

# 基于双注意力LSTM-AdvAE的无监督异常检测与预警

## ——面向多维时间序列的工业故障智能诊断方法

张之翼, 杨卫华

太原理工大学数学学院, 山西 晋中

收稿日期: 2026年3月21日; 录用日期: 2026年4月16日; 发布日期: 2026年4月22日

### 摘要

无监督异常检测在信息科学与工业监测中具有重要应用价值, 但现有方法在多维时间序列的时空特征建模、微弱故障识别等方面仍存在不足。本文提出一种基于双注意力LSTM-AdvAE的无监督异常检测与预警模型, 通过TFDAM双注意力模块对特征与时间维度进行加权增强, 结合LSTM捕捉时序依赖关系, 并利用改进对抗自编码器实现更鲁棒的异常识别。在公开数据集上的实验表明, 该方法在精确率、召回率及F1分数上均优于现有主流方法, 能够有效实现工业设备故障的早期预警。

### 关键词

无监督异常检测, 双注意力, LSTM, 对抗自编码器, 时间序列, 故障预警

# Unsupervised Anomaly Detection and Early Warning Based on Dual-Attention LSTM-AdvAE

## —Intelligent Industrial Fault Diagnosis Method for Multidimensional Time Series

Zhiyi Zhang, Weihua Yang

College of Mathematics, Taiyuan University of Technology, Jinzhong Shanxi

Received: March 21, 2026; accepted: April 16, 2026; published: April 22, 2026

## Abstract

Unsupervised anomaly detection (UAD) has been widely used in industrial monitoring and information science. However, current methods hardly model spatio-temporal dependencies and detect weak faults effectively for high-dimensional time series. This paper proposes a Dual-Attention LSTM-AdvAE model for unsupervised anomaly detection and early warning. The model uses a TFDAM module to weight features and temporal dimensions, adopts LSTM to capture long-term dependencies, and applies an improved adversarial autoencoder for robust anomaly scoring. Experiments on public datasets demonstrate that this method outperforms existing mainstream approaches in precision, recall and F1-score, enabling effective early warning of industrial equipment faults.

## Keywords

Unsupervised Anomaly Detection, Dual-Attention, LSTM, Adversarial Autoencoder, Time Series, Fault Early Warning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

随着工业 4.0 推进, 工业设备监测数据呈现多维化、时序化、海量特点, 蕴含设备运行关键信息, 异常检测对降低停机时间、减少维护成本至关重要。工业场景中, 多维时间序列异常样本占比极低、难以标注, 无监督异常检测因无需依赖标签, 成为研究热点。现有无监督方法存在三大挑战: 难以同时捕捉特征空间关联与时间长期依赖、对初期细微故障敏感不足、鲁棒性难以适应工业噪声与工况波动。传统方法泛化能力差, 深度学习各有局限。为此, 本文提出双注意力 LSTM-AdvAE 方法, 融合双注意力、LSTM 与时序建模、对抗自编码器, 精准聚焦关键信息、放大异常信号, 通过实验验证其有效性, 为工业故障诊断提供新方案。

## 2. 相关工作

### 2.1. 时间序列异常检测的深度学习方法

深度学习在时间序列异常检测中主要分为三类: 基于重构的 AE 及其变体、基于时序建模的 RNN [1] 及其变体、基于对抗学习的 GAN [2] 及其变体。AE [3] 结构简单但对细微异常敏感不足, VAE 引入概率约束提升泛化性, DAGMM [4] 忽略时序依赖; LSTM-VAE [5] 能捕捉时序依赖但忽视特征关联, GRU-AE 效率高但捕捉长期依赖能力较弱, Anomaly Transformer 性能优但计算复杂; GANomaly 灵敏度高但训练不稳定, OmniAnomaly [6] 泛化性强但计算量大, USAD [7] 放大异常重构误差但仍有不足。各类方法均存在局限, 难以同时满足工业场景的精准性与效率需求。

### 2.2. 基于图的高级异常检测方法

基于图的异常检测针对属性网络, 通过 GNN [8] 学习节点嵌入, 依嵌入差异识别异常, 分为结构分析、节点嵌入、生成模型三类。结构分析类通过图特征识别异常, 节点嵌入类使正常节点聚集、异常节点远离, 生成模型类融合 GNN 与 VAE/GAN [9] 学习正常分布。此类方法擅长处理静态关系数据, 但工业多维时间序列的时空依赖动态演化, 难以直接应用。本文将关系学习理念融入时间域, 通过双注意力

捕捉特征关联与时间动态依赖, 解决这一痛点。

### 2.3. 注意力机制在异常检测中的应用

注意力机制可使模型聚焦关键信息, 在异常检测中分为时间注意力与特征注意力。时间注意力突出关键时间片段, 特征注意力聚焦敏感特征维度。现有方法多采用单一维度注意力, 难以同时捕捉时间与特征关键信息, 且与深度学习模型融合简单, 性能提升有限。本文提出 TFDAM (Temporal-Feature Dual-Attention Module) 双注意力模块, 有机结合两类注意力, 对时间与特征维度同时加权, 精准聚焦关键信息, 进一步提升异常检测性能, 弥补现有方法不足。

## 3. 模型架构




Figure 1. Model architecture

图 1. 模型架构

本文图 1 提出的双注意力 LSTM-AdvAE 方法, 核心是通过双注意力聚焦关键信息、LSTM 捕捉时序依赖、AdvAE 放大异常信号, 实现工业多维时间序列异常检测与预警。整体分为三步: TFDAM (Temporal-Feature Dual-Attention Module) 双注意力模块加权增强特征与时间信息, LSTM 网络进行时序建模提取依赖特征, 改进 AdvAE 框架对抗训练放大异常重构误差。该方法创新点在于 TFDAM (Temporal-Feature Dual-Attention Module) 双注意力模块的引入, 以及 LSTM 与 AdvAE 的协同融合, 有效解决现有方法难以兼顾关键信息捕捉与异常信号放大的问题, 提升检测精度与鲁棒性。

### 3.1. 特征增强

工业多维时间序列含大量冗余与噪声, 特征增强分为数据预处理与 TFDAM 双注意力加权。预处理包括数据清洗、归一化与滑动窗口分割: 清洗移除缺失值与噪声, 线性插值填补缺失; 归一化将特征映射至  $[0, 1]$ , 消除量纲影响; 滑动窗口分割将连续时序转为离散样本, 捕捉局部特征与时序依赖。TFDAM 模块由特征与时间注意力组成, 并行处理后乘法融合, 结合残差连接保留原始信息, 缓解梯度消失, 突出关键特征与时间片段, 为后续时序建模奠定基础。

TFDAM (时序 - 特征双重注意力模块) 是一种用于增强特征表示的神经网络模块, 其核心思想是通过并行的注意力机制, 分别从特征维度与时间维度对输入数据进行自适应加权, 从而突出对当前任务最关键的传感器通道与时间片段。

该模块的输入为形状是  $[\text{batch\_size}, \text{seq\_len}, \text{feature\_size}]$  的多维时序数据, 分别对应批大小、时间步长与特征维数。其结构包含两个独立且互补的注意力子模块:

#### (1) 特征注意力机制

该机制旨在评估不同传感器通道(特征)的重要性。其处理流程为:

- 压缩时序维度：对输入数据分别在时序维度上进行全局平均池化与全局最大池化操作，将每个样本的时序信息压缩为聚合统计量，得到两个形状为[batch\_size, 1, feature\_size]的特征描述符。
- 特征变换与融合：将上述两个描述符分别送入一个共享的多层感知机(MLP)进行非线性变换，以学习通道间的高阶交互关系。将两个 MLP 的输出逐元素相加。
- 生成注意力权重：对相加结果使用 Sigmoid 激活函数，得到归一化的通道注意力权重向量  $W_f$ ，其形状为[batch\_size, 1, feature\_size]。该权重向量反映了每个特征通道的重要性。
- 特征加权：将原始输入数据与注意力权重  $W_f$  逐通道相乘，得到特征增强后的输出  $X_f$ ，从而强调了信息量最丰富的传感器通道。

其计算过程可以表示为：

$$M_{output}(F) = \omega(MLP(AvgPool(F)) + MLP(MaxPool(F))) \quad (1)$$

### (2) 时序注意力机制

该机制旨在评估不同时间步的重要性。其处理流程为：

- 压缩特征维度：对经过特征注意力加权的中间结果  $X_f$ ，在特征维度上分别计算平均值与最大值，从而将每个时间步的多维特征压缩为两个具有代表性的标量，得到两个形状为[batch\_size, seq\_len, 1]的时序描述符。
- 描述符合并与变换：将上述两个描述符沿最后一个维度拼接，得到一个形状为[batch\_size, seq\_len, 2]的张量。随后使用一维卷积层(Conv1D)对该张量进行卷积操作，以捕获相邻时间步间的局部上下文关联。
- 生成注意力权重：对卷积输出使用 Sigmoid 激活函数，得到归一化的时序注意力权重向量  $W_t$ ，其形状为[batch\_size, seq\_len, 1]。该权重向量反映了每个时间步的重要性。
- 时序加权：将特征增强后的数据  $X_f$  与注意力权重  $W_t$  逐时间步相乘，得到进一步在时间维度上增强的表示  $X_t$ ，从而突出了最关键的时序片段。

其计算过程可以表示为：

$$M_p(F') = \omega(MLP(AvgPool(F')) + MLP(MaxPool(F'))) \quad (1)$$

### (3) 特征融合与输出

将时序加权后的结果  $X_t$  与原始输入  $X$  通过残差连接相加，得到模块的最终输出  $Y$ 。这种设计既保留了原始信息的完整性，又融入了从特征和时序两个角度提炼出的关键信息。TFDAM 的双重注意力设计使其能够更精细地理解多维时序数据的内在结构，在异常检测等任务中有效提升模型对关键模式变化的感知能力。

LSTM [10]用于捕捉增强特征序列的长期依赖，缓解传统 RNN 梯度消失问题，采用两层隐藏层堆叠提升性能。其通过遗忘门、输入门、输出门协同作用，选择性保留与遗忘信息：遗忘门决定上一时刻细胞状态的保留程度，输入门控制当前信息的更新，输出门调节隐藏状态输出。LSTM 输入为 TFDAM 增强特征序列，输出为含长期依赖的特征向量，与 TFDAM 形成“聚焦 - 分析”协同流程，为后续对抗训练提供可靠的时序特征支撑。

## 3.2. 对抗自编码器

对抗自编码器是一种将生成对抗网络框架与自编码器架构相结合的概率生成模型。其核心创新在于通过对抗训练机制对自编码器的潜在空间分布进行正则化约束，使潜在变量的聚合后验分布能够匹配任

意设定的先验分布(如标准正态分布)。这一设计不仅增强了模型的生成能力,更因其在潜在空间中形成的清晰决策边界,使其在异常检测任务中表现出优于传统自编码器的敏感性。

AdvAE 模型包含三个核心组件: 一个共享的编码器网络  $E$  和两个独立的解码器网络  $D_1, D_2$ 。它们构成两个共享编码器的自编码器:

$$AE_1(W) = D_1(E(W)), AE_2(W) = D_2(E(W)) \quad (3)$$

其中  $W$  表示输入的时间窗口数据。

模型的训练分为两个阶段, 采用独特的对抗性协作策略:

(1) 第一阶段: 基础重构训练

两个自编码器并行训练, 共同学习正常数据的数据分布, 最小化各自的重构误差:

$$L_{AE_1} = \|W - AE_1(W)\|_2 \quad (4)$$

$$L_{AE_2} = \|W - AE_2(W)\|_2 \quad (5)$$

(2) 第二阶段: 对抗性训练

$AE_1$  的目标是生成与真实数据尽可能相似的重构数据,  $AE_2$  的目标是准确区分真实数据与  $AE_1$  生成的重构数据。两者形成对抗性竞争关系:

$$\min_{AE_1} \max_{AE_2} \|W - AE_2(AE_1(W))\|_2 \quad (6)$$

(3) 整体训练目标

综合两个阶段的训练, 得到最终的目标函数:

$$\begin{aligned} \mathcal{L}_{AE_1} &= \frac{1}{n} \|W - AE_1(W)\|^2 + \left(1 - \frac{1}{n}\right) \|W - AE_2(AE_1(W))\|^2 \\ \mathcal{L}_{AE_2} &= \frac{1}{n} \|W - AE_2(W)\|^2 - \left(1 - \frac{1}{n}\right) \|W - AE_2(AE_1(W))\|^2 \end{aligned} \quad (7)$$

其中  $n$  为训练轮次, 随着训练进行, 对抗性损失的权重逐渐增加。模型采用两阶段联合训练策略, 在每一轮迭代中同步执行基础重构训练与对抗性训练, 而非分阶段独立完成。首先, 两个自编码器通过基础重构损失学习正常时序数据的分布特征; 随后在同一轮次内继续开展对抗训练, 使  $AE_1$  尽可能生成逼近真实样本的重构结果,  $AE_2$  则对其进行判别区分, 二者形成动态竞争关系。目标函数在每次反向传播时同步更新, 对抗损失权重随训练轮次逐步提升, 从而实现端到端的稳定联合优化。

### 3.3. 异常评分机制

对于输入时间窗口样本  $W$ , 其异常评分  $S(W)$  由两个自编码器的重构误差加权求和得到:

$$S(W) = \alpha \|W - AE_1(W)\|_2 + \beta \|W - AE_2(AE_1(W))\|_2 \quad (8)$$

其中:

- $\|\cdot\|_2$  表示 L2 范数(二范数);
- $\alpha$  和  $\beta$  为可调的权重系数, 满足  $\alpha + \beta = 1$ ;
- $AE_1(W) = D_1(E(W))$  为自编码器  $AE_1$  的直接重构输出;
- $AE_2(AE_1(W)) = D_2(E(D_1(E(W))))$  为自编码器  $AE_2$  对  $AE_1$  重构输出的再次重构。

权重系数  $\alpha$  和  $\beta$  平衡了两种误差成分的贡献: 当  $\alpha$  值较大时, 模型更依赖于直接重构误差, 对异常的敏感性相对保守; 当  $\alpha$  值较小时(相应地  $\beta$  值增大), 模型更侧重于对抗性重构误差, 对微弱异常具有更

高的灵敏度。

### 3.4. 模型实现细节与超参数设置

本文所有实验均在统一硬件与训练环境下完成, 模型基于 PyTorch 框架实现。为保证实验可复现性, 本节详细说明网络结构、超参数及训练配置。

#### 3.4.1. 数据预处理与滑动窗口

对所有数据集采用相同预处理流程: 首先使用线性插值填补缺失值, 通过 Min-Max 归一化将所有特征映射至 $[0, 1]$ 区间; 采用固定滑动窗口将连续时间序列转换为模型输入样本, 窗口长度统一设置为  $seq\_len = 60$ , 窗口无重叠分割。输入张量形状为 $[batch\_size, 60, feature\_size]$ 。

#### 3.4.2. TFDAM 双注意力模块

特征注意力: 全局平均池化 + 全局最大池化, 共享 MLP 包含 2 层全连接层, 隐藏层节点数为  $feature\_size//4$ , 激活函数为 ReLU, 输出层使用 Sigmoid。时序注意力: 特征压缩后拼接为 $[batch\_size, 60, 2]$ , 通过 1 层一维卷积(卷积核大小 = 3, 步长 = 1, 填充 = 1)提取时序关联, 输出经 Sigmoid 生成时序权重。

#### 3.4.3. LSTM 时序建模层

采用 2 层堆叠 LSTM, 每层隐藏单元数为 128, 返回所有时间步输出以保留时序信息; 使用 ReLU 激活,  $dropout = 0.1$  防止过拟合, 输出特征维度为 $[batch\_size, 60, 128]$ 。

#### 3.4.4. 对抗自编码器(AdvAE)结构

- 编码器 E: 2 层全连接层, 节点数依次为 128→64, 输出潜在向量维度为 32。
- 解码器 D1、D2: 结构对称, 均为 2 层全连接层, 节点数依次为 64→128, 最终重构输出与输入维度一致。
- 判别器(对抗分支): 1 层全连接层, 维度为 64, Sigmoid 输出真伪概率。

## 4. 实验设计与结果分析

### 4.1. 实验数据集

为确保评估的全面性与可靠性, 实验采用了两个在工业异常检测领域广泛认可的公开基准数据集, 以及一个从真实工业场景中采集、包含实际故障记录的自有数据集。这三个数据集分别代表了不同的系统复杂度、数据特性和故障模式, 能够全面考验模型的泛化能力和实用价值。

SWaT 数据集专门为工业控制系统安全研究设计, 完整模拟了一个真实水处理厂的运行过程。数据集记录了长达 11 天的连续操作, 其中前 7 天为无干扰的正常运行数据, 后 4 天则注入了多种模拟真实攻击的异常场景数据。整个数据集包含 51 个传感器与执行器的监测变量, 涵盖了流量、压力、液位、阀门状态等多个关键物理量, 异常片段约占总体数据的 12.14%。该数据集以其真实性与挑战性著称, 异常类型多样且常与正常操作动态交织, 是评估模型在复杂物理系统中检测隐蔽攻击和故障能力的标准试金石。

SMD 数据集采集自某大型互联网公司生产环境中的 28 台服务器, 每台服务器通过 33 个不同的性能指标进行监控, 数据采样间隔为一分钟, 总计跨越 5 周时间。数据集被均匀划分为训练集与测试集, 其中约包含 4.16% 的异常数据。这些异常源于服务器各种软硬件故障, 如 CPU 过载、内存泄漏、磁盘故障等, 其模式兼具瞬时性、周期性和趋势性。SMD 数据集维度高、规模大, 且异常通常表现为多指标协同的复杂模式, 非常适合检验模型在高维、大规模时序数据中挖掘微妙关联异常的能力。

## 4.2. 对比方法与评价指标

### 4.2.1. 评价指标

为进行公平且全面的比较, 本研究选取了涵盖不同技术路线的七种代表性无监督异常检测方法作为基线。这包括基于密度的经典方法局部离群因子(LOF), 基于重构的深度学习自编码器(AE)及其结合时序建模的变体 LSTM-VAE, 基于深度生成模型的 DAGMM, 以及近年来表现突出的先进方法, 如采用对抗训练策略的 USAD, 融合随机建模的 OmniAnomaly, 和基于 Transformer 架构的 Anomaly Transformer。这些方法均在各自提出的文献中展现了优越性能, 覆盖了从传统机器学习到前沿深度学习的多种技术范式。

采用精确率(Precision)、召回率(Recall)、F1 分数(F1-Score)和受试者工作特征曲线下面积(Area Under the ROC Curve, AUC)四个指标进行综合评估。这些指标基于分类结果的混淆矩阵计算, 该矩阵定义了真正例(True Positive, TP)、假正例(False Positive, FP)、真反例(True Negative, TN)和假反例(False Negative, FN)。

精确率: 衡量被模型判定为异常的样本中, 真正是异常的比例, 反映了模型的误报控制能力。其计算公式为:

$$P = \frac{TP}{TP + FP} \quad (9)$$

召回率: 衡量所有真实的异常样本中, 被模型成功检测出的比例, 反映了模型的漏报控制能力。其计算公式为:

$$R = \frac{TP}{TP + FN} \quad (10)$$

F1 分数: 是精确率与召回率的调和平均数, 用于平衡二者, 是衡量模型整体检测精度的核心指标。单一的高精确率可能伴随低召回率, 反之亦然, 而 F1 分数提供了一个综合考量。其计算公式为:

$$F1 = 2 \cdot \frac{P \cdot R}{P + R} \quad (11)$$

ROC 曲线与 AUC: 受试者工作特征曲线描绘了当分类阈值变化时, 真正例率(True Positive Rate, TPR, 即召回率)与假正例率(False Positive Rate, FPR)之间的关系。AUC 即该曲线下的面积, 提供了一个与具体阈值选择无关的、对模型整体排序与区分能力的度量。一个完美的分类器 AUC 值为 1, 而随机猜测的 AUC 值为 0.5。AUC 值越接近 1, 表明模型区分正常与异常样本的能力越强。其中:

$$TPR = \frac{TP}{TP + FN}, FPR = \frac{FP}{FP + TN} \quad (12)$$

本研究将计算并报告所有对比方法的 AUC 值, 以从阈值鲁棒性的角度评估模型性能。这些指标共同构成了一个多维度的评估体系: 精确率和召回率从具体决策层面反映了模型的准确性, F1 分数给出了一个平衡的综合评价, 而 AUC 则从模型输出分数的整体分布质量层面提供了稳健的评估。

### 4.2.2. 实验对比

通过为每个模型搜索并确定能使其性能最大化的检测阈值, 我们获得了如表 1 所示的详细对比结果。综合分析表明, 本文提出的 TFDAM-LSTM-AdvAE 模型在两个数据集上均取得了最佳的综合性能。在 SWaT 数据集上, 我们的模型以 96.60%的精确率、85.10%的召回率、91.21%的 F1 分数和 93.61%的 AUC 值全面领先。在 SMD 数据集上, 模型同样表现出色, 获得了 95.86%的精确率、85.32%的召回率、90.28%的 F1 分数和 92.38%的 AUC 值, 其 F1 分数与 AUC 值在所有对比方法中位列第一。

传统方法 LOF 整体表现最差, 其高计算复杂度及仅关注局部密度差异的特性, 使其难以有效捕捉多元时间序列中复杂的全局异常模式。DAGMM 等早期深度生成模型虽有一定改进, 但同样未充分利用关键的时序信息。其他深度学习方法通过引入循环神经网络或变分推断等技术, 在建模时序依赖方面表现更佳, 但各自存在明显局限。例如, AE 与 LSTM-VAE 等基于重构的方法, 对与正常数据分布接近的微弱异常敏感性不足; USAD 虽引入了对抗训练思想, 但其目标函数相对单一; OmniAnomaly 与 TopoGDN 等模型融入了随机建模或图结构, 但在细粒度特征交互的捕捉上可能不够充分; Anomaly Transformer 凭借自注意力机制擅长捕获长程依赖, 但计算开销较大且对局部特征相关性的聚焦可能不足; GAD-NR [31] 虽在图数据异常检测中表现先进, 但其设计主要面向属性网络, 并未直接针对原始时序数据进行优化。

**Table 1.** Results of comparative experiments

**表 1.** 对比实验结果

Methods	SWaT				SMD			
	P	R	F1	AUC	P	R	F1	AUC
LOF	0.5616	0.6324	0.5969	0.6521	0.5585	0.3896	0.4590	0.5638
AE	0.7230	0.5889	0.6550	0.6841	0.7835	0.7026	0.7408	0.7218
LSTM-VAE	0.8460	0.6281	0.7591	0.7982	0.8156	0.7268	0.7686	0.5613
DAGMM	0.8592	0.5893	0.6991	0.6219	0.6621	0.4768	0.5398	0.5278
USAD	0.7915	0.8027	0.7941	0.8159	0.8234	0.8112	0.8195	0.8076
OmniAnomaly	0.8029	0.6920	0.7389	0.7675	0.8305	0.8166	0.8235	0.8276
TopoGDN	0.8793	0.7191	0.7911	0.8236	0.9157	0.8339	0.8992	0.8905
AnomalyTransformer	0.9212	0.8627	0.8914	0.9150	0.9086	0.8981	0.8966	0.9120
GAD-NR	0.8077	0.8420	0.8243	0.8275	0.8505	0.8766	0.8619	0.8446
TFDAM-LSTM-AdvAE	0.9660	0.8510	0.9121	0.9361	0.9586	0.8532	0.9028	0.9238
MS-Transformer-VAE	0.9345	0.8925	0.9314	0.9487	0.9352	0.8763	0.9152	0.9342

相比之下, 我们的 TFDAM-LSTM-AdvAE 模型成功集成了三项互补优势: 长短期记忆网络对时序动态的稳健建模、时序 - 特征双重注意力模块对细粒度跨维度关联关系的学习、以及对抗自编码器训练框架对异常信号的鲁棒性放大。这种集成式设计使模型能够同时有效捕获全局时序模式与局部特征偏离, 从而在面对多样化的异常类型时, 均能展现出卓越的检测性能。

## 5. 结语

本文围绕工业多维时间序列无监督异常检测与故障预警的核心需求, 针对现有方法在时空特征建模、微弱故障识别等方面的不足, 提出了一种基于双注意力 LSTM-AdvAE 的无监督异常检测与预警模型, 完成了从模型设计、理论推导到实验验证的完整研究工作。本文的核心贡献在于设计了 TFDAM 时序 - 特征双重注意力模块, 实现了特征维度与时间维度的协同加权, 有效解决了单一注意力难以兼顾关键特征与重要时间片段的问题; 构建了 LSTM 与改进 AdvAE 协同融合的架构, 通过 LSTM 捕捉时序长期依赖, 借助 AdvAE 的对抗训练放大异常信号, 结合合理的异常评分机制, 提升了模型对微弱故障的识别灵敏度与鲁棒性。

实验结果表明, 该模型在 SWaT、SMD 两个公开基准数据集上, 其精确率、召回率、F1 分数及 AUC 值均全面优于 LOF、AE、USAD 等主流对比方法, 能够有效捕捉工业设备运行中的异常特征, 实现故障

的早期预警, 验证了模型的有效性与优越性, 为工业设备智能运维提供了可靠的技术方案。

同时, 本文研究仍存在一定局限: 模型在处理超高维、强噪声的极端工业时序数据时, 计算效率仍有提升空间; 异常评分机制中  $\alpha$ 、 $\beta$  权重的自适应调整尚未实现, 需结合具体场景手动调试。未来研究将重点围绕这两方面展开, 优化模型结构以提升计算效率, 引入自适应算法实现权重参数的动态调整; 同时, 将模型拓展至更多工业场景, 结合迁移学习技术, 进一步提升模型的泛化能力, 推动无监督异常检测技术在工业智能诊断领域的深度应用。

## 致 谢

感谢老师和朋友。

## 参考文献

- [1] Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986) Learning Representations by Back-Propagating Errors. *Nature*, **323**, 533-536. <https://doi.org/10.1038/323533a0>
- [2] Goodfellow, I., Pouget-Abadie, J., Mirza, M., et al. (2014) Generative Adversarial Nets. *NIPS'14: Proceedings of the 28th International Conference on Neural Information Processing Systems*, Volume 2, 2672-2680.
- [3] Shi, Y., Lei, M., Ma, R. and Niu, L. (2019) Learning Robust Auto-Encoders with Regularizer for Linearity and Sparsity. *IEEE Access*, **7**, 17195-17206. <https://doi.org/10.1109/access.2019.2895884>
- [4] Zong, B., Song, Q., Min, M.R., et al. (2018) Deep Autoencoding Gaussian Mixture Model for Unsupervised Anomaly Detection. *International Conference on Learning Representations*, Vancouver, 30 April-3 May 2018.
- [5] Lin, S., Clark, R., Birke, R., Schonborn, S., Trigoni, N. and Roberts, S. (2020) Anomaly Detection for Time Series Using VAE-LSTM Hybrid Model. *2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Barcelona, 4-8 May 2020, 4322-4326. <https://doi.org/10.1109/icassp40776.2020.9053558>
- [6] Su, Y., Zhao, Y., Niu, C., Liu, R., Sun, W. and Pei, D. (2019) Robust Anomaly Detection for Multivariate Time Series through Stochastic Recurrent Neural Network. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, Anchorage, 4-8 August 2019, 2828-2837. <https://doi.org/10.1145/3292500.3330672>
- [7] Audibert, J., Michiardi, P., Guyard, F., Marti, S. and Zuluaga, M.A. (2020) USAD: Unsupervised Anomaly Detection on Multivariate Time Series. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 6-10 July 2020, 3395-3404. <https://doi.org/10.1145/3394486.3403392>
- [8] Khan, W., Mohd, A., Suaib, M., Ishrat, M., Shaikh, A.A. and Faisal, S.M. (2025) Residual-Enhanced Graph Convolutional Networks with Hypersphere Mapping for Anomaly Detection in Attributed Networks. *Data Science and Management*, **8**, 137-146. <https://doi.org/10.1016/j.dsm.2024.09.002>
- [9] Khan, W., Abidin, S., Arif, M., Ishrat, M., Haleem, M., Shaikh, A.A., et al. (2024) Anomalous Node Detection in Attributed Social Networks Using Dual Variational Autoencoder with Generative Adversarial Networks. *Data Science and Management*, **7**, 89-98. <https://doi.org/10.1016/j.dsm.2023.10.005>
- [10] Ergen, T. and Kozat, S.S. (2020) Unsupervised Anomaly Detection with LSTM Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, **31**, 3127-3141. <https://doi.org/10.1109/tnnls.2019.2935975>