

# 基于智能图像识别的轨道交通钢轨焊接接头识别<sup>\*</sup>

吴泽宇<sup>1</sup> 王文斌<sup>2</sup> 魏志恒<sup>2</sup> 朱彬<sup>2</sup> 李明航<sup>2</sup>

(1. 中国铁道科学研究院, 100081, 北京; 2. 中国铁道科学研究院集团有限公司城市轨道交通中心, 100081, 北京//第一作者, 硕士研究生)

**摘要 目的:**轨道交通钢轨焊接接头作为钢轨上最为薄弱的结构, 易发展为钢轨焊接接头不平顺, 从而加剧轮轨间作用力, 影响乘客乘坐舒适性, 因此有必要对钢轨焊接接头进行识别。**方法:**介绍了钢轨焊接接头识别中所采用的 AlexNet CNN(卷积神经网络)模型和小波变换的原理, 以及轨道冲击指数的计算方法。提取北京地铁 19 号线某运营列车的轴箱振动加速度信号, 通过小波变换提取其时域及频域特征, 并采用 AlexNet CNN 进行钢轨焊接接头的识别。对其钢轨表面不平顺进行检测, 计算其滑动峰峰平均值, 并与同一里程处根据列车轴箱振动加速度计算得到的轨道冲击指数进行对比, 采用线性拟合的方式分析钢轨焊接接头对轨道冲击指数的影响。**结果及结论:**钢轨焊接接头在列车轴箱振动加速度信号中存在较为明显的空间域分布特征与时频特征: 空间域分布特征表现在每两个钢轨焊接接头信号之间的间距为 25 m, 且每个信号由间距为 2.2 m 的两个尖峰所构成; 时频特征表现为钢轨焊接接头所在里程附近有一明一暗两个亮点。这种清晰的特征使 AlexNet CNN 高效地对钢轨焊接接头进行识别, 准确率在 92.98% 左右。对钢轨表面不平顺实测值进行 30~100 mm 带通滤波后可发现与钢轨焊接接头空间分布特征相一致的特征峰值, 且轨道冲击指数与钢轨焊接接头对应的钢轨表面不平顺滑动峰峰平均值的峰值具有相似的空间分布特征; 钢轨焊接接头处的轨道冲击指数随钢轨焊接接头不平顺的滑动峰峰平均值增大呈现先减小后增大的趋势, 二者并非简单的正相关关系。

**关键词** 城市轨道交通; 钢轨; 焊接接头识别; 智能图像识别

**中图分类号** U213.4<sup>+</sup>6

**DOI:**10.16037/j.1007-869x.2023.10.003

## Identification of Rail Transit Rail Weld Joints Based on Intelligent Image Recognition

WU Zeyu, WANG Wenbin, WEI Zhiheng, ZHU Bin, LI Minghang

**Abstract Objective:** RWJ (rail weld joints) in rail transit

systems are the weakest structural points on rails, which are prone to develop into RWJ irregularities, exacerbating wheel-rail interaction forces and affecting passenger comfort. Therefore, it is necessary to conduct identification of RWJ. **Method:** The principles of the AlexNet CNN (convolutional neural network) model and wavelet transform used in the identification of RWJ are introduced, along with the calculation method of rail impact index. The axle box vibration acceleration signals of a train operating on Beijing Subway Line 19 are extracted, then time-domain and frequency-domain features are extracted through wavelet transform, and RWJ are identified using AlexNet CNN. The rail surface irregularities are detected, its sliding peak-to-peak average value is calculated, and it is compared with the rail impact index obtained from the train axle box vibration acceleration at the same mileage. The impact of RWJ on the rail impact index is analyzed using linear fitting. **Result & Conclusion:** RWJ exhibit distinct spatial domain distribution and time-frequency features in the train axle box vibration acceleration signals: the spatial domain distribution is characterized by a spacing of 25 meters between consecutive rail weld joint signals, each signal is composed of two peaks with a spacing of 2.2 meters. The time-frequency features manifest as two bright spots near the mileage of the RWJ, one brighter and one dimmer. These clear features enable efficient identification of rail weld joints using AlexNet CNN, achieving an accuracy of around 92.98%. After applying 30-100 mm band-pass filtering to the measured rail surface irregularities, it is observed that characteristic peaks are consistent with the spatial distribution features of all RWJ, and the rail impact index and the sliding peak-to-peak average value of rail surface irregularities at corresponding RWJ share similar spatial distribution features. The rail impact index at RWJ exhibits a trend of decreasing followed by increasing as the sliding peak-to-peak average value of RWJ irregularities increase, indicating

\* 北京市自然科学基金-丰台轨道交通前沿研究联合基金项目(L221001); 中国铁道科学研究院集团有限公司科研开发基金项目(2022YJ235); 铁科院(北京)工程咨询有限公司科研开发基金项目(2021ZXJ003)

a complex relationship between the two factors rather than simple positive correlation.

**Key words** urban rail transit; rail; weld joint identification; smart image identification

**First-author's address** China Academy of Railway Sciences, 100081, Beijing, China

钢轨焊接接头作为钢轨上较为常见的轨道薄弱结构,易形成轨道几何上的不平顺,导致列车通过时会产生较大的瞬时冲击,对列车运行的舒适性造成影响,严重时可使得轨道结构发生破坏,导致列车无法安全通过,因此需亟待解决。

基于神经网络的图像识别技术能够提取不同图像的特征信息,从而实现对图像的区分及识别。文献[1]提出了 AlexNet 网络结构模型,并以其优异的图像识别能力赢得了当年的 ILSVRC (ImageNet 大规模视觉识别挑战赛) 冠军,自此 CNN(卷积神经网络)成为了图像识别的核心算法模型。该算法将时频分析技术与图像识别技术相结合,实现对信号的有效分类。文献[2]采用 Gramian 角场和 Markov 转移场将时间序列信号编码为图像,通过平铺 CNN 模型对时间序列图像进行分类;文献[3-4]通过使用递归图将时间序列转换为二维纹理图像,并分别采用支持向量机和深度神经卷积网络对其进行分类。文献[5]通过采集运营列车的轴箱以及车体其他部件的加速度实现对钢轨的动态检测;文献[6-7]从能量角度分析了车辆轴箱振动加速度信号,通过对加速度信号有效值的量纲一化处理获得轨道

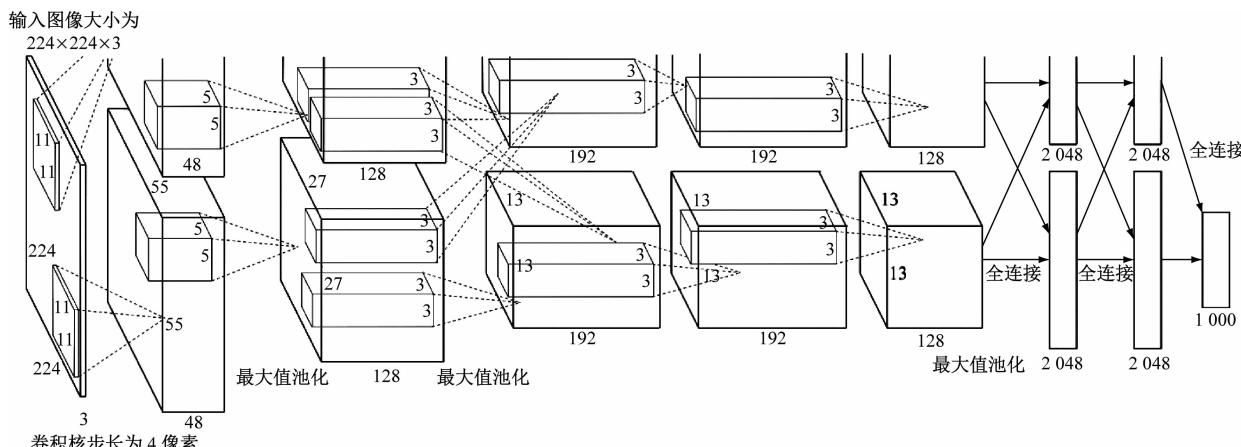
冲击指数,以对轨道短波不平顺进行描述。本文以北京地铁 19 号线实测数据为基础,采用小波变换提取钢轨焊接接头的时频信息,并应用 AlexNet CNN 技术对时频信息进行区分,以实现对钢轨焊接接头的识别;通过计算轨道冲击指数与钢轨表面不平顺的滑动峰峰平均值,评价钢轨焊接接头对车辆动力学的影响。

## 1 轨道交通钢轨焊接接头识别方法原理

### 1.1 AlexNet CNN 模型

CNN 的工作原理受哺乳动物视觉过程的启发而来,是一种前馈形神经网络,在图像识别、视频分析、声音识别、自然语言处理等领域取得了巨大的突破。CNN 通常由 5 层构成,分别是输入层、卷积层、激活层、池化层及全连接层。其中:输入层负责数据的预处理操作;卷积层通过卷积提取图像特征,并降低噪声;激活层对卷积层的输出结果进行非线性映射,避免每层的输出仅是输入的线性组合;池化层又称下采样层,即在保留有效信息的前提下,减少数据量和计算量,并加强图像特征的不变性;全连接层通常位于数个卷积层/采样层的组合之后,在整个 CNN 架构的末端位置,也称稠密层,其作用相当于一个普通的分类器。

AlexNet 作为一种经典的早期 CNN 模型,由 Alex Krizhevsky 设计<sup>[1]</sup>,包括:输入层 1 个,卷积层 5 个,全连接层 3 个。其中,对全连接层进行了最大池化。AlexNet CNN 结构模型<sup>[1]</sup>如图 1 所示。



注:图中长方体侧边的数字为各卷积层与池化层中的卷积核与池化核尺寸及通道数。如:224×224×3 中,224×224 表示图像的宽度和高度,单位为像素;3 表示图像的通道数。

图 1 AlexNet CNN 结构模型

Fig. 1 Structure model of AlexNet

## 1.2 小波变换

为获得一组信号的频率成分,通常采用傅里叶变换将信号从时间域转换到频率域,但傅里叶变换只能获取一段信号总体上频率成分的组成,以及缺失的各频率成分出现的时间信息;此外傅里叶变换只适用于确定性的平稳信号<sup>[8]</sup>,即仅对信号中突变易解释成一系列低成分的高频信号叠加。为避免此种问题的出现,通常对给定的时间序列信号 $x(t)$ ,采用时频分析方法提取信号的频率信息。常用的时频分析方法包括短时傅里叶变换、小波变换、Wigner-Ville 分布等。其中小波变换已成为目前处理非平稳信号最重要的手段之一。

定义 1 个平方可积的小波母函数 $\psi(t)$ ,对其作平移和伸缩变换,得到小波基函数 $\psi_{a,b}(t)$ :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right) \quad (1)$$

式中:

$t$ —时间;

$a$ —伸缩因子;

$b$ —平移因子。

式(1)中,若 $a,b$ 不断变换,可得到一族小波基函数 $\psi_{a,b}(t)$ 。对于给定的二次可积信号 $x(t)$ ,有连续小波变换:

$$w_x(a,b) = \frac{1}{\sqrt{a}} \int x(t)\psi^*\left(\frac{t-b}{a}\right)dt \quad (2)$$

实际信号处理过程中,往往需要将尺度和位移离散,采用离散小波变换进行时频分析,通常采用二进离散小波变换。对于给定的信号 $x(n)$ ,令: $a=2^j, b=2^j k, j \in \mathbf{Z}, k \in \mathbf{Z}$ ,则离散小波变换 $w_x(2^j, 2^j k)$ 为:

$$w_x(2^j, 2^j k) = \frac{1}{\sqrt{2^j}} \sum_n \psi^*\left(\frac{n}{2^j} - k\right) x(n) \quad (3)$$

## 1.3 轨道冲击指数计算方法

提取运营列车的振动加速度信号,并采用惯性基准法对轨道状态进行检测的方法早已被广泛接受并验证<sup>[5,9]</sup>。车辆轴箱振动加速度是轮轨耦合作用的结果,基于轴箱振动加速度的轨道不平顺检测往往受多种因素的影响。文献[10]证明了车轮不圆顺对基于惯性基准法测得的轨道不平顺数据在频域方面影响较大,此外,车轮踏面、钢轨材料、车辆悬挂参数及钢轨廓形等因素均可能对不平顺检测结果造成影响。文献[6]从能量的角度描述轮轨冲击引起的轴箱振动加速度的高频特性,提出采用

轨道冲击指数描述轨道短波不平顺状态。

对于给定的滤波后加速度信号集合 $\{x_i | i = 1, 2, \dots, N\}$ ( $N$ 为加速度信号波形点数),计算其有效值,得到集合 $\{S_r | r = 1, 2, \dots, N - K + 1\}$ 。其中, $K$ 为计算窗长, $S_r$ 为:

$$S_r = \sqrt{\sum_{i=r}^{r+K-1} x_i^2 / K} \quad (4)$$

计算全部加速度有效值的平均值 $\bar{S}$ ,得到轨道冲击指数 $T_{II}$ :

$$T_{II} = S_r / \bar{S} \quad (5)$$

## 2 轨道交通钢轨焊接接头识别分析

### 2.1 钢轨焊接接头样本挑选及时频图构建

提取北京地铁 19 号线某运营列车的轴箱振动加速度信号,如图 2 所示。

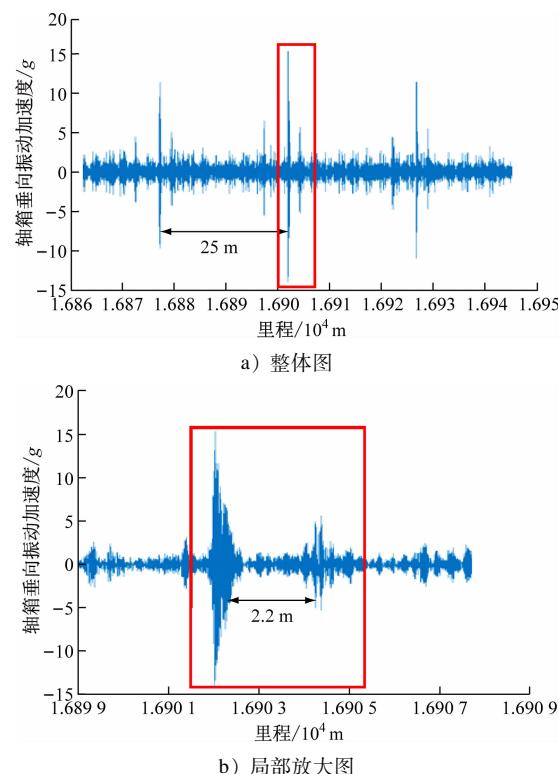


图 2 列车轴箱垂向振动加速度-运营里程关系曲线

Fig. 2 Relation curve of train axle box vertical vibration acceleration and operation mileage

显然,钢轨焊接接头对应的轴箱垂向振动加速度信号在时域上有两个较为明显的特征:①两个冲击信号相隔 25 m,为单根钢轨长度;②钢轨焊接接头会造成一大一小两个冲击,冲击相隔 2.2 m,为转向架轴距,其中,大冲击为钢轨焊接接头对传感器所在轮对的冲击,小冲击为后一轮对在经过钢轨焊

接接头时对前一轮对传感器所造成的冲击。对不同运营里程处的钢轨焊接接头加速度信号进行小波变换,得到如图 3 a) 所示的加速度信号时频图。与图 3 b) 所示的非钢轨焊接接头时频图相比,图 3 a) 所示的加速度信号时频图中钢轨焊接接头信号在时频域上为明显的两点式特征,两点呈现出一明一暗;查看不同程度的钢轨焊接接头信号,发现其频率分布范围基本一致。由此为 AlexNet CNN 模型识别钢轨焊接接头提供了条件。

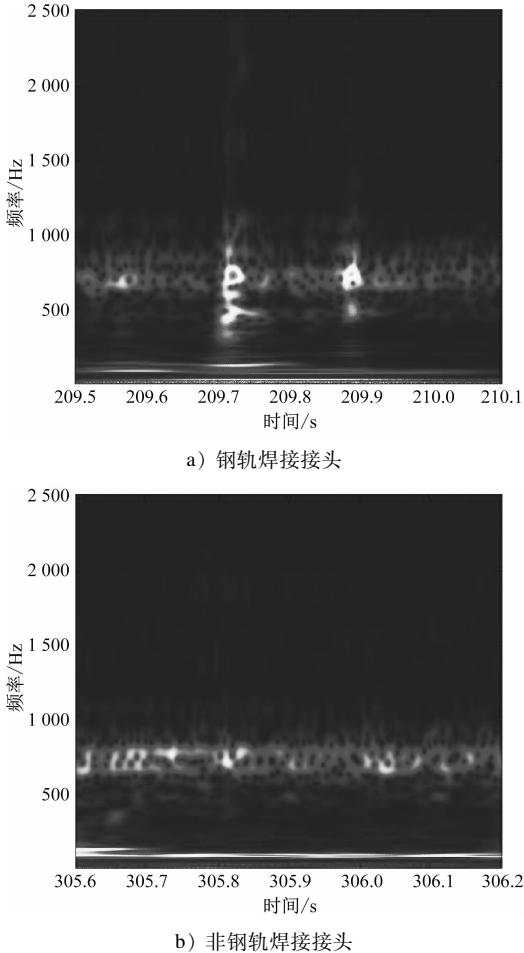


图 3 钢轨焊接接头与非焊接接头信号时频图

Fig. 3 Signal time-frequency diagram of rail weld joints and non-weld joints

## 2.2 钢轨焊接接头识别

挑选 200 组钢轨焊接接头及非焊接接头时频图作为训练样本,通过人工打标签。采用已经预训练的 AlexNet 模型,修改输出参数设置。上述 200 组样本中,70% 用于训练,30% 用于校正。对 AlexNet 模型重新训练,得到一个能够识别轨道短波病害作用下的轴箱振动信号新模型。AlexNet 模型训练的

准确率与损失随迭代次数变化曲线如图 4 所示。由图 4 可见,最终模型的验证准确度达到了 92.98%。

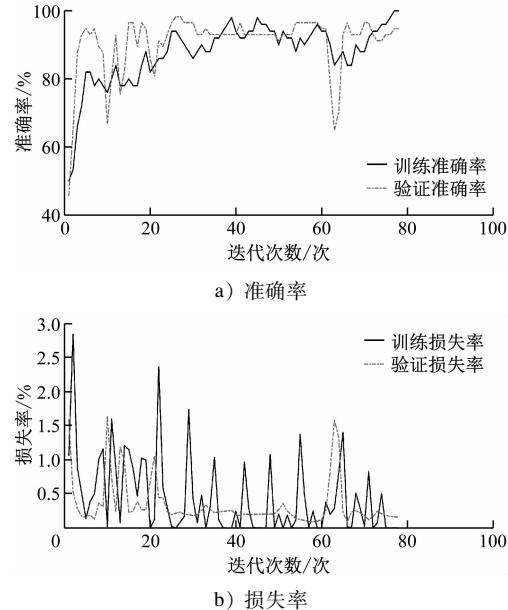


图 4 AlexNet 模型训练的准确率与损失率随迭代次数变化曲线

Fig. 4 Change curves of accuracy and loss rates with iteration times during AlexNet model training

针对已训练好的模型,另选取 100 组钢轨焊接接头和非钢轨焊接接头数据,获取其时频图并对其进行识别,共重复 3 次,其识别准确率与验证准确度相一致。

## 3 钢轨焊接接头不平顺幅值变化对其表面不平顺的影响

使用波磨小车对北京地铁 19 号线某上行普通轨道区段钢轨表面不平顺进行检测,共得到两段钢轨表面不平顺实测波形,如图 5 所示。

为去除图 5 实测结果中钢轨焊接接头不平顺幅值中较大的脉冲,对钢轨表面不平顺波形进行多次不同带宽的带通滤波。对比滤波结果可发现,30~100 mm 的带通滤波结果(见图 6)会出现分布较为均匀的钢轨表面不平顺滑动峰峰平均值峰值,且每个峰值的间距约为 25 m。钢轨焊接接头长度通常不超过 11 mm,且每两个焊接接头之间的距离通常固定为 25 m,其里程特征与带通滤波后的钢轨表面不平顺的滑动峰峰平均值峰值分布特征相似。此外,由于焊接技术的不稳定、焊接材料存在缺陷等众多因素的影响,钢轨焊接接头所在里程处存在较大的不平顺,这也与图 6 中分布较为均匀的滑动峰

峰平均值峰值远大于相邻区域内其他里程处滑动峰峰平均值的特征相符。因此,可认为图6中较为均匀分布的钢轨表面不平顺滑动峰峰平均值峰值为钢轨焊接接头所对应的滑动峰峰平均值。

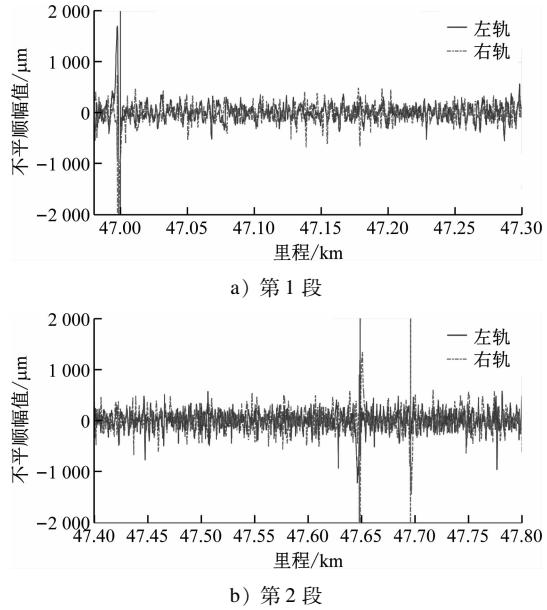


图5 钢轨表面不平顺-运营里程关系曲线

Fig. 5 Relation curve of rail surface irregularities and operation mileage

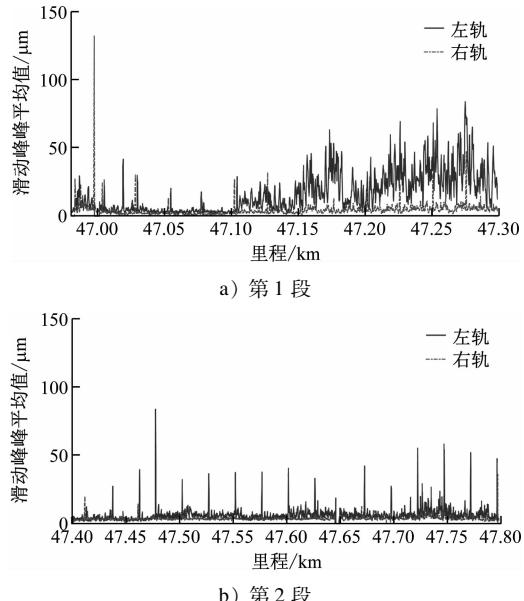


图6 钢轨表面不平顺滑动峰峰平均值-运营里程关系曲线

Fig. 6 Relation curve of sliding peak-to-peak average value of rail surface irregularities and operation mileage

提取运营列车轴箱垂向振动加速度,根据式(4)及式(5)计算轨道冲击指数,得到如图7所示的计算结果。由图7可以看出,轨道冲击指数与经30~

100 mm 滤波的实测钢轨表面不平顺滑动峰峰平均值的波形存在一定程度的相似性。此外,轨道冲击指数具有与钢轨表面不平顺滑动峰峰平均值相似分布特征的峰值,在运营里程上与钢轨焊接接头相对应,说明列车在通过钢轨焊接接头时轴箱产生了较大的垂向振动加速度,进而导致轨道冲击指数的计算值出现了明显的尖峰。

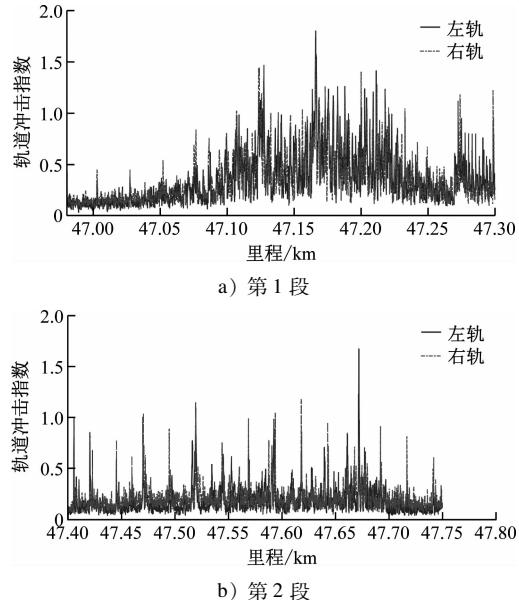


图7 轨道冲击指数-运营里程关系曲线

Fig. 7 Relation curve of track impact index and operation mileage

统计每处钢轨焊接接头对应的钢轨表面不平顺滑动峰峰平均值与轨道冲击指数,以钢轨表面不平顺滑动峰峰平均值为自变量,轨道冲击指数为因变量,剔除部分异常散点并拟合曲线,结果如图8所示,其中黑色散点表示不同滑动峰峰平均值下的轨道冲击指数。由图8可见:轨道冲击指数随钢轨表面不平顺滑动峰峰平均值增长呈先减小后增大的趋势;当钢轨表面不平顺滑动峰峰平均值大于20

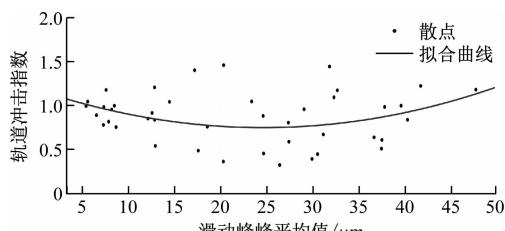


图8 轨道冲击指数-钢轨表面不平顺滑动峰峰平均值拟合曲线

Fig. 8 Fitting curve of track impact index and sliding peak-to-peak average value of rail surface irregularities

$\mu\text{m}$  时, 轨道冲击指数随其增大而缓慢增长, 这说明钢轨焊接接头一定程度上会对基于轨道冲击指数的不平顺检测方法产生影响, 但二者之间并不呈正相关关系。

## 4 结语

1) 钢轨焊接接头在列车轴箱振动加速度信号中存在较为明显的空间域分布特征与时频特征。其中: 空间域分布特征表现在每两个钢轨焊接接头信号之间的间距为 25 m, 且每个信号由间距为 2.2 m 的两个尖峰所构成; 时频特征表现为钢轨焊接接头所在里程附近有一明一暗两个亮点。上述特征清晰明了, 使 AlexNet CNN 能很好地从大量的轴箱振动加速度信号中拾取钢轨焊接接头所在里程, 本文 AlexNet 模型的识别准确率约为 92.98%。

2) 钢轨焊接接头不平顺滑动峰峰平均值对基于轨道冲击指数的短波不平顺检测结果有一定的影响, 钢轨焊接接头处的轨道冲击指数通常随钢轨表面不平顺滑动峰峰平均值的增大而呈现一种先减小而后缓慢增大的趋势, 并不具有正相关性。

## 参考文献

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84.
- [2] WANG Z, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks [C] // Workshops at the 29th AAAI conference on Artificial Intelligence. Menlo Park: AAAI, 2015: 10.
- [3] SOUZA V M A, SILVA D F, BATISTA G E. Extracting texture features for time series classification [C] // 2014 22nd International Conference on Pattern Recognition. Stockholm: IEEE, 2014: 1425.
- [4] HATAMI N, GAVET Y, DEBAYLE J. Classification of time-series images using deep convolutional neural networks [C] // 10th International Conference on Machine Vision (ICMV 2017). Vienna: SPIE (The International Society for Optics and Photon-
- [5] GRASSIE S L. Measurement of railhead longitudinal profiles: a comparison of different techniques [J]. Wear, 1996, 191(1/2): 245.
- [6] 刘金朝, 陈东生, 赵钢, 等. 评判高铁轨道短波不平顺病害的轨道冲击指数法 [J]. 中国铁道科学, 2016, 37(4): 34. LIU Jinzhao, CHEN Dongsheng, ZHAO Gang, et al. Track impact index method for evaluating track short wave irregularity of high-speed railway [J]. China Railway Science, 2016, 37(4): 34.
- [7] 牛留斌, 刘金朝, 孙善超, 等. 钢轨波磨指数与轨道短波不平顺关系研究 [J]. 中国铁道科学, 2020, 41(5): 46. NIU Liubin, LIU Jinzhao, SUN Shanchao, et al. Relationship between rail corrugation index and track short wave irregularity [J]. China Railway Science, 2020, 41(5): 46.
- [8] 刘秀波, 吴卫新. 钢轨焊接接头短波不平顺功率谱分析 [J]. 中国铁道科学, 2000, 21(2): 26. LIU Xiubo, WU Weixin. PSD analysis of shortwave irregularity on welded joints [J]. China Railway Science, 2000, 21(2): 26.
- [9] SUNAGA Y, IDE T, KANAO M. A practical use of axlebox acceleration to control the short-wave track irregularities on Shinkansen [J]. RTRI (Railway Technical Research Institute) Report, 1995, 9(2): 35.
- [10] 王平, 汪鑫, 王源, 等. 基于高铁轨道不平顺的车轮不圆顺识别模型 [J]. 西南交通大学学报, 2020, 55(4): 681. WANG Ping, WANG Xin, WANG Yuan, et al. Polygonal wheel detection model based on track irregularity of high-speed railways [J]. Journal of Southwest Jiaotong University, 2020, 55(4): 681.
- [11] 廖进, 吴松荣, 刘东, 等. 车载式地铁轨道缺陷巡检系统设计 [J]. 现代城市轨道交通, 2020(4): 11. LIAO Jin, WU Songrong, LIU Dong, et al. Design of on-board inspection system for subway track defects [J]. Modern Urban Transit, 2020(4): 11.
- [12] 张祯祥. 基于图像特征的高速铁路轨道焊缝缺陷检测 [J]. 现代城市轨道交通, 2023(7): 27. ZHANG Zhenxiang. High-speed railway track weld defect detection based on image features [J]. Modern Urban Transit, 2023(7): 27.

(收稿日期:2023-03-01)

欢迎访问《城市轨道交通研究》网站

www.umt1998.tongji.edu.cn