

基于迁移学习的高速列车轴承故障智能诊断建模研究

刘林霏

辽宁师范大学数学学院, 辽宁 大连

收稿日期: 2026年7月15日; 录用日期: 2026年8月8日; 发布日期: 2026年8月21日

摘要

高速列车轴承作为走行系统的核心旋转部件, 其运行状态直接关系到列车的安全性与可靠性。长期处于高转速、交变载荷等复杂工况下, 轴承表现出故障率高、易损坏等显著特点, 已成为高速列车安全运维的关键监控对象。轴承故障若未能被及时准确诊断, 可能引发运行延误甚至脱轨等灾难性后果, 因此对其开展精准、鲁棒的故障诊断研究具有重大工程安全价值。传统故障诊断方法多依赖于专家先验知识或传统信号处理技术, 在诊断精度、泛化能力及实时性方面难以满足复杂运营场景下的高标准需求。近年来, 基于深度学习的智能诊断方法凭借其强大的特征学习能力展现了巨大潜力, 然而在实际工程应用中, 仍面临两大挑战: 一是振动信号易受强噪声干扰, 导致故障特征被淹没; 二是故障样本稀缺导致的类间样本不平衡问题, 限制了有监督学习模型的泛化性能。值得注意的是, 与稀缺且获取成本高昂的真实运行故障数据形成鲜明对比的是, 在受控的台架实验环境中, 研究人员能够方便地获取大量标签完备、覆盖各种故障类型与严重程度的轴承数据, 且其物理失效机理与真实列车轴承具有高度相似性。如何有效利用这些丰富的实验室数据来弥补实际运维中故障数据的不足, 成为破局的关键。在此背景下, 迁移学习技术作为一种能够将在一个领域(源域, 如实验室台架)中学到的知识迁移应用到另一个相关但数据分布不同的领域(目标域, 如在线运营列车)的机器学习范式, 为解决上述数据稀缺与分布失衡的困境提供了极具前景的思路。本研究正是在这一现实需求与技术机遇的交汇点上展开, 旨在探索基于迁移学习的解决方案, 以推动高速列车轴承智能故障诊断技术走向真正的工程实用化。

关键词

高速列车轴承, 故障诊断, 迁移学习, 多域特征提取, 可解释性分析

Research on Intelligent Fault Diagnosis Modeling of High-Speed Train Bearings Based on Transfer Learning

Linfei Liu

School of Mathematics, Liaoning Normal University, Dalian Liaoning

Abstract

As the core rotating component of the running gear system for high-speed trains, the operating status of train bearings is directly related to the safety and reliability of the train. Operating for long periods under complex conditions such as high rotational speeds and alternating loads, bearings exhibit prominent characteristics, including a high failure rate and vulnerability to damage, making them a key monitoring target for the safe operation and maintenance of high-speed trains. Failure to diagnose bearing faults in a timely and accurate manner may lead to catastrophic consequences such as operational delays or even derailment. Therefore, conducting research on precise and robust fault diagnosis for such bearings is of great significance for engineering safety. Traditional fault diagnosis methods mostly rely on expert prior knowledge or conventional signal processing techniques, which struggle to meet the high-standard requirements of complex operational scenarios in terms of diagnostic accuracy, generalization ability and real-time performance. In recent years, intelligent diagnosis methods based on deep learning have shown tremendous potential owing to their powerful feature learning capabilities. However, in practical engineering applications, they still face two major challenges: first, vibration signals are easily disturbed by strong noise, resulting in the obscuration of fault features; second, the inter-class sample imbalance caused by scarce fault samples limits the generalization performance of supervised learning models. Notably, in sharp contrast to the scarce and costly real-world operational fault data, researchers can easily obtain a large amount of fully labeled bearing data covering various fault types and severity levels in a controlled bench test environment. Moreover, the physical failure mechanism of such test bearings is highly similar to that of actual train bearings. How to effectively utilize this abundant laboratory data to compensate for the shortage of fault data in actual operation and maintenance has become the key to breaking through the dilemma. Against this background, transfer learning—a machine learning paradigm that can transfer knowledge learned from one domain (source domain, e.g., laboratory test bench) to another related domain with different data distribution (target domain, e.g., online operating trains)—provides a promising solution to the above dilemmas of data scarcity and distribution imbalance. This research is carried out at the intersection of such practical demands and technological opportunities, aiming to explore transfer learning-based solutions and promote the engineering practical application of intelligent fault diagnosis technology for high-speed train bearings.

Keywords

High-Speed Train Bearings, Fault Diagnosis, Transfer Learning, Multi-Domain Feature Extraction, Interpretability Analysis

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

围绕“高速列车轴承智能故障诊断”这一核心课题，需系统性地突破以下两个关键问题：**第一，数据分析与故障特征提取**，该问题的核心在于如何构建能够有效支撑迁移学习的源域数据集，并提取具有强表征能力的故障特征。具体包括如何依据目标域的工况特性与迁移需求，从多源异构的源域数据中筛选具有代表性和泛化能力的样本；以及如何结合轴承故障的物理机理(如冲击响应、频率调制特性)，从复

杂的振动信号中构建能够稳健表征早期故障、复合故障等不同状态的特征指标，从而为后续模型构建奠定高质量的数据基础[1]。第二，**源域诊断模型的构建与验证**，本问题聚焦于如何在标签完备的源域(如试验台架数据)上构建一个高精度、强泛化的基准故障诊断模型。关键在于设计能够深层挖掘故障特征与健康状态之间复杂映射关系的模型结构，并确保该模型在面对源域数据时具备高度的分类置信度与稳定性。同时，需建立科学的模型验证机制，以客观评估其诊断性能，为后续的跨域迁移提供可靠的初始模型。

2. 问题分析

问题一的核心任务在于通过数据分析与故障特征提取，为后续的诊断与迁移学习构建一个高质量且相关性强的特征集合[2]。首先，需要从 161 个源域数据文件中筛选出与在途列车运行数据即目标域的工况更为接近的数据子集，从而减小域间分布差异，为迁移学习奠定基础。考虑到目标域轴承转速约为 600 rpm，采样频率为 32 kHz，应优先选取源域中转速相近的试验数据，并对所有选用的数据进行重采样处理，统一采样频率，确保特征尺度一致。其次，时域特征可包括峭度、裕度因子、均方根值等统计量；频域特征可基于傅里叶变换与包络谱分析，提取如 BPFO、BPFI、BSF 等故障特征频率及其谐波成分的幅值信息；时频域特征则可借助小波包变换提取各频带能量分布。在方法上，可采用两类策略：一是基于传统信号处理与统计分析的特征工程方法，其物理意义明确、计算效率高；二是将一维振动信号转换为二维图像，利用图像纹理与结构信息作为特征，该方法能够捕捉信号中的非线性与非平稳特性，非常适用于深度学习模型。本问题的主要难点在于如何构建一组既能准确区分源域中不同故障类别，又在特征的判别性与迁移性之间取得平衡。

问题二的目标是在问题一提取的特征基础上，构建并评估一个源域故障诊断模型，为后续迁移学习提供可靠的基准。首先，将经过筛选与处理的源域特征数据集按一定比例进行划分，可以划分成 80%训练集、20%测试集，确保模型评估的客观性。随后，基于所构建的特征集，设计并训练分类模型，实现将输入特征向量映射至四种工作状态之一：外圈故障(OR)、内圈故障(IR)、滚动体故障(B)或正常状态(N)。模型的关键参数包括层数、神经元数量等网络结构、学习率及激活函数等，输出为每个样本的预测标签。在选择方法时，可以考虑两类模型：一是经典机器学习算法，比如支持向量机(SVM)或随机森林(Random Forest)，这类模型对结构化统计特征具有良好的适应性，训练成本低且可解释性强；二是深度学习模型，例如针对统计特征构建的多层感知机(MLP)，或针对图像特征构建的卷积神经网络(CNN)，深度模型能够自动学习特征之间的深层关系，获得更高的诊断精度。本问题的主要难点在于源域数据存在严重的类别不平衡问题，正常样本较少，易导致模型偏向多数类。对此，可以在训练过程中采用 SMOTE 过采样技术、欠采样方法或引入类别加权的损失函数，并选用 F1 分数、混淆矩阵等对不平衡数据更为鲁棒的评价指标，以全面评估模型性能。

3. 模型假设与符号说明

3.1. 模型基本假设

为保证模型构建的可行性与实际应用的有效性，本研究在建模前提出如下基本假设，以明确模型适用范围并增强其逻辑完备性：

- 1) 假设所采用的数据来源真实、可靠，且质量满足建模要求；
- 2) 假设所选特征能够充分表征轴承故障的关键模式与状态；
- 3) 假设源域与目标域之间具备一定的数据分布相似性，满足迁移学习的基本前提；
- 4) 假设所有相关设备均遵循统一的维护标准与操作规范，排除因运维差异引入的干扰；

- 5) 假设具备足够的计算资源，以保障模型实时预测与在线更新能力；
- 6) 假设模型输出具备实际指导意义，能够为运维决策提供有效依据；
- 7) 假设所采用的迁移学习方法能够有效缩小源域与目标域之间的分布差异。

3.2. 符号说明

本文用到的所有符号将在表 1 中具体说明。

Table 1. Nomenclature
表 1. 符号说明

符号	含义
N	长度
k	经验阈值
ϵ	最小方差阈值
μ	均值
σ^2	方差
γ_1	偏度
γ_2	峭度
CF	峰值因子
IF	脉冲因子
CLF	裕度因子
$H(\omega)$	振动传递函数
n	滚动体数量
f_r	转频
d	滚动体直径
D	节圆直径
Φ	接触角

4. 数据预处理

为构建适用于后续故障诊断的数据集，需要对原始数据进行系统的预处理与统计分析。在数据集构建过程中，首先对原始信号进行全面的质量检查，包括缺失值检测、异常值识别与处理等关键步骤。考虑到不同故障类别间样本数量存在显著差异，为避免数据量级不同对异常值判别产生干扰，本研究采用按类别分组处理的方法。具体而言，将数据按故障类型(Normal, OR, IR, B)进行分类后，在各组内部进行异常值的筛查与剔除。由于 Normal 类别样本数量较少，为最大限度保留有效信息，设定每类样本的最大异常值剔除比例为 10%，以确保各类别数据的完整性。

表 2 详细展示了数据预处理的整体效果。原始数据集共包含 116 个数据文件，其中 48 kHz 采样文件 56 个，12 kHz 采样文件 60 个。经过特征提取后共获得 10,937 个样本，各类别分布为：Normal 类 450 个，OR 类 5097 个，IR 类 2674 个，B 类 2716 个，呈现出明显的类别不平衡特征。通过分类别异常值处理，每类均按 10%的比例移除异常样本，共计除去 1092 个样本，最终保留 9845 个高质量样本用于后续的研究分析。这个处理策略有效提升了数据质量，又避免了因过度删除而导致的信息损失，为机器学习模型

训练提供了可靠的数据基础。

Table 2. Outlier processing results
表 2. 异常值处理情况

类别	原始文件数	48 kHz 文件数	12 kHz 文件数	提取样本数	异常值移除数	最终样本数	移除率
Normal	4	4	0	450	45	405	10.0%
OR	56	28	28	5097	509	4588	10.0%
IR	28	12	16	2674	267	2407	10.0%
B	28	12	16	2716	271	2445	10.0%
总计	116	56	60	10,937	1092	9845	10.0%

Table 3. Target type allocation
表 3. 目标类型分配

故障类型	样本数	占比	主要来源
外圈故障(OR)	4588	46.6%	12 kHz + 48 kHz DE 数据
滚动体故障(B)	2445	24.8%	12 kHz + 48 kHz DE 数据
内圈故障(IR)	2407	24.4%	12 kHz + 48 kHz DE 数据
正常(N)	405	4.1%	48 kHz Normal 数据

表 3 进一步展示了处理后数据的类型分布特征。其中,外圈故障(OR)样本数量最多,占总数的 46.6%;滚动体故障(B)与内圈故障(IR)样本数量相近,分别占比 24.8%和 24.4%;正常状态(Normal)样本数量最少,仅占 4.1%。所有故障数据均来自于 12 kHz 和 48 kHz 采样率的驱动端(DE)传感器数据,而正常数据仅来自 48 kHz 采样率的 Normal 数据,体现了数据集在故障类型与数据来源方面的不平衡分布特性。




Figure 1. Distribution differences of different fault types on key features
图 1. 不同故障类型在关键特征上的分布差异图

图 1 通过特征分布直方图直观呈现了不同故障类型在关键特征上的差异性[3]。DE_rms 特征显示,Normal 状态的样本主要集中于较小数值区间,而故障状态(OR, IR, B)则表现出更大的振动幅度。

DE_kurtosis 与 DE_peak 特征表明故障类型具有更宽的分布范围，反映出故障信号的非平稳性与冲击特性。DE_spectral_centroid 特征显示 Normal 状态集中于较高频率区域，而故障状态的分布相对分散。DE_BPFO_amplitude 与 DE_BPFI_amplitude 等故障特征频率幅值在故障类型中显著高于正常状态，验证了基于轴承理论计算的故障特征频率的有效性。总体来看，各特征在不同故障类型间呈现出良好的可分性，为后续故障分类的实施奠定了基础。

通过定量对比四个关键特征在不同故障类型间的均值差异，进一步揭示了特征的判别能力。DE_rms 特征中，Normal 状态的均值最低，故障状态的均值相对较高且数值接近 0.4~0.5，表明该特征能有效区分正常与故障状态。DE_kurtosis 特征在故障类型中显著升高，反映出故障信号的冲击特性。DE_peak 特征同样显示故障状态的峰值明显高于正常状态。DE_spectral_centroid 特征呈现相反趋势，Normal 状态具有最高的频谱重心，故障状态相对较低，这可能反映了故障引起的低频成分增加现象。误差线分析表明，各特征在同一故障类型内存在一定变异性，但类型间差异仍然显著，证明了特征选择的合理性。

5. 模型建立与求解

5.1. 问题一模型建立与求解

5.1.1. 数据源筛选策略

本研究旨在构建一个跨域轴承故障诊断模型[4]，利用源域中混合采样率 12 kHz 与 48 kHz 的振动信号进行特征提取与模型训练，实现对 Normal、OR、IR、B 四种轴承状态的准确识别。重点关注驱动端(DE)的振动数据，忽略风扇端数据，以提高模型的针对性和诊断效率。具体流程如下图 2 所示。




Figure 2. Data screening process

图 2. 数据筛选流程

表 4 展示了原始采样率数据的分布及处理方式。

Table 4. Sampling rate allocation
表 4. 采样率分配

原始采样率	样本数	占比	处理方式
12 kHz	2728	61.8%	上采样至 32 kHz
48 kHz	1687	38.2%	下采样至 32 kHz

5.1.2. 特征提取

为全面表征轴承振动信号的故障信息，本研究从时域、频域和时频域三个维度提取了共计 49 个特征，构建了多域融合的特征体系。

Table 5. Statistics of feature dimensions
表 5. 特征维度统计

特征域	特征数量	具体特征
时域	12	Mean, std, var, rms, peak, p2p, skew, kurt, CF, IF, SF, CLF
频域	11	Centroid, var, skew, kurt, BPFO, BPFI, BSF, FR, low/mid/high_ratio
时频域	20	16 个频带能量 + 熵 + 3 个包络特征
元数据	6	file_path, fault_type, sensor, rpm, orig_fs, resamp_fs
总计	49	

表 5 最终构建的特征向量包含 49 个维度，涵盖 12 个时域、11 个频域、20 个时频域及 6 个元数据，全面捕捉故障信息，为后续故障诊断模型提供丰富输入。

5.2. 问题二模型建立与求解

选用以下四种机器学习模型进行故障诊断：

随机森林(Random Forest) [5]：采用多棵决策树进行集成学习，通过投票机制实现分类结果的集成决策。

支持向量机(SVM)：基于结构风险最小化原则构建最优分类超平面，适用于高维特征空间的模式识别。

梯度提升(Gradient Boosting) [6]：通过迭代加权方式集成多个弱分类器(通常为决策树)，逐步提升模型预测性能。

多层感知器(MLP) [7]：利用多层神经网络结构进行非线性映射与特征学习，适用于复杂模式识别任务。

模型训练前进行超参数优化，采用网格搜索(GridSearchCV)方法选择最优参数组合。针对数据集存在的严重类别不平衡问题，本研究在模型训练阶段落地前述平衡策略：先通过 SMOTE 过采样扩充正常样本、随机欠采样压缩外圈故障样本，重构均衡训练集；在随机森林、SVM、梯度提升、MLP 四类模型的损失计算中均配置类别权重参数，自动为样本稀缺的正常类别分配更高损失权重，缓解模型偏置，保证各类故障与正常状态的识别精度均衡。

问题二结果分析

模型构建阶段,对比了随机森林(RandomForest)、支持向量机(SVM)、梯度提升(GradientBoosting)和多层感知器(MLP)四种机器学习模型。性能评估结果表明,随机森林模型在源域故障诊断中表现最优,其准确率达到 0.9558,精确率、召回率和 F1 分数均超过 0.955, AUC 值高达 0.9962,显著优于其他模型。梯度提升模型次之,各项指标均超过 0.91,而 SVM 模型表现稳定,MLP 模型因网络结构优化不足导致性能较低(准确率仅为 0.802)。进一步分析的多指标对比可见,随机森林在精确率(0.9564)和召回率(0.9558)上均保持高水平,体现了其处理多类别故障的强鲁棒性。




Figure 3. Feature importance analysis
图 3. 特征重要性分析

图 3 特征重要性分析揭示了模型决策的关键依据[8]。随机森林与梯度提升模型均识别出时域统计特征(如峰值、标准差、峭度)和故障特征频率幅值为最重要特征,其中梯度提升对关键特征的依赖性更强(最高重要性达 0.121)。这一结果与轴承故障的物理机理高度吻合,例如峰值特征能有效捕捉冲击振动,故障频率幅值直接反映故障特性,验证了特征提取策略的有效性。

综上,结果表明,随机森林模型在源域故障诊断中具有卓越的综合性能,其集成学习机制有效处理了非线性特征和类别不平衡问题,为后续迁移学习任务提供了可靠的基准模型。特征重要性分析进一步增强了模型的可解释性,为故障机理关联提供了依据。

6. 模型评价与推广

6.1. 模型的优点

1) 模型设计系统全面,贴合实际工程需求。本文构建的迁移学习故障诊断模型充分考虑了高速列车轴承在实际运行中面临的噪声干扰与故障样本稀缺等问题,通过多域特征提取、源域模型构建、域适应策略集成等手段,实现了从实验室数据到实际运行数据的有效知识迁移,具有较强的工程适用性。

2) 特征提取方法科学合理,物理机理与数据驱动相结合。本文从时域、频域和时频域三个维度提取了 49 个特征,涵盖统计特征、故障频率幅值、小波能量等,既保留了振动信号的物理意义,又增强了特征的判别能力,为模型提供了丰富且可解释的输入信息。

6.2. 模型的不足

1) 数据预处理依赖人工设定参数, 泛化能力受限。如信号分割窗口长度、异常值剔除比例、特征稳定性阈值等参数仍需依赖经验设定, 未进行系统性的参数敏感性分析, 可能影响模型在不同工况下的适应性。同时, SMOTE 过采样倍率、欠采样比例、类别权重系数等不平衡处理参数同样依靠人工经验确定, 缺少多组参数对比试验, 难以得到全局最优平衡方案。

2) 目标域数据为仿真生成, 未使用真实故障数据验证。本文目标域数据通过源域数据加噪和变换合成, 虽能模拟分布差异, 但与真实列车运行数据的分布仍存在差距, 模型在真实故障样本上的表现尚需进一步验证。

参考文献

- [1] 刘敏, 杨清清, 涂君焕, 等. 基于 CEEMD-MOMEDA-FCM 的圆锥滚子轴承故障诊断[J/OL]. 机械传动: 1-10. <https://link.cnki.net/urlid/41.1129.TH.20250919.1527.002>, 2025-09-24.
- [2] 侯锐, 李然. 基于 MVMD-互相关时频域特征的风电变流器开路故障诊断[J]. 现代电子技术, 2025, 48(16): 31-37.
- [3] 陈硕日, 韩险峰. 基于卷积神经网络的机床轴承故障诊断应用研究[J]. 机械管理开发, 2025, 40(9): 87-89.
- [4] 王庆, 韩景超. 基于随机森林与迁移学习的排水管网缺陷跨区域预测方法[J/OL]. 软件导刊: 1-6. <https://link.cnki.net/urlid/42.1671.TP.20250908.1653.026>, 2025-09-24.
- [5] 马世典, 戴永根, 江浩斌, 等. 基于随机森林算法的智能转向系统故障诊断[J]. 江苏大学学报(自然科学版), 2025, 46(5): 514-522.
- [6] 张建良, 张晓洁, 麻坚, 等. 面向新型电力系统的故障诊断技术研究进展(二): 机器学习和大语言模型技术[J]. 实验技术与管理, 2025, 42(12): 54-70.
- [7] 何晓良, 苏春, 张玉茹. 基于改进 VMD 和 SVM 方法的滚动轴承故障诊断[J]. 东南大学学报(自然科学版), 2026, 56(2): 322-332. <https://link.cnki.net/urlid/32.1178.n.20250901.1035.002>
- [8] 颜凌岚, 常俊, 赵楠, 等. 基于雷达时频特征提取和 CBAM-MFResNet 的人体行为识别[J]. 电子测量技术, 2025, 48(24): 204-212.