



牵引工况下的地铁车轮扁疤故障诊断

梁红琴¹, 武云龙¹, 龙 辉¹, 陶功权², 温泽峰², 谢清林²

(1. 西南交通大学 机械工程学院, 四川 成都 610031;

2. 西南交通大学 轨道交通运载系统全国重点实验室, 四川 成都 610031)

摘 要: 铁道车辆在运营过程中往往会出现包括车轮扁疤在内的各种车轮失圆问题, 这会显著增加轮轨相互作用力进而带来安全隐患。因此, 发展准确、高效的车轮扁疤状态监测方法对于保障列车运行安全性十分重要。文章建立了地铁车辆动力学模型, 并针对实际运营过程中地铁车辆频繁牵引/制动工况, 提出了基于卷积注意力机制 (convolutional block attention module, CBAM) 与残差网络 (residual network) 相结合的牵引工况下车轮扁疤识别模型, 即CBAM-ResNet。首先, 将车轮扁疤损伤输入至所建立的动力学模型, 仿真得到典型牵引工况下车辆动态响应数据。对仿真的构架加速度进行“空间域”切割, 再通过短时傅里叶变换得到时频图数据集, 用于CBAM-ResNet的训练与测试。结果表明, 该模型可在牵引工况下对车轮扁疤进行高精度诊断, 相较于其他经典模型, CABM-ResNet可取得最高诊断精度; 在不同噪声水平下, 基于CBAM-ResNet的车轮扁疤识别准确率最高可提升6.07%。

关键词: 地铁车辆; 车轮扁疤; 深度残差网络; 注意力机制; 故障识别; 仿真; 故障诊断; 城市轨道交通

中图分类号: U231; U270.331⁺.1 **文献标志码:** A **文章编号:** 1000-128X(2025)05-0084-08

0 引言

地铁作为城市轨道交通的主要制式, 在缓解现代化大都市地面交通运输压力的作用日益提高。随着地铁车辆数量的持续增长, 地铁车辆在服役过程的运营维护问题也日益凸显, 目前全国各个城市的地铁线路均出现不同程度的车轮损伤现象^[1]。车轮扁疤作为主要的车轮损伤形式之一, 会显著增加轮轨相互作用力甚至引发安全事故。因此, 研发准确、高效的车轮扁疤状态监测方法对于延长车轮服役寿命、减少运营维护成本十分重要^[2]。目前, 车轮扁疤识别方法主要分为信号处理方法和深度学习识别方法。

信号处理算法通过提取车辆振动数据特征, 并对比分析扁疤故障信号与正常信号特征差异, 进而识别车轮扁疤故障。如文献[3]通过将振动信号经过改进的经验模态分解 (empirical mode decomposition, EMD)

和Hilbert变换获取每个IMF分量对应的Hilbert谱, 对比分析正常车轮与擦伤车轮。文献[4]详细分析了短时傅里叶变换 (short-time Fourier transform, STFT)、维格纳-维尔变换 (Wigner-Ville transform, WVT) 和小波变换等3种时频分析技术在轮轨缺陷动态检测的应用。上述各个方法利用不同的信号处理算法提取故障特征并识别车轮扁疤等故障, 证明了特征提取对故障识别的有效性, 为本文进一步实现车轮扁疤故障识别提供了理论基础。

尽管利用信号处理算法提取数据特征极大地减少了故障类型的识别难度, 但在一定程度上仍然依赖于专家知识。随着深度学习的广泛应用, 其高效的数据挖掘与分析能力为摆脱专家知识依赖提供了不可或缺的帮助, 可以利用深度学习算法对车轮扁疤故障进行特征提取与识别。例如文献[5]结合卷积神经网络 (convolutional neural networks, CNN) 和支持向量机 (support vector machine, SVM) 实现了车轮失圆故障

基金项目: 四川省科技计划项目 (2024JDRC0100)

通信作者: 梁红琴, 女, 博士, 副教授, 主要从事轮轨关系方面的研究; E-mail: sugargl@163.com

引用格式: 梁红琴, 武云龙, 龙辉, 等. 牵引工况下的地铁车轮扁疤故障诊断[J]. 机车电传动, 2025(5): 84-91. DOI: 10.13890/j.issn.1000-128X.2025.02.107.

Citation: LIANG Hongqin, WU Yunlong, LONG Hui, et al. Fault diagnosis method for metro wheel flat under traction condition[J]. Electric drive for locomotives, 2025(5): 84-91. DOI: 10.13890/j.issn.1000-128X.2025.02.107.

分类。文献[6]通过将时频能量谱与VGG16网络相结合对轨道车辆轴箱振动加速度进行分析, 从而实现车轮扁疤损伤程度进行定量估计。文献[7]在残差网络(residual network)的基础上引入多通道注意力机制以学习全局特征关系, 并借此对车轮故障进行分类识别。

上述方法通过神经网络算法对车轮损伤开展识别与评估研究, 然而方法多针对恒定转速工况, 而列车在实际运营过程中由于站间距较短频繁启停, 牵引、制动工况次数较多。若能利用牵引工况下的车辆运行数据训练模型, 即可增加现有数据的使用率, 同时弥补现有模型只能在恒定转速工况下诊断的不足, 其诊断结果也可与恒速工况相互印证参考, 增加模型诊断的可信程度。在车轮扁疤识别模型训练中, 使用的数据集大多为轴箱振动加速度, 而在牵引过程中车辆构架振动加速度最大值会随着列车运行速度的增加而逐渐降低^[8], 因此牵引过程中构架端部的振动加速度相较于高速运行过程会更大。鉴于构架端部振动响应可反映车轮扁疤故障情况, 若利用构架振动数据可完成车轮扁疤识别任务, 后续则可同时利用轴箱与构架数据训练神经网络, 从而达到更高的识别精度。本文利用仿真所得到的车辆构架振动加速度数据, 结合深度残差网络(deep residual network)与卷积注意力机制(convolutional block attention module, CBAM)^[9]实现牵引工况下的车轮扁疤的故障识别, 同时对构架振动数据作为扁疤识别网络训练集的可行性进行验证。

1 地铁车辆多刚体模型

1.1 地铁车辆多刚体模型建立

本文利用Simpack仿真软件, 以长沙轨道交通2号线车辆为研究对象建立其刚体动力学模型。为简化分析, 本文所建动力学模型仅包括单节车辆整车模型, 其中包括1个车体、2个构架、4条轮对和8个轴箱, 除轴箱仅考虑点头自由度外, 其余部件均考虑点头、摇头、侧滚、浮沉、伸缩、横移等6个自由度, 所有部件共计50个自由度。各部件之间通过一系悬挂和二系悬挂进行连接, 其中连接车轴与构架的一系悬挂包括钢簧、垂向减振器和转臂定位装置, 并利用弹簧阻尼单元模拟转臂定位装置, 而连接构架与车体的二系悬挂则由空气弹簧、垂向减振器、横向减振器、横向止挡、牵引拉杆组成。车轮踏面为S1002型踏面^[10], 钢轨为CN60轨。在仿真过程中, 将列车所受的牵引力以转矩的形式施加在轮对中心^[11], 从而实现牵引工况的仿真。

基于上述参数建立的车辆动力学模型如图1所示。在该模型基础上, 将表述旧扁疤的函数作为车轮轮径变化量引入模型, 不同于理想状态下的新扁疤数学模型, 其数学模型可用余弦函数表述^[12], 具体为

$$\left. \begin{aligned} \Delta Z &= \frac{D_f}{2} \left(1 - \cos \frac{2\pi x}{L_f} \right) \\ D_f &= \frac{L_f^2}{16R} \end{aligned} \right\} \quad (1)$$

式中: ΔZ 为扁疤深度; D_f 为有效扁疤深度; R 为车轮半径; x 为车轮行驶距离; L_f 为旧扁疤长度。




图1 地铁车辆-多刚体动力学模型

Fig. 1 Metro train - multibody dynamics model

1.2 牵引特性曲线

为明确在牵引电机对列车进行牵引加速过程中, 车体所受牵引力与列车运行速度之间的关系, 在列车加速至恒速的过程中, 根据牵引电机不同的工作特性将其工作区段分为恒转矩区、恒功率区和自然特性区^[13], 如图2所示。其中, 恒转矩区代表列车低速启动时因受到启动电流与轮轨黏着条件的影响, 电机牵引力受限并保持恒定数值不变; 当列车完成初步提速, 牵引电机进入恒功率区时, 由于受到牵引电机的功率限制, 此时牵引力随速度的增长而减小, 并且两者乘积即功率保持不变; 自然特性区则表征了列车在即将结束加速时电机所持有的自然特性, 具体表现为列车所受到的牵引力与车速的平方成反比。




图2 地铁车辆牵引特性曲线示意图

Fig. 2 Traction characteristic curves of metro train

列车的启动牵引力应满足下式^[14]:

$$F_{\max} \geq M \cdot w_0 \cdot g \cdot 10^{-3} + M \cdot \Delta \alpha \cdot (1 + \gamma) \quad (2)$$

式中: $F_{\max}$ 为最大牵引力, kN; M 为列车牵引质量, t; w_0 为列车运行最高速度时的单位基本阻力, N/t; g 为重力加速度, 取 $g=10 \text{ m/s}^2$; $\Delta \alpha$ 为启动加速度, m/s^2 ; γ 为列车回转质量系数, 一般取0.06~0.07。

文献[15-16]通过分析试验数据指出, 地铁车辆运行时的单位基本阻力为

$$w_0 = 0.9542 + 0.004734v + 0.0007436v^2 \quad (3)$$

式中: v 为列车运行速度。

由于本文只需要获取地铁车辆的构架端部垂向振动加速度, 并将列车所受的牵引力以转矩的形式施加在轮对中心, 设置地铁以初始速度 5 km/h 开始加速, 直至达到地铁最高运行速度 80 km/h 结束。依照牵引电机各个区段特性即可求出恒转矩区速度 v_1 、恒功率区速度 v_2 和自然特性区反比例系数 A , 并根据地铁 AW3 工况参数即可得到列车牵引特性的数学表达, 具体为

$$F = \begin{cases} 377 \text{ kN}, & 0 \text{ km/h} \leq v \leq 40 \text{ km/h} \\ \frac{15080}{v} \text{ kN}, & 40 \text{ km/h} < v \leq 60 \text{ km/h} \\ \frac{9.048 \times 10^5}{v^2} \text{ kN}, & 60 \text{ km/h} < v \leq 80 \text{ km/h} \end{cases} \quad (4)$$

图3给出了地铁车辆在 5~80 km/h 加速过程中构架端部垂向振动加速度的时域响应, 其中车轮扁疤长度为 30 mm, 轨道激励采用美国五级谱。由图3可知, 构架端部垂向振动加速度振幅在加速过程中整体上呈先增大后减小的趋势, 该趋势与文献[17]结果一致, 这从侧面也表明本文所构建的地铁车辆动力学模型的可靠性, 可用于后续扁疤辨识研究。




图3 牵引工况下扁疤引起的构架端部垂向振动加速度
Fig. 3 Vertical vibration acceleration at the end of bogie frame caused by flats under traction conditions

2 基于CBAM-ResNet 车轮扁疤故障诊断流程

本文以地铁车辆运行过程中构架垂向振动加速度为检测信号, 通过模型仿真、数据预处理、数据集划分、模型训练确定最优模型。仿真得到的数据集经过预处理转换为图像数据集, 并将其作为神经网络的训练集参与模型训练, 模型结构以ResNet为主体, 并在其中加入CBAM注意力模块提取振动数据空间特征。整体故障诊断流程如图4所示。




图4 基于CBAM-ResNet的车轮扁疤故障诊断流程

Fig. 4 Fault diagnosis process of wheel flats based on CBAM-ResNet

2.1 数据预处理

由于列车速度信号并非匀速信号, 而是非平稳、

非线性的信号, 采用传统时间域滑窗方法所获取的振动数据包含的信息不尽相同, 甚至在低速区段可能不包含故障信息。因此, 本文采用“空间域”切割^[18]的

方法对仿真所得数据进行划分。

针对时域数据的空间域切割流程如图5所示, 首先按照固定的位移窗口 $X=x_n-x_{n-1}$ 确定切割数据的时间点 $t_1, t_2, t_3, \dots, t_n$, 并以此为基础对时序数据进行切割, 本文选取 $X=10$ 。由于切割后的数据长度不一, 随后使用三次插值处理切割后的时序数据, 最终插值信

号如图5所示。

为提取数据时频特征以方便模型训练学习, 对插值后样本的包络信号进行短时傅里叶变换, 并统一关注截止频率 500 Hz 以下的时频信息, 得到如图6所示的二维时频图像。其中, 短时傅里叶变换选取汉宁窗 (Hanning window) 作为窗函数, 其窗口宽度为 2 048。




图5 构架振动数据预处理流程图

Fig. 5 Flowchart of vibration data preprocessing for bogie frame




图6 不同严重程度下短时傅里叶变换二维时频图

Fig. 6 2D time-frequency graphs based on STFT at different severity levels

2.2 车轮扁疤诊断模型

以上面所得到的数据集为基础构建CBAM-ResNet, 本文以 ResNet-18网络作为网络模型主干, 由于车轮扁疤所引起的构架加速响应主要为冲击响应, 因此在基

本残差块中引入CBAM注意力模块以提高网络模型对数据中的冲击特征信息的挖掘能力, 从而提升模型的诊断效果。其中, CBAM注意力模块是由通道注意力模块 (channel attention module, CAM) 和空间注意力模块 (spatial attention module, SAM) 串联组成的混合

注意力模块。该模块能够从通道和空间两个维度上进行加权计算，以实现自适应特征优化和提取。

通道注意力模块通过对输入信息采取最大池化和全局池化操作以获取不同尺度下的特征信息，通过多层感知机（multilayer perceptron，MLP）进行特征信息融合，逐个加权求和各个通道注意力特征信息来增强重要区域特征，从而使模型可以更好地关注重点区域，进而提升模型性能。其数学描述为

$$M_c(F) = \sigma \left(\text{MLP} \left(\text{AvgPool}(F) \right) + \text{MLP} \left(\text{MaxPool}(F) \right) \right) = \sigma \left(W_1 \left(W_0 \left(F_{\text{avg}}^c \right) \right) + W_1 \left(W_0 \left(F_{\text{max}}^c \right) \right) \right) \quad (5)$$

式中： M_c 为通道注意力特征图， $M_c \in R^{C \times 1 \times 1}$ ； $\sigma(\cdot)$ 为sigmoid激活操作； W_0 、 W_1 为MLP中共享权重参数。

空间注意力模块通过在空间维度上对所输入的空间图进行注意力权重分配，从而提高模型性能。首先，对通道注意力特征图与原始特征图 F 相乘所得到的新特征图 F' 进行全局池化与局部池化提取特征，随后通过卷积操作对其降维，最后经过sigmoid激活函数对特征图各个通道参数做归一化处理，即可得到注意力特征图 M_s ，且 $M_s \in R^{1 \times C \times W}$ 。通过对空间注意力特征图与原始输入特征图进行逐元素相乘操作，即可获得经过CBAM模块处理后的最终特征。其数学表达式为

$$M_s = \sigma \left(f^{7 \times 7} \left(\left(\text{AvgPool}(F) ; \text{MaxPool}(F) \right) \right) \right) = \sigma \left(f^{7 \times 7} \left(\left[F_{\text{avg}}^s ; F_{\text{max}}^s \right] \right) \right) \quad (6)$$

式中： $\sigma(\cdot)$ 为sigmoid激活操作； $f^{7 \times 7}$ 为卷积核大小为 7×7 的卷积运算。

3 试验设置与结果分析

3.1 模型参数与数据集划分

本文使用二维时频图作为CBAM-ResNet网络的输入，通过多次试验确定的最优网络模型参数如表1所示。其中，“[]”为CBAM-ResBlock模块，[通道数@卷积核宽度×高度]×CBAM-ResBlock模块个数； γ 为通道注意力中的通道压缩率；“ 7×7 ”为空间注意力中卷积核大小。在保证模型诊断效果不降低的前提下，可以通过增加ResNet网络的通道来提升模型计算效率。模型其余超参数设置如表2所示。

本文按照扁疤长度将扁疤故障划分为轻度、中度和重度3种故障类型，各个故障类型对应的扁疤长度范围为 $L_f \leq 25$ mm、 $25 \text{ mm} < L_f \leq 40$ mm和 $40 \text{ mm} < L_f \leq 60$ mm。通过仿真计算获得加速度响应，再经过数据预处理构建了车轮扁疤故障的二维时频图像数据集。其中，经短时傅里叶变换后的二维时频图像尺寸大小均为 256×256 ，考虑到计算机的计算效率有限，每类故障类型数量均设置为1 000张，试验数据集详细构成如表3所示。

表1 CBAM-ResNet模型的参数设置

Table 1 Parameter settings of the CBAM-ResNet model

网络层	输入尺寸	参数	步长	输出参数
卷积层	$3 \times 256 \times 256$	$16 @ 3 \times 3$	2	$16 \times 128 \times 128$
最大池化层	$16 \times 128 \times 128$	3×3	2	$16 \times 64 \times 64$
CBAM-ResBlock-1	$16 \times 64 \times 64$	$\begin{bmatrix} 16 @ 3 \times 3 \\ 16 @ 3 \times 3 \\ \gamma = 16 \\ 7 \times 7 \end{bmatrix} \times 2$	1, 1	$16 \times 64 \times 64$
CBAM-ResBlock-2	$16 \times 64 \times 64$	$\begin{bmatrix} 32 @ 3 \times 3 \\ 32 @ 3 \times 3 \\ \gamma = 16 \\ 7 \times 7 \end{bmatrix} \times 2$	2, 1	$32 \times 32 \times 32$
CBAM-ResBlock-3	$32 \times 32 \times 32$	$\begin{bmatrix} 64 @ 3 \times 3 \\ 64 @ 3 \times 3 \\ \gamma = 16 \\ 7 \times 7 \end{bmatrix} \times 2$	2, 1	$64 \times 16 \times 16$
CBAM-ResBlock-4	$64 \times 16 \times 16$	$\begin{bmatrix} 128 @ 3 \times 3 \\ 128 @ 3 \times 3 \\ \gamma = 16 \\ 7 \times 7 \end{bmatrix} \times 2$	2, 1	$128 \times 8 \times 8$
全局均值池化层	$128 \times 8 \times 8$			$128 \times 1 \times 1$
全连接层1	128	100		100
Dropout		0.5		
全连接层2	100	4		4

表2 CBAM-ResNet模型的超参数设置

Table 2 Hyperparameter settings of the CBAM-ResNet model

参数名称	设置	参数名称	设置
样本大小	256×256	样本大小	256×256
批量大小	64	批量大小	64
优化器	Adam	优化器	Adam

表3 试验数据集构成

Table 3 Composition of the experimental dataset

类型	扁疤长度/mm	图像尺寸大小	样本数目
正常		256×256	1 000
轻度	$L_f \leq 25$	256×256	1 000
中度	$25 < L_f \leq 40$	256×256	1 000
重度	$40 < L_f \leq 60$	256×256	1 000

3.2 试验结果分析与对比

将表3中每类故障类型样本按照比例6:2:2划分为训练集、验证集和测试集，其中训练集2 400个样本，验证集800个样本，测试集800个样本。为了充分验证本文所提模型的有效性，本文采用LeNet-5、VGG-16、ResNet作为对比方法，其中LeNet-5和VGG-16的模型参数设置均与原文献保持一致，而ResNet用于消融试验，其模型参数与本文所提方法模型参数设置相同。同时，所有方法的初始超参数设置均保持一致。由于一系悬挂的存在，构架端部垂向振动加速度响应受噪

声信号干扰有所减弱, 因此本文仅考虑信噪比 (SNR) 为 2~10 dB (增量 2 dB) 和无噪声情况下不同方法对车轮扁疤故障的测试诊断精度。为了客观地反映不同方法的表现性能, 将不同噪声情况下 10 次测试集诊断精度的平均值作为所提方法和其他对比方法的评价指标, 同时计算相应的标准差以评估模型的稳定性, 最终不同噪声情况下各个模型测试精度对比如图 7 所示。




图 7 诊断精度柱状图

Fig. 7 Bar chart of diagnostic accuracy

由图 7 可知, 在 5 种噪声和无噪声情况下, CBAM-ResNet 模型的测试诊断精度均优于其他对比方法, 并且在不同噪声情况下的平均测试诊断精度相较于 LeNet-5 模型、VGG-16 模型和 ResNet 模型分别提高了 4.15%、3.27% 和 1.56%, 这表明本文所提方法具有较强的辨识能力; 其次, 随着噪声强度不断提高, 每种

模型的测试诊断精度逐渐下降, 但对于不同的噪声情况, CBAM-ResNet 模型的测试诊断精度相较于其他对比模型最多分别提升 6.07%、4.12% 和 3.04%, 同时其测试诊断精度均保持在 93% 以上, 这显示出本文所提方法在强噪声背景下有着更优的抗噪能力, 能有效降低含噪信号中冗余信息的干扰, 并能准确提取车轮扁疤故障的细节特征, 从而提高模型的诊断效果。

3.3 特征可视化及混淆矩阵结果分析

为了进一步探究不同方法的诊断效果, 以信噪比 (SNR) 2 dB 的噪声条件下测试诊断情况为例, 对不同模型的最后隐藏层特征进行 t-SNE 二维可视化展示, 如图 8 所示。由图 8 可知, 对于正常情况和轻度故障, LeNet-5 模型、VGG-16 模型和 ResNet 模型所提取的特征存在较为严重的混淆现象, 这是由于当轻度故障存在较小的扁疤情况时, 经过预处理得到的时频图在扁疤故障频率范围内能量较小, 容易与正常的时频图混淆, 使得模型在噪声条件下对轻度故障的辨识能力较弱, 但本文所提的方法对于正常情况和轻度故障提取特征容易混淆的现象有明显改善, 并且对其他类型故障的聚集程度也更优于对比方法, 这表明本文所提方法能有效提取噪声干扰条件下故障的细节特征, 减少信号中噪声的干扰, 从而提高对难辨识类型故障的诊断精度。

为了分析不同方法对不同类型故障和正常情况的




图 8 不同模型输出层特征的 t-SNE 可视化结果 (信噪比 2 dB)

Fig. 8 t-SNE visualization of output layer features of different models under SNR 2 dB noise

具体诊断精度,图9给出了信噪比(SNR) 2 dB 噪声条件下不同模型的混淆矩阵结果。由图9可知,所有方法对正常情况、中度故障和重度故障有着较高的诊断精度,均保持在90%以上;对于轻度故障的辨识能力,对比方法明显存在不足,这与图8中t-SNE可视化结果保持一致。但本文所提方法在轻度故障的诊断精度相较于对比方法有较大提升,分别提升了16.5%、21.0%和17.0%,由此充分说明本文所提方法可有效提升噪声干扰条件下对难辨识类型故障的辨识能力,相较于对比方法具有更优的鲁棒性。




图9 不同模型的混淆矩阵结果(信噪比2 dB)

Fig. 9 Confusion matrix results for different models under SNR 2 dB noise

4 结论

针对地铁牵引工况下车轮扁疤故障诊断问题,本文以构架端部垂向振动加速度为监测信号,对牵引工况下地铁车轮扁疤故障诊断展开了初探,主要结论如下:

①本文针对牵引工况下地铁车轮扁疤识别问题开展了研究,通过将时序数据进行空间域切割实现了牵引工况下的车轮扁疤故障识别,拓宽了故障识别网络训练所需数据的选择范围。

②将CBAM注意力机制与ResNet残差网络相结合,用以诊断牵引工况下车轮扁疤故障。结果表明,本文所提方法在强噪声背景下具有更高的诊断精度,能有效降低信号中噪声的干扰。

③可利用构架振动加速度探究其对扁疤识别网络训练能否提供特征信息。结果表明,构架振动加速度

可应用于车轮扁疤识别神经网络的训练过程。

参考文献:

- [1] 任志刚. 北京地铁1^号线车轮异常磨损分析及解决措施[J]. 黑龙江交通科技, 2022, 45(7): 146-148.
REN Zhigang. Analysis of abnormal wheel wear and solutions for Beijing subway line 1st[J]. Communications science and technology Heilongjiang, 2022, 45(7): 146-148.
- [2] 敬霖, 刘凯. 车轮踏面缺陷引起的轮轨动态响应综述[J]. 交通运输工程学报, 2021, 21(1): 285-315.
JING Lin, LIU Kai. Review on wheel-rail dynamic responses caused by wheel tread defects[J]. Journal of traffic and transportation engineering, 2021, 21(1): 285-315.
- [3] 李奕璠, 林建辉, 刘建新, 等. 车轮踏面擦伤识别方法[J]. 振动与冲击, 2013, 32(22): 21-27.
LI Yifan, LIN Jianhui, LIU Jianxin, et al. Identification method of wheel tread flat[J]. Journal of vibration and shock, 2013, 32(22): 21-27.
- [4] LIANG B, D. IWNICKI S, ZHAO Y S, et al. Railway wheel-flat and rail surface defect modelling and analysis by time-frequency techniques[J]. Vehicle system dynamics, 2013, 51(9): 1403-1421. DOI: 10.1080/00423114.2013.804192.
- [5] 梁红琴, 姜进南, 陶功权, 等. 基于轴箱垂向振动加速度的地铁车轮失圆状态诊断方法[J]. 中南大学学报(自然科学版), 2024, 55(1): 431-443.
LIANG Hongqin, JIANG Jinnan, TAO Gongquan, et al. Diagnosis method of out-of-roundness of metro wheels based on vertical vibration acceleration of axle box[J]. Journal of central south university(science and technology), 2024, 55(1): 431-443.
- [6] 李大柱, 牛江, 梁树林, 等. 时频能量谱与VGG16结合的车轮扁疤损伤程度估计方法[J]. 中国机械工程, 2023, 34(16): 1907-1914.
LI Dazhu, NIU Jiang, LIANG Shulin, et al. A method for estimating damage degree of wheel flat scars based on time-frequency energy spectrum and VGG16[J]. China mechanical engineering, 2023, 34(16): 1907-1914.
- [7] CHEN Y X, ZHAO Z X, KIM E, et al. Wheel fault diagnosis model based on multichannel attention and supervised contrastive learning[J]. Advances in mechanical engineering, 2021, 13(12): 168781402110670. DOI: 10.1177/16878140211067024.
- [8] 刘国云, 曾京, 郭平波, 等. 车轮扁疤所引起的车辆系统振动特性分析[J]. 机械工程学报, 2020, 56(8): 182-189.
LIU Guoyun, ZENG Jing, WU Pingbo, et al. Vibration characteristic analysis of vehicle systems due to wheel flat[J]. Journal of mechanical engineering, 2020, 56(8): 182-189.
- [9] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the European conference on computer vision (ECCV). 2018: 3-19. DOI:

- 10.48550/arXiv.1807.06521.
- [10] 任德祥. 面向低轮缘磨耗的地铁车轮型面优化研究[D]. 成都: 西南交通大学, 2019.
- REN Dexiang. Research on optimization of metro wheel profile for low flange wear[D]. Chengdu: Southwest Jiaotong University, 2019.
- [11] 王永冠, 卜继玲, 陶功安. 地铁车辆牵引制动工况仿真[J]. 电力机车与城轨车辆, 2009, 32(6): 23-26.
- WANG Yongguan, BU Jiling, TAO Gongan. Simulation on traction and braking of metro vehicles[J]. Electric locomotives & mass transit vehicles, 2009, 32(6): 23-26.
- [12] 杨光, 任尊松, 袁雨青. 车轮扁疤伤损对高速列车轮对动力学性能影响[J]. 北京交通大学学报, 2018, 42(3): 103-111.
- YANG Guang, REN Zunsong, YUAN Yuqing. Influence of wheel flat on dynamic performance of high-speed train wheelset[J]. Journal of Beijing jiaotong university, 2018, 42(3): 103-111.
- [13] 胡鑫. 考虑牵引力作用的铰接式动车组动力学性能研究[D]. 成都: 西南交通大学, 2021.
- HU Xin. Research on dynamic performance of articulated EMUS considering traction[D]. Chengdu: Southwest Jiaotong University, 2021.
- [14] 陈慧民. 高速动车组牵引特性分析[J]. 城市轨道交通研究, 2008, 11(7): 21-24.
- CHEN Huimin. On the traction characteristics of high-speed motor train[J]. Urban mass transit, 2008, 11(7): 21-24.
- [15] 袁修法, 林建辉. 直线电机驱动地铁车辆运行阻力试验研究[J]. 佳木斯大学学报(自然科学版), 2014, 32(3): 387-389.
- YUAN Xiufa, LIN Jianhui. Study on running resistance of linear motor driving metro vehicle[J]. Journal of Jiamusi university(natural science edition), 2014, 32(3): 387-389.
- [16] 吴安伟. 城市轨道交通车辆基本阻力试验研究[J]. 城市轨道交通研究, 2020, 23(9): 141-143.
- WU Anwei. Research on the basic resistance test of urban rail transit vehicle[J]. Urban mass transit, 2020, 23(9): 141-143.
- [17] CHEN S Q, WANG K Y, CHANG C, et al. A two-level adaptive chirp mode decomposition method for the railway wheel flat detection under variable-speed conditions[J]. Journal of sound and vibration, 2021, 498(4): 115963. DOI: 10.1016/j.jsv.2021.115963.
- [18] 谢清林, 陶功权, 温泽峰. 基于一维卷积神经网络的地铁钢轨波磨识别方法[J]. 中南大学学报(自然科学版), 2021, 52(4): 1371-1379.
- XIE Qinglin, TAO Gongquan, WEN Zefeng. Detection method of metro rail corrugation based on 1-dimensional convolutional neural network[J]. Journal of central south university(science and technology), 2021, 52(4): 1371-1379.

Fault diagnosis method for wheel flats on metro trains under traction conditions

LIANG Hongqin¹, WU Yunlong¹, LONG Hui¹, TAO Gongquan², WEN Zefeng², XIE Qinglin²

(1. School of Mechanical Engineering, Southwest Jiaotong University, Chengdu, Sichuan 610031, China;

2. State Key Laboratory of Rail Transit Vehicle System, Southwest Jiaotong University, Chengdu, Sichuan 610031, China)

Abstract: Various forms of wheel out-of-roundness including wheel flats is frequently encountered during the operation of metro trains. These defects pose potential safety hazards due to amplified wheel-rail interactions. Hence, developing an accurate and efficient method for condition monitoring of wheel flats is crucial to ensuring safety in the operation of these trains. Based on a dynamics model developed for metro trains, this paper presented a model for identifying wheel flats under traction conditions, referred to as CBAM-ResNet, which combined the Convolutional Block Attention Module (CBAM) with the Residual Network (ResNet). This approach particularly focused on the frequent traction and braking conditions in the real-world operation of metro trains. With wheel flats input into the dynamics model, the initial simulation generated dynamic response data of the train under the typical traction condition, i.e. the bogie frame acceleration. This data was then segmented from the "spatial domain" perspective, and a dataset of time-frequency graphs was generated using the Short-Time Fourier Transform (STFT) for training and testing CBAM-ResNet. The results demonstrate that the proposed model outperforms traditional diagnostic methods in terms of accuracy in flat diagnosis under traction conditions, particularly with an accuracy improvement of up to 6.07% for identifying wheel flats across various noise levels.

Keywords: metro train; wheel flats; deep residual network; attention mechanism; fault diagnosis; simulation; fault diagnosis; urban rail transit