

## 面向 WSN 异常节点检测的融合重构机制与对比学习方法

叶苗, 程锦, 黄源, 蒋秋香, 王勇

(桂林电子科技大学广西无线宽带通信与信号处理重点实验室, 广西 桂林 541004)

**摘要:** 针对无线传感器网络 (WSN) 异常检测中的自监督学习异常检测方法需要解决负例样本信息表示单一缺乏多样性和提取 WSN 节点采集到的多模态数据时空特征不够充分影响异常检测性能的问题。对此提出了一种结合对比学习和重构机制的无线传感器网络异常节点检测方法。首先, 通过设计一种对比学习策略为重构机制模型提供足够充足的正负例样本, 并结合生成对抗网络 (GAN) 生成具有多样性特性的负例样本; 其次, 设计了一种基于多头注意力机制和图神经网络的双层时空特征提取模块。通过在实际公开数据集上的系列对比实验及其实验结果表明, 所提方法相比于传统异常检查方法和最近的图神经网络方法具有更好的精确率和召回率。

**关键词:** 无线传感器网络; 异常检测; 图神经网络; 自监督学习

**中图分类号:** TP393

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2024167

## Fusion reconstruction mechanism and contrast learning method for WSN abnormal node detection

YE Miao, CHENG Jin, HUANG Yuan, JIANG Qiuxiang, WANG Yong

Guangxi Key Laboratory of Wireless Wideband Communication and Signal Processing,  
Guilin University of Electronic Technology, Guilin 541004, China

**Abstract:** To tackle the defects of self-supervised learning anomaly detection methods for wireless sensor network (WSN) need to address the problems of single negative sample types and lack of diversity, as well as insufficient extraction of spatiotemporal features from multimodal data of wireless sensor network nodes. To address these challenges, a wireless sensor network anomaly node detection method that combines contrastive learning and reconstruction mechanisms was proposed. Firstly, this method provided sufficient positive and negative example information representation for the reconstruction model by using contrastive learning methods, and combined with generative adversarial network (GAN) to generate negative examples with diverse characteristics. Secondly, a dual layer spatiotemporal feature extraction module based on multi-head attention and graph neural network was designed. Through a series of comparative experiments on actual public datasets and their experimental results, it is shown that the method designed has better accuracy and recall compared to traditional anomaly detection methods and recent graph neural network methods.

**Keywords:** wireless sensor network, abnormal detection, graph neural network, self-supervised learning

收稿日期: 2024-04-10; 修回日期: 2024-08-20

通信作者: 黄源, huangyuan@guet.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62161006); 广西研究生教育创新计划基金资助项目 (No.YCSW2023310); 广西无线宽带通信与信号处理重点实验室主任基金资助项目 (No.GXKL06220110)

**Foundation Items:** The National Natural Science Foundation of China (No.62161006), The subsidization of Innovation Project of Guangxi Graduate Education (No.YCSW2023310), Guangxi Key Laboratory of Wireless Wideband Communication and Signal Processing (No.GXKL06220110)

## 0 引言

无线传感器网络 (WSN, wireless sensor network) 是一种由无线通信的传感器组成的需经过多跳路由的自组织网络<sup>[1]</sup>, 具有网络组建方式自由、网络拓扑结构灵活等特点<sup>[2-3]</sup>, 能够实现对温度、湿度、光强度等多种模态环境信息的探测感知, 被广泛运用于工业检测<sup>[4-5]</sup>、智慧农业<sup>[6]</sup>、医疗监护<sup>[7]</sup>、智慧城市<sup>[8]</sup>等多个领域。

由于其采用无线和多跳通信的方式, 节点能源有限, WSN 的可靠性面临挑战, 采集数据信息传输过程中易受到外界的入侵, 导致数据产生各种异常<sup>[9]</sup>。同时当无线传感器网络受外部环境干扰, 在发生节点本身电池供电、信号干扰、软件缺陷等故障时<sup>[10]</sup>, 测量的数据也会与真实数据之间存在偏差, 从而使数据产生异常<sup>[11]</sup>。对这些异常数据的检测和定位是保证无线传感器网络正常运行的关键技术之一。

节点采集到的数据在数学上可以表示为时序数据, 同一节点采集的多个物理量数据就对应了多个时序数据, 有文献也称其为多模态时序数据<sup>[12]</sup>。这些物理量数据之间往往存在一定的相关性, 例如, 当温度升高时, 湿度可能会下降, 传感器节点测量的电压也可能小幅度上升。在实际应用中, 无线传感器节点以密集排列的方式覆盖监测区域。在这种情况下, 不仅同一个节点采集的多个模态时序数据之间会存在相关性<sup>[13]</sup>, 而且不同传感器节点采集到的时序数据之间也会存在相关性<sup>[14]</sup>。当一个节点测量的温度升高时, 周围邻居节点所测的温度也会相应升高。无线传感器网络数据的这些相关性在数学上可以用属性图来表示<sup>[13]</sup>, 每个属性图节点的信息对应传感器节点采集到的多模态时序数据, 属性图节点之间的边关系就是传感器节点之间的连接关系。本文研究多节点多模态场景下的 WSN 异常检测方法, WSN 的节点异常包括点异常、上下文异常和集体异常<sup>[15-16]</sup>。其中, 点异常是指当一个数据点显著不同于数据集中的其他数据点时, 就被认为是点异常。上下文异常是指在显著偏离上下文数据模式的部分数据点, 这些数据点可能在其他场景下符合正常数据模式。因此, 上下文异常的识别不仅依赖于数据点本身, 还依赖于它所处的上下文。集体异常与上下文异常类似, 各个数据点如果单独来看可能并不显得异常, 但当它们作为一个整体时则表现出

异常特征, 并且不符合正常数据模式。

对 WSN 时序数据异常进行检测的传统方法包括基于统计方法中的均值方差方法<sup>[17]</sup>和概率密度估计法<sup>[18]</sup>, 它们将异常模式与正常的时间和空间分布进行比较来完成检测; 基于距离和聚类的检测方法, 如 K 近邻 (KNN, k-nearest neighbors) 方法<sup>[19-20]</sup>, 通过计算距离来衡量相似度, 不需要建立数据的统计模型即可处理数据。当处理高维数等更加复杂的数据时, 传统方法难以捕捉数据之间复杂的长期依赖等相关性特征, 因此不能很好地完成异常检测。对此卷积神经网络 (CNN, convolutional neural networks)<sup>[21]</sup>、循环神经网络 (RNN, recurrent neural network)<sup>[22]</sup>、长短期记忆 (LSTM, long short-term memory) 网络<sup>[23]</sup>等基于深度学习的异常检测方法被提出, 可以有效捕捉非线性关系, 学习到更复杂的特征表示, 极大地提升了对复杂数据的处理能力。但这类深度学习方法依赖于欧式空间中的距离度量和线性变换方式, 不能很好地处理一些非欧距离和具备空间相关性异常的 WSN 时序数据。因此, 基于图神经网络 (GNN, graph neural network) 方法被运用到 WSN 异常节点检测中, 它不仅能学习到 WSN 数据之间各种时序相关性, 还能利用图数据结构的特点提取 WSN 节点之间的空间相关性。但目前已有的基于 GNN 的 WSN 异常检测方法还存在以下局限性。

首先, 在利用相关性信息提取数据特征方面, 已有 WSN 异常检测方法利用模态间相关性或节点空间位置相关性等特征信息只针对单个节点上多模态间信息或多节点同一模态间信息进行相关性特征的提取, 很少考虑 WSN 中多节点多模态时序数据之间关联性特征的提取<sup>[24-25]</sup>。其次, 现有的 WSN 异常检测方法大多使用重构法或自监督学习方法来处理数据集标签缺失问题<sup>[26-27]</sup>, 但这两种方法各自存在缺陷: 重构法缺乏应对异常信息少和正负例样本类别分布不均衡的问题的能力, 在重构噪声较多的数据时效果较差; 自监督学习方法对数据进行降维操作时可能导致信息丢失, 影响模型的性能。最后, 由于无线传感器异常检测效果、样本数量和样本分布密切相关, 而且大多数数据集存在样本不均衡的问题, 其正常样本数量远多于异常样本数量, 虽然有些文献使用了类似对比学习等方法<sup>[28-30]</sup>尝试构造异常样本来扩增训练数据集, 但这些方法构造

出的负例忽略了样本之间的相似性信息和关联性信息,无法反映真实应用场景中的复杂关系,并且生成的负例中的异常类型缺乏多样性,造成模型学习到的异常信息单一化的问题。

为了解决以上提到的WSN异常检测中提取多模态时空相关特征信息不够充分、异常样本信息单一缺乏多样性和异常样本数量少、样本分布不均衡的问题,本文设计并实现了一种结合对比学习和重构机制的无线传感器网络异常节点检测CLRAD(contrastive learning and reconstruction anomaly detection)方法,包括基于多头注意力机制和图神经网络的双层时空特征提取模块、结合生成对抗网络(GAN, generative adversarial network)的对比学习模块。其中基于多头注意力机制和图神经网络的双层时空特征提取模块能充分提取时空和多时序之间的关联特征信息,适用于完成多节点多模态场景下的WSN异常检测;并且融合了GAN机制的对比学习模块能提供充足的正负样本,有助于平衡数据的特征分布。由于GAN生成的负例样本具有多样性特性,这解决了负例样本单一化的问题,有助于模型更好地适应真实数据集分布的特点。本文所做工作的主要贡献如下。

1) 本文设计了一种结合GAN自主生成相关负例的对比学习方法,相比于已有文献中使用腐蚀函数或构建随机节点子图来扩充对比学习中负例的方法,本文方法解决了生成负例的异常类型单一化的问题,增强了模型的泛化性和检测不同种类异常的能力。

2) 已有方法仅仅在单节点多模态或者多节点单模态场景下检测异常,本文基于多头注意力机制和图神经网络设计的双层时空特征提取模块综合考虑了时空相关性和模态间相关性,提高了异常检测模型的性能,并且适用于多节点多模态场景下的异常检测,应用范围更加广泛。

3) 本文在上述双层时空特征提取模块的基础上,设计了一种结合重构机制和自监督学习的异常检测框架。相比现有异常检测框架能够更加充分地提取节点的时空特征。

## 1 相关工作

本节主要介绍利用传统方法和深度学习方法解决WSN异常检测问题的相关工作。

在过去,很多科研人员尝试使用传统方法,即非深度学习的方法解决WSN异常检测问题。在处理WSN的时序数据时,传统的时间序列模型包括移动平均(MA, moving average)模型、自回归(AR, autoregressive)模型、自回归移动平均(ARMA, autoregressive moving average)模型、整合移动平均自回归(ARIMA, autoregressive integrated moving average)模型等。文献[31]使用小波变换在频域维度上分解流量数据,并使用重构法得到序列的多层级特征表示,同时利用不同大小的滑动窗口来观察不同尺度的子序列特征。文献[32]使用频谱法进行时序数据的异常检测,再利用高通图滤波器提取网络信号的高频分量,并通过特定频率分量进行阈值判断来定位异常。然而,传统方法难以综合表征网络节点属性和结构的时空特征,WSN时空特征信息的多样性也为异常节点检测任务带来了巨大挑战。

深度学习方法能够更好地整合网络结构信息和节点特征信息,从而学习数据的潜在特征,这样有利于提取数据中潜在的复杂模式<sup>[33-34]</sup>。文献[35]使用卷积神经网络与长短期记忆网络解决WSN异常检测问题,该模型通过预测后续时间戳中的时间序列来估计后续时刻出现异常的概率。文献[36]提出了一种基于长短期记忆的自编码器生成对抗网络时间序列异常检测方法,其中编码器将输入时间序列映射到隐藏层,生成器重构输入时间序列,判别器判断异常。这种方法相比传统时序分析的异常检测方法能很好地提取长时序相关性特性,但在用于WSN节点异常检测时不能很好地提取节点之间的空间相关性特征。

提取WSN节点空间相关性异常的有力工具是基于图神经网络GNN的方法。文献[37]提出了一种通过动态节点级输入和固定的拓扑信息来推断节点之间动态关联性的方法,并利用自适应传播来改变WSN中邻居节点之间的拓扑结构和权重表示,提高了模型能准确获得特征信息的能力。文献[38]设计的tGCN模块结合了图卷积网络(GCN, graph convolutional network)与结构信息,并将隐藏层表示作为解码器的输入获得重构后的图信息,通过计算重构误差来检测异常。文献[39]提出了结合GCN和神经网络因子分解机(NNFM, neural network factorization machine)的异常检测方法,该方法利

用邻居节点上的信息提取各节点的特征表示并完成矩阵分解,之后通过多层感知机 (MLP, multilayer perceptron) 进行相似性分组。文献[40]提出了一种基于扩展的时序 GCN 和添加了注意力机制的门控循环单元 (GRU, gated recurrent unit) 的端到端异常检测框架。文献[41]为 WSN 的每个节点都构造一条支路,该支路采用图注意力网络 (GAT, graph attention network) 提取模态间关联特征和时序数据特征,通过 GRU 和全连接层获得单个节点的特征表示,接着将所有节点的特征表示拼接起来通过 GAT 提取不同节点间的空间相关性特征,最后通过重构误差检测节点异常。文献[42]按照不同模态将 WSN 数据分解成多个图,首先每个图利用一个 GAT 提取空间相关性特征,然后通过自适应融合来整合不同模态特征,最后利用 GRU 提取时序的时间依赖关系,通过全连接层得到节点异常的概率。文献[43]提出了图形偏差网络 (GDN, graph deviation network) 模型计算预测行为与实际行为的偏差,从而提高 WSN 中传感器异常检测性能。文献[44]针对 LSTM 无法捕获时延异常的缺点,致力于识别传感器网络出现问题后整个网络的动态变化,提出了支持向量数据描述 (SVDD, support vector data description) 模型,该模型采用图自编码器,可以检测高维数据中的异常。文献[45]在 GDN 的基础进行了改进,加入了 Transformer,提出了 GTA 模型,该模型通过可微分的 Gumbel Softmax 采样策略能更好地学习传感器之间的邻接关系,利用扩散卷积和 GCN 构成 IP 卷积来模拟异常影响流动过程,最后通过 Transformer 预测的方式检测异常。文献[46]为多变量时间序列异常检测提出了 MST-GAT 模型,该模型借鉴 GDN 生成图特征表示。不同的是,该模型在 GDN 的基础上除了考虑模态内数据之间的相关性外,还使用模态间注意力机制捕获不同时序之间的多模态相关性。经过注意力机制提取特征后,使用时序卷积网络提取时序特征。最后,基于变分自编码器的重构模块和基于多层感知机的预测模块共同生成异常检测评分。文献[47]提出了一种基于规则改进变分自编码器的方法。第一阶段开发了一个自适应变分自编码器 (VAE, variational autoencoder) 模型,用于生成修改后的潜在空间向量样本。第二阶段生成模糊规则,以更低的误报率精确分类异常数据。这些方法利用图神经网络提取空间

相关性特征从而提高 WSN 异常检测性能。由于 WSN 数据存在数据标记困难、异常数据样本较少和正负样本不平衡的问题,所以采用以上有监督的学习方法面临着模型预测少数类别样本即异常样本的准确率难以提升的瓶颈。

由于监督学习方法依赖大量的标记数据作为训练样本,因此无监督学习方法更适用于数据量庞大、数据标记成本高或数据不易被标记等情况<sup>[40-48]</sup>,其适用范围更加广泛,因此无监督异常框架也逐步被运用到 WSN 异常检测问题上。文献[49]提出了一种卷积递归自编码器,首先通过卷积编码器对传感器间相关性进行编码,然后使用添加了注意力机制的 ConvLSTM 网络提取时间模式,对时间信息进行建模,再通过卷积解码器重构特征矩阵。文献[50]使用自编码器 (AE, autoencoder) 提取 WSN 中不同时间尺度上的特征信息,并设计了时间卷积网络 (TCN, temporal convolutional network) 与 AE 相结合的框架,该框架适合学习复杂的时间序列信息。文献[51]在无监督的图神经网络框架深度图嵌入 (DGI, deep graph infomax) 基础上做了相关改进。不仅结合了 LSTM 网络和互信息最大化算法来得到动态网络的特征表示,从而获得不同时刻图信息的变化特征,还使用 GCN 来提取某时刻图数据的属性特征信息和空间特征信息。文献[52]在文献[29]的基础上,针对大多数现有的网络嵌入方法假设节点之间只存在单一关系的问题,设计了一种无监督网络嵌入方法来联合多个图的节点嵌入。这些无监督学习方法能够在没有任何标记的数据上进行学习,但在有限正常样本上学习时通常泛化能力不强。

针对以上无监督学习方法的不足,自监督学习方法能够从未标记的数据中提取有用信息并自动生成相关标签,可以认为是一种将无监督学习方法变成有监督学习方法的有效解决方法。其中,自监督学习中的对比学习通过构造数据负例获得正负例对比信息,不需要关注实例上的细节,只需要在特征信息上对数据进行区分。因此,模型及其优化变得更加简单,且泛化能力更强。文献[29]将对对比学习结合到 WSN 异常检测框架中,使用腐蚀函数生成对应的负例,并通过编码器生成原始数据和负例数据的补丁级表示,同时,重构法能够充分获取正常数据的特征信息。文献[27]从局部图异常和全局图异常两方面检测异常,通过对比学习的方式获得负

例表示,并结合重构法,通过计算生成的正负例重构数据和原始数据之间的重构误差来检测异常图。但以上这些方法通常使用单一函数的方式获得负例,没有考虑负例多样性对对比学习效果的影响,降低了异常检测的效率。

本文针对现有 WSN 异常检测工作的问题和局限,设计了一种基于对比学习的融合时空特征的异常检测方法。该方法充分利用了空间位置相关性、模态间相关性和时间相关性,能够捕捉到更丰富的相关性特征信息,从而提高模型的鲁棒性和泛化性,该方法针对多节点多模态的无线传感器网络时序数据进行异常检测,在充分利用提取数据特征信息的同时节约检测数据的成本。

## 2 问题定义

本文通过如下方式将 WSN 采集到的数据建成图数据结构的形式,将传感器节点作为图的节点,传感器网络的拓扑结构作为图的边,则 WSN 可以表示为一个属性图  $G = (X, A)$ , 其中,  $A$  为由属性图  $G$  的拓扑结构获得的邻接矩阵,当连接第  $i$  个节点与第  $j$  个节点的边存在时,  $A_{ij} = 1$ ; 反之,  $A_{ij} = 0$ 。属性图  $G$  的属性矩阵  $X \in \mathbb{R}^{N \times D}$  包含传感器网络中多个时序(也称为多个模态)和多节点的时序属性信息,其中  $N$  为网络中包含的节点个数,  $D$  为每个节点属性特征向量的维度。

$t$ 时刻下该 WSN 异常检测模型的输出标签表示为

$$y_t = \mathcal{F}(X_t, \varpi) \quad (1)$$

其中,  $y_t$  为  $t$ 时刻的输出标签,  $\mathcal{F}$  为需要设计的异常检测模型的映射函数,  $\varpi$  为该异常检测模型参数。当输出标签  $y_t$  为 1 时,  $t$ 时刻存在异常; 当输出标签  $y_t$  为 0 时,  $t$ 时刻为正常。文本通过检测 WSN 对应属性图异常来判断 WSN 中是否存在时空相关性异常和多模态时序数据间的相关性异常。

## 3 基于对比学习的时空特征融合 WSN 异常检测模型

### 3.1 时空特征融合的异常检测模型

本文设计的结合对比学习和重构机制的无线传感器网络异常节点检测 (CLRAD) 模型如图 1 所示,它由负例生成模块、编码器模块、解码器模块、判别器模块等模块组成。

将从传感器上获取的 WSN 时序信息输入数据集预处理模块中,通过 GAN 迭代获得正负例表示作为异常检测模型的输入,经过多头注意力机制处理后,使用由空间卷积、模态卷积和时间卷积构建的图神经网络提取相关空间特征信息、模态特征信息和时间特征信息,并合并这 3 个维度的特征信息获得融合了空间、模态和时间 3 个维度的图级和节点级特征信息表示,然后通过解码器模块重构特征信息获得重构误差,并通过判别器模块判断图数据中是否存在异常节点。接下来,将详细说明模块框架中各个模块的具体设计和功能。

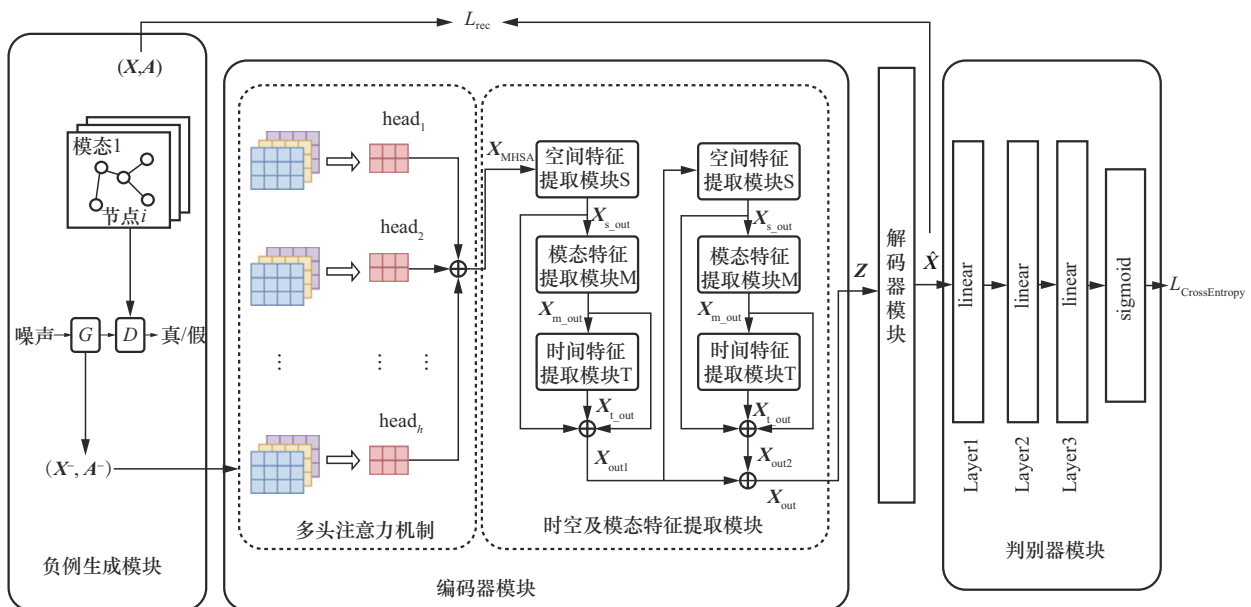


图 1 异常节点检测模型

### 3.2 对比学习机制

对比学习作为自监督学习中的一种重要方法，是通过对正负样本进行评分来实现模型训练中对相关性高的样本和相关性低的样本之间的对比分类。对比学习过程如图 2 所示，设定  $\mathbf{X}$  和  $\mathbf{A}$  分别为对应图数据  $\mathbf{G}$  中的属性矩阵和邻接矩阵，即可表示为  $\mathbf{G}=(\mathbf{X}, \mathbf{A})$ ，则其对应的负例表示为

$$(\mathbf{X}^-, \mathbf{A}^-) = C(\mathbf{X}, \mathbf{A}) \quad (2)$$

其中， $\mathbf{X}^-, \mathbf{A}^-$  分别为  $\mathbf{X}, \mathbf{A}$  对应的负例， $C(\cdot)$  为生成负例的相关函数。通过编码器之后，即可获得图数据的节点嵌入表达。

$$h = \mathcal{E}(\mathbf{X}, \mathbf{A}) \quad (3)$$

$$\mathcal{E}: \mathbb{R}^{N \times N} \times \mathbb{R}^{N \times F} \rightarrow \mathbb{R}^{N \times F'} \quad (4)$$

则定义 Readout 函数获得图数据的信息表示。

$$\hat{s} = \text{Readout}(h) \quad \text{Readout}: \mathbb{R}^{N \times F'} \rightarrow \mathbb{R}^{F'} \quad (5)$$

这里将  $N \times F'$  维的输入变成  $F'$  维，并作为输出。

在对比学习过程中，使用如式(6)所示正负例的二值交叉熵损失函数的形式。

$$L_{\text{BCE}} = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (6)$$

下面介绍本文设计异常检测模型 CLRAD 中各个模块的设计和组成。

### 3.3 负例生成模块

在获取对比学习所需的负例数据时，相比已有对比学习文献[29]中传统的使用腐蚀函数或构建随机节点子图的方法，本文设计了一种基于 GAN 的自主生成相关负例的方法，提高了模型学习到异常的多样性，使负例样本信息的获取不拘束于仅对真实样本切割或采样的方式，可以获得具有更多变化方式的时序信息异常数据，增强了模型的泛化性和检测不同种类异常的能力。

本文设计的生成对抗网络 GAN 包括生成器和判别器两部分，GAN 对对比学习生成的负例的学

习过程可表示为  $\mathbf{X}^- = G(z)$ ,  $y = D(\mathbf{X}^-)$ ，其中， $z$  为一段随机噪声， $\mathbf{X}^-$  为生成器生成的数据样本， $y$  为判别器判断生成器生成数据样本是否真实的概率值。生成器的网络结构为 Linear-ReLU-Linear-ReLU-Linear，判别器的网络结构是在生成器网络结构的基础上增加了 Sigmoid 函数。生成器生成的样本作为判别器的输入，判别器判别真假的結果会反馈给生成器，二者互相给予反馈和矫正最终达到均衡状态，使得生成器生成的样本能够更加接近真实样本。判别器的目标是 minimized 交叉熵损失，生成器的目标是 minimized 生成数据分布和真实数据分布的 JS 散度，因此采用的目标函数为

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (7)$$

其中， $D$  表示判别器网络， $x \sim p_{\text{data}}(x)$  表示从真实数据分布中抽取的真实样本， $D(x)$  表示判别器网络  $D$  认为  $x$  是真实数据的概率， $G$  表示生成器网络， $z \sim p_z(z)$  表示从潜在空间分布  $p_z(z)$  中抽取的随机噪声， $G(z)$  表示生成器网络  $G$  通过噪声生成的伪造样本。判别器网络  $D$  的目标是最大化这个期望值，当判定真实样本为真且伪造样本为假时，即  $D(x) = 1$ ,  $D(G(z)) = 0$  时，该期望值最大。生成器网络  $G$  的目标是最小化这个期望值，当判别器判定伪造样本为真时，即  $D(G(z)) = 1$  时，该期望值最小。判别器网络  $D$  和生成器网络  $G$  通过交替逐步优化来改进其性能，使二者在训练中达到一个相对均衡的状态，此时生成器生成的数据足够真实，以至于判别器无法有效区分生成数据和真实数据。

而拓扑信息的异常往往表示在节点之间连接关系的改变，即边的改变，其异常的方式并不是十分丰富，这是由传感器网络节点之间的特点决定的，




图 2 对比学习过程

传感器节点测量的是某一个位置节点附近的物理量,更多的是考虑与周围邻居节点的相关性。因此,本文设计了更为简单有效的方法来获得邻接矩阵的负例,如式(8)所示。

$$e_{ij} = \begin{cases} 0, & e_{ij} \in S_1 \\ 1, & e_{ij} \in S_0 \end{cases} \quad (8)$$

其中, $S$ 为随机选取的几对节点对的集合, $S_0, S_1 \subset S$ 且 $S_0$ 为 $S$ 集合中没有边连接的节点对, $S_1$ 为 $S$ 集合中有边连接的节点对。当 $e_{ij}=1$ 时,表示节点 $v_i$ 与节点 $v_j$ 之间有边连接;相反,当 $e_{ij}=0$ 时,表示节点 $v_i$ 与节点 $v_j$ 之间没有边连接;这里本文随机选取五对节点,改变其连接关系,由此生成所需的邻接矩阵的负例。

$$e_{ij} \subset A^- \quad (9)$$

其中, $A^-$ 为邻接矩阵的负例, $e_{ij}$ 为改变连接关系的节点对。因此,可以得到与正例形状完全相同的邻接矩阵负例 $A^-$ 和属性矩阵负例 $X^-$ ,其形状与原始数据相同。

这样设计的2种产生负例的方式不仅考虑了时间相关性异常,也考虑了空间相关性异常。

### 3.4 编码器模块

编码器模块主要包括多头注意力机制和双层时空特征提取模块两部分。为了有效提取传感器节点时间序列的空间、模态和时间3个维度的数据信息特征,本文基于GCN和TCN设计了双层时空特征提取模块,该模块由2个时空及模态特征提取模块构成,时空及模态特征提取模块包括空间特征信息提取模块(spatial feature information extraction module)、模态特征信息提取模块(modal feature information extraction module)、和时间特征信息提取模块(temporal feature information extraction module)这3种相关性特征提取模块。为了方便表述,将设计的时空及模态特征提取模块简称为SMT模块(SMT是每个特征模块英文首字母的缩写)。而双层结构的设计思路是借鉴深度学习方法中的跳跃连接和残差连接的思想<sup>[53]</sup>,能将不同类型的时空特征交错地进行融合的同时又能保留原始信息。

自注意力机制在对当前位置的信息进行编码时会过度将注意力集中于自身的信息,而多头注意力机制可以将多个头的注意力信息汇聚在一起,从而避免以上这个缺陷。多头注意力机制通过合并独立学习到的多组注意力池化输出来捕捉数据中的不同相关信息。

其流程为先将输入的序列数据分成多个头,对每个头进行独立的查询、键和值线性变换,再对每个头进行自注意力计算,得到该头的输出,最后将所有头的输出拼接在一起,并进行输出线性变换。

在提取特征信息时,GCN能实现图中对象的固有属性与对象之间拓扑信息的端到端学习。对于一个有 $L$ 层的GCN,第 $i$ 个节点 $v_i$ 在第 $l$ 层的特征表示为 $h_i^{(l)}$ ,则第 $l$ 层的特征表示为 $H^{(l)} = h\{h_1^{(l)}, h_2^{(l)}, \dots, h_N^{(l)}\}$ , $N$ 为节点个数。每一层的输入为邻接矩阵和上一层的特征表示,则层间传播方式表示为

$$H^{(l)} = \Phi(AH^{(l-1)}W^{(l-1)}) \quad (10)$$

其中, $H^{(l)}$ 与 $H^{(l-1)}$ 分别为第 $l$ 层与第 $l-1$ 层的特征表示, $A$ 为图的邻接矩阵, $W$ 为权重矩阵, $\Phi(\cdot)$ 为激活函数, $H^{(0)} = X$ , $X$ 为属性矩阵。

为了规避特征信息分布改变的问题,可以对邻接矩阵做归一化处理,则图卷积层可表示为

$$H^{(l)} = \Phi\left(\tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}H^{(l-1)}W^{(l-1)}\right) \quad (11)$$

其中, $\tilde{A} = A + I$ , $\tilde{D}$ 为 $\tilde{A}$ 对应的度矩阵。

SMT模块包括空间特征信息提取模块、模态特征信息提取模块和时间特征信息提取模块这3种相关性特征提取模块,分别设计如下。

1) 空间特征信息提取模块。将图数据的属性矩阵 $X$ 作为多头注意力机制的输入,属性矩阵 $X$ 的形状为 $[N, M, W]$ 。 $N$ 为传感器网络中节点的数量, $M$ 为模态的数量, $W$ 为时序数据的长度。多头注意力机制的计算表示为

$$X_{\text{MHSA}} = \text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O \quad (12)$$

其中, $Q$ , $K$ 和 $V$ 分别表示查询向量、键向量和值线性变换向量, $h$ 表示头的数量, $\text{head}_i$ 表示第 $i$ 个头的输出, $W^O$ 表示输出变换矩阵, $X_{\text{MHSA}}$ 的形状为 $[N, M, W]$ 。每个头的输出 $\text{head}_i$ 可以表示为

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (13)$$

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (14)$$

之后,将图数据 $G = (X_{\text{MHSA}}, A)$ 的正负例作为空间卷积网络的输入。

$$X_{s\_out} = \Phi\left(\tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}X_{\text{MHSA}}W_s\right) \quad (15)$$

其中,邻接矩阵 $A$ 的形状为 $[N, N]$ , $W_s$ 为空间权重

矩阵。输出为提取了空间特征信息的属性矩阵表达  $\mathbf{X}_{s\_out}$ ，其形状为  $[N, M, W]$ 。

2) 模态特征信息提取模块。将空间特征提取模块的输出  $\mathbf{X}_{s\_out}$  和模态间相关系数作为模态特征提取模块的输入，输出为提取了模态特征信息的属性矩阵表达  $\mathbf{X}_{m\_out}$ ，其形状为  $[N, M, W]$ 。

$$\mathbf{X}_{m\_out} = \Phi \left( \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{C} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X}_{s\_out} \mathbf{W}_m \right) \quad (16)$$

其中， $\mathbf{C}$  为模态相关系数矩阵， $\tilde{\mathbf{D}}$  为度矩阵， $\mathbf{X}_{s\_out}$  为空间特征提取模块输出的特征矩阵， $\mathbf{W}_m$  为模态权重矩阵。

$C_{ks}$  为模态相关系数矩阵中的元素，代表第  $k$  个模态与第  $s$  个模态之间的相关系数，本文使用统计学中的 Pearson 相关系数来确定  $C_{ks}$ ，如式(17)所示。

$$C_{ks} = \frac{\sum_{i=1}^n (X_{i,k} - \bar{X}_k)(X_{i,s} - \bar{X}_s)}{\sqrt{\sum_{i=1}^n X_{i,k} - \bar{X}_k^2} \sqrt{\sum_{i=1}^n (X_{i,s} - \bar{X}_s)^2}} \quad (17)$$

其中， $\mathbf{X}_k$  和  $\mathbf{X}_s$  分别为第  $k$  个模态和第  $s$  个模态的属性矩阵信息。

3) 时间特征信息提取模块。设定一个时间长度为  $T$  的时间序列  $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T\} \in \mathbb{R}^T$ 。时间卷积网络作为一种针对时间序列处理任务的卷积网络算法，使用膨胀卷积来解决输入时间序列的长度受限于卷积核大小的问题<sup>[54-55]</sup>。其表达式为

$$F(t) = \sum_{i=0}^{k-1} f(i) \mathbf{x}_{t-di} \quad (18)$$

其中， $d$  为扩张系数， $k$  为卷积核大小，滤波器  $F = (f_1, f_2, \dots, f_i)$ ，则相邻的取样点之间扩张的大小为  $d-1$ 。TCN 的传输方式可表示为

$$\mathbf{Z} = \text{ReLU}(F(\mathbf{x}) + \mathbf{x}) \quad (19)$$

其中， $\mathbf{Z}$  为整个卷积网络的输出。为了保证网络模块中输入输出的大小相匹配，可以使用一个额外的卷积层处理序列  $\mathbf{x}$  来完成跨层传输。

为了使用 TCN 提取时间特征，本文将模态特征提取模块的输出  $\mathbf{X}_{m\_out}$  作为 TCN 的输入，TCN 的输出就可以表示为

$$\mathbf{X}_{t\_out} = \text{Fconv}(\mathbf{X}_{m\_out}) + \text{linear}(\mathbf{X}_{m\_out}) \quad (20)$$

其中，输出为提取了时间特征信息的属性矩阵表达  $\mathbf{X}_{t\_out}$ ，其形状为  $[N, M, W]$ ，Fconv 表示卷积层，Linear 表示线性层。

最后，将以上 3 个模块的输出结果融合在一

起，作为 SMT 模块的输出，表示为

$$\mathbf{X}_{out1} = \text{Concat}(\mathbf{X}_{s\_out}, \mathbf{X}_{m\_out}, \mathbf{X}_{t\_out}) \quad (21)$$

则双层 SMT 模块的输出表示为

$$\mathbf{X}_{out} = \text{Concat}(\mathbf{X}_{out1}, \mathbf{X}_{out2}) \quad (22)$$

### 3.5 解码器模块与判别器模块

将对比学习模块输出的正负例通过两层 SMT 模块之后，可以获得正例、负例对应的特征提取信息，且形状都为  $[N, M, 3W]$ 。通过对多层 SMT 模块的输出进行维度变换，可以获得与原始数据维度相同的特征提取数据，即通过解码器模块完成对数据的重构，解码器与编码器模块的结构具有对称性，该过程可表示为

$$\mathbf{Z} = \text{SMT}(\mathbf{X}, \mathbf{A})$$

$$(\hat{\mathbf{X}}, \hat{\mathbf{A}}) = \text{Decoder}(\mathbf{Z}) \quad (23)$$

其中， $\mathbf{Z}$  为隐藏层表示，Decoder( $\cdot$ ) 为使用解码器模块进行数据的重构， $\mathbf{X}$  与  $\mathbf{A}$  分别为原始的属性矩阵与邻接矩阵， $\hat{\mathbf{X}}$  与  $\hat{\mathbf{A}}$  分别为特征提取并重构之后的属性矩阵与邻接矩阵。

之后，将重构后图数据正负例输入判别器模块中判别正常或异常，具体判别方式为将原始数据作为数据正例，并在设定的某一节点某一模态的一段连续时刻上人工注入异常来作为数据负例，在模型对滑动窗口中的数据信息进行判断时，需要给正例高分，给负例低分来区分正负例。通过隐藏层表示  $\mathbf{Z}$  和重构输出  $\hat{\mathbf{X}}$  计算获得判定为正常类或异常类的分类概率  $p$ ，其计算表示为

$$p = \text{Sigmoid}(\text{MLP}(\mathbf{Z}, \hat{\mathbf{X}})) \quad (24)$$

### 3.6 两阶段训练过程及损失函数设计

本文设计的是一种重构型机制的异常检测方法，通过设计自监督学习中的对比学习方法为重构机制模型提供足够充足的正负例样本解决样本类别分布不均衡的问题。因此，本文设计的是一种两相训练方式。首先，本文将模型训练去学习正常输入数据的分布特征；其次，结合对比学习方法和生成对抗网络生成的具备多样性特性的负例样本，使模型学习到分辨正常样本和负样本的能力。两阶段训练流程及损失函数设计形式如下。

1) 自编码器重建阶段。使用自编码器对输入的正常数据进行重构，先使用编码器将输入数据编码成隐藏层表示  $\mathbf{Z}$ ，再使用解码器将隐藏层表示  $\mathbf{Z}$  解码为和输入数据相同维度的重构数据。训练目标是不断最小化输入的正例样本和编码器与解码器重构

出来的输出之间的重构误差。设计的重构误差函数如式(25)所示。

$$L_{\text{reconf}} = \|A_R - A\|_F + \|X_R - X\|_F \quad (25)$$

其中,  $A$  和  $X$  分别为输入正例数据的邻接矩阵和属性矩阵,  $A_R$  和  $X_R$  分别为重构数据的邻接矩阵和属性矩阵,  $\|\cdot\|_F$  为 Frobenius 范数, 用以计算矩阵中所有元素平方和的平方根。 $\|A_R - A\|_F$  反映了重构属性图的结构与原始图的结构之间的差异,  $\|X_R - X\|_F$  反映了重构数据的属性与原始数据的属性之间的差异。通过  $L_{\text{reconf}}$  损失函数训练模型学习正常数据的分布, 使得正常数据重构后尽可能地接近原始数据。

2) 自监督学习阶段。在该阶段中, 训练的目标是让模型去学习正常数据与异常数据之间的差异, 使模型拥有分辨正常数据和异常数据的能力。在这个阶段训练模型使用的异常数据是设计的基于对比学习和生成对抗网络的负例生成模块得到的负例样本, 可以考虑使用交叉熵损失来作为损失函数, 具体分析如下。

对比学习中常用的损失函数表示为

$$L_{\text{InfoNCE}} = -\log \frac{\exp\left(q \frac{k^+}{\tau}\right)}{\exp\left(q \frac{k^+}{\tau}\right) + \sum_{i=0}^N \exp\left(q \frac{k_i^-}{\tau}\right)} \quad (26)$$

其中,  $\tau$  为温度系数,  $q$  为锚样本特征,  $k^+$  为正例样本特征,  $k_i^-$  为负例样本特征,  $i \in [1, N]$ ,  $N$  为负例样本数量。

考虑到异常检测问题中数据样本分布的特点, 本文可以将  $L_{\text{InfoNCE}}$  简化为  $L_{\text{CrossEntropy}}$  的形式, 如式(27)所示。

$$L_{\text{CrossEntropy}} = -\sum_{i=0}^N y_i \log(\hat{y}_i) \quad (27)$$

其中,  $\hat{y}_i$  为经过 softmax 处理后样本之间的相似性,

$$\text{softmax}(\hat{y}_i) = \frac{\exp(\hat{y}_i)}{\sum_{j=0}^N \exp(\hat{y}_j)}, \quad \hat{y}_0 = qk^+ \text{ 为锚样本与正}$$

例样本之间的相似性,  $\hat{y}_i = qk_i^-, i \in [1, N]$  为锚样本与负例样本之间的相似性。 $y_i$  为锚样本与正负例样本之间期待的相似性,  $y_0 = 1, y_i = 0, i \in [1, N]$ 。通过降低  $y$  与  $\hat{y}$  之间的交叉熵损失可以指导模型增大锚样本与正例样本之间的相似性, 减少锚样本与负例样本之间的相似性。

当负例样本数量为 1 时,  $L_{\text{CrossEntropy}}$  可以进一步

化简为  $L_{\text{BCE}}$  形式, 如式(28)所示。

$$L_{\text{BCE}} = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (28)$$

其中,  $\hat{y}$  为锚样本与正例样本之间的相似性,  $1 - \hat{y}$  为锚样本与负例样本之间的相似性,  $y = 1$  为锚样本与正例样本之间期待的相似性。

完整的两阶段训练过程就包括针对正常数据特征提取的重构阶段和生成异常数据在内一起训练的自监督学习阶段, 因此设计的总的损失函数就可以表示为

$$\text{Loss} = L_{\text{reconf}} + L_{\text{BCE}} \quad (29)$$

在推断过程中, 只需要利用分类输出当前时刻的二分类概率即可判定当前时刻是否为异常状态。

## 4 仿真分析实验及结论

### 4.1 实验数据集

本文使用的数据集为英特尔伯克利实验室实地部署收集的 WSN 数据集。该数据集包含近两个月以来部署的 54 个传感器收集室内的湿度、温度、光照和电压值信息。该数据集传感器空间位置分布如图 3 所示。




图3 英特尔伯克利实验室实地部署收集的 WSN 数据集传感器空间位置分布

本文在使用该数据集时对数据集的内容做了很多分析和整理。首先, 通过整理发现这个数据集中在光照这一模态数据缺失比较多, 第 5、15 和 18 号节点的数据存在大量值缺失的情况, 因此没有考虑这 3 个节点的数据, 只考虑了其余 51 个传感器节点的数据。其次, 3 月 4 日至 3 月 8 日湿度、温度和电压值 3 种模态的数据发生缺失或数据大量超出合理阈值的情况较少, 数据记录较全, 因此采用了该时间段的数据进行实验。最后, 由于数据的时间间隔不统一, 部分数据时间间隔小于 30 s, 部分数据时间间隔大于 30 s。考虑到在时序数据中, 相邻的观测值往往有某种程度的相关性或趋势, 比如温度变化数据在时间上是连续的, 前一个时间点的数据对下一个时间点的数据有一定的参考价值。此外, 这

样生成的数据不易被误判为异常值。所以本文对数据进行了采样和前向填充，具体做法为设置固定采样时间间隔为 1 min，把离采样时间最近的值作为采样值，若数据值缺失，即在采样时间间隔内没有数值，则用前一个数据值补充。

综上所述，本文选取数据集中 3 月 4 日至 3 月 8 日的 51 个传感器节点数据，其中包含 5 000 个采样时刻和湿度、温度、电压值 3 种模态的信息数据。同时，本文基于采样时刻数量按照 6:4 的比例划分训练集和测试集。

#### 4.2 异常数据注入方式

除了使用上文中介绍的通过 GAN 学习得到的负例之外，本文还使用了其他方式，从点异常、上下文异常和集体异常 3 个方面分别进行异常数据注入。

在点异常方面<sup>[56]</sup>，由于传感器节点部署环境的复杂性和节点自身限制，WSN 采集的数据会因外界环境干扰而存在异常数据点，WSN 多跳传输的特点进一步增加了这种不确定性，传输过程中的误码可能导致个别数据符号变化和数值变化。本文采用镜像变换、尺度变换和最值变换来注入相应的异常情况。其中，镜像变换是一种将幅值按轴向原点翻转的变换方式。在设定的注入异常数据的时间窗口  $[t, t + \tau]$  中，将图原始数据的幅值乘上  $-1$  得到变换后的镜像数据，表示为

$$\mathbf{X}_{t,t+\tau}^{\text{micro}} = (-1)\mathbf{X}_{t,t+\tau} \quad (30)$$

如传输过程中符号位误码造成的异常可以通过镜像变换方式完成注入异常的处理。

尺度变换是按照一定比例改变幅值的大小来实现数据缩放的变换方式。本文将需要注入异常数据的时间窗口内的图数据幅值缩放至预定倍数，其预定倍数在倍数集合  $\{0.5, 1.5, 2, 2.5\}$  中随机选择。该过程可表示为

$$\mathbf{X}_{t,t+\tau}^{\text{scale}} = \alpha\mathbf{X}_{t,t+\tau} \quad (31)$$

其中， $\alpha$  为常数，且  $\alpha \in \{0.5, 1.5, 2, 2.5\}$ 。尺度变换常用于对原始的物理量（如温度、湿度或电压值）数据通过人为缩小或放大正常读数测量值来注入异常。例如，在 WSN 节点发生劫持被攻击时读数被修改，或者由于环境中短暂非正常光照引起的温度升高。

最值变换是一种利用原始数据某一时刻的最值来改变数据幅值的方式，即设定  $t$  时刻为注入异常数据的时间窗口中的一个时刻点，则其幅值变换可

表示为

$$\mathbf{X}_t^m = \mathbf{X}_t \pm (\mathbf{X}^{\max} - \mathbf{X}^{\min}) \quad (32)$$

其中， $\mathbf{X}^{\max}$  和  $\mathbf{X}^{\min}$  分别为该模态节点在图数据中检测到的最大值和最小值。最值变换可以用于注入数据传输中由于干扰导致某个比特位数值变化超过范围等情况下产生的异常。

在上下文异常方面<sup>[57]</sup>，使用的方式是在设定的时间窗口内构造数据幅值的上升趋势或下降趋势。对时间窗口内的任意时刻  $t$ ，有

$$\mathbf{X}_t^{\text{Cont}} = \mathbf{X}_{t-1} \pm \beta(\mathbf{X}^{\max} - \mathbf{X}^{\min}) \quad (33)$$

其中， $t \in [t, t + \Delta t]$ ， $\Delta t$  为注入的上升沿或下降沿的窗口长度， $\beta$  为一个常数系数。

在集体异常方面<sup>[58]</sup>，通常单个数据信息并不能看作异常信息，但多个数据信息组成的集合会产生异常。集体异常的注入方式如式(34)所示。

$$\mathbf{X}_{t,t+\tau}^{\text{Coll}} = a\sin\theta + b \quad (34)$$

其中， $t \in [t, t + \tau]$ ， $\tau$  为注入集体异常信息的窗口长度， $a, b$  均为常数。

#### 4.3 评价指标

为了更好地衡量评价模型的性能，本文将精确率 (Precision)、召回率 (Recall)、F1 分数 (F1 Score)、ROC 曲线 (receiver operating characteristic curve) 和 AUC (area under the curve) 作为评价指标。

精确率，即正确预测为正的占全部预测为正的比例，代表对正样本结果中的预测准确程度。精确率高意味着虚警少，但不能保证模型检测为负时，事件不发生。其计算式为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (35)$$

召回率是在实际为正的样本中被预测为正样本的概率。其计算式为

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (36)$$

F1 分数为综合精确率和召回率的评价指标。在实际应用场景中，精确率和召回率往往呈负相关，为了合理评价模型的性能，平衡精确率和召回率的影响，本文使用 F1 分数这一综合指标来获得更全面的性能评价结果。其计算式为

$$\text{F1 Score} = \frac{2}{\frac{1}{\text{Precision}} + \frac{1}{\text{Recall}}} = \frac{2\text{PrecisionRecall}}{\text{Precision} + \text{Recall}} \quad (37)$$

ROC 曲线是一种用于评估二分类器的性能的图形工具。真阳性率 (TPR, true positive rate) 也称为灵敏度, 是 ROC 曲线的纵轴, 表示所有实际为正的样本中被正确识别为正样本的比例。假阳性率 (FPR, false positive rate) 是 ROC 曲线的横轴, 表示所有实际为负的样本中被错误识别为正样本的比例。以连接(0,0)和(1,1)两点的直线为基准线, ROC 曲线距离基准线越远, 说明该模型的性能越好。

AUC 是 ROC 曲线下的面积, 即 ROC 曲线与横轴之间的面积。AUC 的取值范围在 0 到 1, AUC 值越接近 1, 表示二分类器性能越好。

其中, TP、TN、FP、FN 是混淆矩阵中常见的分类评估指标。其含义如表 1 所示。TP 为被模型预测为正例的正样本, TN 为被模型预测为负例的负样本, FP 为被模型预测为正例的负样本, FN 为被模型预测为负例的正样本。

表 1 分类评估指标含义

实际情况	预测情况	
	正例	负例
正例	TP	FN
负例	FP	TN

#### 4.4 消融实验

为了研究本文使用的网络模型中各个模块的效果和性能, 本文做了相关的消融实验。在方案 1 中, 本文在每个 SMT 模块中并行使用空间特征提取模块、模态特征提取模块和时间特征提取模块, 并将 3 种特征提取模块的结果合并作为整个 SMT 模块的输出。之后, 叠加多个 SMT 模块, 并合并每个 SMT 模块的输出结果, 同时在每层 SMT 模块加入多头注意力机制。

在后续的方案中, 本文逐步禁用各个模块。在方案 4 中, 本文在方案 5 的基础上删除了多头注意力机制, 用来评估多头注意力机制的作用。方案 3 则是在方案 4 的基础上修改了合并每个 SMT 模块输出结果的方式, 仅保留一层 SMT 模块结果的有效性。在方案 2 中, 本文将空间、模态和时间特征提取模块 3 个特征提取模块串联在一起, 仅保留最后一个特征提取模块的输出作为 SMT 模块的输出结果, 并叠加多层这样的 SMT 模块, 用来比较研究并行多个特征提取模块的有效性。在方案 1 中, 本文在方案 2 的基础上仅使用单层的 SMT 模块, 用来评估叠加多个 SMT 模块的作用。

表 2 展示了不同方案的消融实验对比结果。从表 2 中可以分析得到, 相较于单层的神经网络结构, 多层 SMT 模块的图神经网络结构在一定范围内增加了神经网络的深度, 使得每个神经元相对于前一层的感受野变得越来越大, 可以提供全局语义和抽象细节的信息, 有效提高了模型的精度。方案 2 的  $F1$  分数比方案 1 提高了 6%, 并且精确率和召回率都有提升, 特别是精确率明显上升, 同比方案 1 提高了 13%。在 SMT 模块中合并各个特征提取模块的结果使得  $F1$  分数同比方案 2 提升了 6%, 保留每种特征提取模块的特征信息表达有利于特征信息的完整性, 减少在特征提取模块之间的信息传递与处理中特征信息有损失的可能。在多层 SMT 模块的网络框架设计中, 本文将每个 SMT 模块的输出结果合并, 相比于将 SMT 模块串在一起, 且只保留最后一个 SMT 模块的输出结果的方案, 前者的  $F1$  分数提高了 7%。同时, 方案 4 相比于方案 2, 不仅保留了各类特征提取模块的特征信息表达, 还保留了多层 SMT 模块中各个 SMT 模块的特征提取结果, 使得  $F1$  分数上升了 13%, 精确率提高了 7%, 召回率提高了 17%。这说明保留神经网络特征学习过程中不同程度的中间模型的特征提取信息在一定程度上有利于模型性能的提升, 在面对层数较多的神经网络时, 可以适当使用保留中间模块输出的方式来提升网络模型的性能。方案 5 在方案 4 的基础上将  $F1$  分数提高了 20%, 说明多头注意力机制能有效提升模型的性能, 通过给不同位置的输入信号分配不同的权重, 使模型更加关注重要的输入, 有助于网络捕捉到更丰富的特征信息。

从以上分析可以看出, 表 2 中涉及的优化方案均在一定程度上有助于模型性能的提升。相比于方案 1 中单层的 SMT 模块, 方案 5 实现了  $F1$  分数 39% 的提升, 精确率 38% 的提升, 召回率 40% 的提升, 大大提升了模型的性能。

#### 4.5 对比实验

本节将本文使用的异常检测方法与另外 4 种基于深度学习模型的方法进行比较, 完成了以下对比实验。

1) CNN-LSTM。该方法利用卷积模块、长短期记忆网络模块和全连接层搭建深度学习网络<sup>[59]</sup>。卷积模块中使用了卷积核大小为 3 的 2 维卷积块, 其搭建结构为 Conv2d-MaxPool2d-Relu-Conv2d-MaxPool2d—

表2 不同方案消融实验对比结果

方案	SMT 模块层数	各特征提取模块结果是否合并	各 SMT 模块输出结果是否合并	是否使用多头注意力机制	精确率	召回率	F1 分数
方案1	单层	×	×	×	0.59	0.51	0.55
方案2	多层	×	×	×	0.72	0.53	0.61
方案3	多层	√	×	×	0.75	0.6	0.67
方案4	多层	√	√	×	0.79	0.7	0.74
方案5	多层	√	√	√	0.97	0.91	0.94

共5层，之后将卷积模块的输出作为LSTM网络模块的输入，并通过全连接层，获得分类的输出。

2) MTAD-GAT。该方法是一种基于图注意力网络的多变量时间序列异常检测框架<sup>[60]</sup>。利用2个图注意力层，并结合预测和重构2种方法来学习不同的时间序列和时刻之间的相关性。在GAT模块中，该方法构建了两类GAT，一类是面向特征的图注意力层，用来获得相邻节点之间的相关性，并检测多变量之间的相关性；另一类是面向时间的图注意力层，用来获得时间序列中的时间相关性。之后，将这两类GAT的输出合并后通过GRU来获得时序数据中间隔较大的依赖关系，并解决了长期记忆和反向传播中的梯度等问题。

3) GAT-GRU。该方法<sup>[41]</sup>以节点作为构建支路的依据，在每条支路上对单个节点上的多模态时序数据进行标准化的预处理和多模态时序数据的相关特征提取。在特征提取模块，使用GAT对标准化的图数据进行对应相关特征的提取以获得相关特征表达。之后，将2个GAT的输出表达结果合并，并通过GRU和全连接层构成的降维模块获得单个节点对应的特征表示。随后，合并多个节点的特征表示，得到 $N$ 个节点的多模态时序表示。

4) GLSL。该方法<sup>[42]</sup>是最近出现的一种融合时刻特征的异常检测方法，它按照模态将原始数据输入不同的支路中，对每一种模态的数据信息单独进行GAT模型下的特征提取，并将每一个模态上多节点空间位置特征和时序特征提取信息通过自适应融合后合并在一起。将合并后的数据信息通过两层GRU进行处理，解决了时长依赖性问题，进一步提取了传感器网络数据集中的时序特性。

对于每一个模态，该方法都增加一条支路来提取该模态中的多节点空间位置特征和时序特征提取信息，具体操作为将单个模态的多节点时序数据矩阵输入单模态上节点局部空间时序数据特征提取模

块和单模态上节点全局空间时序数据特征提取模块中来提取对应的特征信息。特征提取模块由全连接网络组成，不仅完成了特征提取的任务，也使不同模块获得的特征提取信息合并后的输出结果与输入信息的维度相同。

表3展示了CLRAD与以上4种方法的对比实验结果。其中，CNN-LSTM方法的各项实验指标结果均低于其他方法。原因在于CNN使用了一个可学习的卷积核提取每个卷积窗口内的特征，这就导致像素点的邻居是固定的，也就是说，其邻居节点的顺序是固定的，邻居数量也是固定的。但在GNN中，邻居节点是没顺序的，并且邻居数量也不固定，GNN可以处理节点不固定的任意图，这就意味着相较于CNN，GNN更适合处理节点数量不固定和顺序难以确定的非欧几里得数据，如社交网络等。在本文的对比实验中，CLRAD的F1分数相较于CNN-LSTM提高了20%，精确率和召回率分别上升了18%和21%。

表3 对比实验结果

方法	精确率	召回率	F1 分数
CNN-LSTM	0.79	0.70	0.74
MTAD-GAT	0.78	0.87	0.82
GAT-GRU	0.89	0.82	0.85
GLSL	0.94	0.87	0.91
CLRAD(本文方法)	0.97	0.91	0.94

MTAD-GAT方法针对的是单个节点的异常检测问题，没有考虑到多节点的空间特征信息和多节点的相关张量计算。因此，MTAD-GAT方法需要建立多个模型来训练学习各个节点的特征信息表示，降低训练效率的同时，训练成本是大幅度增加的。因此，相比于MTAD-GAT，考虑了多节点空间特征信息的GAT-GRU、GLSL和CLRAD方法性能更优秀。

GAT-GRU 和 GLSL 分别从节点和模态的角度构建支路来处理多节点多模态的时序数据。GLSL 的性能优于 GAT-GRU 的原因在于真实的数据集中往往节点数量远大于模态的种类数量, GAT-GRU 需要构建的网络模型更大, 在处理模态种类较多的数据时, 这类弊端在 GLSL 中也难以避免。CLRAD 并没有使用创建新的支路的方法来处理更多的数据信息, 而是将所有数据放进张量中处理, 有效解决了因数据量增加而导致的模型体量过度膨胀。CLRAD 相较于 GLSL, 在  $F1$  分数上提高了 3%, 精确率提高了 3%, 召回率提高了 4%。

为了更加全面地衡量本文方法的泛化能力, 还统计了以上每种方法的 ROC 曲线和 AUC 值。图 4 展示的是本文设计的 CLRAD 方法和做对比的 4 种异常检测方法的 ROC 曲线和 AUC 值。从图 4 中信息可以看出, 相较于其他方法, CLRAD 的 ROC 曲线更靠近左上角(0,1)点, 且 AUC 值更高, 说明 CLRAD 具有更好的分类效果和泛化能力。这是由于 CLRAD 不仅采用了对比学习方式, 还通过 GAN 为对比学习提供了更具多样性的负例样本, 使得设计的模型能够更好地适应新样本, 增强了模型的泛化能力。




图4 ROC曲线和AUC值

为了验证不同架构GAN生成数据对CLRAD模型检测效果的影响, 本文进行了不同Linear层数作为生成器和判别器的GAN结构时的对比实验。实验结果显示, 当使用3层Linear层作为生成器和判别器的GAN结构时, 精确率、召回率和 $F1$ 分数可以分别达到97%、91%和94%, 使用4层Linear层作为生成器和判别器的GAN结构的精确率、召回

率和 $F1$ 分数分别是76%、74%和75%, 使用5层Linear层作为生成器和判别器的GAN结构的精确率、召回率和 $F1$ 分数分别是74%、70%和72%。由实验结果可知, 对于IBRL数据集, 随着GAN模型参数的增加, CLRAD模型 $F1$ 分数出现明显下降趋势, 当Linear层数量增加至5层时,  $F1$ 分数下降了22%。这是由于模型中使用过多的Linear层, 容易导致模型复杂度相较于数据量来说过高, 从而引发过拟合问题。这意味着生成器可能生成看似真实但缺乏多样性的样本, 不利于后续模型训练, 这也表明根据训练样本规模选择合适的模型大小对模型的训练效果至关重要。

#### 4.6 可视化结果对比与分析

为了更加清晰地展示CLRAD方法检测异常节点的效果, 本文将部分注入的异常进行可视化处理, 并将正常情况下的数据和注入了异常的数据进行对比。

在点异常的测试中, 在第10号节点, 第2个模态的196至201时刻注入了点异常, 滑动窗口长度为20个时刻。在图5中, 时间戳3000以前数据部分为训练集的数据, 时间戳3000以后数据部分为测试集的数据, 虚线起伏部分为模型检测出的异常情况。当虚线部分的测试结果为1时, 即发生从0到1的跳变时, 则表示模型检测出该处存在异常。这里仅展示模型对测试集的测试结果。图5(a)为未注入点异常的正常数据情况, 可以看到这里的检测结果出现部分跳变, 这是在对原测试集进行检测的过程中发生的误判, 由于在训练模型时, 本文将原始数据都判定为正例, 则导致原始数据集中包含的异常情况可能被误判。图5(b)为注入了点异常的测试结果。从图5(b)可以看到, 有异常显示的尖峰处为点异常注入的时间段, 其对应的跳变虚线即模型检测出的异常结果。

在上下文异常的测试中, 本文在第19号节点, 第2个模态的823至843时刻注入上升趋势的上下文异常, 图6(a)展示的是第19号节点, 第2个模态训练集(时间戳3000以前的数据)和测试集(时间戳3000以后的数据)的数据信息, 图6(b)为注入了上升趋势上下文异常的测试数据, 同样在模型检测出的异常情况(起伏虚线部分)中, 可以看到上下文异常对应的时间窗口处出现虚线的跳变, 即模型检测出异常。




图5 点异常测试结果




图6 上下文异常测试结果

### 5 结束语

对无线传感器网络异常数据的检测与异常节点的识别是保证无线传感器网络正常运行的关键技术之一。本文设计了一种结合对比学习和重构机制的WSN异常节点检测模型, 基于多头注意力机制和图神经网络设计的双层时空特征提取模块能充分提取时空相关性信息和多时序间相关性信息, 采用对比学习和重构机制相结合的方式解决正负样本分布不均衡的问题, 同时利用生成对抗网络自主学习生成更具多样性的负例样本信息。通过实验数据的对比, 证明该模型在异常节点检测任务中拥有更好的性能。本文从数据样本类别不均衡、样本信息的多样性特征提取模块和时空关联特征方面进行了讨论, 但所做工作基本属于数据的时域特征的讨论展开的, 关于传感器采集的时间序列数据, 从频域角度进行分析局部信息和全局信息也是一种有效的方法, 如何在频域分析中进行数据增强和各种相关性特征信息的提取, 以及设计更新的生成式模型方

法, 结合目前新出现的大模型生成式人工智能方法设计出更加高效的信息提取策略对无线传感器网络异常检测领域具有重要的研究意义, 这些也是本文下一步研究的方向。

### 参考文献:

[1] GULATI K, BODDU R S K, KAPILA D, et al. A review paper on wireless sensor network techniques in Internet of things (IoT)[J]. *Materials Today: Proceedings*, 2022, 51: 161-165.

[2] 王天荆, 李秀琴, 白光伟, 等. 无线传感器网络中基于自适应网格的多目标定位算法[J]. *通信学报*, 2019, 40(7): 197-207.

WANG T J, LI X Q, BAI G W, et al. Multi-target localization algorithm based on adaptive grid in wireless sensor network[J]. *Journal on Communications*, 2019, 40(7): 197-207.

[3] O'REILLY C, GLUHAK A, IMRAN M A, et al. Anomaly detection in wireless sensor networks in a non-stationary environment[J]. *IEEE Communications Surveys & Tutorials*, 2014, 16(3): 1413-1432.

[4] DANG T B, LE D T, NGUYEN T D, et al. Monotone split and conquer for anomaly detection in IoT sensory data[J]. *IEEE Internet of Things Journal*, 2021, 8(20): 15468-15485.

- [5] 黄美根, 黄一才, 郁滨, 等. 软件定义无线传感器网络研究综述[J]. 软件学报, 2018, 29(9): 2733-2752.  
HUANG M G, HUANG Y C, YU B, et al. Software-defined wireless sensor networks: a research survey[J]. *Journal of Software*, 2018, 29(9): 2733-2752.
- [6] YANG F, SHU L, YANG Y L, et al. Optimal deployment of solar insecticidal lamps over constrained locations in mixed-crop farmlands[J]. *IEEE Internet of Things Journal*, 2021, 8(16): 13095-13114.
- [7] GAO C, YANG P, CHEN Y P, et al. An edge-cloud collaboration architecture for pattern anomaly detection of time series in wireless sensor networks[J]. *Complex & Intelligent Systems*, 2021, 7(5): 2453-2468.
- [8] 何炎祥, 孙发军, 李清安, 等. 无线传感器网络中公钥机制研究综述[J]. 计算机学报, 2020, 43(3): 381-408.  
HE Y X, SUN F J, LI Q A, et al. A survey on public key mechanism in wireless sensor networks[J]. *Chinese Journal of Computers*, 2020, 43(3): 381-408.
- [9] BOUBICHE D E, ATHMANI S, BOUBICHE S, et al. Cybersecurity issues in wireless sensor networks: current challenges and solutions[J]. *Wireless Personal Communications*, 2021, 117(1): 177-213.
- [10] ZHANG H N, XING S P, WANG J N. Security and application of wireless sensor network[J]. *Procedia Computer Science*, 2021, 183: 486-492.
- [11] CHARALAMPIDOU M, PAVLIDIS G, MOUROUTSOS S G. Sensor analysis and selection for open space WSN security applications[J]. *Majlesi Journal of Electrical Engineering*, 2019, 13(1): 95-108.
- [12] 黄训华, 张凤斌, 樊好义, 等. 基于多模态对抗学习的无监督时间序列异常检测[J]. 计算机研究与发展, 2021, 58(8): 1655-1667.  
HUANG X H, ZHANG F B, FAN H Y, et al. Multimodal adversarial learning based unsupervised time series anomaly detection[J]. *Journal of Computer Research and Development*, 2021, 58(8): 1655-1667.
- [13] VURAN M C, AKAN Ö B, AKYILDIZ I F. Spatio-temporal correlation: theory and applications for wireless sensor networks[J]. *Computer Networks*, 2004, 45(3): 245-259.
- [14] 费欢, 肖甫, 李光辉, 等. 基于多模态数据流的无线传感器网络异常检测方法[J]. 计算机学报, 2017, 40(8): 1829-1842.  
FEI H, XIAO F, LI G H, et al. An anomaly detection method of wireless sensor network based on multi-modals data stream[J]. *Chinese Journal of Computers*, 2017, 40(8): 1829-1842.
- [15] IFZARNE S, TABBAA H, HAFIDI I, et al. Anomaly detection using machine learning techniques in wireless sensor networks[J]. *Journal of Physics: Conference Series*, 2021, 1743(1): 012021.
- [16] LAI K H, ZHA D C, XU J J, et al. Revisiting time series outlier detection: definitions and benchmarks[C]//*Neural Information Processing Systems*. Massachusetts: MIT Press, 2021: 1-8.
- [17] YOGITA, PAL V. Data variance-based distributed outlier detection in wireless sensor networks[C]//*Proceedings of First International Conference on Computational Electronics for Wireless Communications*. Piscataway: IEEE Press, 2022: 465-475.
- [18] SAMPARTHI V S K, VERMA H K. Outlier detection of data in wireless sensor networks using kernel density estimation[J]. *International Journal of Computer Applications*, 2010, 5(6): 28-32.
- [19] WANG L R, LI J B, BHATTI U A, et al. Anomaly detection in wireless sensor networks based on KNN[C]//*Proceedings of the Artificial Intelligence and Security*. Piscataway: IEEE Press, 2019: 632-643.
- [20] WAZID M, DAS A K. An efficient hybrid anomaly detection scheme using K-means clustering for wireless sensor networks[J]. *Wireless Personal Communications*, 2016, 90(4): 1971-2000.
- [21] SARANGI B, MAHAPATRO A, TRIPATHY B. Outlier detection using convolutional neural network for wireless sensor network[J]. *International Journal of Business Data Communications and Networking*, 2021, 17(2): 1-16.
- [22] LAZAR V, BUZURA S, IANCU B, et al. Anomaly detection in software defined wireless sensor networks using recurrent neural networks[C]//*Proceedings of the 2021 IEEE 17th International Conference on Intelligent Computer Communication and Processing (ICCP)*. Piscataway: IEEE Press, 2021: 19-24.
- [23] MATAR M, XIA T, HUGUENARD K, et al. Multi-head attention based Bi-LSTM for anomaly detection in multivariate time-series of WSN[C]//*Proceedings of the 2023 IEEE 5th International Conference on Artificial Intelligence Circuits and Systems (AICAS)*. Piscataway: IEEE Press, 2023: 1-5.
- [24] HUANG B, WANG X H, CUI P, et al. One-class temporal graph attention neural network for dynamic graph anomaly detection[C]//*Proceedings of the 2021 2nd International Conference on Electronics, Communications and Information Technology (CECIT)*. Piscataway: IEEE Press, 2021: 783-790.
- [25] POORNIMA I G A, PARAMASIVAN B. Anomaly detection in wireless sensor network using machine learning algorithm[J]. *Computer Communications*, 2020, 151: 331-337.
- [26] LUO T, NAGARAJAN S G. Distributed anomaly detection using auto-encoder neural networks in WSN for IoT[C]//*Proceedings of the 2018 IEEE International Conference on Communications (ICC)*. Piscataway: IEEE Press, 2018: 1-6.
- [27] LUO X X, WU J, YANG J, et al. Deep graph level anomaly detection with contrastive learning[J]. *Scientific Reports*, 2022, 12(1): 19867.
- [28] ZHENG Y, JIN M, LIU Y X, et al. Generative and contrastive self-supervised learning for graph anomaly detection[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(12): 12220-12233.
- [29] VELIČKOVIĆ P, FEDUS W, HAMILTON W L, et al. Deep graph infomax[J]. *arXiv Preprint, arXiv: 1809.10341*, 2018.
- [30] 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.
- [31] 段雪源, 付钰, 王坤, 等. 基于多尺度特征的网络流量异常检测方法[J]. 通信学报, 2022, 43(10): 65-76.  
DUAN X Y, FU Y, WANG K, et al. Network traffic anomaly detection method based on multi-scale characteristic[J]. *Journal on Communications*, 2022, 43(10): 65-76.
- [32] 蒋俊正, 杨杰, 欧阳缙. 一种新的无线传感器网络中异常节点检测定位算法[J]. 电子与信息学报, 2018, 40(10): 2358-2364.  
JIANG J Z, YANG J, OUYANG S. Novel method for outlier nodes de-

- tection and localization in wireless sensor networks[J]. *Journal of Electronics & Information Technology*, 2018, 40(10): 2358-2364.
- [33] DING K Z, LI J D, AGARWAL N, et al. Inductive anomaly detection on attributed networks[C]//*Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence*. California: International Joint Conferences on Artificial Intelligence Organization, 2020: 1288-1294.
- [34] 陈波冯, 李靖东, 卢兴见, 等. 基于深度学习的图异常检测技术综述[J]. *计算机研究与发展*, 2021, 58(7): 1436-1455.  
CHEN B F, LI J D, LU X J, et al. Survey of deep learning based graph anomaly detection methods[J]. *Journal of Computer Research and Development*, 2021, 58(7): 1436-1455.
- [35] SALMI S, OUGHDIR L. CNN-LSTM based approach for dos attacks detection in wireless sensor networks[J]. *International Journal of Advanced Computer Science and Applications*, 2022, 13(4): 1-8.
- [36] AUDIBERT J, MICHIARDI P, GUYARD F, et al. USAD: UnSupervised anomaly detection on multivariate time series[C]//*Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM Press, 2020: 3395-3404.
- [37] LI Z L, YU J, ZHANG G W, et al. Dynamic spatio-temporal graph network with adaptive propagation mechanism for multivariate time series forecasting[J]. *Expert Systems with Applications*, 2023, 216: 119374.
- [38] LUO X X, WU J, BEHESHTI A, et al. ComGA: community-aware attributed graph anomaly detection[C]//*Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining*. New York: ACM Press, 2022: 657-665.
- [39] 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.
- [40] ZHENG L, LI Z P, LI J, et al. AddGraph: anomaly detection in dynamic graph using attention-based temporal GCN[C]//*Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence*. California: International Joint Conferences on Artificial Intelligence Organization, 2019: 4419-4425.
- [41] ZHANG Q H, YE M, QIU H B, et al. A novel anomaly detection method for multimodal WSN data flow via a dynamic graph neural network[J]. *arXiv Preprint*, arXiv: 2202.10454, 2022.
- [42] YE M, ZHANG Q H, XUE X S, et al. A novel self-supervised learning-based anomalous node detection method based on an autoencoder for wireless sensor networks[J]. *IEEE Systems Journal*, 2024, 18(1): 256-267.
- [43] DENG A, HOOI B. Graph neural network-based anomaly detection in multivariate time series[J]. *arXiv Preprint*, arXiv: 2106.06947, 2021.
- [44] AZIM E, WANG D J, FU Y J. Deep graph stream SVDD: anomaly detection in cyber-physical systems[M]. Berlin: Springer, 2023.
- [45] CHEN Z K, CHEN D S, ZHANG X, et al. Learning graph structures with transformer for multivariate time-series anomaly detection in IoT[J]. *IEEE Internet of Things Journal*, 2022, 9(12): 9179-9189.
- [46] DING C Y, SUN S L, ZHAO J. MST-GAT: a multimodal spatial-temporal graph attention network for time series anomaly detection[J]. *Information Fusion*, 2023, 89: 527-536.
- [47] JOTHI S A, VENKATESAN R, SANTHI V. Rule-based outlier detection with a modified variational autoencoder for enhancing data accuracy in wireless sensor networks[J]. *International Journal of Fuzzy Systems*, 2023, 25(6): 2187-2202.
- [48] ZHANG C X, SONG D J, CHEN Y C, et al. A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33(1): 1409-1416.
- [49] FENG D, WU Z C, ZHANG J, et al. Dynamic global-local spatial-temporal network for traffic speed prediction[J]. *IEEE Access*, 2020, 8: 209296-209307.
- [50] THILL M, KONEN W, WANG H, et al. Temporal convolutional autoencoder for unsupervised anomaly detection in time series[J]. *Applied Soft Computing*, 2021, 112: 107751.
- [51] 郭嘉琰, 李荣华, 张岩, 等. 基于神经网络的动态网络异常检测算法[J]. *软件学报*, 2020, 31(3): 748-762.  
GUO J Y, LI R H, ZHANG Y, et al. Graph neural network based anomaly detection in dynamic networks[J]. *Journal of Software*, 2020, 31(3): 748-762.
- [52] PARK C, KIM D, HAN J W, et al. Unsupervised attributed multiplex network embedding[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(4): 5371-5378.
- [53] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//*Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2016: 770-778.
- [54] WAN R Z, MEI S P, WANG J, et al. Multivariate temporal convolutional network: a deep neural networks approach for multivariate time series forecasting[J]. *Electronics*, 2019, 8(8): 876.
- [55] HE Y D, ZHAO J B. Temporal convolutional networks for anomaly detection in time series[J]. *Journal of Physics: Conference Series*, 2019, 1213(4): 042050.
- [56] BLÁZQUEZ-GARCÍA A, CONDE A, MORI U, et al. A review on outlier/anomaly detection in time series data[J]. *ACM Computing Surveys*, 2022, 54(3): 1-33.
- [57] CARMONA C U, AUBET F X, FLUNKERT V, et al. Neural contextual anomaly detection for time series[J]. *arXiv Preprint*, arXiv: 2107.07702, 2021.
- [58] AHMED M, MAHMOOD A N, HU J K. A survey of network anomaly detection techniques[J]. *Journal of Network and Computer Applications*, 2016, 60: 19-31.
- [59] DOHARE A K, TULIKA. A CNN and LSTM-based data prediction model for WSN[C]//*Proceedings of the 2021 3rd International Confer-*

ence on Advances in Computing, Communication Control and Networking (ICAC3N). Piscataway: IEEE Press, 2021: 1327-1330.

- [60] ZHAO H, WANG Y J, DUAN J Y, et al. Multivariate time-series anomaly detection via graph attention network[C]//Proceedings of the 2020 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE Press, 2020: 841-850.

#### [作者简介]



叶苗 (1977-), 男, 广西桂林人, 博士, 桂林电子科技大学教授、博士生导师, 主要研究方向为边缘存储与云存储、软件定义网络、无线传感器网络、模式识别与机器学习。



程锦 (1999-), 女, 安徽六安人, 桂林电子科技大学博士生, 主要研究方向为无线传感器网络、人工智能。



黄源 (1977-), 男, 广西桂林人, 桂林电子科技大学讲师, 主要研究方向为智能机器人控制、智能信息处理。



蒋秋香 (1978-), 女, 广西桂林人, 桂林电子科技大学工程师, 主要研究方向为无线传感器网络、人工智能、网络安全。



王勇 (1964-), 男, 四川成都人, 博士, 桂林电子科技大学教授、博士生导师, 主要研究方向为云计算、网络流量分析、信息安全。