

基于图提示微调的 WSN 节点时空相关性异常检测方法

叶苗^{1,2}, 崔靖¹, 黄源^{2,3}, 王勇^{1,2}, 何倩^{1,2}, 张继文³

(1. 桂林电子科技大学计算机与信息安全学院, 广西 桂林 541004;

2. 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;

3. 桂林电子科技大学电子工程与自动化学院, 广西 桂林 541004)

摘要: 针对现有异常检测方法在多时序模态数据场景下存在提取时空相关性特征不充分、异常样本类别标注代价高和异常样本不均衡问题, 设计了一种融合时空相关性特征的图神经网络异常检测主干网络和“预训练-图提示-微调”的多任务自监督训练策略。首先, 结合多尺度策略与模态融合机制改进 Mamba 模型, 并引入变分图卷积模块, 构建能充分提取无线传感器网络多节点多模态时序特征的主干网络; 其次, 设计无负例对比学习、预测与重构 3 种预训练子任务, 从无标签数据中学习通用特征, 并设计“图提示-微调”机制减少训练成本并增强检测泛化性能。实验结果表明, 所提方法在公开与实际采集数据集上 F1 值分别达到 91.30% 和 92.31%。

关键词: 无线传感器网络; 异常检测; 图神经网络; 预训练; 提示学习

中图分类号: TP393.0

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025166

Anomaly detection method for spatio-temporal correlation of WSN nodes based on graph prompt fine-tuning

YE Miao^{1,2}, CUI Jing¹, HUANG Yuan^{2,3}, WANG Yong^{1,2}, HE Qian^{1,2}, ZHANG Jiwen³

1. School of Computer Science and Information Security, Guilin University of Electronic Technology, Guilin 541004, China

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

3. School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin 541004, China

Abstract: Aiming at the existing anomaly detection methods in multi-temporal modal data scenarios, which had the problems of insufficient extraction of spatio-temporal correlation features, high cost of anomaly sample category annotation, and imbalance of anomalous samples, a graph neural network anomaly detection backbone network integrating spatio-temporal correlation features and a multi-task self-supervised training strategy of “pre-training-graph prompting-fine-tuning” was designed. Firstly, the Mamba model was improved by combining the multiscale strategy with the modal fusion mechanism, and the variational graph convolution module was introduced to construct a backbone network that could adequately extract the multi-node and multi-modal spatial and temporal features of wireless sensor network. Secondly, three pre-training sub-tasks of no-negative-case comparison learning, prediction, and reconstruction were designed to learn the generalized features from the unlabeled data, and a “graph prompting-fine-tuning” mechanism to reduce the training cost and enhance the detection generalization performance. The experimental results show that the F1 value of this method reaches 91.30% and 92.31% on the public and actual collected datasets respectively.

Keywords: wireless sensor network, anomaly detection, graph neural network, pre-training, prompt learning

收稿日期: 2025-07-01; 修回日期: 2025-09-17

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, No.62372353); 广西研究生教育创新计划基金资助项目(No.2025YCXS078); 广西无线宽带通信与信号处理重点实验室基金资助项目(No.AD25069102)

Foundation Items: The National Natural Science Foundation of China (No.62161006, No.62372353), The Subsidization of Innovation Project of Guangxi Graduate Education (No.2025YCXS078), Guangxi Wireless Broadband Communication and Signal Processing Key Laboratory (No.AD25069102)

0 引言

无线传感器网络 (WSN, wireless sensor network) 是由大量传感器节点通过无线方式连接组成的一种多跳自组织分布式网络^[1], 具有网络组建方式自由、节点部署灵活等特点, 可用于采集温度、湿度、光照、声音等多种环境数据, 广泛应用于国防安全、环境监测、工业检测、医疗保健、智能交通等^[2]多个领域。然而, 受无线通信开放性与节点故障等因素影响, WSN 传输的数据可能会偏离正常模式^[3], 若不能及时检测和定位, 将影响 WSN 的可靠性和稳定性。

在 WSN 中, 每个传感器节点监测的多个物理量可以表示为多元时序, 文献^[4]将其称为多模态时序数据。通常情况下, WSN 数据异常是指明显偏离正常数据规律的数值或模式, 对于单时序数据, 常见的异常类型^[5]包括点异常、上下文异常和集体异常。点异常^[6]是指在数值上明显偏离同类数据整体分布的单个数据点; 上下文异常^[7]是指在特定的上下文或时间范围内不符合正常模式但在其他情境下符合正常模式的数据点; 集体异常^[8]是指共同出现异常模式的一组数据点。此外, 对多个 WSN 时序数据, 由于单个 WSN 节点采集的不同模态时序之间及不同 WSN 节点之间会存在时序相关性。例如, 同一 WSN 节点采集的温度时序数据与湿度时序数据通常呈现负相关性, 这种相关性属于不同时序数据之间的时间相关性^[9]。在火灾情境下, 不同 WSN 节点测量得到的多个温度时序数据, 着火点附近的多个 WSN 节点采集到的不同温度时序数据呈现共同的上升趋势而表现为正相关性, 这种相关性属于不同时序数据之间的空间相关性^[10]。违背这些正常时空相关性规律的多个 WSN 时序数据异常模式, 可以称之为相关性异常^[9-10]。

基于上述异常类型, 研究者们围绕异常检测准确性与检测代价之间的平衡, 提出了各种异常检测方法。传统的异常检测方法有基于统计学、传统机器学习方法等, 如自回归移动平均 (ARMA, autoregressive moving average) 模型^[11]、核密度估计 (KDE, kernel density estimation) ^[12]、主成分分析 (PCA, principal component analysis) ^[13]和 K-Means 聚类^[14]等, 这些方法依赖先验分布与特征工程, 难以适应高维动态数据。而深度学习具备自动特征提取能力, 常见的卷积神经网络 (CNN, con-

volutional neural network) ^[15]、循环神经网络 (RNN, recurrent neural network) ^[16]、长短期记忆 (LSTM, long short-term memory) 网络^[17]等主流深度学习模型已经被广泛应用于异常检测任务, 提高了在高维时序数据建模时进行异常检测的能力, 但目前对处理复杂 WSN 时序数据异常检测任务仍存在以下问题。

首先, 基于深度学习的 WSN 异常检测方法在捕捉复杂的 WSN 时空依赖关系时, 一方面, 在捕捉长距离时间依赖关系方面仍存在不足, 体现在以 RNN 及其变体 LSTM 网络和门控循环单元 (GRU, gated recurrent unit) 为代表的序列建模方法在处理时间跨度较大的长期依赖关系时, 往往会因梯度消失或爆炸等问题导致远距离信息难以有效传递, 限制了模型对复杂时间模式的理解和表达能力; 另一方面, 目前大多数异常检测方法在处理 WSN 高维时序数据的相关性建模时, 仅考虑了同一节点中不同模态之间的相关性或不同节点间同一模态之间的相关性, 难以捕捉多节点多模态之间复杂的时空相关性。

其次, 由于 WSN 时序数据之间存在复杂的时空相关性特征和长期依赖特性, 数据样本类别标注过程极为困难。基于监督学习的 WSN 异常检测方法高度依赖充足且高质量的标签进行训练, 当面对大规模无标签数据时, 往往因模型对正常模式的学习能力不足而无法充分捕获真实的数据分布, 进而影响模型泛化性能, 导致其在真实复杂环境中难以有效识别未知异常。

最后, 深度学习 WSN 异常节点检测方法性能高度依赖样本数量规模大小, 在实际场景中由于异常事件通常发生频率极低, 不可避免地带来了异常样本少的问题。这种情况构成了典型的小样本环境, 即模型在训练阶段缺乏足够的异常样本进行有效学习, 难以捕捉异常类别的判别特征。已有文献通过重采样方法来解决异常样本少的问题^[18-19], 但这些方法各有局限, 对少量异常样本进行过采样可能导致模型对特定异常样本产生过拟合, 对大规模正常样本进行欠采样则可能导致重要信息丢失, 影响模型的整体泛化性能。因此, 如何在异常样本数量少的环境下有效提升模型对异常模式的识别能力, 是设计 WSN 异常检测方法时必须考虑的关键问题。

针对以上问题,本文设计了一种融合WSN多节点多模态时序数据异常检测模型,并设计了一种基于“预训练-图提示-微调”的学习方法,有效解决了训练数据标签缺失和异常样本不足的问题,主要的创新点如下。

1) 针对现有WSN多时序相关性异常检测方法局限于单节点多模态或多节点单模态场景而不适用于多节点多模态的异常检测场景、提取WSN数据的时空相关性特征不够充分的问题,本文基于改进Mamba^[20]模型设计了融合WSN多时序模态数据和多节点间时空相关性特征的异常检测主干网络,以便充分提取时空相关性特征。

2) 针对实际WSN异常样本标注困难带来标注成本高从而影响异常检测性能的问题,本文设计了基于无负例对比学习、预测和重构3种代理子任务的自监督预训练策略,以便在无监督条件下学习具有判别力的样本通用特征表示。

3) 针对实际WSN异常样本数量少带来样本不均衡问题,本文设计了“预训练-图提示-微调”学习机制,在小样本环境下提升异常检测能力,同时降低训练阶段开销。从目前能查阅到的文献来看,很少有将图提示机制引入WSN异常检测任务的研究。

1 相关工作

由于WSN各个节点采集的数据可以表示为多时序数据,本文主要解决WSN多时序数据异常检测中遇到的时空相关性异常、样本标签标注困难和异常样本小带来样本类别不均衡问题。现有工作主要分为两类:多变量时序异常检测(MTSAD, multivariate time series anomaly detection)方法和预训练与提示学习方法。

1.1 多变量时序异常检测相关工作

与传统的单变量检测方法相比,MTSAD不仅需关注多变量时序的动态演化,还需建模变量之间的关联特征,使建模与推理过程更具复杂性。因此,近年来针对WSN数据可以表示为多时序数据的特点,有研究者对此设计了多种基于MTSAD的WSN异常检测方法。通常依据从训练过程中所采用损失函数最小化形式的设计^[21],将这些方法划分为三类:基于重构、基于预测和基于自监督的方法。

基于重构的方法通常使用自编码器结构对输入数据进行编码解码,以重构误差作为异常分数。假设训练阶段正常数据可以较好地重构,而异常数据由于偏离正常模式,重构效果会较差,从而得到较高的异常分数。当异常分数超过一定阈值时,则认为该数据异常。DAEMON^[22]基于自编码器和生成对抗网络(GAN, generative adversarial network)结构,自编码器用于重构输入时序数据,GAN结构分别用于约束自编码器的中间输出和自编码器的重构输出,使自编码器结构的训练过程更加鲁棒并且减少过拟合。GReLeN^[23]利用变分自编码器(VAE, variational autoencoder)框架将图神经网络和随机图关系学习结合,捕捉传感器之间的依赖关系,基于重构误差为每个传感器分配异常分数。DVGCRN^[24]将嵌入引导的概率生成网络与自适应变分图卷积递归网络相结合,建模多变量时间序列中的传感器依赖性和随机性。MGCL^[25]构建多阶图卷积结构,跨变量与时间窗口进行联合建模,实现对复杂拓扑依赖与时序动态的鲁棒感知,结合重构任务从多源传感器数据中提取全局依赖。

基于预测的方法通过历史窗口对未来进行预测,以预测误差作为异常评分。假设训练阶段模型可以准确预测未来时刻的值,而异常时刻由于分布偏移,预测误差将显著增大,超过一定阈值则判断为异常。GTAD^[26]结合图注意力网络和时间卷积网络,同时建模时间依赖性和变量间相关性,并通过预测使用单一维度的误差作为损失函数。Topo-GDN^[27]在图偏差网络(GDN, graph deviation network)基础上引入拓扑分析模块和多尺度时间卷积模块,更好地保留节点局部结构和全局感知能力,增强对复杂时空依赖关系的建模能力。PatchTST^[28]通过补丁化降低复杂度,并利用通道独立性来处理多元时序。SageFormer^[29]基于Transformer在每个序列前加入一个全局Token,用来提取各个变量序列自身的信息,然后利用图学习的方式进行多变量关系的抽取。

基于自监督方的方法通常设计辅助任务,如预测未来时间步、重构历史片段与对比学习等,从大量无标签数据中学习可迁移知识来提升模型的泛化能力,并推广到下游异常检测任务中。TranAD^[30]提出了基于Transformer的双向对抗预测框架,通过前向和反向预测器构建时序约束,结合判别器放

大异常预测残差。CATCH^[31]提出了一种时频联合优化的自监督学习框架，通过将多变量时间序列投影至频域并进行分块，构造时间对比学习与变量间图对比学习目标，以增强模型对周期性变化与变量间耦合特征的表达能。VGATSL^[32]结合变分图注意机制与上下文对比学习，同时建模传感器拓扑结构和时间依赖。TimeAutoAD^[33]融合拓扑感知的图建模与时序信息，通过自监督对比学习构建具有鲁棒性的特征表示。

虽然这些基于多时序分析的 WSN 异常检测方法在重构能力、预测精度及结构建模方面取得了一定进展，但在处理复杂时空依赖性的相关性检测、对异常样本类别的标注和异常小样本问题上仍然存在局限性，具体体现在由于多节点多模态的多时序数据维度更加复杂，现有多时序分析的方法多数聚焦于单节点多模态或多节点单模态的 WSN 多时序异常检测任务，在多节点多模态场景下难以充分提取 WSN 数据各节点之间以及模态之间的时空相关性特征。

1.2 预训练与提示学习相关工作

近年来，“预训练 - 微调”已经成为自然语言处理、计算机视觉等领域的核心范式。然而，该范式在下游任务数据稀缺的情况下容易出现适配不足的问题。为此，提示学习^[34]被引入“预训练 - 微调”框架中，从而形成了“预训练 - 提示 - 微调”范式，其核心思想是在模型参数冻结的条件下，通过使用任务特定的提示向量来提示下游任务。

随着提示学习理念的发展，它逐步扩展到非语言领域，特别是图表示学习中。针对图结构的数据，研究者提出了图提示学习^[35]，通过为每个图或节点设计可学习的图提示向量，引导预训练图模型关注任务相关的子结构或邻接模式，从而形成“预训练 - 图提示 - 微调”范式，并证明了其在适应下游任务方面的有效性。Liu 等^[36]提出了图提示框架，将预训练和下游任务整合到一个公共的任务模板中，使用可学习的提示向量缩小下游任务和预训练模型之间的差距，指导下游任务以特定任务的方式从预训练模型中获取最相关的知识。Sun 等^[37]提出了图提示预训练 (GPPT, graph prompt pre-training)，将独立节点转换为令牌对，通过任务令牌和结构令牌的组合将下游节点分类转化为链接预测问题，并通过实验证明了其有效性。Fang 等^[38]提出

了图提示特征 (GPF, graph prompt feature) 引入图结构感知的提示调优机制，在冻结预训练图神经网络主体参数的同时，仅优化少量的图提示向量，灵活适配图分类、节点分类等任务，并在多个基准数据集上验证了其在低资源设定下的高效性和泛化能力。Chen 等^[39]提出了基于图提示的图神经网络 (GPL-GNN, graph prompt learning for graph neural network)，将提示学习引入图神经网络中，利用无监督预训练得到的结构表示作为图提示，在下游任务中引导模型提取有效特征，实现不需要修改主干网络的轻量微调，提升了小样本任务的适应能力。

由于多节点多时序的 WSN 数据具备图结构特征，节点间的空间拓扑关系与节点内多模态时序信号相结合，形成了复杂的时空依赖模式。传统的预训练 - 微调范式在异常检测任务中往往面临着下游任务标注样本困难、异常样本不足等挑战，致使预训练模型难以充分适配新的异常检测环境。图提示学习通过引入可学习的提示向量，在保持预训练模型参数冻结的前提下，有针对性地引导模型聚焦于与异常检测相关的节点局部结构及时序特征，可以有效缓解预训练任务与异常检测任务间的分布差异。在多节点多模态时序异常检测中，使用图提示学习的方法不仅能够充分利用空间拓扑结构的先验信息，还能通过提示向量动态调整对节点时序特征的关注权重，从而有效提升异常检测模型的通用性与准确性。

2 问题描述与基本原理

2.1 问题定义

WSN 数据表示为 $\mathbf{X} \in \mathbb{R}^{N \times M \times T}$ ，其中 N 表示传感器的节点个数， M 表示每个传感器节点在任意时刻 t 采集到的物理量（如温度、湿度、电压等模态）的种类， T 表示采集的时序长度。可以将时刻 t 采集到的数据建模为一个属性图 $\mathbf{G}_t = (\mathbf{A}, \mathbf{X}_t)$ ，其中 $\mathbf{A} \in \mathbb{R}^{N \times N}$ 为静态邻接矩阵，表示传感器网络中任意 2 个节点之间的邻接关系，当连接第 i 个节点和第 j 个节点的边存在时， $\mathbf{A}(ij) = 1$ ；反之， $\mathbf{A}(ij) = 0$ 。 $\mathbf{X}_t \in \mathbb{R}^{N \times M}$ 为节点在 t 时刻采集的属性矩阵，其中第 i 行 $x_i^t \in \mathbb{R}^M$ 表示节点 i 在 t 时刻的多模态时序数据。因此，可以将 WSN 整个时间段 $t = 1, 2, \dots, T$ 内采集的数据表示为图时序序列 $\mathbf{G}_{1:T} = \{\mathbf{G}_1, \mathbf{G}_2, \dots, \mathbf{G}_T\}$ ，其中， $\mathbf{G}_t = (\mathbf{A}, \mathbf{X}_t)$ 。通常，可以设

计异常节点检测模型映射函数为 F 以及对应权值参数 θ , 输入为某一时间段的属性图子序列 $\mathbf{G}_{t_1:t_2} = \{\mathbf{G}_{t_1}, \dots, \mathbf{G}_{t_2}\}$, 从而得到

$$\mathbf{Y} = F[\mathbf{G}_{t_1:t_2}; \theta] \quad (1)$$

其中, $\mathbf{Y} \in \{0,1\}^{N \times M}$ 表示检测任务的输出, 节点 i 的第 j 个模态结果 \mathbf{Y}_{ij} 表示为 $y(i,j)$, 如果 $y(i,j) = 1$ 则表示WSN在节点 i 的第 j 个模态出现异常, $y(i,j) = 0$ 则表示没有出现异常。

2.2 选择性状态空间模型Mamba

为了克服长程依赖建模受限和计算复杂度高的问题, 研究者们提出了一种有前景的序列建模架构状态空间模型(SSM, state space model)^[40], 并发展出结构化SSM^[41]和Mamba^[20,42]等高效变种模型。Mamba模型结合了选择性SSM和高效的硬件友好算法, 在多种模态任务中展现出优异性能, 如语言、图像、医学、图数据、推荐系统以及时间序列分析^[43]等领域, 展示出广泛的适应性和强大的建模能力。

Mamba模型的理论根基源于状态空间模型的连续动态系统描述, 其数学建模过程遵循以下核心范式: 给定连续输入信号 $x(t) \in \mathbb{R}^n$, 系统通过隐状态 $h(t) \in \mathbb{R}^d$ 的非线性变换得到输出信号 $y(t) \in \mathbb{R}^m$, 其计算过程为

$$h'(t) = \mathbf{A}h(t) + \mathbf{B}x(t) \quad (2)$$

$$y(t) = \mathbf{C}h(t) \quad (3)$$

其中, $\mathbf{A} \in \mathbb{R}^{d \times d}$ 为状态转移矩阵, $\mathbf{B} \in \mathbb{R}^{d \times n}$ 为输入投影矩阵, $\mathbf{C} \in \mathbb{R}^{m \times d}$ 为输出投影矩阵, 三者都是可学习参数矩阵。为了满足离散时间序列建模要求, 可以通过零阶保持(ZOH, zero-order holder)离散化方法将连续系统转化为离散形式(适用于序列建模的递推形式)。

$$\bar{\mathbf{A}} = \exp(\Delta\mathbf{A}) \quad (4)$$

$$\bar{\mathbf{B}} = (\Delta\mathbf{A})^{-1}(\exp(\Delta\mathbf{A}) - \mathbf{I})\Delta\mathbf{B} \quad (5)$$

$$h_t' = \bar{\mathbf{A}}h_{t-1} + \bar{\mathbf{B}}x_t \quad (6)$$

$$y_t = \mathbf{C}h_t \quad (7)$$

其中, $\bar{\mathbf{A}}$ 和 $\bar{\mathbf{B}}$ 为离散化参数矩阵, 该结构使模型具有线性时间复杂度的序列处理能力。

3 基于图提示微调的WSN异常检测方法

本文设计的基于“预训练-图提示-微调”范

式的异常检测方法GPamba-AD(graph-prompted Mamba-based anomaly detection)包括数据预处理策略、特征提取网络以及基于图提示微调的模型训练策略3个方面, 本节对GPamba-AD的实现流程进行详细介绍。

3.1 数据预处理

无线传感器网络采集的数据通常记录为一个时间段 T 内 N 个传感器节点的观测结果, 每个节点可同时采集 M 个物理量, 如温度、湿度、光照等, 用于检测多种模态指标, 因此可以看作多节点多模态时序数据 $\mathbf{X} \in \mathbb{R}^{N \times M \times T}$ 。

由于连续的时序数据本质上是不定长的序列数据, 而多数深度学习模型的输入要求是定长序列样本, 为了充分利用历史数据并提升特征提取效果, 本文采用滑动时间窗口的方式将连续的时间序列切分成多个时间片段, 这样不仅能在训练阶段中构造更多样本, 还能保证同一窗口中的数据具有时间同步性。假设起始时间步为 t_0 , 设窗口长度为 w , 滑动步长为 s , 则起始窗口内的时序片段表示为 $[x_{t_0}, x_{t_0+1}, \dots, x_{t_0+w-1}] \in \mathbb{R}^{N \times M \times w}$, 下一个时序片段则表示为 $[x_{t_0+s}, x_{t_0+s+1}, \dots, x_{t_0+s+w-1}] \in \mathbb{R}^{N \times M \times w}$ 。

对于不同的物理量, 上下限的差异性可能会导致梯度爆炸或消失从而影响模型训练, 也可能使模型将特征差异误认为异常从而影响测试精度。为了消除不同传感器量纲和数值范围带来的影响, 本文使用Z-Score方法对每个节点的每个模态的时间序列单独做标准化。

该模块用于将无线传感器网络采集到的多节点多模态时序数据转换为适合模型训练与评估的输入格式, 确保模型在处理时序数据时具备稳定性与泛化能力。

3.2 时空相关性特征提取网络设计

无线传感器网络采集到的多节点多时序数据具有3个维度: 节点(Node)、模态(Modal, 每个节点采集到的物理量, 即时序数据的特征维度)和时间步(Time), 为了充分提取其特征信息, 本文设计了一种由时序提取模块和空间提取模块构成的时空特征提取网络, 前者用于提取每个节点的时序特征, 后者通过融合空间拓扑信息挖掘节点间的空间相关性特征。融合时空相关性特征的图神经网络异常检测主干网络架构如图1所示。其中, B 为批量大小, N 为WSN节点数, M 为WSN采集的模态

数, W 为滑动窗口大小。

3.2.1 时序信息提取模块

本模块旨在从 WSN 采集到的多节点多模态数据 $\mathbf{X} \in \mathbb{R}^{N \times W \times M}$ 中提取关键的时序特征信息, 包括时间特征 (不同模态之间的相关性特征) 和时序内特征 (单一模态随时间变化的动态表示), 可以采用并行结构的设计, 设计 2 个子模块分别用于提取不同时序模态间的特征和同一时序模态内时序特征。

为了深入提取单一时序模态在时间维度上的特征信息, 本文设计了一种基于 Mamba 层级结构的时序内特征提取子模块。每个 Mamba 层由多尺度膨胀卷积 (MSDCConv, multi-scale dilated convolution) 与 Mamba 模块相结合组成, 以便提升局部细粒度信息的特征提取能力和长时间依赖的特征提取能力。

时序数据通常包含短期周期性波动与长期变化趋势的混合特征, 传统时序卷积方法虽然可以捕捉局部性依赖特征, 但由于受限于感受野难以提取长距离依赖的时序特征。为此, 设计的模块采用多尺度膨胀卷积进行局部特征提取, 可以扩展感受野而

不损失分辨率。同时, 通过引入 Mamba 模块可以增强全局建模能力, 实现跨时间步的长依赖特征学习。具体细节如下: 对于单一模态的时序输入 $\mathbf{X}^{\text{single}} \in \mathbb{R}^{N \times W \times 1}$, 首先通过多个不同膨胀率的卷积核输入进行如式(8)和式(9)所示多尺度特征的提取。

$$\mathbf{Z}^i = \text{ReLU}(\mathbf{W}_{d_i} \mathbf{X}^{\text{single}} + \mathbf{b}_i), i = 1, 2, \dots, k \quad (8)$$

$$\mathbf{Z}^{\text{ms}} = \text{Concat}(\mathbf{Z}^1, \mathbf{Z}^2, \dots, \mathbf{Z}^k) \quad (9)$$

其中, \mathbf{W}_{d_i} 表示膨胀率为 d_i 的膨胀卷积的权重矩阵, \mathbf{b}_i 表示膨胀率为 d_i 的卷积的偏置向量, k 表示不同膨胀率的数量, $\text{Concat}(\cdot)$ 表示沿特征维度拼接, $\mathbf{Z}^i \in \mathbb{R}^{N \times W \times 1}$ 表示膨胀率为 d_i 的卷积操作的特征表示, $\mathbf{Z}^{\text{ms}} \in \mathbb{R}^{N \times W \times k}$ 表示多尺度特征表示。

再将多尺度特征表示 \mathbf{Z}^{ms} 输入 Mamba 模块进行全局建模, 在时间步 t 的特征为 $z_t \in \mathbb{R}^{N \times k}$ 时, 通过线性投影层动态生成。

$$\tilde{\mathbf{A}}_t, \tilde{\mathbf{B}}_t, \mathbf{A}_t = \text{Linear}_{\text{SSM}}(z_t) \quad (10)$$

其中, $\tilde{\mathbf{A}}_t \in \mathbb{R}^{N \times d}$ 为连续状态矩阵参数, d 为隐状态维度, $\tilde{\mathbf{B}}_t \in \mathbb{R}^{N \times d}$ 为连续输入投影参数, $\mathbf{A}_t \in \mathbb{R}^{N \times 1}$ 为时间步离散化参数, 用于控制状态更新频率。

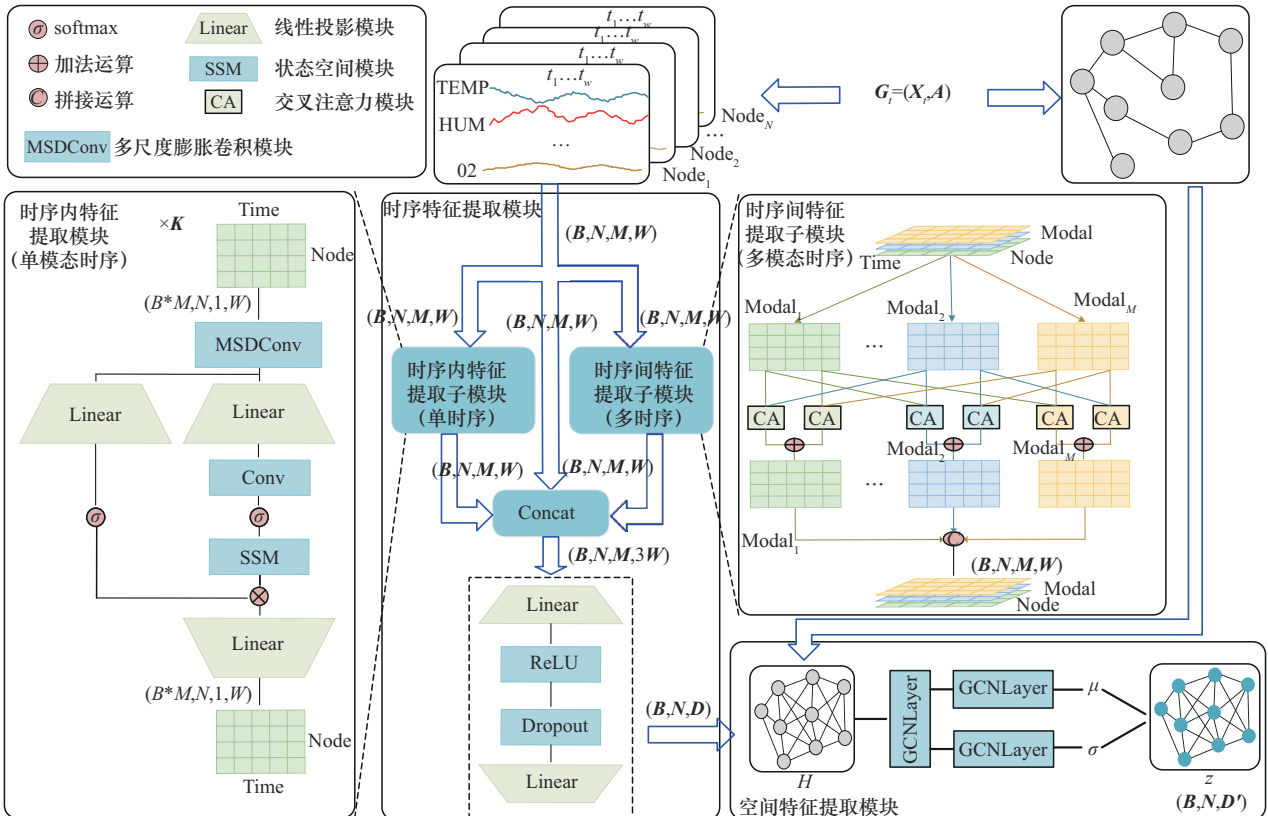


图1 融合时空相关性特征的图神经网络异常检测主干网络架构

为了将连续系统转化为离散时间系统以便时序采样, 本文对 $\tilde{\mathbf{A}}_t$ 和 $\tilde{\mathbf{B}}_t$ 进行ZOH, 具体方式如式(11)~式(14)所示。

$$\bar{\mathbf{A}}_t = \exp(\Delta_t \tilde{\mathbf{A}}_t) \quad (11)$$

$$\bar{\mathbf{B}}_t = \Delta_t \tilde{\mathbf{B}}_t \quad (12)$$

$$h_t = \bar{\mathbf{A}}_t \cdot h_{t-1} + \bar{\mathbf{B}}_t \cdot z_t \quad (13)$$

$$y_t = \mathbf{C}_t \cdot h_t \quad (14)$$

其中, $\bar{\mathbf{A}}_t$ 和 $\bar{\mathbf{B}}_t$ 分别表示连续参数 $\tilde{\mathbf{A}}_t$ 和 $\tilde{\mathbf{B}}_t$ 对应的离散参数, h_t 表示当前时间步的隐状态, h_{t-1} 表示前一时间步的隐状态, \mathbf{C}_t 表示状态输出投影矩阵, y_t 表示当前时间步的输出序列。

经过2层时序内提取层, 可以得到最终的输出序列 $\mathbf{Y} = \{y_1, y_2, \dots, y_W\} \in \mathbb{R}^{N \times W \times M}$ 。

为了捕捉不同时序模态之间的随机依赖关系, 本文通过交叉注意力机制设计了一种多模态融合的时序间特征提取子模块。对于模态 i 的数据 $\mathbf{X}_i \in \mathbb{R}^{N \times W}$ 和另一个不同模态 $j(j \neq i)$ 的数据 $\mathbf{X}_j \in \mathbb{R}^{N \times W}$, 通过交叉注意力机制计算它们之间的相关性并进行融合。

模态 i 序列映射成查询(Q, query)、另一个不同的模态 $j(j \neq i)$ 序列映射成键(K, key)和值(V, value), 计算模态间的注意力系数, 具体方式如式(15)~式(18)所示。

$$\mathbf{Q}_i = \mathbf{W}_Q \mathbf{X}_i \quad (15)$$

$$\mathbf{K}_j = \mathbf{W}_K \mathbf{X}_j \quad (16)$$

$$\mathbf{V}_j = \mathbf{W}_V \mathbf{X}_j \quad (17)$$

$$\alpha_{ij} = \text{softmax} \left(\frac{\mathbf{Q}_i \mathbf{K}_j^T}{\sqrt{d_k}} \right) \quad (18)$$

其中, d_k 表示注意力机制中键值维度, \mathbf{W}_Q 、 \mathbf{W}_K 和 \mathbf{W}_V 是可学习的权重参数, 通过矩阵乘法得到投影矩阵 $\mathbf{Q}_i \in \mathbb{R}^{N \times W \times d_k}$ 、 $\mathbf{K}_j \in \mathbb{R}^{N \times W \times d_k}$ 和 $\mathbf{V}_j \in \mathbb{R}^{N \times W \times d_k}$, $\alpha_{ij} \in \mathbb{R}^{N \times W \times W}$ 反映了在生成当前模态 i 的输出时, 模态 j 的重要性。

在得到注意力权重之后, 设计的不同时序模态信息的融合机制可以表示为

$$\mathbf{O}_i = \sum_{j=1}^M \alpha_{ij} \mathbf{V}_j \quad (19)$$

$$\mathbf{O} = \text{Concat}(\mathbf{O}_1, \mathbf{O}_2, \dots, \mathbf{O}_M) \quad (20)$$

其中, $\mathbf{O}_i \in \mathbb{R}^{N \times W}$ 表示模态 i 从其他模态中提取信

息的融合结果, $\mathbf{O} \in \mathbb{R}^{N \times W \times M}$ 表示多模态融合信息。

最后, 为了融合上述单一时序模态时序依赖特征与多时序模态之间的特性, 本文设计了时序内提取子模块和时序间提取子模块组成的并行结构, 将这2个模块的输出 \mathbf{Y} 和 \mathbf{O} 与输入数据 \mathbf{X} 进行拼接, 再通过多层感知机(MLP, multilayer perceptron)进行特征压缩与非线性映射, 具体方式如式(21)和式(22)所示。

$$\mathbf{F}_{\text{Concat}} = \text{Concat}(\mathbf{X}, \mathbf{Y}, \mathbf{O}) \in \mathbb{R}^{N \times W \times 3M} \quad (21)$$

$$\mathbf{F} = \text{MLP}(\mathbf{F}_{\text{Concat}}) \in \mathbb{R}^{N \times W \times M} \quad (22)$$

这样设计的时序特征提取模块不仅可以实现信息的有效融合与维度压缩, 还可以保留原始数据中的细节特征。该模块能够分别建模不同时序之间的长期依赖关系, 以及单一时序内部的局部动态变化与上下文特征, 从而生成更具判别性和鲁棒性的时序特征表示。

3.2.2 空间信息提取模块

无线传感器网络中的节点通常分布在空间上且具有非欧几里得结构, 传统的卷积操作难以捕捉其中的邻接关系。为了进一步建模传感器节点间的空间拓扑结构信息, 本文在时序特征提取模块之后引入空间特征提取模块, 设计变分图卷积网络(VGCN, variational graph convolutional network), 通过重参数化技巧对多节点时序数据的图结构进行建模, 提取潜在空间表示, 在保持时序特征的同时挖掘传感器节点间的空间依赖, 进而得到完整的时空特征表示。

VGCN能够显式地建模节点表示在潜在空间中的概率分布, 使模型不仅获得确定性的特征嵌入, 同时具备对节点不确定性的建模能力。这种分布式表示有助于提高模型对数据扰动、缺失或异常样本的鲁棒性, 特别适用于噪声较多的无线传感器网络场景。此外, VGCN通过将图数据映射到潜在空间, 在保留图结构信息的同时生成更紧凑且语义丰富的节点表示, 该过程主要利用图卷积网络(GCN, graph convolutional network), 对多节点时序特征 \mathbf{F} 和邻接矩阵 \mathbf{A} 进行一系列变换, 具体计算过程如式(23)~式(25)所示。

$$\mu = \text{GCN}_\mu(\mathbf{F}, \mathbf{A}) \quad (23)$$

$$\sigma = \text{GCN}_\sigma(\mathbf{F}, \mathbf{A}) \quad (24)$$

$$\mathbf{Z} = \mu + \sigma \odot \varepsilon \quad (25)$$

其中, $\text{GCN}_\mu(\cdot)$ 和 $\text{GCN}_\sigma(\cdot)$ 分别表示输出均值和方差的 GCN 层, $\varepsilon \sim N(0,1)$ 是从标准正态分布得出的噪声变量, 通过式(25)进行重参数化得到潜在嵌入表示 \mathbf{Z} 。

3.3 基于图提示微调训练策略设计

在完成 WSN 多时序数据的时空相关性特征提取网络模型设计之后, 为了提升 WSN 异常检测模型的性能, 还需解决实际应用场景中经常遇到的标签缺失和少量异常样本带来的样本分布不均衡问题。对此, 本节对前面提出的异常检测模型设计了基于“预训练-图提示-微调”的训练框架, 如图 2 所示, 包括图预训练模块、图提示微调模块和异常检测判别模块, 详细介绍如下。

3.3.1 图预训练模块设计

针对 WSN 中多节点多模态数据的特点, 本节基于前面设计主干网络中节点时空编码器设计, 结合自监督学习策略来更加有效地提取 WSN 数据中的时间与空间相关性特征。将 WSN 采集数据建模为随时间演化的动态图序列 $\mathbf{G}_t = (\mathbf{X}_t, \mathbf{A})$, 本文设计了如下 3 个子任务优化策略的多任务训练框架, 以

全面提升模型的特征提取能力。

子任务 1。基于 BYOL^[44] 的非对称性无负例图对比学习子任务。常见的无负例对比学习大多是对称结构, 通常通过 2 个编码分支分别处理 2 个不同的增强视图, 并在同一训练过程中对齐嵌入表示, 从而有效提升模型在无监督场景下的判别能力。然而, 对称结构的方法存在一些局限性: 首先, 2 个编码器共享梯度传播路径, 有可能在训练早期陷入局部最优, 导致模型学习目标不稳定; 其次, 在节点数量有限或数据增强噪声较大的情况下, 可能引发节点数据特征分布偏移或对齐困难问题。

为缓解上述问题, 本文使用基于 BYOL 的非对称性无负例图对比学习策略, 通过设计参数独立更新的编码路径, 采用动量编码器提供稳定目标, 结合预测器实现了非对称对齐的学习策略, 这样可以在不引入负例样本的前提下, 有效提升模型在图结构扰动与多视图表达下的鲁棒性和稳定性。该方法特别适用于节点规模有限、结构局部性强和数据增强变异大的无线传感器网络场景, 能够为 WSN 图结构数据提供更加稳定的时空特征表示。

本文通过设计具体的在线网络和目标网络 2 个

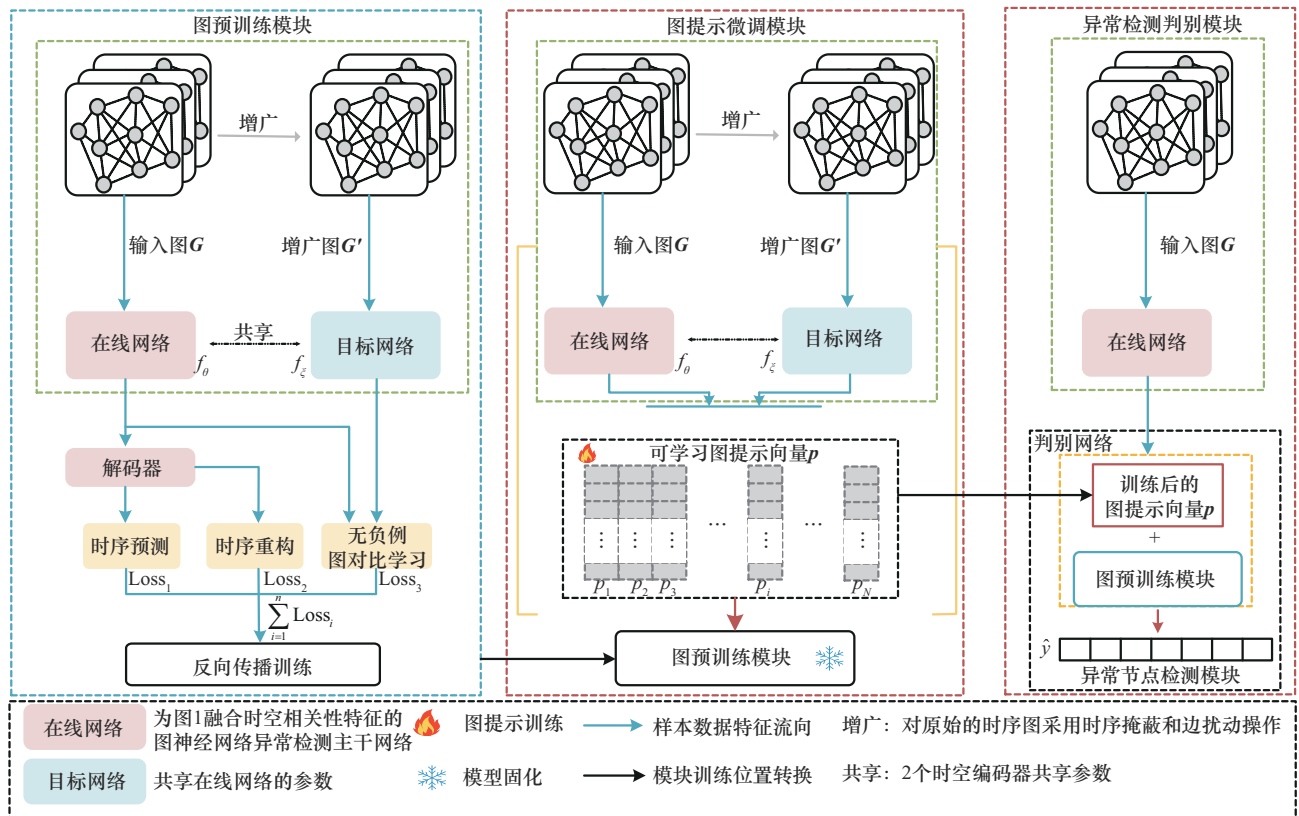


图 2 基于“预训练-图提示-微调”的训练框架

神经网络完成子任务1的学习。

在线网络包括投影头 f_θ 和预测头 q_ϕ , 参数为 θ 和 ϕ ; 输入原始图 \mathbf{G}_t , 输出其时空特征表示为

$$\mathbf{H} = f_\theta(\mathbf{G}_t) \quad (26)$$

$$\mathbf{q} = q_\phi(\mathbf{H}) \quad (27)$$

其中, \mathbf{q} 为在线网络的输出特征, \mathbf{H} 为原始图数据的时空特征表示。

目标网络仅包含投影头 f_ζ , 参数 ζ 通过指数平均移动(EMA, exponential moving average)进行动量更新从在线网络复制, 过程表示为

$$\zeta = m \cdot \zeta + (1 - m) \cdot \theta, m \in [0, 1] \quad (28)$$

将WSN动态图序列 $\mathbf{G}_t = (\mathbf{X}_t, \mathbf{A})$ 分别从时间维度与图结构维度进行时序掩蔽^[45]和边扰动^[46]方式的处理得到 $\mathbf{G}'_t = (\mathbf{X}'_t, \mathbf{A}')$ 。在目标网络中输入增广图 \mathbf{G}'_t , 输出其特征表示为

$$\mathbf{z}' = f_\zeta(\mathbf{G}'_t) \quad (29)$$

损失函数通过最大化正样本对的余弦相似度确保网络学习稳定一致性的表示, 采用计算式为

$$L_{\text{cont}} = 2 - 2 \cdot \frac{\langle \mathbf{q}, \mathbf{z}' \rangle}{\|\mathbf{q}\| \cdot \|\mathbf{z}'\|} \quad (30)$$

子任务2. 多元时序预测子任务。该子任务利用历史时空信息预测未来的节点状态信息, 使编码器能有效捕捉到具有预测能力的时序演化规律和空间结构关系。本文将子任务1中在线网络得到的编码特征 $\mathbf{H} = f_\theta(\mathbf{G}_t)$ 通过一个多层感知机进行传递, 预测下一个时间步的WSN数据 $\hat{\mathbf{Y}}_{t+1} = \text{MLP}(\mathbf{H})$ 。采用预测模型中常用均方误差(MSE, mean square error)作为设计的损失函数, 如式(31)所示计算预测值与真实值之间的平方差。

$$L_{\text{pred}} = \sum_{i=1}^N \sum_{j=1}^M [\hat{\mathbf{Y}}_{t+1}(ij) - \mathbf{Y}_{t+1}(ij)]^2 \quad (31)$$

其中, i 是节点索引, j 是模态索引。

子任务3. 多节点时序数据重构。将子任务1中在线网络得到的编码特征 $\mathbf{H} = f_\theta(\mathbf{G}_t)$ 通过一个多层感知机重构原来的数据结构 $\hat{\mathbf{X}}_{1:T} = \text{MLP}(\mathbf{H})$ 。重构模型中采用常用MSE作为设计的损失函数, 如式(32)所示计算重构值与真实值之间的平方差。

$$L_{\text{recon}} = \sum_{i=1}^N \sum_{j=1}^M \sum_{t=1}^W [\hat{\mathbf{X}}_t(ij) - \mathbf{X}_t(ij)]^2 \quad (32)$$

其中, i 是节点索引, j 是模态索引, t 是时间步

索引。

综合上述3个图对比、时序预测与时序重构自监督子任务模型的设计和协同优化, 本文构建了一个统一的多任务训练框架, 可以同时捕捉WSN数据结构感知信息、动态演化模式与特征保持能力, 充分提取WSN数据中时空关联的相关性特征。

最后, 将式(30)~式(32)的3个损失函数进行联合训练, 构成新的损失函数为

$$L = L_{\text{cont}} + L_{\text{pred}} + L_{\text{recon}} \quad (33)$$

根据上述模型设计, 再通过反向传播算法对本文所提出的时空编码器进行预训练, 对其中的时空编码器的参数 Φ 进行学习优化, 学习得到无线传感器网络数据中每个节点表示 h_1, h_2, \dots, h_N , 再将这些在预训练阶段获得的特征表示和参数在随后的图提示微调训练阶段保持固定。

3.3.2 图提示微调模块设计

通过图预训练模块训练得到固化模型后, 本文采用嵌入图提示向量的方式来提升预训练的固化模型和下游任务的适应性。在此阶段固定3.3.1节预训练模型中得到的参数 Φ , 将WSN数据输入其编码器中得到节点嵌入向量 $\mathbf{H} = f_{\text{enc}}(\mathbf{X}, \mathbf{A}) \in \mathbb{R}^{N \times d}$, 由此可定义一个可学习图提示向量 $\mathbf{P} \in \mathbb{R}^{N \times d}$, 初始值采用服从均匀分布的随机向量, 在微调阶段通过梯度下降进行更新。在本文中, 对于每个节点 i , 将可学习的提示向量 $p_i \in \mathbb{R}^d$ 与其对应嵌入向量 $h_i \in \mathbb{R}^d$ 采用逐元素相加的方式进行融合, 得到生成向量 h_i 的提示特征向量 h_i^* , 如式(34)所示。选择逐元素相加的方式可以在保持原始嵌入语义的同时, 为每个维度均匀注入提示信息, 从而避免拼接或MLP融合可能带来的过拟合风险, 并保证训练的稳定性。

$$h_i^* = h_i + p_i \quad (34)$$

在微调阶段, 预训练得到的主干模型参数保持冻结, 仅更新提示向量参数 $\{p_1, p_2, \dots, p_N\}$, 从而使模型能够通过极少量参数学习实现下游异常检测任务自适应。提示向量在训练过程中逐步收敛, 显式捕获与异常相关的关键特征模式, 包括节点层面的突变趋势和跨节点相关性的偏移。通过与节点嵌入在高维表示空间的融合, 提示向量增强了模型对潜在异常模式的敏感程度, 使其能够更加关注关键特征, 进而提升异常检测性能。最终, 在保持预训练模型参数不变的前提下, 仅对提示向量进行学习与

更新,从而得到与下游异常检测任务高度匹配的提示特征表示。

3.3.3 异常检测判别模块设计

本文设计的基于多任务学习异常检测方法中的预测任务最能反映节点时序动态变化,因此可以仅采用未来预测任务作为判别异常节点的依据。在获取固定预训练模型参数 Φ 和训练得到的提示向量参数 $\{p_1, p_2, \dots, p_N\}$ 后,预测出无线传感器网络下一个时间步各个节点的时序数据 $\hat{Y}_{t+1} \in \mathbb{R}^{N \times M}$,可以通过式(35)计算每个传感器节点的预测误差作为异常得分。

$$\text{score} = \sum_{i=1}^N \sum_{j=1}^M [\hat{Y}_{t+1}(ij) - Y_{t+1}(ij)]^2 \quad (35)$$

将异常得分 score 与阈值 τ 进行比较,若大于阈值则默认为异常,标签置为1,否则为0。

$$\text{label}_{\text{pred}}(ij) = \begin{cases} 1, & \text{score}(ij) > \tau \\ 0, & \text{score}(ij) < \tau \end{cases} \quad (36)$$

其中, $\text{label}_{\text{pred}}(ij)$ 表示在传感器节点 i 模态 j 的预测标签, $\text{score}(ij)$ 表示在传感器节点 i 模态 j 的异常得分。本文考虑设计采用验证集调优的方式确定阈值 τ ,即在验证集上选择使检测性能(F1-score)最优的阈值作为最终设定,这样可以避免人为选择阈值带来的偏差,在后续实验中也表现出了良好的稳定性。

4 实验分析

为了验证本文所设计的基于图提示微调WSN异常检测方法性能,本文分别在公开数据集和实际采集数据集上进行了尽可能全面的测试,本节先介绍使用的实验数据集及环境配置;接着介绍选择的评价指标;然后通过消融实验分析设计的异常检测方法中各模块对检测整体性能贡献的影响;再通过与现有主流方法进行对比进一步验证本文方法的有效性;最后,结合可视化分析对模型检测结果进行了直观展示。

4.1 实验数据集及环境配置

本文使用的公开数据集为英特尔伯克利实验室IBRL(Intel Berkeley research lab)^[47]实地部署的无线传感器网络数据集,该数据集在很多文献^[48]中得到了使用,便于进行基准性能的对比。该无线传感器网络是由54个传感器节点组成,该实验室通过采集室内环境一个多月时间里的温度、湿度、光照强度和节点电压4种时序的多模态信息,采样时间间隔为31 s,传感器节点空间位置分布如图3所示,该公开数据集部署在室内场景。本文还通过基于LoRa(long range radio)^[49]通信协议设计了一个针对室外场景的WSN用于采集室外环境数据,包括14个采集数据的传感器节点以及一个汇聚传输节点,传感器节点相对分布位置和实物图如图4所

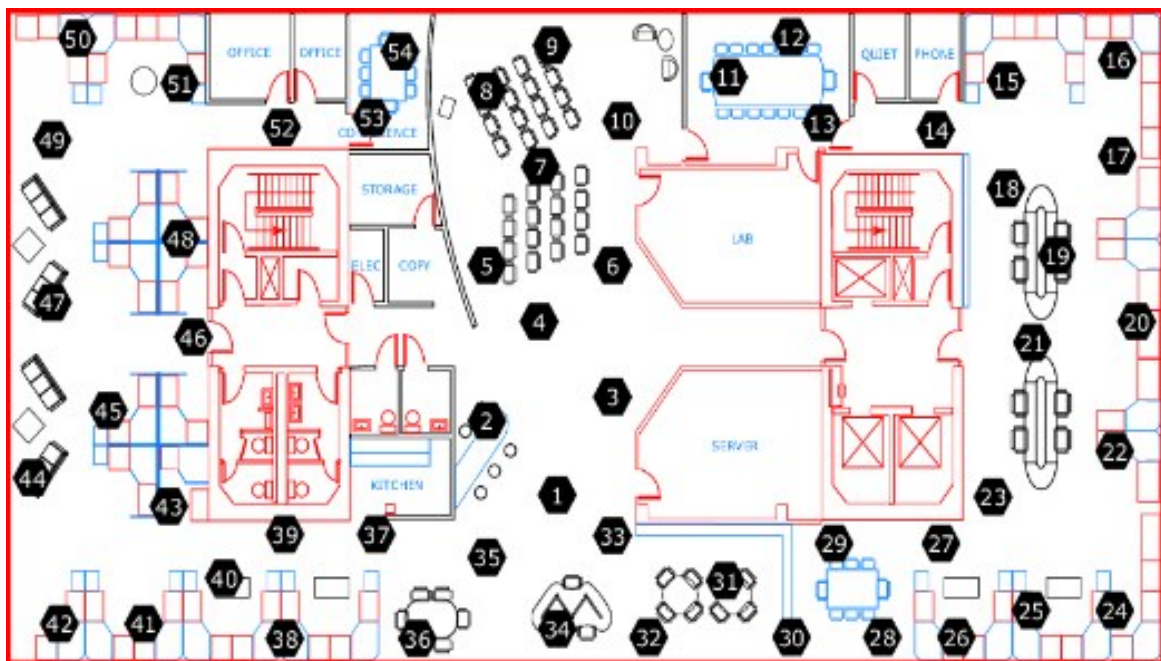



图3 IBRL数据集传感器空间位置分布



(a) 节点分布

(b) 传感器节点实物

图4 WSN异常节点检测系统传感器节点部署

示, 采取和 IBRL 数据集类似的处理方式, 对各个传感器节点每 30 s 采集一次包括温度、湿度、光照强度和节点电压信息数据。

进行性能测试实验机器的具体硬件配置为: Intel(R) Xeon(R) Gold 5218 CPU @ 2.30GHz、NVIDIA GeForce RTX 3090GPU(24G), 软件环境为: Ubuntu 18.04.2 LTS、Python 3.10、PyTorch2.1.1、CUDA Version: 11.8, 通过在 Pycharm2022 中远程连接服务器进行源码编写。设计模型涉及超参数设置的具体过程如下。在批量大小的选择方面, 本文分别尝试了 8、16 和 32, 在学习率方面, 本文尝试了 0.001、0.003、0.005、0.01、0.02 等不同设置, 经过多次调试, 最后发现当批量大小设置为 16, 学习率为 0.005 时效果最好, 因此以下实验结果均基于上述超参数配置进行。此外, 滑动窗口大小为 300, 网络模型使用 Adam 优化器优化。以上超参数的设置是通过多轮实验调试上完成确定的。

和其他研究方法一样, 本文选择精确率 (Pre)、召回率 (Rec) 和 F1 分数 (F1) 作为衡量本文方法性能的评价指标。

4.2 消融实验

为了验证本文所设计的模型中各个组成模块的性能和效果, 以及设计的基于自监督预训练策略对于模型整体性能的影响, 本文设计了如下系列消融实验, 通过移除或修改模型中的各个模块, 能够全面评估设计的各个模块对模型整体性能的贡献, 具体设计的消融实验方案如下。

方案 1。使用原始的 Mamba, 不进行细粒度时序特征信息提取和模态间相干性特征时序融合。

方案 2。使用 Mamba 和 MSDConv 模块, 不进

行时序间的多模态相关性特征信息提取。

方案 3。移除 VGCN 模块, 不进行节点间空间相关性特征信息提取。

方案 4。移除 VGCN 和 CA 交叉注意力 (CA, cross-attention) 模块, 不进行任何相关性特征信息提取。

方案 5。取消基于自监督学习的预训练过程, 直接进行下游任务的训练。

方案 6。保留预训练, 在下游任务训练时不使用提示向量, 直接通过冻结预训练模型参数进行异常检测任务的训练。

本文方法与其他 4 种方法的消融实验结果如表 1 所示, 其中, Pre 表示精确率, Rec 表示召回率, F1 表示 F1 分数, $\sqrt{\quad}$ 表示保留相关模块, \times 表示移除相关模块。方案 1 和方案 2 旨在探究时序提取模块中不同子模块的作用。方案 2 禁用 CA 模块, 其召回率和 F1 分数较基线分别降低了 6.38% 和 5.59%, 表明模型在处理多模态时序数据时, 对模态间相关性异常的检测能力显著下降。方案 1 不仅禁用了 CA 模块还禁用了 MSDConv 模块, 召回率较基线降低了 19.49%, 这表明模型没有充分提取到时序数据的局部细节信息, 严重影响了检测性能。

方案 2、方案 3 和方案 4 则聚焦于相关性提取模块的作用。方案 3 禁用了 VGCN 模块, F1 分数较基线降低了 9.19%, 其原因主要是模型对节点间相关性异常的漏检, 导致模型整体检测效果受损。方案 4 将 2 个相关性提取模块全部禁用, 性能进一步下降。这表明在当前数据集下, 相较于点异常、集体异常与上下文异常, 相关性异常的检

表1 消融实验方案及实验结果

方法	MSDCov	CA	VGCN	预训练	GPL	Pre	Rec	F1
方案1	×	×	√	√	√	89.30%	69.87%	78.40%
方案2	√	×	√	√	√	88.64%	82.98%	85.71%
方案3	√	√	×	√	√	81.25%	82.98%	82.11%
方案4	√	×	×	√	√	91.41%	66.20%	76.79%
方案5	√	√	√	×	×	89.69%	88.83%	89.26%
方案6	√	√	√	√	×	93.18%	87.23%	90.11%
本文方法	√	√	√	√	√	93.33%	89.36%	91.30%

测难度更高，基准模型对此类异常的识别效果相对较弱。

方案5和方案6是对模型训练框架的影响进行分析。方案5取消了基于自监督的预训练过程，直接进行异常检测任务，精确率较基线降低3.64%；方案6在保留预训练的情况下取消提示向量，但由于预训练阶段从WSN数据中获得了具有良好泛化性的通用特征表示，其精确率相较方案5提升了3.49%。最终，本文方法在保留预训练并引入提示向量的前提下，各项指标均达到最优，模型性能实现了进一步提升。

为了验证模型在不同预训练深度以及异常样本占比下的鲁棒性，本文设计了2组互补实验，具体实验方案如下。

实验1。固定异常样本比例为1%，逐步增加预训练轮次（50、100、150、200 epoch），从而验证预训练轮次对模型性能的影响。

实验2。固定最优预训练轮次（100 epoch），将异常样本比例进一步稀释至0.9%、0.7%与0.5%，模拟数据不平衡场景。

从表2可以看出，随着预训练轮次的增加，模型在Rec和F1上呈现出先上升后趋于稳定的趋势。当预训练轮次为100时，模型的Pre、Rec和F1分别达到93.33%、89.36%和91.30%，取得最优表现。这说明适度的预训练能够有效提升模型在异常模式识别上的判别能力，但过多的训练轮次可能导致模型在特征空间中过拟合，从而使精确率和召回率的平衡下降。因此，本文在后续实验中将预训练轮次设置为100，以在检测性能与训练开销之间取得较优的平衡。

表2 预训练轮次对模型性能的影响

预训练轮次	Pre	Rec	F1
200	90.58%	86.99%	88.75%
150	91.11%	87.23%	89.13%
100	93.33%	89.36%	91.30%
50	93.02%	85.11%	88.89%

如表3所示，当异常样本比例为1.0%时，模型取得最优性能，Pre、Rec和F1分别为93.33%、89.36%和91.30%。随着异常样本比例下降，模型性能呈下降趋势，其中在0.5%异常样本比例下，F1下降至78.32%，主要由于测试中异常样本过少，使异常模式在评估过程中表现不充分。总体来看，即便在异常样本比例极低的情况下，模型仍保持一定的检测能力，表明所设计的图提示微调策略在小样本异常检测任务中具有良好的泛化能力。

表3 异常样本比例对模型性能的影响

异常样本比例	Pre	Rec	F1
1.0%	93.33%	89.36%	91.30%
0.9%	89.13%	87.23%	88.17%
0.7%	86.67%	83.98%	84.78%
0.5%	88.30%	70.34%	78.32%

4.3 对比实验

本节将本文方法与CNN-LSTM^[50]、MTAD-GAT^[51]、GAT-GRU^[52]和GLSL^[52]进行比较，并完成以下对比实验。

CNN-LSTM利用卷积模块、长短期记忆网络模块以及全连接层搭建深度学习网络。MTAD-

GAT是一种将预测模型与重构模型优势相结合的异常检测方法。该方法通过预测模块建模数据的时间依赖性,能够敏锐地捕捉时间序列中微小的异常变化,从而为后续的重构提供更准确的参考。GAT-GRU是一类面向多节点多模态时序数据的神经网络结构,模型整体采用重构方式进行异常检测,即将数据映射至低维空间后,再通过对称结构将其还原为高维特征,最终使用重构误差作为异常判别指标。GLSL是对GAT-GRU的改进,为不同模态分别创建特征提取分支,并通过调整2个GAT模块的计算顺序,避免因节点或模态数量增加而导致模型结构冗余。

表4给出了不同方法在检测精确率(Pre)、召回率(Rec)、F1分数(F1)以及模型复杂度(参数量(Par)与FLOPS)上的对比结果。可以看出,传统的CNN-LSTM在F1分数上仅为74.5%,明显低于图结构相关方法,说明仅利用时序建模难以充分捕获节点间的空间依赖。MTAD-GAT在召回率上表现较好(87.0%),但其精确率较低,导致整体F1分数为82.0%,性能仍有不足。GAT-GRU和GLSL通过结合图结构信息提升了检测效果,其中GLSL的F1分数达到90.6%,体现了较强的异常检测能力,但其FLOPS较高($3\ 075.1 \times 10^6$),在计算开销方面存在劣势。

表4 各方法对比实验结果

方法	Pre	Rec	F1	Par/M	FLOPS/M
CNN-LSTM	79.5%	70.0%	74.5%	27.9	14 699.7
MTAD-GAT	77.5%	87.0%	82.0%	1.1	749.2
GAT-GRU	93.3%	87.5%	90.3%	36.5	14 445.6
GLSL	94.5%	87.0%	90.6%	0.6	3 075.1
本文方法	93.3%	89.4%	91.3%	0.4	395.1

相比之下,本文方法在Pre与Rec之间取得了更优的平衡,最终F1分数达到91.3%,在所有方法中表现最佳。同时,本文方法在复杂度方面显著优于对比模型,仅需 0.4×10^6 参数量与 395.1×10^6 的FLOPS,即在保证最优性能的同时,大幅降低了计算与存储开销,展现了良好的高效性与实用性。这一结果表明,引入图提示机制与多任务优化策略能够有效增强模型对时序模式与空间结构依赖的综合建模能力,从而在异常节点检测任务中展现出更优

的性能水平。

为了验证本文所设计模型的泛化能力和稳定性,相对在室内场景采集数据的IBRL公开数据集,本文还在室外场景下基于LoRa通信方式采集了实际数据集并对此进行了验证,实验结果如表5所示,在室内场景中,本文设计的异常检测方法取得了93.33%精确率、89.36%召回率以及91.30% F1分数,整体表现良好,说明模型能够较为准确地识别异常。在基于LoRa通信方式的室外场景真实数据集中,设计方法性能进一步提升,精确率达到93.82%,召回率为90.85%,F1分数为92.31%。对2组室内和室外场景下数据集的实验结果共同验证了本文方法在多种环境条件下均表现出更好的异常检测性能,充分体现了其良好的泛化能力与稳定性。

表5 不同场景下的对比实验结果

数据集	Pre	Rec	F1
室内场景公开数据集	93.33%	89.36%	91.30%
室外场景真实数据集	93.82%	90.85%	92.31%

4.4 可视化分析

本节通过部分测试数据对模型检测效果进行案例分析。图5表示28号节点采集的一段含有4 900个时刻并添加过相关性异常的温度和湿度数据,实线表示原始标签,虚线表示预测标签,点线表示误差标签,误判主要发生在时间相关性消失导致异常的起始和结束时刻,产生该现象的主要原因在于模型基于时空依赖的异常响应略有延迟或提前,从而出现局部误判。这也说明了相关性异常检测模块在捕获时序依赖特征上的局限性。图6展示了IBRL数据集中27号节点采集的一段含有2 280个时刻的温度数据,其中,实线为原始的正常数据,点线标记为注入的点异常数据,虚线标记为注入的上下文异常数据,点划线标记为注入的集体异常数据。使用窗口大小为300的滑动窗口构造测试样本,根据预测的结果进行异常检测,图7为不同异常分别对应的样本标签,图8为不同异常对应的异常检测结果的标签。从图7和图8可以看出,两者基本一致,模型误判主要发生在滑动窗口两端刚包含异常数据时,以及原始正常数据波动较大的情况。这一现象的产生主要是因为滑动窗口内时序信息不完整以及异常幅度与正常波动接近,使模型难以立即判定异常,从而导致边缘误判。图9展示了3个邻接节点11、12和13

的温度数据，并在 11 号节点上添加了点异常数据。图 10 展示了图 9 中 3 个节点的异常检测结果。从图 10 可以看出，节点 11 的点异常均被正确识别，表明模型在时间局部扰动下具有良好的检测性能。节点 12 和 13 并未出现误报，这表明在显式建模图结构依赖关系的条件下，模型能够有效约束异常响应的作用范围，使其主要集中于受扰节点，从而避免空间关联信息传播而导致的误检泛化现象。




图 5 WSN 数据相关性异常检测




图 6 测试样本数据

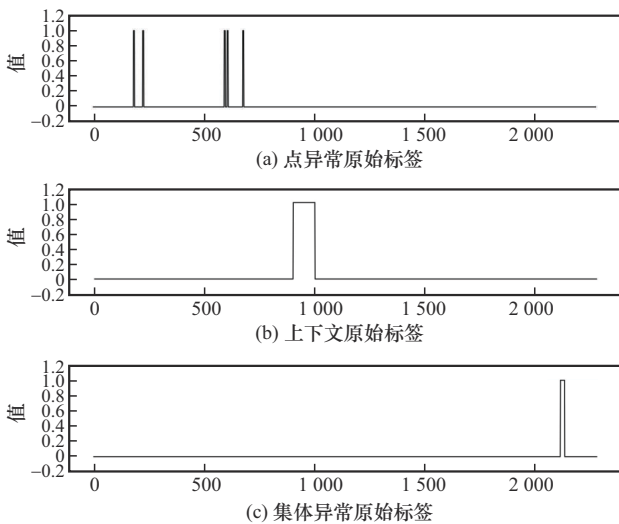


图 7 测试样本数据标签




图 8 测试样本数据异常检测结果




图 9 WSN 空间相关性样本数据




图 10 WSN 空间相关性数据异常检测结果

5 结束语

本文提出了一种基于预训练与提示微调的多节点多时序异常检测框架,系统地整合时序建模、图结构建模与多任务策略。针对长距离依赖性不足和时空相关性问题,本文引入多尺度膨胀卷积与Mamba模块结合的架构来增强节点内部多粒度时序模式的建模能力,并通过交叉注意力机制捕捉不同时序间的相关性,还借助VGCN获取多节点的结构信息,从而充分提取高质量的时空相关性特征。针对样本标注困难和异常样本数量少的问题,本文设计了基于图提示微调的训练策略,在预训练阶段,模型同时进行无负例对比学习、时序重构与时序预测任务,从而促使模型学习具有判别性与泛化能力的潜在表示。在下游异常检测任务中,引入少量可学习的图提示向量,通过冻结预训练模型并在预测任务上微调,使模型具备少量参数调整即可适应具体场景的能力。实验结果表明,在WSN异常检测任务上,本文方法优于现有主流方法。然而,当节点数据存在大量缺失或在超大规模网络下时,模型性能和计算效率可能受限。在下一阶段的研究中,可以考虑缺失数据补全、图采样或分层提示机制,并结合更丰富的时序与图特征提取方法,以进一步提升异常检测效果。

参考文献:

- [1] ZHU R X, BOUKERCHE A, LONG L B, et al. Design guidelines on trust management for underwater wireless sensor networks[J]. *IEEE Communications Surveys & Tutorials*, 2024, 26(4): 2547-2576.
- [2] GUPTA D, RAMESH J V N, KUMAR M K, et al. Optimizing cluster head selection for E-commerce-enabled wireless sensor networks[J]. *IEEE Transactions on Consumer Electronics*, 2024, 70(1): 1640-1647.
- [3] 王泽南, 王意洁, 周小晖, 等. 基于多窗口划分集成学习的多维时间序列异常检测[J]. *计算机研究与发展*, 2025: 1-13.
WANG Z N, WANG Y J, ZHOU X H, et al. Anomaly detection for multivariate time series based on multi-window segmentation ensemble learning[J]. *Journal of Computer Research and Development*, 2025: 1-13.
- [4] HUANG X H, ZHANG F B, FAN H Y, et al. Multimodal adversarial learning based unsupervised time series anomaly detection[J]. *Computer Research and Development*, 2021, 58(8).
- [5] MIAO J W, TAO H C, XIE H R, et al. Reconstruction-based anomaly detection for multivariate time series using contrastive generative adversarial networks[J]. *Information Processing & Management*, 2024, 61(1): 103569.
- [6] LIU S H, ZHOU B, DING Q, et al. Time series anomaly detection with adversarial reconstruction networks[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(4): 4293-4306.
- [7] ZHANG X X, SHI S, SUN H C, et al. ACVAE: a novel self-adversarial variational auto-encoder combined with contrast learning for time series anomaly detection[J]. *Neural Networks*, 2024, 171: 383-395.
- [8] LI Y F, PENG X Y, ZHANG J, et al. DCT-GAN: dilated convolutional transformer-based GAN for time series anomaly detection[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(4): 3632-3644.
- [9] YU X Y, ZENG B B, WANG L D. Anomaly detection for industrial time series data based on correlation analysis and CNN-BiLSTM with self-attention[J]. *Asian Journal of Mathematics and Computer Research*, 2024, 31(2): 96-108.
- [10] LI G, JUNG J J. Deep learning for anomaly detection in multivariate time series: approaches, applications, and challenges[J]. *Information Fusion*, 2023, 91: 93-102.
- [11] LIU L Y, LIU S Q, HE S, et al. Anomaly detection in nuclear power production based on neural normal stochastic process[J]. *Sensors*, 2025, 25(14): 4358.
- [12] GU Y Y, JAZIZADEH F. Time series anomaly detection using generative adversarial network discriminators and density estimation for infrastructure systems[J]. *Automation in Construction*, 2024, 165: 105500.
- [13] LIANG A S, HU Y P, LI G N. The impact of improved PCA method based on anomaly detection on chiller sensor fault detection[J]. *International Journal of Refrigeration*, 2023, 155: 184-194.
- [14] GUO Y C, FENG F, DI A, et al. MLAnalysis: an open-source program for high energy physics analyses[J]. *Computer Physics Communications*, 2024, 294: 108957.
- [15] ZHANG H, KUMAR N, WU S, et al. Anomaly detection with memory-augmented adversarial autoencoder networks for industry 5.0[J]. *IEEE Transactions on Consumer Electronics*, 2024, 70(1): 1952-1962.
- [16] TOOR A A, LIN J C, GRAN E G. UoCAD2: an unsupervised online contextual anomaly detection approach using optimized hyperparameters of RNNs for multivariate time series[J]. *Internet of Things*, 2025, 33: 101664.
- [17] 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.
- [18] XU H Z, WANG Y J, JIAN S L, et al. Calibrated one-class classification for unsupervised time series anomaly detection[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(11): 5723-5736.
- [19] XU J H, WU H X, WANG J M, et al. Anomaly transformer: time series anomaly detection with association discrepancy[J]. *arXiv Preprint*, arXiv: 2110.02642, 2021.
- [20] GU A, DAO T. Mamba: linear-time sequence modeling with selective state spaces[J]. *arXiv Preprint*, arXiv: 2312.00752, 2023.
- [21] HO T K K, KARAMI A, ARMANFARD N. Graph anomaly detection in time series: a survey[J]. *arXiv Preprint*, arXiv: 2302.00058, 2023.
- [22] CHEN X H, DENG L W, HUANG F T, et al. DAEMON: unsupervised

- anomaly detection and interpretation for multivariate time series[C]//Proceedings of the 2021 IEEE 37th International Conference on Data Engineering (ICDE). Piscataway: IEEE Press, 2021: 2225-2230.
- [23] ZHANG W Q, ZHANG C, TSUNG F. GRELEN: multivariate time series anomaly detection from the perspective of graph relational learning[C]//IJCAI. 2022: 2390-2397.
- [24] CHEN W, TIAN L, CHEN B, et al. Deep variational graph convolutional recurrent network for multivariate time series anomaly detection[C]//International Conference on Machine Learning. PMLR, 2022: 3621-3633.
- [25] CUI Z, ZANG D, ZHANG J Q, et al. MGCL: multiorder graph neural network with cross-learning for multivariate time-series anomaly detection[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 2535014.
- [26] GUAN S W, ZHAO B J, DONG Z K, et al. GTAD: graph and temporal neural network for multivariate time series anomaly detection[J]. Entropy, 2022, 24(6): 759.
- [27] LIU Z, HUANG X, ZHANG J Y, et al. Multivariate time-series anomaly detection based on enhancing graph attention networks with topological analysis[C]//Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2024: 1555-1564.
- [28] NIE Y Q, NGUYEN N H, SINTHONG P, et al. A time series is worth 64 words: long-term forecasting with transformers[J]. arXiv Preprint, arXiv: 2211.14730, 2022.
- [29] ZHANG Z, WANG X, GU Y S. Series-aware graph-enhanced transformers for multivariate time series forecasting[J]. arXiv Preprint, arXiv: 2307.01616, 2023.
- [30] TULI S, CASALE G, JENNINGS N R. TranAD: deep transformer networks for anomaly detection in multivariate time series data[J]. arXiv Preprint, arXiv: 2201.07284, 2022.
- [31] WU X J, QIU X F, LI Z Y, et al. CATCH: channel-aware multivariate time series anomaly detection via frequency patching[J]. arXiv Preprint, arXiv: 2410.12261, 2024.
- [32] GAO Y, QI J, YE H J, et al. Variational graph attention networks with self-supervised learning for multivariate time series anomaly detection[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 74: 3503113.
- [33] JIAO Y, YANG K, SONG D J, et al. TimeAutoAD: autonomous anomaly detection with self-supervised contrastive loss for multivariate time series[J]. IEEE Transactions on Network Science and Engineering, 2022, 9(3): 1604-1619.
- [34] BROWN T B, MANN B, RYDER N, et al. Language models are few-shot learners[J]. Advances in Neural Information Processing Systems, 2020, 33: 1877-1901.
- [35] SUN X G, ZHANG J W, WU X X, et al. Graph prompt learning: a comprehensive survey and beyond[J]. arXiv Preprint, arXiv: 2311.16534, 2023.
- [36] LIU Z M, YU X T, FANG Y, et al. GraphPrompt: unifying pre-training and downstream tasks for graph neural networks[C]//Proceedings of the ACM Web Conference 2023. New York: ACM Press, 2023: 417-428.
- [37] SUN M C, ZHOU K X, HE X, et al. GPPT: graph pre-training and prompt tuning to generalize graph neural networks[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2022: 1717-1727.
- [38] FANG T R, ZHANG Y C, YANG Y, et al. Universal prompt tuning for graph neural networks[J]. Advances in Neural Information Processing Systems, 2023, 36: 52464-52489.
- [39] CHEN Z H, WANG Y, MA F Y, et al. GPL-GNN: graph prompt learning for graph neural network[J]. Knowledge-Based Systems, 2024, 286: 111391.
- [40] GU A, JOHNSON I, GOEL K, et al. Combining recurrent, convolutional, and continuous-time models with linear state space layers[J]. Advances in Neural Information Processing Systems, 2021, 34: 572-585.
- [41] GU A, GOEL K, RÉ C. Efficiently modeling long sequences with structured state spaces[J]. arXiv Preprint, arXiv: 2111.00396, 2021.
- [42] DAO T, GU A. Transformers are SSMs: generalized models and efficient algorithms through structured state space duality[J]. arXiv Preprint, arXiv: 2405.21060, 2024.
- [43] LIANG A B, JIANG X G, SUN Y, et al. Bi-mamba+: bidirectional mamba for time series forecasting[J]. arXiv Preprint, arXiv: 2404.15772, 2024.
- [44] GRILL J B, STRUB F, ALTCHÉ F, et al. Bootstrap your own latent-a new approach to self-supervised learning[J]. Advances in Neural Information Processing Systems, 2020, 33: 21271-21284.
- [45] LUO D S, CHENG W, WANG Y H, et al. Time series contrastive learning with information-aware augmentations[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(4): 4534-4542.
- [46] YOU Y N, CHEN T L, SUI Y D, et al. Graph contrastive learning with augmentations[J]. Advances in Neural Information Processing Systems, 2020, 33: 5812-5823.
- [47] Intel Berkeley research lab. IBRL dataset[J]. 2025.
- [48] AKRAM J, ANAISSI A, AKRAM A, et al. Adversarial label-flipping attack and defense for anomaly detection in spatial crowdsourcing UAV services[J]. IEEE Transactions on Consumer Electronics, 2025, 71(1): 2163-2174.
- [49] 熊润群, 张华俊, 梁川, 等. 一种多无人机辅助的 LoRa 网络节能数据采集方法[J]. 计算机学报, 2024, 47(8): 1970-1987.
- XIONG R Q, ZHANG H J, LIANG C, et al. A multi-UAV-assisted energy-saving data collection for LoRa networks[J]. Chinese Journal of Computers, 2024, 47(8): 1970-1987.
- [50] DOHARE A K, TULIKA. Retracted: a CNN and LSTM-based data prediction model for WSN[C]//Proceedings of the 2021 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N). Piscataway: IEEE Press, 2021: 1327-1330.
- [51] 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.
- [52] YE M, ZHANG Q, XUE X, 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.


[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。



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。



崔靖 (2000-), 男, 江苏盐城人, 桂林电子科技大学硕士生, 主要研究方向为无线传感器网络、异常检测。



何倩 (1979-), 男, 湖南安仁人, 博士, 桂林电子科技大学教授、博士生导师, 主要研究方向为云服务、网络安全。



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。



张继文 (2000-), 男, 安徽黄山人, 桂林电子科技大学硕士生, 主要研究方向为无线传感器网络、异常检测。