

基于声发射信号的压力容器异常检测模型

谢遵强¹, 陈双叶², 刘明珠²

(1. 山东华鲁制药有限公司, 山东 聊城 252100;

2. 北京工业大学 信息科学技术学院, 北京 100124)

摘要: 传统压力容器的监测和异常检测方法在处理复杂声发射信号上存在精确度不高且耗时较长等问题; 为了解决这些问题, 提出了一种基于 CNN 和 LSTM 的自编码器模型 AENet; 该模型用 ResNet 结构替换了自编码器网络中的线性结构, 从而显著提高了异常检测的准确率和检测精度; 具体来说, 模型通过 CNN 提取声发射信号的局部空间特征, 结合 LSTM 捕捉时间序列的短期和长期依赖性, 实现对原始时域信号的重建, 并通过计算重建信号与输入信号之间的误差来判断异常信号的存在; 经实验测试, 在检测压力容器泄漏时, 该模型的准确率达到 93.58%; 与传统自编码器、变分自编码器及其他基于深度学习的自编码器模型相比, AENet 在捕捉复杂时间序列信号特征方面更具优势, 显著减少了误报和漏报现象; 这为压力容器的安全监控提供了可靠保障, 满足了工业工程应用中的实际需求。

关键词: 声发射; 异常检测; CNN; LSTM; 自编码器; ResNet

Anomaly Detection Model for Pressure Vessels Based on
Acoustic Emission SignalsXIE Zunqiang¹, CHEN Shuangye², LIU Mingzhu²

(1. Shandong Hualu Pharmaceutical Co., Ltd., Liaocheng 252100, China;

2. School of Information Science and Technology, Beijing University of Technology, Beijing 100124, China)

Abstract: Conventional monitoring and anomaly detection methods for pressure vessels have the characteristics of poor accuracy and time-consuming processing for complex acoustic emission signals. In order to solve these problems, a self-encoder model AENet based on convolutional neural network (CNN) and long short-term memory (LSTM) is proposed, which replaces the linear structure in the self-encoder network with a ResNet structure, thus significantly improving the accuracy and detection precision of anomaly detection. Specifically, the model extracts the local spatial features of acoustic emission signals through the CNN, combines with the LSTM to capture the short-term and long-term dependencies of time series, reconstructs original time-domain signals, and determines the existence of anomalous signals by calculating the error between the reconstructed signals and the input signals. After experimental testing, the model achieves an accuracy of 93.58% in detecting pressure vessel leakage. The AENet has notable advantages over the traditional self-encoders, variational self-encoders and other deep learning-based self-encoder models in capturing the features of complex time-series signals, which significantly reduces the phenomena of false and missed alarms. This provides a reliable guarantee for the safety monitoring of pressure vessels and meets the practical needs in industrial engineering applications.

Keywords: acoustic emission; anomaly detection; CNN; LSTM; auto encoder; ResNet

0 引言

随着社会经济的发展 and 科技的进步, 压力容器已成为各行各业中不可或缺的基础设备, 尤其在煤化工、石

油化工、电力、能源等行业以及军工科研领域扮演着至关重要的角色。然而, 作为一种高危设备, 压力容器存在较大的安全隐患, 一旦发生事故, 不仅会对生产造成严重影响, 还可能引发环境污染、火灾等次生灾害, 甚

收稿日期: 2024-10-25; 修回日期: 2024-12-13。

作者简介: 谢遵强(1971-), 男, 大学本科, 工程师。

通讯作者: 刘明珠(2000-), 女, 硕士研究生。

引用格式: 谢遵强, 陈双叶, 刘明珠. 基于声发射信号的压力容器异常检测模型[J]. 计算机测量与控制, 2025, 33(11): 118-123, 141.

至危及人员生命安全。压力容器的安全使用不仅关乎生产运营, 还影响着经济效益、环境保护和社会稳定, 对其状态的实时监控和健康预警已成为亟待解决的问题。现有的压力容器监控方法多依赖于定期检查和传统传感器技术, 但这些方法存在明显不足, 如定期检查难以实现持续监控, 容易错过潜在风险; 传统传感器的监测精度和范围有限, 且在复杂工况下表现不佳, 难以有效应对突发状况^[1-2]。

近年来, 异常检测研究在工业、医疗和网络安全等领域取得了显著进展, 特别是在复杂时间序列数据的分析方面。自编码器 (AE, autoencoder) 通过重建误差进行异常检测, 文献 [3] 提出的 Chronos 系统利用自编码器, 同时利用时间特征有效检测分布式拒绝服务 (DDoS, distributed denial of service) 攻击, 但是该系统更适合用于简单的异常检测行为中。LSTM 自编码器 (LSTM-AE) 由于能够捕捉时间依赖性, 被广泛应用于多变量时序数据的检测, 文献 [4] 使用 LSTM-AE 成功识别高压变压器的异常情况, 所提出的方法也可以用于在先前确定的变化的新常态测量上重新训练。文献 [5] 利用变分自编码器 (VAE, variational autoencoder), 通过概率建模处理数据分布的不确定性, 在 IoT 入侵检测和工业控制系统中展示了良好性能。文献 [6] 结合 CNN 和 LSTM 的混合模型, 如时间卷积网络自编码器 (TCN-AE), 在心电图异常检测中表现突出。此外, 文献 [7] 和文献 [8] 开发了用于结构健康监测和流式数据处理的先进检测方法。文献 [9] 和文献 [10] 展示了 LSTM-AE 在医疗数据分析和 SCADA 警报检测中的应用潜力。同时, 文献 [11] 提出的轻量级 LSTM-VAE 架构在工业控制系统中的水处理应用中取得了显著效果。

1 声发射技术

声发射 (AE, acoustic emission) 技术因其高灵敏度和对大面积结构进行连续监测的能力, 在结构健康监测 (SHM, structural health monitoring) 领域得到了广泛应用^[12], 尤其在裂纹萌生和扩展的监测方面表现出色。文献 [13] 的研究表明声发射技术通过监测由于材料变形或开裂而释放的瞬时弹性波, 能够直接捕捉到设备内部缺陷的动态变化信息, 区别于依赖外部激励的传统检测方法, 具有动态实时检测的优势, 也说明虽然声发射技术采集系统的进步可以确保实时观察到材料的状况, 但是定量声发射分析对于实际应用仍有困难。此外, 文献 [14] 表明声发射技术可以快速定位缺陷位置, 并对大范围结构进行全面评估, 显著提升在役设备的运行安全性和监测效率, 具有良好的经济效益。

文献 [15] 中将声发射技术应用于复合材料冲击损

伤诊断中, 将通过复合材料上的压电传感器在低速撞击下收集的声发射信号用于训练深度学习网络, 模型预测精度较高。文献 [16] 通过拉深件的微裂纹实验, 提取正常状态与裂纹状态之间的声发射信号, 通过遗传算法进行优化, 解决了声发射信号特征参数的提取和优化问题。

与传统的无损检测技术相比, 声发射技术以其动态实时监测的特性脱颖而出。这种技术能够持续追踪并捕捉材料或结构中缺陷的动态变化, 提供实时数据, 从而揭示缺陷在不同负载和环境条件下的行为模式。相比之下, 其他无损检测方法往往只能提供某一时刻的静态快照, 无法展现缺陷随时间的演变过程。声发射检测不仅在技术上更为先进, 而且在实际应用中也显示出了明显的优势。它的检测周期较短, 这意味着可以在较短的时间内完成对结构的全面检查, 从而加快工程进度。同时, 由于其高效的检测流程, 声发射技术在成本控制方面也表现出色, 相较于其他方法, 它能够以更低的投入实现同等甚至更优的检测效果, 这无疑为企业和项目带来了显著的经济效益。

本文提出了一种用于检测压力容器中的声发射异常信号的自编码器模型 AENet, 并通过模型训练和消融实验来验证模型的可靠度与准确性, 取得了良好的结果。

2 深度学习技术

深度学习技术在近些年迅速发展, 并在各种复杂任务中展现出了优越的性能。作为其中的重要组成部分, 卷积神经网络 (CNN, convolutional neural network)^[17] 和长短期记忆网络 (LSTM, long short-term memory)^[18] 已成为解决图像处理和序列数据分析问题的主流方法。它们通过深层次的特征提取与时序信息的记忆机制, 能够在分类、预测等任务中取得良好的效果。下面将分别介绍 CNN 和 LSTM 的基本原理及其结构特点。

2.1 CNN

CNN 是一种具有层次化结构的深度学习模型^[19], 其核心在于通过卷积操作来提取输入数据的特征。CNN 通常由卷积层、池化层和全连接层组成。卷积层通过卷积核在输入数据上进行滑动操作, 从局部区域提取特征, 并通过共享权重的方式减少参数数量, 从而提高计算效率。池化层则用于下采样特征图, 降低数据的维度和模型的复杂度, 同时增强模型的平移不变性。全连接层则将高阶特征映射为输出结果, 实现分类或回归任务。

数学上卷积操作可以表示为:

$$Y_{i,j} = \sum_{m,n} X_i + m \cdot j + n \cdot W_{m,n} + b \quad (1)$$

其中: X 为输入数据, W 为卷积核, b 为偏置项, Y 为卷积结构。激活函数通常应用于卷积结果, 以增加非线性建模能力。

2.2 LSTM

LSTM 属于循环神经网络 (RNN, recurrent neural network) 的一种^[20], 它继承了 RNN 的核心优势。LSTM 引入了遗忘机制, 该机制能够保留对数据至关重要的信息, 并有选择地遗忘那些无关紧要的信息。这种设计有效地克服了传统神经网络在处理长序列时面临的依赖问题, 并有效改善了梯度消失的现象。

LSTM 的基本结构如图 1 所示, 它由遗忘门、输入门和输出门组成。各门所涉及到的公式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \hat{C}_t \quad (5)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (7)$$

σ 为 Sigmoid 激活函数, $\tanh$ 为 $\tanh$ 激活函数, C_{t-1} 与 h_{t-1} 通过遗忘门 f_t 、输入门 i_t 和输出门 O_t 后, 得到了 t 时刻的单位状态 C_t 和单元输出 h_t , C_{t-1} 与 h_{t-1} 分别对应了上一时刻单元状态和上一时刻单元输出。




图 1 LSTM 网络结构图

3 声发射数据采集与处理

AE 声发射传感器的核心元件采用压电陶瓷片, 压电材料受到机械振动时会产生电荷, 从而将机械振动转换为电信号。压电陶瓷传感器输出的信号非常微弱, 且内阻很大, 信号传输时极易受到电磁信号干扰引入噪声, 需要加入前置放大电路。为了消除共模干扰, 前置放大电路将压电陶瓷传感器的输出信号进行放大和阻抗变换, 以差分信号的形式输出。

声发射传感器将结构产生的应力波转换成电信号, 接入到高速数据采集卡进行信号采集, 高速信号采集卡的结构如图 3 所示。




图 2 压电陶瓷传感器前置放大电路




图 3 高速声发射信号采集卡

转换器, FPGA, ARM 嵌入式处理器和千兆以太网接口组成。信号采集频率可设置为 20, 40, 65, 80 MSPS, ARM 嵌入式处理对采集到的原始声发射信号进行实时处理, 提取声发射信号的特征参数, 通过千兆网将信号原始数据与特征数据发送到计算机。

选用谐振频率为 150 kHz 的声发射传感器, 采样率为 2.5 MHz 的高速数据采集装置, 采集装置通过千兆网络和计算机连接, 采集到的数据经与处理后送到 AENet 模型进行训练、识别。

在压力容器正常到加压的条件中连续采集声发射信号, 对每一帧信号处理, 记录下信号的原始波形图和经过傅里叶快速变换 (FFT) 后的频谱图, 图 4 是经过预处理后的某帧信号的幅值图和频谱图。一共采集了 55 596 帧数据, 将每一帧的幅值图和频谱图作为原始的数据集。




图 4 预处理后的某帧信号的幅值图和频谱图

高速采集卡实现声发射信号的高速采集, 由高速 AD

观察图 4 可以发现, 正常信号的幅值波动范围较小, 是以 mV 为数量级单位波动的, 并且主频在 60~80 kHz 之间。

4 网络结构

在本文中, 提出了一种用于异常检测的 AENet 模型。该模型采用自编码器作为主要的网络框架, 编码器和解码器通过残差结构进行堆叠。整体结构如图 5 所示。自编码器由编码器 (Encoder) 和解码器 (Decoder) 两部分组成。编码器负责将输入数据压缩成低维潜在空间表示, 而解码器则从这个潜在空间重建输入数据。这种结构使得模型能够学习到输入数据的高效特征表示。编码器和解码器通过残差结构 (ResNet) 进行堆叠, 它通过添加直接连接 (shortcut connections) 来解决深层网络训练中的梯度消失和梯度爆炸问题, 有助于提高模型的训练效率和重建质量。




图 5 整体结构图

4.1 编码器与解码器

与传统的自编码器模型相比较, 本文提出的 AENet 模型用 ResNet 结构^[21]替换了 AE 网络中的线性结构, 并在编码器和解码器中引入了多尺度卷积。编码器和解码器由多个 ResNet 模块堆叠而成, 且每个模块通过串联的多尺度卷积层构成, 以提取不同尺度的特征。AENet 网络由 4 个编码器和 3 个解码器组成。每个编码器包含多尺度 CNN 模块 (由 1×1 、 3×1 和 5×1 的一维卷积核串联构成)、LSTM 层、ReLU 激活函数和下采样层等。编码器模块的结构如图 6 所示。输入网络的每个子序列的形状为 100×1 , 4 个编码器逐层提取特征后, 特征空间分别为 64×1 、 32×1 、 16×1 和 8×1 。解码器的结构与编码器相反, 如图所示, 由上采样层、多尺度 CNN 模块 (同样由 1×1 、 3×1 和 5×1 的一维卷积核串联)、LSTM 层组成, 并使用 ReLU 作为激活函数。解码器将 8×1 的特征空间依次重建为 16×1 、 32×1 和 64×1 , 最后由输出层输出 100×1 的重建信号。在解码过程中, 每个解码器在接收上一层输入的同时, 结合对应编码器的输出特征进行联合学习。多尺度卷积的引入能够增强网络的特征提取能力, 帮助模型更好地重建原始信号, 加快收敛速度, 并有效缓解梯度消失问题。




图 6 编码器与解码器网络结构图

4.2 训练过程

模型训练过程分为两个阶段：前向传播和反向传播。在训练阶段, 将大量正常的声发射信号数据输入到编码器中, 模型通过多层 CNN 提取信号的空间特征, 并通过 LSTM 捕捉时间序列中的短期和长期依赖性。在编码器的每一层中, 通过逐步下采样, 信号的维度被压缩, 并提取更具代表性的特征。这些特征经过编码器后, 被传递到解码器进行重建。

解码器结构与编码器相反, 通过多尺度的上采样层逐步恢复信号的维度, 重新生成与原始输入信号一致的形状。解码器通过卷积层和 LSTM 层进一步处理, 从低维特征恢复出完整的时序信号。在每一次前向传播过程中, 解码器重建的信号会与原始输入信号进行对比, 通过计算重建信号与原始信号之间的重建误差来衡量模型的性能。

反向传播阶段, 使用均方误差 (MSE) 作为损失函数。模型通过梯度下降算法对网络中的权重进行优化, 逐步减小重建误差。损失函数的计算公式为:

$$L = \frac{1}{n} \sum_{i=1}^n (X_i - \tilde{X}_i)^2 \quad (8)$$

其中: X_i 是原始输入信号, $\tilde{X}_i$ 是解码器重建后的信号。训练过程的目标是最小化重建误差, 从而使模型能够在输入正常信号时精确地重建信号。

通过迭代更新模型参数, 模型逐渐学习到正常信号的分布特征。当训练达到预定的停止条件或损失函数不再显著下降时, 训练过程结束。此时, 模型的参数被固定, 并用于后续的异常检测任务。训练完成后, 模型的重建误差会保持较低值, 对于输入的测试数据, 当重建误差超过设定的阈值时, 信号将被标记为异常。

4.3 异常判定

在训练阶段结束时, 网络模型的权重和偏置已确定。这时, 神经网络的每一层节点可以被视为输入信号在不同特征空间中的表达。由于训练过程使用的是正常

信号数据,模型只能提取正常信号的特征。在特征空间中,异常的映射会被扭曲,导致冗余和信息丢失。异常的特征在卷积网络中被扭曲,无法映射到特征空间,也无法通过自动编码器进行重构。网络对异常的重构效果较差。因此,是否存在异常可以通过网络模型对待测数据的重构效果来判断,这里可以通过重构数据与原始数据之间的距离来评估重构效果。我们选择均方误差(MSE)作为最终的异常判定标准。MSE 对大误差非常敏感,可以放大异常信号与正常信号之间的差异,便于更准确地检测异常。假设输入样本数据为 $X = \{x_1, x_2, \dots, x_n\}$, 神经网络的重构输出为 $Y = \{y_1, y_2, \dots, y_n\}$, 重构误差可以表示为均方误差:

$$\text{error} = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \quad (9)$$

神经网络模型对异常信号和正常信号的重构误差差异较大。异常信号的误差通常较大,而正常信号的误差应接近于 0。基于这一特性,可以合理地设置阈值 T 作为决策阈值,而阈值选择为训练集的均值加 2 倍标准差,决策过程如下:

$$\text{result} = \begin{cases} 0, \text{error} < T \\ 1, \text{error} > T \end{cases} \quad (10)$$

为了确定异常检测阈值,我们计算的 error 遵循伽马分布。根据 error 的直方图估算伽马分布的参数,并将异常检测阈值 T 确定为伽马分布的第 90 个百分位数。如果每个测试片段的 error 大于该阈值,则判定该片段异常;如果小于该阈值,则判定该片段正常,即在公式(10)公式中,“0”表示样本为正常信号,“1”表示样本为异常信号。

5 实验结果与分析

5.1 数据集准备

在上文提到,原始数据集中包含 55 596 张图片,按照训练集、测试集的比例为 8 : 2 来划分。

5.2 实验环境

实验环境是 64 位的 Windows Server 2019 系统,配备了 90 GB 的 RAM, 12 vCPU Intel (R) Xeon (R) Platinum 8352V CPU @ 2.10 GHz 的 CPU 处理器以及一块 RTX 4090 (24 GB) 以加速图像处理。网络基于 Pytorch (GPU) 框架构建,并使用随机梯度下降 (SGD) 优化器进行优化。不同的网络模型在相同的数据集上训练,并使用相同的参数。测试数据集通过在验证集中损失最小的权重进行评估。

为了确保参数能够快速更新并收敛于全局最优,每 10 个时期将学习率乘以 0.95。初始学习率一般从较小的数值开始,随着训练的进行逐渐增加到预定的学习率,这有助于模型在初期稳定下来,初始学习率设为 0.01,在我们的私人数据集上使用这一初始学习率。

SGD 优化器每次训练和梯度更新后学习率的衰减值设为 $1e-4$ 。动量设为 0.9,用以减缓振荡程度并加速梯度下降的收敛,训练周期为 600,训练批量大小为 32。

5.3 评价指标

在本实验中,我们选取 ACC、Precision、Recall、 F_1 作为模型的评价指标。其中 ACC 为模型预测正确的样本数占总样本数的比例。Precision 为模型预测为正类的样本中,实际为正类的比例。Recall 为实际为正类的样本中,模型正确预测为正类的比例。 F_1 同时考虑了模型的精确率 (Precision) 和召回率 (Recall),是精确率和召回率的调和平均数。 F_1 分数的值越高,表示模型的性能越好:

$$\text{ACC} = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (12)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (13)$$

$$F_1 \text{ score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (14)$$

TP (真阳性) 表示实际为正类且预测正确的样本数; TN (真阴性) 表示实际为负类且预测正确的样本数; FP (假阳性) 表示实际为负类但错误预测为正类的样本数; FN (假阴性) 表示实际为正类但错误预测为负类的样本数。

5.4 消融实验

本实验中,选取 CNN-AE、LSTM-AE、S-AENet 与本文提出的 AENet 进行消融实验。消融实验中的 S-AENet 模型将 AENet 中的多尺度卷积替换为单一尺度卷积,保持其他部分不变。

表 1 消融实验结果 %

算法	ACC	Pre	Rec	F_1
CNN-AE	89.78	87.60	88.99	88.78
LSTM-AE	88.44	89.45	87.82	88.63
S-AENet	91.68	90.66	86.65	88.61
AENet	93.58	93.73	87.32	90.42

实验结果表明 AENet 在各项指标上表现最为优异,其准确率达到 93.58%,精确率为 93.73%,召回率为 87.32%, F_1 分数为 90.42%。这表明多尺度卷积与 LSTM 的结合能够有效捕捉复杂信号的多种特征,提高异常检测的精度和鲁棒性。相比之下,S-AENet 的准确率为 91.68%,略低于 AENet,这说明单一尺度卷积难以全面捕捉多种频率成分,导致性能有所下降。

CNN-AE 的表现略逊于 S-AENet,其准确率为 89.78%,这表明虽然卷积神经网络能够有效提取局部特征,但缺乏对时间序列的建模能力,限制了其在复杂

信号处理中的应用。LSTM-AE 的准确率为 88.44%，低于 CNN-AE 和 S-AENet，说明仅使用 LSTM 进行时间序列建模时，无法充分提取信号的空间特征。

总体来看，消融实验的结果清晰地表明，AENet 中的多尺度卷积和 LSTM 对性能提升起到了关键作用。多尺度卷积的引入使模型能够更好地提取信号中的多种特征，而 LSTM 则增强了对时间依赖性的建模能力。通过多尺度卷积与时间序列建模的结合，AENet 能够实现更高的检测精度和更强的鲁棒性，为压力容器的声发射信号检测提供了一种可靠的解决方案。

5.5 对比试验

对比实验将 AENet 与 LSTM-GAN、VAE 和传统自编码器 (AE) 进行性能比较。

表 2 对比实验结果

算法	ACC	Pre	Rec	F_1
AE	84.52	85.97	85.22	85.59
VAE	86.73	86.91	88.22	87.56
LSTM-GAN	91.29	89.68	88.69	89.18
AENet	93.58	93.73	87.32	90.42

实验结果表明，与 AENet 相比，LSTM-GAN 的各项指标次之，其准确率为 91.29%， F_1 分数为 89.18%。尽管 LSTM-GAN 在处理复杂信号时展现了一定的重建能力，但由于依赖生成对抗网络的结构，其在捕捉声发射信号的时间依赖性和特征提取上略显不足。

VAE 的检测性能明显低于 AENet 和 LSTM-GAN，其准确率为 86.73%， F_1 分数为 87.56%。虽然 VAE 能够通过概率建模处理信号的不确定性，但在应对高度非线性和噪声干扰较大的声发射信号时表现欠佳。传统自编码器 (AE) 的检测性能最差，准确率仅为 84.52%， F_1 分数为 85.59%，这表明其在提取复杂工业信号特征时能力有限，难以应对多样化的异常情况。

对比实验的结果表明，AENet 在检测精度和鲁棒性方面明显优于其他对比模型。AENet 结合了多尺度卷积和 LSTM 的优势，能够更好地提取信号的时空特征，尤其在处理声发射信号的复杂性和多样性时表现出色。这使得 AENet 在压力容器的安全监测和异常检测中具有显著的应用价值，能够为工业设备的实时监控提供更高效的解决方案。

6 结束语

本文提出的 AENet 在压力容器异常检测任务中显示出优越性能，为设备安全监测提供了一种高效的解决方案。然而，随着设备运行工况的复杂化，信号的非线性和噪声干扰问题仍需进一步解决，未来工作可以考虑

结合多模态数据融合方法来增强模型的检测精度和适应性。此外，模型在实际应用中的计算效率和实时性也需要进一步优化，以满足更多工业场景的需求。尽管如此，该方法在提高异常检测精度和减少维护成本方面展现了广阔的应用前景。

参考文献：

[1] GHADARAH N, AYRE D. A review on applications of acoustic emission in structural health monitoring of polymer matrix composites [J]. Journal of Nondestructive Evaluation, 2023, 42 (2): 111–129.

[2] NAIRACAI C, Acoustic emission monitoring of bridges: review and case studies [J]. Engineering Structures, 2010, 32 (6): 1704–1714.

[3] SALAHUDDIN M A, YANG K, KHALID O. Chronos: DDoS attack detection using time-based autoencoder [J]. IEEE Internet of Things Journal, 2020, 7 (12): 11455–11462.

[4] MITICHE I, MCGRIL T, BOREHAM P, et al. Data-driven anomaly detection in high-voltage transformer bushings with LSTM auto-encoder [J]. Sensors, 2021, 21 (21): 7426.

[5] KHANAM F, LAHASAN B, THILL C. A hybrid variational autoencoder and deep neural network for IoT intrusion detection [J]. Sensors, 2022, 22 (8): 2886.

[6] THILL C, ALOUL F, AL-ALI A R. Temporal convolutional network autoencoder for cardiac anomaly detection [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32 (2): 473–484.

[7] NGUYEN L H, GOULET J A. Anomaly detection with the switching Kalman filter for structural health monitoring [J]. Structural Control and Health Monitoring, 2018, 25 (1): e2136.

[8] ZHANG M, GUO J, LI X, et al. Data-driven anomaly detection approach for time-series streaming data [J]. Sensors, 2020, 20 (20): 5646.

[9] RAZAQUE A, ABENOVA M, ALOTAIBI M, et al. Anomaly detection paradigm for multivariate time series data mining for healthcare [J]. Applied Sciences, 2022, 12 (18): 8902.

[10] ANDRADE J R, ROCHA C, SILVA R, et al. Data-driven anomaly detection and event log profiling of SCADA alarms [J]. IEEE Access, 2022, 10: 73758–73773.

[11] NASER D, KIRCHBUCHNER F, KUIJPER A. Lightweight LSTM-VAE for multivariate time series anomaly detection in industrial control systems [J]. Sensors, 2022, 22 (8): 2886.

(下转第 141 页)