



基于实值傅里叶变换与HDMixer的 牵引电机故障诊断

刘锦怡¹, 李秉坤¹, 刘 帅², 王连富²

(1. 中车科技创新(北京)有限公司第六研究所, 北京 100083;

2. 中车长春轨道客车股份有限公司, 吉林 长春 130062)

摘要: 转向架系统作为列车走行部的重要组成部分, 其健康状况直接关系到列车运行的安全性。因此, 实现对转向架系统故障信息的诊断具有极其重要的意义, 其不仅可以提升列车的运行安全, 还能为日后的维修与维护提供可靠依据。文章首先聚焦于列车转向架系统中牵引电机的故障诊断, 采用实值傅里叶变换(real fast fourier transform, rFFT)技术对信号进行处理, 通过频谱分析提取故障特征, 以捕捉电机运行中的异常信号; 然后, 引入一种基于可扩展Patch与层级依赖的多元时间序列预测神经网络模型——HDMixer作为主要分析工具。该模型利用其独特的架构特点, 对不同时间序列数据进行深入分析, 从而提高故障诊断的精度和可靠性。试验结果表明, 在理论基础和数据验证的支持下, HDMixer模型在牵引电机故障诊断中表现出色, 诊断准确率超过93%。不仅如此, 该模型在不同工况条件下依然能够保持高准确率, 显示出良好的泛化能力。该研究不仅为转向架系统的故障诊断提供了有效的方法, 而且为列车的日常维护和长期运行安全提供了重要的技术支持。

关键词: 故障诊断; 转向架; 牵引电机; 深度学习; 神经网络; 城市轨道交通

中图分类号: U269.32²

文献标志码: A

文章编号: 1000-128X(2025)05-0170-09

0 引言

随着交通运输向现代化与高速化发展, 轨道交通已成为城市交通系统中不可或缺的一部分, 并承担着越来越重要的功能角色, 确保轨道交通系统的安全性和高效运行对于城市发展具有重要意义。转向架系统作为列车的核心子系统, 其工作状态与性能将直接影响列车的行车安全, 其中关键零部件的失效则是影响转向架系统可靠性的主要因素之一^[1]。传统的部件故障检测方法主要依赖于定期维护和人工检测, 但这种方法存在检测周期长、成本高、实时性差等问题。现代信号处理技术和人工智能等技术的发展, 为轨道交通系统部件的状态监测和故障预测提供了新的解决方案。目前针对转向架部件的故障诊断研究主要基于三大方

向, 最常采用的方法是基于信号处理的诊断, 就是通过频域分析、时频分析等方法实现振动信号的特征分析与故障诊断; 其次随着大数据、人工智能等领域的技术发展, 机器学习等相关方法也被运用到智能故障诊断中, 与信号处理相比, 其对专业知识的要求较低^[2], 通常包括故障树^[3]、支持向量机^[4]等方法。同样, 深度学习也在支撑着精准故障诊断的发展, 通常多以视觉领域为主, 例如目标检测、图像处理^[5]等应用方法。因此, 本文将以牵引电机的振动信号与电流信号的处理特征即频域特征为基础, 结合在深度学习领域具有优秀表现的HDMixer模型对牵引电机的故障诊断进行研究。本研究将通过试验验证其有效性和实用性, 为今后诊断转向架系统中牵引电机的故障提供参考, 有助于避免电机故障所造成的损失, 提高转向架系统运行的可靠性及稳定性, 为轨道交通系统的智能维护

通信作者: 刘锦怡, 女, 硕士, 主要从事故障预测与健康管理方面的研究; E-mail: 1294473771@qq.com

引用格式: 刘锦怡, 李秉坤, 刘帅, 等. 基于实值傅里叶变换与HDMixer的牵引电机故障诊断[J]. 机车电传动, 2025(5): 170-178.DOI:10.13890/j.issn.1000-128X.2025.05.102.

Citation: LIU Jinyi, LI Bingkun, LIU Shuai, et al. Traction motor fault diagnosis based on rFFT and HDMixer[J]. Electric drive for locomotives, 2025(5): 170-178.DOI:10.13890/j.issn.1000-128X.2025.05.102.

提供理论和技术支持。

1 牵引电机故障研究现状及试验背景

牵引电机作为转向架系统中的核心动力装置，主要为列车提供牵引力，负责推动列车运行^[6]。牵引电机不仅要面临严峻的工作条件和巨大的工作负荷，而且要承受来自轮轨系统的振动和冲击，以及长期的电、磁、热、机械应力等复合作用的影响^[7]，很容易出现疲劳损伤、故障等问题，影响列车的动力性能，甚至危及列车运行安全。一台牵引电机的故障也可能会增加其他牵引电机和部件的负担，加速它们的磨损和故障；同时，牵引电机故障还可能引起电气系统的不稳定，影响列车其他电气设备的正常运行^[8]，进而增加维护成本，降低列车的运营效率，影响整体运输能力。

1.1 牵引电机的故障机理及研究现状

牵引电机的组成部件主要包括转子、定子、轴承、速度传感器和温度传感器等，如图1所示。对应的部件也存在相应的常见故障，其中转子常见的故障有转子断条，该故障会造成牵引电机在运行过程中发热并导致导条和端环损坏；常见的定子故障为定子匝间短路，最终导致定子局部过热或绝缘失效；而轴承作为重要部件，故障通常出现在其组成部件上，如保持架、滚动体、内圈、外圈；定子、转子不同轴心或铁芯呈椭圆形造成的静态偏心和轴弯曲在高转速时的机械共振造成的动态偏心故障最终也会引起牵引电机气隙偏心故障^[9]。




图1 牵引电机内部简化图^[9]
Fig. 1 Simplified internal view of a traction motor ^[9]

当故障出现时，通常在载荷的作用下故障部位会与正常部位进行不断的碰撞，其产生的冲击力将造成其他零件的振动，最终形成一系列的减幅振荡，并且振荡的频率也不断变化。目前用于牵引电机故障信号采集检测的技术有振动检测法、绝缘检测法、放电检测法、磁通检测法、温度检测法，但采集到的信号中通常包含有大量噪声，针对该问题，多数研究采用不同的信号处理方法来降低噪声的影响^[9]。




图2 常见的牵引电机故障^[10]
Fig. 2 Common traction motor faults ^[10]

1.2 试验背景

本研究的数据集源于北京交通大学先进轨道交通自主运行全国重点实验室^[10]，试验台中单条传动链包含电机、减速齿轮箱、轴箱。传动链由三相异步交流电机驱动，负载通过液压装置进行加载。电机轴承型号为SKF6205-2RSH，结构如图3所示，减速齿轮箱的齿轮为斜齿轮，驱动齿轮齿数为16，从动齿轮齿数为107，驱动齿轮支撑轴承型号为哈尔滨轴承厂的32305，轴箱轴承型号为哈尔滨轴承厂的352213。图4为故障模拟试验台，其中①部分为牵引电机，电流钳用来监测电流，在驱动端和非驱动端各有一个加速度计。




图3 电机轴承结构图
Fig. 3 Structure of motor bearing



图4 地铁列车传动系统故障模拟试验台^[10]

Fig. 4 Fault simulation test bench for metro train drive system^[10]

常见的地铁牵引电机性能参数如表1所示，试验中的机械故障模拟通常是通过真实再现故障状态。轴承故障一般是在轴承上钻孔或刻槽以模拟滚动体缺陷，或安装带损伤的轴承或在试验过程中人为引入磨损；转子故障是在转子上制造断条或增加偏心，或调整转子配重来引入不平衡状态；定子故障则是通过制造定子偏心或铁芯断裂或使用振动激励器模拟定子松动。

表1 牵引电机性能参数

Table 1 Performance parameters of traction motor

参数项目	参数值
额定电压/V	1 050
额定电流/A	131
额定频率/Hz	60.9
额定功率/kW	190
额定转速/(r·min ⁻¹)	1 800
额定效率/%	93.52
额定功率因数/%	82
质量/kg	620
极数	4

试验共采集了三向振动信号和三相电流信号，分别在电机的驱动端和非驱动端测点位置采集了三相加速度值，在电机线缆处采集了三相电流值，每个通道的采样频率均为 64 kHz。试验中同时也考虑了9种不同的工况，如表2所示。通过变频器控制电机速度，从而模拟列车运行速度的不同，以及电动液压负载设备来控制横向负载的不同，从而模拟列车的直线行驶和过弯，垂直负载设定为 10 kN 的恒定值。

表2 试验工况总览^[10]

Table 2 Summary of experimental conditions^[10]

工况	电机转速/横向负载	工况	电机转速/横向负载
WC1	20 Hz/0 kN	WC6	40 Hz/-10 kN
WC2	20 Hz/10 kN	WC7	60 Hz/0 kN
WC3	20 Hz/-10 kN	WC8	60 Hz/10 kN
WC4	40 Hz/0 kN	WC9	60 Hz/-10 kN
WC5	40 Hz/10 kN		

2 牵引电机故障特征分析

2.1 牵引电机故障原理说明

对于牵引电机的故障诊断，研究通常使用振动信号和电流信号作为监测信号，因其可以反映电机的机械状态和电气状态。因此，可以通过分析这些信号在时域和频域中的变化来有效地识别电机的不同故障类型。表3概括了牵引电机不同部件故障类型所对应的电流信号和振动信号在时域及频域上不同的特征表现。

表3 不同故障类型的时频域特征

Table 3 Time-frequency domain characteristics of different fault types

故障类型	时域特征	频域特征
定子故障	电流波形异常波动	电流信号的频谱中表现出特定的频率成分和异常的谐波
转子故障	不规则的振动或周期性的脉冲，振动信号的周期性波动或信号的幅值波动	低频峰值
轴承故障	周期性脉冲振动信号	明显的峰值，尤其是在与转速成倍关系的频率上
电磁故障	周期性波动或不规则振动波形	低频振动，且这些频率成分与电机的转速和供电频率密切相关

2.2 时域分析

在信号处理和时频域特征分析中通常选用振动信号作为研究目标，主要原因是振动信号对机械结构和设备中的异常情况的敏感性较高^[11]，在监测机器和设备健康状况时，振动信号能够揭示设备内部的磨损、裂纹、松动等问题。此外，振动信号中包含的频率信息还可以采用信号处理技术来识别和分离不同来源的振动成分，从而实现实时监测和分析，并被广泛应用于旋转机械的预测性维护中，提前发现潜在问题，进而避免设备故障^[12]。因此基于目前时频域特征分析的研究，本研究首先通过最直观的故障诊断方法，也就是对振动值及电流值在时域上进行可视化分析和评

估^[13]。图 5 为牵引电机驱动端和非驱动端在不同工况下发生上述故障的振动信号时域图。从时域图中难以对比出不同故障间波形、瞬时特性和周期性的区别, 难以直接提取和量化频率成分, 也不易发现处于不同工况下同一类别故障的共性。除此之外, 时域中噪声和

信号通常混杂在一起, 去除噪声也是分析中的难题。然而, 在频域中, 可以更容易地识别和滤除特定频段的噪声。例如, 通过设计带阻滤波器的方法, 可以有效地去除某些频段内的噪声, 同时保留信号的其他部分, 有助于信号噪声比优化和信号增强^[14]。




图 5 不同工况下正常状态与故障状态时域波形

Fig. 5 Time-domain waveforms of normal and faulty states under different conditions

2.3 频域分析

鉴于时域分析方法存在不足, 为此引入频域分析方法。振动信号的频域分析是最常用的振动分析技术,

离散的时域信号通过快速傅里叶变换被转换至频域, 频率成分的变化将用来进一步诊断故障^[15]。实值快速傅里叶变换 (rFFT) 是快速傅里叶变换的一个变种, 专门用于处理实数序列, 因为实数序列的傅里叶变换

结果是共轭对称的, 所以只对非负频率部分进行计算, 如式(1)所示。与传统的快速傅里叶变换相比, rFFT 的运算次数更少, 所需内存更少, 效率更高, 能够同时实现更高的吞吐量和更低的延迟^[16]。与适合非平稳信号的小波变换相比, rFFT 计算复杂度较低。图 6 所示为图 5 中的振动信号经 rFFT 变换后 (左) 和小波变换后 (右) 的频域图, 经对比分析可见, rFFT 变换后频

域特征更明显。由图 6 可见, 在 rFFT 频谱中无故障时未见低频波峰, 当电机出现短路故障时, 低频部分未见异常而波峰的位置有所改变, 当电机出现断条、轴弯曲、轴承故障时出现不同的低频波峰。

本文将完全使用 rFFT 把输入时间序列从时域转到频域再计算其绝对值, 将计算结果输入到深度神经网络对部件的三轴加速度采集值的 rFFT 结果进行特征提




图 6 不同工况下正常状态与故障状态频域波形

Fig. 6 Frequency-domain waveforms of normal and faulty states under different conditions

取, 然后进行多层卷积滤波, 最后融合到线性层对所有部件的故障进行端到端式诊断, 如式(1)。

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{-i \frac{2\pi}{N} kn} \quad (1)$$

式中: $X[k]$ 为rFFT在频率索引 k 处的值; $x[n]$ 为输入的实数序列; N 为输入序列的长度; i 为虚数单位; k 的取值范围为 $0 \leq k \leq \left\lfloor \frac{N}{2} \right\rfloor$ 。

3 建立神经网络故障诊断分类模型

3.1 HDMixer神经网络

HDMixer是一种基于可扩展Patch与层级依赖的多元时间序列预测神经网络, 能够处理多元时间序列数据中的复杂依赖关系, 通过捕捉数据中的层级依赖关系和空间特征来提高预测性能, 并且具有较强的通用性, 适用于各种类型的多元时间序列数据^[17]。HDMixer的模型结构如图7所示, 输入层的多元时间序列数据首先经过长度可扩展修补器(length-extendable patcher, LEP), 数据预处理将多元时间序列数据划分为多个补丁(Patch), 并进行归一化处理, 使每一个Patch都包含固定长度的时间步和所有维度的特征。之后通过编码器实现每个Patch的特征提取, 并构建层级依赖结构。层级依赖管理模块(hierarchical dependency explorer, HDE)通常由多个层级的编码器组成, 包括自注意力机制、卷积层、层级依赖构建, 实现短期、长期、变量间依赖关系的捕捉。其中自注意力机制用于捕捉Patch内的时间依赖关系, 通过计算时间步之间的注意力权重, 提取时间步之间的相关性; 卷积层则通过卷积操作提取时间序列中的空间特征, 用于捕捉Patch内的局部特征; 而层级依赖构建通过逐层传递和汇总信息, 构建不同层级之间的依赖关系。之后再通过加权或拼接操作, 以及信息传递的混合机制将不同层级的特征信息融合、汇总。最终, 解码器模块实现预测结果的生成, 与编码器的结构类似, 同样具有自注意力机制、卷积层, 用于提取依赖关系和局部特征, 而特征重构则根

据逐层传递和汇总的特征信息, 生成最终的预测结果。

3.2 模型的应用流程

首先完成对数据的预处理, 对每一段数据进行滑窗分段处理(sliding window), 因为时间序列数据具有时间依赖性, 即当前时间步的数据通常与之前的时间步有一定的关联。滑窗处理通过固定长度的窗口捕捉这种时间依赖性, 使得模型可以学习到时间序列中的模式和趋势, 提高预测的准确性^[18]。基于上文中时频域的分析结果, 将经过特征处理rFFT变换及标准化后的数据作为模型的输入数据。在数据集定义中完成对训练与测试数据集的划分, 本试验在经过长度为64 000、间隔长度为640的滑窗处理后, 采用工况不同的数据分别作为训练集、验证集和测试集, 其中训练集的工况为转速20 Hz、60 Hz, 共39 644个样本, 验证集和测试集的工况均为转速40 Hz, 样本数量分别为1 982个和17 840个, 如此设计的目的是对模型的泛化性进行评估, 查看其是否适用于不同工况下的故障诊断。其中训练数据集的分布情况如图8所示, 训练数据集中无故障M0的数据较多, 验证集与测试集类似, 这也正是在故障诊断中常见的现象。

HDMixer模型的训练阶段如图8所示, 在完成数据预处理后, 进入模型的训练阶段, 其中HDMixer的主干网络负责提取不同维度数据中的特征, 再通过卷积层和池化层进一步提取特征。




图8 训练数据集分布图

Fig. 8 Distribution of training dataset

3.3 模型的训练过程

3.3.1 试验环境及训练参数

模型的运行环境是Intel(R) Xeon(R) Gold 6130处理器和NVIDIA V100显卡, 操作系统是ubuntu20.04 (python 3.8), 深度学习框架为PyTorch 1.11.0, CUDA的版本为11.3。模型的训练次数Epoch设置为30, 训练批batch size为32, 优化器为Adam, 学习率初始值为0.000 1, 其余的参数设置如图10所示。




图7 HDMixer模型整体结构图^[16]

Fig. 7 Overall structure of HDMixer^[16]




图9 模型应用流程图

Fig. 9 Flowchart of model application

Namespace(affine=0, batch_size=32, c_out=6, checkpoints='./checkpoints/', d_ff=2048, d_layers=1, d_model=512, dec_in=6, decomposition=0, deform_patch=1, deform_range=0.25, des='test', dropout=0.05, e_layers=3, enc_in=2, fc_dropout=0.05, file_keywords='data_motor.csv', gpu=0, head_dropout=0.0, individual=0, is_training=1, itr=2, kernel_size=25, lambda=0.1, learning_rate=0.0001, loss='mse', lradj='type3', mix_channel=1, mix_time=1, mix_variable=1, model='HDMixer', model_id='test', n_heads=8, num_class=5, num_workers=0, output_attention=False, padding_patch='end', patch_len=640, patience=3, pct_start=0.3, pred_len=16000, r=0.01, random_seed=2021, revin=1, root_path='/root/autodl-tmp/Data_Final_Stage', sample_list_test='Sample_2', sample_list_train='Sample_1,Sample_3', sample_stride=1, selected_columns=['CH1', 'CH2', 'CH3', 'CH4', 'CH5', 'CH6', 'CH7', 'CH8', 'CH9'], seq_len=32000, step_per_sample=640, subtract_last=0, test_flop=False, train_epochs=30, use_amp=False, use_gpu=True, use_multi_gpu=False, valid_test_ratio=0.1, window_size=6)

图10 模型参数设置

Fig. 10 Model parameters

模型中每层的流程如下：

① 数据预处理。RevIn层通过归一化输入特征，使模型能够处理跨分布的时间序列数据，并将patch_shift_linear用于降维处理、特征映射，输入特征维度参数为32 000，映射到特征维度150，从而降低计算复杂度。

② 特征编码与混合模块。

Patch Mixer：多层线性投影 + 激活函数（GELU）+ Dropout，在空间维度上混合特征，提取不同时间步中局部特征。

Time Mixer：处理时间步上的依赖关系，每个时间步有50个特征，模型将其映射到更高维的空间（100维），并经过激活和Dropout。

Variable Mixer：与Time Mixer类似，但作用在变量维度上，对多变量特征进行建模，学习它们之间的相互作用，变量数从3增加到6，然后回到3，确保模型不会丢失变量间的重要特性。

③ Flatten将编码器输出的多维特征展平，作为全连接层的输入。全连接层（Linear）输入特征维度25 600，输出16 000，用于生成最终预测。

④ 卷积层。独立的卷积路径（如conv、conv1、conv2）通过多层Conv1d + Tanh模块处理一维特征，利用MaxPool和步幅卷积对数据进行降采样。

⑤ 分类器。全连接层堆栈处理从所有路径压平后的特征向量，将其减少到最终的输出维度，包括Tanh激活函数，以及最后的Sigmoid层用于分类。

3.3.2 模型试验结果

模型的训练过程如图11所示，首先需要初始化模型的所有参数、优化器和损失函数，以及所需要的数据加载器。其次，在训练的迭代过程中，每个轮次都会遍历一次整个训练数据集，同时也在此处设置了早停机制防止模型过拟合。此外，训练数据集也将分成数个批次，从而降低显存占用，并通过小批次随机梯度下降实现参数更新，提升训练效率。输入数据通过前向传播实现从输入与输出之间的复杂映射，此处使

算法1：HDMixer框架	
输入：	epochs：迭代轮次，DataLoader：数据加载器
输出：	model：训练后的模型
1:	function Train_HDMixer():
2:	#初始化模型参数
3:	for epoch in range(Max_Epochs):
4:	for batch in DataLoader:
5:	# 前向传播
6:	Predictions ← HDMixer_Network
(batch.inputs)	
7:	# 计算损失
8:	Loss ← Loss_Function(Predictions,
batch.labels)	
9:	# 反向传播和参数更新
10:	Loss.backward()
11:	Optimizer.step()
12:	return model

图11 模型的训练过程

Fig. 11 Training process of model

用的激活函数为ReLU。之后, 通过均方误差 (MSE) 作为损失函数量化模型预测概率与实际标签间的误差进一步指导模型的优化。最终, 反向传播通过从输出层向输入层逐次计算梯度误差, 从而优化网络参数、最小化损失函数。

经过多次迭代, 以及Adam优化算法的参数优化最后得到一个完成训练的模型。模型最终的输出结果是根据对每一个状态的预测概率进行判断的, 当概率大于0.5时则判断该状态为1, 综合输出一个长度为5, 取值为0或1的数组。图12所示为训练期间损失值的变化图, 可见训练过程中的验证损失也在同步稳定地下降。最终模型在不同负载、不同转速的工况下, 诊断正确率可以达到93.80%, 召回率为93.80%, 精确率为93.77%, F1值为93.78%, 实现有效地区分故障类型。




图12 模型训练期间损失变化图
Fig. 12 Loss over training epochs

3.4 神经网络分类方法对比

通过与其他主流的神经网络分类模型进行对比, 效果如表4所示。其中CNN所需要的训练时长较长, 且计算量需求大, LSTM的训练时间虽短但准确率较低, 尤其对于超长的输入效率有明显的下降。与传统的Transformer相比, HDMixer的训练时间更短, 且准确率更高。因此综合来看, HDMixer更适合长序列的输入数据, 并可以与rFFT相结合通过频域对牵引电机的故障进行诊断分类。

表4 不同神经网络的对比结果
Table 4 Comparative results of different neural networks

模型	准确率	训练时间	参数量
CNN	83.19%	长	最多
LSTM	78.72%	中等	少
Transformer	87.53%	最长	多
HDMixer	93.80%	短	中等

4 结论

综上所述, 本文提出了一种基于实值傅里叶变换 (rFFT)与多元时间序列预测神经网络(HDMixer)的牵引

电机故障诊断方法。试验结果表明, rFFT方法能够有效地将时域信号转换为频域信号, 提取出与故障相关的特征频率, 从而识别电机的故障类型, 再结合HDMixer神经网络模型进行分析, 在不同工况下均能保持93%以上的正确率, 具备优异的泛化能力。这一研究不仅为牵引电机的故障诊断提供了可靠的方法, 还为列车的日常运维提供了重要的技术支持, 具有广泛的应用前景。日后工作中将收集更多样化和更大规模的数据集, 涵盖更多故障模式和不同的工况条件, 以提升模型的泛化能力和鲁棒性。此外, 也可以研究更轻量化的模型架构或采用模型压缩技术, 以降低模型复杂度并提高推理效率。

参考文献:

[1] 金学松, 郭俊, 肖新标, 等. 高速列车安全运行研究的关键科学问题[J]. 工程力学, 2009, 26(增刊2): 8-22.
JIN Xuesong, GUO Jun, XIAO Xinbiao, et al. Key scientific problems in the study on running safety of high speed trains[J]. Engineering mechanics, 2009, 26(Suppl 2): 8-22.

[2] 田家臣. 基于故障诊断的轨道车辆转向架智能运维系统的设计与实现[D]. 北京: 北京交通大学, 2023.
TIAN Jiachen. Design and implementation of intelligent operation and maintenance system for rail vehicle bogies based on fault diagnosis[D]. Beijing: Beijing Jiaotong University, 2023.

[3] 王丹. 基于故障树和贝叶斯网络的动车组转向架系统故障诊断[D]. 天津: 天津大学, 2015.
WANG Dan. Fault diagnose of CRH bogie system based on fault tree and Bayesian network[D]. Tianjin: Tianjin University, 2015.

[4] 刘畅, 伍星, 刘韬, 等. 基于近似等距投影和支持向量机的滚动轴承故障诊断[J]. 振动与冲击, 2018, 37(5): 234-239.
LIU Chang, WU Xing, LIU Tao, et al. Fault diagnosis of rolling bearings based on near-isometric projection and support vector machine[J]. Journal of vibration and shock, 2018, 37(5): 234-239.

[5] 顾超. 基于目标轮廓特征的图像识别及列车转向架故障检测[D]. 苏州: 苏州大学, 2014.
GU Chao. Image recognition based on object contour feature and its application in train bogie fault diagnosis[D]. Suzhou: Soochow University, 2014.

[6] 廖俊. 地铁车辆牵引电机轴承故障分析及改善措施[J]. 现代城市轨道交通, 2024(2): 57-63.
LIAO Jun. Analysis of bearing faults in metro vehicle traction motors and improvement measures[J]. Modern urban transit, 2024(2): 57-63.

[7] 张宝杰, 麻宸伟, 贾震, 等. 基于卷积神经网络的牵引电机定子绕组匝间短路故障诊断[J]. 铁道学报, 2024, 46(4): 73-79.
ZHANG Baojie, MA Chenwei, JIA Zhen, et al. Fault diagnosis of stator winding inter-turn short circuit in traction mo-

- tors based on convolutional neural network[J]. Journal of the China railway society, 2024, 46(4): 73-79.
- [8] LI Yanshu, LI Fang, LU Chang, et al. Retraction note: composite fault diagnosis of traction motor of high-speed train based on support vector machine and sensor[J]. Soft computing, 2024, 28(1): 377.
- [9] 程海鹏, 吴连军, 宋山, 等. 牵引电机故障诊断方法研究[J]. 内燃机与配件, 2020(14): 76-77.
CHENG Haipeng, WU Lianjun, SONG Shan, et al. Research on fault diagnosis method of traction motor[J]. Internal combustion engine & parts, 2020(14): 76-77.
- [10] DING Ao, QIN Yong, WANG Biao, et al. Evolvable graph neural network for system-level incremental fault diagnosis of train transmission systems[J]. Mechanical systems and signal processing, 2024, 210: 111175.
- [11] GOYAL D, PABLA B S. The vibration monitoring methods and signal processing techniques for structural health monitoring: a review[J]. Archives of computational methods in engineering, 2016, 23(4): 585-594.
- [12] POPESCU T D, AIORDACHIOAIE D, CULEA-FLORESCU A. Basic tools for vibration analysis with applications to predictive maintenance of rotating machines: an overview[J]. The international journal of advanced manufacturing technology, 2022, 118(9): 2883-2899.
- [13] 谢国民. 基于时频联合小波法的采煤关键部件故障诊断研究[D]. 阜阳: 辽宁工程技术大学, 2012.
- XIE Guomin. Research of coal minning machine mechanical fault diagnosis based on the combination wavelet method and time-frequency[D]. Fuyang: Liaoning Technical University, 2012.
- [14] SMITH S W. The scientist and engineer's guide to digital signal processing[M]. 2nd ed. California: California Technical Publishing, 1999.
- [15] 石项夫. 基于振动信号分析的电机滚动轴承故障诊断与性能退化评估方法[D]. 杭州: 浙江大学, 2023.
SHI Xiangfu. Fault diagnosis and prognostics for motor rolling bearing based on vibration analysis[D]. Hangzhou: Zhejiang University, 2023.
- [16] GARRIDO M, PARHI K K, GRAJAL J. A pipelined FFT architecture for real-valued signals[J]. IEEE transactions on circuits and systems I-regular papers, 2009, 56(12): 2634-2643.
- [17] HUANG Qihe, SHEN Lei, ZHANG Ruixin, et al. Hdmixer: hierarchical dependency with extendable patch for multivariate time series forecasting[J]. Proceedings of the AAAI conference on artificial intelligence, 2024, 38(11): 12608-12616.
- [18] LI Yan, LU Xinjiang, XIONG Haoyi, et al. Towards long-term time-series forecasting: feature, pattern, and distribution[C]// IEEE. 2023 IEEE 39th International Conference on Data Engineering (ICDE). Anaheim: IEEE, 2023: 1611-1624.

Traction motor fault diagnosis based on rFFT and HDMixer

LIU Jinyi¹, LI Bingkun¹, LIU Shuai², WANG Lianfu²

(1. 6th Research Institute, CRRC Technology Innovation (Beijing) Co., Ltd., Beijing 100083, China;

2. CRRC Changchun Railway Vehicles Co., Ltd., Jilin, Changchun 130062, China)

Abstract: The bogie system is a crucial component of the running gear on railway vehicles, with its health condition directly related to train operational safety. Therefore, fault diagnosis of the bogie system is of great significance not only in improving operational safety but also in providing a reliable basis for future repair and maintenance. This study focused initially on fault diagnosis for traction motors in the bogie system. The real fast Fourier transform (rFFT) was adopted for signal processing, and fault features were extracted through spectral analysis to capture anomalies during motor operation. Furthermore, a multivariate time series prediction neural network model based on the extendable Patch with hierarchical dependency (HDMixer) was introduced as the main analytical tool. This special architecture enabled in-depth interpretation of different time series data, thus improving the accuracy and reliability of fault diagnosis. Supported by the theoretical foundations and data validation, experimental results show that the HDMixer model achieves a diagnostic accuracy of more than 93% for traction motor faults, indicating outstanding performance. In addition, the model maintains high accuracy under different conditions, demonstrating excellent generalizability. This research offers an effective method for fault diagnosis of the bogie system, providing important technical support to ensure train safety during routine maintenance and long-term operation.

Keywords: fault diagnosis; bogie; traction motor; deep learning; neural network; urban rail transit