

doi: 10.7690/bgzdh.2026.06.012

无线通信网络传输数据多变量时间序列异常检测方法

黄金雪, 谢新就

(广州商学院现代信息产业学院, 广州 511363)

摘要: 针对无线通信网络传输数据的多变量时间序列异常检测效果不佳的问题, 提出一种基于时空记忆增强的并行编码器-解码器(spatio-temporal memory-augmented parallel encoder-decoder, STMA-PED)模型。该模型采用并行双流编码结构, 分别通过局部多尺度特征编码器与全局时序上下文编码器, 实现细粒度局部模式与长期依赖关系的高效提取; 引入可微分神经记忆库, 存储正常模式原型, 并通过注意力机制实现编码表示与记忆原型之间的重构差异度量。融合差异度指标与注意力分散度构建异常评分机制, 显著提升了异常判别的准确性与鲁棒性。实验结果表明: 该方法在多变量时间序列异常分数计算中的最小误差仅为 0.16%, 在 10 与 60 dB 噪声环境下检测结果与真实标注完全一致, 验证了其在复杂无线通信环境下的优异性能。

关键词: 传输数据; 并行双流编码器; 多变量时间序列; 记忆增强模块; 无线通信网络; 异常检测

中图分类号: TP273; TN92 **文献标志码:** A

Anomaly Detection Method for Multivariate Time Series of Data Transmitted by Wireless Communication Network

Huang Jinxue, Xie Xinjiu

(School of Modern Information Industry, Guangzhou College of Commerce, Guangzhou 511363, China)

Abstract: In order to improve the performance of anomaly detection for multivariate time series data transmitted in wireless communication networks, a spatio-temporal memory-augmented parallel encoder decoder (STMA-PED) model is proposed. The model adopts a parallel dual-stream coding structure, and achieves the efficient extraction of fine-grained local patterns and long-term dependencies through the local multi-scale feature encoder and the global temporal context encoder. The differentiable neural memory bank is introduced to store the normal pattern prototype, and the reconstruction difference measurement between the encoded representation and the memory prototype is achieved through the attention mechanism. The anomaly scoring mechanism is constructed by integrating the difference index and the distraction index, which significantly improves the accuracy and robustness of anomaly discrimination. The experimental results show that the minimum error of the proposed method is only 0.16% in the calculation of the anomaly score of multivariate time series, and the detection results are consistent with the real annotation in the noise environment of 10 and 60 dB, which verifies its excellent performance in the complex wireless communication environment.

Keywords: transmitted data; parallel two-stream encoder; multivariate time series; memory enhancement module; wireless communication network; anomaly detection

0 引言

近年来, 无线通信网络迅猛发展, 其传输数据展现出多维动态交织的复杂特性, 对网络数据处理及应用提出了更高要求^[1]。多变量时间序列作为无线通信网络传输数据的主要形式之一, 内部涵盖了多个关键指标的时序演变, 如丢包率、传输时延、信号强度等, 同时蕴含了不同变量间的深层次时空关联, 例如丢包率上升与信号衰减之间存在时空耦合效应, 信号强度波动与时延抖动之间存在同步性等。与此同时, 无线通信网络环境具有动态非平稳特性, 导致多变量时间序列(传输数据)建模难度显

著增加。用户行为的随机移动、网络拓扑的弹性重构以及电磁干扰的突发注入等因素相互耦合, 进一步加剧了传输数据时变规律捕捉的难度^[2]。此外, 多变量时间序列异常状态具有多样性, 从单个时间点的瞬态异常到持续数秒的子序列模式偏离, 乃至跨设备协同故障引发的系统级性能崩塌, 其引发的不同类型多变量时间序列异常均需要差异化的检测策略, 对多变量时间序列异常检测方法造成了较大的挑战。由此可见, 设计一种高效且精准的多变量时间序列异常检测方法, 对于无线通信网络的后续发展及其应用具有至关重要的作用。

收稿日期: 2024-12-06; 修回日期: 2025-01-15

基金项目: 2023 年度广东省教育科学规划(2023GXJK581)

第一作者: 黄金雪(1979—), 女, 广东人, 博士。

已有方法因模型性能不足，无法获得精准的多变量时间序列异常检测结果，制约了无线通信网络的发展。其中，张本初等^[3]提出结合对抗互信息的抗噪模型。该模型通过对比学习机制实现全局与局部互信息最大化，以捕捉时空依赖性；同时引入自适应权重和过滤器模块，降低噪声样本对训练的干扰，提升模型抗噪能力。构建模型通过互信息最大化和抗噪设计提升了性能，但对比学习机制可能增加计算复杂度，尤其在处理高维多变量数据时，训练效率可能降低，进而影响多变量时间序列异常检测的实时性。李汉章等^[4]提出融合时空特征的异常检测模型，采用图注意力网络，由时间图模块和空间图模块组成。时间图模块通过单向加权图模拟时间依赖关系，空间图模块通过全局双向加权图捕捉空间关联，并引入多维注意力机制挖掘深层特征。门控循环单元融合时空信息后，通过比较预测值与观测值的差异来判定异常。图注意力网络结构复杂，训练和推理时间可能较长，尤其在处理大规模时间序列数据时，计算资源消耗较高；与此同时，模型依赖图结构的构建，若时间或空间依赖关系建模不准确，可能影响检测性能。邓春华等^[5]提出基于长短期记忆网络—支持向量(long short-term memory-support vector machine, LSTM-SVM)的模型。利用 LSTM 预测时序样本数据，通过支持向量机分类异常数据，构建 LSTM-SVM 模型。离线检测时，通过执行片段提取、匹配、时间约束识别和异常检测 4 步完成任务。LSTM-SVM 模型结合了深度学习和传统机器学习方法，但模型复杂度较高，训练和调参难度较大，无法保障多变量时序异常检测的精度。蔡美玲等^[6]提出基于 Transformer 生成对抗网络(generative adversarial network, GAN)的无监督异常检测方法，采用 Transformer 网络作为生成对抗网络的基础模型，引入图注意力层学习时序变量间的复杂依赖关系，应用 Patch 技巧捕捉时间窗口内异常细节，并结合重构误差与鉴别误差计算异常分数。Transformer GAN 模型由于其复杂的结构和生成器与鉴别器之间的博弈过程，可能在数据量较少时面临训练稳定性问题和模式崩溃。此外，引入图注意力层和 Patch 技巧虽然增强了模型的性能，但也可能增加过拟合的风险，尤其是在小数据集上，这可能影响无监督异常检测的精度。

为了解决上述问题或者缺陷，笔者提出无线通信网络传输数据多变量时间序列异常检测方法。

1 多变量时间序列异常检测

为提升多变量时间序列异常检测性能，引入记忆增强神经网络与编码器，构建多变量时间序列异常检测模型——时空记忆增强型并行编码器-解码器(STMA-PED)模型，为无线通信网络数据精准传输提供更加可靠的支撑。

STMA-PED 采用并行双流架构，摒弃传统单一架构，同步捕捉多变量时间序列的局部细粒度特征与全局时序模式，有效提升了综合特征的完整性与全面性，为异常检测提供更精准的特征数据支持^[7]。与此同时，STMA-PED 模型引入了可微分神经记忆库(differentiable neural memory bank, BNMB)，用于学习和存储传输数据的正常模式原型。通过与记忆库中的模式对比，可实现多变量时间序列异常检测，最大限度提高模型对未见异常模式的敏感性，显著提升检测效果^[8]。多变量时间序列异常检测 STMA-PED 模型架构如图 1 所示。

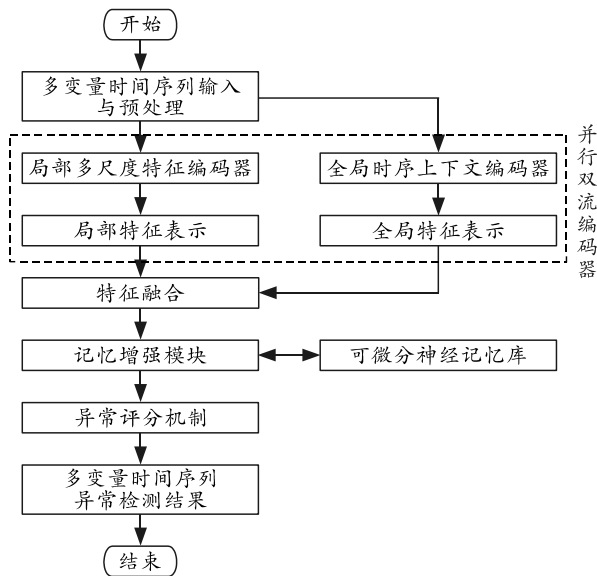


图 1 STMA-PED 模型架构

1.1 多尺度时空特征并行提取

由于无线通信网络传输数据具有高维非平稳、时空耦合及动态资源扰动等复杂特性，致使算法易受长期依赖关系干扰。并行双流编码结构中，局部多尺度特征编码器可聚焦细粒度局部模式，全局时序上下文编码器能捕捉长期依赖关系，二者同步作用能高效提取多尺度时空特征，有效应对复杂数据特性；因此，该模型采用并行双流编码结构，分别通过局部多尺度特征编码器与全局时序上下文编码器，同步捕捉时间序列的细粒度局部模式与长期依赖关系，实现多尺度时空特征的高效提取。

步骤 1: 在无线通信网络数据传输过程中获取多变量时间序列, 记为 $X \in R^{T \times D}$ 。 T 为时间步长, D 为变量维度, 为 STMA-PED 模型的输入^[9]。

步骤 2: 并行双流编码器(局部多尺度特征编码器与全局时序上下文编码器)对多变量时间序列 X 的局部特征与全局特征进行同时捕捉, 以此来提升构建模型的特征提取性能, 为多变量时间序列复杂动态行为的全面理解提供有力的依据^[10]。

局部多尺度特征编码器由 2 层改进的 Inception 模块构成, 而每层 Inception 模块由多种尺度的卷积核、批归一化层与 ReLU 激活函数组成。其中, 不同尺度的卷积核可以同时多变量时间序列 X 不同时间尺度的局部特征进行提取, 批归一化层与 ReLU 激活函数主要承担着非线性特性引入与收敛速度加快的任务^[11]。局部多尺度特征编码器的引入与应用, 能够有效增强构建模型对短期异常模式的感知能力, 其输出的局部特征表示为:

$$\left. \begin{aligned} Z_i^{(p)} &= C_{i=1}^n \left[\sigma(W_i^{(p)} * X^{(p-1)} + b_i^{(p)}) \right] \\ Z_i &= Z_i^{(2)} = C_{i=1}^n \left[\sigma(W_i^{(2)} * X^{(2-1)} + b_i^{(2)}) \right] \end{aligned} \right\} \quad (1)$$

式中: $Z_i^{(p)}$ 为第 p 层改进 Inception 模块的输出结果; $C_{i=1}^n[\bullet]$ 为 n 种尺度卷积操作函数; $\sigma(\bullet)$ 为 ReLU 激活函数; $W_i^{(p)}$ 与 $b_i^{(p)}$ 为第 p 层改进 Inception 模块中第 i 种尺度卷积操作函数对应的权重向量与偏置项; $X^{(p-1)}$ 为第 p 层改进 Inception 模块的输入, $X^{(0)}=X$; Z_i 为多变量时间序列 X 的局部特征表示; $p=1, 2$ 。

全局时序上下文编码器由 4 层膨胀因果卷积层构成, 其通过膨胀因子的引入(每层的膨胀因子按照指数规律增长, 卷积核大小保持一致), 能够以较少的层数获得较大的感受野, 并不会影响原有多变量时间序列的因果性, 进而高效捕捉多变量时间序列 X 的长期依赖关系^[12]。全局时序上下文编码器的引入与应用, 能够有效增强构建模型对长期异常模式的感知能力, 其输出的全局特征表示为:

$$\left. \begin{aligned} Z_g^{(k)} &= \sigma(W^{(k)} * \delta_{d^{(k)}}(\text{BN}(Z_g^{(k-1)})) + b^{(k)}) \\ Z_g &= Z_g^{(4)} = \sigma(W^{(4)} * \delta_{d^{(4)}}(\text{BN}(Z_g^{(4-1)})) + b^{(4)}) \end{aligned} \right\} \quad (2)$$

式中: $Z_g^{(k)}$ 为第 k 层膨胀因果卷积层的输出结果; $W^{(k)}$ 与 $b^{(k)}$ 为第 k 层膨胀因果卷积层对应的权重向量与偏置项; $\delta_{d^{(k)}}(\bullet)$ 为膨胀因子为 $d^{(k)}$ 的卷积操作函数; $\text{BN}(\bullet)$ 为批归一化层; $Z_g^{(k-1)}$ 为第 $k-1$ 层膨胀因果卷积层的输出结果; Z_g 为多变量时间序列 X 的全局特征表示; $k=1, 2, 3, 4$ 。

步骤 3: 将步骤 2 输出的多变量时间序列 X 的局部特征表示 Z_i 与全局特征表示进行特征维度拼接, 以此来获取综合特征, 表达式为:

$$Z = \zeta [Z_i, Z_g] \quad (3)$$

式中: Z 为综合特征; $\zeta[\bullet]$ 为特征维度拼接操作函数。

随后, 将综合特征 Z 输入至一个单层门控循环单元, 通过更新门与重置门处理多变量时间序列的长期依赖关系, 避免梯度爆炸或者消失等问题的产生, 进一步融合多变量时间序列的时空信息, 从而获得最终的综合特征编码表示^[13]。

$$\left. \begin{aligned} h_t &= \text{GRU}[Z_t, h_{t-1}] \\ H &= \{h_t\}_{t=1}^T \end{aligned} \right\} \quad (4)$$

式中: h_t 与 h_{t-1} 为时间步 t 与 $t-1$ 的多变量时间序列综合特征向量; Z_t 为时间步 t 的综合特征; $\text{GRU}[\bullet]$ 为门控循环单元操作函数; H 为综合特征编码。

1.2 记忆增强与原型重构机制

多尺度时空特征并行提取虽能全面捕捉数据不同层面的信息, 但仅靠这些特征难以精准区分正常与异常模式。引入可微分神经记忆库存储和学习正常模式原型, 可建立起正常模式的基准。借助注意力机制计算编码特征与记忆原型的相似度权重, 能依据特征与正常模式的匹配程度, 从记忆库精准读取并重构对应的正常模式表示, 以此更有效地识别出偏离正常模式的异常, 提升异常检测的准确性。模型引入可微分神经记忆库, 用于存储和学习正常模式原型; 通过注意力机制计算编码特征与记忆原型间的相似度权重, 并据此从记忆库中读取并重构出对应的正常模式表示。

基于记忆增强神经网络定义一个可微分神经记忆库 M , 其每一行 m_i 代表一个学习到的“正常模式原型”^[14]。与此同时, 计算多变量时间序列综合特征向量 h_t 与记忆库中所有原型 m_i 的余弦相似度, 获取注意力权重系数, 表达式为:

$$\omega_{t,i} = \frac{\exp[\alpha \cdot \cos(h_t, m_i)]}{\sum \exp[\alpha \cdot \cos(h_t, m_i)]} \quad (5)$$

式中: $\omega_{t,i}$ 为注意力权重系数; $\exp[\bullet]$ 为指数函数; α 为辅助系数, 用于锐化注意力权重的分布; $\cos(h_t, m_i)$ 为 h_t 与 m_i 之间的余弦相似度, 取值范围为 $[-1, 1]$ 。

根据式(5)计算得到的注意力权重 $\omega_{t,i}$, 从记忆库中读取一个重构后的正常模式表示^[15]。

$$\hat{h}_t = \sum_{i=1}^N \omega_{t,i} \cdot m_i \quad (6)$$

式中： \hat{h}_i 为重构正常模式； N 为预定义的记忆库原型数量。

1.3 多指标融合异常判别

记忆增强与原型重构机制虽能基于正常模式对输入数据进行一定程度的校准与解读，但单一的重构表示与编码表示对比，难以全面且精准地衡量数据的异常程度。因为仅依靠重构差异可能忽略特征权重分布的异常情况，所以模型综合计算编码表示与重构表示之间的差异度指标，能直接反映数据与正常模式的偏离程度；同时耦合注意力权重的分散度作为辅助异常指标，可捕捉特征权重分配的异常，避免因局部特征异常被掩盖而漏检。通过融合二者构建最终的异常评分机制，能从多个维度综合判断异常，显著提升异常判别的准确性与鲁棒性。在上述基础上，模型综合计算编码表示与重构表示之间的差异度指标，并耦合注意力权重的分散度作为辅助异常指标，通过融合二者构建最终的异常评分机制，从而显著提升了异常判别的准确性与鲁棒性。

通常情况下，异常时间步的模式无法在记忆库中找到高度相似的原型，使得读取后的表示与原始编码表示之间存在着较大的差异性；因此，所提方法制定融合异常评分机制。计算原始编码 h_i 与记忆库重构表示 \hat{h}_i 之间的余弦距离，将其作为差异度指标。

$$d_i = 1 - \cos(h_i, \hat{h}_i) \tag{7}$$

式中： d_i 为多变量时间序列的差异度指标； $\cos(h_i, \hat{h}_i)$ 为 h_i 与 \hat{h}_i 的余弦距离。

量化注意力权重的分散程度，计算香农熵，将其作为辅助异常指标，表达式为：

$$e_i = - \sum_{i=1}^N \omega_{i,i} \cdot \log_2(\omega_{i,i} + \epsilon) \tag{8}$$

式中： e_i 为多变量时间序列的辅助异常指标； ϵ 为一个极小的正数，用于防止对 0 取对数的情况发生。

将式(7)与(8)输出结果进行线性组合，并在整个窗口上求和，即可获得多变量时间序列的最终异常分数：

$$S = \frac{1}{T} \sum_{i=1}^T \left[\beta \cdot d_i + (1 - \beta) \cdot \frac{e_i}{\max(e_i)} \right] \tag{9}$$

式中： S 为多变量时间序列的异常分数； β 为组合权重超参数，用于平衡 d_i 与 e_i 的重要性； $\max(e_i)$ 为所有时间步中注意力权重分散度的最大值，用于对熵

进行归一化处理，从而使得 $e_i/\max(e_i)$ 取值范围在 0~1 之间。

以输出的异常分数 S 为依据，制定多变量时间序列异常检测规则^[16]：

$$\left. \begin{aligned} S > \tau & \text{ 多变量时间序列异常} \\ S \leq \tau & \text{ 多变量时间序列正常} \end{aligned} \right\} \tag{10}$$

式中 τ 为多变量时间序列异常检测阈值，其需要根据无线网络传输数据实际情况进行动态的设置。

综上所述，基于 STMA-PED 模型的构建与应用，所提方法实现了多变量时间序列异常的有效检测，为无线网络数据的准确传输提供了一定帮助。

2 实验设计与结果分析

选取结合对抗互信息的多变量时间序列异常检测方法和基于 LSTM-SVM 模型的多变量时间序列异常检测方法作为对比方法 1 和对比方法 2，与所提方法共同进行对比实验，通过实验数据的记录、处理与分析，验证所提方法的应用性能。

2.1 实验数据集构建

从 SWaT、WADI、SMD 等公开数据集与无线通信专属数据集中随机抽取 8 000+ 多变量时间序列样本，以此为基础，构建实验数据集，如表 1 所示，实现无线传感网络架构如图 2 所示。

表 1 实验数据集

数据集	正常	异常	总样本	数据	冗余	干扰
	样本	样本				
	数量	数量	数量	方式		
训练集	2 356	2 142	4 498	人工标注+	10.23	2.32
验证集	1 524	1 325	2 849	系统日志	8.45	3.55
测试集	798	754	1 552	匹配	9.54	4.01




图 2 无线传感网络架构

2.2 STMA-PED 模型训练

所提方法以 STMA-PED 模型作为多变量时间序列异常检测的核心所在。为了确保实验结论的准确性，通过训练集对 STMA-PED 模型进行预先训练，训练目标是实现总损失最小化，结果如图 3 所示。




图 3 STMA-PED 模型总损失变化

由图 3 可知：当训练次数达 10 次时，STMA-PED 模型总损失降至最小值 4，此时对应的模型参数取值即为最佳取值。总损失在训练过程中的变化趋势反映了模型的学习过程。在训练初期，总损失快速下降，表明模型能迅速捕捉到数据中的一些基本特征和模式，参数调整对降低损失起到了明显作用。随着训练次数的增加，损失下降速度逐渐变缓，说明模型在不断优化参数以适应更复杂的特征和模式。当训练到第 10 次时达到最小值，表明此时模型的参数组合已经能够较好地拟合训练数据，实现了总损失的最小化。而后续训练次数增加时损失略有上升，可能是由于模型出现了过拟合现象，即模型过于适应训练数据中的噪声和特殊情况，导致在验证集和测试集上的泛化能力下降。选择第 10 次训练对应的参数作为最佳取值，能够平衡模型的拟合能力和泛化能力。综合以上实验结果，确定具体最佳参数为：多变量时间序列窗口长度是 30，多变量时间序列预测步长为 5，局部特征维度为 64，全局特征维度为 32，膨胀因子取 1、2、4、8，改进 Inception 模块卷积核大小为 5、11、23，批大小为 32，学习率是 0.000 1，Dropout 率为 0.2，权重衰减系数为 0.01。

2.3 多变量时间序列异常分数计算误差分析

在测试集随机抽取 30 个多变量时间序列样本，应用所提方法、对比方法 1 与对比方法 2 计算多变量时间序列异常分数，计算其与实际异常分数的误差，如图 4 所示。




图 4 多变量时间序列异常分数计算误差

由图 4 可知：相较于对比方法 1 与对比方法 2 来看，所提方法应用后多变量时间序列异常分数计算误差显著更小，最小值达到了 0.16%。这一结果得益于所提方法对多变量时间序列特征的全面捕捉和异常评分机制的科学设计。所提方法通过并行双流架构，同时提取多变量时间序列的局部细粒度特征和全局时序模式，使得模型能够更准确地理解数据的复杂动态行为，为异常分数计算提供了更可靠的依据。记忆增强神经网络与可微分神经记忆库的引入，进一步增强了模型对正常模式的学习和存储能力。在计算异常分数时，充分考虑了记忆库重构表示与原始编码表示的差异性，通过差异度指标与辅助异常指标的有效融合，制定了异常评分机制。这种机制能够更精确地反映多变量时间序列的实际异常情况，有效地提高了多变量时间序列异常分数计算精度，使其无限接近多变量时间序列实际异常分数，进而显著降低了所提方法的多变量时间序列异常分数计算误差。相比之下，对比方法 1 和对比方法 2 可能在特征提取或异常评分机制上存在不足，导致计算误差较大。

2.4 多变量时间序列异常检测结果分析

从测试集中随机选取 30 个正常多变量时间序列样本和 30 个异常多变量时间序列样本，分别应用所提方法、对比方法 1 和对比方法 2，在噪声 10 和 60 dB 环境下进行检测。

在噪声环境下的实验中，所提方法在 10 与 60 dB 的噪声水平下应用后，多变量时间序列异常检测结果与实验样本标注结果保持一致，这不仅展示了所提方法在多变量时间序列异常检测方面的高精度，而且证明了其在噪声环境下的鲁棒性。对比方法 1 和方法 2 在多变量时间序列异常检测中，其结果与实验样本标注结果存在一定偏差；且随着噪声数值的增加，错误样本数量也相应增加，这表明 2 种方法的整体应用性能较差。这主要是因为所提方法引入记忆增强神经网络与编码器，构建了

STMA-PED 模型，这是其取得优异性能的关键。并行双流架构能够同时提取多变量时间序列的局部特征与全局特征，局部多尺度特征编码器通过不同尺度的卷积核可以捕捉不同时间尺度的局部特征，批归一化层与 ReLU 激活函数引入非线性特性并加快收敛速度，增强了模型对短期异常模式的感知能力；全局时序上下文编码器通过膨胀因果卷积层高效捕捉多变量时间序列的长期依赖关系，增强了模型对长期异常模式的感知能力。这种全面的特征提取方式显著提高了多变量时间序列特征的提取全面性，为多变量时间序列异常检测提供了更全面的依据支撑。同时，可微分神经记忆库的引入及其应用，使得模型能够学习和存储传输数据的正常模式原型，通过与记忆库中的模式对比实现异常检测，增加了模型对未见异常模式的敏感性。对比方法 1 和对比方法 2 可能在特征提取的全面性或对正常模式的学习能力上存在欠缺，导致在噪声环境下容易受到干扰，从而出现检测结果偏差和错误样本数量增加的情况。

3 结束语

无线网络正深度融合变革，架构复杂度指数级增长，传输数据的多变量时间序列产生复杂时空耦合效应。动态资源分配与开放频谱特性又增数据不确定性，导致多变量时间序列出现多种异常，影响网络运行安全稳定，故提出相关异常检测方法。实验结果表明：该模型通过并行双流架构有效捕捉局部与全局特征，可微分神经记忆库增强对未见异常模式的敏感性，在异常分数计算和检测结果上均优于对比方法，不仅提高了检测精度，而且在噪声环境下展现出良好鲁棒性，为无线网络数据精准传输提供了可靠支撑。

参考文献：

- [1] 段美然, 赵辉, 谷松原, 等. 基于深度迁移学习的多变量时间序列异常检测[J]. 中国电子科学研究院学报, 2023, 18(2): 138-145.
- [2] 王玲, 周南, 申鹏. 基于自适应 k 近邻的时间序列异常模式识别[J]. 计算机研究与发展, 2023, 60(1): 125-139.
- [3] 张本初, 乔焰, 胡荣耀. 结合对抗互信息的多变量时间序列抗噪异常检测[J]. 计算机应用研究, 2024, 41(8): 2384-2391.
- [4] 李汉章, 严宣辉, 李镇力, 等. 面向多变量时间序列异常检测的双图注意力网络模型[J]. 计算机科学与探索, 2025, 19(4): 1048-1064.
- [5] 邓春华, 周勇. 基于 LSTM-SVM 模型的 ES 多变量时序异常检测[J]. 计算机仿真, 2023, 40(3): 471-475.
- [6] 蔡美玲, 汪家喜, 刘金平, 等. 基于 Transformer GAN 架构的多变量时间序列异常检测[J]. 中国科学: 信息科学, 2023, 53(5): 972-992.
- [7] 王静, 何苗苗, 丁建立, 等. 面向多维时间序列异常检测的时空图卷积网络[J]. 西安电子科技大学学报, 2024, 51(3): 170-181.
- [8] 尹春勇, 周立文. 基于再编码的无监督时间序列异常检测模型[J]. 计算机应用, 2023, 43(3): 804-811.
- [9] 谢伟, 卢士达, 时宽治, 等. 面向工业物联网时序数据的异常检测方法[J]. 计算机工程与应用, 2024, 60(12): 270-282.
- [10] 秦欢欢, 王梦凡, 柯熙政. 工业互联网下的无线光通信研究进展[J]. 电子测量与仪器学报, 2023, 37(10): 1-13.
- [11] 周浩, 禹可, 吴晓非. 基于得分生成模型的时间序列异常检测方法[J]. 北京邮电大学学报, 2024, 47(2): 51-57.
- [12] 陆秋琴, 王璐, 黄光球. 考虑时序特征的污染物数据异常检测及恢复[J]. 安全与环境学报, 2023, 23(12): 4590-4599.
- [13] 张亦弛, 朱晓强. 基于网络性能评价的多元时序相似度算法[J]. 电子设计工程, 2023, 31(11): 163-166.
- [14] 李婧, 周师严. BLAC: 注意力机制时序网络流量异常检测模型[J]. 现代电子技术, 2023, 46(4): 91-96.
- [15] 霍纬纲, 梁锐, 李永华. 基于随机 Transformer 的多维时间序列异常检测模型[J]. 通信学报, 2023, 44(2): 94-103.
- [16] 王春枝, 邢绍文, 高榕, 等. 基于预训练交互式图神经网络的多元时间序列异常检测[J]. 中南民族大学学报(自然科学版), 2023, 42(4): 541-550.