, 我们将详细介绍本文提出的在极其弱监督场景下的小样本图异常检测框架 EWS-

FSGAD。EWS-FSGAD算法的总体框架如图1所示,流程概括如下:首先,在模型的元训练阶段,给定一个用于构建元训练任务的包含极其有限标记节点和大量未标记节点的输入图(辅助网络),通过采样分别构建元训练支持集和测试集(详见第3.5节)。然后,通过图增强技术(随机掩蔽图上的边和节点)生成其增强视图。接着,分别使用两个具有不同参数的 GLN_θ 和 GLN_ϕ 模型,学习原始视图及其增强视图中的节点表示(详见第3.2节)。随后,使用分类器

计算支持集中节点在原始视图中的异常得分,并由此计算偏差损失 \mathcal{L}_D (详见第3.3节)。与此同时,通过预测器重建查询集中节点在原始视图中的表示,并利用余弦相似度计算其与增强视图中对应节点表示的重建损失 \mathcal{L}_R (详见第3.4节)。最后,通过跨网络元学习技术进行模型训练,从而优化模型参数。完成元训练之后,在元测试阶段,模型将在目标网络上通过少量标记节点进行微调,并计算未标记节点的异常得分,从而完成模型测试(详见第3.5节)。

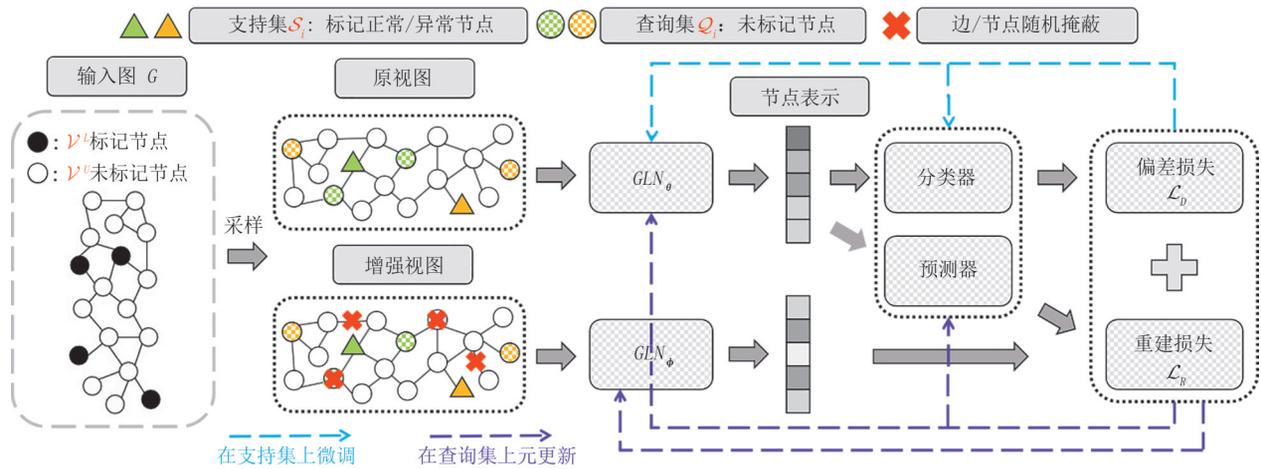


图1 EWS-FSGAD算法的总体框架

3.1 问题定义

在本文中,我们将图表示为 $G=(\mathbf{A}, \mathbf{X})$ 或 $G=(\mathcal{V}, \mathcal{E}, \mathbf{X})$ 。节点属性矩阵表示为 $\mathbf{X}=[x_1^T, x_2^T, \dots, x_N^T] \in \mathbb{R}^{N \times d}$,其中 \mathbf{x}_i 表示节点 v_i 的属性向量,反映了节点 v_i 在图 G 中所包含的各种特征或性质, N 表示节点的数量, d 表示节点特征的维度。图的邻接矩阵表示为 $\mathbf{A}=\{0, 1\}^{N \times N}$ 。具体来说, $A_{i,j}=1$ 表示节点 v_i 和节点 v_j 之间存在一条边, $A_{i,j}=0$ 则表示不存在边。 \mathcal{V} 表示节点集合,即 $\{v_1, v_2, \dots, v_N\}$ 。 \mathcal{E} 表示边的集合,即 $\{e_1, e_2, \dots, e_M\}$ 。

本文假设 $\mathcal{V}=\{\mathcal{V}^L, \mathcal{V}^U\}$,其中 \mathcal{V}^L 包含少量标记的异常和正常节点,而 \mathcal{V}^U 包含所有未标记的节点。在我们的工作中,假设 $|\mathcal{V}^L| \ll |\mathcal{V}^U|$ 以模拟真实应用中的极其弱监督场景。具体来说,在极其弱监督场景中,我们通常仅能获取包含极少数标记节点(例如, $|\mathcal{V}^L|=10$)的元训练任务,并且其标签占比通常不超过0.1%,甚至更低(即 $|\mathcal{V}^L|/|\mathcal{V}^U| < 0.1\%$)。EWS-FSGAD方法旨在学习一个异常检测模型,该模型能够在 \mathcal{V}^L 中支持集的指导下,为 \mathcal{V}^U 中查询集的异常节点赋予比正常节点更高的异常得分,从而

有效完成FS-GAD任务。

3.2 网络编码器GLN

现有的GAD研究在学习节点表示时通常仅使用一到两层的GCN层,这种方式往往只关注节点间的局部结构信息,忽略了对于GAD任务至关重要的全局结构信息。为了更有效地学习节点的鲁棒特征表示,本文提出了一种新颖且通用的GNN架构,称为GLN,其网络架构如图2所示。从图2中可以看出,GLN由四个关键模块组成:GCN层、FA-GDC层、交叉注意力机制和自适应加权聚合模块,其中前三者构成了单层的GLN。下面将详细介绍针对输入图 $G=(\mathbf{A}, \mathbf{X})$,GLN如何通过这些模块来学习鲁棒的节点表示 \mathbf{Z} 。

GCN层:作为GLN层的一条支路,GCN层专注于捕获节点间的局部结构信息。本文遵循文献[10]中的GCN信息传播过程与更新函数,在第 l 层GLN中,经过GCN层处理后,可以得到

$$\tilde{\mathbf{H}}_{loc}^{(l)} = \sigma \left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}_{loc}^{(l-1)} \mathbf{W}_{loc}^{(l)} \right) \quad (1)$$

其中, $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$ 表示输入图带有自环的邻接矩阵,

\mathbf{I}_N 是单位矩阵; $\tilde{\mathbf{D}}$ 是对应的度矩阵, $\tilde{\mathbf{D}}_{ii} = \sum_j \tilde{\mathbf{A}}_{ij}$;

$\mathbf{H}_{loc}^{(l-1)} \in \mathbb{R}^{N \times h^{(l-1)}}$ 表示第 $l-1$ 层 GLN 输出的局部隐层特征矩阵, $h^{(l)}$ 是第 l 层的隐层维度, 在模型输入端有 $\mathbf{H}_{loc}^{(0)} = \mathbf{X}$; $\mathbf{W}_{loc}^{(l)} \in \mathbb{R}^{h^{(l-1)} \times h^{(l)}}$ 是可学习的权重参数矩阵; $\sigma(\cdot)$ 是非线性激活函数, 在本文中我们采用的是 ReLU 激活函数。由于 GCN 层直接从节点的一阶邻域中聚合信息并更新节点表示, 因此, 它有助于 GLN 专注于捕获节点之间的局部结

构信息。

局部结构信息指的是节点与其直接邻居节点之间的连接关系和特征模式, 这些直接相连的节点通常在图中表现出较强的相似性或关联性。在 GAD 中, 异常节点往往与其正常邻居在连接模式或特征上存在显著差异。通过分析局部结构差异, 能够有效捕捉这些差异, 从而判定节点是否异常。即使在标记节点极其有限的情况下, 局部结构仍然能够提供关于其他节点的重要信息。

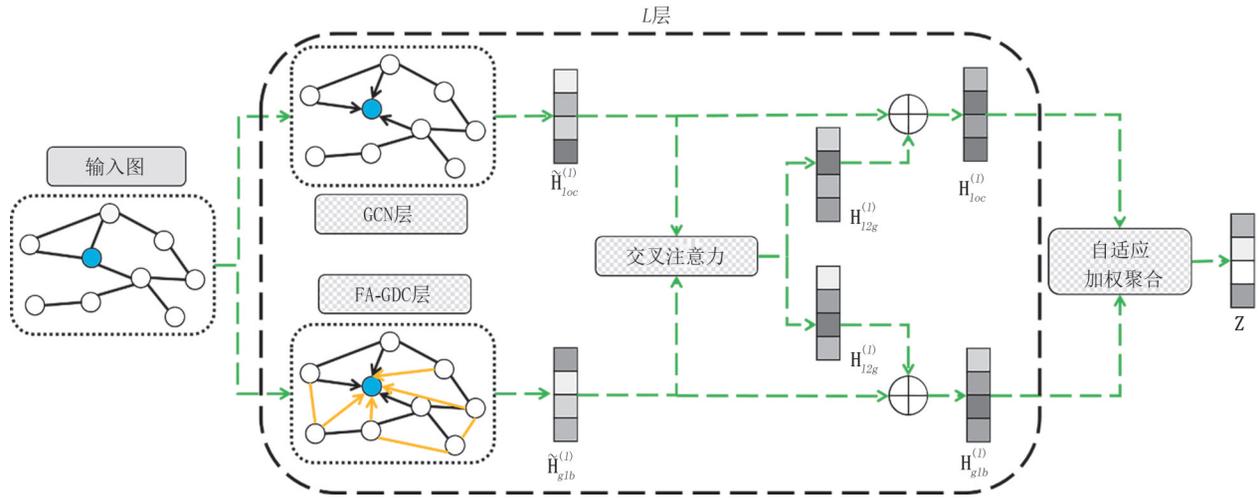


图2 GLN网络架构示意图

FA-GDC层: 作为GLN层的另一条支路, FA-GDC层专注于捕获节点间的全局结构信息。GDC^[24]首次将图扩散卷积定义为

$$S = \sum_{k=0}^{\infty} \theta_k \mathbf{T}^k \quad (2)$$

其中, θ_k 是权重系数, 现有的方法^[51]通常采用热核 (Heat Kernel) 系数 $\theta_k^{HK} = e^{-t} \frac{t^k}{k!}$; \mathbf{T} 是转移矩阵, 通常选择对称转移矩阵 $\mathbf{T}_{sym} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}$ 。

为了简化 GDC 超参数调试的复杂性, ADC^[52] (Adaptive Diffusion Convolution) 对其进行了改进。具体而言, ADC 将图扩散精确到每个 GNN 层的每个特征通道, 其每一层的信息传播函数可以表示为

$$\mathbf{H}_i^{(l)} = \sum_{k=0}^{\infty} \theta_{ki}^{(l)} \mathbf{T}^k \mathbf{H}_i^{(l-1)} \quad (3)$$

其中, $\mathbf{H}_i^{(l)}$ 表示第 l 层的隐层特征矩阵 $\mathbf{H}^{(l)}$ 的第 i 列, 即第 i 个特征通道, $i=0, 1, \dots, h^{(l-1)}-1$; $\theta_{ki}^{(l)}$ 是可学习的权重系数, 表示在信息传播过程中, 第 l 层第 i 个特征通道的 k 阶邻域的权重系数, 并且满足 $\theta_{ki}^{(l)} > 0$ 且 $\sum_{k=0}^{\infty} \theta_{ki}^{(l)} = 1$ 。

虽然 ADC 显著提升了 GDC 的性能, 但其对 $\theta_{ki}^{(l)} > 0$ 的限制带来了一个更加严重的问题: ADC 所学习的权重系数导致其在频域上表现为低通滤波器的特性。除此之外, 文献[53]中表明, GCN 以及现有的大多数 GNN 方法在频域上也具有低通滤波器的特性。尽管这一特性有助于保留节点特征之间的共性, 但如文献[54]所指出, 它却忽略了节点特征之间的差异。因此, 当模型始终采用低通滤波器时, 学习到的节点特征表示会变得难以区分。一些研究^[55-56]已经证明, 图信号中的高频信息对于增强模型的判别能力至关重要, 尤其是在网络存在不协调性时。在 GAD 任务中, 由于异常节点通常随机分布在图的各个位置, 并且其行为显著偏离周围节点, 表现出极强的不协调性, 其信号特征在谱域中表现出高度振荡, 包含大量高频信息。因此, 亟需设计一种能够自适应调整频率特性的图卷积层, 以精确捕获异常节点的高频信息。

文献[56]指出, 当公式(2)中的权重系数 $\theta_k = (-\alpha)^k$ 且 $\alpha \in (0, 1)$ 时, GNN 模型表现出高通滤波器的特性。这表明, 当 θ_k 可以取负值时, GNN 模型将具

备高通滤波的性质,从而更加突出异常节点的特征,并有效抑制噪声和冗余信息,进而提升模型的准确性和鲁棒性。受此启发,本文提出了FA-GDC,通过移除ADC中 $\theta_{ki}^{(l)} > 0$ 的限制,即令 $\theta_{ki}^{(l)} \in (-1, 1)$ 。这样,FA-GDC不仅能够有效捕获节点间的全局结构信息,还可以通过学习灵活的权重系数 $\theta_{ki}^{(l)}$ 自适应地调节其频率特性,从而精准捕获异常节点的高频信息。同时,FA-GDC与另一条支路GCN互为补充,后者主要用于捕获节点的低频信息。

通过设计具有高通性质的图卷积层FA-GDC来捕获节点的高频信息,在元训练任务的标记节点极其缺乏的FS-GAD场景下,其必要性体现在两个方面:一方面,FA-GDC能够突出节点的显著特征,使得从有限样本中提取的特征更加有效和具有区分性;另一方面,FA-GDC有助于减少低频噪声或常规模式对异常检测结果的干扰,使模型更加专注于捕获与异常相关的特征。

在第 l 层GLN中,通过FA-GDC我们可以得到:

$$\begin{aligned} [\bar{\mathbf{H}}_{glb}^{(l)}]_i &= \sigma \left(\sum_{k=0}^{\infty} \theta_{ki}^{(l)} \left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \right)^k [\mathbf{H}_{glb}^{(l-1)}]_i \right) \\ \tilde{\mathbf{H}}_{glb}^{(l)} &= \bar{\mathbf{H}}_{glb}^{(l)} \mathbf{W}_{glb}^{(l)} \end{aligned} \quad (4)$$

其中, $\mathbf{H}_{glb}^{(l-1)} \in \mathbb{R}^{N \times h^{(l-1)}}$ 表示第 $l-1$ 层GLN输出的全局隐层特征矩阵,在模型的输入端有 $\mathbf{H}_{glb}^{(0)} = \mathbf{X}$; $\mathbf{W}_{glb}^{(l)} \in \mathbb{R}^{h^{(l-1)} \times h^{(l)}}$ 是可学习的权重参数矩阵; $\theta_{ki}^{(l)} \in (-1, 1)$ 是可学习的权重系数; $[\mathbf{H}_{glb}^{(l-1)}]_i$ 表示 $\mathbf{H}_{glb}^{(l-1)}$ 的第 i 列,即第 i 个特征通道, $i = 0, 1, \dots, h^{(l-1)} - 1$ 。由于求和到无穷项在现实中无法实现,因此,本文遵循ADC^[52]中的做法,使用前 M 项来近似FA-GDC层。公式(4)可以进一步表示为

$$\begin{aligned} [\bar{\mathbf{H}}_{glb}^{(l)}]_i &= \sigma \left(\sum_{k=0}^M \theta_{ki}^{(l)} \left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \right)^k [\mathbf{H}_{glb}^{(l-1)}]_i \right) \\ \tilde{\mathbf{H}}_{glb}^{(l)} &= \bar{\mathbf{H}}_{glb}^{(l)} \mathbf{W}_{glb}^{(l)} \end{aligned} \quad (5)$$

这种近似的合理性在于,通过公式(4)提取节点的全局结构信息并使用 $\tilde{\mathbf{A}}^k$ 进行计算时,当前节点仅与其 k 阶邻居节点进行信息传播与聚合。根据“六度分割理论”,一个节点最多与其六阶邻居节点进行信息传播即可获取其在图上的全局结构信息,因此本文无须将公式(4)的求和扩展至无穷项。出于稳定性考虑,本文在后续实验中将 M 设置为10。

全局结构信息包括整个图的拓扑结构和节点之间的关联,在GAD中用于识别那些与图整体结构

显著不同的节点。在标记节点极其有限的情况下,全局结构信息尤为重要,因为它基于整个图的统计特性、社区结构和节点度分布,而不依赖于特定的标记节点。这些信息能够帮助识别与整体图结构显著偏离的节点,即使这些节点未被标记。通过比较节点在图中的位置和角色,可以发现整体结构中的异常部分或节点。

交叉注意力:在每一层GLN中,本文通过GCN层获得节点的局部隐层特征矩阵 $\tilde{\mathbf{H}}_{loc}^{(l)} \in \mathbb{R}^{N \times h^{(l)}}$,通过FA-GDC层获得节点的全局隐层特征矩阵 $\tilde{\mathbf{H}}_{glb}^{(l)} \in \mathbb{R}^{N \times h^{(l)}}$ 。为了在节点间实现局部结构信息与全局结构信息的有效交互,从而促进信息的互补融合,本文引入了广泛应用的缩放点积注意力(Scaled Dot-product Attention)机制。该机制的公式如下:

$$\mathbf{H} = \text{softmax} \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}} \right) \mathbf{V} \quad (6)$$

其中, $\mathbf{Q} \in \mathbb{R}^{N \times d}$ 表示查询向量(Query); $\mathbf{K} \in \mathbb{R}^{M \times d}$ 表示键向量(Key); $\mathbf{V} \in \mathbb{R}^{M \times f}$ 表示值向量(Value); $\mathbf{H} \in \mathbb{R}^{N \times f}$ 为注意力输出向量。

为此,本文首先使用两组可学习的权重参数矩阵 $\{\mathbf{W}_{loc}^{(l)Q}, \mathbf{W}_{loc}^{(l)K}, \mathbf{W}_{loc}^{(l)V} \in \mathbb{R}^{h^{(l)} \times h^{(l)}}\}$, $\{\mathbf{W}_{glb}^{(l)Q}, \mathbf{W}_{glb}^{(l)K}, \mathbf{W}_{glb}^{(l)V} \in \mathbb{R}^{h^{(l)} \times h^{(l)}}\}$ 分别将 $\tilde{\mathbf{H}}_{loc}^{(l)}$ 和 $\tilde{\mathbf{H}}_{glb}^{(l)}$ 映射到三个不同的向量空间中:

$$\begin{cases} \mathbf{Q}_{loc}^{(l)} = \tilde{\mathbf{H}}_{loc}^{(l)} \mathbf{W}_{loc}^{(l)Q} \\ \mathbf{K}_{loc}^{(l)} = \tilde{\mathbf{H}}_{loc}^{(l)} \mathbf{W}_{loc}^{(l)K} \\ \mathbf{V}_{loc}^{(l)} = \tilde{\mathbf{H}}_{loc}^{(l)} \mathbf{W}_{loc}^{(l)V} \end{cases} \quad (7)$$

$$\begin{cases} \mathbf{Q}_{glb}^{(l)} = \tilde{\mathbf{H}}_{glb}^{(l)} \mathbf{W}_{glb}^{(l)Q} \\ \mathbf{K}_{glb}^{(l)} = \tilde{\mathbf{H}}_{glb}^{(l)} \mathbf{W}_{glb}^{(l)K} \\ \mathbf{V}_{glb}^{(l)} = \tilde{\mathbf{H}}_{glb}^{(l)} \mathbf{W}_{glb}^{(l)V} \end{cases} \quad (8)$$

然后,首先以 $\mathbf{Q}_{loc}^{(l)}$ 作为查询向量, $\mathbf{K}_{glb}^{(l)}$ 作为键向量, $\mathbf{V}_{glb}^{(l)}$ 作为值向量,应用缩放点积注意力,可以得到:

$$\mathbf{H}_{g2l}^{(l)} = \text{softmax} \left(\frac{\mathbf{Q}_{loc}^{(l)} \mathbf{K}_{glb}^{(l)T}}{\sqrt{h^{(l)}}} \right) \mathbf{V}_{glb}^{(l)} \quad (9)$$

接着以 $\mathbf{Q}_{glb}^{(l)}$ 作为查询向量, $\mathbf{K}_{loc}^{(l)}$ 作为键向量, $\mathbf{V}_{loc}^{(l)}$ 作为值向量,应用缩放点积注意力,可以得到

$$\mathbf{H}_{l2g}^{(l)} = \text{softmax} \left(\frac{\mathbf{Q}_{glb}^{(l)} \mathbf{K}_{loc}^{(l)T}}{\sqrt{h^{(l)}}} \right) \mathbf{V}_{loc}^{(l)} \quad (10)$$

这样一来,节点成功实现了其局部结构信息与全局结构信息的交互。最后,通过残差连接完成信息的融合:

$$\mathbf{H}_{loc}^{(l)} = \tilde{\mathbf{H}}_{loc}^{(l)} + \mathbf{H}_{g2l}^{(l)} \quad (11)$$

$$\mathbf{H}_{glb}^{(l)} = \tilde{\mathbf{H}}_{glb}^{(l)} + \mathbf{H}_{lg}^{(l)} \quad (12)$$

从而得到节点在每一层中最终的局部隐层特征矩阵 $\mathbf{H}_{loc}^{(l)} \in \mathbb{R}^{N \times h^{(l)}}$ 和全局隐层特征矩阵 $\mathbf{H}_{glb}^{(l)} \in \mathbb{R}^{N \times h^{(l)}}$ 。

局部结构信息和全局结构信息提供了不同层次和尺度上的特征。通过交叉注意力有效结合这些多尺度信息,模型能够在标记样本极其有限的情况下更准确地捕捉异常节点的特征,并更好地泛化到未见过的数据,从而降低过拟合风险。同时,在缺乏标记样本的情况下,异常节点可能不均匀地分布在图中,融合不同尺度的信息有助于识别这些异常节点,即使它们的表现形式和位置各异。

自适应加权聚合:在经过 L 层 GLN 层后,我们得到节点的最终局部隐层特征矩阵 $\mathbf{H}_{loc}^{(L)} \in \mathbb{R}^{N \times v}$ 和全局隐层特征矩阵 $\mathbf{H}_{glb}^{(L)} \in \mathbb{R}^{N \times v}$,其中 $v = h^{(L)}$ 表示节点最终低维特征嵌入的维度。为了获得最终的节点表示,本文提出通过一个可学习的权重参数矩阵 $\mathbf{W} \in \mathbb{R}^{2 \times v}$,在每个特征通道上进行自适应加权聚合:

$$\mathbf{z}_i = h_i^{loc} \odot \mathbf{W}_1 + h_i^{glb} \odot \mathbf{W}_2 \quad (13)$$

其中, $h_i^{loc} \in \mathbb{R}^v$ 表示 $\mathbf{H}_{loc}^{(L)}$ 的第 i 行, h_i^{glb} 同理; $\mathbf{W}_1 \in \mathbb{R}^v$ 表示 \mathbf{W} 的第 1 行, \mathbf{W}_2 同理; $\mathbf{z}_i \in \mathbb{R}^v$ 表示节点 v_i 最终的节点表示; \odot 表示逐元素乘积。这样一来,我们能够获得所有节点的最终鲁棒节点表示 $\mathbf{Z} \in \mathbb{R}^{N \times v}$ 。

3.3 偏差损失 \mathcal{L}_D

GLN 学得的节点表示将被输入到分类器中,以进一步评估每个节点的异常性。具体而言,分类器采用一个单隐藏层的多层感知机 (Multi-layer Perceptron, MLP),用于将输入的节点表示转换为对应的异常得分:

$$h_i = \text{ReLU}(\mathbf{W}_h \mathbf{z}_i + b_h) \quad (14)$$

$$s_i = \mathbf{w}_s^T h_i + b_s \quad (15)$$

其中, s_i 表示节点 v_i 的异常得分; $h_i \in \mathbb{R}^h$ 为中间输出; $\mathbf{W}_h \in \mathbb{R}^{h \times v}$ 和 $\mathbf{w}_s \in \mathbb{R}^h$ 分别表示可学习的权重矩阵和权重向量; $b_h \in \mathbb{R}^h$ 和 $b_s \in \mathbb{R}$ 为对应的偏置项。本文使用 MLP_θ 表示该分类器,并简化计算过程如下:

$$s_i = MLP_\theta(\mathbf{z}_i) \quad (16)$$

从根本上讲,EWS-FSGAD 的目标是利用少量的标记节点,通过计算异常得分来区分异常节点和正常节点。为此,本文采用了文献[20]中提出的偏差损失 (Deviation Loss),以促使模型为异常节点分配更高的异常得分。为了引导模型的学习过程,本文首先定义了一个参考分数 μ_r ,作为一组随机选择的正常节点的平均异常得分,用以量化异常节点与正常节点之间的偏差。具体来说,本文首先从一个

高斯先验分布中采样 k 个异常得分,即 $\mathcal{R} = \{r_1, r_2, \dots, r_k\} \sim \mathcal{N}(\mu, \sigma^2)$,其中 r_i 表示随机选取的正常节点的异常性。参考分数 μ_r 被定义为这些采样得分的均值:

$$\mu_r = \frac{1}{k} \sum_{i=1}^k r_i \quad (17)$$

标准得分被定义为节点 v_i 与参考分数之间的偏差:

$$dev(v_i) = \frac{s_i - \mu_r}{\sigma_r} \quad (18)$$

其中, σ_r 表示被采样节点异常得分集合 $\mathcal{R} = \{r_1, r_2, \dots, r_k\}$ 的标准差。最终的目标函数为

$$\mathcal{L}_D = (1 - y_i) \cdot |dev(v_i)| + y_i \cdot \max(0, m - dev(v_i)) \quad (19)$$

其中, y_i 是节点 v_i 的标签,若节点 v_i 是一个异常节点,则 $y_i = 1$,否则 $y_i = 0$; m 为置信区间。

通过最小化上述损失函数,EWS-FSGAD 能够使正常节点的异常得分趋近于 μ_r ,同时强制提高异常节点的异常得分,使其与 μ_r 之间存在至少 m 的正偏差。这样,即使在标记节点极其有限的情况下,EWS-FSGAD 仍能有效学习节点表示,捕捉节点行为模式,从而具备区分异常与正常模式的能力。综上所述,通过优化偏差损失 \mathcal{L}_D ,EWS-FSGAD 能够显著提升异常节点的异常得分。

3.4 重建损失 \mathcal{L}_R

为了增强 EWS-FSGAD 所学习到的节点表示的鲁棒性,本文引入了图对比学习中的自监督重建损失,以提供更多有效的自监督信息。具体而言,对于输入图 G 的原始视图 $G = (\mathbf{A}, \mathbf{X})$,首先利用图增强技术 (Graph Augmentation),通过随机掩蔽 G 中的边和节点生成其增强视图 $G^a = (\bar{\mathbf{A}}, \bar{\mathbf{X}})$,即 \mathbf{A} 的每一个元素和 \mathbf{X} 的每一行均以 γ 的概率被置零。如图 1 所示,对于节点 v_i ,本文通过两个不同参数的 GLN_θ 和 GLN_ϕ 模型,分别获取其在原始视图和增强视图中的节点表示:

$$\mathbf{z}_i = GLN_\theta(\mathbf{A}, \mathbf{X}) \quad (20)$$

$$\bar{\mathbf{z}}_i = GLN_\phi(\bar{\mathbf{A}}, \bar{\mathbf{X}}) \quad (21)$$

随后,本文通过一个预测器 p_θ (一个单隐藏层的 MLP)^[57-58],利用 \mathbf{z}_i 生成预测值 $p_\theta(\mathbf{z}_i)$,其中 $p_\theta(\mathbf{z}_i)$ 是对 $\bar{\mathbf{z}}_i$ 的估计。本文的主要目标是通过 \mathbf{z}_i 来重建 $\bar{\mathbf{z}}_i$,因此需要增强 $\bar{\mathbf{z}}_i$ 与 $p_\theta(\mathbf{z}_i)$ 之间的相似性。为此,本文通过优化两者之间的归一化均方差差来实现:

$$\begin{aligned} \text{MSE}(\bar{z}_i, p_\theta(z_i)) &= \left\| \frac{\bar{z}_i}{\|\bar{z}_i\|_2} - \frac{p_\theta(z_i)}{\|p_\theta(z_i)\|_2} \right\|_2^2 \quad (22) \\ &= 2 - 2 \cdot \frac{\bar{z}_i \cdot p_\theta(z_i)}{\|\bar{z}_i\|_2 \|p_\theta(z_i)\|_2} \end{aligned}$$

其中, $\|\cdot\|_2$ 表示 L_2 范数。由此, 重建损失可以定义为

$$\mathcal{L}_R = -\frac{\bar{z}_i \cdot p_\theta(z_i)}{\|\bar{z}_i\|_2 \|p_\theta(z_i)\|_2} \quad (23)$$

\mathcal{L}_R 实际上是 \bar{z}_i 与 $p_\theta(z_i)$ 之间余弦相似度的负值。需要强调的是, 在计算 \mathcal{L}_R 的过程中, 并未使用节点的标签信息, 而是通过约束节点在其原始视图和增强视图中的表示一致性, 最大化它们之间的互信息。因此, 该损失可以在任意节点上进行计算。在模型训练阶段, 本文通过计算查询集(未标记节点)的重建损失, 为模型提供更多自监督信息, 从而促进模型优化, 增强其泛化性能。

3.5 模型训练与测试

综上所述, 整个模型的目标函数主要由两部分组成: 一是针对标记节点(支持集)的监督损失函数, 即偏差损失 \mathcal{L}_D ; 二是针对无标记节点(查询集)的自监督损失函数, 即重建损失 \mathcal{L}_R 。因此, 总的损失函数可以表示为

$$\mathcal{L} = \mathcal{L}_D + \beta \mathcal{L}_R \quad (24)$$

其中, β 是用于调节 \mathcal{L}_D 和 \mathcal{L}_R 之间的比例的权重参数。

正如前文所述, 在实际应用中, 我们通常只能获得图中少量的标记节点以及大量未标记节点。然而, 现实中往往存在一些与目标网络处于相似领域的其他网络。例如, ACM 和 DBLP 可视为在计算机科学领域中具有相似引用关系的引文网络。除此之外, 已有研究表明^[59-61], 基于拓扑结构和节点属性的相似性, 可以将源网络中的有价值元知识迁移到目标网络, 从而提升目标网络的性能。为了模拟真实的测试环境并进一步提升 EWS-FSGAD 的性能, 本文引入了广泛应用的跨网络元学习(Cross-network Meta-learning)训练机制^[20]。具体而言, 除了目标网络 $G^t = \{A^t, X^t\}$ 之外, 本文假设存在 P 个与目标网络处于相同领域的辅助网络, 表示为 $\mathcal{G}^a = \{G_1^a = (A_1^a, X_1^a), G_2^a = (A_2^a, X_2^a), \dots, G_P^a = (A_P^a, X_P^a)\}$ 。在每个网络中, 节点被进一步划分为 $\mathcal{V} = \{\mathcal{V}^L, \mathcal{V}^U\}$, 其中 \mathcal{V}^L 包含少量标记的异常节点和正常节点, \mathcal{V}^U 则包含其余的未标记节点。

作为一种有效的知识提取与迁移范式, 元学习

近年来因其在多个领域中的广泛应用而受到越来越多的研究关注^[62-64]。本质上, 元学习的目标是在多种学习任务上训练模型, 使其能够在面对极少甚至只有一个标记数据的新任务时, 依然表现出良好的适应性。跨网络元学习旨在使 EWS-FSGAD 在训练阶段从辅助网络上的不同 FS-GAD 任务中提取异常元知识, 并对目标网络上的新任务进行进一步微调, 从而使模型能够快速且有效地进行自适应。

具体而言, 本文将每个学习任务定义为在单个网络上执行 FS-GAD。令 \mathcal{T}_i 表示由 G_i^a 构建的 FS-GAD 任务, 则在每个训练周期将存在 P 个这样的学习任务。需要说明的是, 令 θ 表示 GLN_θ, MLP_θ 和 p_θ 的所有可学习参数, 令 ϕ 表示 GLN_ϕ 的所有可学习参数。如图 1 所示, EWS-FSGAD 的训练过程主要包括两个阶段: 微调和元更新。在微调阶段, 对于每个辅助网络 G_i^a , 首先构建学习任务 \mathcal{T}_i : 从 \mathcal{V}_i^L 中随机采样 K 个异常节点和 K 个正常节点构成支持集 \mathcal{S}_i , 从 \mathcal{V}_i^U 中随机采样 $Q/2$ 个异常节点和 $Q/2$ 个正常节点构成查询集 \mathcal{Q}_i 。然后, 使用 θ 初始化 $\theta_i: \theta_i^0 \leftarrow \theta$, 接着基于 \mathcal{L} , 执行 T 步微调:

$$\mathcal{L}(\{\mathcal{S}_i, \mathcal{Q}_i; \theta_i^{t-1}\}) = \mathcal{L}_D(\mathcal{S}_i; \theta_i^{t-1}) + \beta \mathcal{L}_R(\mathcal{Q}_i; \theta_i^{t-1}) \quad (25)$$

$$\theta_i^t = \theta_i^{t-1} - \alpha \nabla_{\theta_i^{t-1}} \mathcal{L}(\{\mathcal{S}_i, \mathcal{Q}_i; \theta_i^{t-1}\}) \quad (26)$$

算法 1. EWS-FSGAD 的训练算法。

输入:

- (1) P 个辅助网络, 即 $\mathcal{G}^a = \{G_1^a = (A_1^a, X_1^a), G_2^a = (A_2^a, X_2^a), \dots, G_P^a = (A_P^a, X_P^a)\}$;
- (2) 一个目标网络 $G^t = \{A^t, X^t\}$;
- (3) 每个网络由少量的标记节点和大量的无标记节点所构成的集合 $\{\mathcal{V}_1^L, \mathcal{V}_1^U\}, \dots, \{\mathcal{V}_P^L, \mathcal{V}_P^U\}$ 和 $\{\mathcal{V}^L, \mathcal{V}^U\}$;
- (4) 训练轮次 E , 支持集每类样本个数 K , 查询集大小 Q , 微调步数 T , 学习率 α, β_1, β_2 。

输出: \mathcal{V}^U 中节点的异常分数。

- 1: 初始化参数 θ, ϕ ;
- 2: WHILE $e < E$ DO
- 3: FOR 每个网络 G_i^a (任务 \mathcal{T}_i) DO
- 4: 从 \mathcal{V}_i^L 中随机采样 K 个异常节点和 K 个正常节点构成支持集 \mathcal{S}_i^a , 从 \mathcal{V}_i^U 中随机采样 $Q/2$ 个异常节点和 $Q/2$ 个正常节点构成查询集 \mathcal{Q}_i^a ;
- 5: 初始化 $\theta_i: \theta_i^0 \leftarrow \theta$;
- 6: WHILE $t \leq T$ DO
- 7: 使用公式(19)在 \mathcal{S}_i^a 上计算 $\mathcal{L}_D(\mathcal{S}_i^a; \theta_i^{t-1})$, 使用公式(23)在 \mathcal{Q}_i^a 上计算

$\mathcal{L}_R(\mathcal{Q}_i^r; \theta_i^{t-1})$,使用公式(24)计算 $\mathcal{L}(\{\mathcal{S}_i^r, \mathcal{Q}_i^r; \theta_i^{t-1})$,并同时计算 $\nabla_{\theta_i^{t-1}}\mathcal{L}(\{\mathcal{S}_i^r, \mathcal{Q}_i^r; \theta_i^{t-1})$;

8: 根据公式(25)和公式(26),使用梯度下降方法更新 θ_i^{t-1} ,

$\theta_i^t \leftarrow \theta_i^{t-1} - \alpha \nabla_{\theta_i^{t-1}}\mathcal{L}(\{\mathcal{S}_i^r, \mathcal{Q}_i^r; \theta_i^{t-1})$;

9: END

10: END

11: 使用公式(19)在 \mathcal{Q}_i^s 上计算 $\mathcal{L}_D(\mathcal{Q}_i^s; \theta_i^T)$,使用公式(23)在 \mathcal{Q}_i^s 上计算 $\mathcal{L}_R(\mathcal{Q}_i^s; \theta_i^T)$,使用公式(24)计算 $\mathcal{L}(\mathcal{Q}_i^s; \theta_i^T)$,并同时计算 $\nabla_{\theta}\mathcal{L}(\mathcal{Q}_i^s; \theta_i^T)$;

12: 根据公式(28)和公式(29),元更新 $\theta, \phi, \theta \leftarrow \theta -$

$\beta_1 \nabla_{\theta} \sum_{i=1}^P \mathcal{L}(\mathcal{Q}_i^s; \theta_i^T), \phi \leftarrow \phi - \beta_2 \nabla_{\phi} \sum_{i=1}^P \mathcal{L}_R(\mathcal{Q}_i^s; \theta_i^T)$;

13: END

14: 在目标网络 G' 上利用 $\{\mathcal{V}_i^l, \mathcal{V}_i^u\}$ 微调 θ ;

15: 计算 \mathcal{V}_i^u 中节点的异常分数。

其中, $t \in \{1, 2, \dots, T\}$; $\mathcal{L}_D(\mathcal{S}_i; \theta_i^{t-1})$ 表示基于参数 θ_i^{t-1} 在支持集 \mathcal{S}_i 上计算的偏差损失, $\mathcal{L}_R(\mathcal{Q}_i; \theta_i^{t-1})$ 同理; α 是微调阶段的学习率。值得强调的是,在微调阶段,由于同时优化 GLN_{θ} 和 GLN_{ϕ} 会导致模型的崩溃(即产生恒定输出)^[57-58],因此在微调阶段,参数 ϕ 保持不变。

在完成每个学习任务 \mathcal{T}_i 的 T 步微调并获得 θ_i^T 后,本文将对 θ 和 ϕ 进行元更新。通过跨网络元学习训练模型,本文旨在使EWS-FSGAD学习到良好的模型初始化参数 θ 和 ϕ ,以便在面对新的测试任务时,能够通过少量的微调步数迅速适应。具体而言,这一目标可以通过优化模型在所有学习任务中查询集的性能来实现。模型的目标函数被定义为:

$$\min_{\theta, \phi} \sum_{i=1}^P \mathcal{L}(\mathcal{Q}_i; \theta_i^T) \quad (27)$$

考虑到不同模块在功能上的差异,本文对其元更新采用了不同的学习率和损失函数^[50]。具体来说,在所有 \mathcal{Q}_i 上,本文使用下式对 θ 和 ϕ 进行元更新:

$$\theta \leftarrow \theta - \beta_1 \nabla_{\theta} \sum_{i=1}^P \mathcal{L}(\mathcal{Q}_i; \theta_i^T) \quad (28)$$

$$\phi \leftarrow \phi - \beta_2 \nabla_{\phi} \sum_{i=1}^P \mathcal{L}_R(\mathcal{Q}_i; \theta_i^T) \quad (29)$$

其中, β_1 和 β_2 分别表示 θ 和 ϕ 的元学习率。需要特别注意的是, GLN_{ϕ} 仅用于计算 \mathcal{L}_R ,因此其元更新是基于 \mathcal{L}_R 进行的,而 $\theta(GLN_{\theta}, MLP_{\theta}$ 和 $p_{\theta})$ 的元更新则是基于 \mathcal{L} 进行的。

在完成对 P 个学习任务的元训练之后,本文将

在目标网络 G' 上,利用 $\{\mathcal{V}_i^l, \mathcal{V}_i^u\}$ 对 θ 进行微调。微调后,本文通过 GLN_{θ} 提取 \mathcal{V}_i^u 中节点的表示,并使用 MLP_{θ} 计算其异常得分,从而完成模型的测试。完整的算法概述如算法1所示。

值得注意的是,本文方法采用跨网络元学习训练机制,通过从辅助网络中学习如何快速适应目标网络的能力,能够从有限的标记节点中提取可迁移的异常元知识。这使得模型能够在目标网络中高效检测异常节点。相比之下,传统的预训练模型通常依赖于在大规模数据集上进行训练,并通过微调来适应特定任务,无法在标记节点有限的情况下迅速适应。

在Meta-GDN^[20]中所采用的跨网络元学习假设中, \mathcal{V}_i^l 仅包含标记的异常节点,而 \mathcal{V}_i^u 则包含其余的未标记异常节点以及所有标记的正常节点。在构建学习任务 \mathcal{T}_i 时,从 \mathcal{V}_i^l 和 \mathcal{V}_i^u 中各随机采样 K 个异常节点和 K 个正常节点以构成支持集 \mathcal{S}_i ,同时从 \mathcal{V}_i^l 和 \mathcal{V}_i^u 中再随机采样 $Q/2$ 个异常节点和 $Q/2$ 个正常节点以构成查询集 \mathcal{Q}_i 。然而,由于Meta-GDN将 \mathcal{V}_i^u 中的所有节点均视为正常节点,这在数据集中引入了数据噪声,进而对模型造成了一定的混淆,影响了其收敛速度和性能。

为解决上述问题,本文假设在实际应用中,能够获取到一部分标记的异常节点与正常节点,并明确规定 \mathcal{V}_i^l 中包含若干有标记的异常节点和正常节点。因此,在构建学习任务 \mathcal{T}_i 时,从 \mathcal{V}_i^l 中随机采样 K 个异常节点和 K 个正常节点构成支持集 \mathcal{S}_i ,并从 \mathcal{V}_i^u 随机采样 $Q/2$ 个异常节点和 $Q/2$ 个正常节点构成查询集 \mathcal{Q}_i 。通过这种方式,避免在数据集中引入噪声,从而不会对模型造成混淆,有助于模型更准确地捕获和学习节点的异常模式,加快收敛速度,并提高异常检测的性能和模型的鲁棒性。

4 实 验

在本节中,本文进行了大量实验验证了所提出的EWS-FSGAD框架的有效性。首先,介绍了所使用的数据集及实验设置;然后,展示并分析了实验结果,并与现有的GAD基线模型进行了对比;除此之外,设计了消融实验,以进一步验证模型各个关键模块的有效性;最后,对模型的超参数、t-SNE可视化以及复杂度进行了实验分析。

4.1 数据集

本文在三个广泛应用于GAD任务的真实世界

基准数据集上对模型性能进行了评估。各数据集的简要统计信息如表2所示,详细信息如下:

表2 实验数据集

数据集	节点数	边数	特征维度	异常数
Flickr	7575	239 738	12 407	450
PubMed	19 717	44 338	500	940
Yelp	24 522	43 728	10 000	1200

(1)Flickr^[65]:来自图片共享平台Flickr的社交网络数据集。其中,节点代表用户,边表示用户之间的友谊关系。在该社交网络中,用户通常会分享个性化的内容,例如博客或图片,因此其中的文本内容被视为节点的属性。为进行实验,本文将完整的网络随机划分为大小相似且不重叠的子网络。

(2)PubMed^[66]:公开的引文网络数据集。其中,节点表示与糖尿病相关的科学文章,边表示文章之间的引用关系。节点属性通过TF/IDF加权词向量表示,词向量来自包含500个单词的词典。本文从原始完整网络中提取了不重叠的子网络以用于实验。

(3)Yelp^[67]:来自Yelp.com,包含美国多个州餐馆的评论数据,餐馆按邮政编码进行组织。根据Yelp的反欺诈过滤算法,评论者被分为异常(评论被过滤的用户)和正常(评论未被过滤的用户)两类。按照文献^[20]的数据集构建方式,本文根据邮政编码选择同一区域的餐馆来构建每个子网络,其中节点代表评论者,如果两位评论者曾评论同一餐馆,则在其间建立一条边。文本内容使用词袋模型^[68]处理,以获得每个节点的属性。

需要注意的是,除Yelp数据集外,Flickr和PubMed数据集中并不存在真实的异常节点。在实际的FS-GAD场景中,由于图数据标注成本高昂且异常节点极其稀少,能够获取的标记数据极其有限。因此,领域内的许多研究工作^[7,12-14,20-21]普遍采用结合真实数据集与人工注入异常节点的公开数据集的方式来验证模型的有效性。这种数据集构建方式已被广泛接受,并被验证了其合理性。因此,为确保与现有研究的公平比较,本文按照先前研究^[7]中的方法对Flickr和PubMed数据集注入了异常节点。具体而言,本文注入了两类异常:结构异常和属性异常。

(1)结构异常:小规模的全连接团是现实场景中典型的异常子结构,其节点之间的连接显著密集,形成局部异常区域,连接密度远高于正常节点。例如,

在社交网络中,垃圾用户常通过随机关注形成密集的连接区域^[69];在引文网络中,某些论文通过互相引用形成伪造的引用团体,以人为提升引用量^[70]。基于这一假设,本文随机选择 p 个节点并在它们之间建立边,使这些节点相互连接,重复此过程 q 次,从而生成 q 个大小为 p 的全连接团,共计注入 pq 个结构异常节点。

(2)属性异常:本文通过将目标节点的特征替换为候选节点集中与其欧几里得距离最大的节点的特征,生成与其邻域属性显著不同的异常节点。此方法能够有效模拟局部上下文中偏离正常特征分布的异常模式。为确保注入平衡,本文共计注入 pq 个属性异常节点。

4.2 实验设置

本小节将详细介绍实验设置,包括所选的基线模型、评价指标以及参数设置。

4.2.1 基线模型

本文将提出的EWS-FSGAD模型与三类异常检测方法进行了对比:(1)无监督GAD方法,包括DOMINANT^[7]、ANEMONE^[12]、CoLA^[13]和PREM^[14];(2)半监督GAD方法,包括SemiGNN^[15]、DeepSAD^[16]和SADAG^[17];(3)FS-GAD方法,包括Meta-GDN^[20]和ANEMONE-FS^[21]。以下是这些方法的简要介绍:

(1)DOMINANT^[7]:基于深度学习,通过图自编码器联合重构节点的邻接矩阵和属性矩阵,并利用其重构误差的加权和评估节点的异常性。

(2)ANEMONE^[12]:基于对比学习,通过从原始数据构建多视图,利用局部级别和上下文级别的图对比学习损失函数捕捉节点的异常模式。

(3)CoLA^[13]:基于对比学习,使用GCN评估节点与其相邻子图的一致性,从而识别异常模式。

(4)PREM^[14]:通过引入预处理和匹配方法,消除训练期间信息传播的必要性,并采用简化的对比损失,从而显著降低训练时间和内存消耗。

(5)SemiGNN^[15]:使用分层注意力机制从多视图数据中学习,优化不同邻域和视图之间的关联,应用于欺诈检测。

(6)DeepSAD^[16]:基于深度学习的非结构化数据异常检测方法。本文将节点属性作为其输入。

(7)SADAG^[17]:通过将正常节点嵌入超球面内部、异常节点嵌入超球面外部,利用节点嵌入与超球面中心之间的距离来检测异常。

(8)Meta-GDN^[20]:基于元学习,采用偏差损失端到端训练,并通过跨网络元学习在多个辅助网络中学习元知识,从而显著提升异常检测的有效性和泛化性。

(9)ANEMONE-FS^[21]:在ANEMONE模型的基础上引入有限的标记样本,构建额外的正负样本对,以充分利用监督信息,提升异常检测性能。

4.2.2 评价指标

为了评估本文提出的EWS-FSGAD模型及基线模型的性能,本文采用了AUC-ROC和AUC-PR作为评价指标:

(1)AUC-ROC:在以往的研究中被广泛用于评估GAD模型的性能^[7,13,20,71]。ROC曲线展示了在不同阈值下,真阳性率(即将异常节点正确识别为异常的比例)与假阳性率(即将正常节点误识别为异常的比例)之间的关系。AUC-ROC表示ROC曲线下的面积,反映了随机选择的异常节点的异常得分高于正常节点的概率。其值越接近于1,说明模型性能越好。

(2)AUC-PR:PR曲线展示了不同阈值下的精确率与召回率之间的关系。AUC-PR是PR曲线下的面积,用于评估模型对正例(异常节点)的检测能力。与AUC-ROC类似,AUC-PR的值越接近于1,说明模型性能越好。

4.2.3 参数设置

对于网络编码器 GLN_θ ,设置其网络层数 L 为2,隐层特征维度 h^1 为512,节点低维特征嵌入维度 v 为512,FA-GDC层的求和项数 M 为10, GLN_θ 的网络结构与 GLN_θ 相同。如公式(14)和公式(15)所示,分类器采用单隐藏层的MLP,其隐层特征维度 h 设置为1024,预测器 p_θ 的网络结构与分类器相同。公式(17)中的 μ_r 是通过从标准高斯分布(即 $\mathcal{N}(0,1)$)中采样的 $k=5000$ 个异常得分计算得出的;公式(19)中的置信区间 m 设置为5。在生成增强视图 G^a 时,随机掩蔽节点和边的概率 γ 设置为0.1;公式(24)中用于调节偏差损失 \mathcal{L}_D 和重建损失 \mathcal{L}_R 之间比例的权重参数 β 设置为1。

对于模型训练,微调步数 T 设置为5,训练轮次 E 设置为200。微调阶段的学习率 α 设置为0.0001,元更新阶段的元学习率 β_1 和 β_2 均设置为0.003。本文采用Adam优化器,并将权重衰减系数设置为0.001。dropout概率设置为0.5。在支持集 \mathcal{S} 中,每类节点的数量 K 设置为1或者3,查询集的大小 Q 设

置为20。在跨网络元学习的训练方式下,假设网络总数为5,其中包括4个辅助网络($P=4$)和1个目标网络。在极其弱监督设置下,对所有数据集进行了实验。具体而言,本文选择了三种不同的标签设置:每个类别分别有5、10或15个标签($|\mathcal{V}^L|=10,20,30$),即每个网络的标记节点集中分别包含5、10或15个异常节点和正常节点,这些标记节点是从网络的节点集中随机选择的。在目标网络上进行微调时,节点被划分为40%用于微调,20%用于验证,40%用于测试。

在所有数据集上,本文使用不同的随机数种子进行10次实验,最终报告EWS-FSGAD及其他基线模型在这10次实验中的平均性能。

4.3 实验结果与分析

本小节评估了EWS-FSGAD框架及其他模型的性能。各数据集上所有方法的性能比较结果详见表3、表4和表5。在每类标签数量分别为5、10和15的极其弱监督场景下,本文测试了1-shot($K=1$)和3-shot($K=3$)两种实验设置的性能。需要说明的是,由于无监督GAD方法(DOMINANT、ANEMONE、CoLA、PREM)未利用标签信息,因此其在所有实验设置下的性能相同。同时,由于半监督GAD方法(SemiGNN、DeepSAD、SADAG)以及FS-GAD方法中的ANEMONE-FS未从标记样本中采样以构成支持集,因此它们在1-shot和3-shot的设置下的性能相同,仅随每类标签数量的变化而变化。

根据以上实验数据,可以得出以下结论:

(1)首先,在所有数据集的各种实验设置下,本文提出的EWS-FSGAD模型在异常检测性能上显著优于所有基线模型,验证了其在极其弱监督场景下完成FS-GAD任务的有效性。特别是在PubMed数据集上,EWS-FSGAD在AUC-PR指标上远超其他算法(28.8%~35.4%)。除此之外,即使在目标网络上仅使用每类节点中的一个标记样本(1-shot)进行微调,EWS-FSGAD仍然表现出最佳实验性能。

(2)其次,尽管直观上半监督和小样本方法利用有限的标记数据能够提升模型性能,但在除Yelp数据集外的实验中,能够观察到无监督方法有时表现出优于半监督和小样本方法的性能。这可能是因为,在极其弱监督场景下,随机选择的极少量标记样本往往缺乏代表性,无法充分反映其

表3 在 Flickr 数据集上不同算法的实验性能对比 (ROC、PR 分别代表 AUC-ROC、AUC-PR)

每类标签数量		5		10		15		5		10		15	
实验设置		1-shot						3-shot					
类型	评价标准(%)	ROC	PR										
无监督	DOMINANT ^[7]	79.8±0.6	37.8±1.3	79.8±0.6	37.8±1.3	79.8±0.6	37.8±1.3	79.8±0.6	37.8±1.3	79.8±0.6	37.8±1.3	79.8±0.6	37.8±1.3
	ANEMONE ^[12]	57.1±2.6	9.6±1.2	57.1±2.6	9.6±1.2	57.1±2.6	9.6±1.2	57.1±2.6	9.6±1.2	57.1±2.6	9.6±1.2	57.1±2.6	9.6±1.2
	CoLA ^[13]	56.0±1.9	8.3±1.8	56.0±1.9	8.3±1.8	56.0±1.9	8.3±1.8	56.0±1.9	8.3±1.8	56.0±1.9	8.3±1.8	56.0±1.9	8.3±1.8
	PREM ^[14]	72.8±0.2	24.1±0.6	72.8±0.2	24.1±0.6	72.8±0.2	24.1±0.6	72.8±0.2	24.1±0.6	72.8±0.2	24.1±0.6	72.8±0.2	24.1±0.6
半监督	SemiGNN ^[15]	55.4±2.8	10.2±1.0	59.2±2.3	14.1±3.4	61.3±2.1	15.7±3.9	55.4±2.8	10.2±1.0	59.2±2.3	14.1±3.4	61.3±2.1	15.7±3.9
	DeepSAD ^[16]	79.5±0.5	30.9±1.2	80.3±0.9	33.7±1.2	81.3±0.8	37.0±2.6	79.5±0.5	30.9±1.2	80.3±0.9	33.7±1.2	81.3±0.8	37.0±2.6
	SADAG ^[17]	71.3±2.2	17.4±1.7	74.4±1.3	22.3±3.4	75.4±1.9	25.0±4.9	71.3±2.2	17.4±1.7	74.4±1.3	22.3±3.4	75.4±1.9	25.0±4.9
小样本	Meta-GDN ^[20]	75.5±5.8	29.4±6.7	71.0±7.2	22.9±4.8	76.2±5.8	23.7±7.5	77.9±6.5	28.9±6.4	74.3±5.6	23.7±5.5	76.6±2.1	22.5±3.1
	ANEMONE-FS ^[21]	59.3±1.8	8.9±0.6	60.1±1.5	10.3±1.5	61.2±3.3	11.3±2.9	59.3±1.8	8.9±0.6	60.1±1.5	10.3±1.5	61.2±3.3	11.3±2.9
	EWS-FSGAD (ours)	82.5±4.3	38.7±6.8	83.3±3.5	39.2±7.2	83.5±3.2	41.2±7.4	83.7±4.8	39.1±6.1	84.2±1.3	39.7±5.1	84.6±2.6	42.5±8.8

表4 在 PubMed 数据集上不同算法的实验性能对比 (ROC、PR 分别代表 AUC-ROC、AUC-PR)

每类标签数量		5		10		15		5		10		15	
实验设置		1-shot						3-shot					
类型	评价标准(%)	ROC	PR										
无监督	DOMINANT ^[7]	93.3±0.1	35.6±0.7	93.3±0.1	35.6±0.7	93.3±0.1	35.6±0.7	93.3±0.1	35.6±0.7	93.3±0.1	35.6±0.7	93.3±0.1	35.6±0.7
	ANEMONE ^[12]	90.7±0.4	40.7±2.0	90.7±0.4	40.7±2.0	90.7±0.4	40.7±2.0	90.7±0.4	40.7±2.0	90.7±0.4	40.7±2.0	90.7±0.4	40.7±2.0
	CoLA ^[13]	88.8±0.3	32.0±1.5	88.8±0.3	32.0±1.5	88.8±0.3	32.0±1.5	88.8±0.3	32.0±1.5	88.8±0.3	32.0±1.5	88.8±0.3	32.0±1.5
	PREM ^[14]	84.4±0.1	45.0±0.1	84.4±0.1	45.0±0.1	84.4±0.1	45.0±0.1	84.4±0.1	45.0±0.1	84.4±0.1	45.0±0.1	84.4±0.1	45.0±0.1
半监督	SemiGNN ^[15]	65.6±3.1	21.7±3.7	68.8±2.3	25.5±2.6	69.8±2.3	27.9±3.6	65.6±3.1	21.7±3.7	68.8±2.3	25.5±2.6	69.8±2.3	27.9±3.6
	DeepSAD ^[16]	62.3±1.1	9.4±0.8	63.8±1.5	10.8±0.8	65.1±1.3	12.8±0.7	62.3±1.1	9.4±0.8	63.8±1.5	10.8±0.8	65.1±1.3	12.8±0.7
	SADAG ^[17]	65.8±6.0	8.3±0.9	65.1±5.5	8.1±0.9	67.3±4.0	8.5±0.7	65.8±6.0	8.3±0.9	65.1±5.5	8.1±0.9	67.3±4.0	8.5±0.7
小样本	Meta-GDN ^[20]	81.1±1.9	15.5±3.5	80.6±2.4	16.5±3.9	80.6±2.3	15.7±3.6	83.2±2.8	18.6±3.8	82.8±3.1	18.5±4.1	80.2±3.8	16.1±3.6
	ANEMONE-FS ^[21]	81.4±0.5	27.8±1.9	81.8±0.7	29.2±0.6	82.2±0.9	30.3±2.1	81.4±0.5	27.8±1.9	81.8±0.7	29.2±0.6	82.2±0.9	30.3±2.1
	EWS-FSGAD (ours)	96.0±1.7	73.8±8.7	97.1±1.2	77.5±6.0	97.2±1.6	79.3±6.3	96.1±1.9	74.8±9.6	97.2±1.4	78.8±5.3	97.7±0.5	80.4±5.7

表5 在 Yelp 数据集上不同算法的实验性能对比 (ROC、PR 分别代表 AUC-ROC、AUC-PR)

每类标签数量		5		10		15		5		10		15	
实验设置		1-shot						3-shot					
类型	评价标准(%)	ROC	PR										
无监督	DOMINANT ^[7]	37.9±0.4	3.8±0.1	37.9±0.4	3.8±0.1	37.9±0.4	3.8±0.1	37.9±0.4	3.8±0.1	37.9±0.4	3.8±0.1	37.9±0.4	3.8±0.1
	ANEMONE ^[12]	42.0±0.8	4.4±0.1	42.0±0.8	4.4±0.1	42.0±0.8	4.4±0.1	42.0±0.8	4.4±0.1	42.0±0.8	4.4±0.1	42.0±0.8	4.4±0.1
	CoLA ^[13]	43.5±0.9	4.7±0.2	43.5±0.9	4.7±0.2	43.5±0.9	4.7±0.2	43.5±0.9	4.7±0.2	43.5±0.9	4.7±0.2	43.5±0.9	4.7±0.2
	PREM ^[14]	50.7±0.1	5.1±0.1	50.7±0.1	5.1±0.1	50.7±0.1	5.1±0.1	50.7±0.1	5.1±0.1	50.7±0.1	5.1±0.1	50.7±0.1	5.1±0.1
半监督	SemiGNN ^[15]	51.2±2.2	5.6±0.5	52.4±2.2	5.7±0.4	53.2±1.4	5.8±0.3	51.2±2.2	5.6±0.5	52.4±2.2	5.7±0.4	53.2±1.4	5.8±0.3
	DeepSAD ^[16]	59.8±0.7	7.2±0.3	60.7±0.9	8.0±0.3	61.9±0.6	9.0±0.4	59.8±0.7	7.2±0.3	60.7±0.9	8.0±0.3	61.9±0.6	9.0±0.4
	SADAG ^[17]	47.7±1.3	5.1±1.3	48.5±1.0	5.0±0.1	49.8±0.3	5.2±0.2	47.7±1.3	5.1±1.3	48.5±1.0	5.0±0.1	49.8±0.3	5.2±0.2
小样本	Meta-GDN ^[20]	63.7±3.2	9.2±0.9	60.0±3.2	8.8±1.2	61.2±3.9	8.8±1.4	61.9±3.3	9.1±0.9	60.2±2.7	9.2±1.2	63.2±1.7	8.7±1.3
	ANEMONE-FS ^[21]	46.1±1.6	4.7±0.1	47.0±2.0	4.8±0.2	47.7±0.6	4.9±0.1	46.1±1.6	4.7±0.1	47.0±2.0	4.8±0.2	47.7±0.6	4.9±0.1
	EWS-FSGAD (ours)	65.7±1.3	10.3±0.9	66.5±3.0	10.5±0.8	66.8±1.6	10.7±0.8	68.4±1.7	10.5±0.8	68.7±1.1	10.8±1.1	68.9±1.7	11.1±1.2

他节点的行为模式,从而无法有效指导半监督和小样本方法学习异常模式,反而可能导致性能下降。相比之下,EWS-FSGAD能够有效利用稀缺的标记样本和大量无标记样本,不仅优于半监督和小样本方法,还超越了无监督方法。即使标记样本的普适性不足,EWS-FSGAD也能够通过GLN捕获样本的全局和局部结构信息,从而进行异常模式的分析和推断。重建损失的引入也使得

EWS-FSGAD学到的节点表示更加鲁棒。此外,跨网络元学习的训练方式使得EWS-FSGAD能够快速适应新的极其弱监督场景,具备强大的异常检测能力。

(3)最后,随着每类标签数的增加,半监督和小样本方法的性能逐渐提升,证明了标记信息的重要性,并表明通过增加标记样本数量,可以有效提升EWS-FSGAD及其他半监督GAD和FS-

GAD算法的性能。除此之外,当每类标签数量固定时,EWS-FSGAD在3-shot设置下的性能优于1-shot设置,这表明在目标网络上进行微调时,通过利用更多的标记节点,从标记节点集中采样得到更大的支持集,能够获得更加优越的实验性能。

4.4 消融实验

为了进一步验证EWS-FSGAD模型中各个关键模块的作用,本文在所有数据集上,针对每类标签数量为5的实验设置进行了大量的消融实验(Ablation Study),实验结果如表6所示。

表6 消融实验(w/o表示EWS-FSGAD模型没有使用某个模块,ROC、PR分别代表AUC-ROC、AUC-PR)

每类标签数量	5															
	数据集				Flickr				PubMed				Yelp			
	实验设置		1-shot		3-shot		1-shot		3-shot		1-shot		3-shot			
评价标准(%)	ROC	PR	ROC	PR												
EWS-FSGAD(w/o FA-GDC)	73.4±6.6	20.3±6.5	75.1±5.0	21.0±4.4	80.2±6.8	17.5±2.7	82.3±3.5	18.7±4.9	63.2±1.8	9.4±1.3	63.5±2.5	9.8±1.1				
EWS-FSGAD(w/o GCN)	77.7±4.5	32.8±6.2	78.0±5.4	33.1±5.7	94.8±1.3	71.2±5.2	94.8±1.4	71.4±4.8	65.4±2.7	9.7±1.4	65.7±1.8	10.1±1.6				
EWS-FSGAD(w/o 交叉注意力)	78.7±5.9	35.2±6.9	79.9±3.8	35.8±6.5	95.0±1.7	73.1±8.9	95.4±1.9	73.2±11.9	66.1±2.3	10.2±1.4	67.4±1.7	10.3±1.3				
EWS-FSGAD(w/o 重建损失)	80.8±2.4	31.3±8.1	81.0±4.1	31.6±9.4	95.8±1.4	71.4±7.2	96.0±1.4	72.6±6.8	64.0±2.7	9.9±1.7	64.7±2.5	10.0±1.5				
EWS-FSGAD	82.5±4.3	38.7±6.8	83.7±4.8	39.1±6.3	96.0±1.7	73.8±8.7	96.1±1.9	74.8±9.6	65.7±1.3	10.3±0.9	68.4±1.7	10.5±0.8				

表6中所用模型变体的介绍如下:

(1)EWS-FSGAD:本文提出的EWS-FSGAD模型,结构与第3节中介绍的一致。

(2)EWS-FSGAD(w/o FA-GDC):保持其他结构不变,移除GLN层中的FA-GDC层,使GLN网络仅由GCN层组成以学习节点表示。

(3)EWS-FSGAD(w/o GCN):保持其他结构不变,移除GLN层中的GCN层,使GLN网络仅由FA-GDC层组成以学习节点表示。

(4)EWS-FSGAD(w/o 交叉注意力):保持其他结构不变,移除GLN层中的交叉注意力模块。

(5)EWS-FSGAD(w/o 重建损失):保持其他结构不变,训练过程中不使用自监督重建损失 \mathcal{L}_R ,即移除 GLN_ϕ 和 p_θ ,总损失函数仅包括标记数据上的偏差损失 \mathcal{L}_D 。

通过表6的实验结果,我们可以得出以下结论:

(1)全局与局部信息的重要性:无论是移除GLN层中的FA-GDC层(用于捕获节点全局结构信息),还是移除GCN层(用于捕获节点局部结构信息),相应的退化模型EWS-FSGAD(w/o FA-GDC)和EWS-FSGAD(w/o GCN)的性能均显著低于完整的EWS-FSGAD框架。这表明,在学习鲁棒的节点表示时,同时考虑节点的全局和局部结构信息至关重要。

(2)全局信息的关键作用:EWS-FSGAD(w/o FA-GDC)的性能低于EWS-FSGAD(w/o GCN),说明节点的全局结构信息在GAD任务中起到了比局部结构信息更为关键的作用。这一结果有效验证了本文之前提出的假设,即全局结构信息在异常检

测中的重要性。

(3)交叉注意力模块的必要性:在移除GLN层中的交叉注意力模块后,EWS-FSGAD(w/o 交叉注意力)无法有效地实现全局与局部结构信息之间的交互和融合,只能单独提取这些信息,因此其性能低于完整的EWS-FSGAD。这表明,在学习节点表示时,节点间全局与局部结构信息的交互及互补(包括全局与局部信息的互补、高频与低频信息的互补)对提升模型性能至关重要。

(4)重建损失的影响:在移除自监督重建损失 \mathcal{L}_R 后,EWS-FSGAD(w/o 重建损失)的性能有所下降。这表明, \mathcal{L}_R 能够为模型优化提供更多有效的自监督信息,帮助学习更加鲁棒的节点表示,从而有效挖掘数据的本质特征,提升异常检测性能。

4.5 超参数分析实验

本文进一步探究了所提出的EWS-FSGAD模型对关键超参数的敏感性和鲁棒性。在PubMed数据集上,每类标签数量为5的实验设置下,评估了EWS-FSGAD在三个超参数的不同取值下的AUC-ROC指标。这三个超参数分别是:调节偏差损失和重建损失的权重参数 β 、节点低维特征嵌入的维度 v 以及微调步数 T 。具体而言,权重参数 β 的取值范围为 $\{0.01, 0.1, 1, 10, 100\}$,嵌入维度 v 的取值范围为 $\{64, 128, 256, 512, 1024\}$,微调步数 T 的取值范围为 $\{1, 3, 5, 10, 15\}$ 。实验结果如图3所示。

通过图3中的实验结果,我们可以得出以下结论:

(1)权重参数 β 的影响: β 用于调节EWS-

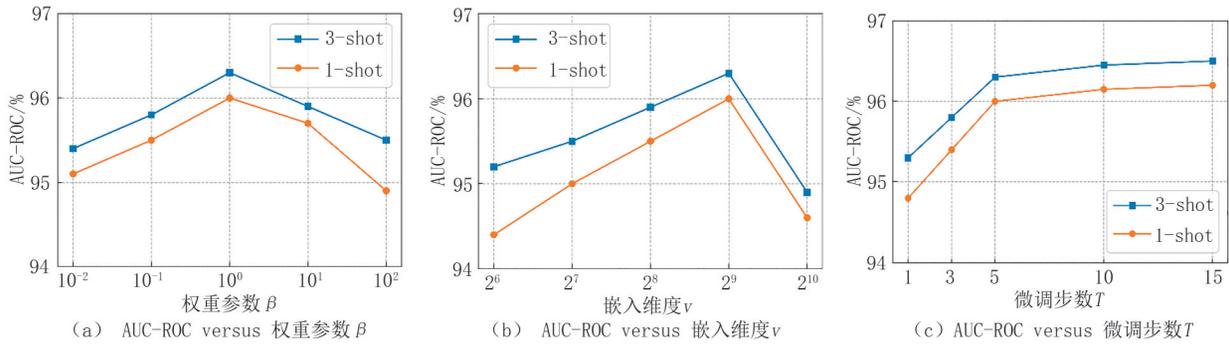


图3 在每类标签数量为5的PubMed数据集上的超参数敏感性分析

FSGAD在有监督偏差损失 \mathcal{L}_D 和自监督重建损失 \mathcal{L}_R 之间的权重分配。当 β 较大时, EWS-FSGAD 更加关注通过重建节点表示来提取节点的本质特征, 但这可能导致对决定性分类信息的关注不足, 从而忽略异常节点与正常节点之间的差异。因此, 过大的或过小的 β 都会导致模型的性能下降。在本实验中, 最佳的 β 取值为1。

(2) 嵌入维度 v 的影响: v 表示 GLN 提取的节点低维特征嵌入的维度。当 v 过小时, EWS-FSGAD 的模型容量不足, 导致节点表示的信息量有限; 而当 v 过大时, 尽管模型容量增大, 但过大的嵌入维度可能使节点表示变得稀疏, 并引入冗余信息, 从而对性能产生负面影响。因此, 过大的或过小的 v 都会导致性能的下降。在本实验中, 最佳的 v 取值为512。

(3) 微调步数 T 的影响: T 表示在微调阶段, 通过梯度下降在支持集上微调模型参数的步数。从图3(c)可以观察到, 随着 T 从1增加到5, AUC-ROC 指标迅速提升, 但随后增长趋于平缓。因此, 为了在模型性能和复杂度之间取得平衡, 本实验选择了 $T=5$ 。

为了更加深入地探究 shot 数 (K) 的增加对于 FS-GAD (Meta-GDN、ANEMONE-FS 和 EWS-FSGAD) 模型性能的影响, 本文在 PubMed 数据集上, 每类标签数量为15时, 进一步评估了小样本模型在 5-shot 和 10-shot 实验设置下的 AUC-ROC 和 AUC-PR, 结果如图4所示。需要说明的是, 由于 ANEMONE-FS 不涉及从标记节点中分别采样 K 个异常节点和 K 个正常节点来构建支持集, 因此, 其在不同 shot 数设置下的实验结果保持一致。

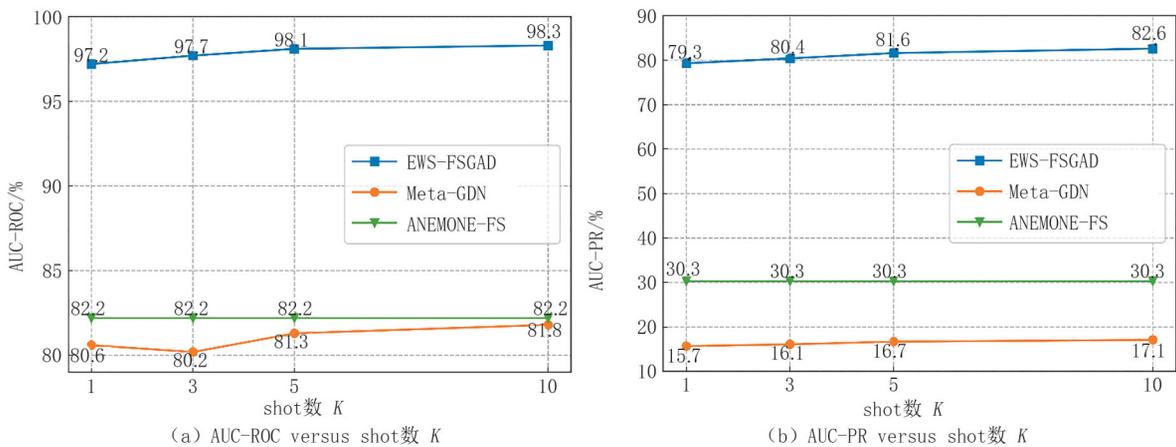


图4 在每类标签数量为15的PubMed数据集上的shot数对小样本图异常检测模型性能的影响分析

通过图4中的实验结果, 我们可以发现:

(1) 随着 shot 数的增加, EWS-FSGAD 的性能 (AUC-ROC、AUC-PR) 稳步提升。尽管 Meta-GDN 的 AUC-ROC 存在一定波动, 但总体上也呈现增长趋势, AUC-PR 则持续提升。这表明, 增加 shot

数可以为 FS-GAD 模型提供更多监督信息, 从而有效提升模型性能。此外, EWS-FSGAD 在稳定性上显著优于现有的 Meta-GDN 模型。

(2) EWS-FSGAD 的 AUC-ROC 提升逐渐减缓, 整体提升幅度也较为有限。这是因为随着 shot

数的增加, EWS-FSGAD能够从更多标记节点中提取更加丰富的信息。在初始增长阶段, AUC-ROC的提升较为明显。然而, 随着shot数的进一步增加, 额外标记节点对AUC-ROC的改善作用逐渐减弱, 最终导致提升的饱和。除此之外, 当 $K=1$ 时, AUC-ROC已经接近饱和状态, 达到97.2%(最大值为100%), 因此继续增加shot数不会带来数值的显著提升。相比之下, AUC-PR在 $K=1$ 时的值为79.3%, 仍有较大提升空间, 随着shot数的持续增加, 其能够持续显著提升。

4.6 t-SNE可视化

为了更加直观地评估EWS-FSGAD的图异常检测性能, 本文在PubMed数据集上, 每类标签数量为5的实验设置下, 利用t-SNE^[72]算法对模型在测试阶段所提取的异常节点和正常节点的嵌入进行了可视化。具体来说, 本文分别对Meta-GDN、ANEMONE-FS和EWS-FSGAD进行了可视化, 并将结果展示于图5中。需要说明的是, 由于ANEMONE-FS不涉及从标记节点中分别采样 K 个异常节点和 K 个正常节点以构建支持集, 因此其在1-shot和3-shot设置下的实验结果是相同的。

从图5可以看出, EWS-FSGAD通过GLN提取的节点特征表现出更强的鲁棒性和更高的区分度, 从而使得图异常检测性能达到了最优。

4.7 复杂度分析

本节通过实验分析了EWS-FSGAD与其他

FS-GAD模型(Meta-GDN、ANEMONE-FS)的训练效率, 包括时间复杂度和空间复杂度。为了确保实验的公平性, 所有实验均在同一台机器上进行。在每类标签数量为5和1-shot设置的PubMed数据集上, 模型的运行时间与显存占用情况如表7所示。其中, MT表示模型训练时显存的占用大小, ME表示模型推理时显存的占用大小, TT表示模型训练时单次迭代所需的时间, TE表示模型完成推理所需的时间。显存的单位为MB, 时间的单位为秒。

表7 在每类标签数量为5和1-shot的PubMed数据集上的复杂度分析

方法	MT	TT	ME	TE
Meta-GDN ^[20]	403	0.0187	399	0.0050
ANEMONE-FS ^[21]	306	1.4642	303	359
EWS-FSGAD (ours)	7275	4.5932	3027	0.0119

通过表7中的实验结果, 我们可以观察到:

(1) EWS-FSGAD的推理时间(TE)与Meta-GDN接近, 并显著低于ANEMONE-FS。这主要是因为ANEMONE-FS在推理过程中采用了耗时的子图采样和多轮评估策略, 而EWS-FSGAD和Meta-GDN的推理过程较为简化, 只需使用网络编码器提取节点表示, 接着通过分类器计算节点的异常得分, 因此其推理时间复杂度较低。

(2) EWS-FSGAD在训练时的显存占用(MT)和单次迭代时间(TT)较高。这主要是由于EWS-FSGAD的网络编码器GLN中引入了复杂度较高

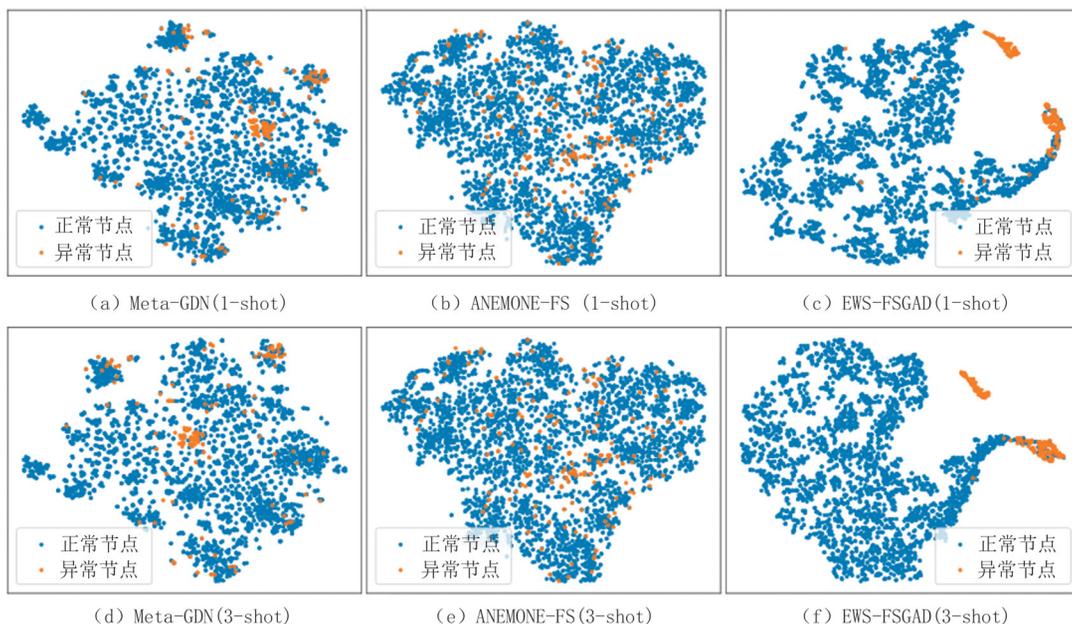


图5 在每类标签数量为5的PubMed数据集上的t-SNE可视化

的注意力机制。除此之外,重建损失 \mathcal{L}_r 的引入也增加了模型的计算复杂度。尽管EWS-FSGAD在训练时的空间和时间复杂度较高,但在当前GPU硬件水平下是普遍可以接受的。

总体而言,本文提出的EWS-FSGAD方法在评价指标(AUC-ROC、AUC-PR)和训练效率之间达到了较好的平衡,为现实应用场景中的大规模工业部署提供了有力的支持。

5 结论

在本研究中,首次探讨并解决了在极其弱监督场景下的小样本图异常检测问题。为了克服现有模型在标记数据极其有限的元训练任务下的性能瓶颈,本文提出了EWS-FSGAD框架。具体而言,本文首先提出了一个通用且高效的GNN模块,即GLN,其能够同时捕获并利用节点间的全局和局部结构信息,并进一步引入注意力机制实现节点间信息的交互与融合,从而更有效地学习节点的低维特征嵌入。此外,本文还采用了图对比学习中的自监督重建损失,以提供更多有效的自监督信息,从而优化模型并提升其泛化能力。通过在多个真实数据集上的大量实验验证,相较于现有的算法,在标记数据极其有限的元训练任务下,EWS-FSGAD能够更精确地捕捉到异常节点的本质特征,显著提升了小样本图异常检测任务的有效性。

尽管本文提出的EWS-FSGAD模型有效提升了极其弱监督场景下的小样本图异常检测任务的性能,但仍面临以下的挑战:(1)EWS-FSGAD要求以完整的图结构作为输入,通过图扩散卷积和常规图卷积学习节点表示,并引入了计算开销较大的注意力机制,这导致其在时间和内存资源上的要求较高。因此,是否可以借鉴如GraphSAGE^[36]等方法,通过为每个节点采样固定邻居节点以构建子图,从而有效降低时间和空间复杂度,以适应更大规模图数据,仍是一个值得深入研究的方向;(2)EWS-FSGAD主要针对图数据中的节点级异常检测,但边级和图级异常检测同样是图异常检测领域的重要研究课题。因此,如何将EWS-FSGAD拓展至边级别和图级别的异常检测任务,例如设计边表示学习机制以捕捉边的异常特征,或引入全图表示学习方法实现整体图结构的异常检测,也是一个亟待研究和探讨的方向;(3)EWS-FSGAD通过注意力机制实现节点间的信息交互,以捕捉节点之间的复杂关

系。然而,近期研究表明^[73],其他更高效的信息交互方式在性能和计算效率上可能具有显著优势。因此,如何将这些先进的信息交互技术融入EWS-FSGAD,以优化节点信息交互效率并提升模型在大规模图数据中的适用性,也是一个需要进一步研究的方向。

作者贡献声明 郑文捷、傅司超二人对本文具有同等贡献,为共同第一作者。

参考文献

- [1] Chen M, Cai X, Lin J, et al. Tensor learning induced multi-view spectral clustering. *Chinese Journal of Computers*, 2024, 47(1): 52-68.(in Chinese)
(陈曼笙, 蔡晓莎, 林家祺, 等. 张量学习诱导的多视图谱聚类. *计算机学报*, 2024, 47(1): 52-68)
- [2] Chen M, Ren L, Wang C, et al. Multi-view clustering by hybrid-order affinity: a generalized perspective. *Chinese Journal of Computers*, 2024, 47(7): 1453-1468.(in Chinese)
(陈曼笙, 任骊安, 王昌栋, 等. 基于混合阶相似性的多视图聚类: 一个广义的视角. *计算机学报*, 2024, 47(7): 1453-1468)
- [3] Wang Y, Fu S, Peng Q, et al. Multi-view interaction graph convolutional network for semi-supervised classification. *Journal of Software*, 2024, 35(11): 5098-5115.(in Chinese)
(王悦天, 傅司超, 彭勤牧, 等. 半监督场景下多视角信息交互的图卷积神经网络. *软件学报*, 2024, 35(11): 5098-5115)
- [4] Ying R, He R, Chen K, et al. Graph convolutional neural networks for web-scale recommender systems//*Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. London, UK, 2018: 974-983
- [5] Bandyopadhyay S, Lokesh N, Murty M N. Outlier aware network embedding for attributed networks//*Proceedings of the AAAI Conference on Artificial Intelligence*. Honolulu, USA, 2019: 12-19
- [6] Dou Y, Liu Z, Sun L, et al. Enhancing graph neural network-based fraud detectors against camouflaged fraudsters//*Proceedings of the ACM International Conference on Information and Knowledge Management*. Virtual Event, Ireland, 2020: 315-324
- [7] Ding K, Li J, Bhanushali R, et al. Deep anomaly detection on attributed networks//*Proceedings of the SIAM International Conference on Data Mining*. Calgary, Canada, 2019: 594-602
- [8] Fan H, Zhang F, Li Z. Anomalydae: Dual autoencoder for anomaly detection on attributed networks//*Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing*. Barcelona, Spain, 2020: 5685-5689
- [9] Li Y, Huang X, Li J, et al. Specac: Spectral autoencoder for anomaly detection in attributed networks//*Proceedings of the ACM International Conference on Information and Knowledge Management*. Beijing, China, 2019: 2233-2236
- [10] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks//*Proceedings of the International*

- Conference on Learning Representations. Toulon, France, 2017: 1-14
- [11] Duan J, Wang S, Zhang P, et al. Graph anomaly detection via multi-scale contrastive learning networks with augmented view//Proceedings of the AAAI Conference on Artificial Intelligence. Washington, USA, 2023: 7459-7467
- [12] Jin M, Liu Y, Zheng Y, et al. Anemone: Graph anomaly detection with multi-scale contrastive learning//Proceedings of the ACM International Conference on Information and Knowledge Management. Virtual, Australia, 2021: 3122-3126
- [13] Liu Y, Li Z, Pan S, et al. Anomaly detection on attributed networks via contrastive self-supervised learning. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(6): 2378-2392
- [14] Pan J, Liu Y, Zheng Y, et al. PREM: A simple yet effective approach for node-level graph anomaly detection//Proceedings of the IEEE International Conference on Data Mining. Shanghai, China, 2023: 1253-1258
- [15] Wang D, Lin J, Cui P, et al. A semi-supervised graph attentive network for financial fraud detection//Proceedings of the IEEE International Conference on Data Mining. Beijing, China, 2019: 598-607
- [16] Ruff L, Vandermeulen R A, Göritz N, et al. Deep semi-supervised anomaly detection//Proceedings of the International Conference on Learning Representations. Addis Ababa, Ethiopia, 2020: 1-23
- [17] Kumagai A, Iwata T, Fujiwara Y. Semi-supervised anomaly detection on attributed graphs//Proceedings of the International Joint Conference on Neural Networks. Shenzhen, China, 2021: 1-8
- [18] Pang G, Shen C, Van Den Hengel A. Deep anomaly detection with deviation networks//Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Anchorage, USA, 2019: 353-362
- [19] Ding K, Wang J, Li J, et al. Robust graph meta-learning for weakly-supervised few-shot node classification. ACM Transactions on Knowledge Discovery from Data, 2024, 18(4): 1-18
- [20] Ding K, Zhou Q, Tong H, et al. Few-shot network anomaly detection via cross-network meta-learning//Proceedings of the Web Conference. Ljubljana, Slovenia, 2021: 2448-2456
- [21] Zheng Y, Jin M, Liu Y, et al. From unsupervised to few-shot graph anomaly detection: a multi-scale contrastive learning approach. arXiv preprint arXiv:2202.05525, 2022
- [22] Xu F, Wang N, Wen X, et al. Few-shot Message-Enhanced Contrastive Learning for Graph Anomaly Detection//Proceedings of the IEEE International Conference on Parallel and Distributed Systems. Ocean Flower Island, China, 2023: 288-295
- [23] Moustafa N, Slay J. UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set)//Proceedings of the Military Communications and Information Systems Conference. Canberra, Australia, 2015: 1-6
- [24] Gasteiger J, Weissenberger S, Günnemann S. Diffusion improves graph learning//Advances in Neural Information Processing Systems. Vancouver, Canada, 2019: 13333-13345
- [25] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 770-778
- [26] Devlin J, Chang M W, Lee K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding//Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Minneapolis, USA, 2019: 4171-4186
- [27] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich, Germany, 2015: 234-241
- [28] Covington P, Adams J, Sargin E. Deep neural networks for youtube recommendations//Proceedings of the ACM Conference on Recommender Systems. Boston, USA, 2016: 191-198
- [29] Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model. IEEE Transactions on Neural Networks, 2008, 20(1): 61-80
- [30] Wu Z, Pan S, Chen F, et al. A comprehensive survey on graph neural networks. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(1): 4-24
- [31] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering//Advances in Neural Information Processing Systems. Barcelona, Spain, 2016: 3837-3845
- [32] Levie R, Monti F, Bresson X, et al. Cayleynets: Graph convolutional neural networks with complex rational spectral filters. IEEE Transactions on Signal Processing, 2018, 67(1): 97-109
- [33] Li R, Wang S, Zhu F, et al. Adaptive graph convolutional neural networks//Proceedings of the AAAI Conference on Artificial Intelligence. New Orleans, USA, 2018: 3546-3553
- [34] Zhuang C, Ma Q. Dual graph convolutional networks for graph-based semi-supervised classification//Proceedings of the World Wide Web Conference. Lyon, France, 2018: 499-508
- [35] Gilmer J, Schoenholz S S, Riley P F, et al. Neural message passing for quantum chemistry//Proceedings of the International Conference on Machine Learning. Sydney, Australia, 2017: 1263-1272
- [36] Hamilton W, Ying Z, Leskovec J. Inductive representation learning on large graphs//Advances in Neural Information Processing Systems. Long Beach, USA, 2017: 1024-1034
- [37] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks//Proceedings of the International Conference on Learning Representations. Vancouver, Canada, 2018: 1-12
- [38] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need//Advances in Neural Information Processing Systems. Long Beach, USA, 2017: 5998-6008
- [39] Xu K, Hu W, Leskovec J, et al. How powerful are graph neural

- networks//Proceedings of the International Conference on Learning Representations. New Orleans, USA, 2019: 1-17
- [40] Zhang J, Zhang H, Xia C, et al. Graph-bert: Only attention is needed for learning graph representations. arXiv preprint arXiv: 2001.05140, 2020
- [41] Zhang M, Li P. Nested graph neural networks//Advances in Neural Information Processing Systems. Virtual. 2021: 15734-15747
- [42] Li H, Cao J, Zhu J, et al. Curvature graph neural network. Information Sciences, 2022, 592: 50-66
- [43] Song Y, Zhou C, Wang X, et al. Ordered gnn: Ordering message passing to deal with heterophily and over-smoothing//Proceedings of the International Conference on Learning Representations. Kigali, Rwanda, 2023: 1-18
- [44] Zhou Z H. A brief introduction to weakly supervised learning. National Science Review, 2018, 5(1): 44-53
- [45] RenJunfei, Tong Zhu, ChenWenliang. Self-training with incomplete labeling for multi-label text classification//Proceedings of the Chinese National Conference on Computational Linguistics. Harbin, China, 2023: 17-30
- [46] Zhou Y, Zhu Y, Ye Q, et al. Weakly supervised instance segmentation using class peak response//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake, USA, 2018: 3791-3800
- [47] Lu Z, Fu Z, Xiang T, et al. Learning from weak and noisy labels for semantic segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(3): 486-500
- [48] Yao H, Zhang C, Wei Y, et al. Graph few-shot learning via knowledge transfer//Proceedings of the AAAI Conference on Artificial Intelligence. New York, USA, 2020: 6656-6663
- [49] Ding K, Wang J, Caverlee J, et al. Meta propagation networks for few-shot semi-supervised learning on graphs//Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver, Canada, 2022: 6524-6531
- [50] Wang S, Dong Y, Ding K, et al. Few-shot node classification with extremely weak supervision//Proceedings of the ACM International Conference on Web Search and Data Mining. Singapore, 2023: 276-284
- [51] Kondor R I, Lafferty J. Diffusion kernels on graphs and other discrete structures//Proceedings of the International Conference on Machine Learning. Sydney, Australia, 2002: 315-322
- [52] Zhao J, Dong Y, Ding M, et al. Adaptive diffusion in graph neural networks//Advances in Neural Information Processing Systems. Virtual, 2021: 23321-23333
- [53] Nt H, Maehara T. Revisiting graph neural networks: All we have is low-pass filters. arXiv preprint arXiv:1905.09550, 2019
- [54] Oono K, Suzuki T. Graph neural networks exponentially lose expressive power for node classification//Proceedings of the International Conference on Learning Representations. Addis Ababa, Ethiopia, 2020: 1-37
- [55] Zhu J, Yan Y, Zhao L, et al. Beyond homophily in graph neural networks: Current limitations and effective designs//Advances in Neural Information Processing Systems. Virtual, 2020: 7793-7804
- [56] Chien E, Peng J, Li P, et al. Adaptive universal generalized pagerank graph neural network//Proceedings of the International Conference on Learning Representations. Virtual, Austria, 2021: 1-24
- [57] Grill J B, Strub F, Alché F, et al. Bootstrap your own latent: a new approach to self-supervised learning//Advances in Neural Information Processing Systems. Virtual, 2020: 21271-21284
- [58] Thakoor S, Tallic C, Azar M G, et al. Bootstrapped representation learning on graphs//Proceedings of the International Conference on Learning Representations Workshop. Virtual, Austria, 2021: 1-14
- [59] Tang X, Li Y, Sun Y, et al. Transferring robustness for graph neural network against poisoning attacks//Proceedings of the International Conference on Web Search and Data Mining. Houston, USA, 2020: 600-608
- [60] Zhou F, Cao C, Trajcevski G, et al. Fast network alignment via graph meta-learning//Proceedings of the IEEE Conference on Computer Communications. Toronto, Canada, 2020: 686-695
- [61] Zhou Q, Li L, Cao N, et al. ADMIRING: Adversarial multi-network mining//Proceedings of the IEEE International Conference on Data Mining. Beijing, China, 2019: 1522-1527
- [62] Ding K, Wang J, Li J, et al. Graph prototypical networks for few-shot learning on attributed networks//Proceedings of the ACM International Conference on Information and Knowledge Management. Virtual Event, Ireland, 2020: 295-304
- [63] Liu L, Zhou T, Long G, et al. Isometric propagation network for generalized zero-shot learning//Proceedings of the International Conference on Learning Representations. Virtual, Austria, 2021: 1-13
- [64] Liu L, Zhou T, Long G, et al. Prototype propagation networks (PPN) for weakly-supervised few-shot learning on category graph//Proceedings of the International Joint Conference on Artificial Intelligence. Macao, China, 2019: 3015-3022
- [65] Tang L, Liu H. Relational learning via latent social dimensions//Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Paris, France, 2009: 817-826
- [66] Sen P, Namata G, Bilgic M, et al. Collective classification in network data. AI Magazine, 2008, 29(3): 93-93
- [67] Rayana S, Akoglu L. Collective opinion spam detection: Bridging review networks and metadata//Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Sydney, Australia, 2015: 985-994
- [68] Zhang Y, Jin R, Zhou Z H. Understanding bag-of-words model: a statistical framework. International Journal of Machine Learning and Cybernetics, 2010, 1: 43-52
- [69] Zhao C, Xin Y, Li X, et al. An attention-based graph neural network for spam bot detection in social networks. Applied Sciences, 2020, 10(22): 8160
- [70] Liu J, Bai X, Wang M, et al. Anomalous citations detection in academic networks. Artificial Intelligence Review, 2024, 57(4): 103
- [71] Li J, Dani H, Hu X, et al. Radar: Residual analysis for anomaly

detection in attributed networks//Proceedings of the International Joint Conference on Artificial Intelligence. Melbourne, Australia, 2017: 2152-2158

[72] van der Maaten L, Hinton G. Visualizing data using t-SNE. *Journal of Machine Learning Research*, 2008, 9(86): 2579-

2605

[73] Tang C, Zhao Y, Wang G, et al. Sparse MLP for image Recognition: Is Self-Attention Really Necessary//Proceedings of the AAAI Conference on Artificial Intelligence. Virtual, 2022, 36(2): 2344-2351



ZHENG Wen-Jie, Ph. D. candidate. His main research interests include data mining, graph representation learning and few-shot learning.

FU Si-Chao, Ph. D. candidate. His interests include manifold learning, graph representation learning, few-shot learning and class-incremental learning.

CHEN Jia-Zhen, Ph. D. candidate. Her interests include data mining, graph representation learning and graph anomaly detection.

PENG Qin-Mu, Ph. D., associate professor. His

interests include visual computing, machine learning and medical image analysis.

TU Yi-Qun, B. E. His interests include visual computing and machine learning.

ZOU Bin, Ph. D., professor. His interests include statistical learning theory and machine learning.

JING Xiao-Yuan, Ph. D., professor. His interests include machine learning, artificial intelligence and software engineering.

YOU Xin-Ge, Ph. D., professor. His interests include pattern recognition, image and signal processing, visual computing, biometric recognition and intelligent anti-counterfeiting.

Background

This paper focuses on few-shot graph anomaly detection (FS-GAD) with extremely weak supervision. With the rapid development of internet technology, FS-GAD has received increasing research interest across various fields in recent years, which aims to utilize a few labeled nodes as references to detect abnormal behaviors of abundant unlabeled nodes. Although the existing FS-GAD methods have made some progress, their superior performance highly depends on a large amount of labeled information from the meta-training tasks, which is contradictory to the extremely limited labeled data in the real world. Meanwhile, most of the existing works only consider the first-order structure information between nodes to learn node representation, while neglecting their long-range dependency relationships that are crucial for graph anomaly detection tasks.

Consequently, we propose a simple yet efficient EWS-FSGAD framework to solve the above-mentioned problems, which provides an innovative approach and perspective for FS-GAD. Specifically, we first propose a universal and efficient graph neural network architecture, called Global and Local

Network (GLN), which can effectively capture global and local structural information between nodes simultaneously and also introduces the attention mechanism to realize information interaction and fusion between different nodes to learn robust node representations more effectively. In addition, the self-supervised reconstruction loss from graph contrast learning is further introduced to maximize the mutual information between low-dimensional node feature embeddings from the original view and the augmented view, which aims to provide more self-supervised information for the proposed EWS-FSGAD optimization to learn more robust and essential low-dimensional node embeddings. Finally, the proposed EWS-FSGAD can quickly adapt to new test tasks of graph anomaly detection under the guidance of cross-network meta-learning technology. Extensive experiments have demonstrated the effectiveness of the proposed EWS-FSGAD framework.

This work was supported in part by the National Key Research and Development Program of China under Grant 2022YFF0712300, in part by the Fundamental Research Funds for the Central Universities under Grant YCJ20241203.