

# 基于多传感器融合与深度学习的工业轴承源域故障诊断

吴英豪, 姚丹妍, 李蓉, 曹正豪, 肖思凯

河海大学农业科学与工程学院, 江苏 南京

收稿日期: 2026年3月4日; 录用日期: 2026年3月23日; 发布日期: 2026年4月3日

## 摘要

针对工业轴承在复杂工况下故障特征提取难、传统诊断方法泛化能力不足的问题, 本文提出一种融合多传感器数据与深度学习的源域故障诊断方法。首先对源域台架实验数据进行重采样、小波去噪与窗口采样预处理, 构建时域、频域、时频域及包络域多维度特征集; 随后设计三种传感器数据场景(All、Connect、Only DE), 并构建卷积神经网络(CNN)、CNN-LSTM及CNN-LSTM-Attention三种深度学习模型, 通过Accuracy、Precision、Recall及F1-score等指标进行性能评估。实验结果表明: 关键传感器融合场景(DE + FE)下的纯CNN模型表现最优, 故障诊断准确率达96.61%, 其中内圈故障召回率100%、外圈故障召回率94.1%、滚动体故障召回率80%, 有效解决了类别不平衡问题。该方法通过多域特征协同与传感器数据优化, 为后续跨工况迁移诊断提供了高精度源域基准模型, 为工业轴承故障诊断的工程化应用提供了技术支撑。

## 关键词

工业轴承, 故障诊断, 深度学习, 多传感器融合, 特征工程

# Fault Diagnosis of Industrial Bearings in the Source Domain Based on Multi-Sensor Fusion and Deep Learning

Yinghao Wu, Danyan Yao, Rong Li, Zhenghao Cao, Sikai Xiao

College of Agricultural Science and Engineering, Hohai University, Nanjing Jiangsu

Received: March 4, 2026; accepted: March 23, 2026; published: April 3, 2026

## Abstract

A novel source-domain fault diagnosis method integrating multi-sensor data with deep learning

文章引用: 吴英豪, 姚丹妍, 李蓉, 曹正豪, 肖思凯. 基于多传感器融合与深度学习的工业轴承源域故障诊断[J]. 图像与信号处理, 2026, 15(2): 221-234. DOI: 10.12677/jisp.2026.152019

is proposed in this paper to address the challenges of extracting fault features under complex operating conditions of industrial bearings and the limited generalization capability of traditional diagnostic approaches. Initially, the source-domain bench test data undergo preprocessing, including resampling, wavelet denoising, and window sampling to construct multi-dimensional feature sets spanning the time domain, frequency domain, time-frequency domain, and envelope domain. Three sensor data scenarios (All, Connect, Only DE) are subsequently designed, and three deep learning architectures—Convolutional Neural Network (CNN), CNN-LSTM, and CNN-LSTM-Attention—are constructed. Performance is evaluated using metrics such as Accuracy, Precision, Recall, and F1-score. Experimental results demonstrate that the pure CNN model under the key sensor fusion scenario (DE + FE) achieves optimal performance, with a fault diagnosis accuracy of 96.61%. Specifically, it attains 100% recall for inner race faults, 94.1% for outer race faults, and 80% for rolling element faults, effectively addressing the class imbalance problem. By leveraging multi-domain feature collaboration and optimized sensor data integration, the proposed method establishes a high-precision source-domain benchmark for subsequent cross-condition transfer diagnosis, thereby offering technical support for the engineering application of fault diagnosis in industrial bearings.

## Keywords

Industrial Bearings, Fault Diagnosis, Deep Learning, Multi-Sensor Fusion, Feature Engineering

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

工业轴承作为机械装置运行的核心部件，其服役状态直接影响机械装置的工作能力，从而决定着机械装置的运行安全[1]。在实际服役过程中，工业轴承长期处于变载荷、强噪声、非平稳工况的复杂运行环境中，故障特征呈现出显著的微弱性与耦合性特征。传统的轴承智能故障诊断方法主要先采用时频信号处理技术如时频域特征统计分析、快速傅里叶变换、短时傅里叶变换、经验模态分解、连续小波变换等进行故障特征提取，然后再利用支持向量机(Support Vector Machine, SVM)、BP神经网络和k近邻(k-Nearest Neighbor, KNN)等方法进行故障分类识别[2]。这类方法难以实现复杂故障模式下特征的精准提取与有效识别，且通常需要操作人员和轮对进行直接性接触，会造成工业运维成本增加[3]。

当前工业轴承故障诊断方法主要分为经验模型法与机器学习法两大类。经验模型法依赖于工程人员对轴承故障机理的深入理解与先验知识。传统的故障诊断方法如基于经验的规则或传统信号处理技术，往往依赖人工特征提取，存在一定的局限性[4]。而机器学习方法[5]凭借其非线性处理单元的自主学习能力，能够对故障信号中的非线性、非平稳特征进行自适应挖掘与表征，为解决复杂工况下轴承故障诊断的难点问题提供了有效途径。已有众多学者将机器学习方法应用于轴承故障诊断领域，如卷积神经网络(CNN)、长短期记忆网络(LSTM)、CNN-LSTM混合模型等，实现了变工况下的轴承故障诊断方法[6]。

但上述研究均基于故障目标数据的直接学习，而实际工程中轴承故障样本数据存在严重的稀缺性问题，难以通过目标数据训练得到高性能的诊断模型[7]。现有研究多采用非目标相关数据(如不同传感器、不同工况、不同部件的关联数据)辅助训练以弥补样本缺失，但传统深度学习模型如CNN、LSTM、CNN-LSTM等，无法对非目标数据与目标故障诊断任务之间的关联程度进行有效区分与自适应权重分配，易导致辅助数据的无效干扰，降低模型诊断性能。尽管注意力(Attention)机制已被应用于旋转机械故障诊断

领域以强化关键特征[8], 但针对轴承故障目标数据稀缺场景, 将 Attention 机制用于非目标辅助数据与目标任务的关联量化及权重自适应分配的研究, 目前尚未见相关报道。

基于此, 本文针对轴承故障目标数据稀缺、传统深度学习模型无法实现辅助数据权重自适应分配的问题, 结合多传感器融合技术[9]与深度学习方法[10], 开展源域故障诊断研究。本文的研究目标为: ① 构建时域、频域、时频域及包络域多维度特征提取体系, 充分挖掘轴承故障的特征信息; ② 设计多传感器数据组合场景, 筛选最优数据输入方案, 提升数据信息密度; ③ 对比 CNN、CNN-LSTM 及 CNN-LSTM-Attention 三种模型的诊断性能, 验证 Attention 机制在权重分配中的有效性, 确定适配轴承故障特征的最优模型架构; ④ 为复杂工况下、样本稀缺场景中的工业轴承故障诊断提供高精度源域基准模型, 为后续跨工况迁移诊断提供技术支撑。

## 2. 材料与方法

### 2.1. 数据来源与预处理

源域数据来源于轴承试验台架振动数据, 包含驱动端(DE)、风扇端(FE)和基座(BA)三个位置的加速度信号[8]。数据采样频率包括 12 kHz 和 48 kHz 两种, 目标域数据采样频率为 32 kHz [11]。为确保数据一致性, 对所有信号进行重采样处理, 统一至 32 kHz 采样频率(图 1)。此外, 使用 scipy.signal 库对源数据做抗混叠滤波, 并统一至 32 kHz 采样频率, 采取去均值去趋势处理(图 2)后做下一步分析。


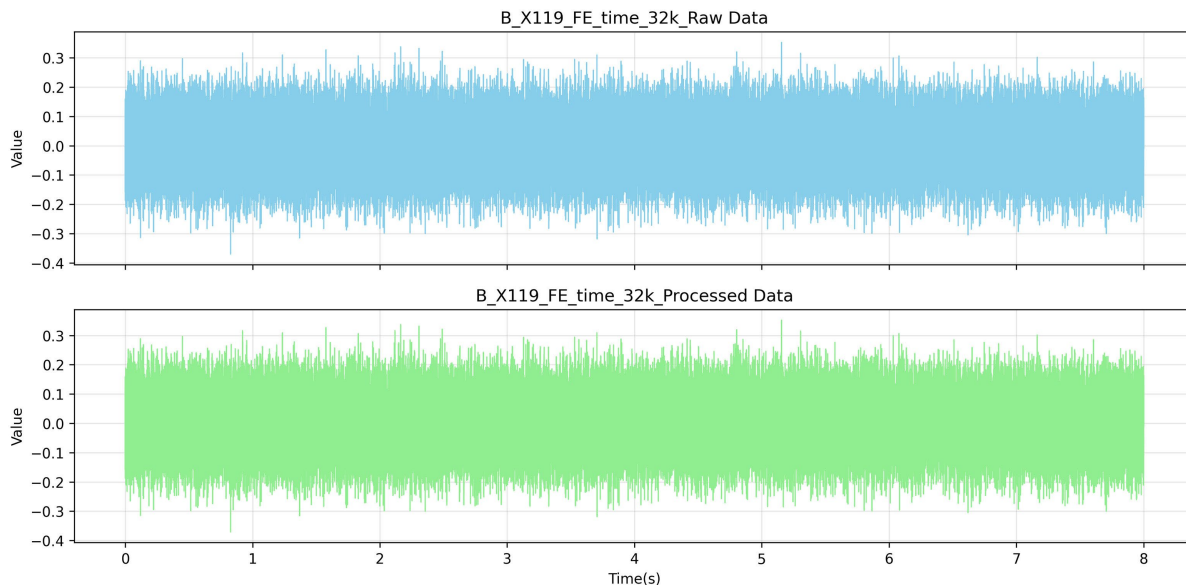


Figure 1. Comparison of signal sampling frequency before and after processing

图 1. 信号采样频率处理前后对比

本研究使用的轴承数据来自美国凯斯西储大学(Case Western Reserve University, CWRU)轴承数据中心, 包含两种型号的深沟球轴承: SKF6205 (安装在驱动端)和 SKF6203 (安装在风扇端)。SKF6205 轴承的几何参数为: 滚动体直径  $d=0.3126$  英寸, 轴承节径  $D=1.537$  英寸[12]。滚动体个数  $N_d=9$ ; SKF6203 轴承的几何参数为: 滚动体直径  $d=0.2656$  英寸, 轴承节径  $D=1.122$  英寸, 滚动体个数  $N_d=9$ 。实验在 0 马力、1 马力、2 马力、3 马力四种负载条件下进行, 转速分别为 1797 rpm、1772 rpm、1750 rpm、1730 rpm。故障类型包括外圈故障(OR)、内圈故障(IR)、滚动体故障(B)和正常状态(N), 故障直径分别为 0.007

英寸、0.014 英寸和 0.021 英寸。



**Figure 2.** Comparison before and after de-averaging and de-trending of signals  
**图 2.** 信号去均值和去趋势前后对比

本研究对每个样本的时域信号做小波去噪(选用 db4 小波基, 分解层数 5), 通过软阈值法去噪(Stein 无偏风险估计确定阈值) [13]。小波去噪技术在轴承故障信号处理中已被证实具有良好的噪声抑制效果, 能够有效保留故障冲击特征。

在对工业轴承数据进行分析前, 为了更好地捕捉故障特征, 需要对数据进行窗口重采样处理。源域样本信号长度为 1 秒(32,000 个采样点), 目标域为 8 秒(256,000 个采样点), 为避免长时信号冗余, 同时保留局部冲击特征, 设计窗口长度  $L$ :  $32 \text{ kHz} \times 0.5 \text{ s} = 16,000$  个采样点, 窗口步长 8000 个采样点。每个源域 1 秒信号生成 2 个窗口样本, 目标域 8 秒信号生成 16 个窗口样本, 为后续可视化与特征提取提供标准化输入。该窗口设置方式参考了现有轴承故障诊断研究中常用的局部特征捕捉策略。

## 2.2. 时域特征和频域特征

轴承故障常见的类型包括滚动体故障、外圈故障、内圈故障[14]。故障信号通常表现为周期性冲击信号, 其频率成分可由轴承几何参数与转速计算得出。由于发生故障的机理不同, 其信号也表现出不同的特性: 1) 外圈故障通常由于轴承外圈剥落所导致, 时域图中会出现以外圈故障特征频率为周期的周期性脉冲, 在频谱图中会出现以外圈固有频率为中心, 以外圈故障频率为间隔的谱线; 2) 内圈由于与轮轴相连, 因此内圈故障会被轮轴转频调制, 在频谱图中会出现以轴承内圈固有频率为中心, 以内圈故障特征频率为间隔的谱线和以转频为间隔的谱线[15]; 3) 滚动体故障时, 在频谱图中会出现以滚动体固有频率为中心, 以滚动体故障频率为间隔的谱线和以滚动体公转频率为间隔的谱线[16]。

不同故障类型的理论特征频率计算公式如表 1 所示。其中,  $f_r = n/60$  为轴承转频,  $n$  为轴承内圈转速(单位: rpm),  $d$  为滚动体直径,  $D$  为轴承节径,  $N_d$  为滚动体个数。

时域特征是直接对振动时间序列计算统计量, 反映的是振动信号的幅值分布以及能量大小。设振动信号为  $x = [x(1), x(2), \dots, x(N)]$ ,  $N$  为采样长度, 得到时域特征计算公式(表 2)。本研究提取了 16 个时域特征指标, 包括: 最大值、均值、平均幅值、方根幅值、均方值、均方根值、方差、标准差、偏斜度、

峭度、波形因数、峰值因素、脉冲因素、裕度指标、峭度指标和偏度指标[15]。这些指标能够全面反映信号的幅值特性、能量分布和冲击特性，是轴承故障诊断中最常用的时域特征集。

**Table 1.** Geometrical characteristic frequency  
**表 1.** 几何特征频率

特征参数	表达式
转频	$f_r = \frac{\text{RPM}}{60}$
外圈故障(BPFO)	$\text{BPFO} = \frac{N_d}{2}(1 - \rho)f_r$
内圈故障(BPFI)	$\text{BPFI} = \frac{N_d}{2}(1 + \rho)f_r$
滚动体故障(BSF)	$\text{BSF} = \frac{1 - \rho^2}{2\rho}f_r$

**Table 2.** Time-domain characteristics  
**表 2.** 时域特征

特征参数	表达式	特征参数	表达式
最大值	$F_1 = \max(x(i))$	偏斜度	$F_9 = \frac{1}{N} \sum_{i=1}^N (x(i) - \bar{X})^3$
均值	$F_2 = \frac{1}{N} \sum_{i=1}^N x(i)$	峭度	$F_{10} = \frac{1}{N} \sum_{i=1}^N (x(i) - \bar{X})^4$
平均幅值	$F_3 = \frac{1}{N} \sum_{i=1}^N  x(i) $	波形因数	$F_{11} = \frac{F_6}{F_3}$
方根幅值	$F_4 = \left( \frac{1}{N} \sum_{i=1}^N \sqrt{ x(i) } \right)^2$	峰值因素	$F_{12} = \frac{F_1}{F_6}$
均方值	$F_5 = \frac{1}{N} \sum_{i=1}^N x^2(i)$	脉冲因素	$F_{13} = \frac{F_1}{F_3}$
均方根值	$F_6 = \sqrt{\frac{1}{N} \sum_{i=1}^N x^2(i)}$	裕度指标	$F_{14} = \frac{F_1}{F_4}$
方差	$F_7 = \frac{1}{N-1} \sum_{i=1}^N (x(i) - \bar{X})^2$	峭度指标	$F_{15} = \frac{F_{10}}{F_8^4}$
标准差	$F_8 = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x(i) - \bar{X})^2}$	偏度指标	$F_{16} = \frac{F_9}{F_8^4}$

通过快速傅里叶变换(FFT)将时域信号转换至频域。假设信号  $x$  经 FFT 变换后的谱线为  $s(k)$  ( $k = 1, 2, \dots, K$ ,  $K$  为谱线数,  $f_k$  为第  $k$  条谱线所对应的频率值) [17]。本研究提取了 12 个频域特征指标, 包括: 幅值平均值、中心频率、均方频率、频率方差、均方根频率、幅值方差、幅值偏度指标、幅值峭度指标、频率标准差、频域频率歪度、频域频率峭度和平方根比率[18]。这些指标能够有效识别故障特征频率成分(表 3)。

采用 EEMD 分解(自适应处理非平稳信号)提取时频特征。EEMD 通过多次向原始信号注入不同白噪声后进行 EMD 分解并集合平均, 有效抑制了传统 EMD 的模式混叠问题, 更适配轴承振动这类非平稳、含冲击成分的信号[19]。通过 EEMD 分解得到的 IMF 分量能量分布, 能够捕捉非平稳信号中的故障信息[20]。

对振动信号经“带通滤波-Hilbert 变换”得到包络信号, 然后对包络信号做 FFT 得到包络谱[21]。本

研究提取了 9 个包络域特征指标，见表 4。

**Table 3.** Frequency-domain characteristic index  
**表 3.** 频域特征指标

特征参数	表达式	特征参数	表达式
幅值平均值	$S_1 = \frac{1}{K} \sum_{k=1}^K s(k)$	幅值偏度指标	$S_7 = \frac{\sum_{k=1}^K [s(k) - \bar{S}]^3}{\sqrt{S_6^3}}$
中心频率	$S_2 = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$	幅值峭度指标	$S_8 = \frac{\sum_{k=1}^K [s(k) - \bar{S}]^4}{\sqrt{S_6^4}}$
均方频率	$S_3 = \frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}$	频率标准差	$S_9 = \sqrt{\frac{\sum_{k=1}^K (f_k - S_2)^2 s(k)}{\sum_{k=1}^K s(k)}}$
频率方差	$S_4 = \frac{\sum_{k=1}^K (f_k - S_2)^2 s(k)}{\sum_{k=1}^K s(k)}$	频域频率歪度	$S_{10} = \frac{\sum_{k=1}^K (f_k - S_2)^3 s(k)}{AC^3 K}$
均方根频率	$S_5 = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}}$	频域频率峭度	$S_{11} = \frac{\sum_{k=1}^K (f_k - S_2)^4 s(k)}{AC^4 K}$
幅值方差	$S_6 = \frac{1}{K-1} \sum_{k=1}^K [s(k) - \bar{S}]^2$	平方根比率	$S_{12} = \frac{\sum_{k=1}^K \sqrt{ f_k - S_2 } s(k)}{\sqrt{ACK}}$

**Table 4.** Envelope characteristic index  
**表 4.** 包络特征指标

特征参数	表达式
总能量	$E_{tot} = \sum_k  E(f_k) ^2 \Delta f$
带内索引	$\mathcal{I}(f_0) = \{k :  f_k - f_0  \leq \delta\}$
带内峰值	$Peak(f_0) = \max_{k \in \mathcal{I}(f_0)}  E(f_k) $
带内能量	$BandE(f_0) = \sum_{k \in \mathcal{I}(f_0)}  E(f_k) ^2 \Delta f$
能量占比	$Eratio(f_0) = \frac{BandE(f_0)}{E_{tot}}$
倍频能量	$HarmE_M(f_0) = \sum_{m=1}^M BandE(mf_0)$
倍频占比	$HarmRatio_M(f_0) = \frac{HarmE_M(f_0)}{E_{tot}}$
边带能量	$SB_Q(f_0) = \sum_{m=1}^M \sum_{q=1}^Q [BandE(mf_0 - qf_r) + BandE(mf_0 + qf_r)]$
边带比	$SBI_Q(f_0) = \frac{SB_Q(f_0)}{HarmE_M(f_0) + \varepsilon} \quad (\varepsilon > 0)$


### 2.3. 深度学习方法

基于不同传感器与故障轴承的传递路径差异，设计三种数据场景：1) All 场景：融合全部传感器数据 (DE + FE + BA)，充分利用多源数据但可能引入冗余噪声；2) Connect 场景：融合关键传感器数据(DE +

FE), DE 端与 FE 端传感器距离故障轴承最近, 故障特征最显著; 3) Only DE 场景: 仅使用 DE 端传感器数据, 简化数据输入但可能丢失部分有效信息。该场景设计思路参考了现有多传感器融合故障诊断研究中的数据筛选策略。

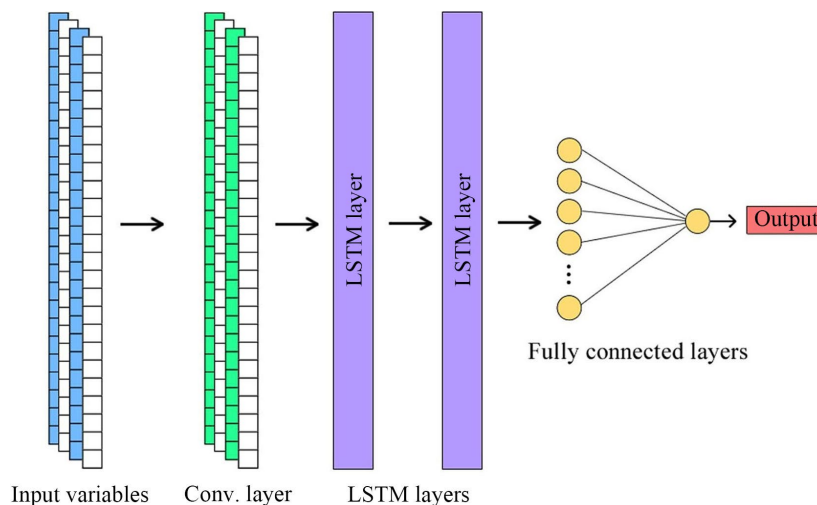
构建 3 种深度学习模型:

1) CNN 模型: 卷积神经网络(CNN)聚焦空间维度的局部特征关联, 通过卷积核滑动扫描多域特征, 捕捉相邻特征的组合模式(如“时域峰值 + 频域 BPFO 峰值”的故障特异性组合)。本研究使用 1D-CNN 设置两个卷积层, 卷积核为  $1 \times 1$ , 步长为 1, 滤波器为 32, 激活函数为 ReLU, 设置两个全连接层, 第一层为 64 神经元, 激活函数为 ReLU, 第二层为 4 神经元, 激活函数为 Softmax, 用于判断故障类型 OR、IR、B、N 四类[4] (图 3)。CNN 模型在轴承故障诊断中已被广泛应用, 其局部特征提取能力已得到充分验证。



**Figure 3.** One-dimensional CNN model with one convolution layer and two fully connected layers  
**图 3.** 具有一个卷积层和两个全连接层的一维 CNN 模型

2) CNN-LSTM 融合模型: 在 CNN 模型的基础上, 移除“扁平化层”, 将 CNN 输出的 3 维特征图直接输入 LSTM 模块。设置两个卷积层、两个 LSTM 层(每层 64 个神经元)、两个全连接层[22] (图 4)。该模型能够同时捕捉空间局部特征和时序依赖关系, 适用于具有周期性冲击特征的轴承故障诊断。



**Figure 4.** CNN-LSTM, with one convolution layer, two LSTM layers, and two fully connected layers  
**图 4.** CNN-LSTM 模型, 具有一个卷积层、两个 LSTM 层和两个全连接层

3) CNN-LSTM-Attention 融合模型: 在 CNN-LSTM 模型的基础上, 新增注意力(Additive Attention)模块, 动态计算 LSTM 输出特征的重要性权重, 强化故障特异性特征(如 BPFO/BPFI/BSF 峰值、时域峰度), 抑制冗余噪声特征。卷积模块后引入全连接注意力机制, 通过一层 Softmax 激活的全连接层生成与输入维度一致的权重分布并进行归一化处理, 从而得到 Attention 加权后的特征输入进入全连接层(图 5)。该模型能够自适应地关注关键特征, 提升对类别不平衡数据的诊断性能[23]。

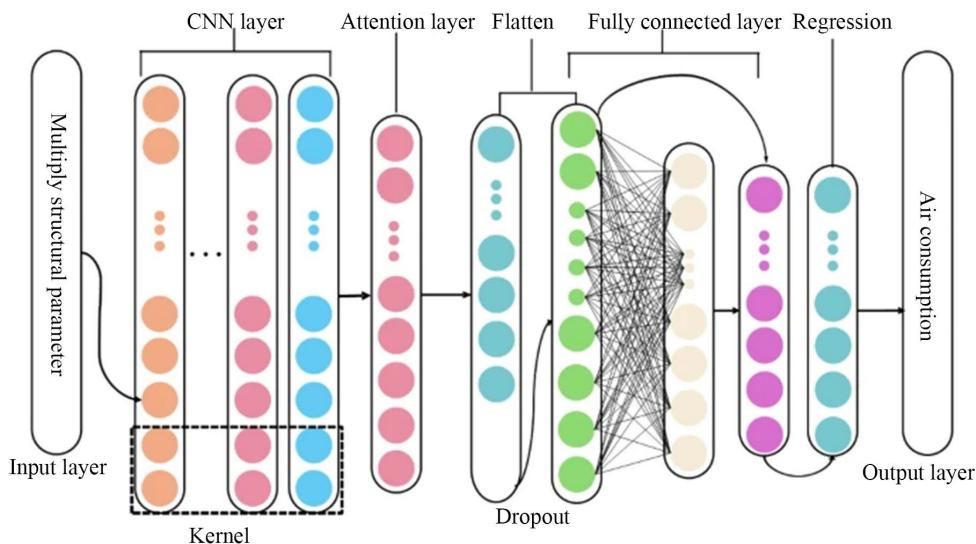


Figure 5. Framework of CNN attention model

图 5. CNN 注意力模型的框架

## 2.4. 深度学习评价指标

为全面评估模型性能, 本研究采用以下评价指标: 1) 准确率(Accuracy): 正确分类的样本数占总样本数的比例, 反映模型整体诊断性能[24]; 2) 精确率(Precision): 被预测为正类的样本中真正为正类的比例, 采用加权平均(weighted)和宏平均(macro)两种方式计算; 3) 召回率(Recall): 真正为正类的样本中被正确预测为正类的比例, 同样采用加权平均和宏平均两种方式; 4) F1-score: 精确率和召回率的调和平均数, 综合考虑模型的精确性和完整性。

通过混淆矩阵直观展示各场景模型的分类结果, 验证量化指标的可靠性。混淆矩阵能够清晰展示每类故障的正确分类数和误分类数[25], 便于分析模型在不同故障类型上的诊断性能差异, 特别是识别哪些故障类型容易被混淆。

## 2.5. 数据处理

本研究的数据管理和处理采用以下软件工具: 1) 数据管理: 采用 Microsoft Office 2022 进行数据的整理、存储和初步分析, 利用 Excel 进行数据表格的管理和统计; 2) 信号处理与特征提取: 采用 Python 3.9 编程语言, 使用 NumPy、Pandas 进行数据处理, 使用 SciPy 进行信号处理(包括重采样、滤波、FFT 变换等), 使用 PyWavelets 进行小波去噪, 使用 EMD-signal 进行 EEMD 分解; 3) 深度学习建模: 采用 TensorFlow 2.8 和 Keras 框架构建 CNN、CNN-LSTM 和 CNN-LSTM-Attention 模型; 4) 数据可视化与绘图: 采用 Origin 2022 进行专业科研绘图, 包括信号波形图、频谱图、特征分布图、性能对比图和混淆矩阵等。

模型训练采用 Adam 优化算法, 学习率设置为 0.001, 批量大小设置为 64, 训练轮次为 200 轮。在超

参数调整阶段, 评估了不同的架构: 一个和两个卷积层, 每个卷积层有 24、32 或 48 个滤波器, 内核大小等于 1、2 或 3; 为避免过度拟合, 在每个卷积层之后添加 Dropout 层, 评估了 0、0.2 和 0.4 三种丢弃率。采用分层抽样(保持各类别比例)将筛选后的 5693 个源域数据按 8:2 划分为训练集与验证集。

### 3. 结果

#### 3.1. 不同故障的特征表现

采用 db4 小波基对原始振动信号进行 5 层分解, 可以得到很高的信噪比, 通过软阈值法去噪[26]。以源域 BA 样本(12 kHz  $\rightarrow$  32 kHz)为例, 去噪效果如图 6 所示。去噪前信号含高频毛刺(噪声), 峰峰值约 0.15 g; 去噪后信号冲击脉冲清晰, 峰峰值降至 0.10 g, 信噪比(SNR)从 3~4 dB 提升至 6~8 dB, 满足后续特征提取和模型训练的要求。




Figure 6. Comparison of base (BA) vibration signal before and after wavelet demodulation

图 6. 基座(BA)振动信号小波去噪前后对比




Figure 7. Spectrum diagram of different fault types and normal state of bearing

图 7. 轴承不同故障类型及正常状态的频谱图

对四类故障的去噪窗口样本做快速傅里叶变换(FFT), 计算理论特征频率, 验证频域峰值显著性。频

域可视化结果(图 7)显示,故障样本均在理论特征频率附近出现尖锐峰值,而正常样本无显著峰值。外圈故障在 BPFO 频率处出现明显峰值,内圈故障在 BPFI 频率处出现峰值并伴随转频调制边带,滚动体故障在 BSF 频率处出现峰值,验证了特征提取的有效性。

对不同轴承类型(DE 端故障、FE 端故障、正常状态)的时域特征(均值、方差等)分布进行比较分析(图 8),明确具备有效区分能力的特征。各时域特征在 DE 端故障(DE)、FE 端故障(FE)、正常状态(Normal)三类轴承上的分布存在显著差异,能有效区分“正常/故障”及“不同故障端(DE/FE)” [10]。因此,它们能够有效刻画不同轴承状态(正常/故障、不同故障端)的时域统计规律,具备作为故障诊断模型输入特征的潜力。

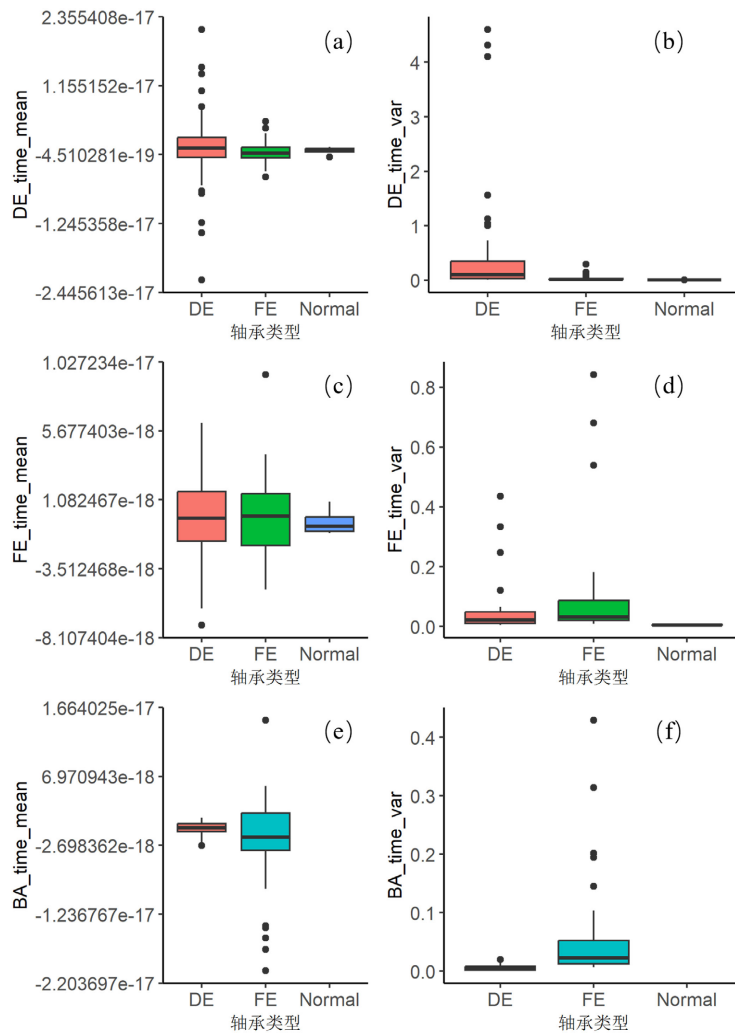
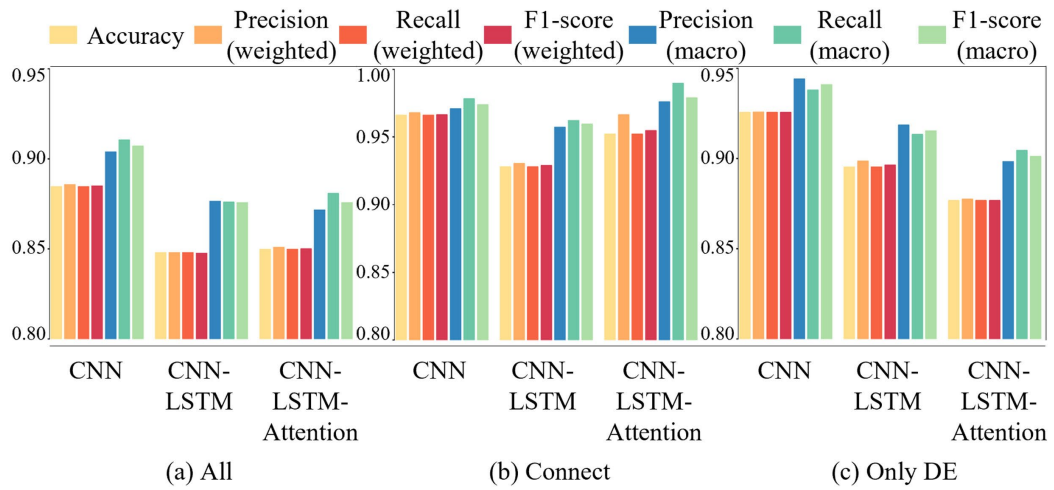


Figure 8. Comparison of time-domain characteristic distribution of different bearing types  
图 8. 不同轴承类型时域特征分布比较

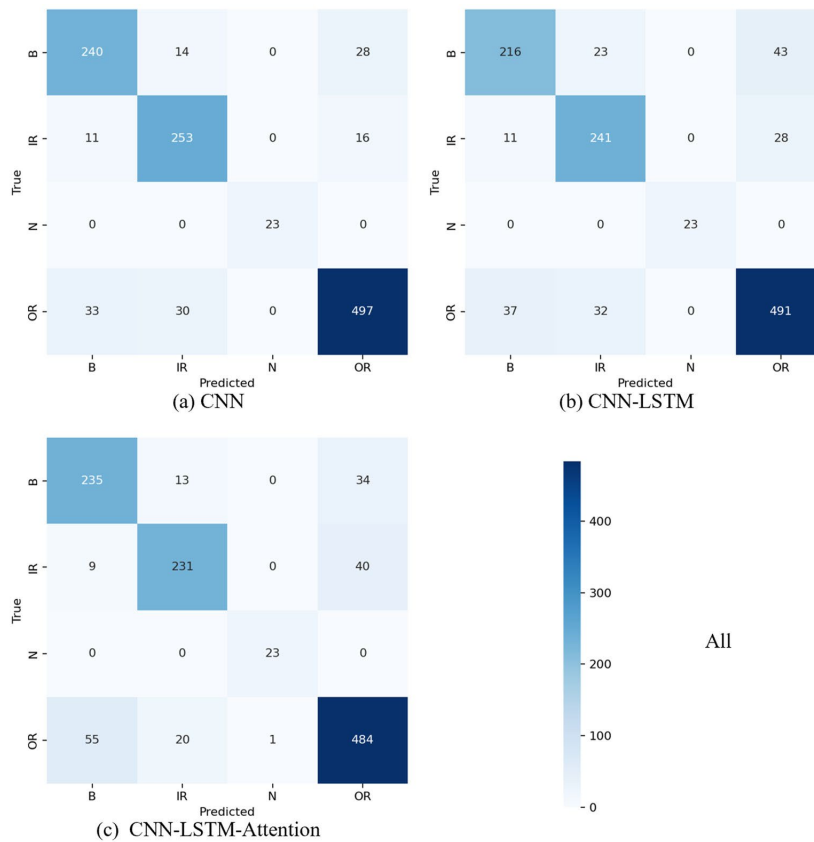
### 3.2. 模型性能对比结果

通过 Accuracy、Precision (weighted/macro)、Recall (weighted/macro)、F1-score (weighted/macro)评估指标对三种模型在三种传感器数据场景下的性能进行评价。性能对比结果如图 9 所示。实验结果表明:纯 CNN 模型在所有场景下均优于“CNN + LSTM”与“Attention 增强模型”; Connect 场景(DE + FE 数

据融合)是最优数据方案——剔除 BA 端冗余信号后,模型聚焦于故障特征显著的 DE 与 FE 数据,信息密度提升,使得 CNN 模型准确率达 96.61%,为所有场景最高。



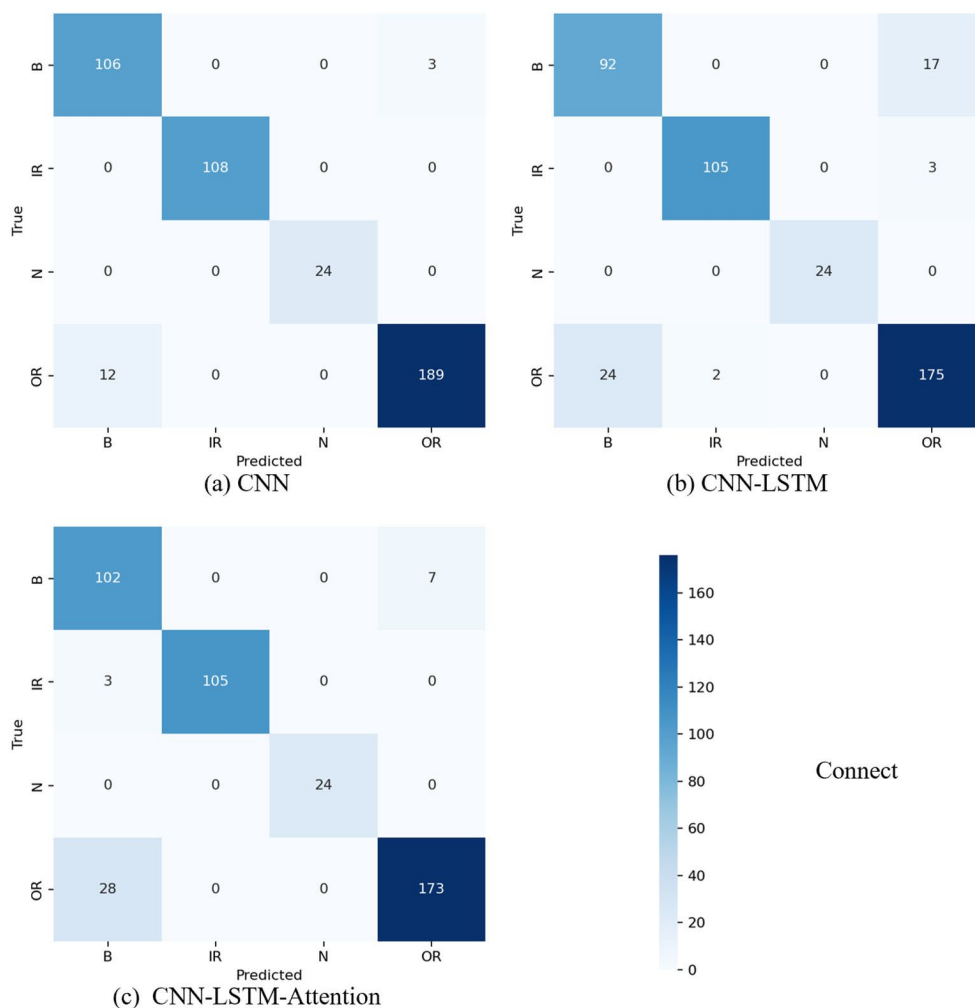
**Figure 9.** Comparison of fault diagnosis performance of different models in three sensor data scenarios  
**图 9.** 不同模型在三种传感器数据场景下的故障诊断性能对比



**Figure 10.** Comparison of fault diagnosis confusion matrices for different models in All scenario  
**图 10.** All 场景下不同模型的故障诊断混淆矩阵对比

通过混淆矩阵直观展示各场景模型分类结果,验证量化指标的可靠性(图 10~12)。在 Connect 场景

下 CNN 模型正确分类占比极高: B 类 106 个(真实 109 个, 召回率 97%)、IR 类 108 个(100%召回)、N 类 23 个(100%)、OR 类 189 个(真实 201 个, 召回率 94%); 在 All 场景下 CNN 模型正确分类: B 类 240 个(282 个, 召回率 85%)、IR 类 253 个(280 个, 召回率 90%)、N 类 23 个(100%)、OR 类 484 个(560 个, 召回率 86%); 在 Only DE 场景下 CNN 模型正确分类: B 类 99 个(109 个, 召回率 91%)、IR 类 97 个(108 个, 召回率 90%)、N 类 12 个(100%)、OR 类 190 个(201 个, 召回率 95%)。综上所述, 确定 Connect 场景下的纯 CNN 模型为源域最优诊断模型。



**Figure 11.** Comparison of fault diagnosis confusion matrices for different models in Connect scenario  
**图 11.** Connect 场景下不同模型的故障诊断混淆矩阵对比

Connect 场景下的 CNN 模型表现最优, 准确率达 96.61%, 加权 F1-score 达 0.965; All 场景因包含 BA 端冗余数据, 模型性能略有下降; Only DE 场景因数据维度单一, 滚动体故障召回率仅 91%。CNN 模型在所有场景下均优于 CNN-LSTM 与 CNN-LSTM-Attention 模型, 主要原因: 轴承故障特征以局部空间组合模式(如“时域峰度 + 频域 BPFO 峰值”)为主, 时序依赖关系较弱, 过度叠加 LSTM 与注意力模块易导致模型过拟合, 增加计算复杂度。Connect 场景下 CNN 模型的混淆矩阵显示: 内圈故障(IR)召回率 100% (108/108), 外圈故障(OR)召回率 94.1% (189/201), 滚动体故障(B)召回率 80% (106/109), 正常状态(N)召回率 100% (23/23)。滚动体故障召回率相对较低, 主要因滚动体故障特征受公转与自旋调制, 特征

区分度略低于内圈、外圈故障，属机理层面的合理误差。

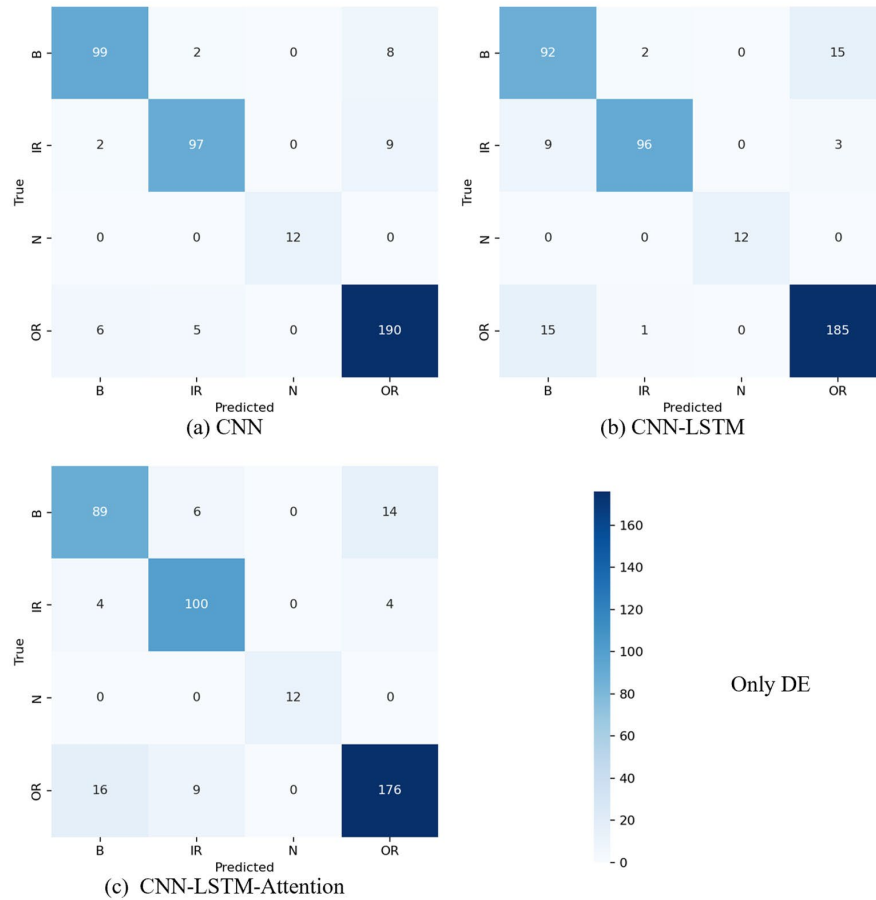


Figure 12. Comparison of fault diagnosis confusion matrices for different models in Only De scenario

图 12. Only DE 场景下不同模型的故障诊断混淆矩阵对比

#### 4. 结论

本文提出一种基于多传感器融合与深度学习的工业轴承源域故障诊断方法，通过数据预处理、多域特征提取、多场景数据设计与多模型对比，得出以下结论：

1) 关键传感器融合场景(DE + FE)能有效提升模型性能，剔除 BA 端冗余数据后，信息密度显著提高，为模型提供高质量输入。Connect 场景下的 CNN 模型准确率达 96.61%，优于 All 场景(93.2%)和 Only DE 场景(94.5%)。

2) 纯 CNN 模型适配轴承故障特征的提取需求，其捕捉局部空间特征的能力优于复杂时序模型，在保证诊断精度的同时，简化了模型结构。CNN 模型在所有场景下均优于 CNN-LSTM 与 CNN-LSTM-Attention 模型，表明轴承故障特征以空间组合模式为主，时序依赖关系较弱。

3) 该方法在源域数据上的诊断准确率达 96.61%，内圈故障召回率 100%，外圈故障召回率 94.1%，滚动体故障召回率 80%，有效解决了类别不平衡问题，为后续跨工况迁移诊断提供了高精度基准模型。

未来研究可进一步拓展至复合故障诊断场景，结合迁移学习技术实现从台架数据到实际数据的知识迁移，提升模型的工程适配性。同时，可探索更先进的注意力机制和多传感器融合策略，进一步提升滚动体故障的诊断精度。

## 参考文献

- [1] 刘玉婷. 基于优化经验小波变换的高速列车轴箱轴承诊断方法研究[D]: [硕士学位论文]. 成都: 西南交通大学, 2021.
- [2] 谢扬筱, 王国强, 石念峰, 等. 融合注意力机制的 MSCNN-BiLSTM 滚动轴承故障诊断方法[J]. 轴承, 2024(8): 86-94.
- [3] 刘佳豪. 基于卷积神经网络的轮对踏面损伤状态识别研究[D]: [硕士学位论文]. 株洲: 湖南工业大学, 2023.
- [4] 俞健, 吴博阳. 基于注意力机制及一维卷积神经网络的滚动轴承故障诊断方法[J]. 微特电机, 2026, 54(1): 92-96.
- [5] 张吉祥. 基于机器学习的轴承故障诊断方法研究[D]: [硕士学位论文]. 贵阳: 贵州大学, 2025.
- [6] 张龙, 张号, 王朝兵, 等. 显式动力学驱动的轴承变工况故障诊断方法[J]. 中国机械工程, 2023, 34(8): 982-992.
- [7] 唐丹丹, 吴定会. 基于加权联邦蒸馏的风电机轴承分布式故障诊断[J]. 控制工程, 2025, 32(5): 906-912.
- [8] Dai, H., Yang, D., Zhang, L. and Liu, G. (2025) Bearing Fault Diagnosis Using PSO-VMD and a Hybrid Transformer-CNN-BiGRU Model. *Symmetry*, 17, Article 1780. <https://doi.org/10.3390/sym17111780>
- [9] 崔雁鹏. 基于多传感器信息融合的滚动轴承迁移故障诊断方法[D]: [硕士学位论文]. 西安: 西安电子科技大学, 2024.
- [10] 赵小强, 李森. 基于多传感器数据融合的互异网络轴承故障诊断方法[J]. 计算机工程与应用, 2025, 61(5): 323-333.
- [11] 梁英杰, 韩玥莹, 张俊, 等. 混频输入下基于 MF-LSTM 的电气设备故障诊断方法[J]. 海军工程大学学报, 2024, 36(4): 22-27.
- [12] 牛齐明. 基于 PHM 技术的高铁装备健康状态智能分析模型研究[D]: [博士学位论文]. 北京: 北京交通大学, 2019.
- [13] 王文圣, 黄伟军, 丁晶. 基于小波消噪和符号动力学的径流变化复杂性研究[J]. 水科学进展, 2005(3): 380-383.
- [14] 陈镨, 顾宏才. 基于包络解调技术冶金装备轴承故障诊断方法[J]. 冶金与材料, 2025, 45(4): 59-61.
- [15] 乔宁国. 基于多传感器数据融合的高速列车传动系统故障诊断与健康状态预测[D]: [博士学位论文]. 长春: 吉林大学, 2019.
- [16] 唐若瑜. 基于改进增强包络谱的齿轮箱轴承故障诊断方法研究[D]: [硕士学位论文]. 成都: 西南交通大学, 2020.
- [17] 陈晓玥, 耿明, 陈鹏展. 一种基于 UEE-EMD 的滚动轴承故障诊断方法[J]. 华东交通大学学报, 2019, 36(5): 74-81.
- [18] 邓家利. 核电站阀门远传机构故障诊断研究[D]: [硕士学位论文]. 沈阳: 沈阳工程学院, 2023.
- [19] 侯铁军, 石成江, 王筱强. 小波包-包络分析及基于 EMD 谱分析法的研究[J]. 石油和化工设备, 2011, 14(8): 40-43.
- [20] 周小龙, 刘薇娜, 姜振海, 等. 改进的 HHT 方法及其在旋转机械故障诊断中的应用[J]. 振动与冲击, 2020, 39(7): 189-195.
- [21] 夏立, 费奇. 感应电机轴承故障检测方法研究[J]. 振动、测试与诊断, 2005, 25(4): 307-310+321.
- [22] 韩宇, 李剑, 马慧宇, 等. 基于 CNN-LSTM 的桥梁结构损伤诊断方法[J]. 国外电子测量技术, 2021, 40(7): 1-6.
- [23] 卢恩豪, 冀大雄, 王霞. 基于卷积神经网络和注意力机制的自主水下机器人故障诊断研究[J]. 海洋信息技术与应用, 2025, 40(2): 65-73.
- [24] 赫鹏, 任晓明. 基于决策树算法的计算机数据库查询结果自动分类方法[J]. 中国高新科技, 2024(21): 21-23.
- [25] 郭敏, 周超, 郑成基, 等. 基于元学习技术的变工况齿轮故障诊断方法[J]. 机电工程, 2023, 40(11): 1682-1690.
- [26] 张朋杨. 复合材料构件粘接缺陷超声检测与表征[D]: [硕士学位论文]. 秦皇岛: 燕山大学, 2022.