

面向变载荷工况的滚动轴承多模态半监督 CNN-SVM 智能诊断架构研究

何欢, 胡志豪, 高睿显*, 蒋捷, 王志鹏, 杨昊闾, 方靖哲

温州大学数理学院, 浙江 温州

收稿日期: 2026年6月21日; 录用日期: 2026年7月15日; 发布日期: 2026年7月27日

摘要

针对变载荷工况下滚动轴承故障诊断中存在的跨工况特征分布漂移、目标域标签稀缺及深度模型缺乏物理可解释性等问题, 提出一类融合多维度流形重构、CNN-SVM 特征解耦与半监督伪标签学习的多模态智能诊断架构。首先, 在剥离全局稳态趋势的基础上, 联合时域高阶统计量、频域能量解调与连续小波变换构建高维特征映射, 并利用主成分分析(PCA)构建低秩正交投影流形, 在保留主体解释方差的同时滤除19.5%的尾部冗余成分。其次, 构建CNN-SVM 串联诊断网络, 以前置CNN提取高阶拓扑表征, 依凭后端SVM 结构风险最小化原则确立全局决策边界。再次, 嵌入基于动态置信度阈值的伪标签闭环迭代机制, 自适应挖掘目标域无标签样本的隐式聚类结构以修正决策面, 有效抑制小样本约束下的局部过拟合。最后, 引入基于集成树基尼不纯度的特征溯源算子量化特征权重, 并通过0~3 HP 梯度载荷实验进行综合验证。结果表明: 该架构显著缓解了分布偏移引发的收敛阻滞, 极限重载下的诊断准确率达91.94%, 特征重要性演化分析结果揭示了载荷递增诱发的频带能量迁移规律, 诊断核心判据由基础幅频指标(如频谱质心)向表征信号复杂度的深层拓扑指标(如谱滚降、谱熵)转移。该方法不仅实现了复杂工况高精度预测, 还确立了数据驱动决策与机械耗散动力学间的物理映射关系。

关键词

变载荷工况, 半监督学习, CNN-SVM, 流形降维, 故障诊断

Research on Multi Modal Semi Supervised CNN-SVM Intelligent Diagnosis Architecture for Rolling Bearings under Variable Load Conditions

Huan He, Zhihao Hu, Ruixian Gao*, Jie Jiang, Zhipeng Wang, Haochang Yang, Jingzhe Fang

*通讯作者。

文章引用: 何欢, 胡志豪, 高睿显, 蒋捷, 王志鹏, 杨昊闾, 方靖哲. 面向变载荷工况的滚动轴承多模态半监督 CNN-SVM 智能诊断架构研究[J]. 应用数学进展, 2026, 15(7): 215-228. DOI: 10.12677/aam.2026.157317

Abstract

Aiming at the problems of cross condition feature distribution drift, scarce target domain labels, and lack of physical interpretability of deep models in rolling bearing fault diagnosis under variable load conditions, a multimodal intelligent diagnosis architecture was proposed, which integrated multi-dimensional manifold reconstruction, CNN-SVM feature decoupling, and semi supervised pseudo label learning. Firstly, based on the detachment of the global steady-state trend, a high-dimensional feature map was constructed by combining high-order time-domain statistics, frequency-domain energy demodulation, and continuous wavelet transform. Principal component analysis (PCA) was used to construct a low rank orthogonal projection manifold, which could filter out 19.5% of tail redundant components while retaining the main explanatory variance. Secondly, a CNN-SVM serial diagnostic network was constructed to extract high-order topological representations from the pre CNN, and establish global decision boundaries based on the principle of minimizing the structural risk of the back-end SVM. Thirdly, a pseudo label closed-loop iterative mechanism based on a dynamic confidence threshold was embedded to adaptively mine the implicit clustering structure of unlabeled samples in the target domain to correct the decision surface, effectively suppressing local overfitting under small sample constraints. Finally, a feature traceability operator based on integrated tree Gini impurity was introduced to quantify feature weights, and comprehensive verification was carried out through 0~3 HP gradient loading experiments. The results showed that the architecture significantly alleviated the convergence blockage caused by distribution offset, and the diagnostic accuracy under extreme overload reached 91.94%, and the evolution analysis of feature importance revealed the frequency band energy transfer law induced by increasing load, and the diagnostic core criterion shifted from basic amplitude frequency indicators (such as spectral centroid) to deep topological indicators that could characterize signal complexity (such as spectral roll off and spectral entropy). This method not only achieved high-precision prediction of complex working conditions, but also established a physical mapping relationship between data-driven decision-making and mechanical dissipative dynamics.

Keywords

Variable Load Conditions, Semi-Supervised Learning, CNN-SVM, Manifold Dimensionality Reduction, Fault Diagnosis

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

滚动轴承作为旋转机械的核心传动部件,其健康状态直接决定了装备系统的运行可靠性。当轴承内、外圈或滚动体萌生局部缺陷时,接触应力的突变会激发出宽频非平稳冲击脉冲[1]。传统的故障诊断方法主要依赖包络解调、小波分析等信号处理技术来提取故障特征频率。然而,在实际服役环境中,强背景噪声与时变载荷的耦合干涉,极易掩盖微弱的故障冲击成分,导致依赖固定物理先验的单一分析手段在变工况下面临特征提取失效的瓶颈。

近年来,以卷积神经网络(CNN)为代表的驱动方法,凭借其强大的非线性映射能力,在机械故障特征自适应提取中展现出显著优势。但该类全监督深度网络高度依赖大规模且分布一致的有标签样本。工业现场设备通常长期处于稳态运行,故障样本获取困难,数据呈现出“海量无标签、稀缺有标签”的极度不平衡属性[2]。同时,设备频繁经历交替变载荷作业(如 0~3 HP),使得振动信号的特征流形发生严重的边缘概率分布偏移(Covariate Shift) [3]。若直接利用有限的源域样本训练模型,并进行跨工况推理,极易引发局部过拟合与泛化性能衰退。因此,探索能够适应分布漂移且降低标签依赖的半监督或跨域表征机制,成为当前突破“数据孤岛”难题的关键[4]。

2. 数据预处理与多维数据空间重构

2.1. 缺陷激振的运动学物理映射模型

滚动轴承主要由内圈、外圈、滚动体及保持架组成。当部件存在局部损伤时,滚动体与缺陷的周期性碰撞将激发出非平稳的冲击振动响应。结合轴承几何结构参数,其理论故障特征频率推导如下:

外圈故障特征频率(BPFO):

$$f_{BPFO} = f_r \cdot \frac{N_d}{2} \cdot \left(1 - \frac{d}{D}\right) \quad (1)$$

内圈故障特征频率(BPFI):

$$f_{BPFI} = f_r \cdot \frac{N_d}{2} \cdot \left(1 + \frac{d}{D}\right) \quad (2)$$

滚动体故障特征频率(BSF):

$$f_{BSF} = f_r \cdot \frac{D}{d} \cdot \left[1 - \left(\frac{d}{D}\right)^2\right] \quad (3)$$

其中, $f_r = n/60$ 为轴承转频(n 为转速,单位 rpm), d 为滚动体直径, D 为轴承节径, N_d 为滚动体个数。上述本征频率构成了后续频域解调与故障寻址的物理判据。

2.2. 数据预处理与样本空间重构

2.2.1. 观测源选取与频谱一致性校正

为消除 12 kHz 与 48 kHz 采样率异构引发的谱分布失真,本节采用抗混叠重采样技术。通过设定 16 kHz 低通截止频率并结合分段线性内插算法,将原始信号统一重采样至 32 kHz,以保证频带的一致性。

2.2.2. 趋势移除与时域空间增强

原始传感器信号不可避免地耦合了设备稳态运行的直流漂移。为提取纯粹的高频激变特征,对标准化后的序列 $x_{original}(t_i)$ 实施零均值化算子:

$$x(t) = x_{original} - \frac{1}{N} \sum_{i=1}^N x_{original}(t_i) \quad (4)$$

(4)式中, N 为离散采样点总数。随后,构建自适应带通滤波器。设 $H(f)$ 为滤波器在频域的传递函数,经傅里叶变换校正后的离散序列 $x_{filtered}(t)$ 可表述为:

$$x_{filtered}(t) = \mathcal{F}^{-1} \{ H(f) \cdot \mathcal{F} \{ x(t) \} \} \quad (5)$$

此运算通过频域相乘与时域逆映射,完成了冲击脉冲能量的无损分离。

2.2.3. 连续流形的拓扑截断与增广

为构建深度学习模型所需的样本集, 本文采用重叠滑动窗口法对时间序列进行分割。设提取的时间窗口尺度为 L , 重叠位移率为 r , 则滑动位移算子 $step$ 定义为:

$$step = L \times (1 - r) \quad (6)$$

对于预处理完毕的连续序列向量 $S_{pre} = [s'_1, s'_2, \dots, s'_T]$, 第 k 个窗口的起始点 i_k 遵循序列 $i_k = 1 + (k-1) \times step$ 。对应的子样本集矩阵 W_k 被提取为:

$$W_k = [s'_{i_k}, s'_{i_k+1}, \dots, s'_{i_k+L-1}] \quad (7)$$

通过上述滑动位移算子遍历完整序列, 最终重构出扩维特征空间 $D = [W_1, W_2, \dots, W_K]$ 。

2.3. 非平稳信号的高维拓扑度量与低秩流形重构

2.3.1. 非高斯随机过程的多域联合度量

为捕获轴承退化信号中的非高斯损伤脉冲, 本文构建了多域的联合特征空间 $\mathcal{X} \in \mathbb{R}^{K \times 60}$ 。对于离散序列 $\{x_i\}_{i=1}^N$, 其特征向量包含刻画冲击强度的峭度 K 与峰值因子 C_f :

$$K = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\sigma^4}, C_f = \frac{\max |x_i|}{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (8)$$

其中, $\bar{x}$ 为样本均值, σ 为标准差。同时, 利用希尔伯特变换提取信号包络 $A(t)$, 并计算频域谱熵 H_s , 用以量化能量分布的紊乱度:

$$H_s = -\sum_f P(f) \log P(f) \quad (9)$$

其中 $P(f)$ 为归一化功率谱密度。通过该多域算子集, 可将一维物理信号映射至高维语义空间, 实现对故障形态的初级测度。

2.3.2. 频域解调算子与时频联合多尺度映射

由于振动信号在传输界面中存在复杂的频带调制现象, 低频故障特征(如 BPFI、BPFO)易掩埋于高频共振带。因此, 通过离散傅里叶变换(DFT)将时序数据向频率域映射:

$$X(f_k) = \sum_{n=0}^{N-1} x(t_n) e^{-j2\pi f_k t_n / N} \quad (10)$$

为剥离转频及稳态噪声掩蔽, 对特定高频共振带信号引入希尔伯特变换(Hilbert Transform)进行包络解调提取:

$$H[x(t)] = x(t) * \left(\frac{1}{\pi t} \right) \quad (11)$$

进一步引入连续小波变换(CWT), 在时间和尺度双重约束下剖析能量瞬态聚焦现象:

$$WT(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t-\tau}{a} \right) dt \quad (12)$$

其中, a 与 τ 分别为反映频率解析度的尺度参数与平移参数, ψ^* 为母小波共轭函数。

2.3.3. 能量扩散动力学与 PCA 低秩重构

在挖掘多域特征内在力学联系时, 定义均方根值(RMS)表征系统激振的有效全局能量:

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (13)$$

考虑到从多域空间提取的 60 维特征存在强烈的内部共线性冗余, 本研究实施主成分分析(PCA)正则化。计算特征协方差矩阵的正交本征特征值 λ_i , 前三个主成分的累计方差贡献率 η 满足:

$$\eta = \frac{\sum_{i=1}^3 \lambda_i}{\sum_{i=1}^{60} \lambda_i} = 80.5\% \quad (14)$$

由此投影生成的三维低秩流形, 成功剥离了 19.5% 的尾部噪声冗余。

2.4. 结果分析与数学验证

2.4.1. 非平稳冲击能量的瞬态聚焦性验证

小波变换时频分析 - 多尺度特征提取




Figure 1. Time frequency analysis of wavelet transform

图 1. 小波变换时频分析

基于式(12)的连续小波变换映射结果如图 1 所示。由图可见, 正常状态下, 时频能量分布均匀平稳; 而发生故障时, 时频图出现显著的能量聚集。以内外圈故障为例, 高频段出现了大面积高能共振带(亮黄色区域), 且该能量聚集表现出与理论特征频率(式(1)~(3))高度吻合的准周期性。这表明连续小波变换成功捕获了低频冲击对高频段的幅度调制过程。

2.4.2. 物理损伤尺度扩张的泛化规律

为验证式(13)所提的能量分布机制，图2绘制了时域激振能量(RMS)与频域总功率的二维平面映射。拓扑散点轨迹清晰地刻画了缺陷尺度延伸对信号内能的调制逻辑：当故障损伤尺寸从微小(0.007 inch)扩展至严重(0.021 inch)时，数据类簇从低特征空间的密集稳定态，呈现出向高能域严格的线性放射型延展。这种时频能量的强正相关耦合，在数学机制上确证了局部缺陷导致的机械损耗向全频段发散的耗散动力学本质。




Figure 2. Relationship between time-domain RMS and frequency-domain total power
图2. 时域 RMS 与频域总功率关系图

2.4.3. 高阶特征流形的低秩降维有效性

图3呈现了高维特征在主成分空间(PC1, PC2)的二维映射分布。由图可见，PC1的累计解释方差为80.5%，PC2的累计解释方差为48.3%，PC3的累计解释方差为21.1%，表示前3个主成分(PC1、PC2、PC3)共解释了原始高维特征80.5%的方差。这说明降维后仍保留了原始特征的大部分信息，可视化结果具有可靠性。




Figure 3. 2D projection view of PCA principal components
图3. PCA 各主成分 2D 投影视图

3. 面向变载荷工况的多模态半监督智能诊断架构设计

在完成特征降维后,为实现变载荷工况下的鲁棒诊断,本节针对驱动端 48 kHz 振动信号定义了 10 类健康状态(包含正常及 0.007~0.021 英寸损伤)。针对跨工况特征漂移、标签稀缺及模型缺乏可解释性的问题,本文在 0~3 HP 梯度载荷下,提出了一类融合 CNN-SVM 深度解耦、伪标签半监督学习与集成树特征溯源的综合诊断架构。

3.1. 基于 CNN-SVM 的深度特征解耦与决策边界优化

针对浅层模型易陷局部最优、CNN 在小样本下易过拟合的问题,本文结合 CNN 的特征提取能力与 SVM 在小样本下的泛化优势,构建了 CNN-SVM 级联诊断网络。

3.1.1. 深度卷积前端特征映射

网络前端采用一维/二维卷积架构作为特征映射提取器。设第 $l-1$ 层的输入特征图为 X^{l-1} , 则第 l 层的第 k 个卷积核输出 $y_{i,j}^k$ 可由空间离散卷积严格定义为:

$$y_{i,j}^{(l,c)} = \sigma \left(\sum_m \sum_n x_{i+m,j+n}^{l-1} W_{m,n}^{(l,c)} + b^{(l,c)} \right) \quad (15)$$

(15)式中, $W_{m,n}^{(l,c)}$ 为离散卷积的权值矩阵, b^k 为偏置项。为破除网络的线性映射局限,引入 ReLU 激活函数 $\sigma(\cdot) = \max(0, \cdot)$ 进行非线性截断;随后,串联最大池化算子执行下采样:

$$p_{i,j}^{(l,c)} = \max_{(m,n) \in \Omega} \left(y_{i \times s + m, j \times s + n}^{(l,c)} \right) \quad (16)$$

其中, Ω 为池化窗口大小, s 为滑动步长。

采用此框架,既利用了 CNN 的时空自学习能力,又借助 SVM 结构风险最小化原则,约束了小样本工况下的过拟合空间。

3.1.2. SVM 最大间隔分类超平面

预训练阶段, CNN 通过交叉熵损失进行优化。收敛后,将池化层提取的深层特征向量 v_i 直接输入 RBF-SVM 中。SVM 通过求解以下拉格朗日对偶问题,实现高维空间的分类间隔最大化:

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(v_i, v_j), \\ \text{s.t.} \quad & 0 \leq \alpha_i \leq C, \sum_{i=1}^N \alpha_i y_i = 0. \end{aligned} \quad (17)$$

(17)式中, α_i 为拉格朗日乘子, $K(\cdot, \cdot)$ 为 RBF 核函数, C 为惩罚参数。

通过 SMO 算法优化求解上述对偶问题,对于目标域输入的全新测试样本,设其由 CNN 提取的高阶特征向量为 v_{new} , 引入核技巧处理非线性映射后,最终的 CNN-SVM 串联诊断决策函数可严谨表述为:

$$\hat{y}_{new} = \arg \max_k \left(\sum_{j: y_j = k} \alpha_j^k K(z_{new}, z_j) + b^k \right) \quad (18)$$

(18)式中, α_j^k 与 b^k 分别为对应的第 k 类的拉格朗日乘子与偏置。

3.2. 面向工业稀疏样本的半监督伪标签扩展机制

针对实际工业设备“稳态运行数据海量、故障标签稀缺”的数据非均衡问题,全监督网络在小样本约束下极易产生局部过拟合。为此,本研究在 CNN-SVM 架构基础上嵌入伪标签半监督闭环学习算子。

该机制利用少量源域数据初始化的基准模型,对目标域无标签样本进行前向推理以获取预测概率分

布 $P(y|x;\theta)$ 。设定动态置信度阈值 τ_t ，筛选低信息熵样本并分配伪标签 $\hat{y}_j$ 。其伪标签的硬分配生成规则严格定义为：

$$\hat{y}_j = \arg \max_c P(y = c | x_j; \theta), \text{ if } \max P(y | x_j; \theta) \geq \tau_t \quad (19)$$

筛选后的高置信度样本被重新纳入训练。基于流形假设，即特征空间内的邻近样本同属一类，模型的联合优化目标等效于极小化以下经验风险函数(涵盖源域监督损失与目标域自监督正则化项)：

$$\mathcal{L}(\theta) = \frac{1}{N_s} \sum_{i=1}^{N_s} H(y_i, P(x_i)) + \alpha(t) \frac{1}{N_t} \sum_{j=1}^{N_t} \mathbb{I}(\max(P(x_j)) \geq \tau_t) H(\hat{y}_j, P(x_j)) \quad (20)$$

(20)式中， N_s 与 N_t 分别为有标签与无标签样本数； $H(\cdot, \cdot)$ 为交叉熵损失； $\mathbb{I}(\cdot)$ 为示性算子。权重系数 $\alpha(t)$ 随迭代轮次递增：初期抑制错误伪标签造成的梯度震荡；后期强化目标域正则化约束。

3.3. 基于集成树的黑盒特征可解释性溯源机理

CNN-SVM 模型虽具备高诊断精度，但其“黑盒”属性掩盖了故障演化的物理规律。为此，本文引入随机森林算法，利用基尼不纯度量化各域特征对分类结果的贡献，进而实现特征重要性评估。针对 10 类轴承健康状态，决策树节点 D 的基尼不纯度严谨定义为类别概率的二阶多项式：

$$Gini(m) = 1 - \sum_{k=1}^K p_{m,k}^2 \quad (21)$$

(21)式中， p_k 为节点中第 k 类物理状态样本的经验概率。假设某特征将节点 D 物理分裂为左、右子集与 D_{left} 与 D_{right} ，则该特征诱导的分裂增益(Split Gain)可度量为系统不纯度的离散下降量：

$$\Delta Gini = Gini(D) - \left(\frac{|D_{left}|}{|D|} Gini(D_{left}) + \frac{|D_{right}|}{|D|} Gini(D_{right}) \right) \quad (22)$$

通过对加权积分决策树节点的归一化增益，可精确提取各特征的全局贡献权重。

4. 综合实验结果分析与多模态动力学讨论

为验证多模态特征解耦与深度架构的综合性能，实验基于 48 kHz 驱动端宽频加速度信号，在 0~3 HP 梯度载荷下展开跨域诊断评估。

4.1. 基准特征空间的线性不可分敏感性分析

表 1 对比了四类浅层分类器在 60 维特征下的诊断性能。在 3 HP 载荷下，逻辑回归(LR)的准确率降至 0.8941，表明特征具有较强的非线性。引入数据增强后，XGBoost 准确率提升至 0.976，而 LR 却因数据增强带来的非线性干扰导致性能下降。这一对比结果，印证了在变载荷工况下引入 CNN 提取深层非线性特征的必要性。

Table 1. Performance comparison of baseline models under varying loads

表 1. 变载荷下基准模型性能对比表

诊断模型	评价指标	轻载工况(0 HP)	中载工况(1 HP)	中载工况(2 HP)	极限重载(3 HP)
Logistic Regression	Accuracy	0.9524	0.9324	0.9405	0.9100
	F1-Score	0.9522	0.9311	0.9365	0.8941
SVM	Accuracy	0.9215	0.9537	0.9386	0.9080
	F1-Score	0.9323	0.9520	0.9365	0.8994

续表

Random Forest	Accuracy	0.9847	0.9755	0.9687	0.9794
	F1-Score	0.9822	0.9733	0.9682	0.9788
XGBoost	Accuracy	0.9554	0.9778	0.9693	0.9794
	F1-Score	0.9517	0.9732	0.9682	0.9788

通过评估模型的性能，发现 RandomForest (随机森林)模型在多数载荷下的测试集准确率相对较高且较为稳定，因此分析 RandomForest 在不同载荷下的训练结果。

4.2. 深度特征预提取与网络收敛动力学响应

基于构建的 CNN-SVM 模型，对 0 HP 至 3 HP 四种不同载荷工况进行训练求解，模型收敛性及泛化演化特征如下：




Figure 4. Convergence curves of accuracy and loss for the CNN model in the base feature space
图 4. 基础特征空间下 CNN 模型的准确率与损失收敛曲线




Figure 5. Comparison of cross-domain convergence evolution of the model under varying load conditions (0 HP to 3 HP)
图 5. 不同变载荷工况(0 HP~3 HP)下 CNN 模型的跨域收敛演化对比

图 4 展示了前置 CNN 网络的预训练收敛曲线。由图可知, 训练损失在初期快速下降, 准确率迅速收敛至高位, 且验证集与训练集曲线最终高度贴合。这不仅表明该网络未发生明显过拟合, 更证明其具备优异的特征提取与非线性映射能力, 在单一数据分布下拟合性能良好。

图 5 进一步揭示了载荷(0~3 HP)对模型收敛的影响。在轻载(0 HP)下, 模型快速收敛; 然而在较高载荷(1~3 HP)下, 前 10 个 Epoch 因强非线性冲击与噪声导致梯度震荡, 验证损失出现明显波峰。尽管存在早期收敛迟滞, 模型最终仍凭借网络深度与非线性激活成功越过局部极小值, 达到平稳收敛。

4.3. 变载荷工况下半监督诊断模型的跨域泛化性能

表 2 通过 CNN-SVM 半监督模型验证了跨工况准确率呈“V 型”规律: Load 0 时(0.9622)迁移良好; Load 2 时(0.8755)因信号非平稳性加剧、流形偏移而降至最低; Load 3 时(0.9194)则因重载冲击特征主导、类间可分性增强而显著回升。上述现象既验证了伪标签机制应对分布偏移的有效性, 又准确反映了变载荷下机械系统的非线性动力学演化特征。

Table 2. Quantitative evaluation of pseudo-label learning performance under different load conditions
表 2. 不同载荷工况下伪标签学习性能的定量评价

载荷工况	准确率(Acc.)	精确率(Pre.)	F1 分数(F1)	召回率(Rec.)
Load 0	0.9622	0.9630	0.9622	0.9620
Load 1	0.9560	0.9612	0.9560	0.9553
Load 2	0.8755	0.8807	0.8755	0.8741
Load 3	0.9194	0.9246	0.9194	0.9171

4.4. 梯度载荷下的特征拓扑演化与权重物理溯源

图 6 给出了随机森林模型在 0~3 马力(HP)变载荷工况下, 轴承故障测试集的混淆矩阵与特征重要性排序结果。由图 6(a)和图 6(b)可得, 在 0 HP (空载)工况下, 模型整体分类精度较高, 仅少数 Ball_014 样本被跨类误判为 InnerRace_014。此时, 频谱质心(spec_centroid)与包络标准差(env_std)的特征权重占据主导, 表明在无外部载荷干扰时, 故障引起的系统频率重心偏移及包络能量波动是区分故障状态的最敏感指标。由图 6(c)和图 6(d)可得, 当载荷提升至 1 HP 时, 模型的误判主要集中于 OuterRace_014 与 Ball_007 之间, 且决策依据发生显著变化。频域谱滚降(fd_spec_rolloff)跃居首位, 统计四分位距(stat_iqr)紧随其后。这说明轻载的引入改变了信号能量分布, 模型更倾向于利用频带边缘能量衰减特性与时域离散程度来刻画故障。由图 6(e)和图 6(f)可得, 在 2 HP (中载)工况下, 模型分类表现依然稳定, Ball 与 OuterRace 类间仅存极少量混淆。此时 stat_iqr 与 fd_spec_rolloff 稳居权重前两位, 且占比之和相较 1 HP 进一步扩大。这反映出在中载区域, 频域高频能量分布与时域抗干扰统计量已成为极稳定的鉴别面, 模型对其依赖性趋于固化。由图 6(g)和图 6(h)可得, 在 3 马力(重载)工况下, 尽管面临复杂的接触应力与更强的背景噪声, 模型仍保持了极高的分类鲁棒性, 仅出现零星散点误判。特征权重分布揭示了关键规律: 除 fd_spec_rolloff 保持绝对优势外, 频域谱熵(fd_spec_entropy)权重显著上升并位居次席。这印证了重载下振动信号的非平稳性与复杂度剧增, 模型需依赖信息熵等深层特征来维持分类边界的清晰。

综上所述, 随机森林模型在变载荷下具备强鲁棒性。特征权重的动态演变揭示了明显的载荷耦合效应: 随载荷递增(0~3 HP), 模型核心决策依据由基础频幅特征(如 spec_centroid, env_std)向反映信号复杂度的高阶信息熵特征(如 fd_spec_rolloff, fd_spec_entropy)转移。此机制不仅解释了模型的高精度表现, 更为后续复杂工况下的特征自适应降维研究指明了方向。




Figure 6. Diagnostic decision distribution and feature importance evolution of the Random Forest model under varying load conditions. (a) (c) (e) (g) Classification confusion matrices under 0 HP, 1 HP, 2 HP, and 3 HP loads, respectively; (b) (d) (f) (h) Top 30 feature weight distributions based on global Gini impurity reduction under the corresponding loads

图 6. 变载荷工况下随机森林模型的诊断决策分布与特征重要性演化。(a) (c) (e) (g)依次为 0 HP、1 HP、2 HP、3 HP 载荷下的分类混淆矩阵；(b) (d) (f) (h)依次为对应载荷下全局基尼不纯度缩减量排名前 30 的特征权重分布




Figure 7. Feature importance ranking of pseudo-label learning under load 0 (no-load) condition
图 7. 载荷 0 (空载)工况下伪标签学习特征重要性排序

图 7 揭示了载荷 0 (空载状态)下的特征敏感性分布。在此工况下,特征敏感性呈多元均衡分布,其中平均绝对偏差(stat_mad)、低频段能量占比(fft_band0_ratio)与谱滚降(fd_spec_rolloff)占主导地位。这表明在无载荷基准下,伪标签迭代可同时提取时域离散度与频域能量骨架。这种多维特征的协同贡献为模型确立了稳定的初期聚类边界,有效辅助了状态的初步界定。




Figure 8. Feature importance ranking of pseudo-label learning under load 1 condition
图 8. 载荷 1 工况下伪标签学习特征重要性排序

图 8 展示了 1 HP 载荷下特征权重的迁移规律。受初始载荷影响,特征敏感度显著转向,频域比例特征(fft_band0_ratio 与 fft_band2_ratio 重要性均超 0.06)跃升为主导。这揭示了物理系统受载初期的能量重

分布效应，即外部激振促使能量在特定频带间迁移。频带能量分配比例由此取代单一时域幅值，成为伪标签学习的首要分类判据，验证了模型对变工况能量演变机制的自适应捕捉能力。




Figure 9. Feature importance ranking of pseudo-label learning under load 2 condition

图 9. 载荷 2 工况下伪标签学习特征重要性排序

图 9 刻画了 2 HP (中高载荷)工况下的特征依赖演化。此时，时域标准差(td_std)主导分类，频谱熵(fd_spec_entropy)排位显著前移。这一现象揭示了载荷加剧带来的振动烈度分化与信号复杂度提升。结果表明，中高载荷诱发的非线性摩擦与随机冲击，促使模型的学习机制由浅层的能量分布判别，自适应转化为深层的信号混乱度量。




Figure 10. Feature importance ranking of pseudo-label learning under load 3 condition

图 10. 载荷 3 工况下伪标签学习特征重要性排序

图 10 呈现了极限重载(载荷 3)工况下的特征极化现象。特征空间在此环境下高度集中, `fft_band1_ratio` 与 `fd_spec_rolloff` 占据绝对主导(权重均超过 0.065)。这反映了重载受力模式的本质转变: 高频冲击主导导致频谱重心剧烈偏移。刻画高频轮廓及能量分布的指标由此成为状态识别的核心判据。长尾特征贡献的极度压缩使得特征依赖呈现显著的低维稀疏性, 有力证明了伪标签学习机制在极限工况下的特征降维与关键线索聚焦能力。

5. 结论

针对变载荷工况下轴承故障特征分布漂移与有标签样本稀缺的问题, 本文提出一类融合物理流形重构、CNN-SVM 解耦与伪标签半监督学习的多模态诊断架构。基于 0~3 HP 变载荷振动信号的分析与验证, 得出以下结论:

首先, 多维空间映射与低秩流形降维有效揭示了损伤的耗散动力学本质。时频解析表明, 局部缺陷冲击对高频谐振带具有显著的幅值调制作用; 随损伤尺度(0.007 至 0.021 inch)扩展, 激振能量在时频域呈向高能区放射状延展。据此构建的 PCA 三维正交投影流形, 保留了原始特征 80.5% 的解释方差并滤除尾部冗余, 实现了高频非平稳特征的高效降维。其次, 引入伪标签半监督机制的 CNN-SVM 架构显著提升了跨域诊断鲁棒性。实验证实, 在 0~3 HP 变载荷下, 协变量偏移(Covariate Shift)易导致单一全监督网络泛化受限。所提架构以前端 CNN 提取拓扑特征, 后端 SVM 基于结构风险最小化原则构建超平面; 配合动态置信度阈值的伪标签闭环迭代, 模型可利用目标域无标签数据的流形结构自适应校准分类边界, 有效抑制了小样本过拟合现象。最后, 特征重要性演化分析揭示了变载荷下频带能量的动态迁移规律。随着载荷由空载增至 3 HP, 基准模型的核心判据由基础幅频指标(包络标准差、频谱质心)向表征信号非平稳度的高阶指标(谱滚降、谱熵)转移。引入伪标签迭代后, 模型进一步捕获到工况突变引发的系统能量重分布效应, 频带能量占比(如 `fft_band0_ratio`)取代单一时域统计量跃升为主导特征。此演化过程深刻映射了变应力下的物理损耗机制, 为复杂工况特征的可解释性提供了客观依据。

基金项目

温州大学硕士研究生创新基金项目(3162025004057), 浙江省大学生科技创新活动计划(新苗人才计划)(2025R444A017), 温州大学国家级大学生创新创业训练计划项目(JWXC2024081)。

参考文献

- [1] Randall, R.B. and Antoni, J. (2011) Rolling Element Bearing Diagnostics—A Tutorial. *Mechanical Systems and Signal Processing*, 25, 485-520. <https://doi.org/10.1016/j.ymssp.2010.07.017>
- [2] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
- [3] Lu, W., Liang, B., Cheng, Y., Meng, D., Yang, J. and Zhang, T. (2017) Deep Model Based Domain Adaptation for Fault Diagnosis. *IEEE Transactions on Industrial Electronics*, 64, 2296-2305. <https://doi.org/10.1109/tie.2016.2627020>.
- [4] Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N. and Nandi, A.K. (2020) Applications of Machine Learning to Machine Fault Diagnosis: A Review and Roadmap. *Mechanical Systems and Signal Processing*, 138, Article 106587. <https://doi.org/10.1016/j.ymssp.2019.106587>