

DOI: 10.19650/j.cnki.cjsi.J2513998

基于 PPIR-CBAM-VAE 的阻抗法不均衡数据 玻璃窗胶条失效诊断方法研究^{*}

尤增颖¹, 郭碧涵¹, 朱海勇², 周玉勤², 徐佳文¹

(1. 东南大学仪器科学与工程学院 南京 210096; 2. 江苏润仪仪表有限公司 淮安 211699)

摘 要: 玻璃窗胶条长时间使用会发生老化, 破坏结构的密封性, 带来安全隐患。这类损伤具有高度隐蔽性, 采用传统的人工检查手段不能及时发现问题, 并导致健康-故障数据不平衡。针对这一问题, 提出了一种将压电阻抗技术与 Transformer 深度学习模型结合的非侵入式故障诊断方法。针对实际应用中故障样本稀缺与数据分布不平衡的核心挑战, 创新性地提出了一种基于卷积注意力机制和变分自编码器的数据增强生成模型, 通过学习真实故障数据分布生成新样本以扩充数据集并提升 Transformer 模型的泛化能力。为进一步优化生成数据质量, 提升诊断准确性, 引入 PPIR 技术, 将其与 CBAM-VAE 结合形成 PPIR-CBAM-VAE 协同优化方法。PPIR 技术通过精确保留关键谐振峰特征、剔除非峰值点, 并利用线性插值修复非峰值区域来生成样本, 在丰富样本多样性的同时显著提升数据集稳定性。实验结果表明, PPIR-CBAM-VAE 方法在极具挑战性的健康-故障样本不平衡比达 20:3 的条件下, 诊断准确率达到 92.13%; 在不平衡比为 4:1 的条件下, 诊断准确率从基础方法的 92.27% 显著提升至 96.45%, 极大优化了模型对少数类故障样本的识别性能。该研究系统构建了融合压电阻抗技术、Transformer 模型及创新性 PPIR-CBAM-VAE 数据增强的故障诊断框架, 为建筑密封系统健康监测提供了高灵敏性、高适用性的新解决方案。

关键词: 玻璃窗胶条; 压电阻抗技术; 数据增强; 变分自编码器; Transformer 模型; 故障诊断

中图分类号: TH703 **文献标识码:** A **国家标准学科分类代码:** 560.35

Impedance-based failure window seal strips failure diagnosis with imbalanced data using PPIR-CBAM-VAE model

You Zengying¹, Wu Bihan¹, Zhu Haiyong², Zhou Yuqin², Xu Jiawen¹

(1. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China;

2. Jiangsu Runyi Instruments Co., Ltd., Huaian 211699, China)

Abstract: The adhesive strip of a glass window tends to age over long-term use, undermining the sealing integrity of the structure and posing safety risks. Such damage is often highly concealed, and traditional manual inspections fail to detect it in time, leading to an imbalanced distribution of healthy and faulty data. To address this issue, this study proposes a nonintrusive fault diagnosis method that integrates piezoelectric impedance technology with a Transformer-based deep learning model. To tackle the core challenges of scarce fault samples and imbalanced data distributions in practical applications, we innovatively propose a data augmentation model—CBAMVAE, which combines a convolutional block attention mechanism with a variational autoencoder. By learning the distribution of real fault data, the model generates synthetic samples to expand the dataset and enhance the Transformer's generalization capability. Furthermore, to improve the quality of generated data and increase diagnostic accuracy, we incorporate the PPIR technique, combining it with CBAM-VAE to form the PPIR-CBAM-VAE collaborative optimization method. PPIR retains critical resonance peak features, removes nonpeak points, and applies linear interpolation to restore nonpeak regions, thereby enriching samples diversity while significantly enhancing dataset stability. Experimental results show that under a highly challenging healthy-to-fault ratio of 20:3, the PPIRCBAMVAE method achieves a diagnostic accuracy of 92.13%. When the imbalance ratio is 4:1, the accuracy improves markedly from 92.27% (baseline) to 96.45%, greatly boosting the recognition of minority-class faults samples. This study establishes a systematic fault diagnosis framework

收稿日期: 2025-04-30 Received Date: 2025-04-30

^{*} 基金项目: 国家自然科学基金(52275093)项目资助

that integrates EMI technology, a Transformer model, and the innovative PPIRCBAMVAE data augmentation method, providing a highly sensitive and broadly applicable solution for health monitoring of building sealing systems.

Keywords: window seal strips; piezoelectric impedance; data augmentation; variational autoencoder; Transformer; fault diagnosis

0 引言

在现代建筑中,胶条是玻璃和窗户的密封材料,其以优异的弹性和耐候性,逐渐取代了传统刚性连接。但是,随着使用时间的延长,胶条在受紫外线、臭氧和温湿循环等环境因素的作用下,出现硬化、脆裂和剥离等失效情况,导致密封性能下降,严重时候可能导致玻璃灾难性脱落^[1-5]。

因此,对玻璃窗的胶条健康状态的实时监测与早期损伤识别,对于提升建筑安全性至关重要。结构健康监测(structural health monitoring, SHM)作为一种先进的监测方法,能够在结构早期遭遇损伤时候,提供有效的识别与预警支持^[6]。常见的故障诊断方法主要包括:超声波检测^[7]、时间反转方法^[8]、振动响应方法^[9]以及压电阻抗方法(electromechanical impedance, EMI)^[10]。其中,EMI方法利用压电材料的机电耦合特性来评估损伤状态^[11-12],通过电阻抗谱反映整体结构的损伤情况,该方法不仅具有数据采集过程简便、操作灵活、灵敏度高、成本低等优势^[13],而且能够通过电学测量手段间接反映结构的机械状态变化,从而实现高效、全面的健康状态评估与监控^[14]。

近年来,神经网络模型因其强大的模式识别能力与数据驱动特性,具备了高效处理和分析复杂的结构健康监测数据的能力,广泛应用于故障诊断和损伤检测^[15-17]。Zhang等^[18]基于EMI方法引入自适应电感分流电路和一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)模型,通过调节分流电路的电感值,丰富压电阻抗信号的数据集,实现了基于大数据的多种结构故障的精准分类与识别。Yang等^[19]的研究发现,外部轴向拉力能够影响压电阻抗信号,他们利用基于径向基函数的人工神经网络成功缓解了这一影响。Na等^[20]则结合概率神经网络与压电阻抗法用来解决结构被腐蚀和管道壁厚变薄对机械强度的影响,他们提出的方法在检测准确度高同时成本低廉。

然而在众多实际应用场景中,使用神经网络的方法时,医学诊断^[21]、欺诈检测^[22]和故障监测^[23]等任务中类别不平衡问题经常出现。在类别不平衡问题中,少数类样本的数量远远少于多数类样本,容易导致深度学习模型更偏向于学习多数类,忽略了少数类。为了应对这一问题,研究者们提出了多种改进策略,主要包括数据层面的增强技术和模型层面的优化策略,旨在不平衡

数据条件下依然获得可靠且精准的识别性能。在数据层面,Hussein等^[24]对合成少数类过采样技术(synthetic minority over sampling technique, SMOTE)进行了改进,提出通过基于与原始少数类样本的距离来调整新样本的位置,从而直接将样本直接扩充至平衡状态,在数据高度不平衡的情况下,这一方法显著提高了模型的泛化能力。Chen等^[25]结合不平衡数据采样方法(adaptive synthetic, ADASYN)和贝叶斯优化自适应扩充数据集,并且提出了AB-轻量梯度提升机(AB-light gradient boosting machine, AB-LightGBM)入侵检测框架,有效缓解了数据不平衡问题。在算法层面,Pei等^[26]探讨了代价敏感学习在遗传编程中的应用,以改善在高维不平衡分类问题中的表现。Pan等^[27]基于迁移学习提出了一种非平衡强台风形成预报框架,该框架融合了大气、海面和海洋水文变量,并利用预学习模型获取先验知识。此外,变分自编码器^[28](variational autoencoder, VAE)和生成对抗网络^[29](generative adversarial networks, GAN)等深度学习模型也被广泛应用于少数类样本扩充任务,VAE模型通过学习原始数据专注于生成样本的分布一致性,GAN模型则通过对抗判别机制生成高质量的样本,以改善数据的不平衡问题。

在实际的结构健康监测应用中,传感器的部署常常受到工程环境的诸多限制。一方面,工程结构损伤事件发生概率较低,因为安全问题不能人为诱导;另一方面,传感器成本较为昂贵并且对环境适应性要求严苛,使得大规模的部署较为困难。此外,信号的收集依赖专业人士进行人工标注,进一步加大了高质量故障数据的获取难度和成本,导致少数类样本也就是异常样本严重缺乏,进而影响分类器模型的泛化性能力。

此外,现有的数据增强方法仍然存在一些不足。由于训练样本数量有限,GAN还易陷入模式崩溃(mode collapse)现象^[30],进一步限制了其在小样本不平衡数据增强中的应用效果。值得注意的是,Zhang等^[18]的研究中至少使用了3 000个样本,这在实际工程结构故障数据收集集中可能不切实际。但是,VAE在数据有限的情况下,仍能表现良好,生成效果更加稳定且可控。然而,传统架构使用多层感知器(multilayer perceptron, MLP)作为编码器和解码器^[28],无法完全捕捉数据分布中的细节信息,导致生成的样本模糊^[31]。Giorgiuti等^[32]分析阻抗数据的实部以判别损伤,发现阻抗谱中的关键挑战在于不仅要学习受损信号的显著差异,还要学习细微差异。这都加剧了阻抗数据特征识别的复杂性困难。在传统的

多层感知器的编码器结构中,可能会忽略阻抗数据的细微特征,这一情况导致潜在空间的表示不足,生成的样本无法准确捕捉真实数据中的细微变化,进一步加剧故障识别的难度。

为了解决上述问题,本研究结合了卷积块注意力模块(convolutional block attention module, CBAM)与变分自编码器 VAE 的优势,提出了一种 CBAM-VAE 模型,旨在增强生成模型对复杂数据特征的识别能力。该设计有效地捕捉了阻抗数据中的全局与局部关键特征,抑制了在学习生成新数据时产生的噪声对特征学习的干扰,减少了生成数据的模糊性,从而提升了分类器模型的泛化能力。此外,为进一步优化数据增强效果,提出基于 CBAM-VAE 的峰值特征保留与插值修复(peak preservation and interpolation repair, PPIR) PPIR-CBAM-VAE 的方法,通过优化 CBAM-VAE 生成数据,增强信号的多样性与稳定性。

1 理论分析

1.1 基于压电阻抗法的玻璃窗胶条失效数据采集

1) 基于有限元法的压电阻抗动力学方程求解研究

如图 1 所示,一个被测结构上面附着两个铅锆钛酸盐(lead zirconate titanate, PZT)压电传感器,PZT1 和 PZT2。PZT1 通过施加激励电压产生微小机械振动,振动在结构中传播,以检测结构的变化。PZT2 则负责接收这些机械振动变化并将其转换为输出电压,用于评估结构的健康状态,识别潜在的损伤。将电感并联到 PZT2 的两端,并采集电感两端的输出电压作为响应信号。




图 1 双 PZT 的压电阻抗测量结构

Fig. 1 Piezoelectric impedance measurement structure with double PZT

假设测量装置内阻为无限大,该结构有限元形式的动力学方程可表示为式(1)~(3)。

$$\mathbf{M}\ddot{\mathbf{q}} + \mathbf{C}\dot{\mathbf{q}} + \mathbf{K}\mathbf{q} + \mathbf{k}_1 Q_1 + \mathbf{k}_2 Q_2 = 0 \quad (1)$$

$$\frac{1}{C_{p1}} Q_1 + \mathbf{k}_1^T \mathbf{q} = \tilde{V}_e \quad (2)$$

$$\frac{1}{C_{p2}} Q_2 + \mathbf{k}_2^T \mathbf{q} + L\ddot{Q}_2 = 0 \quad (3)$$

其中, \mathbf{M} 为悬臂梁的质量矩阵, \mathbf{C} 为悬臂梁的阻尼矩阵, \mathbf{K} 为悬臂梁的刚度矩阵, \mathbf{q} 为系统的位移矢量, \mathbf{k}_1 为 PZT1 和结构之间的机电耦合阻抗矩阵, \mathbf{k}_2 为 PZT2 和结构之间的机电耦合阻抗矩阵, Q_1 为 PZT1 表面的电荷量(单位为 C), Q_2 为 PZT2 表面的电荷量(单位为 C), C_{p1} 为 PZT1 两端的电容值(单位为 F), C_{p2} 为 PZT2 两端的电容值(单位为 F), \tilde{V}_e 为激励电压(单位为 V), V_{out} 为响应信号(单位为 V)。频率为 ω 时,设:

$$\mathbf{q} = \mathbf{q}_0 e^{j(\omega t - \varphi_q)} \quad (4)$$

$$Q_2 = p e^{j(\omega t - \varphi_p)} \quad (5)$$

对 \mathbf{q} , Q 分别求导,得到式(6)~(9),即:

$$\dot{\mathbf{q}} = (j\omega) \mathbf{q}_0 e^{j(\omega t - \varphi_q)} = (j\omega) \mathbf{q} \quad (6)$$

$$\ddot{\mathbf{q}} = (-\omega^2) \mathbf{q} \quad (7)$$

$$\dot{Q}_2 = (j\omega) p e^{j(\omega t - \varphi_p)} = (j\omega) Q_2 \quad (8)$$

$$\ddot{Q}_2 = (-\omega^2) Q_2 \quad (9)$$

代入式(1)~(3)中可得电感两端的输出电压 V_{out} 为:

$$V_{out} = L \ddot{Q}_2 = \frac{C_{p1} C_{p2} \mathbf{k}_1 \mathbf{k}_2^T \tilde{V}_e L \omega^2}{(-\omega^2 \mathbf{M} + j\omega \mathbf{C} + \mathbf{K})(C_{p2} L \omega^2 - 1) + (1 - C_{p2} L \omega^2) C_{p1} \mathbf{k}_1 \mathbf{k}_1^T + C_{p2} \mathbf{k}_2 \mathbf{k}_2^T} \approx \frac{C_{p1} C_{p2} \mathbf{k}_1 \mathbf{k}_2^T \tilde{V}_e L \omega^2}{(-\omega^2 \mathbf{M} + j\omega \mathbf{C} + \mathbf{K})(C_{p2} L \omega^2 - 1)} \quad (10)$$

由式(10)可知,输出电压的频域特征不仅取决于结构本身的质量、阻尼和刚度,也跟 PZT 与结构的耦合强度、压电片的电学参数及激励电压密切相关。任一参数的微小变化,都会通过谐振峰的频移、幅值变化或相位差异体现出来,从而敏锐反映出粘结松脱、裂纹等损伤状态。 $-\omega^2 \mathbf{M} + j\omega \mathbf{C} + \mathbf{K}$ 反映了被测结构的状态和边界条件,不同的结构状态测得的响应信号 V_{out} 不同。而电感 L 作为一个关键的可调变量,为系统引入了额外的自由度。通过调节电感 L ,可在不改变被测结构的前提下改变系统的谐振频率和幅值响应,从而获得多种结构响应特性。不同电感值的调节有助于获取多样的机电阻抗曲线,积累不同状态下的故障特征,丰富数据集,为结构健康监测提供可靠的实验支撑与理论依据。

2) 玻璃窗实验装置设计与分析

图 2 展示了基于压电陶瓷(PZT)的玻璃窗振动测试系统架构。该系统通过 4 组胶条(胶条 1~4)对称地固定玻璃基体,确保结构的稳定性与可靠性。本系统的主要研究对象为单侧胶条失效与多侧胶条失效故障对结构振动特性的影响。在系统设计方面,激励信号由系统仿真软件生成,幅值和频率均可调。信号通过高精度数据采

集卡进行数模转换后,由功率放大器进行放大,以驱动 PZT1 驱动器输出振动。

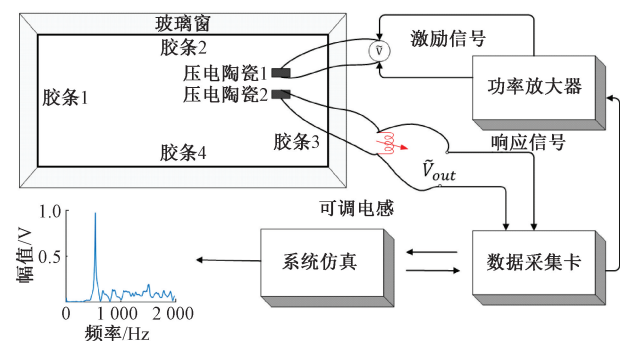


图 2 玻璃装置系统


Fig. 2 Glass device system

PZT1 通过逆压电效应将电信号转换为机械振动,该振动通过胶条与玻璃界面的传递作用至被测结构,从而激发结构的振动响应。系统引入的可调电感电路用于调节电学谐振特性,增强了数据集的多样性和丰富性,进一步拓宽对系统动态特性分析的维度。PZT2 传感器则基于正压电效应,捕获玻璃结构的振动响应信号,并通过数据采集卡进行数字化处理,最终将处理后的信号回传至计算机。


在系统仿真平台上,采用了相敏检波信号处理算法,对不同胶条失效模式下的振动信号特征进行量化分析与评估。通过这些分析,研究能够深入探讨不同故障模式对结构动态特性,尤其是振动响应的影响,为进一步优化结构健康监测方法和故障诊断技术提供重要参考。图 3 展示了原始 PZT 信号与经相敏检波处理后所得到的频域特征曲线之间的对比情况。如图 3(a) 所示,原始信号在 50~1 050 Hz 的扫频范围内呈现出复杂的时域波动。这些波动往往受到外部噪声、环境干扰以及结构本身非理想响应的影响,致使原始信号中的有用频域信息被部分掩盖。为此,引入相敏检波技术对信号进行处理。图 3(b) 展示了经该技术处理后的频域响应特征曲线。可以明显看出,相较于原始信号,处理后的频域曲线中关键的峰值更加清晰,频谱特征更加突出,且整体走势与原始频率响应保持一致。这说明相敏检波能够有效突出结构对激励信号的特征响应,抑制背景噪声及非结构相关的干扰成分。

1.2 数据增强与训练过程

数据生成与故障识别的处理流程如图 4 所示,首先将 PZT2 采集的数据按统一比例划分为训练集与测试集。针对训练集中存在的类别不平衡问题,分别采用 5 种变分自编码器数据增强模型:多层感知器变分自编码器 (multilayer perceptron variational autoencoder, MLP-VAE)、卷积神经网络变分自编码器 (convolutional neural



(a) 相敏检波前
(a) Before phase-sensitive detection



(b) 相敏检波后
(b) After phase-sensitive detection

图 3 PZT 传感器信号对比

Fig. 3 Comparison of PZT sensor signals

network variational autoencoder, CNN-VAE)、挤压激励变分自编码器 (squeeze-and-excitation variational autoencoder, SE-VAE)、坐标注意力变分自编码器 (coordinate attention variational autoencoder, CA-VAE) 和卷积块注意力模块变分自编码器 (convolutional block attention module variational autoencoder, CBAM-VAE) 对少数类样本进行数据扩充,以平衡数据集。此策略不仅提升了样本数量,还可引入额外特征,增强数据多样性。最后,将生成样本与原始数据合并,构建扩展训练集,与测试集一同用于故障分类模型的训练,并在测试集上通过准确率、精确率、召回率和 F1 分数等指标评估,以验证基于 VAE 的数据扩充对故障分类性能的提升效果。

1) 基于 CBAM-VAE 结构的生成模型研究

本条主要介绍用于数据增强的 CBAM-VAE 模型构建原理,VAE 是一种结合自动编码器与概率图模型的生成框架,旨在学习输入数据的潜在分布,并据此生成新样本。本研究在传统的 MLP-VAE 基础上,将全连接层替换成卷积层,并且引入卷积注意力机制,构建 CBAM-VAE 模型,以增强特征提取和数据生成能力。

图 5(a) 展示了传统的 MLP-VAE 结构,该模型由编码器、均值层、方差层和解码器构成,其中编码器和解码

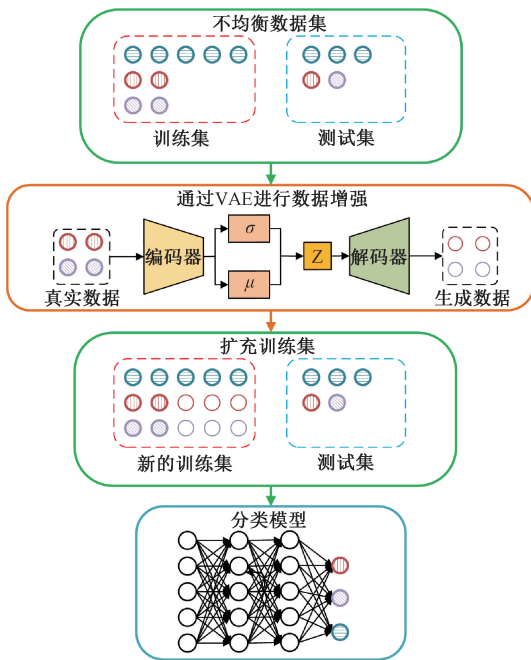
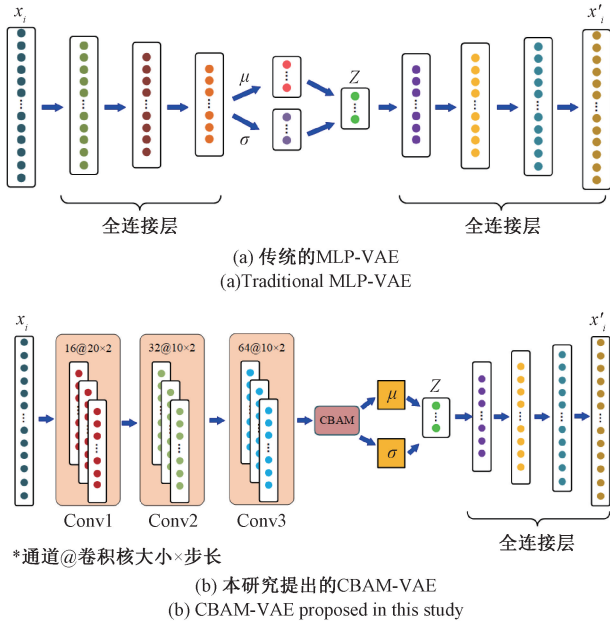


图4 数据增强整体流程

Fig. 4 Overall flowchart of data augmentation



(a) 传统的MLP-VAE
(a) Traditional MLP-VAE
(b) 本研究提出的CBAM-VAE
(b) CBAM-VAE proposed in this study

图5 VAE 结构对比

Fig. 5 Comparison of VAE structures

器均由多个全连接层组成,每层均由线性变换和 ReLU 激活函数组成,均值层和方差层也采用全连接层结构。VAE 中的重建过程涉及将输入编码到潜在空间,从学习到的潜在分布中采样,生成采样的潜在变量 z ,并将潜在变量 z 解码回原始输入空间。潜在变量 z 表示潜在空间中编码输入关键特征的点。值得注意的是,编码器不会

直接输出隐藏变量值。潜在变量 z 由编码器输出的平均值(μ)和方差(σ)确定,它描述了潜在空间的分布。

传统全连接层架构在处理复杂结构的阻抗信号时,无法有效捕捉数据的局部特征和位置信息,导致编码器难以学习到关键特征,并将数据映射到不同法代表性的潜在空间。这样,解码器接收到失真的潜在向量,影响了重构数据的准确性,从而产生模糊的生成样本。

针对这个问题,如图 5(b) 所示,本文提出的方法将编码器中的全连接层替换为一维卷积层,并引入卷积注意力模块来处理输入信号的位置信息和局部特征。卷积层的卷积操作比全连接层更好地捕捉阻抗特征,参数设置中,第 1 层卷积核尺寸为 20,用以覆盖更大的空间特征,后两层卷积核尺寸为 10,步幅设为 2,以捕捉局部特征和峰值位置。解码器的最后采用 HardTanh 激活函数,以确保生成数据输出范围与输入数据一致。

卷积层中通道数量从低到高的转变可以优化和增强数据的特征表示,每个通道代表对输入数据不同方面或特征的响应,借助每个通道捕捉不同层次的信息,随后将这些特征输入到 CBAM 模块中。CBAM 由 2 个模块内组成:通道注意力模块(convolutional block attention module, CAM)和空间注意力模块(spatial Transformer networks, SAM)。如图 6 所示,在 CAM 结构的设计中,摒弃了 CAM 中的传统 MLP 设计,将结构简化为 2 个具有 ReLU 激活功能的完全连接层。




图6 CBAM 结构设计

Fig. 6 Structural design of CBAM

输入特征以两步过程进行 CAM:第 1 步自适应平均池操作用于汇集来自每个通道的特征,对每个通道内的所有特征值进行平均,以获得每个通道的平均值,第 2 步引入一个完全连接的层来学习通道之间的关系。Sigmoid 激活函数将全连接层的输出映射到 $[0, 1]$ 范围,表示每个通道的注意力权重。然后将这些信道注意力权重与原始特征图相乘以执行加权,放大重要特征信道,同时抑制噪声更多、关键特征信息较少的信道,从而减少对网络学习关键特征的干扰。

然后,SAM 沿着输入张量的空间维度执行平均池化和最大池化操作。平均池化强调数据的整体特征,而最大池化强调突出的局部特征。结果沿通道维度连接,以

利用两种池化操作的优点,创建一个新的张量。然后采用一维卷积层来处理这个张量并生成空间注意力权重。Sigmoid 激活函数用于将卷积层的输出映射到 $[0,1]$ 范围,从而产生空间注意力权重。

为了进行更直接比较,移除了 CBAM 模块,仅保留卷积层生成潜在变量 z ,构建了基础的卷积变分自编码器(CNN-VAE),如图 7 所示。同时,为评估不同注意力机制对数据特征提取的影响,分别采用压缩与激励(SE)和坐标注意力(CA)机制替换 CBAM 模块,构建了 SE-VAE 和 CA-VAE 模型,其结构如图 8 所示。




图 7 CNN-VAE 的架构
Fig. 7 Architecture of CNN-VAE




图 8 SE-VAE 和 CA-VAE 的架构
Fig. 8 Architectures of SE-VAE and CA-VAE

2) 神经网络分类器模块的设计

在这项研究中,尽管阻抗信号中峰值的确切位置容易受到干扰并可能漂移,但峰值相对位置与故障非线性引起的峰值形状变化之间的潜在关系仍然作为特征存在。换句话说,通过深入探索阻抗信号的局部特征和峰值之间的关系,可以减轻复杂环境的影响。值得注意的是,Transformer 模型的多头注意力机制特别强调数据点之间的关系,阻抗信号中的关键信息之一确实是峰值之间的关系^[33-36]。

因此,本研究采用 Transformer 模型作为分类器,Transformer 模型的结构如图 9 所示,它由多个相同的层组成,每个层都有两个子层:一个自注意力机制层和一个前馈神经网络层。每个子层之间都使用了残差连接和层归一化。输入特征被馈送到嵌入层,然后在传递到编码

器层之前添加位置信息。分类结果通过线性层和归一化指数函数层输出。

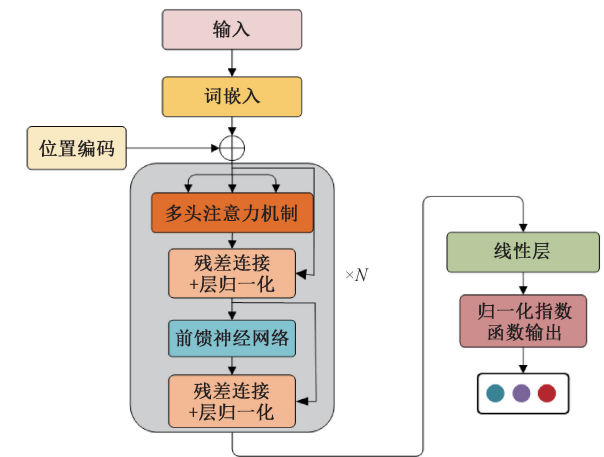


图 9 Transformer 模型的结构
Fig. 9 Structure of Transformer model

2 实验验证

2.1 玻璃窗实验装置

玻璃窗系统的实验装置如图 10 所示,被测结构为尺寸为 $80\text{ cm}\times50\text{ cm}\times3.7\text{ cm}$ 的塑钢窗扇,采用封胶条进行固定,胶条使用的是 PVC 材料。为了采集信号,玻璃表面并排粘贴了两块压电陶瓷片,其中一片用于激励,另一片用于收集玻璃的振动响应信号。




图 10 实验装置
Fig. 10 Experimental setup

实验开始时,通过系统仿真软件发送激励信号,设定采样频率为 20 kHz ,扫描频率范围为 $200\sim5\,800\text{ Hz}$,以确保覆盖玻璃窗在不同频段的动态响应。激励信号通过 OPA541 功率放大器放大后传输至 PZT1,驱动被测玻璃结构产生机械振动。同时,PZT2 连接至可调电感电路,并由外部电源供电,通过调节电感值获取不同条件下的同一故障数据,进一步丰富实验数据。

2.2 胶条失效故障数据的对比分析

1) 并联电感对阻抗响应曲线影响

根据推导的压电阻抗法有限元动力学方程可知,电感 L 是影响系统响应的关键变量,通过调节电感值,可以改变系统的谐振频率和响应信号的幅值响应。如图 11 所示, L_0 代表没有并联电感电路时候的响应曲线, $L_1 \sim L_5$ 分别代表逐步增加的并联电感值。与没有并联电感电路的结构响应 L_0 相比,加入电感后,结构响应 L_1 在谐振频率附近的信号增强了一个数量级。此外,谐振峰与结构固有频率峰发生耦合,导致固有频率峰值显著增大。




图 11 不同电感值的结构响应信号

Fig. 11 Structural response signals with different inductance values


在实验过程中,通过调节电感值 $L_1 \sim L_5$,在保持机械结构状态不变的情况下,采集了一系列不同的频域响应信号。引入电学变量的方式,使系统在结构不变的条件下展现出频率响应的多样性,从而灵活调整结构的频域特性,获得不同电感配置下的振动数据。这不仅有效扩充了样本数量,为数据驱动模型的训练提供了更多支持。

2) 不同故障数据的对比分析与评估


如图 12 所示,展示了 3 种不同故障状态下的玻璃窗结构的响应信号,所有数据均经过降采样处理,这些状态包括玻璃窗胶条的 3 种不同工况:所有胶条均处于健康状态(案例 1)、仅胶条 1 失效(案例 2)以及胶条 1 和 2 同时失效(案例 3)。

由图 12(a)可以看出不同工况下信号在 $0 \sim 600$ Hz 低频段变化较小,表明该频段对结构的故障不敏感;而在中频段约 $800 \sim 1\,000$ Hz 出现明显变化,且高频段的多个峰表现出明显放大效果。随着胶条失效数量的增加,系统的高频响应变化更为剧烈。

图 12(b) 所示,中频段信号下,3 种工况的差异较大。健康状态(案例 1)下,阻抗曲线呈现尖锐、单峰的特征,整体特征波动较为稳定,说明系统动态特性完整;在仅胶条 1 失效的状态(案例 2)中,信号峰值出现轻微波动,显示出一定的动态变化,比较不稳定;而在胶条 1 和 2



(a) 信号整体趋势
(a) Overall signal trend



(b) 谐振峰放大图
(b) Magnified view of resonant peak

图 12 不同故障条件下的结构响应信号

Fig. 12 Structural response signals under different fault conditions

同时失效的状态(案例 3)中,谐振峰出现明显双峰,表明系统动态特性发生了显著变化。

由此可见,通过学习信号中峰值的相对位置和形态变化,可有效识别故障状态,为后续的系统故障诊断提供有力支持。

2.3 玻璃窗小样本故障实验讨论

1) 故障分类与数据集预划分

具体的样本量及类别不平衡比例如表 1 所示,共设定 3 种数据分布:1:1(平衡)、4:1(轻度不平衡)和 20:3(高度不平衡)。在平衡数据集(1:1)中,3 种状态各 100 个样本,总计 300 条;在 4:1 的不平衡设置中,状态 1 为 100 个样本,状态 2 和 3 为 25,总计 150 条;在 20:3 设置中,状态 1 为 100,状态 2 和 3 为 15,总量为 130。需说明的是,表 1 中数据量均为训练集数量,测试集在不同设定下保持不变,共 300 条,每类各 100 条。

2) 不同模型生成数据的效果对比

图 13 展示了在仅胶条 1 失效的情况下,各模型在 $0 \sim 2\,000$ Hz 范围内生成的幅值特征对比图。图 13(a) 显示,另外两种不含注意力机制的模型 MLP-VAE 和

表 1 数据集划分及分布情况

Table 1 Dataset partition and distribution (个)

不平衡比	状态 1 数据量	状态 2 数据量	状态 3 数据量	数据 总量
1 : 1	100	100	100	300
4 : 1	100	25	25	150
20 : 3	100	15	15	130

CNN-VAE,与引入卷积块注意力模块的模型 CBAM-VAE 在整体上都较好保留了原始数据的基本特征,生成数据趋势与真实数据保持一致,但从图 13(b)~(e)的局部特征分析可见,这 3 种变分字编码器模型在特征提取和降噪方面存在明显差异。

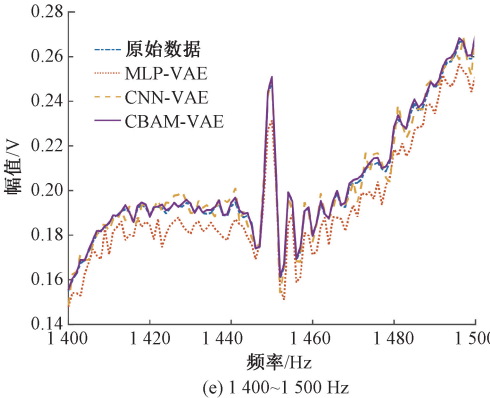
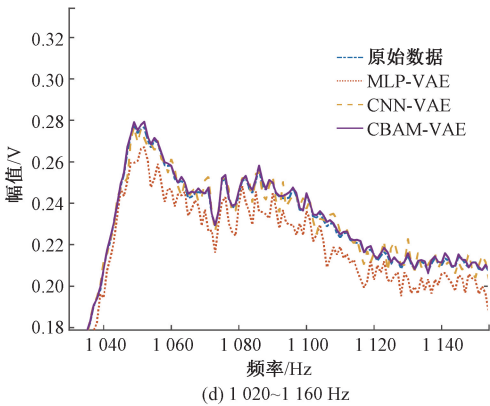
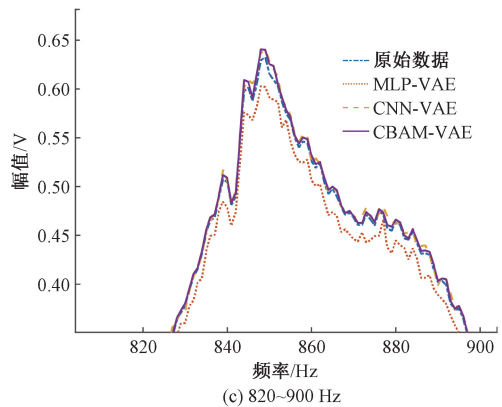
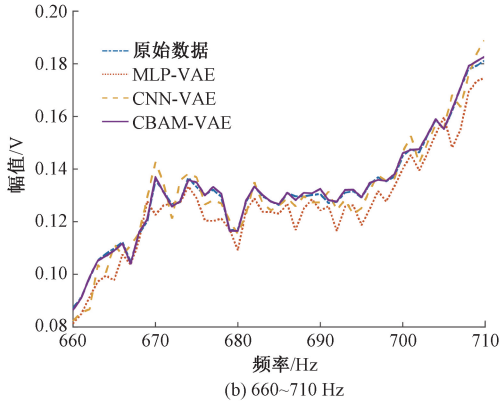
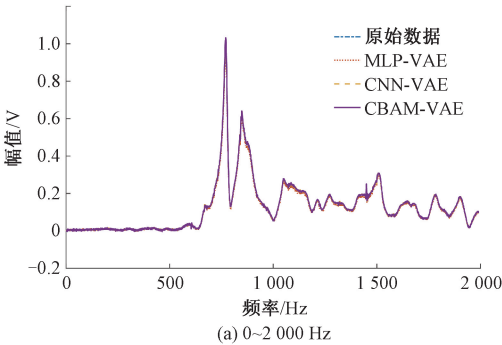


图 13 仅胶条 1 失效故障下 MLP-VAE、CNN-VAE 与 CBAM-VAE 生成数据与真实数据对比

Fig. 13 Comparison of actual data and generated data by MLP-VAE, CNN-VAE and CBAA-CAE under the fault of rubber strip 1 failure

其中,采集的真实数据作为对比基准,MLP-VAE 生成的数据噪声较多,高频段波动大,特征边界模糊,影响故障识别,CNN-VAE 在降噪和局部特征提取方面有所改进,但在细节保留和噪声抑制上仍显不足,部分关键特征存在弱化或失真现象。而本研究提出的 CBAM-VAE 生成的数据曲线与真实数据最为接近,细节特征的还原效果更佳,在数据增强方面展现出更优的特征保留与降噪能力。这是其在引入注意力机制后,能够自适应地调整模型对不同频率信息的关注程度,使得关键特征得到有效突出,同时减少背景噪声的干扰。

为评估引入不同注意力机制的数据特征提取效果,还同时对比了 SE-VAE、CA-VAE、CBAM-VAE 这 3 种模型对于仅胶条 1 失效的案例数据的幅值处理结果,如图 14 所示。相较于基础的 CNN-VAE 和 MLP-VAE 模型,引入注意力机制的 3 种模型 (SE-VAE、CA-VAE、CBAM-VAE) 均显著提升了噪声抑制能力,并更有效地突出了数据的关键特征。其中,本研究提出的 CBAM-VAE 在数据增强任务中表现出更优的特征保留与噪声抑制生产能力,这源于其通道注意力模块和空间注意力模块协

同作用,能够自适应地聚焦于关键特征信息,有效学习重要特征并抑制生成噪声。从图 14 的局部放大图,图 14(b)~(e)观察可见,CA-VAE 与 CBAM-VAE 生成的曲线在视觉上与真实数据均表现出较高吻合度,其细微





图 14 仅胶条 1 失效故障下 SE-VAE、CA-VAE 与 CBAM-VAE 生成数据与真实数据对比


Fig. 14 Comparison of actual data and generated data by SE-VAE, CA-VAE and CBAM-VAE under the fault of rubber strip 1 failure

差异难以直接从图中判别。因此,2.3 节将引入机器学习量化指标,进一步精确评估这 3 种注意力机制 VAE 模型 (SE-VAE、CA-VAE、CBAM-VAE) 的性能差异。

3) 不同数据增强方法的效果对比分析

为量化评估在不同不平衡比条件下数据增强方法的效果,本文在两种类别不平衡设置(20:3 与 4:1)下,对比了 5 种数据增强模型 (MLP-VAE、CNN-VAE、SE-VAE、CA-VAE、CBAM-VAE) 的性能。评估指标包括准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F1 分数 (F1-Score)^[37],并重点关注各模型对少数类样本的识别能力。每种不平衡比例设置下均进行 20 轮实验验证,取算术平均值作为最终评估结果,详见图 15 和 16。案例 1、2 和 3 这 3 种类别分别对应无故障状态、仅胶条 1 失效状态和胶条 1 和 2 同时失效状态。

如图 15 所示,在类别不平衡比为 20:3 的实验中,本实验对比了 MLP-VAE、CNN-VAE、SE-VAE、CA-VAE 和



在少数类的识别上,CBAM-VAE 同样表现突出。如图 15(d)所示,案例 2 的 F1 分数达到 89.35%,案例 3 为 87.41%,均优于其他 5 种模型。相较之下,MLP-VAE 在案例 2 和案例 3 上的 F1 分数分别为 87.99%和 84.51%,CNN-VAE 分别为 88.26%和 86.01%,SE-VAE 分别为 88.83%和 86.04%,CA-VAE 分别为 89.04%和 86.58%。

CBAM-VAE 的性能优势主要源于其引入的卷积块注意力模块(CBAM)独特的双路结构。其中,通道注意力模块能有效学习不同特征通道的重要性权重,突出关键

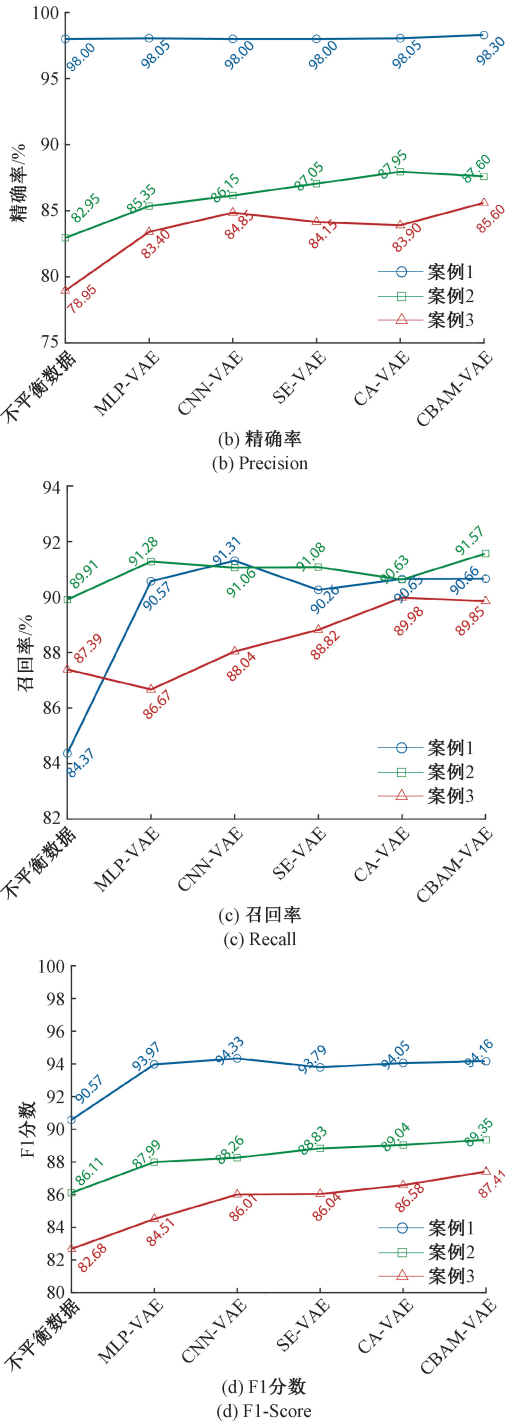
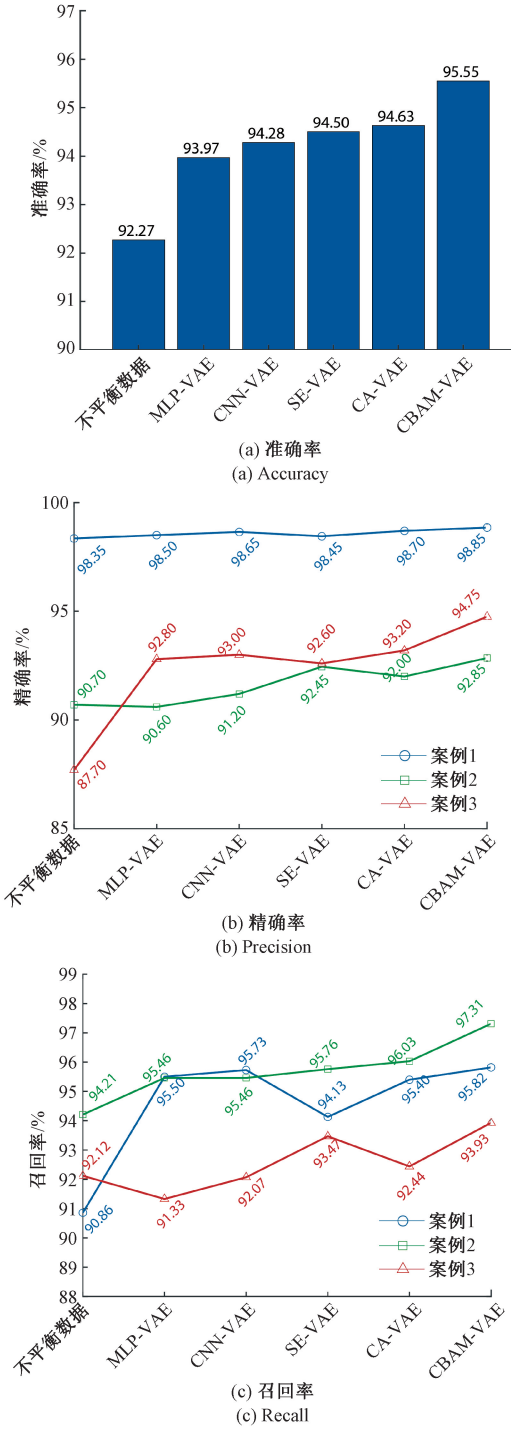


图 15 不平衡比为 20:3 时的增强实验结果
Fig. 15 Data augmentation results at an imbalance ratio of 20:3

CBAM-VAE 这 5 种数据增强模型的性能,重点评估它们对少数类别的识别能力。结果表明,CBAM-VAE 在所有类别上的表现均优于其他模型,整体分类准确率达到 90.62%,明显高于 MLP-VAE (88.93%)、CNN-VAE (89.67%)、SE-VAE (89.73%) 和 CA-VAE (89.97%)。






图 16 不平衡比为 4:1 时的增强实验结果

Fig. 16 Data augmentation results at an imbalance ratio of 4:1

信息通道;而空间注意力模块则专注于特征图中的关键空间区域,提升对重要位置的响应。二者协同作用,使模型在不平衡数据场景下,能够有效缓解少数类特征容易被多数类特征掩盖或稀释的问题,从而显著提升分类效果。

相比之下,SE-VAE 仅依赖通道注意力,虽然能提升重要通道的响应,但缺乏对空间位置信息的显式建模,当特征分布复杂或关键区域位置多变时,其增强效果容易受限。而 CA-VAE 则通过沿固定坐标轴分解的方式嵌入位置信息,虽部分弥补了 SE 的不足,但其位置信息嵌入方式灵活性有限。在捕捉峰值位置和峰值之间的关系,以及关键峰值特征时,其灵活性可能不及 CBAM 空间注意力模块通过卷积自适应学习空间依赖关系的机制。需要指出的是,受限于少数类样本数量,模型在不同少数类别间的表现仍存在差异。例如,在 CBAM-VAE 模型下,案例 2 的 F1 分数 (89.35%) 比案例 3 (87.41%) 高出 1.94%。这种差异可能与两类样本在特征空间中的高度相似性有关,从而给模型区分最相近的少数类增加了难度。

如图 16(a) 所示,当类别不平衡比降低至 4:1 时, CBAM-VAE 依然展现出明显优势,整体分类准确率达到 95.55%,不仅高于 MLP-VAE (93.97%) 和 CNN-VAE (94.28%),相较于无增强的基线模型 (92.27%) 提升了 3.28%。这一结果不仅验证了数据增强方法在缓解类别不平衡问题上的有效性,更凸显了 CBAM-VAE 通过其注意力机制对分类性能的进一步增益。与其他引入注意力机制的模型相比, CBAM-VAE 同样领先,高于 SA-VAE 的 94.50% 和 CA-VAE 的 94.63%。在所有模型中,数据增强均带来了准确率的提升,而 CBAM-VAE 的效果最为突出。

从精确率来看,如图 16(b) 所示, CBAM-VAE 在多数类和少数类中均表现优越。案例 1 的精确率为 98.85%,略高于 CNN-VAE (98.65%)、MLP-VAE (98.50%)、SA-VAE (98.45%) 和 CA-VAE (98.70%)。在案例 2 中, CBAM-VAE 的精确率为 92.85%,优于 CNN-VAE (91.20%)、MLP-VAE (90.60%)、SA-VAE (92.45%)、CA-VAE (92.00%);案例 3 的精确率为 94.75%,同样优于其他模型。

在召回率方面,从图 16(c) 可见, CBAM-VAE 在少数类的表现尤为突出。案例 2 的召回率为 97.31%,相比其他 4 种增强模型均有所提升,同时比不平衡数据方法显著提升了 3.1%;案例 3 的召回率为 93.93%,优于 MLP-VAE (91.33%)、CNN-VAE (92.07%) 和 CA-VAE (92.44%),略高于 SE-VAE (93.47%)。在案例 1 中, CBAM-VAE 的召回率为 95.82%,与其他模型性能相近,表明增强方法有效保留了多数类的识别能力。

如图 16(d) 所示,从 F1 分数综合评估, CBAM-VAE 在所有类别中均实现最优表现。案例 2 的 F1 分数为 94.97%,高于 MLP-VAE (92.89%)、CNN-VAE (93.20%)、SA-VAE (94.03%) 和 CA-VAE (93.90%)。案例 3 的 F1 分数为 94.27%,同样处于领先水平;案例 1 的 F1 分数为 97.25%,略高于其他模型。

综上所述, CBAM-VAE 不仅在多数类上保持了优异性能,更在少数类识别上展现出显著优势,适用于极端类别不平衡条件下的故障识别任务,展现出其作为高效数据增强方法的实用价值与应用潜力。

2.4 基于 CBAM-VAE 与峰值特征保留-插值修复的协同优化方法

1) 峰值特征保留与插值修复方法

如 2.2 节所述,在机械结构不变的前提下,调节并联电感值会引起阻抗响应中谐振峰位置的明显偏移。但尽管峰值位置发生变化,其峰的数量及相对分布模式基本一致,说明信号仍属于同一类故障,这表明故障特征更多体现在信号的整体趋势与分布模式上,而不是依赖于某一具体谐振峰的具体位置或幅值。

图 17 展示了在 3 组相近电感值下采集的信号样本:案例 2-L1、案例 2-L2、案例 2-L3 为仅胶条 1 失效状态下的信号,案例 3-L1、案例 3-L2、案例 3-L3 为胶条 1 和 2 同时失效状态下的信号,所有数据均已进行归一化处理。可以看出,尽管各组信号中谐振峰位置存在微小偏移,但其整体形态保持高度一致,进一步验证了调节电感值带来的变化不会影响故障类别的论据。

为进一步优化 CBAM-VAE 生成的数据,提出一种信号重构优化方法:基于 CBAM-VAE 与峰值特征保留-插值修复的协同优化方法 (CBAM-VAE based collaborative method for PPIR, PPIR-CBAM-VAE),该方法通过优化生




图 17 在 3 种非常接近的电感值下不同故障情况的响应信号
Fig. 17 Response signals under different fault conditions with three very close inductance values

成信号的关键结构特征,进一步提高数据质量与可用性。其完整流程如图 18 所示。

如图 18(a)所示,首先由 CBAM-VAE 模型学习生成一批故障信号,在图 18(b)中,利用 Python 的 find_peaks


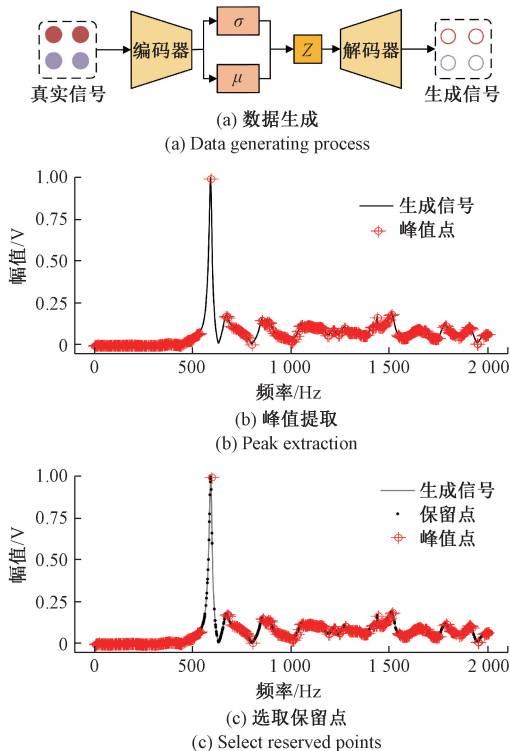


图 18 PPIR-CBAM-VAE 方法流程

Fig. 18 Flowchart of the PPIR-CBAM-VAE method

函数从生成信号中提取局部极大值点。这些峰值(十字标记点标记)被视为信号的关键特征,需在后续插值过程中保持不变,是确保信号整体特征不变的关键依据。

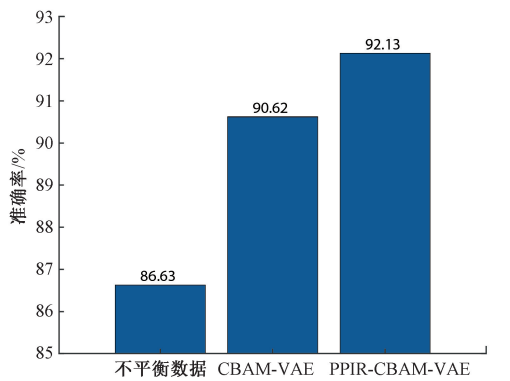
为构造缺失信号,图 18(c)展示了对生成信号的非峰值点进行删除:具体方法是在非峰值点中随机删除 800 个采样点,构造稀疏信号,剩余数据点包括全部峰值和部分未被删除的非峰值点作为保留点,为后续的插值重建提供支撑。

在图 18(d)中,对缺失信号采用线性插值进行重建,生成信号是连续平滑的曲线,保留了重要特征同时具有良好的整体连续性。并且信号的整体趋势未发生明显变化,所有谐振峰和关键峰值仍被保留,同时通过插值处理使得谐振峰及其他峰的位置产生了微小的变化。通过插值填补非峰值点的数据缺失,能够在保留关键峰值信息的同时,减少数据的不稳定性,从而提高后续特征提取和模型训练的可靠性。


2) PPIR-CBAM-VAE 方法的实验对比分析

为评估所提出的 PPIR-CBAM-VAE 方法的有效性,本节分别在类别不平衡比为 20:3 和 4:1 的条件下,对比了 4 种方法的分类性能:数据不平衡方法,CBAM-VAE 方法,PPIR-CBAM-VAE 方法,以及作为对照组的 Balance 方法(1:1 平衡比下的情况)。在每种不平衡设置下,所有方法均进行了 20 轮独立实验验证,并将各项性能指标取平均值作为最终评估依据,实验结果详见图 19 和 20。


从图 19(a)可以看出,数据不平衡方法分类准确率为 86.63%,CBAM-VAE 模型将其提升至 90.62%,而 PPIR-CBAM-VAE 方法进一步提高至 92.13%,说明其具备更强的整体分类能力。图 19(b)中,PPIR-CBAM-VAE 显著改善了案例 3 的精确率,从 78.95% 提升至 90.50%,在少数类识别中表现突出。然而,从图 19(c)可见,虽然 CBAM-VAE 在案例 3 的召回率上略高,为 89.85%。PPIR-CBAM-VAE 的召回率为 89.13%,略低于 CBAM-VAE 方法。这表明在增强案例 3 的识别能力的同时,PPIR-CBAM-VAE 方法可能使得案例 2 被误判为案例 3,可能是因为由两个类别之间的特征存在重叠。总体



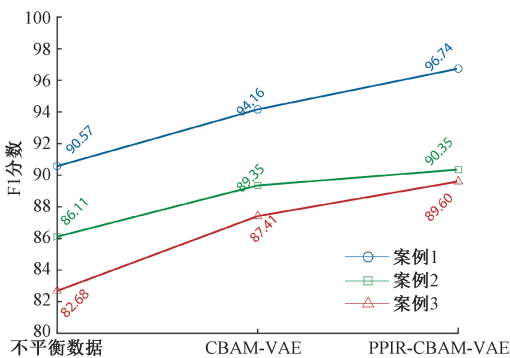
(a) 准确率
(a) Accuracy




(b) 精确率
(b) Precision




(c) 召回率
(c) Recall




(d) F1分数
(d) F1-Score




(a) 准确率
(a) Accuracy



(b) 精确率
(b) Precision



(c) 召回率
(c) Recall



(d) F1分数
(d) F1-Score

图 19 不平衡比为 20:3 时 PPIR-CBAM-VAE 方法结果
Fig. 19 Results of the PPIR-CBAM-VAE method at an imbalance ratio of 20:3

图 20 不平衡比为 4:1 时 PPIR-CBAM-VAE 方法结果
Fig. 20 Results of the PPIR-CBAM-VAE method at an imbalance ratio of 4:1

来看,如图 19(d)所示,PPIR-CBAM-VAE 在各类别的 F1 分数均高于其他方法,案例 1 达到 96.74%,案例 2 为 90.35%,案例 3 为 89.60%,表现出更优的识别精度与分类稳定性,验证了其在不平衡数据下的增强优势。

当类别不平衡比降至 4:1 时,如图 20(a)所示,数据不平衡方法的准确率为 92.27%,CBAM-VAE 方法提升至 95.55%,PPIR-CBAM-VAE 方法进一步提升至 96.45%,而平衡数据方法表现最佳,准确率达 98.77%,完全平衡的数据集获得最优的分类效果。与不平衡数据方法相比,PPIR-CBAM-VAE 的准确率提高了 4.18%,验证了其在数据增强方面的有效性。

从图 20(b)和(c)可见,PPIR-CBAM-VAE 显著提高了案例 3 的精确率,由 CBAM-VAE 的 94.75%提升至 97.55%,但召回率略有下降,从 93.93%降至 93.12%,仍高于不平衡数据方法的 92.12%。这表明该方法在提升案例 3 的识别精度的同时,可能引入了部分案例 2 的误判。平衡数据方法在所有类别的召回率均接近 99%,再次证明完全平衡数据对分类器性能的积极影响。

在 F1 分数方面,图 20(d)可见,PPIR-CBAM-VAE 分别在案例 1、案例 2 和案例 3 上取得了 98.81%、95.30%和 95.26%的高分,其整体表现最优。虽然平衡数据方法的各类 F1 分数接近 99%,但其对数据量要求较高,在数据获取受限或成本较高的情况下难以适用。

综上所述,PPIR-CBAM-VAE 方法在数据增强方法中表现最优,在准确率、召回率和 F1 分数上均超越 CBAM-VAE,说明其生成数据质量较高,能够有效缓解类别不平衡问题,提高分类器的适应性和稳定性。

3 结 论

本研究针对玻璃胶条长期使用后易失效的问题,提出了一种基于压电阻抗技术的非侵入式故障诊断方法,设计了玻璃窗胶条振动响应系统,并通过可变电感调节覆盖更多故障场景,扩展了实验数据集。研究发现,玻璃胶条在失效情况下改变了阻抗信号的特征响应,如峰值位置偏移与幅值变化。针对实际应用时的数据不平衡问题,结合 CBAM-VAE 模型生成故障样本扩充数据集,显著提高了分类器对复杂故障模式的识别能力,验证了本研究提出的方法在胶条失效诊断中的高灵敏性和适用性,为建筑密封系统健康监测提供了一种新的解决方案。

为优化 CBAM-VAE 生成的数据,进一步提高故障诊

断的准确性,本研究基于 CBAM-VAE 与峰值特征保留-插值修复技术提出了一种 PPIR-CBAM-VAE 协同优化方法。PPIR-CBAM-VAE 方法通过保留关键谐振峰特征并插值修复非峰值数据点扩充数据集,进一步丰富信号和提升数据集稳定性。实验表明,在不平衡比为 20:3 的条件下,PPIR-CBAM-VAE 显著提升了分类性能,准确率达到 92.13%。不平衡比为 4:1 时候,准确率从 92.27%提升至 96.45%,提升模型在少数类样本识别方面的性能,该方法为故障样本难以获取问题提供了一种新的增强策略。

然而,机电阻抗方法在实际应用中易受温度等环境因素的干扰,在本研究中未充分考虑这些因素,未来可通过设计更完善的结构测量装置和数据处理方法,减小环境因素的影响,从而提升结构健康监测的准确性和可靠性,实现更稳健的故障诊断。

综上,本研究通过分析玻璃窗结构的胶条密封问题,从理论建模、实验验证到数据增强方法的提出,系统构建了结合压电阻抗技术与深度学习的数据增强故障诊断框架,为工程结构健康监测提供了新的解决方案和理论基础。

参考文献

[1] IMTIAZ T. 基于深度学习的建筑窗户识别与损伤检测[D]. 哈尔滨:哈尔滨工业大学, 2024.
IMTIAZ T. Building window recognition and damage detection using deep learning neural network[D]. Harbin: Harbin Institute of Technology, 2024.

[2] 王子龙, 谭川龙. 隐框玻璃幕墙结构胶损伤影响规律研究[J]. 四川建材, 2024, 50(12): 71-73,89.
WANG Z L, TAN CH L. Effect rule of structural adhesive damage onmechanical characteristics of hiddenframe glass curtain walls [J]. Sichuan Building Materials, 2024, 50 (12): 71-73,89.

[3] 周练, 张凯, 徐涵, 等. 负风压作用下隐框玻璃幕墙承载行为和脱胶损伤实验研究[J]. 上海交通大学学报, 2024, 58(7): 1130-1138.
ZHOU L, ZHANG K, XU H, et al. Load bearing behavior and de-bonding damage experimental study of concealed-frame glass curtain wall under negative wind pressure[J]. Journal of Shanghai Jiao Tong University, 2024, 58(7): 1130-1138.

[4] ZHANG L, LU H L, LI H Y. Multi-scale damage detection of glass curtain wall by acoustic emission and

- vibrational modal analysis [C]. *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems* 2023, 2023, 12486; 148-157.
- [5] MIAO X Y, CHEN X, RASMUSSEN S, et al. Compression-compression fatigue damage of wrinkled carbon/glass hybrid composite laminates[J]. *Composite Structures*, 2024, 346: 118443.
- [6] WANG G B, KE J W. Literature review on the structural health monitoring (SHM) of sustainable civil infrastructure: An analysis of influencing factors in the implementation[J]. *Buildings*, 2024, 14(2): 402.
- [7] LI N, WANG F R, SONG G B. Monitoring of bolt looseness using piezoelectric transducers: Three-dimensional numerical modeling with experimental verification[J]. *Journal of Intelligent Material Systems and Structures*, 2020, 31(6): 911-918.
- [8] 张海燕, 孙修立, 曹亚萍, 等. 基于时间反转理论的聚焦 Lamb 波结构损伤成像[J]. *物理学报*, 2010, 59(10): 7111-7119.
- ZHANG H Y, SUN X L, CAO Y P, et al. Structural damage imaging based on time-reversal theory for focusing of Lamb waves [J]. *Acta Physica Sinica*, 2010, 59(10): 7111-7119.
- [9] 李亮, 张丙强, 杨小礼. 高速列车振动荷载下大断面隧道结构动力响应分析[J]. *岩石力学与工程学报*, 2005(23): 4259-4265.
- LI L, ZHANG B Q, YANG X L. Analysis of dynamic response of large cross-section tunnel under vibrating load induced by high speed train[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2005(23): 4259-4265.
- [10] 高峰, 李以农, 王德俊, 等. 用于结构健康诊断的压电阻抗技术[J]. *振动工程学报*, 2000(1): 98-103.
- GAO F, LI Y N, WANG D J, et al. Research on piezoelectric impedance technology for structural health monitoring [J]. *Journal of Vibration Engineering*, 2000(1): 98-103.
- [11] TENREIRO A F G, LOPES A M, DA SILVA L F M. A review of structural health monitoring of bonded structures using electromechanical impedance spectroscopy [J]. *Structural Health Monitoring*, 2022, 21(2): 228-249.
- [12] TAHA H M, BALL R J, HEATH A, et al. Crack growth and closure in cementitious composites: Monitoring using piezoceramic sensors[J]. *Sensors and Actuators A: Physical*, 2022, 333: 113221.
- [13] MIAO R S, SHEN R L, ZHANG S H, et al. A review of bolt tightening force measurement and loosening detection[J]. *Sensors*, 2020, 20(11): 3165.
- [14] DU F, WU S H W, XU C H, et al. Electromechanical impedance temperature compensation and bolt loosening monitoring based on modified Unet and multitask learning[J]. *IEEE Sensors Journal*, 2023, 23(5): 4556-4567.
- [15] CHA Y J, YOU K, CHOI W. Vision-based detection of loosened bolts using the Hough transform and support vector machines [J]. *Automation Construction*, 2016, 71(2): 181-188.
- [16] 闫宇楠, 刘智康, 徐佳文, 等. 基于 CBAM-CNN 和压电悬臂梁的温度解耦质量感知方法[J]. *仪器仪表学报*, 2024, 45(4): 113-126.
- YAN Y N, LIU Z H K, XU J W, et al. Temperature decoupled mass sensing based on CBAM-CNN and piezoelectric cantilever beam [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(4): 113-126.
- [17] PEREIRA P E C, DE REZENDE S W F, BARELLA B P, et al. Electromechanical impedance-based damage detection using machine learning approaches[J]. *Ingenieria E Investigacion*, 2024, 44(3): 111646.
- [18] ZHANG X, WANG H, HOU B R, et al. 1D-CNN-based damage identification method based on piezoelectric impedance using adjustable inductive shunt circuitry for data enrichment [J]. *Structural Health Monitoring*, 2022, 21(5): 1992-2009.
- [19] YANG J W, ZHU H P, WANG D S H, et al. The compensation technique of tensile force effect on the electro-mechanical impedance method for structural health monitoring [J]. *Journal of Intelligent Material Systems and Structures*, 2015, 26(18): 2477-2488.
- [20] NA W S, BAEK J. Impedance based health monitoring technique with probabilistic neural network for possible wall thinning detection of metal structures[J]. *Journal of Sensors*, 2017, 2017(1): 8950518.
- [21] MARTINEZ-MURCIA F J, ORTIZ A, GORRIZ J M, et al. Deep convolutional autoencoders vs PCA in a highly-unbalanced Parkinson's disease dataset: A

- DaTSCAN study[C]. Springer, Cham, 2019: 47-56.
- [22] TENG SH, CHEN G F, YAN ZH CH, et al. Vibration-based structural damage detection using 1-D convolutional neural network and transfer learning[J]. Structural Health Monitoring, 2023, 22(4): 2888-2909.
- [23] 王辉, 徐佳文, 严如强. 基于深度宽卷积 Q 网络的行星齿轮箱故障智能诊断方法[J]. 仪器仪表学报, 2022, 43(3): 109-120.
- WANG H, XU J W, YAN R Q. Intelligent fault diagnosis for the planetary gearbox based on the deep wide convolution Q network[J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 109-120.
- [24] HUSSEIN A S, LI T R, YOHANNESE C W, et al. A-SMOTE: A new preprocessing approach for highly imbalanced datasets by improving SMOTE[J]. International Journal of Computational Intelligence Systems, 2019, 12(2): 1412-1422.
- [25] CHEN W J, WANG H K, FEI M R, et al. An intrusion detection method using adasyn and bayesian optimized lightghm[C]. 2022 34th Chinese Control and Decision Conference, 2022: 4622-4627.
- [26] PEI W B, XUE B, ZHANG M J, et al. A cost-sensitive genetic programming approach for high-dimensional unbalanced classification[C]. 2019 IEEE Symposium Series on Computational Intelligence, 2019: 1770-1777.
- [27] PAN X T, WANG X, ZHAO CH W, et al. USFP: An unbalanced severe typhoon formation prediction framework based on transfer learning[J]. Frontiers in Marine Science, 2023, 9: 1046964.
- [28] KINGMA D P, WELING M. Auto-encoding variational bayes[J]. ArXiv preprint arXiv:1312.6114, 2013.
- [29] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. Advances in Neural Information Processing Systems, 2014, 27: 2672-2680.
- [30] LUO Y X, YANG ZH W. DynGAN: Solving mode collapse in gans with dynamic clustering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(8): 5493-5503.
- [31] DOSOVITSKIY A, BROX T. Generating images with perceptual similarity metrics based on deep networks[C]. 2016 30th Conference on Neural Information Processing Systems, 2016, 29: 658-666.
- [32] GIURGIUTIU V, KROPAS-HUGHES C V. Comparative study of neural network damage detection from a statistical set of electro-mechanical impedance spectra[C]. Smart Nondestructive Evaluation and Health Monitoring of Structural and Biological Systems II. SPIE, 2003, 5047: 108-119.
- [33] 王琦, 张涛, 徐超炜, 等. 多尺度注意力融合与视觉 Transformer 方法优化的电阻抗层析成像深度学习方法[J]. 仪器仪表学报, 2024, 45(7): 52-63.
- WANG Q, ZHANG T, XU CH W, et al. Optimized learning method for electrical impedance tomography with multi-scale attention fusion and vision transformer[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 52-63.
- [34] 李欣宇, 孙传猛, 魏宇, 等. 融合 Transformer 与残差通道注意力的恶劣场景水位智能检测方法[J]. 电子测量与仪器学报, 2023, 37(1): 59-69.
- LI X Y, SUN CH M, WEI Y, et al. Water level intelligent detection method based on fuse Transformer residual channel attention mechanism in harsh environments[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 59-69.
- [35] 黄星华, 吴天舒, 杨龙玉, 等. 一种面向旋转机械的基于 Transformer 特征提取的域自适应故障诊断[J]. 仪器仪表学报, 2022, 43(11): 210-218.
- HUANG X H, WU T SH, YANG L Y, et al. Domain adaptive fault diagnosis based on Transformer feature extraction for rotating machinery[J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 210-218.
- [36] 施杰, 张威, 李志, 等. 采用改进 Transformer 模型的滚动轴承声振信号故障诊断方法[J]. 电子测量技术, 2025, 48(11): 105-116.
- SHI J, ZHANG W, LI ZH, et al. Fault diagnosis of rolling bearing acoustic and vibration signals using an improved Transformer[J]. Electronic Measurement Technology, 2025, 48(11): 105-116.
- [37] SOKOLOVA M, LAPALME G. A systematic analysis of performance measures for classification tasks[J]. Information Processing & Management, 2009, 45(4): 427-437.

作者简介



尤增颖,2022 年于安徽工程大学获得学士学位,2025 年于东南大学获得硕士学位,主要研究方向为信号处理,结构健康监测,压电结构故障诊断。

E-mail:220223416@seu.edu.cn

You Zengying received her B.Sc. degree from Anhui Polytechnic University in 2022, and her M.Sc. degree from Southeast University in 2025. Her main research interests include signal processing, structural health monitoring, and piezoelectric structure fault diagnosis.



周玉勤,1992 年于河海大学获得学士学位,仪表测量与控制高级工程师,江苏润仪仪表有限公司董事长,南京理工大学和南京工业大学兼职教授。长期致力于智能化仪器仪表、控制系统的生产、研发与销售。

E-mail:2690524269@qq.com

Zhou Yuqin received her B.Sc. degree from Hohai University in 1992. She is a senior engineer in Instrumentation Measure-

ment and Control, Fellow of Jiangsu Runyi Instrument Co., Ltd., and adjunct professor at Nanjing University of Science and Technology and Nanjing Tech University. She has been long engaged in the production, research and development, and sales of intelligent instruments and control systems.



徐佳文(通信作者),分别在 2009 年和 2012 年于中国科学技术大学获得学士学位和硕士学位,2017 年于美国康涅狄格州立大学获得博士学位,现为东南大学副研究员、博士生导师,主要研究方向为压电振动能量采集,压电结构故障诊断,信号处理。

E-mail:jiawen.xu@seu.edu.cn

Xu Jiawen (Corresponding author) received his B.Sc. and M.Sc degrees both from the University of Science and Technology of China in 2009 and 2012, respectively, and his Ph.D. degree from the University of Connecticut, USA, in 2017. He is currently an associate researcher and doctoral supervisor at Southeast University. His main research interests include piezoelectric vibration energy harvesting, piezoelectric structure fault diagnosis, and signal processing.