

DOI: 10.3901/JME.2023.03.110

基于轴箱振动与动力学模型驱动的高速列车车轮失圆状态识别方法^{*}

邓磊鑫 谢清林 陶功权 温泽峰

(西南交通大学牵引动力国家重点实验室 成都 610031)

摘要: 针对高速列车车轮失圆识别难以兼顾效率与精度问题, 提出一种基于轴箱振动与动力学模型的高速列车车轮失圆状态智能识别方法。首先, 利用静态检测设备采集车轮非圆原始数据, 提出一种数据增强技术构建车轮非圆增强数据集。其次, 将增强数据集输入至高速列车车辆—轨道耦合动力学模型, 获取车轮不同失圆状态下轴箱振动样本集。最后, 通过构建恰当结构与配置参数的一维卷积神经网络(1-dimensional convolutional neural network, 1-DCNN), 可对轴箱振动信号进行自适应特征提取, 实现对车轮失圆状态的智能识别分类。结果表明: 提出的车轮失圆状态智能识别方法能实现正常车轮、多边形车轮、擦伤车轮、随机非圆化车轮与局部缺陷车轮 5 类车轮失圆状态的智能分类, 准确率达 99.2%(标准差为 0.05), 且单个样本平均识别耗时为 0.4 ms。结合现场试验, 所提方法对实测轴箱振动具有较好识别能力, 测试精度为 95%。与经典的 SVM 和 BP 神经网络相比, 1-DCNN 模型具有更高的识别准确度。

关键词: 车轮失圆; 车辆—轨道耦合动力学模型; 轴箱振动; 数据增强; 一维卷积神经网络

中图分类号: U279

Identification Method of Wheel Out-of-roundness State of High-speed Train Based on Axle Box Vibration and Dynamic Model

DENG Leixin XIE Qinglin TAO Gongquan WEN Zefeng

(State Key Laboratory of Traction Power, Southwest Jiaotong University, Chengdu 610031)

Abstract: It is difficult to consider both efficiency and precision in traditional methods to detect wheel out-of-roundness (OOR) of high-speed train. An intelligent identification method based on the axle box vibration and dynamic model is proposed. Firstly, the original data of wheel OOR is collected by a static detection device, and a data enhancement technique is proposed to construct the enhanced data set of wheel OOR. Then, the enhanced data set serves as input to the vehicle-track coupled dynamics model of high-speed train to obtain the vibration sample set of axle box under the excitation of different types of wheel OOR. Finally, the features of axle box vibration signal are adaptively extracted to identify and classify wheel OOR types using a 1-dimensional convolutional neural network (1-DCNN) with appropriate structure and configuration parameters. The results show that the proposed method can intelligently classify five types of wheel OOR, including normal, polygonal, scratched, stochastic non-roundness and local defect wheels. The accuracy rate is 99.2% (standard deviation of 0.05) and the average identification time of a single sample is 0.4 ms. Combined with the field test, the proposed method has a good recognition ability for the measured axle box vibration, and the test accuracy is 95%. Compared with the Support Vector Machine (SVM) and Back Propagation (BP) neural network methods, the 1-DCNN model has higher accuracy.

Key words: wheel out-of-roundness; vehicle-track coupled dynamics model; axle box vibration; data enhancement; 1-DCNN

0 前言

高速列车车轮普遍存在周向非均匀磨损, 进而

导致车轮失圆。各种车轮失圆状态会引起不同程度的动力学响应^[1]。车轮表面擦伤引起高速列车轮轨接触状态的骤然恶化, 从而造成动态冲击效应, 导致轮对轴承、车轴和钢轨的损伤, 增加车辆和线路的维修费用。高阶车轮多边形激励起车辆部件或轨道结构的耦合振动, 会缩短关键部件的疲劳寿命及

^{*} 国家自然科学基金(U21A20167)和牵引动力国家重点实验室自主课题(2020TPL-T12)资助项目。20220402 收到初稿, 20221110 收到修改稿

产生较大的噪声污染。为保障列车运行安全性、乘坐舒适性及降低维护成本,采用车轮镟修手段对失圆车轮踏面进行廓形修复,消除车轮失圆造成的安全隐患。及时、准确地获取车轮状态,可为车轮镟修策略提供指导与帮助,保障列车运行安全性和运营品质。因此,车轮失圆状态的检测识别方法研究具有重要意义。

车轮失圆状态的检测方法可分为静态检测法和动态检测法。静态检测法采用测试仪器实现静止列车的车轮状态检测,其准确性较高,但效率较低。动态检测法通过采集运行列车车辆部件振动、轮轨力、钢轨振动等信号间接辨识车轮状态,其具有实时监测的可能性,因此,学者多对动态检测方法进行研究。

李景泉等^[2]提出采用等臂叉形机构(位移测量法)检测车轮擦伤,其测量精度受机构部件的加工精度、连接方式以及装置的安装精度影响,列车低速运行时,具有较好准确度。杨雪荣等^[3]提出基于计算机视觉(图像检测法)的轮对踏面擦伤检测方法。但检测装置成本较高,且检测精度受图像拍摄效果影响。江航等^[4]对轮轨噪声(噪声检测法)进行采集分析,实现对车轮扁疤的故障诊断。声音检测方式简单,但检测信号易被邻轮声音信号干扰,适合用于定性分析。赵蓉等^[5]提出基于粒子群-支持向量机(PSO-SVM)算法结合钢轨振动信号(振动检测法)的车轮擦伤识别方法。该方法不受速度影响,识别精度较高,且能实现擦伤等级判断。李旭伟等^[6]构建了轮轨垂向力全连续测量方法(轮轨力检测法)并用于车轮多边形的监测。但该方法应用效果受车辆轴距特征、轨道结构特点等因素影响,技术手段较复杂。振动加速度检测法成本较低,能进行连续不间断测量,且不受车速限制。鉴于此,不少学者基于振动信号对车轮多边形识别方法进行研究。李奕璠等^[7]基于改进的希尔伯特-黄变换提取轴箱振动的时频特征进而分析车轮踏面擦伤及车轮多边形的故障振动特性。宋颖等^[8]提出一种改进的聚合经验模态分解(EEMD)与魏格纳-威尔分布(WVD)相结合的时频分析方法,实现车轮多边形状态识别及车轮多边形磨损幅值评估。SUN等^[9]提出角度域层次的滤波方法对实测轴箱振动信号进行降噪处理,实现车轮多边形状态的诊断,并可分析其阶次。上述研究工作采用振动信号作为间接辨识车轮多边形的信息源时,不可避免地都采取一定信号处理算法提取振动信号中映射车轮多边形的特征表述,其需要依赖大量的专家经验且需要人工提取信号特征。卷积

神经网络^[10](Convolutional neural network, CNN)通过卷积层卷积算法实现故障细节特征自动提取和学习,能达成“端到端”的智能识别与诊断。在轨道交通领域,不少学者基于卷积神经网络模型结合振动信号进行故障识别及诊断,并取得良好效果^[11-14]。

综上所述,车轮失圆状态研究目标侧重于车轮擦伤及车轮多边形,多种车轮失圆状态的智能化识别方法亟待研究。利用机械设备监测信号结合数据驱动方法可实现对故障的智能诊断。但基于不完备的故障信号样本,其故障诊断识别普适性和准确性会大打折扣。向家伟^[15]通过建立机械传动系统数值模型并进行个性化仿真分析,可解除故障样本不充分、不完备限制。为进一步提高故障样本质量,向家伟^[16]提出通过生成式对抗网络生成大量与故障样本相似的新样本,从而提高诊断模型的实际应用能力。受此启发,本文提出一种基于轴箱振动和动力学模型驱动的方法。通过构建车辆-轨道刚柔耦合动力学模型,获取不同车轮失圆激励下的完备轴箱振动信号,结合一维卷积神经网络算法,以对高速列车车轮失圆状态进行智能识别与分类。

1 卷积神经网络基本理论

CNN通常由特征提取层和分类识别层组成。特征提取层由卷积层与池化层交替衔接而成。分类识别层由密集连接层和激活函数构成。

1.1 卷积层

采取预设大小的卷积核与上一层数据进行卷积运算提取局部细节特征,进一步结合非线性映射算法输出特征信息,其数学模型如下^[17]:

$$X_j^n = f \left(\sum_{i \in M_i} X_i^{n-1} * W_{ij}^n + B_j^n \right) \quad (1)$$

式中, i 和 j 分别为输入与输出数据的位置索引; M_i 为第 i 个卷积区域; X_i^{n-1} 为 $n-1$ 层的第 i 个输入特征; $*$ 为卷积运算; B 为偏置矩阵; W 为权重矩阵; X_j^n 为 n 层的第 j 个输出特征; $f(\cdot)$ 为激活函数。

深度学习方法中非线性映射通常选取修正线性单元(Rectified linear units, ReLU)模型,其数学表述如下

$$f(x) = \max\{0, x\} \quad (2)$$

式中, x 为卷积运算后的输出特征。

1.2 池化层

池化层利用池化函数实现目标层数据特征降采样,可减少训练参数数目,增强样本数据显著特性,

并在一定程度上约束过拟合行为。典型池化算子分为最大池化与平均池化。本文采用最大池化算子,其主要思想是捕获某空间尺度整体特征中的最大值替代原整体空间的输出特性,其数学模型如下

$$H_i^{n+1}(j) = \max_{(j-1)d+1 \leq m \leq jd} \{F_i^n(m)\} \quad (3)$$

式中, F_i^n 和 H_i^{n+1} 分别为第 n 层的第 i 通道输入特征与第 $n+1$ 层第 i 通道输出特征; j 为池化区域增量; m 为池化区域的数据位置变量; d 为池化区域宽度。

1.3 分类层

分类层主要由全连接层和激活函数构成。第一层全连接层衔接特征提取层,实现池化层数据“展平”操作以整合局部特征信息。设置后续不同层数、层结构的全连接层及激活函数可揭示局部特征的辨识信息,满足特定研究需求。此外,通常在全连接层间设置抑制过拟合技术 Dropout,其主要原理为在模型学习过程中随机删减特征检测器,降低模型对非典型特征的学习能力,从而约束模型过拟合趋势。分类层最终目标是解决二分类或多分类问题。二分类问题通常采用 Sigmoid 激活函数。多分类问题采

用 Softmax 激活函数,其数学模型如下

$$S_i = \frac{e^{Z_i}}{\sum_{k=1}^n e^{Z_k}} \quad (4)$$

式中, n 为类别总数; i 为输出类别数; S 为输出类别概率; Z 为输出预测值。

2 基于轴箱振动与动力学模型驱动的车轮失圆状态识别流程

基于车辆—轨道耦合动力学原理^[22]建立了车辆—轨道耦合动力学模型,获取轴箱振动信号,利用一维卷积神经网络映射车轮失圆状态与轴箱振动信号之间的相关关系,最终实现基于轴箱振动与动力学模型驱动的车轮失圆状态智能识别与分类。图1为基于轴箱振动与动力学模型驱动的车轮失圆状态识别流程,可分为5部分:① 车轮非圆数据采集;② 车轮非圆数据扩充;③ 动力学仿真模型及轴箱振动样本集构建;④ 1-DCNN 结构设计与训练;⑤ 车轮失圆状态智能识别。

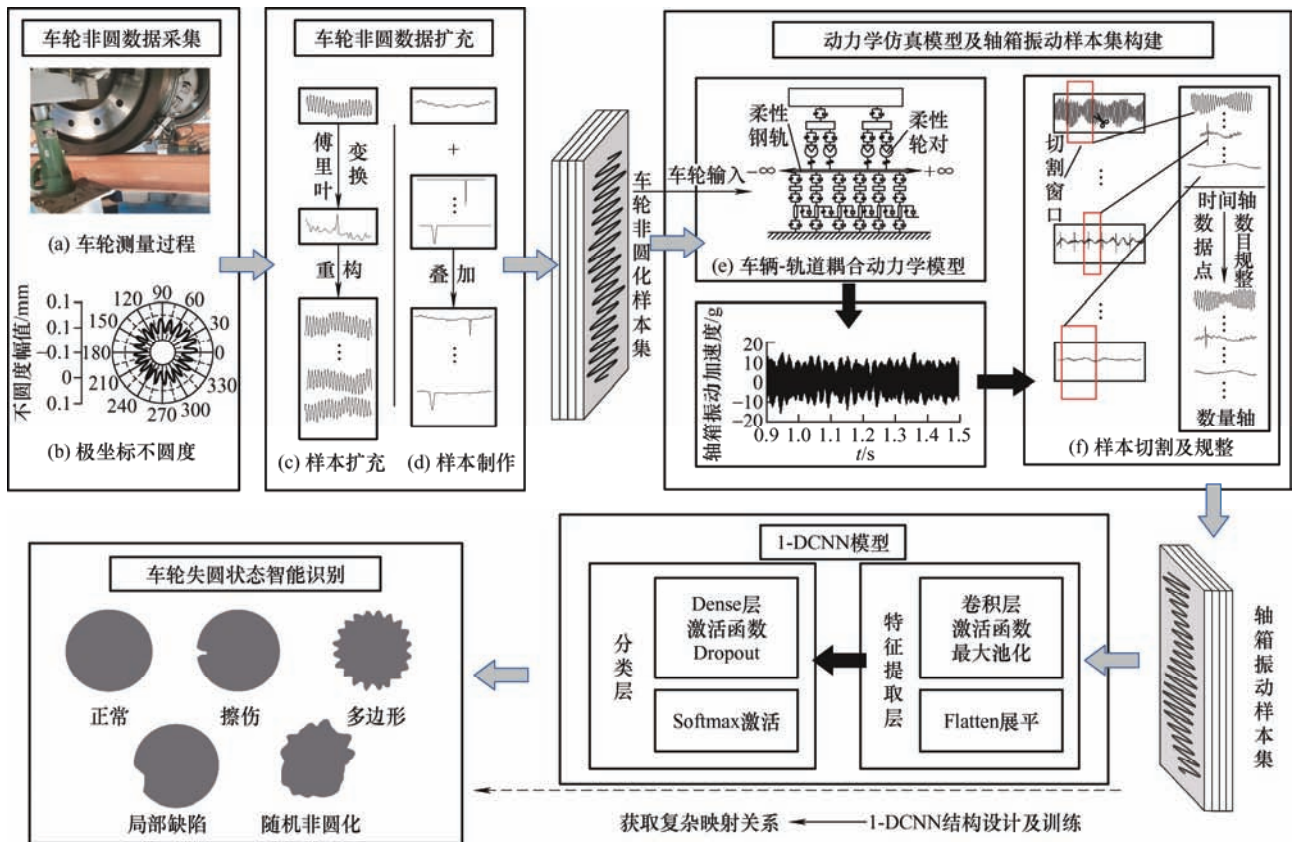


图1 基于轴箱振动与动力学模型驱动的车轮失圆状态识别流程

2.1 车轮非圆数据采集

通过将车轮非圆化信息输入动力学模型可获得仿真轴箱振动信号。完备的轴箱振动信号对车轮非圆化的种类及数量有较高要求。利用车轮表面粗糙度测量仪 MÜLLER-BBM 对车轮非圆化信息进行直接测量，以获取实测车轮非圆化数据，进而输入动力学模型获取相应轴箱振动响应。

车轮非圆化磨损测量过程如图 2 所示。测量时使用千斤顶装置抬起轮对，缓解车轮制动机构，匀速旋转车轮，传感器探头接触车轮表面以测量车轮轮径变化，从而获得车轮非圆化数据。测量设备固定的采样间隔是 1 mm，测量精度为 0.1 μm。车轮测量数据通常经过毛刺剔除及曲率平滑，剔除测试数据中的毛刺，可获得用于动力学模型输入的车轮非圆化数据。




图 2 车轮非圆化磨损测量现场照片

2.2 车轮非圆数据扩充

铁路现场典型车轮非圆化可分为 9 类^[18]：偏心、局部缺陷、周期性非圆化、随机非圆化、波磨、粗糙度、扁疤、剥落、剥离。分析实测高速铁路车轮失圆结果可知，偏心、多边形、擦伤、局部缺陷与随机非圆化 5 类非圆特征占据主要成分，多边形车轮阶次成分表现为 17~20 阶。此外，车轮普遍存在不同程度的偏心磨损，严重的车轮偏心通常伴随车轮多边形同时出现^[19]，因此本文不对偏心车轮进行识别。

实测车轮非圆化数据中，正常车轮、多边形车轮的数据样本较多，随机非圆化、擦伤、局部缺陷车轮的样本较少。车轮非圆化样本的种类及数量决定轴箱振动样本的完备性。利用数据增强技术增强车轮非圆样本集。一方面，基于车轮非圆反演原理^[20]对正常、多边形与随机非圆化车轮进行样本扩充，另一方面，采取车轮局部非圆构造方法对擦伤及局部缺陷进行样本制作。

车轮非圆反演步骤如下：将实测车轮非圆化信号经离散傅里叶变换得到其窄带频谱。取车轮周长

与窄带频谱中心波长之比的前 40 阶车轮非圆阶次为扩充参照，假设车轮非圆化的模拟信号由前 40 阶阶次表征的正弦函数叠加形成，各正弦波具有不同频率、幅值与相位，详细数学表述如下

$$y(x) = \sum_{i=1}^{40} A_i \sin\left(\frac{i}{2\pi r} 2\pi x + a_i\right) \quad (5)$$

式中， x 为车轮周向位置； a_i 为第 i 阶非圆化相位，通过随机算法产生； A_i 为第 i 阶非圆化幅值； r 为车轮半径。

通过车轮非圆化阶次反求第 i 阶非圆化幅值 A_i

$$A_i = \sqrt{2} \times 10^{L_i/20} \quad (6)$$

式中， L_i 为第 i 阶车轮非圆化的粗糙度水平。

图 3 为某车轮多边形样本扩充结果，图 3a 表示实测车轮非圆化数据；图 3b 经傅里叶变换及相关运算求解得到的前 40 阶阶次成分；图 3c 和图 3d 为经车轮非圆反演步骤产生的 2 个扩充车轮数据。对比原始样本与扩充样本可知，扩充样本能保留原始样本的幅值水平及阶次特征。正常与随机非圆化车轮非圆数据扩充过程同理，故不再赘述。

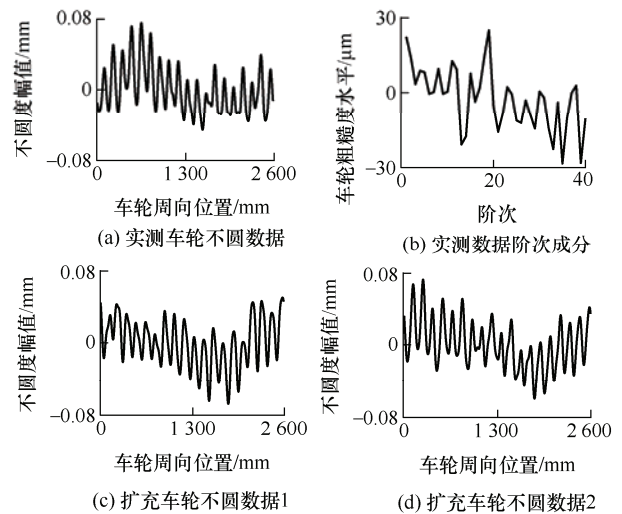


图 3 车轮失圆数据扩充

车轮局部非圆构造如图 1d 所示，将实测正常车轮数据同表征擦伤及局部缺陷车轮非圆化特征的数学模型进行随机周向位置数据叠加，形成擦伤及局部缺陷车轮非圆化样本。擦伤及局部缺陷车轮非圆化特征的数学模型如下

$$h(t) = -\frac{B}{2} \left(1 - \cos \frac{2\pi t}{L}\right) \quad 0 < t < L \quad (7)$$

式中， t 为空间位置； B 与 L 分别为擦伤或局部缺陷深度与长度。

依据车轮非圆化实测结果，车轮擦伤长度 L 设

为 20~50 mm(增量 1 mm), 深度 B 设为 0.05~0.2 mm(增量 0.01 mm); 车轮局部缺陷长度 L 设为 200~240 mm(增量 5 mm), 深度设为 0.14~0.32 mm(增量 0.02 mm)。

利用样本扩充及车轮局部非圆构造方法增强车轮非圆样本集, 进而输入动力学模型进行仿真计算, 可获取较为完备的轴箱振动数据。

2.3 动力学仿真模型及轴箱振动样本集构建

针对高速列车车轮失圆状态识别, 基于机械传动系统个性化故障诊断基本原理^[15]与车辆—轨道耦合动力学原理^[21-22], 提出一种动力学仿真模型获取轴箱振动信号, 并经信号切割及规整制作形成振动样本集。通过建立车辆—轨道刚柔耦合动力学模型, 结合实测轴箱振动信号进行模型验证, 验证后模型用于多种失圆车轮仿真计算, 获取完备轴箱振动信号, 并将其输入 1-DCNN 模型进行训练进而实现失圆状态识别分类。

考虑轮对与钢轨柔性的动力学模型较刚性轮轨能更加准确地反映由车轮失圆导致的中高频振动特性^[21-22]。以国内某型高速列车为研究对象, 根据其实际参数建立车辆—轨道刚柔耦合动力学模型^[23]。

(1) 建立车辆模型, 考虑 1 个车体、2 个转向架构架和 4 个柔性轮对组成的多自由度动力学系统, 其中每个刚体考虑垂向、横向、点头、摇头和侧滚 5 个方向的自由度, 总计 15 个自由度。采用有限元实体单元建模柔性轮对, 并利用模态叠加法求解^[24]。一系、二系悬挂系统采用三维弹簧-阻尼单元模拟, 参数设置参照实际车型参数。

(2) 建立轨道模型, 考虑钢轨、扣件系统、整体道床及路基组成的多层轨道结构系统。左右钢轨被视为连续弹性离散点支承基础上的 Timoshenko 梁。扣件系统采取三维弹簧-阻尼单元模拟。整体道床考虑成柔性体, 用有限元实体单元建模, 并利用模态叠加法进行求解^[25]。路基支撑层简化为均匀分布的弹簧-阻尼单元连接。各结构间的弹簧-阻尼单元参数参照文献[25]。

(3) 车辆模型与轨道模型通过轮轨间接接触算法联合为整个动力学系统。采用实时在线获取轮轨接触点方法^[26]确定柔性轮对与钢轨接触关系。采用赫兹非线性接触理论计算轮轨接触法向力, 利用沈氏理论计算轮对切向力, 相关理论不在本文赘述, 详见文献[23]。

为验证动力学仿真模型的可靠性, 对模型仿真结果与实测轴箱振动信号进行时域、频域对比, 结

果如图 4 所示, 该模型具有较好的准确性。模型部分车辆与轨道参数设置如表 1 所示。




图 4 仿真与实测轴箱振动信号对比图

表 1 车辆-轨道刚柔耦合动力学模型部分参数

| 参数 | 数值 |
|---------------------|--------------------|
| 轮对质量/kg | 1 881 |
| 一系弹簧垂向刚度/(N/m) | 9.00×10^5 |
| 一系弹簧垂向阻尼/(N/(m/s)) | 1.05×10^4 |
| 一系弹簧横向刚度/(N/m) | 5.45×10^6 |
| 一系弹簧横向阻尼/(N/(m/s)) | 500 |
| 空气弹簧垂向刚度/(N/m) | 2.40×10^5 |
| 空气弹簧横向阻尼/(N/(m/s)) | 1.50×10^4 |
| 空气弹簧垂向阻尼/(N/(m/s)) | 2.50×10^4 |
| 扣件垂向刚度/(N/m) | 4.00×10^7 |
| 扣件垂向阻尼/(N/(m/s)) | 3.00×10^4 |
| 扣件横向刚度/(N/m) | 2.94×10^7 |
| 扣件横向阻尼/(N/(m/s)) | 5.20×10^4 |
| 轨道板离散垂向刚度/(N/m) | 1.00×10^8 |
| 轨道板离散垂向阻尼/(N/(m/s)) | 1.00×10^4 |

将增强车轮非圆样本集作为车辆—轨道刚柔耦合动力学模型的车轮不平顺激励, 轨道不平顺采取中国高速铁路无砟轨道不平顺谱 (TB/T 3352—2014), 车辆运行速度分别设置为 300 km/h、350 km/h, 获取轴箱振动加速度数据。部分典型轴箱振动及车轮非圆化特征如图 5 所示。正常车轮下, 轮轨接触状态良好, 轮轨系统的动态响应主要受轨道不平顺影响; 存在车轮多边形磨损的车轮会引起显著的轮轨系统动态冲击作用; 擦伤车轮在列车高速运行时, 轮轨接触状态的骤然恶化会造成动态冲击效应并在轴箱振动信号中显现; 车轮局部缺陷相较于车轮擦伤在车轮踏面尺度上具有较长的范围, 其冲击效应相对较小, 振动衰减趋势较缓; 随机非圆化车轮沿车轮周向粗糙度呈现为无规则变化, 其轴箱振动随轮轨接触状态的随机变化而表现为混沌状态。

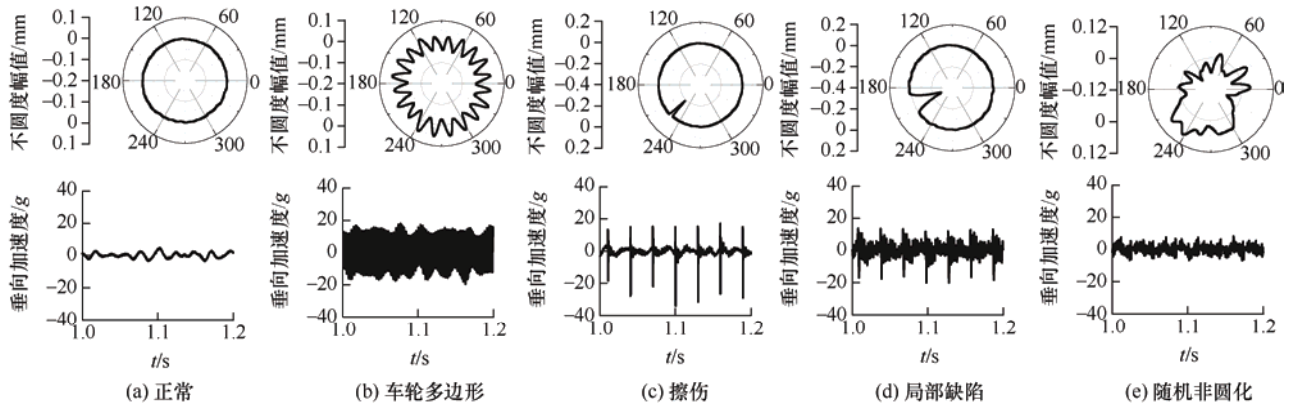


图5 各车轮状态及轴箱振动仿真结果

各轴箱振动信号通过一定样本制作手段形成样本输入集。典型的技术手段是采取切割窗口对时序信号进行切割划分,降低时间尺度。确立切割窗口是样本制作的关键所在。轴箱振动响应主要受轮轨接触状态影响,理想状态下,无轨道激励时,同一车轮前一车轮周长与后一车轮周长对应的振动响应相一致。鉴于此,采取单个车轮周长下的振动响应映射车轮失圆状态。不同速度下,车轮滚过整个车轮周长位移的时间长度相异。若采取传统的固定切割窗口实行振动时域信号样本切割划分,则无法确保各样本容纳数目一致的车轮周期,在速度差异性较大时,可能会给车轮失圆状态识别造成不可预知的困难。因此,提出“整周期化”技术实现振动信号样本切割制作,如图1f所示,具体步骤如下。

(1) 确定时间切割窗口长度 l 。单个车轮周长周期内的振动变化映射车轮非圆化特征。如图1f所示,通过计算不同速度下滚过单个车轮周长的时间长度 l ,可确定不同长度的切割窗口,进而自适应地实现振动信号切割划分。

(2) 设定样本数据点标准数目 m_0 。因振动信号样本时间长度 l 存在一定差异,而模型仿真的计算步长 t 一般固定不变,从而导致各样本数据点数目 m 相异。为提升振动样本数据集的规整性,满足1-DCNN模型对输入样本的规范性要求,本文以某一最高车速 v_{\max} 下振动样本包含数据点数目 m_{\min} 作为样本数据点标准数目 m_0 。样本数据点数目 m 与时间长度 l 的转换关系如下

$$m = \frac{l}{t} \quad (8)$$

(3) 样本数据点规整。各样本在整个样本时间

维度 l 上进行随机、分散地数据点缩减,使数据点数目规整为 m_0 。具体数据缩减方法如下:采用三次样条拟合函数对原始数据进行拟合,选取非极值点的两相邻数据点,使用两个数据点的时间中点处的拟合数值替换原有两数据点并整合进样本时序维度。

通过上述特征“整周期化”切割手段对仿真轴箱振动信号实行样本制作,从每个仿真工况的轴箱振动信号中切割提取1至2个样本,形成样本集。样本集样本总数为18 000,其中训练集15 000,测试集3 000。具体样本构成如表2所示。若某样本预测标签为[0.97,0.01,0.000 5,0.01,0.009 5],则该样本识别结果为正常车轮。

表2 轴箱振动样本集描述

| 失圆类别 | 样本数目 | 类别标签 |
|------|-------|-------------|
| 正常 | 7 000 | [1,0,0,0] |
| 多边形 | 4 000 | [0,1,0,0] |
| 随机非圆 | 2 000 | [0,0,1,0] |
| 擦伤 | 2 000 | [0,0,0,1] |
| 局部缺陷 | 3 000 | [0,0,0,0,1] |

2.4 1-DCNN 模型设计与训练

轴箱振动为一维时间序列,采用典型二维卷积神经网络模型会破坏一维序列数据结构及增加模型识别的困难程度。因此,本文构建基于原始一维时序信号作为输入特征源的1-DCNN模型对正常、擦伤、多边形、局部缺陷与随机非圆化5类车轮状态进行“端到端”的智能分类识别。图6所示为本文1-DCNN模型的具体构造。第一部分为输入样本。第二部分是由卷积层和最大池化层交替构成的特征提取层,其功能是实现样本特征的自

动提取。第三部分为分类识别层, 包含一系列密集连接层(Dense 层), 结合抑制过拟合技术

Dropout, 最终通过 Softmax 激活函数实现车轮失圆状态的分类识别。




图 6 1-DCNN 模型的具体结构

卷积运算为 1-DCNN 模型关键所在。较小卷积核会使模型学习到在振动信号中普遍存在的细节特征(高频噪声污染), 干扰模型的识别能力^[27]。鉴于此, 本模型第一层卷积层采用较大卷积核, 削弱高频信号对特征提取造成的影响, 并提取样本典型特征。第二层卷积层采用相同大小卷积核进一步突出显著特征。

在 1-DCNN 模型中, 选取适宜的模型参数能兼顾模型训练精度和训练速度。该 1-DCNN 模型具体参数设置如表 3 所示。

表 3 1-DCNN 具体参数配置

| 类型 | 参数设置 | |
|-----------|-----------------|------|
| | 卷积核或网络节点数或参数/步长 | 深度/层 |
| 卷积层 1 | 12×1/1×1 | 4 |
| 池化层 1 | 4×1/1×1 | 4 |
| 卷积层 2 | 12×1/1×1 | 4 |
| 池化层 2 | 4×1/1×1 | 4 |
| Dense 层 1 | 16 | 1 |
| Dropout1 | 0.05 | 1 |
| Dense 层 2 | 16 | 1 |
| Dropout2 | 0.1 | 1 |
| Softmax 层 | 5 | 1 |

2.5 车轮失圆状态智能识别

采用“Adam”优化器训练网络, 学习率设为 0.001, 损失函数为“categorical_crossentropy”。为避免梯度弥散与梯度爆炸, 利用批处理样本技术进

行训练, 批大小为 512。该 1-DCNN 模型建立在基于 Python 3.6.5 的 Keras 深度学习库中。计算机硬件配置为 i7-6500U 处理器 12 GB 内存 Windows 10 系统。

通过上节所设 1-DCNN 模型结构训练轴箱振动样本集, 最终实现正常、擦伤、多边形、局部缺陷与随机非圆化 5 类车轮状态的智能识别分类。

3 结果分析

3.1 训练结果分析

图 7 展示了模型训练与测试过程的精度与损失变化。从中可知, 其精度水平整体为上升趋势并逐渐收敛。测试集未显露过拟合现象, 表明 Dropout 技术运用恰当。此外, 模型在较少训练轮次下测试及训练精度都可达到较高水平(95%), 说明模型训练收敛速度较快。观察测试与训练精度及损失曲线演变规律, 异于常见形式, 在模型训练中前期阶段, 测试集精度及损失性能优于训练集, 剖析其原因可能是样本集随机划分特性, 测试集与训练集样本特征存在一定差异, 训练集各车轮状态类别具有更复杂的细节特性需要模型进一步学习, 因而模型对某些差异性较大的训练样本的识别能力有所欠缺, 而差异性较大样本在测试集中占比较小, 从而导致相同识别能力下, 测试集识别效果更佳。该现象侧面印证样本集具有足够的复杂程度, 有利于提升模型泛化能力。

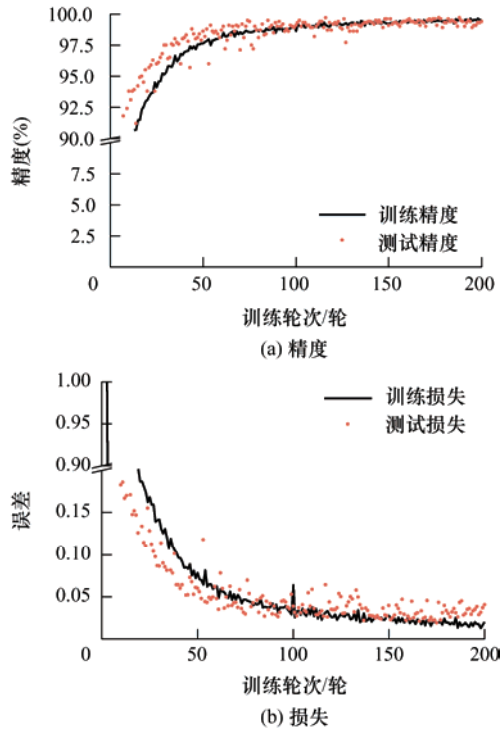


图7 精度及损失变化

为评估模型识别车轮状态能力, 采取多次试验以观察试验普适性结果, 从而避免单次试验结果的随机性及局限性。对样本集训练集及测试集进行 10 次随机划分, 获取 10 次试验的测试精度及单个样本识别耗时, 结果如图 8 所示。由图 8 可知, 10 次试验车轮失圆状态识别精度都可达 99%, 表明将该模型用于车轮失圆状态分类识别的准确度高且模型的鲁

棒性较强。此外, 单个样本识别耗时不超过 0.4 ms。




图8 试验结果

3.2 可视化分析

为深入探究该一维卷积神经网络模型实现车轮失圆状态识别的工作机制, 分别对多边形车轮、正常车轮、擦伤车轮、局部缺陷与随机非圆化车轮样本经卷积层卷积后的输出特征进行可视化, 结果如图 9a~9e 所示。第一卷积层卷积后的输出数据维持着输入样本显著性强的数据特征, 高频的谐波特性被剔除, 起到低通滤波器的功能。第二卷积层卷积后的输出数据凸显为各数据种类的相干性特性。正常车轮表现为单调趋势性波动; 擦伤车轮冲击效应被显著增强; 多边形车轮细节特征为等间隔的谐波信息; 随机非圆化车轮相关特性为非等间隔、非平稳、规律不明显的波动; 局部缺陷车轮呈现为阶梯状逐渐衰弱的冲击信号。

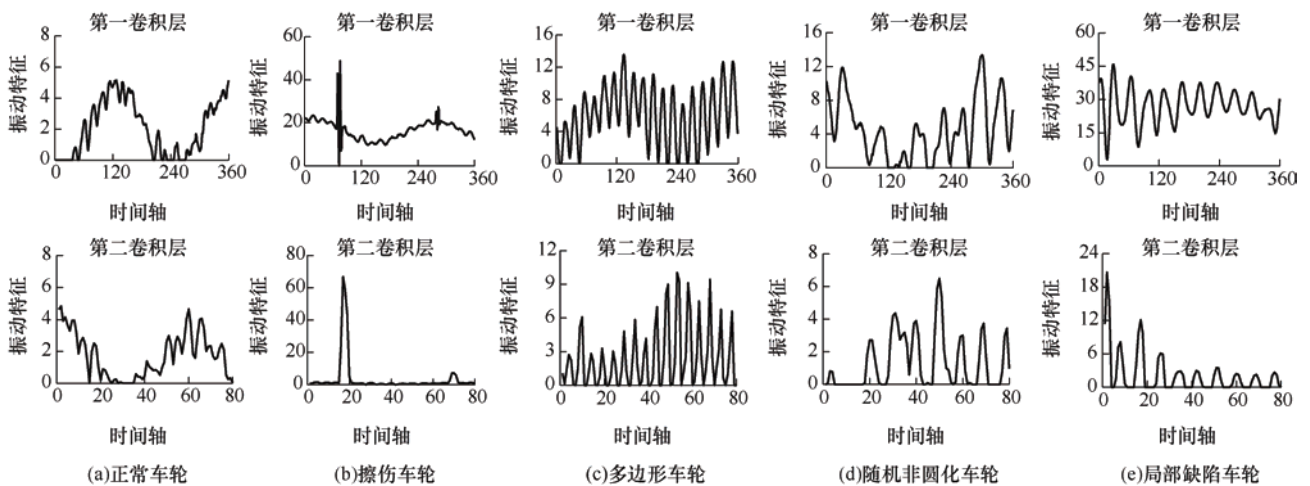


图9 卷积层数据可视化

T-分布邻域嵌入算法 (T-distributed stochastic neighbor embedding, T-SNE)^[28]可将数据从高维复杂空间降维至低维空间, 以对数据内分布形态进行直观观测。基于 T-SNE 算法对 1-DCNN 特征提取与分类识别过程进行可视化分析, 结果如图 10 所示。测

试样本集在原始输入层冗杂成堆、难以准确区分; 第一卷积层样本集整体区分度较小程度增强, 印证上述分析, 第一卷积层仍保留着大部分数据特征, 数据集主体构造未产生显著改变; 第二卷积层数据辨识度明显增强, 显露聚类趋势; 第一 Dense 层样

本特性显现为数据类别的成堆非混杂分布, 该 Dense 层为后续样本类别识别起到关键性作用; 最终分类识别层能有效、准确地达成测试样本集的分

类识别。通过整个散点图变化趋势可知, 本文提出的一维卷积神经网络模型能逐层次地实现样本特征的自动提取及数据类别的分类识别。

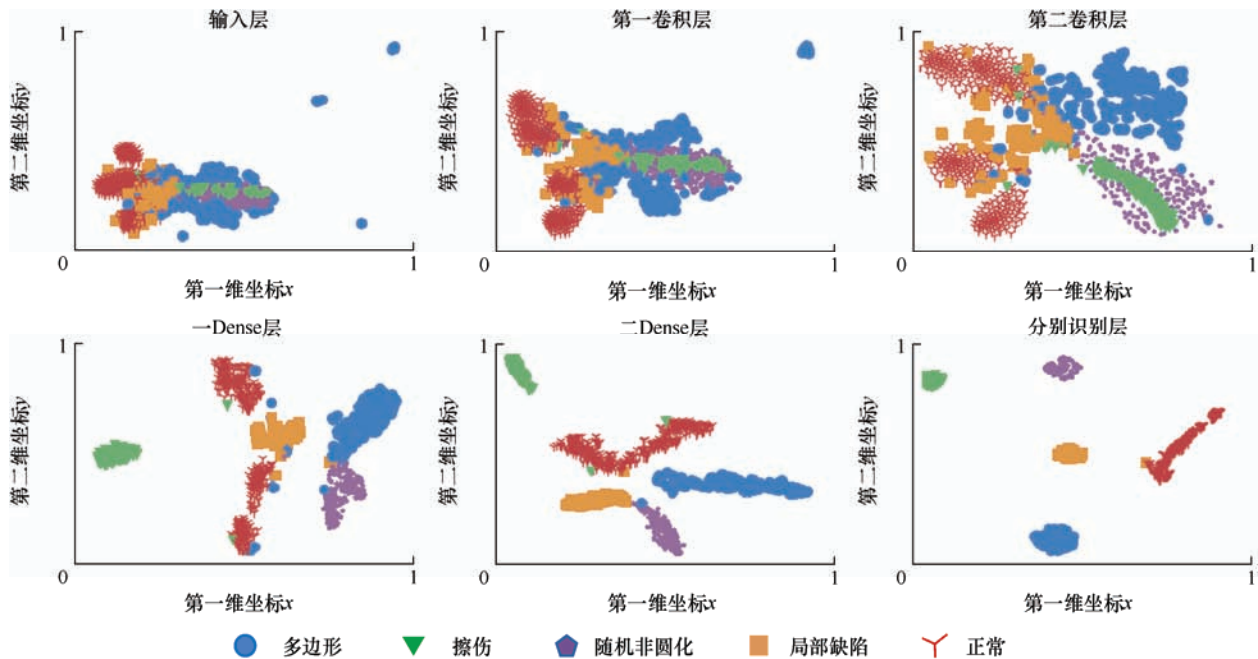


图 10 基于 T-SNE 的模型可视化

3.3 对比分析

为进一步探究提出的 1-DCNN 模型性能, 与支持向量机(Support vector machine, SVM)及 BP 神经网络方法进行对比分析。各算法计算硬件一致, 其具体的参数配置如下。

SVM 采用高斯核函数, 选取不同惩罚因子 C , 经多次训练, 其精度变化过程如表 4 所示。可知惩罚因子 C 超过 8 000 时, SVM 模型性能趋于稳定。BP 神经网络性能主要取决于神经网络隐含层结构及大小。表 5 给出了 BP 神经网络在不同网络结构下的性能变化。可知随着隐含层及神经元数目增加, 其精度水平在一定范围内有所提升。

表 4 SVM 性能随惩罚因子变化情况

| 惩罚因子 C | 精度(%) |
|----------|-------|
| 10 | 82.92 |
| 100 | 90.23 |
| 300 | 91.69 |
| 2 000 | 95.33 |
| 4 000 | 96.20 |
| 8 000 | 96.63 |
| 10 000 | 96.63 |
| 12 000 | 96.62 |

对样本集进行 10 次随机划分并采取上述算法

进行试验, 结果如表 6 所示。平均识别时间为 10 次试验单个样本识别耗时均值。SVM 平均识别精度可达 96.6%, BP 神经网络模型精度可达 97.7%, 本文构建的 1-DCNN 模型平均识别精度可达 99.2%。BP 神经网络的识别时间最短, 1-DCNN 模型相较于 BP 神经网络, 模型复杂度更高, 识别耗时更长, 但相较于 SVM, 识别速度更快。

表 5 BP 神经网络性能随网络结构变化情况

| 隐含层网络结构 | 精度(%) |
|------------------|-------|
| (16, 16) | 79.28 |
| (32, 32) | 97.47 |
| (64, 64) | 97.47 |
| (16, 16, 16) | 88.64 |
| (32, 32, 32) | 96.56 |
| (64, 64, 64) | 97.31 |
| (64, 64, 64, 64) | 97.42 |

表 6 常见分类模型对比

| 模型算法 | 平均精度(%) | 平均识别时间/ms |
|-----------------|---------|-----------|
| 支持向量机 SVM | 96.58 | 2.574 |
| BP 神经网络 | 97.69 | 0.014 |
| 一维卷积神经网络 1-DCNN | 99.20 | 0.345 |

3.4 试验验证

对国内某高速铁路列车进行现场试验,使用振动加速度传感器采集轴箱振动信号,如图 11 所示。采用车轮粗糙度测量仪测量列车车轮不圆度,发现车轮主要分为多边形和正常车轮两种状态。利用本文所述轴箱振动信号切割方法结合高斯低通滤波形成实测轴箱振动样本集,正常样本数目为 700,多边形样本数目为 600。将该样本集作为测试样本集对仿真信号所训练模型进行测试,测试精度为 95%。



图 11 轴箱振动信号采集

轴箱仿真信号是通过计算车辆—轨道耦合动力学模型所获得的,难以完全匹配实测车轮状态下的轴箱振动。鉴于此,将实测轴箱振动和仿真轴箱振动样本融合形成新的训练与测试样本集,对 1-DCNN 模型进行进一步训练。利用新测试样本对模型进行测试,测试集平均精度为 99%。基于 T-SNE 进行模型输出可视化,部分结果如图 12 所示。新模型对实测振动和仿真振动都具有较好的识别分类效果。进一步将测试结果采用混淆矩阵进行分析,如图 13 所示。0~4 分别表示正常、多边形、擦伤、局部缺陷、随机非圆 5 种车轮状态。从结果可知,所提方法对 5 种车轮状态中的前 4 类具有较高的识别精度,而随机非圆车轮的识别精度相对较低。基于仿真振动样本训练的识别模型对于实测振动信号具有一定的识别能力。采用实测振动结合仿真振动信号进行训练能够进一步优化识别模型,提升模型工程应用能力。

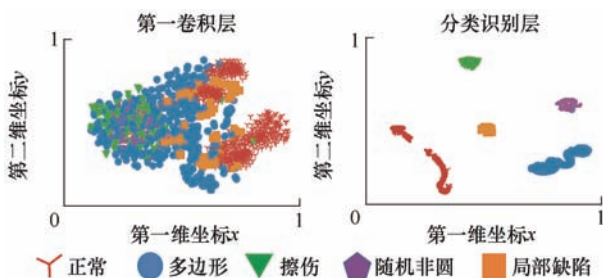


图 12 基于 T-SNE 的数据可视化

| | | | | | |
|-----------|-------|-------|-------|-------|-------|
| 预测类 \ 真实类 | 0 | 1 | 2 | 3 | 4 |
| 0 | 99.49 | 0.43 | 0 | 0 | 0 |
| 1 | 0 | 99.57 | 0 | 1.67 | 0.94 |
| 2 | 0 | 0 | 99.35 | 0 | 0.94 |
| 3 | 0 | 0 | 0 | 98.33 | 3.77 |
| 4 | 0.51 | 0 | 0.65 | 0 | 94.35 |

图 13 车轮状态混淆矩阵

4 结论

针对高速列车车轮失圆识别难以兼顾效率与精度问题,提出一种基于轴箱振动与动力学模型驱动的高速列车车轮失圆状态智能识别方法。结合仿真模拟和实测数据进行分析,得到如下结论。

(1) 本文提出的方法不依赖人工选取的先验性经验对时域信号进行特征处理,采取 1-DCNN 进行故障特征自动提取,实现正常、车轮多边形、车轮擦伤、随机非圆化与局部缺陷等 5 类车轮状态识别。

(2) 基于动力学模型获取的轴箱振动样本集结合 1-DCNN 进行训练,所获模型识别精度较高,10 次试验识别精度都可达 99%,且单个样本识别时间不超过 0.4 ms。与支持向量机算法及 BP 神经网络进行对比研究表明,1-DCNN 模型识别准确性更高。

(3) 仿真振动样本训练获得的模型对实测振动具有一定识别能力,采取实测轴箱振动样本对模型进行测试,测试精度为 95%。采用实测振动结合仿真振动信号进行训练能够进一步优化识别模型,提升模型工程应用能力。

本文提出的车轮失圆状态智能识别方法在仿真数据集上具有良好的表现性能,对实测振动数据集也具有一定识别能力,后续可考虑联合实测与仿真数据并结合数据增强方法或迁移学习方法,进一步探究实测轴箱振动数据下的车轮失圆状态识别分类以及车轮失圆程度的定量识别。

参 考 文 献

- [1] 金学松,吴越,梁树林,等. 高速列车车轮多边形磨耗、机理、影响和对策分析[J]. 机械工程学报,2020,56(16): 118-136.
- JIN Xuesong, WU Yue, LIANG Shulin, et al.

- Characteristics , mechanism , influences and countermeasures of polygonal wear of high-speed train wheels[J]. Journal of Mechanical Engineering, 2020, 56(16): 118-136.
- [2] 李景泉, 刘继. 车轮踏面擦伤自动检测方法的研究和试验[J]. 同济大学学报, 2003, 31(4): 473-476.
LI Jingquan, LIU Ji. Research and experiment of the method for checking and measuring tread flats of wheels automatically[J]. Journal of Tongji University, 2003, 31(4): 473-476.
- [3] 杨雪荣, 张湘伟, 成思源, 等. 基于物理模型的计算机视觉轮对踏面擦伤检测方法[J]. 机械工程学报, 2009, 45(5): 214-219.
YANG Xuerong, ZHANG Xiangwei, CHENG Siyuan, et al. Method of physical-based computer vision detection for tread surface flats of wheelsets[J]. Journal of Mechanical Engineering, 2009, 45(5): 214-219.
- [4] 江航, 尚春阳, 高瑞鹏. 基于 EMD 和神经网络的轮轨故障噪声诊断识别方法研究[J]. 振动与冲击, 2014, 33(17): 34-38.
JIANG Hang, SHANG Chunyang, GAO Ruipeng. Wheel/rail fault noise diagnosis method based on EMD and neural network[J]. Journal of Vibration and Shock, 2014, 33(17): 34-38.
- [5] 赵蓉, 史红梅. 基于高阶谱特征提取的高速列车车轮擦伤识别算法研究[J]. 机械工程学报, 2017, 53(6): 102-109.
ZHAO Rong, SHI Hongmei. Research on wheel-flat recognition algorithm for high-speed train based on high-order spectrum feature extraction[J]. Journal of Mechanical Engineering, 2017, 53(6): 102-109.
- [6] 李旭伟, 曾宇清, 李甫永, 等. 轮轨垂向力地面连续测量的复合测区方法[J]. 中国铁道科学, 2019, 40(5): 87-94.
LI Xuwei, ZENG Yuqing, LI Fuyong, et al. Compound measuring zone method for continuous measurement of wheel/rail vertical force on ground[J]. China Railway Science, 2019, 40(5): 87-94.
- [7] 李奕璠, 刘建新, 李忠继. 基于 Hilbert-Huang 变换的列车车轮失圆故障诊断[J]. 振动、测试与诊断, 2016, 36(4): 734-739.
LI Yifan, LIU Jianxin, LI Zhongji. The fault diagnosis method of railway out-of-round wheels using Hilbert-Huang transform[J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(4): 734-739.
- [8] 宋颖, 梁磊, 王玥, 等. 基于改进 EEMD 和 WVD 联合时频分析的车轮多边形状态识别方法[J]. 交通运输工程学报, 2021, 21(6): 259-268.
SONG Ying, LIANG Lei, WANG Yue, et al. Wheel polygon state recognition method based on improved EEMD-WVD joint time-frequency analysis[J]. Journal of Traffic and Transportation Engineering, 2021, 21(6): 259-268.
- [9] SUN Qi, CHEN Chunjun, KEMP A H, et al. An on-board detection framework for polygon wear of railway wheel based on vibration acceleration of axle-box[J]. Mechanical Systems and Signal Processing, 2021, 153: 107540.
- [10] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: A survey[J]. Mechanical Systems and Signal Processing, 2021, 151: 107398.
- [11] CHEN Jungan, JIANG Jean, GUO Xinnian, et al. A self-adaptive CNN with PSO for bearing fault diagnosis[J]. Systems Science & Control Engineering, 2021, 9(1): 11-22.
- [12] SHI Dachuan, YE Yungang, GILLWALD M, et al. Designing a lightweight 1D convolutional neural network with Bayesian optimization for wheel flat detection using carbody accelerations[J]. International Journal of Rail Transportation, 2021, 9(4): 311-341.
- [13] 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, 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, 2021, 52(4): 1371-1379.
- [14] YUAN Zhandong, ZHU Shengyang, YUAN Xuancheng, et al. Vibration-based damage detection of rail fastener clip using convolutional neural network: Experiment and simulation[J]. Engineering Failure Analysis, 2021, 119: 104906.
- [15] 向家伟. 数值模型驱动的传动系统故障个性化诊断原理[J]. 机械工程学报, 2021, 57(15): 116-128.
XIANG Jiawei. Numerical model driving personalized diagnosis principle for fault detection in mechanical transmission systems[J]. Journal of Mechanical Engineering, 2021, 57(15): 116-128.
- [16] 向家伟. 机械故障数值模拟驱动的生成式对抗网络及智能诊断原理[J]. 中国科学: 技术科学, 2021, 51(3): 341-355.

- XIANG Jiawei. Numerical simulation driving generative adversarial networks in association with the artificial intelligence diagnostic principle to detect mechanical faults[J]. *Scientia Sinica Technologica*, 2021, 51(3): 341-355.
- [17] 管涛, 王辉, 刘智豪, 等. 基于多输入层卷积神经网络的滚动轴承故障诊断模型[J]. *振动与冲击*, 2020, 39(12): 142-149.
- ZAN Tao, WANG Hui, LIU Zhihao, et al. A fault diagnosis model for rolling bearings based on a multi-input layer convolutional neural network[J]. *Journal of Vibration and Shock*, 2020, 39(12): 142-149.
- [18] 陶功权, 温泽峰, 金学松. 铁道车辆车轮非圆化磨耗形成机理及控制措施研究进展[J]. *机械工程学报*, 2021, 57(6): 106-120.
- TAO Gongquan, WEN Zefeng, JIN Xuesong. Advances in formation mechanism and mitigation measures of out-of-round railway vehicle wheels[J]. *Journal of Mechanical Engineering*, 2021, 57(6): 106-120.
- [19] 王鹏, 陶功权, 杨晓璇, 等. 中国高速列车车轮多边形磨耗特征分析[J/OL]. *西南交通大学学报*, 2021: 1-9[2022-10-09]. <http://kns.cnki.net/kcms/detail/51.1277.U.20211124.1532.002.html>.
- WANG Peng, TAO Gongquan, YANG Xiaoxuan, et al. Analysis of polygonal wear characteristics of Chinese high-speed train wheels[J/OL]. *Journal of Southwest Jiaotong University*, 2021: 1-9[2022-10-09]. <http://kns.cnki.net/kcms/detail/51.1277.U.20211124.1532.002.html>.
- [20] 陶功权, 谢清林, 刘晓龙, 等. 形态学滤波方法在车轮非圆化信号降噪中的应用[J]. *机械工程学报*, 2020, 56(18): 116-122.
- TAO Gongquan, XIE Qinglin, LIU Xiaolong, et al. Application of morphology filtering method in the de-noising of wheel out-of-roundness signals[J]. *Journal of Mechanical Engineering*, 2020, 56(18): 116-122.
- [21] 谢清林. 基于数据与模型双重驱动的地铁钢轨波浪形磨耗识别方法初探[D]. 成都: 西南交通大学, 2021.
- XIE Qinglin. A preliminary study on wave corrugation detection method of metro lines based on data-model dual drive[D]. Chengdu: Southwest Jiaotong University, 2021.
- [22] 翟婉明. 车辆—轨道耦合动力学[M]. 4 版. 北京: 科学出版社, 2015.
- ZHAI Wanming. Vehicle-track coupling dynamics[M]. Fourth ed. Beijing: Science Press, 2015.
- [23] 吴越, 韩健, 左齐宇, 等. 钢轨波磨对高速列车车轮多边形磨耗产生与发展的影响[J]. *机械工程学报*, 2020, 56(17): 198-208.
- WU Yue, HAN Jian, ZUO Qiyu, et al. Effect of rail corrugation on initiation and development of polygonal wear on high-speed train wheels[J]. *Journal of Mechanical Engineering*, 2020, 56(17): 198-208.
- [24] ZHONG Shuoqiao, XIONG Jiayang, XIAO Xinbiao, et al. Effect of the first two wheelset bending modes on wheel-rail contact behavior[J]. *Journal of Zhejiang University-SCIENCE A*, 2014, 15(12): 984-1001.
- [25] XIAO Xinbiao, LING Liang, JIN Xuesong. A study of the derailment mechanism of a high speed train due to an earthquake[J]. *Vehicle System Dynamics*, 2012, 50(3): 449-470.
- [26] HAN Jian, ZHONG Shuoqiao, XIAO Xinbiao, et al. High-speed wheel/rail contact determining method with rotating flexible wheelset and validation under wheel polygon excitation[J]. *Vehicle System Dynamics*, 2018, 56(8): 1233-1249.
- [27] 张伟. 基于卷积神经网络的轴承故障诊断算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
- ZHANG Wei. Study on bearing fault diagnosis algorithm based on convolutional neural network[D]. Harbin: Harbin Institute of Technology, 2017.
- [28] MAATEN V D, LAURENS. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9(11): 2579-2625.

作者简介: 邓磊鑫, 男, 2000 年出生。主要研究方向为车轮失圆状态检测。

E-mail: dlx998226@outlook.com

温泽峰(通信作者), 男, 1976 年出生, 博士, 研究员, 博士研究生导师。主要研究方向为轮轨关系及减振降噪。

E-mail: zfwen@swjtu.edu.cn