

基于迁移学习的滚动轴承故障诊断方法研究

胡闽珊, 郑菲菲

重庆理工大学数学科学学院, 重庆

收稿日期: 2026年5月10日; 录用日期: 2026年6月15日; 发布日期: 2026年6月24日

摘要

高速列车轴承智能故障诊断是保障轨道交通运营安全的关键技术。随着我国“八纵八横”高铁网络的快速扩展, 列车运行密度持续加大, 轴承故障预警面临新的挑战: 一方面, 台架实验数据与真实运行数据存在显著分布差异; 另一方面, 故障样本稀缺导致传统深度学习模型泛化能力不足。在此背景下, 迁移学习为解决这类问题提供了有效的路径。本文提出一种基于特征选择与机器学习的跨工况故障诊断方法。针对源域中正常样本极少的类别不平衡问题, 采用SMOTE过采样增加样本。在此基础上, 对比了随机森林重要性排序、递归特征消除(RFE)和自编码器三种特征选择方法, 并结合随机森林、支持向量机与多层感知机(MLP)三种分类器进行性能评估。实验结果表明, RFE-20特征子集与MLP的组合在源域验证集上取得最佳性能, 准确率达95.16%。使用该最佳模型对16个无标签的目标域样本进行预测, 93.8%的样本预测置信度超过0.9, 预测类别涵盖内圈、外圈、滚动体故障及正常状态。

关键词

轴承故障分类, 迁移学习, 递归特征消除, 多层感知机, 跨工况迁移

Research on Rolling Bearing Fault Diagnosis Method Based on Transfer Learning

Minshan Hu, Feifei Zheng

College of Mathematical Sciences, Chongqing University of Technology, Chongqing

Received: May 10, 2026; accepted: June 15, 2026; published: June 24, 2026

Abstract

Intelligent fault diagnosis of high-speed train bearings is a key technology to ensure the operational safety of rail transit. With the rapid expansion of China's "Eight Vertical and Eight Horizontal" high-speed railway network, the operation density of trains continues to increase, bringing new challenges to bearing fault early warning. On the one hand, there exists a significant distribution discrepancy between bench test data and real operational data; on the other hand, the scarcity of fault

samples results in insufficient generalization ability of traditional deep learning models. Against this background, transfer learning provides an effective solution to address such problems. This paper presents a cross-condition fault diagnosis method based on feature selection and machine learning. To address severe class imbalance in the source domain, SMOTE oversampling is applied. Three feature selection methods—Random Forest importance, RFE, and Autoencoder—are compared, combined with Random Forest, SVM, and MLP classifiers. Results show that the RFE-20 feature subset with MLP achieves the highest source-domain accuracy of 95.16%. The optimal model is validated on 16 unlabeled target-domain train bearing samples, with 93.8% prediction confidence above 0.9, covering inner race, outer race, rolling element faults, and normal conditions.

Keywords

Bearing Fault, Classification, Recursive Feature Elimination (RFE), Multilayer Perceptron (MLP), Cross-condition Transfer

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

轴承是旋转机械设备的核心构成部件,广泛应用于轨道车辆、电力设备、航空发动机等各类机械设备,当前轴承故障的检测方法主要基于专家知识和经验的诊断方法和基于数据驱动的诊断方法。但是在实际应用中,原始振动信号的采集易受到各种情况的干扰,使我们很难收集到足够多的故障数据和标签。在此背景下,迁移学习为解决这类问题提供了有效的路径[1][2]。

现有跨工况故障诊断方法主要分为两类:一是基于迁移学习的域适应方法,如深度对抗网络(DANN)等,试图通过学习域不变特征来对齐源域与目标域分布;二是基于特征工程的传统机器学习方法,通过提取鲁棒的故障特征并选择稳定特征子集,直接利用源域训练模型对目标域进行预测。

本文采用第二种思路,通过特征提取与特征选择,首先,针对源域中的正常样本极少问题,采用SMOTE过采样平衡各类样本量。然后,从振动信号中提取42维时域、频域、包络谱及时频域特征,并对比随机森林重要性、递归特征消除(RFE)及自编码器三种特征选择方法,结合随机森林、支持向量机与多层感知机(MLP)三种分类器进行系统评估。最终选定RFE-20-MLP作为最佳模型,在源域验证集上达到95.16%的准确率。将该模型直接应用于16个无标签的目标域样本,获得了93.8%的高置信度预测,验证了跨工况泛化能力。

2. 数据预处理与分析

2.1. 数据分析

本文以161个具有代表性的轴承试验台架振动数据文件作为问题研究的源域数据集,和另外给出来自实际的16个轴承故障文件作为目标域数据集,数据来源于2025年“华为杯”中国研究生数学建模竞赛E题官方提供的“高速列车轴承智能故障诊断”数据集。其中,源域数据集基于轴承试验台架采集,其工况特征与公开的CWRU等数据集相似;目标域数据集为竞赛提供的16个实际列车轴承振动数据文件。为了比较源域与目标域振动信号的特征差异,为后续的跨域设备状态识别等研究提供基础,分别对已知设备状态的源域(包含正常、内圈故障、外圈故障等明确状态的设备)和未知设备状态的目标域抽取的振动数据,从时域波形分析与频域功率谱密度分析。

2.1.1. 对源域数据和目标域数据的分析

正常与故障轴承的振动信号特征区分明显。正常状态振动平稳、幅值较小；而三种故障状态均表现为振幅增大和冲击特征，且其冲击的频率、强度与规律各不相同，下图 Normal Fault 表示正常状态、Inner Race Fault 表示内圈故障、Outer Race Fault 表示外圈故障、Ball Fault 表示滚动体故障。观察图 1 可知，四种状态的频域能量分布差异显著，正常状态能量集中于低频，故障状态能量向中高频扩散，且呈现出不同的共振与调制特征，为故障诊断提供了频域依据。如图 2 展示了不同轴承健康状态下的时域波形对比，正常状态无明显周期性冲击，振动平稳随机。其余三种故障有周期性的冲击，振动幅度不均，其中滚动体故障振动特征最为复杂。

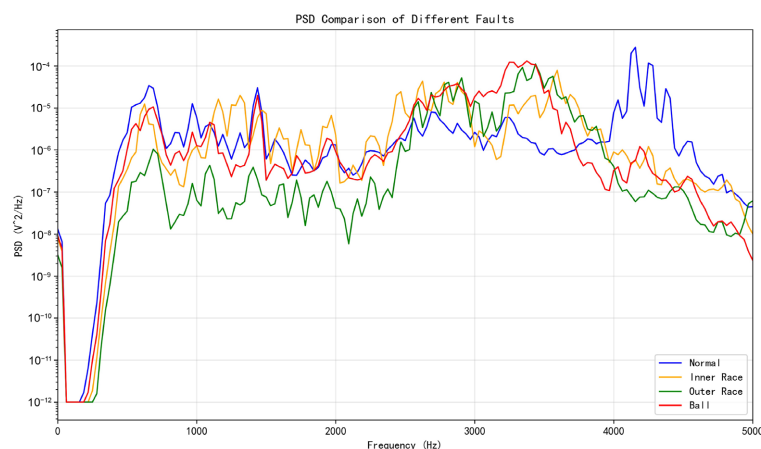


Figure 1. Comparison of power spectral density of bearings under different states

图 1. 轴承不同状态的功率谱密度对比

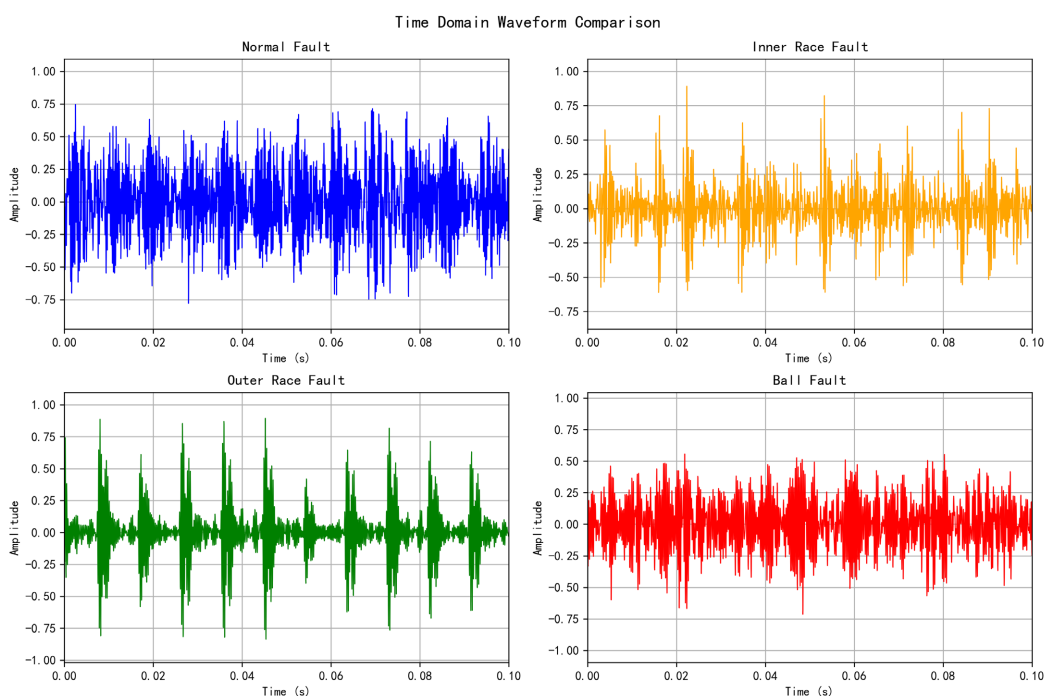


Figure 2. Comparison of time-domain waveforms of bearings under different states

图 2. 轴承不同状态的时域波形对比

2.1.2. 信号去噪

原始振动信号的状态信息常受无关信息干扰, 随机噪声会混入其中, 会让信号状态信息的准确表达与识别变得困难, 对诊断分析结果产生严重影响。因此在实际的信号处理环节中, 有必要预先处理原始振动数据[3]。本研究选择小波去噪和带通滤波。采用信噪比(Signal-to-Noise Ratio, SNR)和均方根误差(Root Mean Square Error, RMSE)作为降噪性能指标。

将小波去噪与带通滤波两种去噪方法的 SNR 和 RMSE 进行可视化对比。如图 3、图 4 所示, 带通滤波在 RMSE 和 SNR 指标上均优于小波去噪, 平均 RMSE 为 0.0505, 仅为小波去噪(0.1523)的约 1/3。平均 SNR 达 16.57 dB, 远高于小波去噪的 2.82 dB。这说明带通滤波能够在保留故障冲击特征的同时, 更有效地抑制噪声干扰, 信号失真度低、信噪比提升显著。因此, 本文最终选择带通滤波作为轴承信号的预处理方法。




Figure 3. Comparison of SNR between two denoising methods

图 3. 两种去噪方法的 SNR 对比图




Figure 4. Comparison of RMSE between two denoising methods

图 4. 两种去噪方法的 RMSE 对比图

2.2. 特征提取

在传统方法中信号处理是后续特征提取及故障分类的基础, 本文从时域、频域、包络谱、时频域四个维度对轴承振动信号进行全方位特征提取, 涵盖多类典型指标。

2.2.1. 基于时域分析的故障特征提取

时域分析方法是信号处理领域中最基础且直观的方法之一, 常用的时域指标包括峭度、均值、最大最小值、均方根值等指标。

2.2.2. 基于频域分析的故障特征提取

在故障诊断中信号处理中, 频域分析法是常用的分析方法。傅里叶变换是频域分析法的基础方法[4]。基于频谱幅值分布提取系列频域指标, 包含: 频谱质心、频谱带宽、频谱滚降点、频谱平坦度、频谱熵、频谱偏度、频谱峰度、频谱通量。

2.2.3. 基于包络谱分析的故障特征提取

包络谱分析是从振动信号里提取出关键的包络特征, 针对轴承故障高频调制、低频冲击的特点, 采用希尔伯特变换提取信号幅值包络, 再对包络信号做频谱分析得到包络谱。

2.2.4. 基于时频域分析的故障特征提取

本文采用 STFT 短时傅里叶变换与 CWT 连续小波变换构建时频矩阵, 进一步提取时频域统计特征。如均值、方差、极值、能量、熵等[5][6]。

本文共提取 42 维多维域特征, 包括时域 10 维、频域 11 维、包络谱 12 维, 以及 STFT 与 CWT 时频域各 6 维统计特征, 全面覆盖信号的时域统计、频域结构、故障调制特征与时频分布信息。

2.3. 类别不均衡处理

由于滚动轴承正常状态样本仅 4 个, 而故障样本总数达 157 个, 存在严重的类别不平衡问题。若不加以处理, 分类模型将严重偏向多数类(外圈故障), 导致正常状态及其他少数故障的识别率极低。为此, 本文采用合成少数类过采样技术(Synthetic Minority Over-sampling Technique, SMOTE)对源域特征进行平衡处理。

应用 SMOTE 后, 源域各故障类别的样本数均提升至 77 个(与原始外圈故障样本数持平), 实现了类别均衡。分类器能够更公平地学习各类故障的特征, 有效改善了对正常状态和少数故障的识别效果。

2.4. 特征选择

2.4.1. 随机森林(Random Forest, RF)

构建好随机森林分类模型, 以轴承工作状态类别(包括外圈故障、内圈故障、滚动体故障以及正常工作状态)为因变量, 以时域指标和故障频率特征指标等为自变量建立分类模型。将筛选好的数据集按照 8:2 的比例拆分成训练集和测试集, 提取特征。

随机森林按特征重要性降序排序, 计算累积贡献率, 选取累积贡献率达到 80% 的前 22 个特征, 如图 5 所示。

2.4.2. 递归特征消除(Recursive Feature Elimination, RFE)

递归特征消除(RFE)是一种基于模型的特征选择方法, 开始使用全部的特征对模型进行训练, 得到各特征的权重。从权重最小的特征开始逐步剔除, 每次剔除 5 个最不重要的特征, 逐步迭代直至剩余特征数 20, 特征选择的结果见表 1。




Figure 5. Feature importance ranking based on RF
图 5. RF 特征重要性排序

Table 1. Top 20 features selected based on Recursive Feature Elimination

表 1. 基于递归特征消除选择的前 20 个特征

排名	特征	排名	特征
1	skewness	11	spectral_entropy
2	form_factor	12	env_BSF_peak_2x
3	freq_center	13	stft_tf_std
4	freq_variance	14	stft_tf_max
5	freq_peak	15	stft_tf_energy
6	spectral_centroid	16	cwt_tf_mean
7	spectral_bandwidth	17	cwt_tf_std
8	spectral_rolloff	18	cwt_tf_max
9	spectral_skewness	19	cwt_tf_energy
10	spectral_kurtosis	20	cwt_tf_entropy

2.4.3. 自编码器(Auto Encoder, AE)

自编码器输出的是全新的低维特征，这些特征是原始特征的“非线性融合”，输入高维原始特征，编码器将其压缩到低维。例如无法解释“特征 1”对应原始数据的哪个具体的指标，基于降维效率、后续任务需求，本文设定自编码器为 42-128-64-12 编码器(ReLU + BN + Dropout)与对称解码器，MSE 损失，

Adam 学习率为 0.001, 训练 100 轮, batch = 32, 10%验证集早停。

3. 模型预测分析

对筛选得到的特征子集对模型进行训练, 以支持向量机(SVM)、随机森林(Random Forest)以及多层感知机(MLP)这三种经典机器学习模型为基础。划分源域训练集与测试集进行训练, 训练完成后, 使用这些模型对目标对象(不同故障类型的轴承等)进行预测分类。评价指标为准确率、精确率、召回率、F1 分数。

3.1. 模型选择

3.1.1. 支持向量机(Support Vector Machine, SVM)故障特征分类

训练支持向量机分类模型的参数如表 2 所示, 表 3 为 SVM 模型在不同特征选择方法下的关键性能指标表格。SVM 在三种特征选择方法(随机森林(RF-22)、递归消除法(REF-20)、自编码器(AE-12))中, 随机森林(RF-22)效果最好。

Table 2. SVM classification model parameters

表 2. 支持向量机分类模型参数

参数名称	参数意义	调参范围	结果
c	控制模型对分类错误的容忍程度	[0.1, 1, 10]	10
gamma	决定样本间的相似性对分类边界的影响程度	[scale, 0.001, 0.01]	scale
kernel	决定 SVM 如何处理数据的非线性关系	[rbf, poly]	rbf

Table 3. Key performance indicators of SVM model

表 3. 支持向量机模型的关键性能指标

特征选择	准确率	精确率	召回率	F1 分数
全特征(42-dim)	0.8387	0.8522	0.8387	0.8413
随机森林(RF-22)	0.8226	0.8364	0.8226	0.8227
递归消除法(REF-20)	0.7903	0.7994	0.7903	0.7932
自编码器(AE-12)	0.7903	0.8027	0.7903	0.7927

3.1.2. 基于多层感知机(Multilayer Perceptron, MLP)故障特征分类

多层感知机(MLP)分类器采用三层隐藏层结构, 神经元数量分别为 128、64 和 32, 各层激活函数均为 ReLU, 输出层为 4 个单元的 Softmax 层, 用于输出四种故障类型的概率。模型训练使用 Adam 优化器, 初始学习率设置为 0.0008, 同时引入 L2 正则化(系数为 0.01)以防止过拟合。

表 4 为是 MLP 模型在不同特征选择方法下的关键性能指标表格。MLP 在三种特征选择方法(随机森林(RF-22)、递归消除法(REF-20)、自编码器(AE-12))中, 递归消除法(REF-20)效果最好。

3.1.3. 基于随机森林的故障特征分类

随机森林模型的参数如表 5 所示, 表 6 为是 SVM 模型在不同特征选择方法下的关键性能指标表格。随机森林在三种特征选择方法(随机森林(RF-22)、递归消除法(REF-20)、自编码器(AE-12))中, 递归消除法(REF-20)效果最好。

Table 4. Key performance indicators of MLP model

表 4. MLP 模型的关键性能指标

特征选择	准确率	精确率	召回率	F1 分数
全特征(42-dim)	0.9355	0.9362	0.9355	0.9344
随机森林(RF-22)	0.9194	0.9182	0.9194	0.9183
递归消除法(REF-20)	0.9516	0.9546	0.9516	0.9516
自编码器(AE-12)	0.8871	0.8914	0.8871	0.8851

Table 5. Random Forest (RF) model parameters

表 5. 随机森林模型参数

参数名称	参数值	说明
n_estimators	100	决策树数量
max_depth	None	树的最大深度(不限制)
min_samples_split	2	内部节点再划分所需的最小样本数
min_samples_leaf	1	叶子节点的最小样本数
class_weight	balanced	类别权重自动平衡, 适应样本不均衡

Table 6. Key performance indicators of random forest model

表 6. 随机森林模型的关键性能指标

特征选择	准确率	精确率	召回率	F1 分数
全特征(42-dim)	0.9194	0.9211	0.9194	0.9188
随机森林(RF-20)	0.9032	0.9026	0.9032	0.9015
递归消除法(REF-22)	0.9355	0.9413	0.9355	0.9348
自编码器(AE-12)	0.8710	0.8743	0.8710	0.8672

综合三张关键性能指标表格中不同模型在各类特征选择方法下的性能表现, MLP 模型在自编码器特征选择时, 准确率为 95.16%、精确率为 95.46%、召回率为 95.16%、F1 分数为 95.16%均显著高于其在随机森林和递归消除法特征选择下的表现, 说明 MLP 模型结合递归消除法特征选择, 在分类的准确性、预测可靠性、以及综合平衡性能上, 都展现出了更优的效果, 更能满足分类任务需求。

最终选择递归消除 - 多层感知机模型(Recursive Feature Elimination-Multi-Layer Perceptron, 以多层感知机(MLP)模型), 且采用递归消除法进行特征选择。

3.2. 特征提取的消融研究

为了验证递归特征消除法在特征提取中的作用, 设计消融实验对比使用原始 42 维特征与递归特征消除后的 22 维特征对分类性能的影响。实验采用相同的 MLP 分类器, 在源域数据上进行 3 折交叉验证。

结果如图 6 所示, 原始特征的平均准确率为 93.55%, 采用递归特征消除(RFE)筛选后的 22 维特征的平均准确率为 95.16%, 这说明在降低特征维度的同时实现了性能优化, 证明 RFE 能有效剔除冗余特征, 提取具有强判别性的故障信息。

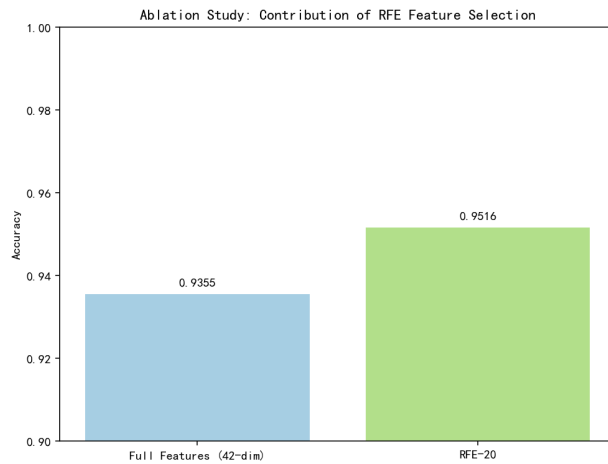


Figure 6. Ablation study of RFE feature selection
图 6. RFE 特征选择的消融实验结果

4. 目标域故障诊断结果与分析

基于 16 个目标域滚动体故障样本, 采用经 RFE 特征选择优化后的 MLP 模型进行故障诊断, 预测结果整体表现优异。模型在目标域上的预测置信度分布呈现出显著的高置信度集中特征, 具体统计结果如表 7 和图 7 预测置信度分布饼图所示。

Table 7. Prediction results on target domain samples

表 7. 目标域样本预测结果

样本 ID	A	B	C	D	E	F	G	H
预测故障类型	B	IR	IR	IR	IR	B	OR	OR
预测置信度	0.9999	0.95113	0.99999	0.99939	0.99999	0.99994	0.99209	0.67415
样本 ID	I	J	K	L	M	N	O	P
预测故障类型	IR	IR	N	OR	B	IR	OR	IR
预测置信度	0.99999	0.99999	0.94975	0.96484	0.99995	1	0.9994	0.98646

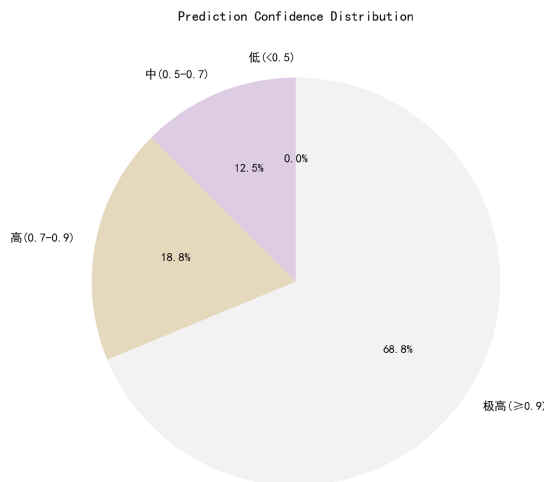


Figure 7. Prediction confidence distribution pie chart
图 7. 预测置信度分布饼图

从表 5 可知, 模型在目标域上的预测置信度分布呈现出显著的高置信度集中特征。依据设定的置信度等级: 极高: ≥ 0.9 , 高: ≥ 0.7 且 < 0.9 , 中: ≥ 0.5 且 < 0.7 , 低: < 0.5 , 对结果进行划分, 可以清晰地评估预测结果的整体可靠性。绝大多数目标域样本的分类结果具备极高的置信度, 在 16 个目标域样本中, 只有 1 个样本的置信度在 0.5~0.7 中等置信度区间。有 15 个样本的统计置信度 ≥ 0.9 , 占比为 93.75%。从故障类别分布看, 预测结果包含 10 个内圈故障(IR)、4 个外圈故障(OR)、2 个滚动体故障(B)和 1 个正常状态(N)四类, 虽然无法获得真实标签进行定量验证, 但高置信度分布和类别多样性间接证明了模型在跨工况条件下的良好泛化能力。

5. 总结与讨论

本文针对高速列车滚动轴承跨工况故障诊断中源域与目标域数据分布偏移的问题构建了一套递归特征消除(RFE)优化的多层感知机(MLP)故障诊断模型。通过源域与目标域的多组对比实验, 在源域验证集上取得 95.16%的准确率, 并在 16 个无标签的目标域样本上获得了 93.8%的高置信度预测。验证了所提方法的有效性 with 可靠性。但是本文所用的目标域的数量只有 16 个, 缺乏大量样本。且 RFE 特征选择过程需要迭代训练模型, 计算成本相对较高。未来可以扩充目标域的样本, 提升评估的统计意义, 结合更高效的特征筛选方法, 进一步提升模型的整体效率。

参考文献

- [1] 陈强强, 戴邵武, 戴洪德, 等. 滚动轴承故障诊断方法综述[J]. 仪表技术, 2019(9): 1-4+42.
- [2] 张安安, 黄晋英, 冀树伟, 等. 基于卷积神经网络图像分类的轴承故障模式识别[J]. 振动与冲击, 2020, 39(4): 165-171.
- [3] 孙伟, 熊邦书, 黄建萍, 莫燕, 小波包降噪与 LMD 相结合的滚动轴承故障诊断方法[J]. 振动与冲击, 2012(18): 153-156.
- [4] 洪晓翠, 段礼祥, 徐继威, 等. 变工况下轴承故障的残差对抗网络诊断方法[J]. 石油机械, 2022, 50(5): 32-42.
- [5] 李恒, 张氢, 秦仙蓉, 孙远韬. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J]. 振动与冲击, 2018(19): 124-131.
- [6] 林京, 屈梁生. 基于连续小波变换的信号检测技术与故障诊断[J]. 机械工程学报, 2000(12): 95-100.