

[自控·检测]

DOI:10.3969/j.issn.1005-2895.2025.06.009

融合注意力机制的改进 ACGAN 轴承故障样本生成与诊断

柯斌, 张守京, 董彬彬, 许涛

(西安工程大学机电工程学院, 陕西 西安 710600)

摘要:为缓解轴承故障样本稀缺对智能故障诊断模型性能的制约,课题组提出一种融合注意力机制的改进辅助分类生成对抗网络(Auxiliary Classifier Generative Adversarial Network, ACGAN)模型,用于高质量故障图像生成与扩展。首先,将采集的一维振动信号经短时傅里叶变换(Short-Time Fourier Transform, STFT)转换为时频图像,增强其时频特征表达能力;其次,用最小二乘损失代替传统 ACGAN 二元交叉熵损失以解决训练过程中存在梯度消失的缺点,提升训练稳定性;最后,在判别器结构中嵌入通道与空间注意力模块(Spatial Attention Module, SAM),增强模型对关键故障特征的响应能力。实验结果表明:该方法能够有效生成高质量故障样本,提高故障诊断的精度。

关键词:轴承;故障诊断;辅助分类生成对抗网络;短时傅里叶变换;最小二乘损失;注意力机制

中图分类号:TH133.3 文献标志码:A 文章编号:1005-2895(2025)06-0061-08

Attention-Enhanced ACGAN for Bearing Fault Sample Generation and Diagnosis

KE Bin, ZHANG Shoujing, DONG Binbin, XU Tao

(School of Mechanical and Electrical Engineering, Xi'an Polytechnic University, Xi'an 710600, China)

Abstract: In order to alleviate the limitations of intelligent fault diagnosis models caused by the scarcity of labeled bearing fault samples, the research group proposed an enhanced Auxiliary Classifier Generative Adversarial Network (ACGAN) model with attention mechanisms to enable high-quality fault image generation and data augmentation. Firstly, the collected one-dimensional vibration signals were transformed into time frequency representations using the Short-Time Fourier Transform (STFT), enhancing the expressiveness of features in both temporal and spectral domains. Secondly, the Least Squares Loss was used to replace the traditional ACGAN binary cross entropy loss to solve the shortcomings of gradient disappearance in the training process and improve the training stability. Finally, a channel and Spatial Attention Module (SAM) were integrated into the discriminator structure to increase its sensitivity of the model to critical fault-related features. Experimental results demonstrate that the proposed approach can effectively synthesize high-quality fault samples, thereby significantly improve diagnostic accuracy in small-sample scenarios.

Keywords: bearing; fault diagnosis; ACGAN (Auxiliary Classifier Generative Adversarial Network); STFT (Short-Time Fourier Transform); Least Squares Loss; attention mechanism

轴承是工业设备中关键的传动与支撑部件,其运行状态直接关系到整机的可靠性、稳定性和运行效率。轴承一旦发生故障,常导致设备停机甚至生产中断,造成较大经济损失。因此,开展有效的轴承故障诊断不

仅有助于减少意外停机时间、提升运行安全性与效率,还能延长设备使用寿命,降低运维成本。

近年来,人工智能的快速发展推动了智能故障诊断技术的精进,其中基于深度学习的方法因其强大的

收稿日期:2025-07-18;修回日期:2025-09-29

基金项目:陕西省自然科学基金(2025JC-YBMS-406)。

第一作者简介:柯斌(1999),男,硕士研究生,主要研究方向为故障诊断。E-mail:2535328386@qq.com

特征提取与建模能力受到广泛关注^[1]。深度学习能够从大量监测数据中自动学习故障特征,实现对振动信号的高效处理与精确识别,从而显著提升故障诊断的智能化水平^[2]。已有研究通过引入连续小波变换(Continuous Wavelet Transform, CWT)与卷积神经网络(Convolutional Neural Network, CNN)^[3]、融合 CNN 与长短时记忆网络(Long Short-Term Memory, LSTM)^[4]或采用半监督自编码器结构^[5],在轴承故障识别中取得一定成效。然而,这些方法普遍依赖大量带标签样本,而实际工况中故障数据采集困难,导致模型性能受到严重制约^[6]。

为缓解样本不足问题,近年来生成对抗网络(Generative Adversarial Network, GAN)^[7-8]被广泛用于故障样本生成与扩展,凭借其优秀的分布拟合能力,在小样本条件下表现良好。周建民等^[9]提出基于梯度惩罚的 Wasserstein GAN,用于不平衡数据下的故障样本生成。Meng 等^[10]提出了引入 Wasserstein 距离与权重惩罚的改进型辅助分类生成对抗网络(Auxiliary Classifier Generative Adversarial Network, ACGAN),有效提升生成样本质量与故障识别能力。刘迪洋等^[11]提出结合改进型深度卷积生成对抗网络与 Swin Transformer 的诊断方法,通过 CWT 转换与样本扩容提升分类性能,实现了高相似度样本生成与故障精准识别。尽管上述方法在样本扩展与小样本诊断方面取得进展,但在生成图像的多样性、细节保真度以及训练稳定性等方面仍存在改进空间,尤其在关键特征提取与分类精度方面仍有待提升。

针对上述问题,课题组提出一种融合注意力机制的改进辅助分类生成对抗网络(ACGAN)模型。首先,采用短时傅里叶变换(Short-Time Fourier Transform, STFT)将振动信号转换为时频图,增强特征表达能力;其次,以最小二乘损失替代传统 ACGAN 的对抗损失,以缓解梯度消失并提升训练稳定性;最后,在判别器中嵌入通道与空间注意力模块(Spatial Attention Module, SAM),引导模型聚焦于关键区域特征,从而提升生成样本质量与故障诊断性能。

1 理论背景

1.1 短时傅里叶变换

短时傅里叶变换 STFT 是一种常用的时频分析方

法,通过对信号施加滑动窗口并执行局部傅里叶变换,将一维振动信号转化为同时反映时间与频率特性的二维时频图。相比于一维信号,二维信号表示更适用于卷积神经网络 CNN 建模,有助于提取更加丰富的特征信息。STFT 的计算公式如下:

$$A(t, \omega) = \int_{-\infty}^{+\infty} s(t)g(t - u)e^{-j\omega u} dt. \quad (1)$$

式中: $A(t, \omega)$ 为短时傅里叶变换幅值; t 为振动信号的时间自变量; $s(t)$ 为振动信号; $g(t)$ 为窗函数; u 为窗函数的位置; ω 为频率。

STFT 所生成的时频图分辨率受时间分辨率与频率分辨率共同影响,合理配置二者有助于提升故障特征的表达能力并抑制噪声干扰。由于窗函数长度一经设定,时间分辨率与频率分辨率亦随之固定,使得 STFT 难以自适应不同频率成分的变化^[12]。因此,窗口长度的设定需结合信号特性与诊断需求。参考文献[13]的实验经验,课题组将窗口长度选为 256,重叠长度设为 250,以更有效地捕捉关键时频特征。

1.2 辅助分类生成对抗网络

在多类别故障诊断任务中,需针对不同故障类型生成具有标签控制的样本。因此,需将类别信息引入生成对抗网络中以提升其可控生成能力。辅助分类生成对抗网络(ACGAN)在传统生成对抗网络 GAN 架构基础上引入标签指导机制,通过在生成器中嵌入类别信息,并在判别器中同时进行真伪判别与类别预测,使网络能够生成与特定标签对应的故障样本,从而更好地满足多分类故障诊断对样本多样性与类别一致性的要求。辅助分类生成对抗网络结构如图 1 所示。




图 1 辅助分类生成对抗网络结构

Figure 1 ACGAN structure

1.3 注意力机制

卷积块注意力模块(Convolutional Block Attention Module, CBAM)是一种结构简单且性能优异的注意力

机制,适用于各类前馈卷积神经网络。该模块依次在通道维度和空间维度上推理生成注意力权重图,分别挖掘“重要通道信息”和“关键空间区域”。最终通过与原始特征图进行逐元素加权,实现对关键信息的增强与冗余特征的抑制,从而提升网络的特征表达能力与判别性能。卷积块注意力模块的结构如图 2 所示。CBAM 可概括为:

$$\left. \begin{aligned} F' &= M_c(F) \otimes F; \\ F'' &= M_s(F') \otimes F'. \end{aligned} \right\} \quad (2)$$

式中: F 和 F'' 分别为输入特征和最终输出的精炼特征; M_c 和 M_s 分别为一维通道注意力图和二维空间注意力图; \otimes 为逐元素乘法。




图 2 卷积注意力模块的结构

Figure 2 Structure of CBAM

2 ACGAN 改进方法

2.1 损失函数的改进

在辅助分类生成对抗网络中,生成器通过输入随机噪声向量 z 和类别标签 C 生成带标签图像,判别器则不仅需判断样本的真假(对抗任务),还需识别其类别(分类任务)。因此,ACGAN 的损失函数通常由对抗损失 L_S 和分类损失 L_C 这 2 部分组成。

$$L_S = E[\ln P(S = \text{real} | X_{\text{real}})] + E[\ln P(S = \text{fake} | X_{\text{fake}})]; \quad (3)$$

$$L_C = E[\ln P(C = c | X_{\text{real}})] + E[\ln P(C = c | X_{\text{fake}})]. \quad (4)$$

式中: S 为样本真实性标签; C 为样本类别标签; c 为样本的真实类别或生成时设定的类别; X_{real} 和 X_{fake} 分别为真实样本和生成样本; $E[\cdot]$ 为样本分布的期望; $P(S = \text{real} | X_{\text{real}})$ 为判别器判定真实样本为“真实”的概率; $P(S = \text{fake} | X_{\text{fake}})$ 为判别器判定生成样本为“伪造”的概率; $P(C = c | X_{\text{real}})$ 为判别器预测真实样本属于类别 c 的概率; $P(C = c | X_{\text{fake}})$ 为判别器预测生成样本属于类别 c 的概率。

判别器需同时优化 2 个目标,因此其损失为 $L_S + L_C$ 。而生成器的目标则是生成既被判别器判为真实,又能正确分类的样本,其损失为 $-L_S + L_C$ 。但传统 ACGAN 中对抗损失通常基于二元交叉熵(Binary Cross-Entropy, BCE)设计,虽能在训练初期提供有效梯度,但当判别器过于强大时,其输出趋近于 0 或 1,易造成梯度消失,影响生成器训练。

为解决该问题,在生成器与判别器中引入最小二乘损失(Least Squares Loss),通过最小化预测值与目标标签之间的均方误差,有效平滑梯度变化,提升训练过程的稳定性与收敛效率。改进后的损失函数如下:

$$L_D = \frac{1}{2} E_{x \sim P_{\text{real}}} [(D_S(x) - 1)^2] + \frac{1}{2} E_{z \sim P_z, c \sim P_c} \cdot [D_S(G(z, c))^2] - E_{x \sim P_{\text{real}}} [\ln P(C = c_r | x)] - E_{z \sim P_z, c \sim P_c} [\ln P(C = c | G(z, c))]; \quad (5)$$

$$L_G = \frac{1}{2} E_{z \sim P_z, c \sim P_c} [D_S(G(z, c)) - 1]^2 - E_{z \sim P_z, c \sim P_c} [\ln P(C = c | G(z, c))]. \quad (6)$$

式中: x 为真实样本; c_r 为真实样本的类别标签; D 和 G 分别为判别器和生成器; L_D 和 L_G 分别为判别器和生成器的总损失; $D_S(x)$ 为判别器对真实样本的输出; $D_S(G(z, c))$ 为判别器对生成样本的输出; P_{real} 为真实数据分布; P_z 和 P_c 分别为噪声和类别标签的分布; $P(C = c | G(z, c))$ 为判别器对生成样本的类别预测概率; $P(C = c_r | x)$ 为判别器对真实样本的类别预测概率; $E_{x \sim P_{\text{real}}}$ 为真实数据分布的数学期望; $E_{z \sim P_z, c \sim P_c}$ 为潜在变量分布与类别标签分布的联合期望。

2.2 模型结构设计

生成器网络结构如图 3 所示,输入为 100 维随机噪声向量与对应故障类别标签。标签经嵌入层向量化后与噪声向量进行逐元素相乘,实现类别信息的融合与控制。融合后的潜在向量经全连接层映射为高维特征,并重塑为初始特征图。随后通过 4 层转置卷积模块逐步上采样,恢复图像空间结构。除最后一层外,各转置卷积层均配备批归一化与 LeakyReLU 激活函数,以增强非线性建模能力并加快训练收敛。最后一层采用 Tanh 激活函数,输出尺寸为 $64 \times 64 \times 1$ 的灰度图像,确保像素值归一化于 $[-1, 1]$,提升生成图像质量与稳定性。生成器的结构参数如表 1 所示。




图 3 生成器网络结构

Figure 3 Generator network structure

表 1 生成器的结构参数

Table 1 Generator structure parameters

网络层	结构参数	输出尺寸
Dense	(16 384)	(4 × 4 × 1 024)
ConvT1	(512, 4, 2)	(8 × 8 × 512)
ConvT2	(256, 4, 2)	(16 × 16 × 256)
ConvT3	(128, 4, 2)	(32 × 32 × 128)
ConvT4	(1, 4, 2)	(64 × 64 × 1)

判别器网络结构如图 4 所示,输入为尺寸为 64 × 64 × 1 的单通道灰度图像,依次经过 4 组卷积模块完

成特征提取与逐层下采样。每个模块均由 3 × 3 卷积层、LeakyReLU 激活函数和 Dropout 组成,以增强特征表达能力并降低过拟合风险。为强化模型对关键区域特征的感知能力,在第 2、第 3 和第 4 卷积模块后引入卷积注意力模块 CBAM,实现更精细的判别特征建模。最终提取的高维特征经展平后分别输入至 2 个全连接分支:1 支采用 sigmoid 激活函数输出真实性概率,另 1 支通过 softmax 实现多类故障的辅助分类。判别器的结构参数如表 2 所示。




图 4 判别器的网络结构

Figure 4 Discriminator network structure

表 2 判别器的结构参数

Table 2 Discriminator structure parameters

网络层	结构参数	输出尺寸
Conv1	(64, 3, 2)	(32 × 32 × 64)
Conv2	(128, 3, 2)	(16 × 16 × 128)
Conv3	(256, 3, 2)	(8 × 8 × 256)
Conv4	(512, 3, 2)	(4 × 4 × 512)
Flatten	-	(8 192)
Linear(真假)	-	1
Linear(类别)	-	7

在 3 种不同负载工况(功率为 0, 200 和 400 W)下采集的原始振动信号,共计 99 组数据,采样频率为 51.2 kHz,持续采集时间为 10 s。数据涵盖 6 种典型故障类型,包括内圈裂纹、外圈裂纹、滚动体裂纹及其两两组合。课题组选取负载功率为 200 W 条件下的 6206 型轴承作为研究对象,将其划分为 7 种运行模式,并采用滑窗重叠采样策略提取样本,窗口长度设置为 1 024,步长为 512。数据集的详细信息如表 3 所示。

3.2 模型性能比较与分析

为评估最小二乘损失对模型训练稳定性的影响,课题组对比了采用传统二元交叉熵(BCE)损失的传统 ACGAN 与引入最小二乘损失的改进型 ACGAN 在训练过程中的损失变化趋势。实验中,生成器与判别器

3 实验验证

3.1 数据集说明

实验采用 HUST 轴承数据集^[14],该数据集包含 6204 型、6205 型、6206 型、6207 型和 6208 型滚珠轴承

均使用自适应矩估计 (Adaptive Moment Estimation, ADAM) 优化器进行了独立训练,初始学习率设置为 0.000 2,批量大小为 32,训练迭代次数为 1 000。图 5 所示为 2 种损失函数配置下生成器与判别器的训练损失曲线。

表 3 HUST 数据集详细信息
Table 3 HUST dataset details

轴承状态	训练集	测试集	类别标签
正常	100	500	0
滚动体故障	100	500	1
内圈故障	100	500	2
外圈故障	100	500	3
内圈和滚动体故障	100	500	4
内圈和外圈故障	100	500	5
外圈和滚动体故障	100	500	6

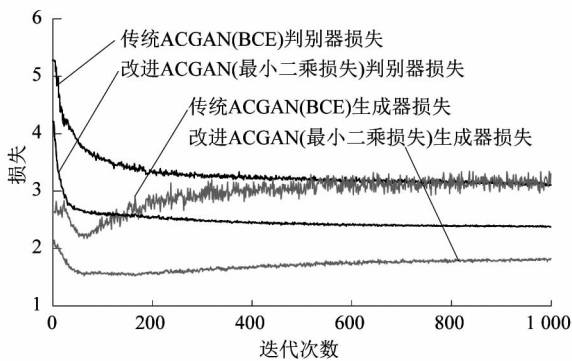


图 5 2 种损失函数配置下生成器与判别器的训练损失曲线

Figure 5 Training Loss curves of generator and discriminator under two loss function configurations

从图 5 可知,传统 ACGAN (BCE) 与改进 ACGAN (最小二乘损失) 在训练过程中的损失曲线呈现出明显差异。传统 ACGAN (BCE) 在训练初期虽能迅速降低损失,但随后波动较大,反映出模型训练不稳定;而引入最小二乘损失后的改进 ACGAN,无论在生成器还是判别器方向,损失曲线均表现出更平稳的下降趋势,波动幅度明显减小,其中生成器损失整体更低,表明其在捕捉真实数据分布方面更具优势,有效提升了训练稳定性与生成样本质量。

为系统评估 CBAM 模块在判别器中的最优嵌入策略,设计如表 4 所示的消融实验,分别对不同数量 (0~4 个) 及不同位置 (1~4 卷积层) 嵌入 CBAM 的配

置进行对比分析。实验以判别器在测试集上的分类性能为评估标准,采用精确率、召回率与 F1 分数共 3 项指标进行综合衡量,实验结果如表 5 所示。

从实验结果可知:未引入 CBAM 的基础模型 (实验 I) 在 3 项指标上表现良好,说明网络具备一定的判别能力,而合理嵌入 CBAM 模块可进一步提升性能;实验 VI 在第 2、第 3 和第 4 卷积层引入 CBAM 时,模型取得最高的精确率 (96.95%)、最高的召回率 (96.94%) 与最高的 F1 分数 (96.94%),显著优于其他配置,表明后层特征中引入注意力机制有助于模型聚焦关键区域、增强判别能力;相比之下,实验 VII 将 CBAM 嵌入全部 4 层卷积后性能反而下降,说明注意力模块的引入需适度,过多引入可能导致特征冗余或干扰,影响分类效果。故 CBAM 嵌入第 2、第 3 和第 4 卷积层为当前结构下的最优策略,在提升特征建模能力的同时兼顾网络稳定性与泛化性能。

表 4 CBAM 模块嵌入配置对比实验设计
Table 4 Experimental design of CBAM module embedding configurations contrast

实验编号	CBAM 模块数	插入位置
I	0	
II	2	1 层,2 层
III	2	2 层,3 层
IV	2	3 层,4 层
V	3	1 层,2 层,3 层
VI	3	2 层,3 层,4 层
VII	4	1 层,2 层,3 层,4 层

表 5 不同 CBAM 模块嵌入配置的判别性能评估结果对比

Table 5 Comparison of discriminant performance evaluation results for various CBAM module embedding configurations

实验编号	精确率/%	召回率/%	F1 分数/%
I	95.88	95.86	95.83
II	92.92	92.71	92.63
III	91.81	91.37	91.29
IV	90.05	89.60	89.46
V	90.87	90.43	90.27
VI	96.95	96.94	96.94
VII	90.39	90.20	90.20

3.3 生成样本质量评估

为验证所提方法生成图像的可视质量与故障特征表达能力,将7类典型故障样本的真实图像与对应的生成图像作对比,结果如图6所示。可以观察到:所生

成图像在整体结构上与真实图像保持高度一致,且具备良好的类别区分性,尤其在纹理分布与高频特征区域展现出较强的重构能力,表明改进 ACGAN 模型有效捕捉了不同类别故障的关键模式。




图6 7类典型故障样本的真实图像和对应的生成图像对比

Figure 6 Comparison of real images and corresponding synthetic images of 7 typical fault samples

为进一步量化生成样本的质量与真实性,课题组引入结构相似性指数 (Structural Similarity Index, SSIM) 与感知图像距离指标 (Learned Perceptual Image Patch Similarity, LPIPS) 对生成图像与真实图像进行配对评估。SSIM 从亮度、对比度和结构信息 3 个方面衡量图像之间的一致性,取值范围为 $[0, 1]$,值越大表示结构相似度越高;LPIPS 基于深度特征空间中图像间的感知距离进行衡量,数值越小代表生成图像在视觉感知上更接近真实图像。

实验中针对每类故障样本的生成图像分别计算对应的 SSIM 与 LPIPS 值,并取所有类别的平均值作为整体评价指标,评估结果如图 7 和图 8 所示。

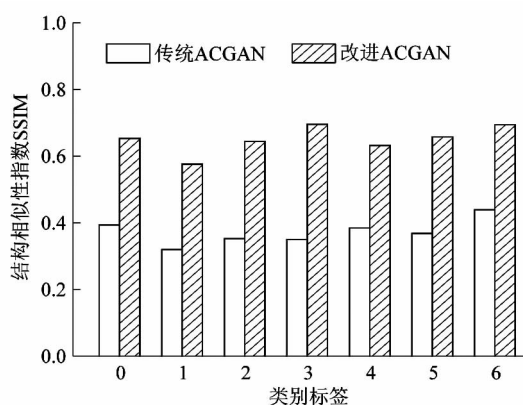


图 7 基于 SSIM 的生成图像质量评估

Figure 7 Quality assessment of generated images based on SSIM

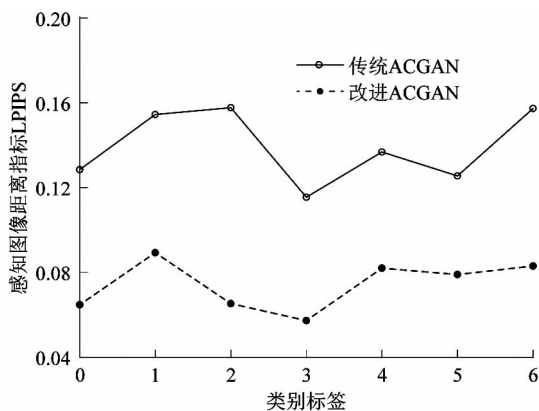


图 8 基于 LPIPS 的生成图像质量评估

Figure 8 Quality assessment of generated images based on LPIPS

由图 7 和图 8 可以看出改进 ACGAN 方法在 SSIM

上整体高于传统 ACGAN 方法,且在 LPIPS 上表现出更低的感知差异,表明所提出方法在保持图像结构一致性与提升感知质量方面具有明显优势。

3.4 故障网络分类训练

为验证所提出生成方法在少样本场景下的实用性,并系统评估其对故障诊断性能的提升效果,课题组在类别分布高度不平衡(故障样本与正常样本比例 r 分别为 1:5、1:10 和 1:20)条件下开展分类实验,以模拟实际工况中少数类样本难以获取的典型问题。针对训练集中样本稀缺的类别,采用改进 ACGAN 方法进行数据扩增,并基于典型卷积神经网络 (CNN) 完成故障识别任务,同时与多种主流故障诊断模型进行性能对比,分类结果如表 6 所示。

表 6 不同方法的故障分类准确率对比

Table 6 Fault classification accuracy comparison of different methods

方法	故障分类准确率/%		
	$r = 1:5$	$r = 1:10$	$r = 1:20$
改进 ACGAN	96.00	93.14	90.86
CNN	94.00	86.86	78.86
WLT-ACGAN	93.40	92.20	89.80
传统 ACGAN + CNN	93.60	91.60	86.00
STFT-SACGAN	91.20	85.90	83.30

从表 6 可以看出:随着样本不平衡程度的加剧,各方法的分类准确率均呈下降趋势;然而,课题组提出的改进 ACGAN 方法在所有不平衡条件下均取得最优结果,准确率分别达到 96.00%、93.14% 和 90.86%,在极端不平衡(故障样本与正常样本比例为 1:20)条件下仍显著优于其他对比模型。这充分体现了改进 ACGAN 方法在样本生成质量、类别分布控制以及故障特征区分能力方面的综合优势。

改进 ACGAN 法在不同故障样本与正常样本比例下的测试集混淆矩阵如图 9 所示,结果表明课题组提出的改进 ACGAN 方法通过高质量样本生成显著改善了少数类的识别能力,有效缓解了模型对多数类的学习偏置;即使在数据极度不平衡的条件下,仍能够保持较高的分类精度,体现出良好的鲁棒性与适应性。

4 结语

针对轴承故障样本稀缺对智能诊断模型性能的影响




图 9 改进 ACGAN 法在不同故障样本与正常样本比例下的测试集混淆矩阵

Figure 9 Test set confusion matrix of improved ACGAN method under different proportions of fault samples and normal samples

响,课题组提出了一种融合注意力机制的改进型辅助分类生成对抗网络(ACGAN)方法。该方法结合 STFT 时频转换、最小二乘损失函数及 CBAM 注意力模块,有效提升了故障特征表达能力和样本生成质量。实验

结果表明:在样本不平衡条件下,该方法显著提高了故障识别的准确率和模型稳定性;与传统 ACGAN 及单一特征提取方法相比,该方法在诊断精度和泛化能力上展现出显著优势。后续工作应着重于模型自适应能力优化及轻量化设计,以促进其在复杂实际工况中的广泛应用。

参考文献:

[1] LIM D H, KIM K S. Development of deep learning-based detection technology for vortex-induced vibration of a ship's propeller [J]. Journal of Sound and Vibration, 2022, 520: 116629.

[2] ZHANG T, LIU S L, WEI Y, et al. A novel feature adaptive extraction method based on deep learning for bearing fault diagnosis [J]. Measurement, 2021, 185: 110030.

[3] 骆东松, 王毅科, 王春梅. 基于时频图与卷积神经网络的滚动轴承故障诊断[J/OL]. 控制工程, 1-10 [2025-06-25]. <https://doi.org/10.14107/j.cnki.kzgc.20240405>.

[4] 陈保家, 陈学力, 沈保明, 等. CNN-LSTM 深度神经网络在滚动轴承故障诊断中的应用[J]. 西安交通大学学报, 2021, 55(6): 28-36.

[5] 陈仁祥, 张晓, 张旭, 等. 改进掩码自编码器的滚动轴承半监督故障诊断[J]. 仪器仪表学报, 2024, 45(1): 26-33.

[6] SHAO S Y, WANG P, YAN R Q. Generative adversarial networks for data augmentation in machine fault diagnosis [J]. Computers in Industry, 2019, 106: 85-93.

[7] ZHOU F N, YANG S, FUJITA H, et al. Deep learning fault diagnosis method based on global optimization GAN for unbalanced data [J]. Knowledge-Based Systems, 2020, 187: 104837. 1-104837. 19.

[8] 颜毅斌, 管俊杰, 吉天平. 数据驱动下基于改进生成对抗网络的滚动轴承故障诊断方法[J]. 机电工程技术, 2024, 53(5): 207-210.

[9] 周建民, 夏晓枫, 李家辉. 改进生成对抗网络的不平衡数据下轴承故障诊断[J]. 控制工程, 2025, 32(6): 1039-1048.

[10] MENG Z, LI Q, SUN D Y, et al. An intelligent fault diagnosis method of small sample bearing based on improved auxiliary classification generative adversarial network [J]. IEEE Sensors Journal, 2022, 22(20): 19543-19555.

[11] 刘迪洋, 张清华, 胡勤. 基于深度学习的轴承故障小样本扩容及智能诊断[J]. 机床与液压, 2025, 53(4): 10-18.

[12] 谢莹, 刘雪伟, 鲁振杰. 基于改进辅助分类生成对抗网络的小样本轴承故障诊断方法[J/OL]. 轴承, 1-12 [2025-07-03]. <https://link.cnki.net/urlid/41.1148.TH.20231220.1742.004>.

[13] TAO H F, WANG P, CHEN Y Y, et al. An unsupervised fault diagnosis method for rolling bearing using STFT and generative neural networks [J]. Journal of the Franklin Institute, 2020, 357(11): 7286-7307.

[14] THUAN N D, HONG H S. HUST bearing: a practical dataset for ball bearing fault diagnosis [J]. BMC Research Notes, 2023, 16(1): 138.