

基于WPD-1DCNN的地铁钢轨波磨识别方法

刘铁生¹, 于燕坤¹, 梁骏杰², 孙岳欣³, 郝敬荣¹, 蒋春雷¹

(1. 北京市地铁运营有限公司, 北京 100082; 2. 北京交通大学交通运输学院, 北京 100044;
3. 北京锦鸿希电信息技术股份有限公司, 北京 100070)

摘要:为实现地铁钢轨波磨状态的准确识别与智能监测, 提出一种结合小波包分解(WPD)与一维卷积神经网络(1DCNN)的波磨识别方法。基于现场实测列车轴箱垂向加速度信号, 采用4层小波包分解提取16个子带能量特征, 并进行能量归一化构建能量向量; 设计轻量化1DCNN结构, 以能量向量为输入, 实现多尺度特征学习。选取无波磨、长波波磨和短波波磨3种典型波磨类型作为分类标签, 构建训练集与测试集进行模型训练与验证。结合不同波磨类型在低频与高频子带中的能量分布差异, 对特征提取结果进行分析。结果表明: 该方法平均识别准确率达97.60%, 长波波磨的召回率为100%。与SVM、LSTM和2DCNN等模型相比, 1DCNN表现出更高的精度与更强的泛化能力, 可在不依赖专用检测设备的条件下实现列车运行过程中的波磨智能识别。结合传统波磨测试的波长域评价体系, 分析其与本研究识别结果的一致性, 提出在线识别与现场精测互补的工程应用流程。本研究验证了WPD与1DCNN融合方法在地铁钢轨波磨识别中的有效性, 为轨道运行状态在线监测和智能维护提供了新思路。

关键词:城市轨道交通; 钢轨波磨; 小波包分解; 一维卷积神经网络; 振动信号识别; 深度学习

中图分类号: U231

文献标志码: A

文章编号: 1672-6073(2026)04-0188-10

Metro Rail Corrugation Identification Method Based on WPD-1DCNN

Liu Tiesheng¹, Yu Yankun¹, Liang Junjie², Sun Yuexin³, Hao Jingrong¹, Jiang Chunlei¹

(1. Line Branch, Beijing Mass Transit Railway Operation Co., Ltd., Beijing 100082; 2. School of Traffic and Transportation, Beijing Jiaotong University, Beijing 100044; 3. Beijing Jinhong Xi-Dian Information Technology Corp., Beijing 100070)

Abstract: To achieve accurate identification and intelligent monitoring of metro rail corrugation, this study proposes a novel method combining WPD and 1DCNN for rail corrugation identification. Based on the vertical axle-box acceleration signals collected from in-service metro trains, sixteen sub-band energy features were extracted through four-level WPD and normalized to construct energy vectors. A lightweight 1DCNN architecture was designed to perform multiscale feature learning using the energy vectors as input. Three corrugation types—no corrugation, long-wavelength corrugation, and short-wavelength corrugation—were selected as classification labels for model training and testing. Based on the differences in energy distribution among different corrugation types in low- and high-frequency sub-bands, the feature extraction results were analyzed. The results demonstrated that the proposed method achieved an average recognition accuracy of 97.60%, with a recall rate of 100% for long-wavelength corrugation. Compared with SVM, LSTM, and 2DCNN models, the 1DCNN model exhibited higher accuracy and stronger generalization capability. It enables intelligent rail corrugation identification under in-service operating conditions without reliance on specialized inspection systems. The consistency between the wavelength-domain evaluation framework of conventional rail corrugation testing and the identification results of this study was analyzed, and a complementary

收稿日期: 2025-07-06 修回日期: 2026-01-30

第一作者: 刘铁生, 男, 硕士, 工程师, 从事城市轨道交通线路安全研究, lubin_0_0@163.com

通信作者: 梁骏杰, 男, 硕士研究生, 从事轨道交通运营安全与管理方面研究, 1316689604@qq.com

基金项目: 国家重点研发计划(2022YFB4301200); 北京市地铁运营有限公司科研项目(2022000507015002)

引用格式: 刘铁生, 于燕坤, 梁骏杰, 等. 基于WPD-1DCNN的地铁钢轨波磨识别方法[J]. 都市轨道交通, 2026, 39(4): 188-197.

engineering application workflow integrating online identification with on-site precision measurement was proposed. This study verified the effectiveness of the WPD-1DCNN fusion method in metro rail corrugation recognition and provided a new approach for online monitoring and intelligent maintenance of track conditions.

Keywords: urban rail transit; rail corrugation; wavelet packet decomposition; one-dimensional convolutional neural network; vibration signal identification; deep learning

工程上对钢轨波磨的识别与评估主要依赖现场检测与周期性复测,常用方式有人工巡检以及利用波磨测量小车等设备对轨面不平顺等特征进行测量,为后续养护与治理决策提供依据^[1]。受作业窗口、人工投入与检测效率等因素限制,传统测试方法无法实现波磨状态的连续感知与快速识别,难以满足地铁高密度运营条件下的在线化监测需求^[1-2]。

为提升波磨状态识别的效率与在线化水平,近年来相关研究逐步转向利用运营列车振动响应开展数据驱动检测,并结合信号处理与深度学习建立波磨识别模型,在工程可部署性与识别性能方面取得了一定进展^[3-8]。然而,现有方法仍普遍受样本规模限制、工况扰动敏感以及跨区段泛化能力不足等因素影响^[3-8],难以兼顾工程部署条件与稳健识别需求^[1-3,6-7]。因此,亟须探索一种在有限样本条件下仍具备稳定特征表达能力,同时能够适应复杂运营工况扰动的波磨识别方法,以提升在线监测的可靠性与可推广性^[9-10]。

综上所述,本研究将小波包分解 WPD 与一维卷积神经网络 1DCNN 相结合,利用列车轴箱垂向振动信号构建地铁波磨识别模型。WPD 可在多尺度下揭示波磨信号的能量分布特征,1DCNN 则能自动学习其时序规律,二者融合实现对复杂非平稳信号的精确识别。基于 4 层小波包分解提取 16 个子带能量,并经能量归一化形成频带特征向量,完整反映不同波磨类型的能量分布特征。

WPD 与 1DCNN 的联合方法虽已在机械故障诊断、刀具磨损识别等领域得到验证,但案例较少,且尚未应用于钢轨波磨识别与监测。本文将该方法首次引入地铁线路场景,基于列车振动响应构建波磨智能识别框架,可在不依赖专用设备的情况下实现在线状态评估,为轨道波磨智能监测提供新的技术思路。

1 现场勘察与数据采集

为研究钢轨波磨对列车车体振动特性的影响,并为波磨状态识别提供训练数据,在北京地铁某线路开展现场试验,试验所用车辆为地铁 DKZ 型车。试验区段为实际运营线路,轨道结构为钢弹簧浮置板道床,

线路中包含多个小半径曲线与曲线过渡段,具备典型的波磨发展环境。试验时,将压电式加速度传感器安装于车辆走行部轴箱处,用以采集列车运行期间的车体垂向振动加速度信号,采样频率设置为 2 000 Hz。为了确保轴箱加速度信号主要反映钢轨波磨所引起的激励响应,列车轮对经过预先检修与动平衡处理,轮圆度和踏面光洁度均满足技术标准,且列车运行过程中未启用制动系统或其他可能引入干扰的装置。此外,列车通过试验区段时保持恒定速度,尽量避免因加减速或曲线运行等因素引起额外扰动。

同时,对测试区段钢轨波磨的实际状况进行现场勘查,发现主要存在两类典型波磨形式。

1) 短波波磨。主要出现在小半径曲线内轨,波长在 20~50 mm 之间,波谷部位常伴随明显的裂纹、剥离掉块等结构损伤,肉眼可见明显细密波痕,波磨深度较深,属于典型的严重波磨。

2) 长波波磨。多分布于大半径曲线内轨和直线区域内外轨,波长集中在 300~350 mm 范围内,主要表现为钢轨表面磨耗,无明显剥蚀破损,一般难以被肉眼察觉,波磨深度相对较浅。

为研究不同类型波磨对列车动力响应的影响,分别选取存在这两类波磨的轨道区间作为测试段,并在列车通过这两个区间过程中同步采集振动加速度数据,列车在两区间内的运行平均速度约为 72.5 km/h。选取列车进入波磨区起始时刻向后延续的 40 s 加速度信号进行分析处理,图 1 展示了该时段内列车在两类波磨区间内行驶时的垂向振动加速度时域信号。

由图 1 可知,两者的振幅存在较为显著的差异,列车在两类波磨区间内行驶时,短波波磨区间内的加速度信号振幅有明显增大,呈现出十分突出的高频强冲击特性,这反映出轨面存在较为严重的不平顺状况或者周期性激励,使得轮轨系统产生了剧烈的振动。长波波磨区间内的加速度信号波动相对较小,整体信号的幅值较低,表明轨面扰动程度较微弱,列车垂向动态响应较平稳。

同样采集列车在无波磨区间内行驶时的垂向振动加速度数据,为划分不同波磨状态的样本,对列车




图 1 垂向振动加速度信号

Figure 1 Vertical vibration acceleration signals

在各区域行驶前 40 s 内采集到的轨道振动信号进行特征统计分析。计算结果表明,不同波磨状态下信号能量与冲击特征差异明显。无波磨信号的均方根(RMS)为 $0.770 \text{ m}\cdot\text{s}^{-2}$,峭度(K)为 2.799,峰均比(CF)为 4.679,振动能量较低;长波波磨信号 RMS 增至 $5.341 \text{ m}\cdot\text{s}^{-2}$, K 为 26.845, CF 为 21.699,表明信号能量显著上升并伴随强烈冲击成分;短波波磨信号 RMS 高达 $45.989 \text{ m}\cdot\text{s}^{-2}$, K 为 12.620, CF 为 18.162,反映其具有高能量与非平稳特性。为综合表征波磨强度,定义指标:

$$I = \text{RMS} \times \sqrt{K} \quad (1)$$

式中, I 为波磨强度综合评价指标,用于综合表征列车通过不同波磨区段时垂向振动信号的能量水平和冲击特征。

3 类样本计算结果分别为:无波磨 $I=1.288$,长波波磨 $I=27.674$,短波波磨 $I=163.373$,数值呈显著递增趋势,能够有效刻画波磨程度差异。基于上述特征分布,建立如下分级判据:

$$\begin{cases} \text{无波磨: } \text{RMS} < 2, K < 6, I < 5 \\ \text{长波波磨: } 2 \leq \text{RMS} < 10, K \geq 8, 5 \leq I < 50 \\ \text{短波波磨: } \text{RMS} \geq 10, I \geq 50 \end{cases} \quad (2)$$

该阈值依据样本统计规律确定,可反映波磨从平稳到强冲击阶段的动态演化特征。按照此分级规则对采集到的全部样本进行筛选,最终获得无波磨数据点 420 236 个,长波波磨数据点 95 859 个,短波波磨数据点 156 154 个,为后续进行神经网络训练提供数据基础。

在此强调,本文之后的研究均基于这 3 种波磨类型开展,以上经现场采集得到的原始数据是进行实验的基本保障。

2 WPD-1DCNN 识别方法

2.1 WPD

小波包分解(wavelet packet decomposition, WPD)

也被称为最优子带树结构,是对传统小波变换的一种优化方法。由于传统小波变换遵循海森堡不确定性原则,在时域和频域上均无法精准反映信号特征,而小波包分解具备任意多尺度分析的能力,能够更准确地揭示信号的本质特性与关键特征。目前,小波包分解已被广泛应用于信号处理领域,一个 3 层的小波包分解结构如图 2 所示。




图 2 3 层小波包分解

Figure 2 Three-level wavelet packet decomposition

其中, S_0 代表输入的原始信号,经过第 1 层分解后,得到低频 L 和高频 H 两个子信号分量,之后进行的每一次分解都会产生这两种分量。

2.1.1 分解层数设置

设原始信号为 $x(t)$,经过小波包分解后,可得到 2^j 个不同频段的子带信号 $x_{j,k}(t)$,其中 j 为分解层数, k 为第 j 层的第 k 个子节点。各子带的频率范围具有固定分辨率,可表示为:

$$f_{j,k} = \left[\frac{k}{2^j} f_s, \frac{k+1}{2^j} f_s \right], k = 0, 1, \dots, 2^j - 1 \quad (3)$$

式中, f_s 为信号采样频率, Hz。

为避免先验设定过粗的子带宽度,首先采用高分辨率 Welch 频谱(汉宁窗、窗长 2 048 点、50%重叠)获取 0~2 000 Hz 的细谱,并对各时窗功率谱取平均以获得稳态谱特征。随后通过功率谱密度确定主峰的半功率带宽(-3 dB)与累计能量 90% 区间,结果显示:长波波磨能量主要集中在 0~180 Hz,主峰半功率带宽约 80 Hz;短波波磨能量集中于 600~800 Hz,主峰半功率带宽约 100 Hz,且两主峰间距约 250 Hz。依据“子带宽度应不小于主峰带宽且不大于峰间距一半”的准则^[11],确定目标分辨率为 100~120 Hz,以兼顾频率分辨能力与计算效率。

目前,对于小波包分解层数的设置暂无明确规定,大部分学者进行层数选择时主要依靠过往经验。本文按照文献[12]中的方法,根据式(4)最终确定分解层数为 4 层。

$$j = \left\lceil \log_2 \left(\frac{f_s}{f} \right) \right\rceil - 1 \quad (4)$$

式中, f 为每一个子带的频率分辨率, Hz; $\lceil \cdot \rceil$ 为向上取整运算符。

2.1.2 小波基选择

现阶段常用小波基如表 1 所示。为确定最适合轨道波磨信号分析的小波基, 对 db2、db4、db6、sym4 与 coif1 等常用小波基进行 4 层小波包分解。基于 3 种典型波磨信号, 计算能量集中、熵反向、包络峭度、谱平坦度反向和峰值因子 5 项指标, 每个指标均进行归一化处理, 对不同小波基的分解性能进行综合评价。

表 1 常用小波基

Table 1 Commonly used wavelet bases

常用类型	dbN	symN	coifN	biorN.M 或 rbioN.M
特点	紧支撑、正交、渐近正则性强, 适合分析突变、尖峰等信号	是 db 的对称改进版本, 具有更好的近似对称性	具有更高的正则性, 尺度函数和小波函数都有消失矩	可实现真正对称, 支持精确重构
适用范围	广泛用于振动信号处理、机械故障诊断等	适合需要边界处理更好的应用场景, 如生物信号、图像压缩	对分析频率变化较平滑的信号较有优势	信号压缩、图像边缘处理、故障诊断中对对称性要求较高的场合

指标对比结果如图 3 所示, db4 小波基在五个评价指标中整体表现最优。其能量集中和熵反向值较高, 表明能量分布集中、特征提取能力强; 包络峭度和峰值因子较大, 说明其能有效保留冲击与调制特征; 谱平坦度反向指标高, 体现出良好的频谱分辨率与噪声抑制能力。综合比较可知, db4 在时域与频域特征保持之间取得了最佳平衡, 因此被选定为本文小波包分解分析的最优小波基。




图 3 不同小波基指标对比

Figure 3 Comparison of indicators for different wavelet bases

2.1.3 子带能量特征提取

子带信号的能量作为表征该频段振动强度的重要指标, 定义为:

$$E_{j,k} = \sum_{n=1}^{N_{j,k}} |x_{j,k}(n)|^2 = \sum_{n=1}^{N_{j,k}} |C_{j,k}(n)|^2 \quad (5)$$

式中, $E_{j,k}$ 为该频带所包含的振动能量, $\text{m}^2 \cdot \text{s}^{-4}$; $N_{j,k}$ 为该子带的系数数目; $x_{j,k}(n)$ 为小波包分解后, 在第 j 层第 k 个子频带上得到的信号, $\text{m} \cdot \text{s}^{-2}$; $C_{j,k}(n)$ 为第 j 层第 k 个子带上的小波包系数, $\text{m} \cdot \text{s}^{-2}$ 。

为了构造标准化的能量特征向量, 便于后续神经网络处理, 可对能量进行归一化处理:

$$\tilde{E}_{j,k} = \frac{E_{j,k}}{\sum_{k=0}^{2^j-1} E_{j,k}} \quad (6)$$

上述归一化能量 $\tilde{E}_{j,k} \in [0,1]$, 满足所有子带能量之和为 1:

$$\sum_{k=0}^{2^j-1} \tilde{E}_{j,k} = 1 \quad (7)$$

对 1 s 内采集到的无波磨、短波波磨、长波波磨的垂向振动加速度信号分别进行 4 层小波包分解后, 得到 3 种波磨类型的第 4 层共 16 个子带能量归一化, 如图 4 所示。




图 4 3 种波磨类型的第 4 层子带能量

Figure 4 Energy of the fourth-level sub-bands for three corrugation types

从图 4 中可以看出, 无波磨的信号在多数高频子带中的能量分布都较为平均, 没有出现突变现象; 短波波磨信号在高频子带如 [4, 5] 处呈现出显著的能量突增情况, 其振动响应是以高频短波为主; 长波波磨信号在低频子带如 [4, 0]、[4, 1] 处能量比较强, 其主要特征集中在低频长波部分。

因此, 仅对短波波磨的中高频子带([4, 5]~[4, 8])

和长波波磨的低频子带([4, 0]~[4, 3])进行绘制, 得到的第 4 层部分子带波形如图 5 所示, 每个子带的最大幅值投影到左 Y 轴, 所得结果与先前的分析相呼应。




图 5 第 4 层部分子带时域波形

Figure 5 Time-domain waveforms of selected sub-bands at the fourth decomposition level

根据能量较高的子带分辨率, 结合式(8)和式(3), 通过计算得出短波波磨的特征波长为 29.3 mm, 长波波磨的特征波长为 322.2 mm, 分别对应现场勘察结果。可以发现, 如果应用小波变换容易导致高频信号特征丢失, 依靠小波包分解来进行能量特征提取, 能较好地对波磨类型作出区分, 分析结果证明了小波包分解的可行性。

$$\lambda = \frac{v}{f_e} \quad (8)$$

式中, λ 为波磨特征波长, mm; v 为车辆通过波磨区间的速度, $\text{m}\cdot\text{s}^{-1}$; f_e 为波磨激励频率, Hz。

需要指出的是, 由式(8)可知, 本文计算得到的波

磨特征波长与列车运行速度密切相关。当列车速度发生变化时, 对应的波磨激励频率虽保持一定的特征分布, 但由于速度差异, 计算出的特征波长会随之改变。因此, 当前方法主要适用于列车以近似恒定速度通过测量区段的情况, 能够较准确地反映波磨的实际空间周期特征。若在列车加速或减速运行区段使用该方法, 速度变化会导致信号的时频特性发生偏移, 从而影响波磨波长的计算精度及分类结果。

本研究中 WPD 被用于对列车通过钢轨时采集到的垂向振动加速度信号进行多层分解, 将分解后得到的第 4 层共 16 个子带的能量特征构建成特征向量 $\tilde{E} = [\tilde{E}_{4,0}, \tilde{E}_{4,1}, \dots, \tilde{E}_{4,15}]^T$ 作为之后神经网络的输入, 以增强网络对多频信号特征的感知能力, 从而进一步提升钢轨波磨识别的准确性与鲁棒性。

2.2 1DCNN 架构设计

卷积神经网络(CNN)是一种前馈神经网络, 其具有局部感知和权重共享的特点, 广泛用于图像处理、语音识别和时序信号分析等领域。CNN 的核心结构包括卷积层、汇聚层^[13]和全连接层, 能通过多层次的特征提取, 自动学习输入数据的深层特征表示。与传统机器学习相比, CNN 具备端到端的学习能力, 擅长直接从原始数据中提取关键特征, 是深度学习的基础模型。CNN 的相关知识在很多文献里均有讨论, 在此不再赘述。

值得一提的是, 本文使用的不是传统卷积神经网络, 而是改进的一维卷积神经网络(1DCNN)。1DCNN 专为处理一维时序信号设计, 能够通过时间维度上滑动卷积核提取局部特征, 可以有效抓住信号里的短时变化和局部关系。相比传统二维卷积, 1DCNN 在处理振动信号、语音波形、生物电信号这些一维数据时, 效率更高也更加灵活。依靠参数共享和局部连接, 1DCNN 能降低模型复杂度, 同时特征提取能力很强, 已经在机械故障诊断、结构健康监测等领域广泛应用。本文所构建的 1DCNN 模型架构如图 6 所示。

将经过小波包分解提取出的能量特征向量作为输入, 经过 5 层一维卷积进行特征提取, 最后接入全连接层输出 3 种波磨类型。由于经过分解后只有 16 个子带, 输入的向量维度较短, 因此采用大通道数来进行卷积, 并且只在前两个卷积层后加入最大汇聚层, 在提高所抽取特征鲁棒性的同时防止过多汇聚层导致维度丢失。批量归一化操作通过对每一层的输出在批次维度上进行标准化, 强制各层输出保持一致的数据分

布,从而加快模型收敛速度。同时在 Conv1、Conv2 和第 1 个全连接层后使用 Dropout 处理,能够有效缓解过拟合问题。为了增强网络的非线性表达能力,每

一层的输出结果接入 ReLU 激活函数,进行非线性变换。波磨分类共有无波磨、短波波磨、长波波磨 3 种类型,因此最后分类层输出的向量维度为 3。




图 6 1DCNN 模型架构细节

Figure 6 Architecture of the proposed 1DCNN model in detail

在 CNN 模型中,合理选择超参数对于在保证较高识别精度的同时提升模型训练效率具有重要意义。针对本文所构建的 1DCNN 模型采用随机搜索法对各项超参数进行优化,最终获得如表 2 所示的最优参数配置。

表 2 1DCNN 参数设置

Table 2 Parameter settings of 1DCNN

类型	配置	零补
Kernel1	3×1×64 Padding=1	same
最大汇聚层 1	2×1×64	否
Dropout1	0.2	—
Kernel2	5×1×128 Padding=2	same
最大汇聚层 2	2×1×128	否
Dropout2	0.3	—
Kernel3	3×1×256 Padding=1	same
Kernel4	3×1×512 Padding=1	same
Kernel5	3×1×256 Padding=1	same
全连接层 1	(256×4)×128	—
Dropout3	0.4	—
全连接层 2	128×3	—

注:“same”表示送往卷积层的特征值经卷积运算后,其输出值与输入值保持一致;“—”表示该类型此处无需填写;Kernel 的配置为 3×1×64 分别代表卷积核大小为 3×1,输出通道数为 64,最大汇聚层同理;Dropout 的配置为其对应的暂退率;全连接层 1 的输入维度(长度)为最后一个卷积层输出的展开,故为 256×4。

由于 3 种波磨类型的数据量不均衡,为了提升模型在类别不平衡情况下的分类性能,采用 sklearn 库中的“compute_class_weight”函数计算类别权重,依据样本分布自动分配损失函数中的权重系数。该权重随后被转换为张量并加载至计算设备,用于构建带权重的交叉熵损失函数(CrossEntropyLoss),以增强模型对少数类的学习能力。为缓解梯度消失和梯度爆炸等问题,模型训练过程中采用批量训练策略,批量大小设为 16。选用具有自适应学习率调整能力的 Adam 优化器,初始学习率设置为 1×10^{-3} ,并加入 L2 正则项(权重衰减系数为 1×10^{-5})以防止过拟合。此外,引入学习率调度机制,采用 StepLR 策略,在每训练 5 个周期后将学习率乘以 0.5,实现训练后期学习速率的平稳下降,从而提升模型的收敛性能与泛化能力。

本文提出的 1DCNN 模型建立在基于 Python 语言的 PyTorch 深度学习库中,PC 硬件配置为 Intel(R) Core(TM) i7-10700K CPU @ 3.80GHz、NVIDIA GeForce RTX 3080、Windows 10 系统、16 GB 内存。

3 实验验证

3.1 数据集建立

为便于模型训练与特征提取,将原始的波磨加速度信号进行分段处理。3 种波磨类型的原始数据均包含

数万个采样点，若直接输入模型，不仅计算开销大，还可能掩盖局部特征，因此需对其进行合理切片。

选取长度为 512 的数据段进行分片处理，该长度足以覆盖多个信号周期，能保留典型的波磨特征，同时保证长度不会太长造成切片后的样本集数量过少。切片过程采用滑动窗口方式，不重叠提取固定长度片段，并为每段打上对应的类别标签，舍弃最后长度不足 512 的数据点，构建分类训练样本集。

最终得到 3 种波磨类型共 1 311 条样本作为小波包分解与神经网络训练的数据集，将其中 70% 的样本作为训练集，30% 的样本作为测试集，各波磨类型的样本集具体描述如表 3 所示。

表 3 不同波磨类型样本集描述

Table 3 Description of sample sets for different types of corrugation					
波磨类型	训练集数量/条	测试集数量/条	总数量/条	1311	分类标签
无波磨	588	232	820		0
短波波磨	208	96	304		1
长波波磨	121	66	187		2

3.2 模型训练与结果分析

为验证 1DCNN 模型的有效性，用经过切片处理的数据集进行模型训练，训练迭代次数设为 200，训练结果如图 7 所示。




图 7 1DCNN 训练结果
Figure 7 Training results of the 1DCNN

由图 7 可以看出，模型在训练初期(前 30 轮内)准确率迅速上升，随后逐渐趋于平稳，表明其在短时间内完成了主要的特征学习，具备较强的收敛能力。在整个训练过程中，训练集准确率和测试集准确率始终

保持着较高水平，二者的趋势基本一致，未出现明显的过拟合或欠拟合现象。测试集准确率随着迭代次数的增加，整体稳定在 97% 以上，且波动幅度较小，最大准确率为 97.97%，平均准确率达到 97.60%，说明模型具有良好的泛化能力。

使用混淆矩阵对模型的分类性能进行评估，结果如图 8 所示，混淆矩阵各评价指标如表 4 所示。




图 8 训练结果混淆矩阵
Figure 8 Confusion matrix for training results

表 4 混淆矩阵评价指标

波磨类型	评价指标/%			
	精确率	召回率	F1 分数	准确率
无波磨	98.70	98.28	98.49	97.97
短波波磨	95.83	95.83	95.83	
长波波磨	98.51	100	99.25	

由表 4 可以看出，各波磨类型的精确率、召回率与 F1 分数均超过 95%，其中长波波磨的召回率达到 100%，显示出模型对其具有极强的识别能力，总体准确率为 97.97%。该结果表明，本文构建的 1DCNN 模型能够有效提取能量特征中与钢轨波磨相关的信息，实现对不同波磨类型的准确识别。

3.3 精度对比

为了进一步验证本文提出的钢轨波磨检测模型的有效性，选取支持向量机(SVM)、长短期记忆网络(LSTM)与二维卷积神经网络(2DCNN)进行对比实验，检测精度结果如表 5 所示。

SVM 是一种基于结构风险最小化原则的监督学习算法，具有良好的泛化能力，广泛应用于小样本分类任务中。采用小波包分解后提取的归一化子带能量特征作为 SVM 模型的输入向量，将数据集按 7：3 比例划分为训练集和测试集。模型使用径向基函数(radial

basis function, RBF)核函数, 惩罚参数 C 取 10, 核宽度参数 γ 设置为 0.1。为确保模型间具有可比性, 统一在固定的随机种子下进行数据划分, 保证训练集与测试集的一致性。

表 5 模型精度对比
Table 5 Comparison of model accuracy

模型	训练集平均精度/%	测试集平均精度/%
1DCNN	96.31	97.60
LSTM	93.56	95.98
2DCNN	90.33	93.27
SVM	89.28	92.63

从表 5 可以看出, SVM 模型的分类性能最低, 其在训练集和测试集上的准确率明显低于 1DCNN、2DCNN 和 LSTM 等深度神经网络模型。可能因为 SVM 对特征提取的依赖性较强, 难以有效建模复杂的非线性关系。因此, 尽管 SVM 作为一种经典的分类算法在小样本场景下具有一定优势, 但在本研究所涉及的波磨识别任务中, 其表现不如深度学习模型。

图 9 展示了 LSTM、2DCNN 和 SVM 模型在训练过程中测试集的准确率变化趋势, 并将 1DCNN 模型在测试集上的平均准确率(红色虚线)作为对照参照。从图 9 中可以看出, 3 种模型的测试集准确率均随迭代次数的增加而逐渐提升, 并在一定训练轮次后趋于稳定。其中, LSTM 模型的测试集准确率在迭代初期快速上升, 随后趋于平稳, 最终未能超越 1DCNN 的平均准确率; 2DCNN 模型在训练后期存在一定波动性, 说明其对时序特征的建模能力仍有不足; SVM 模型在




图 9 各模型测试集精度对比
Figure 9 Comparison of test accuracy among different models

测试集上的准确率整体较低, 且收敛速度较慢, 表现出较弱的泛化能力。3 种模型在测试集上的性能均未达到 1DCNN 的水平, 仍存在一定的提升空间。

4 传统波磨测试结果对比

4.1 传统波磨测试方法及评价指标

工程现场波磨识别通常依赖波磨测量小车获取轨面粗糙度空间序列, 并在波长域输出特征波长、粗糙度谱与超限率等指标, 用于维护决策与治理验收。

以 RMF1100 波磨测量小车为例, 其由采集小车与分析软件构成, 可通过里程与位移测量实现轨面粗糙度连续采样, 采样间隔可达 0.2 mm, 具备较高空间分辨率。维护管理中常按波长区段进行限值控制, 并将波长划分为 10~30 mm、30~100 mm、100~300 mm 及 300~1 000 mm 等区段, 以分段超限比作为判据之一。为降低焊缝、接头等离散不平顺对最大值判据的干扰, 工程验收通常采用“超限率”指标反映波磨整体发展水平, 从而提高判据鲁棒性。此外, 粗糙度空间波形经频谱或波长谱转换后可更直观识别主导波长及多波长叠加现象^[13]。

4.2 波长域输出与本文识别标签映射讨论

传统测试输出本质为“波长—幅值”的定量关系, 本文方法输出为无波磨、长波波磨、短波波磨类别及置信度, 二者观测域不同但可建立映射: 短波长区间谱峰主导对应短波波磨, 较长波长区间谱峰主导对应长波波磨。传统测试通常以粗糙度级等指标对轨面短波不平顺进行量化评价, 其定义如下:

$$L_r = 10 \lg \left(\frac{r}{r_0} \right)^2 \tag{9}$$

式中: L_r 为粗糙度级, dB; r 为粗糙度幅值有效值, μm ; r_0 为参考幅值, 取 $1 \mu\text{m}$ 。

该指标常以 1/3 倍频程波长谱形式用于波磨评价与限值对照, 传统测试与本文方法对比如表 6 所示。

表 6 传统测试与本文方法对比
Table 6 Comparison between conventional corrugation testing and the proposed method

维度	传统测试 (波磨测量小车)	本文方法(轴箱振动+ WPD-1DCNN)	差距/优势
测量对象	轨面粗糙度几何	运营列车振动加速度	观测域不同
输出形式	波长谱峰值、超限率、粗糙度级	无波磨/长波/短波类别+置信度	输出更适配 在线筛查
作业条件	需现场窗口与专用设备	可依托运营数据连续获取	在线化优势 明显
工程定位	精确验收、治理评估	风险筛查、区段定位与触发复测	形成互补 闭环

曲线钢弹簧浮置板轨道区段的实测粗糙度谱表明,内轨在波长约 200 mm 处存在明显峰值,同时在波长约 40 mm 及 31.5 mm 附近出现更突出峰值,呈现长波与短波叠加且短波更显著的复合型波磨特征。分波段超限率分析进一步显示外轨整体满足限值,而内轨在 30~100 mm 与 100~300 mm 波长段存在较多数据超限,超限率可达 6%~11%,表明波磨具有内轨集中与波段聚集特征^[13]。另一方面,环线地铁多区段统计结果显示 25~50 mm、100~125 mm 与 190~210 mm 为典型波长聚集区间,其中 25~50 mm 出现频率较高^[14]。为直观说明传统波磨测试文献中波长域统计结论与本文识别标签之间的对应关系,图 10 给出了典型波长区间的归纳示意。




图 10 波长—识别标签对应关系

Figure 10 Wavelength-label relationship

上述传统测试结论在尺度分布上与本文标签体系一致,说明本文识别结果具有明确的波长域工程对应关系。

4.3 对比分析总结

传统测试方法能够直接输出波长谱、粗糙度级与超限率等几何量,适用于精测与验收,但检测频次与覆盖效率受现场条件限制,现场实施时需要进行线路封锁且采集周期长,难以满足高密度运营条件下的连续监测需求,在既有环线及曲线区段实测研究中已详细体现^[14-15]。本文方法基于运营列车轴箱垂向振动信号,利用 WPD 构建多尺度频带特征并结合 1DCNN 进行波磨类型识别,可在不依赖专用检测设备的条件下实现在线筛查与风险区段定位,从而在检测时效性、覆盖能力与工程部署成本方面形成相对传统方法的优势。

基于上述分析,本文方法可作为传统波磨测试的重要补充,形成“在线识别—现场复测—治理验收”的协同应用闭环,在提升波磨检测时效性与线路覆盖能力的同时,兼顾工程评价的可靠性与可解释性。

5 结论与展望

本文针对钢轨波磨的识别问题,提出一种基于小波包分解与一维卷积神经网络相结合的波磨识别方法。与传统依赖轨检车或激光设备的波磨检测方式相比,本文方法基于列车运行时的轴箱垂向加速度信号实现识别,无需额外检测装置,显著降低检测成本与线路封锁时间。该算法可嵌入现有车载监测系统,实现列车运营过程中的实时监测与早期预警。同时,本方法与传统检测设备形成互补:传统设备直接测量轨面几何形貌,空间分辨率高;本方法则从振动响应角度揭示轮轨动力特征,更能反映波磨对列车运行的实际影响。首先利用小波包对振动信号进行 4 层分解,并提取其能量特征作为输入样本,进一步通过 1DCNN 模型实现对波磨的自动分类与识别。研究结论如下:

1) 不同类型的波磨振动信号的能量特征分布在较大差别,说明小波包分解提取的能量特征可以有效反映出钢轨波磨的状态,为能量向量的构建提供了有力依据。

2) 所构建的 1DCNN 模型能够从能量样本中自动学习具有判别性的特征,在识别准确率和鲁棒性方面均优于传统信号处理方法,验证了该方法在钢轨波磨识别任务中的有效性与实用性。

3) 与 SVM、LSTM 及 2DCNN 等模型相比,本文所提出的钢轨波磨识别方法在精度方面表现优越。该模型在测试集上的识别平均准确率达到 97.60%,为最高水平。

后续研究可引入速度修正系数或分段分析策略,拓展该方法在列车变速运行工况下的适用范围。

参考文献

- [1] 崔日新, 石熠, 李玉路, 等. 北京地铁减振轨道钢轨波磨治理效果试验研究[J]. 都市轨道交通, 2024, 37(6): 35-40.
Cui Rixin, Shi Yi, Li Yulu, et al. Experimental study on rail corrugation treatment for vibration reduction tracks in Beijing subway[J]. Urban Rapid Rail Transit, 2024, 37(6): 35-40.
- [2] 李巍. 地铁钢轨波磨成因分析及工程对策研究[J]. 轨道交通材料, 2024, 3(3): 32-36.
Li Wei. Probing into the cause of rail corrugation on metro

- line and study of the countermeasures[J]. Materials for Rail Transportation System, 2024, 3(3): 32-36.
- [3] 谢焯, 赵闻强, 杨红运, 等. 基于一维深度卷积生成对抗网络的钢轨波磨识别方法[J]. 铁道建筑, 2022, 62(12): 62-66.
- Xie Ye, Zhao Wenqiang, Yang Hongyun, et al. Rail corrugation identification method based on 1-dimensional deep convolutional generative adversarial networks[J]. Railway Engineering, 2022, 62(12): 62-66.
- [4] 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.
- [5] 王阳, 肖宏, 张智海, 等. 基于一维卷积神经网络的钢轨波磨迁移诊断方法[J]. 铁道学报, 2025, 47(4): 115-123.
- Wang Yang, Xiao Hong, Zhang Zhihai, et al. Rail corrugation migration diagnosis method based on one-dimensional convolutional neural network[J]. Journal of the China Railway Society, 2025, 47(4): 115-123.
- [6] 马添翼, 李伟, 陈建政, 等. 基于CEEMDAN-MPE算法的地铁短波长钢轨波磨识别[J]. 噪声与振动控制, 2023, 43(2): 120-126.
- Ma Tianyi, Li Wei, Chen Jianzheng, et al. Identification method for metro rail corrugation based on CEEMDAN-MPE algorithm[J]. Noise and Vibration Control, 2023, 43(2): 120-126.
- [7] Zhang Yong, Li Bingkui, Li Jun, et al. Rail corrugation identification method based on parameter optimization VMD and SPWVD[C]//2019 IEEE 16th International Conference on Networking, Sensing and Control (ICNSC). May 9-11, 2019. Banff, AB, Canada. IEEE, 2019: 110-115.
- [8] Belov I V, Shalymov R V, Tkachenko A N, et al. Development of an algorithm for detecting railway corrugations in acceleration data[C]//2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus). IEEE, 2021: 1609-1613.
- [9] 杨斌, 樊志刚, 王建国, 等. 小波包和 1D CNN 结合的刀具磨损状态识别[J]. 机械设计与制造, 2024(9): 228-232.
- Yang Bin, Fan Zhigang, Wang Jianguo, et al. Tool wear status recognition based on wavelet packet and 1D CNN[J]. Machinery Design & Manufacture, 2024(9): 228-232.
- [10] Zhou J, Ma R, Chen J. Bearing fault diagnosis based on 1D-CNN-LSTM-TL[C]//ICETIS 2022; 7th International Conference on Electronic Technology and Information Science. VDE, 2022: 1-6.
- [11] Harris, F. J. On the use of windows for harmonic analysis with the discrete fourier transform[J]. Proceedings of the IEEE, 1978, 66(1): 51-83.
- [12] 李威霖. 车铣刀具磨损状态监测及预测关键技术研究[D]. 成都: 西南交通大学, 2013.
- Li Weilin. Research on key technologies of tool condition monitoring and prediction in turning and milling[D]. Chengdu: Southwest Jiaotong University, 2013.
- [13] 阿斯顿·张, 扎卡里·C. 立顿, 李沐, 等. 动手学深度学习[M]. 北京: 人民邮电出版社, 2023: 170-172.
- Zhang Aston, Zachary C. Lipton, Li Mu, et al. Dive into deep learning[M]. Beijing: Posts & Telecom Press, 2023: 170-172.
- [14] 伍彦俊, 李明谔, 刘庆杰. 地铁曲线区段钢弹簧浮置板轨道钢轨波磨特征及打磨效果分析[J]. 铁道工务, 2025, 3(5): 31-35.
- [15] 焦朋宇, 王文波, 关庆华, 等. 基于实测数据的环线地铁钢轨波磨特征分析[J]. 噪声与振动控制, 2023, 43(6): 149-156.
- Jiao Pengyu, Wang Wenbo, Guan Qinghua, et al. Analysis of the characteristics of rail corrugation in a metro loop line based on measurement data[J]. Noise and Vibration Control, 2023, 43(6): 149-156.

(编辑: 傅依萱)