

文章编号:1005-0523(2025)03-0096-12



基于1DResAE网络模型的车轮多边形检测研究

林凤涛^{1,2,3},倪鹏辉^{2,3},杜磊⁴,杨洋^{2,3},杨世德^{2,3},胡伟豪^{2,3,4},谭荣凯^{2,3}

(1. 华东交通大学轨道交通基础设施性能监测与保障国家重点实验室,江西 南昌 330013;

2. 华东交通大学轨道车辆智能运维技术与装备江西省重点实验室,江西 南昌 330013;

3. 华东交通大学机车车辆智能运维铁路行业重点实验室,江西 南昌 330013;4. 中铁物总运维科技有限公司,北京 100071)

摘要:深度学习在振动信号识别中具有准确率高、精确率高的优势,但是车轮多边形标签数据难以大量获取,无法满足常规神经网络模型的训练需求。现有解决少样本问题的方法是将时域数据转化为频域数据,然而这种方法在时频域转换时会致使部分数据特征丢失。针对此问题,提出一种基于1DResAE网络模型的车轮多边形检测方法。该模型可在不进行振动信号时频域转换的情况下,通过对时域信号的无监督学习、特征提取和监督学习完成对列车车轮多边形的检测。通过融合一维卷积、残差网络和自编码器,形成了可提取和学习复杂的一维振动信号特征的一维深度神经网络;根据自编码器中编码器所提取和学习的特征,分类器利用少量标签数据进行监督学习,完成列车车轮多边形的模式识别。通过小比例轮轨对滚实验台采集的数据进行实验验证表明:该方法的检测精确率为98.971%,误差小且分类效果突出。对于车轮多边形检测任务,1DResAE能够有效检测出车轮多边形的阶数,具有一定的实用性。

关键词:车轮多边形;深度学习;故障检测;残差网络;自编码器

中图分类号:U269

文献标志码:A

本文引用格式:林凤涛,倪鹏辉,杜磊,等. 基于1DResAE方法的车轮多边形检测研究[J]. 华东交通大学学报,2025,42(3):96-107.

Research on Wheel Polygon Detection Based on 1DResAE Network Model

Lin Fengtao^{1,2,3}, Ni Penghui^{2,3}, Du Lei⁴, Yang Yang^{2,3}, Yang Shide^{2,3}, Hu Weihao^{2,3,4}, Tan Rongkai^{2,3}

(1. State Key Laboratory of Performance Monitoring and Protecting of Rail Transit Infrastructure, East China Jiaotong University, Nanchang 330013, China; 2. Jiangxi Provincial Key Laboratory of Intelligent Operation and Maintenance Technology and Equipment for Rail Vehicles, East China Jiaotong University, Nanchang 330013, China; 3. Key Laboratory of Railway Industry of Intelligent Operation and Maintenance for locomotive Vehicle, East China Jiaotong University, Nanchang 330013, China; 4. China Railway Total Transportation and Maintenance Technology Co., Ltd., Beijing 10071, China)

Abstract: Deep learning technology offers advantages in vibration signal recognition with high accuracy and precision. However, acquiring a large number of labeled data for polygonal wheel detection is challenging, which fails to meet the training requirements of conventional neural network models. Existing methods to address the issue of small sample sizes often convert time-domain data into frequency-domain data, but this can re-

收稿日期:2024-02-28

基金项目:国家自然科学基金项目(52065021);江西省“双千计划”科技创新领军人才项目(S2021GDKX1442);江西省教育厅科学技术研究项目(GJJ210641);华东交通大学载运工具与装备教育部重点实验室自主课题(KLCEZ2022-10);中国国家铁路集团有限公司科技开发重点项目(N2023G021)

sult in the loss of certain data features during the time-frequency conversion. To address this issue, a polygonal wheel detection method based on the 1DResAE deep neural network model is proposed. This model completes the detection of polygonal train wheels by unsupervised learning, feature extraction, and supervised learning of time-domain signals without the need for time-frequency conversion of vibration signals. By integrating one-dimensional convolution, residual networks, and autoencoders, a one-dimensional deep neural network is formed, capable of extracting and learning complex one-dimensional vibration signal features. Based on the features extracted and learned by the encoder in the autoencoder, the classifier performs supervised learning with a small amount of labeled data to achieve pattern recognition of polygonal train wheels. Experimental verification using data collected from a small-scale wheel-rail rolling test bench demonstrated that the detection accuracy of this method is 98.971%, with low error and outstanding classification performance. For the task of polygonal wheel detection, the 1DResAE model effectively detects the polygonal order of wheels and has practical applicability.

Key words: wheel polygon; deep learning; fault detection; residual network; autoencoder

Citation format: LIN F T, NI P H, DU L, et al. Research on wheel polygon detection based on 1DResAE network model[J]. Journal of East China Jiaotong University, 2025, 42(3): 96–107.

随着我国铁路运营里程不断增加,列车在运行过程中磨损产生车轮多边形的问题日益突出。这不仅加快了列车关键零部件的损坏速度,还显著缩短了轮轨系统的服役寿命。车轮多边形在低速列车上主要表现为低于10阶的低阶多边形,而在高速列车上主要表现为20阶左右的高阶多边形^[1-3]。本文拟研究一种基于改进一维卷积神经网络(1D-CNN)的方法进行列车车轮多边形的检测,以提高车轮多边形检测的准确性和效率。

目前,国内外学者对于车轮多边形的检测研究提出了很多方法。陈翔宇等^[4]通过分析轴箱加速度的时域特征与频域特征,完成车轮多边形故障识别。徐晓迪等^[5]利用Lp范数准则和广义Hilbert包络解调方法,提取车辆动态响应信号中隐含的车轮多边形信息,该方法对车轮多边形的诊断效果较好。陈博^[6]通过改进的集合经验模态分解(MEEMD)方法提取特征,并以此利用多尺度排列熵特征和遗传算法-支持向量机(GA-SVM)对车轮多边形进行识别,识别准确率为97.50%。史红梅等^[7]利用样本熵和小波变换,将钢轨振动加速度的最优数据转换为时频图,再通过残差网络提取图像特征,实现了车轮踏面擦伤深度的识别,识别率达到99.38%。李凤林等^[8]对轴箱振动加速度进行总体经验模态分解(EEMD),借助相关能量(CN)自动提取车轮多边形故障的IMF分量,然后利用包络谱分析和频谱分

析,诊断车轮的多边形故障及阶次。孙琦等^[9]应用波长固定机理,快速去除其他转频倍频谐波的影响,从而实现在线监测车轮多边形不圆状态。以上均是基于分析时频谱的智能方法,但时频域分析法通常需要进行大量且复杂的数据预处理,且在数据转换的过程中易产生特征损失,而传统车轮多边形检测方法又对人工经验和专用测量设备有较大的依赖。振动加速度以时域数据形式表示能够在一定程度上反映机械运行状态,但其特征复杂且规律不明显,难以准确提取有效特征。

目前主流的深度学习网络有VGG(卷积神经网络)^[10]、ResNet(残差网络)^[11]、AlexNet(深度卷积神经网络)^[12]、DenseNet(密集连接卷积神经网络)^[13],这些神经网络均能够有效解决因特征复杂导致的数据不易提取和学习的问题。其中一维深度神经网络因其强大的特征提取与学习能力,可通过时域数据判断或预测机械运行的状态,此类神经网络目前在其他旋转部件诊断的研究中效果突出,因此可用于车轮多边形检测。刘冲^[14]将一维卷积自编码引入一维卷积神经网络,形成联合抗噪故障诊断模型,提高了不同噪声环境下轴承故障的诊断能力。周兴康等^[15]将残差学习机制和自编码器引入一维卷积神经网络,形成了一维残差卷积自编码器,显著提高了齿轮箱的故障诊断率。赵敬娇等^[16]将残差连接与1D-CNN结合形成了无监督学习机制,通

过验证得出该方法可有效提高故障识别的准确率。刘岚等^[17]提出了一种将一维卷积网络与残差网络相结合并添加一条残差连接通道的方式,得出在较小训练与测试样本比的情况下,故障诊断准确率较高。肖乾等^[18]提出了一种滚动轴承故障诊断方法,通过消融实验得出该方法具有很好的适应能力,故障识别准确率高。Gan等^[19]建立了机车-定位耦合动力学模型,提出一种基于卷积神经网络的车轮多边形定量检测方法,并通过车轮多边形实测数据进行验证得出该模型能快速检测车轮多边形的主要特征。于洋等^[20]提出一种基于广义S变化和改进卷积神经网络相结合的方式,改进激活函数,以解决卷积神经网络(CNN)过拟合的问题,故障的识别率和泛化能力都较高。由此可预见利用一维深度神经网络完成列车车轮多边形检测有极好的前景,但因车轮多边形标签数据难以获得的原因,目前研究仍存在因标签数据量不足导致检测误差大及实用性不高的问题。

根据上述的相关研究,本文通过融合一维卷积、残差网络和自编码器,提出一种基于改进的一维深度残差卷积自编码神经网络(1DResAE)方法的列车车轮多边形诊断研究,并以LMA型踏面车轮为研究对象,通过Simpack动力学仿真软件获取仿真数据用于训练神经网络。

通过使用小比例轮轨对滚实验台获取实验数据对神经网络分类预测性能进行验证,结果表明本文神经网络模型在仅有少量标签数据进行训练的条件下仍有较高的识别准确率,能够解决常规神经网络模型因标签数据量不足导致检测误差大及实用性不高的问题。

1 1DResAE 网络模型

1.1 相关技术

1.1.1 一维卷积神经网络

一维卷积^[21]是在二维卷积的基础上,降低卷积核的维度,使其仅在宽度或高度上进行卷积。其输入矩阵可以是非方阵,且大小不受限制,因此一维卷积神经网络在处理自然语言类问题时表现更优。卷积神经网络中,每一次卷积都是对特征的提取和学习。数据在卷积层中通过卷积核逐步放大特征,卷积层越多,能够提取的特征就越丰富。

一维卷积神经网络通过带有标签的数据进行

训练,其训练过程本质上是一个逻辑回归过程,也是一个映射过程。通过已知的 x 与 y 的关系计算权重 ω 和偏置 b ,最终计算得到最佳的 ω 和 b ,使 x 与 y 的映射关系最佳,训练式如

$$y = \omega x + b \quad (1)$$

式中: x 为输入; y 为 x 的映射标签; ω 为权重; b 为偏置。

1.1.2 残差网络(ResNet)

网络深度加深会使卷积神经出现梯度爆炸和消失现象,导致权重停止更新或大幅更新,从而使网络不稳定甚至破坏网络。此外,神经网络的深度越深其在特征学习时越容易出现原始特征丢失的现象,使神经网络出现退化问题。残差网络作为一种卷积神经网络,能有效解决梯度爆炸、梯度消失现象,以及神经网络退化问题。残差网络基本结构单元如图1所示, x 为样本数据集, $F(x)$ 为残差网络输出。




图1 残差网络基本结构单元

Fig. 1 The basic structural unit of residual network

残差网络通过shortcut连接实现了深层网络的恒等映射,使网络结构的改变产生额外的参数,也不会增加计算的复杂度。因其网络结构的特殊性,网络依旧可以通过端到端的反向传播训练,还可通过shortcut连接实现首尾的映射。残差单元的基本表达式为

$$x_{l+1} = x_l + F(x_l, W_l) \quad (2)$$

式中: x_l 为浅层单元第 l 层的输入; $W_l = \{W_{l,k} | 1 \leq k \leq K\}$ 为浅层单元第 l 层的参数; K 为残差单元层数。通过递归计算,可得任意层单元 L 特征的表达式为

$$x_L = x_l + \sum_{i=1}^{L-l} F(x_i, W_i) \quad (3)$$

式中: x_L 为深层单元第 L 层的输入; W_i 为深层单元第 i 层参数。

与传统卷积神经网络相比,残差网络通过直接将输入信息绕道传到输出的方式,既保护了信息的完整性,又使整个网络只需要学习输入、输出差别的那一部分,由此简化学习目标和难度。

1.1.3 卷积自编码器

自编码器是一种无监督的深度学习模型^[22],它利用输入数据 X 本身作为监督,通过反向传播和最优化方法,训练神经网络得到一个映射关系,从而得到一个重构输出 X_R 。该算法包括编码(Encoder)和解码(Decoder)两个阶段,其中编码阶段是把高维输入 X 编码为低维的隐层变量 h ,使神经网络能够学习到最有信息量的特征,解码阶段则是反向将隐层变量 h 还原到初始维度输出 X_R 。因此可将自编码器视为两个网络联结组成。自编码器算法框架结构如图2所示。




图2 自编码器算法框架结构

Fig. 2 Autoencoder algorithm framework structure

卷积自编码器的编码过程由卷积层和池化层组成,解码过程为反卷积过程。

1) 编码阶段(卷积操作): k 个初始卷积核 W 各配备一个偏置 b ,通过激活函数将输入 x 卷积变换为 k 个特征 h 。表达式为

$$h_k = \sigma(x * W_k + b_k) \quad (4)$$

式中: $*$ 为卷积运算; h_k 为编码器的第 k 层的输出特征; W_k 为编码器的第 k 层卷积核权重; b_k 为编码器的第 k 层偏置; $\sigma(\cdot)$ 为非线性激活函数。

2) 解码阶段(反卷积操作): 将特征 h 与对应的转置卷积核进行卷积计算并求和,之后与偏置 c 相加,通过激活函数获得输出 y 。表达式为

$$y = \sigma\left(\sum_k h_k * W_{-k} + c\right) \quad (5)$$

式中: y 为解码器输出的重构数据; W_{-k} 为解码器的反卷积核; c 为解码器的偏置。

3) 更新权值: 通过损失函数,利用真实值与输出值的平方和求均值。表达式为

$$E(\theta) = \frac{1}{2n} \sum_{i=1}^n (x_i - y_i)^2 \quad (6)$$

式中: $E(\theta)$ 为损失函数; x_i 为第 i 个样本的原始输入数据; y_i 为第 i 个样本的解码器重构输出数据; n 为样本数。

1.2 1DResAE 网络模型的算法及优化改进

1DResAE 以传统的残差网络和卷积自编码器为基础。传统残差网络通过将二维卷积替换为一维卷积,构建出一维残差卷积神经网络。卷积自编码器的 Encoder 阶段由一维残差卷积神经网络完成,Decoder 阶段根据 Encoder 阶段中残差网络的输出矩阵设置相应的反卷积层数,完成自编码器部分的搭建,进而搭建出 1DResAE 网络模型。

1.2.1 网络结构

由于本文所研究的对象存在数据量大、数据结构复杂和数据特征为时域特征等问题,因此为提高神经网络性能,需对前文所述 1DResAE 网络模型基本结构的基础上进行网络结构优化。为节约神经网络计算所需的计算资源和计算成本,残差块卷积结构采用 $1*1, 3*1, 1*1$ 的形式,为防止梯度爆炸或梯度消失、加快模型学习速度并增强模型的泛化性,在每一个卷积层后添加归一化层。根据所研究的问题将算法设计为两个过程:阶段1通过自编码器的自监督学习特性对无标签数据进行特征学习,阶段2则利用带标签的数据对编码器进行微调。本文所用 1DResAE 网络模型如图3所示。

1.2.2 更改激活函数

神经网络中,神经元通过激活函数增加非线性因素,使复杂的输入映射到简单的输出,进而可应用于非线性问题^[23]。图像识别中常使用的 RGB 和灰度图通常关注目标的正值特征部分,对负值映射特征的保留需求较低,因此残差网络通常使用能够抹除负值特征、增强非线性表达能力的 ReLu 函数作为激活函数。然而,列车运行过程中采集的车轮振动信号中含有大量负值特征信息,这些负值特征与车轮故障密切相关,若使用 ReLu 函数将造成负值特征的丢失,严重影响故障特征的准确提取。因此,需要更改能够保留负值特征的激活函数。自编




图3 列车车轮多边形检测1DResAE网络模型

Fig. 3 Train wheel polygon detection 1DResAE network model

码器在相同多边形故障条件下,分别使用 SeLu 和 ReLu 输出的重构波形图如图4所示。




图4 自编码器重构波形图

Fig. 4 Autoencoder reconstruction waveform diagram

SeLu 函数能够有效保留输入信号的负值特征并重构输出,而 ReLu 函数则会将输入的负值全部置为0,并抹除负值特征。因此,本文提出使用 Se-Lu 函数作为 1DResAE 网络模型中残差网络编码部分的激活函数,能够保持输入的性质,保留负值输入特征,进而提升深度神经网络对车轮多边形的检

测性能。

2 1DResAE 网络模型训练

神经网络训练需要样本数据,且样本需求量较大。由于实验台测量数据的获取比仿真数据更困难,因此使用 Simpack 动力学仿真数据进行训练与测试,用实验台实验数据进行验证。

2.1 振动数据仿真

2.1.1 车辆动力学仿真模型

对列车系统整体的运动状态进行分析,需要建立相应的数学计算方法。由于列车系统是由多个刚性体构成的闭环运动系统,结合拉格朗日法与车辆系统动力学理论,可得车辆系统动力学方程^[24]

$$M\ddot{X} + C\dot{X} + KX = P \quad (7)$$

式中: M 为系统的质量矩阵; C 为系统的阻尼矩阵; K 为系统的刚度矩阵; $\ddot{X}$ 为系统的加速度矩阵; $\dot{X}$ 为系统的速度矩阵; X 为系统的位移矩阵; P 为系统的广义外力矩阵。

根据上述内容以及某型动车组的相关参数,利用动力学计算软件 Simpack 进行动力学建模,部分

动力学参数设置如表 1 所示,其中一系垂向减振器两端各一个接头,故刚度数值应除以 2。创建的轨道车辆系统动力学模型如图 5 所示。在模型中,一系弹簧和一系减振器连接轮对与构架,二系空气弹簧、二系横向减振器和抗蛇行减振器则连接构架与车体,各悬挂元件均由力元代替。

表 1 某型高速列车动力学参数
Tab.1 Dynamic parameters of a high-speed train

结构参数	数值	结构参数	数值
轴距/m	2.5	构架质量/kg	2 056
车体质量/t	33.786	构架重心高/m	-0.52
车体重心高/m	1.656	轮对质量/kg	1 627
一系垂向减振器阻尼(每轴箱)/(kN·s/m)	10	一系垂向减振器接头刚度(两端串联后)/(kN/m)	15 000/2
二系横向减振器阻尼(每个)/(kN·s/m)	15	二系垂向减振器阻尼(每个)/(kN·s/m)	10




图 5 车辆系统动力学模型
Fig. 5 Dynamics model of rail vehicle system

2.1.2 车轮多边形动力学模型

在车轮多边形动力学建模中,车轮多边形多以谐波函数的形式进行数值表达,并建立模型。列车车轮表面不圆顺表现为在踏面廓形无变化的情况下,半径差在踏面圆周方向发生周期性变化。在车轮滚完一个圆周周期后,对应每个角度的轮径差以谐波函数的形式表现^[25]。车轮多边形计算式为

$$\begin{cases} \Delta r = A \sin(n\alpha_1 + \alpha_0) \\ r = R - \Delta r \end{cases} \quad (8)$$

式中: α_0 为初始相位角; α_1 为转动角度; Δr 为轮圆周不圆顺的轮径差; A 为多边形幅值; r 为多边形轮的实际半径; R 为名义滚动圆半径; n 为多边形阶数。


列车车轮的非周期性车轮多边形可通过多个谐波函数叠加进行数学表达,故本文对某阶为主要阶次的非周期性车轮多边形进行动力学建模时,采用谐波函数叠加的方式进行数学表达,并进行动力学建模。

2.1.3 数据采集与预处理


在 Simpack 动力学仿真软件中,设置武广线轨道激励谱模拟轨道不平顺,列车运行速度设置为 250 km/h。将仿真计算获得的各类型车轮多边形的振动加速度数据划分为 5 912 组,每组数据包括轴向 x 、径向 y 、垂向 z 三向振动加速度,每个方向含

1 000 个振动加速度数据,部分仿真数据波形图如图 6 所示。


通过动力学仿真计算获得的 5 912 组振动加速



(a) x 方向振动加速度



(b) y 方向振动加速度



(c) z 方向振动加速度

图 6 仿真计算三向振动加速度波形图
Fig. 6 Simulation calculation of three-way vibration acceleration waveform

度数据,其中4 552组作为训练集、680组作为验证集、680组作为测试集。训练集中2 770组设置标签,验证集和测试集均设置标签,标签设置如表2所示。其中单阶车轮多边形指的是仅包含1个阶次的振动特征,如车轮表面每转动一圈出现了18个波峰,就被称为18阶多边形;多阶车轮多边形指的是车轮表面包含了多个频率成分,从而导致了不同阶次的波形叠加在一起。本文的多阶车轮多边形设定为1个主要阶次,4个次要阶次,其中主要阶次的粗糙度设为10 μm ,次要阶次的粗糙度设为4 μm ,主要阶次和次要阶次的粗糙度差异为60%。例如18阶为主要阶次的多阶车轮多边形,指的就是18阶为主要阶次,19~22阶为次要阶次。

表2 各车轮多边形类型对应标签设置参数

Tab.2 The label setting corresponding to each wheel polygon type is set

车轮多边形类型	向量标签	数字标签
单阶18阶	[1,0,0,0,0,0,0,0,0,0]	0
18阶为主要阶次的多阶	[0,1,0,0,0,0,0,0,0,0]	1
单阶19阶	[0,0,1,0,0,0,0,0,0,0]	2
19阶为主要阶次的多阶	[0,0,0,1,0,0,0,0,0,0]	3
单阶20阶	[0,0,0,0,1,0,0,0,0,0]	4
20阶为主要阶次的多阶	[0,0,0,0,0,1,0,0,0,0]	5
单阶21阶	[0,0,0,0,0,0,1,0,0,0]	6
21阶为主要阶次的多阶	[0,0,0,0,0,0,0,1,0,0]	7
单阶22阶	[0,0,0,0,0,0,0,0,1,0]	8
22阶为主要阶次的多阶	[0,0,0,0,0,0,0,0,0,1]	9
标准车轮	[0,0,0,0,0,0,0,0,0,1]	10

2.2 网络参数设置

第1阶段,使用无标签数据训练自编码网络,学习率设为0.01,批次大小设为8,循环次数设为1 000;第2阶段,使用标签数据微调分类器,学习率设为0.000 01,批次大小设为32,循环次数设为2 000。根据前文所述网络模型结构设置网络参数,编码器采用ResNet50相关参数设置,解码器依据编码阶段输出矩阵和输入矩阵设置相应网络参数,分类器由全局平均池化层和两个全连接层组成。编码器首先通过一个卷积核宽度为7、步长为2的卷积层提取初步特征,随后经过步长为2的一维最大池化层进行下采样。接着,特征依次通过4个卷积核宽度为3、步长为2的卷积模块(卷积层2至卷积层5),逐步提取更加抽象的深层特征。编码器末端

设置瓶颈层,采用1*1卷积进行特征压缩。解码器部分由5个反卷积层组成,其中前4层卷积核宽度为3、步长为1,第5层卷积核宽度为7、步长为2,同时在反卷积层4之后设置卷积核步长为2的上采样层,以逐步恢复特征图的空间分辨率。分类器部分则采用一维全局平均池化将特征向量化,并通过两个全连接层完成最终的分类判别,每个全连接层包含12个神经元,正则化系数为0.000 1,用于防止过拟合并提升模型泛化能力。

2.3 1DResAE网络模型的训练与测试流程

列车车轮多边形故障分类识别网络的训练与测试流程包含两个主阶段:第1阶段以无监督学习为主,采用无标签数据集进行训练;第2阶段以监督学习的方式,对第1阶段训练出的权重和偏置进行微调并完成分类,使用有标签数据进行训练与测试。

第1阶段:无监督学习训练。

- 1) 输入:训练集 X_1 ;
- 2) 搭建自编码器网络,设置卷积层、池化层、标准化(BN)层、反卷积层、上采样层和激活函数等;
- 3) 初始化自编码器网络的权重和偏置,设置超参数,并开始循环训练;
- 4) 计算卷积、池化和BN等输出特征 f_1 ,并计算上采样、反卷积输出 X' ;
- 5) 计算输入与输出误差,求解并更新反卷积参数 w_i 、 b_i ,根据反卷积参数求解并更新卷积参数 w 、 b ;
- 6) 损失最优激活回调函数,结束循环。

第2阶段:分类微调。

- 1) 输入:训练集 X_2 、训练集标签 Y_2 、测试集 X ;
- 2) 搭建分类器,设置池化层、全连接层和激活函数等;
- 3) 初始化全连接层的权重和偏置,设置超参数,并开始循环训练;
- 4) 计算卷积、池化和BN等输出特征 f_2 ,并将特征 f_2 输入全连接层分类得到预测标签 y' ;
- 5) 计算损失和准确率,并根据损失和准确率计算并更新全连接层权重和偏置;
- 6) 损失和准确率最优激活回调函数,结束循环并保存网络模型参数。

上述步骤中训练集 X_2 取自于训练集 X_1 。1DResAE网络模型训练过程使用Adam优化器完成随机梯度下降法训练,网络训练达到预期效果后,输出

并保存网络模型参数。

3 实验与结果分析

3.1 故障检测实验流程

首先,通过仿真计算获得振动数据构建算法模型的训练集、验证集、测试集,以此验证算法模型分类检测性能。其次,通过车轮滚动实验台获取振动数据做成测试集,用于验证模型对实测数据的分类预测能力。最后,通过算法模型评价指标等说明该算法应用在列车车轮多边形检测的实用性。

3.2 实验数据采集与处理

滚动实验台选用小比例轮轨对滚实验台,如图7所示。实验台分为机械结构和测量装置。机械结构由3.8 kW伺服电机,长轴,轨道轮,正常车轮试件和模拟不同阶数车轮多边形样件轮组成;测量装置选择航伽科技HA3M50-100g三轴振动加速度传感器和HP9004动态数据采集卡。实验前更换需检测的车轮多边形样件轮,以仿真计算设计的实验参数为基础参数,经等比例等效计算获得实验台参数设置值,速度设置为250 km/h。开始实验时,通过HP9004动态数据采集卡对振动加速度数据进行连续采集。车轮多边形类型和数量设置如表2所示,通过三向振动加速度传感器采集共1 360组数据,每组数据同样包括轴向 x 、径向 y 、垂向 z 三向振动加速度。通过小比例轮轨对滚实验台测得的1 360组振动加速度数据与仿真计算数据作相同的预处理,只作为测试集,用于验证1DResAE网络模型针对列车车轮多边形分类预测的实用性。标签设置如表2所示。




图7 小比例轮轨对滚实验台

Fig. 7 Small proportion wheel-rail rolling test bench

3.3 模型性能验证分析

3.3.1 评价指标分析

通过观察与分析神经网络模型在训练过程中

的损失和准确率,可判断神经网络学习数据特征的能力。测试集的分类效果则用于评估最终模型在执行列车车轮多边形故障分类预测任务中的泛化能力和鲁棒性。在第1阶段无监督学习过程中,当循环225次时训练集的损失降到0.005 0,验证集的损失降到0.016 6。在第2阶段分类器的有标签数据微调阶段训练过程中,当循环为151次时,训练集和验证集的准确率均超过99.00%。此时训练集的损失为0.540 2、准确率为99.63%,验证集的损失为0.598 7、准确率为99.12%。

第1阶段的训练集损失曲线和验证集损失曲线如图8所示。第2阶段的训练集损失曲线、训练集准确率曲线、验证集损失曲线和验证集准确率曲线如图10所示。

由图8、图9可知,1DResAE网络模型收敛和训练效果优异。为了验证模型的分类预测准确性以及鲁棒性,使用仿真数据测试集进行测试,并输出混淆矩阵直观展示分类结果。通过测试集验证结果可知,1DResAE网络模型针对高速列车车轮多边形阶数的检测和分类精确率为99.99%,且计算过程




图8 第1阶段损失曲线

Fig. 8 First stage loss curve




图9 第2阶段损失曲线与准确率曲线

Fig. 9 Second stage loss curve and accuracy curve

中所产生的损失小于0.2。分类预测的混淆矩阵如图10所示。

混淆矩阵显示结果表明,神经网络模型在列车车轮多边形阶数的预测上具有较高的准确率,能对各类别的车轮多边形实现精准识别。结合测试集中存在多种类振动数据和带有异常振动数据集的情况,可判断最终的神经网络模型具有较强的泛化能力和较高的鲁棒性。

3.3.2 模型特征层可视化分析

通过特征层可视化,可以更深入地理解神经网络特征的学习机制,更清晰地观察神经网络在学习过程中如何分析数据,并直观地展示高维数据在神经网络中逐步被分类预测的过程。为了验证1DResAE网络模型逐层提取特征能力,采用非监督降维算法(t-SNE)对各层输出数据进行降维可视化展示,如图11所示。从可视化结果可以看出,相同标签下的数据通过模型卷积编码计算后,在二维空间中逐渐展现出了较高的相似性。经过模型分类计算并对

数据特征选择后,不同标签下的数据被集中在特定的区域内,各类型数据最终获得良好的分类效果。




图10 仿真数据测试混淆矩阵

Fig. 10 Simulation data test confusion matrix




图11 t-SNE可视化

Fig. 11 t-SNE visualization

3.3.3 与其他模型分类性能对比

与故障诊断领域中几种常用的监督式神经网络算法作对比,可进一步验证1DResAE网络模型应用在检测列车车轮多边形故障任务中的有效性和先进性,同时还可验证其在处理时域数据任务中的先进性。一维卷积神经网络(1DCNN)的层设置为:5层卷积层、5层池化层、2层全连接层。全连接神经网络(BPN)的层设置为:3层全连接层,各层神经元个数分别为3 000,100,11;第2层全连接层与第3层全连接层之间设置1层池化层。循环神经网络(RNN)的层设置为:输入层、隐含层和输出层;其

中隐含层设置64次循环,输出层为全连接层。为了降低实验的偶然性,采用5折交叉验证法计算各类型分类识别算法的平均准确率。最终的5折交叉验证结果对比如表3所示。从平均准确率对比可以看出,1DResAE网络模型的平均准确率高于其他分类识别算法,证明其对时域数据的特征提取能力优于其他分类识别算法,能够更准确的识别分类列车车轮多边形阶数。

3.4 分类预测效果分析

为了验证1DResAE网络模型在列车车轮多边形故障诊断中的实用性,使用小比例轮轨对滚实验

表3 各类型分类识别算法准确率对比

Tab.3 Accuracy comparison of various types of classification and recognition algorithms						%
算法	测试结果1 准确率	测试结果2 准确率	测试结果3 准确率	测试结果4 准确率	测试结果5 准确率	平均准确率
1DResAE	97.794	100.000	100.000	100.000	100.000	99.559
1DCNN	15.882	16.174	15.882	16.618	17.323	16.376
BPN	13.971	55.147	68.382	66.176	79.412	56.618
RNN	21.029	23.971	23.235	25.441	22.500	23.235

台所测振动数据制作的测试集进行验证。经5折交叉验证法验证,1DResAE 网络模型对列车车轮多边形诊断分类的平均精确率为98.971%,平均损失仅为0.257 17。通过实验数据进行分类预测所得混淆矩阵如图12所示。结果表明,该模型在识别列车车轮多边形阶数方面有很高的准确率,证明其在处理列车车轮多边形故障诊断问题时的实用性。




图12 实验数据测试混淆矩阵
Fig. 12 Experimental data test confusion matrix

3.5 工程应用可行性分析

1DResAE 网络模型通过对振动信号的分析,能够有效检测出车轮多边形的阶数。本研究通过仿真数据和实验台数据进行验证,结果表明 1DResAE 网络模型在识别列车车轮多边形类别的检测中均表现出较高的精确率,证明了该方法在车轮多边形识别任务中有较高的有效性和鲁棒性。因此,在应对更复杂多变的实际检测振动数据时该方法仍能使用,并将保持较高的准确率。

综上所述,在车轮多边形检测任务中,1DResAE 网络模型能够稳定检测出车轮多边形的阶数,具有较高的工程应用可行性。

4 结论

1DResAE 网络模型有效融合了一维卷积、残差网络和自编码器,能够以无监督方式学习复杂的传感器信号,并自主学习抽象特征。实验证明,该模型能够对列车车轮多边形故障进行有效识别,主要结论如下。

1) 1DResAE 网络模型结合了一维卷积、残差网络和自编码器的优势,能够通过数据重构的方式使无标签的数据作为训练集对神经网络模型训练,进而解决了标签数据不足的问题。此外,残差网络的特性增加了模型对振动数据特征的提取和学习能力,提高了训练过程的收敛速度、并降低了误差。

2) 使用 SeLu 函数作为 1DResAE 网络模型神经元的激活函数,相较 ReLu 函数,神经网络训练并未出现效果变差的现象。同时,SeLu 函数使得神经网络不仅能够获得与 ReLu 函数相似的振动数据正值特征,还能保留振动数据的负值特征,进而在一定程度上减小了自编码网络的重构误差。

3) 通过实验台数据验证,1DResAE 网络模型识别列车车轮多边形类别的精确率为98.971%,检测精确率高、损失小,能够精确识别到车轮多边形的阶数,并区分发生的是单阶多边形还是多阶多边形,在处理列车车轮多边形检测问题上有较高的实用性。

参考文献:

[1] 金学松, 吴越, 梁树林, 等. 高速列车车轮多边形磨损、机理、影响和对策分析[J]. 机械工程学报, 2020, 56(16): 118-136.
JIN X S, WU Y, LIANG S L, 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] 左齐宇. 某线某 300 km/h 高速列车车轮多边形特征及

- 其影响分析[D]. 成都: 西南交通大学, 2019.
- ZUO Q Y. Analysis on characteristics and influence of wheel polygon of a certain 300 km/h high-speed train on a certain line[D]. Chengdu: Southwest Jiaotong University, 2019.
- [3] FU B, BRUNI S, LUO S. Study on wheel polygonization of a metro vehicle based on polygonal wear simulation [J]. *Wear*, 2019, 438: 203071.
- [4] 陈翔宇, 樊懿葳, 李凤林. 基于轴箱加速度时频域特征的车轮多边形故障识别[J]. *机械*, 2021, 48(7): 35-43.
- CHEN X Y, FAN Y W, LI F L. Wheel polygon fault diagnosis based on the time and frequency domain characteristics of axle box acceleration[J]. *Machinery*, 2021, 48(7): 35-43.
- [5] 徐晓迪, 刘金朝, 孙善超, 等. 基于车辆动态响应的车轮多边形自动识别方法[J]. *铁道建筑*, 2019, 59(9): 101-105.
- XU X D, LIU J Z, SUN S C, et al. Automatic method for polygonalization of wheel treads based on vehicle dynamic response[J]. *Railway Engineering*, 2019, 59(9): 101-105.
- [6] 陈博. 高速列车车轮多边形的检测与识别方法研究[D]. 成都: 西南交通大学, 2018.
- CHEN B. Study on detection and diagnosis method of wheel polygonization of high-speed trains[D]. Chengdu: Southwest Jiaotong University, 2018.
- [7] 史红梅, 张航, 李建钹. 基于残差深度网络的高速列车车轮踏面擦伤智能检测[J]. *机械工程学报*, 2022, 58(16): 134-144.
- SHI H M, ZHANG K, LI J B. Intelligent detection of tread flat of high-speed train wheel based on residual network[J]. *Journal of Mechanical Engineering*, 2022, 58(16): 134-144.
- [8] 李凤林, 杜红梅, 樊懿葳, 等. 基于形态学滤波的车轮多边形故障诊断方法[J]. *机械*, 2023, 50(8): 39-46.
- LI F L, DU H M, FAN Y W, et al. The method of wheel polygonal fault diagnosis based on morphological filtering [J]. *Machinery*, 2023, 50(8): 39-46.
- [9] 孙琦, 张兵, 李艳萍, 等. 一种波长固定的车轮多边形在线故障检测方法[J]. *铁道科学与工程学报*, 2018, 15(9): 2343-2348.
- SUN Q, ZHANG B, LI Y P, et al. Wavelength-fixing mechanisms for detecting the wheel polygon-shaped fault onsite[J]. *Journal of Railway Science and Engineering*, 2018, 15(9): 2343-2348.
- [10] DO M N, VETTERLI M. The contourlet transform: an efficient directional multiresolution image representation [J]. *IEEE Transactions on image processing*, 2005, 14(12): 2091-2106.
- [11] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON E G. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [13] ZHANG K, GUO Y, WANG X, et al. Multiple feature re-weight DenseNet for image classification[J]. *IEEE Access*, 2019, 7: 9872-9880.
- [14] 刘冲. 基于联合抗噪算法的滚动轴承故障诊断研究[J]. *华东交通大学学报*, 2020, 37(4): 82-87.
- LIU C. Research on joint anti-noise algorithm and its application in rolling bearing fault diagnosis[J]. *Journal of East China Jiaotong University*, 2020, 37(4): 82-87.
- [15] 周兴康, 余建波. 基于深度一维残差卷积自编码网络的齿轮箱故障诊断[J]. *机械工程学报*, 2020, 56(7): 96-108.
- ZHOU X K, YU J B. Gearbox fault diagnosis based on one-dimension residual convolutional auto-encoder[J]. *Journal of Mechanical Engineering*, 2020, 56(7): 96-108.
- [16] 赵敬娇, 赵志宏, 杨绍普. 基于残差连接和1D-CNN的滚动轴承故障诊断研究[J]. *振动与冲击*, 2021, 40(10): 1-6.
- ZHAO J J, ZHAO Z H, YANG S P. Rolling bearing fault diagnosis based on residual connection and 1D-CNN[J]. *Journal of Vibration and Shock*, 2021, 40(10): 1-6.
- [17] 刘岚, 侯立群. 基于改进一维残差网络的轴承故障诊断[J]. *仪器仪表用户*, 2021, 28(9): 45-50.
- LIU L, HOU L Q. Bearing fault diagnosis method based on improved 1D residual network[J]. *Instrumentation*, 2021, 28(9): 45-50.
- [18] 肖乾, 李楷文, 周生通, 等. 基于MR-DCA的滚动轴承微弱故障诊断[J]. *华东交通大学学报*, 2024, 41(1): 113-119.
- XIAO Q, LI K W, ZHOU S T, et al. Research on MR-DCA based diagnosis of weak faults of rolling bearings [J]. *Journal of East China Jiaotong University*, 2024, 41(1): 113-119.
- [19] GAN W W, BAI Z H, XIE Q L, et al. Study on the vibration behaviour of locomotives under wheel polygon excitation and its quantitative detection method[J]. *IEEE Access*, 2024, 12: 91873-91885.

- [20] 于洋, 马军, 王晓东, 等. 基于GST与改进CNN的滚动轴承智能故障诊断[J]. 铁道科学与工程学报, 2022, 19(7): 2050-2060.
YU Y, MA J, WANG X D, et al. Intelligent fault diagnosis of rolling bearings based on GST and improved CNN [J]. Journal of Railway Science and Engineering, 2022, 19(7): 2050-2060.
- [21] ZHAO M H, ZHONG S S, FU X Y, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4681-4690.
- [22] MISHRA D, SINGH S K, SINGH R K. Wavelet-based deep auto encoder-decoder (WDAED)-based image compression[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 31(4): 1452-1462.
- [23] 魏艳红, 张玉莲. 焊接工艺智能设计研究进展[J]. 电焊机, 2020, 50(9): 213-220.
WEI Y H, ZHANG Y L. Research progress on intelligent design of welding process[J]. Electric Welding Machine, 2020, 50(9): 213-220.
- [24] 魏燕明, 张雪艳, 岳奕丹, 等. 基于子结构法的齿轮箱-基座耦合系统结构振动仿真研究[J]. 机械强度, 2019, 41(1): 226-231.
WEI Y M, ZHANG X Y, YUE Y D, et al. Simulation studies on structure vibration of gearbox-base coupling system based on the substructure method[J]. Journal of Mechanical Strength, 2019, 41(1): 226-231.
- [25] 林凤涛, 黄琴, 张海, 等. CRH3 高速列车多边形磨耗车

轮通过钢轨波磨区段的轮轨力研究[J]. 铁道科学与工程学报, 2021, 18(7): 1706-1714.

LIN F T, HUANG Q, ZHANG H, et al. Study on wheel-rail force of CRH3 high speed train with wheel polygon when passing corrugation rail[J]. Journal of Railway Science and Engineering, 2021, 18(7): 1706-1714.



第一作者: 林凤涛(1977—), 男, 教授, 博士, 博士生导师, 江西省“双千计划”科技创新领军人才, 江西省主要学科学术和技术带头人, 研究方向为列车安全技术。E-mail: ecjtu411@163.com。



通信作者: 谭荣凯(1990—), 男, 讲师, 博士, 研究方向为轨道车辆关键部件服役性能。E-mail: tanrongkai7@163.com。

(责任编辑: 姜红贵)