

# 基于 LSTM 的脱轨系数间接测量方法研究\*

孙昭意, 陈建政, 吴越, 乔笑冉

(西南交通大学轨道交通运载系统全国重点实验室 成都, 610031)

**摘要** 为了对脱轨系数进行准确而高效的在线监测,基于长短时记忆(long short-term memory,简称 LSTM)网络算法,对脱轨系数间接测量问题展开研究。首先,选取实测地铁车辆上易测得的物理信号作为输入,研究不同输入信号与脱轨系数的相关性;其次,建立网络模型的样本数据集并对脱轨系数划分相应标签,通过网络训练实现标签的准确划分;最后,筛选标签中脱轨系数临近安全限值的样本数据作为网络的输入,实现脱轨系数具体数值的间接测量,并在另一条试验线路上验证了该方法的有效性。研究表明:将轴箱横、垂向振动加速度信号、车体摇头角速度信号、一系悬挂垂向压缩位移量以及车辆运行速度全部作为网络输入信号,进行脱轨系数间接测量的效果最好;基于 LSTM 方法可以有效地对脱轨系数标签进行分类,且能够对危险区域内脱轨系数进行精确测量,满足实际线路上脱轨系数间接测量及评价的要求。该研究成果有助于地铁车辆长期运营时脱轨系数间接测量以及安全监测等。

**关键词** 脱轨系数;振动加速度;长短时记忆网络;间接测量

**中图分类号** U270.1

## 引言

近年来,随着轨道车辆的运行速度和运载量的不断提升,列车运行安全性也随之受到挑战<sup>[1]</sup>,这对于车辆安全性的实时监控十分重要。脱轨系数是评价轨道车辆安全性的关键指标,如何准确而高效地进行测量具有重要的研究意义和工程价值。

脱轨系数测量技术本质上是轮轨横向和垂向力的测量方法。轮轨力测量技术可分为直接测量和间接测量法。直接测量常用测力轮对直接测量轮轨力,该方法需要对轮对进行打孔、贴片和封装操作。间接测量法是通过以车辆系统中易于采集的信号作为输入,逆向求解车辆系统轮轨力。间接测量技术相较而言具有操作简单、安全性高、经济性、不影响车轮和车轴使用寿命等优点。因为地铁车辆在线路运行中必须对其安全性长期实时监控,但测力轮对不能长期装车使用,故采用间接测量法对地铁车辆长期跟车安全监测具有重要研究意义和前景。

国内外学者针对轮轨力以及脱轨系数间接测量方法进行了大量研究。Nordstrom<sup>[2]</sup>通过轴箱上测得的加速度等信号,通过脉冲响应函数计算加速度与脱轨系数之间的内在关系。Xia等<sup>[3]</sup>通过建立车

辆逆动力学模型,测量车体横、垂向振动加速度和车体侧滚角速度等来计算脱轨系数。Akira<sup>[4]</sup>采用非接触式间隙传感器测量车轮变形量,通过车轮、一系弹簧和构架的变形量推导轮轨横、垂向力。上述测量方法均存在精度较低等问题。孙善超<sup>[5]</sup>在时域内推导在线轮轨力识别算法,将轴箱加速度作为输入,利用单自由度识别模型对轮轨力进行识别,并将识别结果与正演模型轮轨力比较,两者相关系数达到 0.82 以上。周亚波<sup>[6]</sup>应用卡尔曼滤波技术对轮轨力反演进行了研究,建立了整车轮轨力反演模型,验证在不同轨道线路条件下轮轨力的估计效果。

经典的脱轨系数间接测量技术通过建立动力学方程式和物理模型计算得到。该方法大多基于仿真计算模型进行研究,而列车实际振动响应和轮轨力较为复杂,且传统模型轮轨力测量大多是在直线轨道上进行的,对于列车通过曲线时的研究相对较少。比较而言,基于神经网络的方法更能够适应实际线路中轮轨力测量的需要。Li等<sup>[7]</sup>采用径向基函数网络实现了间接测量轮轨力,但由于网络性能的原因,该方法的测试精度还需进一步提高。Urda等<sup>[8]</sup>建立了铁路模型的试验车辆,并利用神经网络算法进行验证,1:10 的试验车辆模型在测试轨道上采用测力

\* 四川省科技计划资助项目(2023YFH0049)

收稿日期:2022-10-09;修回日期:2022-12-30

轮对直接得到的轮轨力数值与采用人工神经网络方法预测的轮轨力数值差别不大,该方法简单且计算效率较高,但未考虑各个轮对之间的内在联系。

笔者为实现脱轨系数间接测量,基于车辆上易采集信号作为网络输入信号,以基于测力轮对方法实际测得的脱轨系数为目标,采用 LSTM 网络的方法,研究不同输入信号与脱轨系数之间的相干关系,完成了通过基于输入信号对脱轨系数标签分类并对危险区域(即脱轨系数接近限值)间接测量的工作。这种先粗分标签、再对危险标签数据精细测量的方法有利于提高效率 and 实施性,适用于地铁车辆长期安全状态监测。

## 1 研究思路

图 1 为现场实测传感器布置和测力轮对安装示意图。轴箱横向和垂向振动加速度实测数据通过在测试车辆轴箱体上安装加速度传感器得到。一系悬挂垂向压缩位移量是指安装拉线位移传感器测量车辆运行时轴箱与构架之间的垂向相对位移。车体摇头角速度是在车体地板面上安装陀螺仪进行测量。车辆运行速度计算是通过安装在构架上的光电式测速传感器配合使用反光材料计算得到。脱轨系数测量通过测力轮对进行采集。

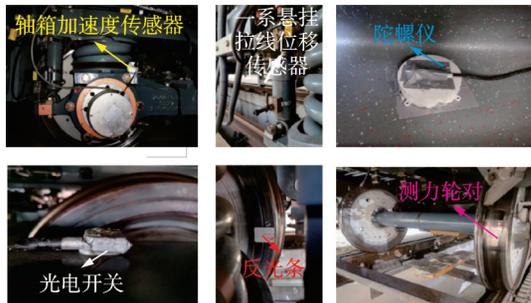


图 1 现场实测传感器布置和测力轮对安装示意图

Fig.1 Layout of sensors and installation of instrument wheelset

轮轨力测点如图 2 所示。在测力轮对左右 2 个车轮辐板上粘贴应变片,并对轮对进行标定工作。应变片以惠斯通电桥方式连接,标定获得静态标定系数,求解线性方程计算轮轨横、垂向力。按照 GB/T 5599—2019 的方法,通过轮轨横向力与轮轨垂向力之比计算得到车辆运行过程中的脱轨系数<sup>[9]</sup>。

用于 LSTM 训练的数据来源于某运营地铁车辆线路试验。表 1 为某运营地铁车辆线路试验条件。通过不同输入信号的组合,建立基于 LSTM 网络的脱轨系数标签分类模型,找到最佳输入信号组

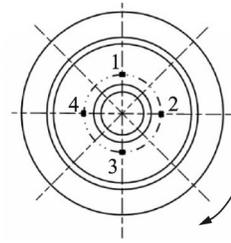


图 2 轮轨力测点

Fig.2 The measuring point of wheel-rail force

表 1 某运营地铁车辆线路试验条件

Tab.1 Test conditions for a metro line

试验条件	试验参数
线路类型	直线、曲线
列车载荷	超员载荷(AW3)
试验速度/(km·h <sup>-1</sup> )	40, 50, 60, 70, 80, 90
车辆编组	6 辆编组, 试验仪器安装在头车车辆

合方式,将标签分类出脱轨系数临近安全阈值的样本数据,采用 LSTM 网络进行训练,准确测量出脱轨系数的数值。

图 3 为脱轨系数间接测量流程图。流程包括实测数据信号的采集过程、5 种输入信号数据和脱轨系数数据的预处理过程(例如:低通滤波、平滑处理、标准化、时间域与空间域的转换、样本集的切割以及脱轨系数标签设置等)。对于 LSTM 网络,首先,确定最佳输入信号组合;其次,进行网络模型参数设置,将数据代入模型进行训练并实现粗略分类;最后,将分类得到的临近脱轨系数安全性限值的数据进行网络精细预测,在工程实际中做到较短时间内得到脱轨系数的大小,为车辆安全运行提供判定依据。

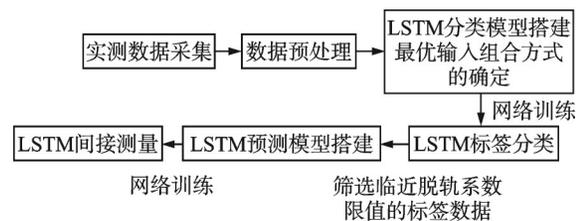


图 3 脱轨系数间接测量流程图

Fig.3 Flow chart of indirect measurement of derailment coefficient

## 2 数据预处理

实测得到的不同输入输出信号时域图如图 4 所示。由于原始的轴箱横向、垂向振动加速度,车体摇头角速度,一系悬挂垂向压缩位移量,车辆运行速度

的输入信号与脱轨系数输出信号难以直接建立相关联系,因此需要对数据进行信号预处理。实测得到的脱轨系数频带分布在 10 Hz 以内,而实测得到的不同输入信号的频带达到 2 kHz,远大于脱轨系数频带的范围。这是由于测力轮对测量轮轨垂向力和横向力采用间断法测量,通过在车轮侧表面 $0^{\circ}, 90^{\circ}, 180^{\circ}, 270^{\circ}$  4 个方向沿圆周布置应变片组成桥路,只能测出低频成分的轮轨力。由于在地铁车辆动力学试验中,车辆脱轨系数等安全性评估采用低频轮轨力足够适用,因此脱轨系数测量以及其他安全性等评定采用间断法测量是合理的<sup>[10]</sup>。为保证不同输入信号与脱轨系数的频域范围一致,以 10 Hz 作为截止频率低通滤波。

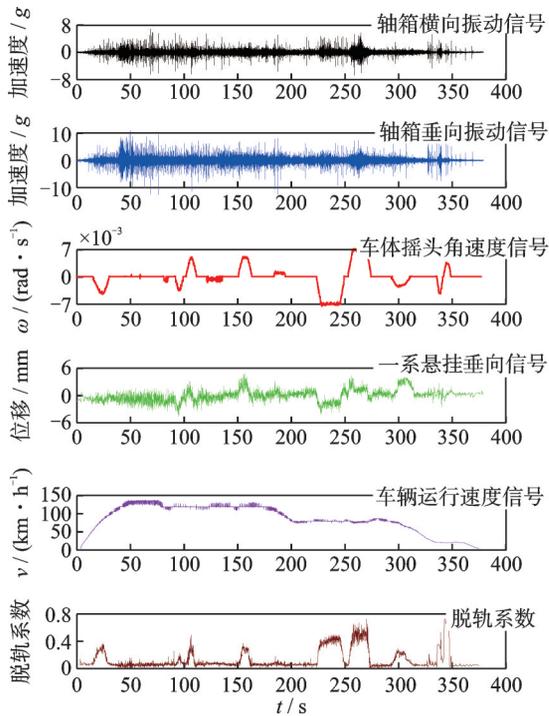


图 4 不同输入输出信号时域图

Fig.4 Time domain diagram of different input and output signals

滤波并提取幅值信号后输入信号与脱轨系数对比如图 5 所示。可见,经过低通滤波的输入信号与脱轨系数两者之间已经显示出一些相关性。

由图 5 发现,数据具有很明显的波动和毛刺,故采用平滑和标准化操作处理。经过归一化处理后的平滑和标准化数据对比如图 6 所示。在该线路上进行多次试验,得到多组数据,将所有数据进行累加拼接,同样进行上述处理操作。

地铁车辆在运行过程中速度不断变化,后期在固定时间窗口对样本分割切片时,每段分割样本位

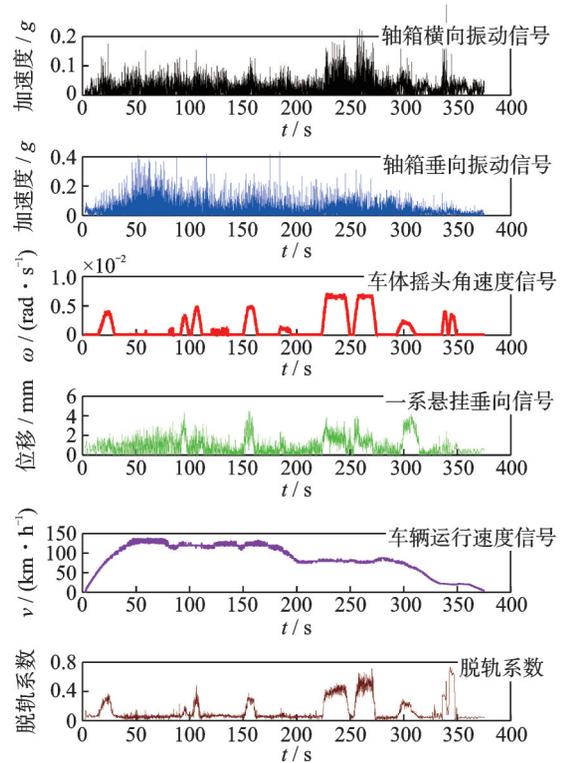


图 5 滤波并提取幅值信号后输入信号与脱轨系数对比

Fig.5 Comparison between input signal and derailment coefficient after filtering and extracting amplitude signals

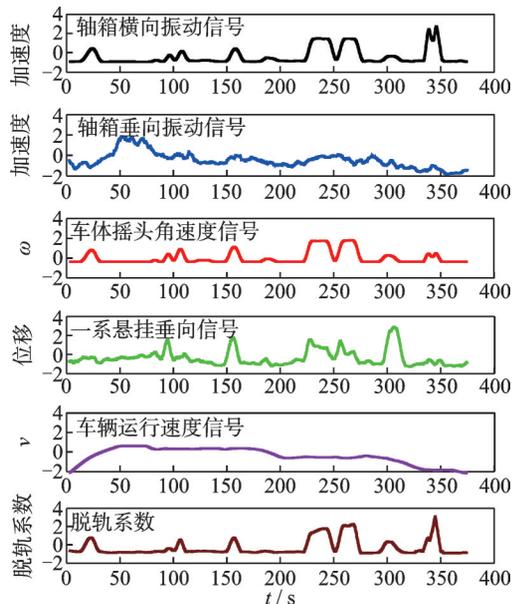


图 6 归一化处理后的平滑和标准化数据对比

Fig.6 Comparison after smoothing and standardization signals

移不同,加大了后期脱轨系数标签识别的难度。因此,笔者将不同输入信号和脱轨系数信号同时转化到位移空间,便于后期样本集切割。将地铁车辆的速度进行积分,得到位移随时间的变化关系,再将输入信号以及脱轨系数信号由时间域转化为空间域。图 7 为归一化试验样本数据随运行里程变化图。

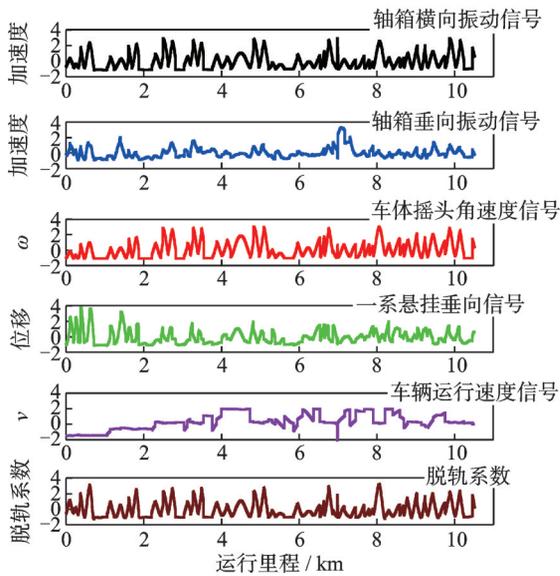
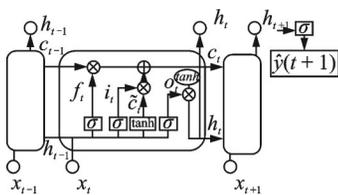


图7 归一化试验样本数据随运行里程变化图

Fig.7 Test sample data with running mileage

### 3 长短时记忆网络

实测采集的不同输入信号与脱轨系数存在相关性,又因为车辆的输入信号以及脱轨系数都是按照固定的采样间隔采集的序列型数据,因此非常适合采用循环神经网络(recurrent neural network,简称RNN)建模。由于数据空间长度大,采用传统的RNN模型存在梯度消失或者梯度爆炸等问题,故采用LSTM网络进行训练。LSTM网络能够有选择地加入新的信息,并且有选择地遗忘之前累积的信息,可有效解决简单循环神经网络存在的上述问题。长短时记忆网络结构<sup>[11]</sup>如图8所示。

图8 长短时记忆网络结构<sup>[11]</sup>Fig.8 LSTM network structure<sup>[11]</sup>

长短时记忆网络正是利用遗忘门 $f(t)$ 、输入门 $i(t)$ 、输出门 $o(t)$ 和一个内部记忆单元 $c(t)$ 一系列算法的运算,最终得到所需要的脱轨系数 $\hat{y}(t)$ 的值。

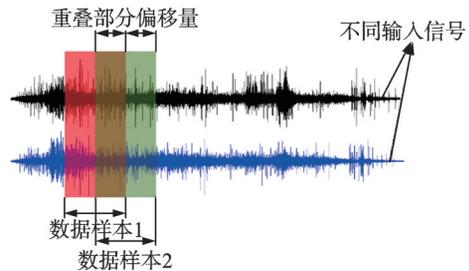
## 4 基于LSTM网络的脱轨系数间接测量方法

### 4.1 样本集预处理

#### 4.1.1 样本切割

将不同输入信号和脱轨系数信号作为试验样本

进行操作。由于不同输入信号与插值后的脱轨系数信号采样频率均为2 kHz,采集信号中包含的数据点非常多,如果直接将其作为数据输入很可能造成计算机内存不足,影响LSTM的检测速度,因此需要对数据进行分割处理,将数据切分成小段样本,每段信号作为一个样本。笔者提出了一种空间域移动窗口分割数据的方法,重叠样本分割<sup>[12]</sup>如图9所示。该方法可以扩大样本集的数量,同时防止等距采样难以提取数据全部特征信息的问题,使LSTM模型的强大学习能力更好发挥。

图9 重叠样本分割<sup>[12]</sup>Fig.9 Overlapping sample segmentation<sup>[12]</sup>

振动信号数据总长度为 $H$ ,样本长度为 $h$ ,振动信号移动量为 $w$ ,相邻两个样本之间重叠长度为 $h-w$ 。其中, $H=10\ 516\text{ m}$ 。样本长度 $h$ 的选取是由于轮轨力信号在车轮转动2周内变化不大,采用车轮2周的长度作为样本长度,分析3 983个样本数据,求得每组样本数据脱轨系数的极差,发现样本中脱轨系数平均极差值在0.01左右,变化很小,故选取2周的车轮半径(5.28 m)作为样本长度是合理的,移动量 $w=2.64\text{ m}$ 。

移动窗口分割的样本数量 $N$ 为

$$N = \left\lfloor \frac{H-h}{w} + 1 \right\rfloor \quad (1)$$

数据分割之后样本集的扩充倍数 $\alpha$ 为

$$\alpha = (h+w)/h \quad (2)$$

第 $i$ 个样本在振动信号中的位置 $x_i$ 为

$$x_i = [m(i-1):m(i+1)] \quad (i \in [1, N]) \quad (3)$$

其中: $\lfloor \cdot \rfloor$ 为向下取整; $x_i$ 为分割的样本,通过设置相应的窗口移动量 $w$ 可以得到不同的样本数据集合。

将不同的输入信号和脱轨系数采用分割方法进行处理,最终所有输入信号和脱轨系数信号均包含3 132个样本,每个样本中有1 632个数据点,即输入输出样本量均为 $3\ 132 \times 1\ 632$ 。

#### 4.1.2 脱轨系数标签设置

将采集到的3 132个脱轨系数样本数据进行特征提取以及标签的设置。笔者对每一样本内所有数

据点计算绝对均值作为特征进行提取。绝对均值是样本信号绝对值的平均值,即

$$x_{\text{mean}} = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (4)$$

其中: $N$ 为一个样本中脱轨系数数据点的个数,在本研究中 $N$ 为 1 632。

将数据样本进行绝对均值处理,可将  $3\ 132 \times 1\ 632$  的脱轨系数信号展平成  $3\ 132 \times 1$  的信号,展平后的脱轨系数信号如图 10 所示。

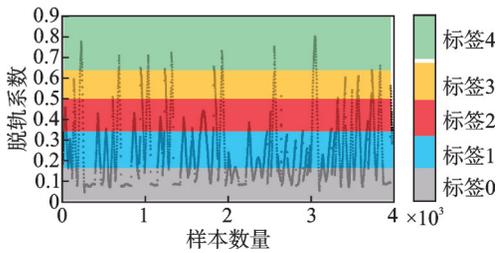


图 10 脱轨系数样本绝对均值散点图

Fig.10 Scatter chart of absolute mean of derailment coefficient

表 2 为脱轨系数样本类别标记及数量分布。将样本进行类别标记,脱轨系数在 0~0.8 的范围内等分为 5 个标签,每个标签的样本数量大致为 600 个,同时样本涵盖直线段、曲线半径分别为 300, 500, 700, 1 000, 1 200, 1 500 和 2 000 m 的小半径曲线、中等半径曲线和大半径曲线。

表 2 脱轨系数样本类别标记及数量分布

Tab.2 Derailment coefficient sample category mark and quantity distribution

脱轨系数的范围	标签	数量
0~0.16	0	650
0.16~0.32	1	624
0.32~0.48	2	628
0.48~0.64	3	629
0.64~0.80	4	601
共计		3 132

## 4.2 网络模型的搭建以及样本集的建立

### 4.2.1 网络模型的搭建

笔者通过随机搜索的方式最终确定 LSTM 网络层数以及超参数的设置。首先,设置 3 层 LSTM 网络层,激活函数采用 tanh 函数,第 1~3 层隐含单元数分别设为 128, 64 和 32,在每个 LSTM 层后面连接丢弃层;其次,连接全连接层,全连接层将输出维度转化为一维,通过 Softmax 函数输出脱轨系数标签分类结果。LSTM 模型结构如图 11 所示。

模型的训练迭代次数设置为 2 000 步,批尺寸

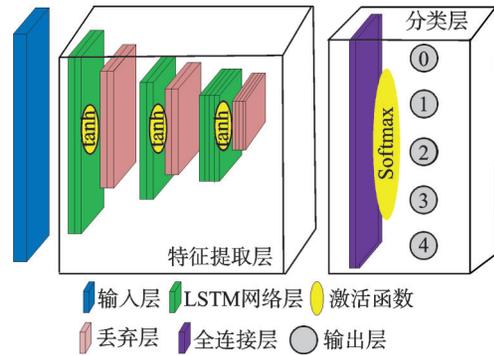


图 11 LSTM 模型结构

Fig.11 LSTM model structure

设置为 24,损失函数选择稀疏分类交叉熵损失函数。LSTM 网络前向传播得到各层误差,而优化器的作用是更新各层的网络权值参数,利用“Adam”优化器训练模型。学习速率开始为 0.001,后期衰减为 0.000 1,可以在后期捕捉局部特征细节,引入了早停法机制,避免过拟合。

### 4.2.2 样本集的建立

LSTM 网络的输入样本集为轴箱横向、垂向加速度信号 ( $\ddot{y}_w, \ddot{z}_w$ )、陀螺仪摇头角速度信号 ( $\dot{\phi}_c$ )、一系悬挂垂向压缩位移量 ( $z_{1w}$ ) 和车辆运行速度信号 ( $v_c$ ) 之间的不同组合。3 132 个样本数据对应 3 132 个脱轨系数标签,该标签的划分作为神经网络的输出。为增强 LSTM 网络的泛化能力,对样本集随机选取 70% 的数据用于训练,30% 的数据用于验证。

## 4.3 最佳输入变量的确定以及模型的训练与验证

输入变量从  $\ddot{y}_w, \ddot{z}_w, \dot{\phi}_c, z_{1w}$  以及  $v_c$  中进行选择训练,选出最优输入组合方式用于模型的训练与验证。表 3 为不同输入组合方式网络训练正确率和损失值。图 12 为不同输入组合方式正确率和损失值柱状图。可以看出,随着输入变量维度的增加,网络模型的正确率不断提高,损失函数值不断下降,标签分类的效果越好。其中,将 5 个输入维度全部作为网络输入变量时,其训练效果最好。这是由于 5 个输入变量都与脱轨系数有关系:轴箱横、垂向加速度测量轮对振动特性,能够反映轮轨横、垂向力的变化过程;一系悬挂垂向位移压缩量反映列车通过曲线过程中左右轮轨力增载和减载的过程,同样对脱轨系数有影响;车体的摇头角速度体现列车通过曲线时变化情况,当列车通过曲线时,脱轨系数的数值通常变大,引起摇头角速度的变化;速度信号与脱轨系数也有关联,通常脱轨系数较大值发生在高速的情况下居多。

采用 5 个输入数据作为样本数据,迭代 1 000

表 3 不同输入组合方式网络训练正确率和损失值

Tab.3 Accuracy and loss value of network training with different input combinations

序号	不同组合方式	训练集	验证集	训练集	验证集
		正确率/%	正确率/%	损失值	损失值
1	$\ddot{y}_w$	78.79	81.72	0.504 4	0.496 1
2	$\dot{\phi}_c$	72.01	72.91	0.712 4	0.685 4
3	$z_{tw}$	51.36	52.82	1.162 6	1.130 5
4	$\ddot{z}_w$	54.45	51.24	1.041 2	1.121 4
5	$\ddot{y}_w, \dot{\phi}_c$	87.41	85.33	0.318 6	0.380 2
6	$\ddot{y}_w, z_{tw}$	91.19	89.09	0.244 5	0.294 2
7	$\ddot{y}_w, \ddot{z}_w$	88.22	82.84	0.299 3	0.446 8
8	$\ddot{y}_w, \nu_c$	90.93	89.01	0.264 3	0.310 0
9	$\ddot{y}_w, \dot{\phi}_c, \nu_c$	94.87	94.06	0.152 5	0.215 8
10	$\ddot{y}_w, \dot{\phi}_c, \ddot{z}_w$	94.42	92.78	0.150 2	0.247 0
11	$\ddot{y}_w, \dot{\phi}_c, z_{tw}$	96.64	94.51	0.107 2	0.203 9
12	$\ddot{y}_w, z_{tw}, \dot{\phi}_c, \nu_c$	98.93	96.99	0.049 0	0.122 5
13	$\ddot{y}_w, z_{tw}, \dot{\phi}_c, \ddot{z}_w$	98.77	96.69	0.049 3	0.171 0
14	$\ddot{y}_w, \dot{\phi}_c, \nu_c, \ddot{z}_w$	96.06	94.36	0.125 9	0.184 8
15	$\ddot{y}_w, \ddot{z}_w, \dot{\phi}_c, \nu_c, z_{tw}$	99.16	98.19	0.037 3	0.085 3

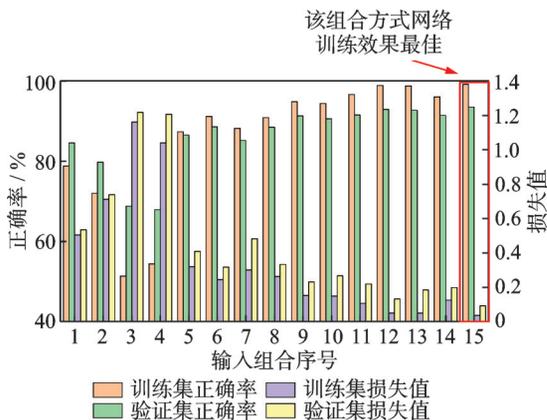


图 12 不同输入组合方式正确率和损失值柱状图

Fig.12 Bar chart of accuracy and loss values of different input combinations

次, LSTM 网络训练集和验证集正确率以及损失函数曲线如图 13, 14 所示。

可以看出, 在 LSTM 网络训练过程中, 随着迭代次数的增加, 正确率不断呈上升趋势, 损失函数值总体呈下降趋势。当迭代达到 1 000 次时, 训练集的正确率达到 98.29%, 验证集的正确率达到 98.04%, 训练集损失函数值在 0.058 左右, 验证集损失函数值在 0.098 左右。当损失函数为最小值时, 保存最优模型参数到本地, 利用该模型对测试数据集测试模型性能。

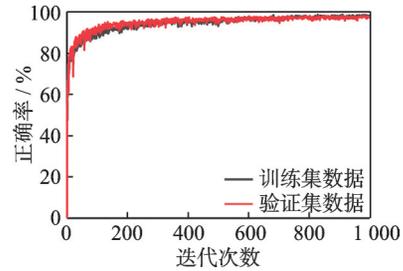


图 13 训练集和验证集正确率

Fig.13 Accuracy of training set and validation set

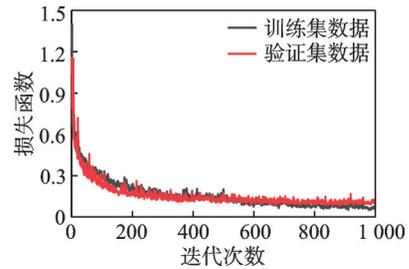


图 14 训练集和验证集损失函数曲线

Fig.14 Loss values of training set and validation set

#### 4.4 测试集数据的选取以及模型训练结果

选取另一条线路试验数据作为模型的测试数据, 该线路包含曲线半径分别为 400, 600, 800 和 1 700 m 以及直线等线路条件, 车辆运行速度涵盖 40~120 km/h, 以保证脱轨系数标签分类具有普适性和说服力。选取 1 270 个样本数据作为测试集, 对测试数据集采用混淆矩阵的方法评价模型的训练效果。测试集数据混淆矩阵如图 15 所示。混淆矩阵的每一行为实际标签, 每一列为网络预测标签。可以发现, 数据标签分类效果很好, 分布在混淆矩阵的对角线上, 说明预测标签和实际标签吻合, 极少部分预测错误的标签也预测到相邻的标签中, 其原因是相邻 2 个标签的输入数据特征不够明显, 导致网络分类错误。

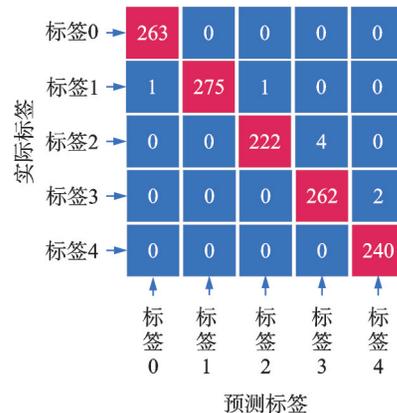


图 15 测试集数据混淆矩阵

Fig.15 Confusion matrix of test set data

除了准确率、损失函数以及混淆矩阵作为评价模型性能的指标外,针对测试集的每一类数据采用准确率、召回率以及  $F_1$  值对模型进行评价<sup>[13]</sup>。脱轨系数标签分类模型精度性能指标如表 4 所示。可以看出,脱轨系数间接测量的标签分类准确率、召回率和  $F_1$  值的平均值均在 99.30% 以上,满足脱轨系数现场实时检测的精度要求。

表 4 脱轨系数标签分类模型精度性能指标

**Fig.4 Accuracy performance index of label classification model for derailment coefficient** %

标签	类别	准确率	召回率	$F_1$ 值
0	0~0.16	99.62	100.00	99.81
1	0.16~0.32	100.00	99.28	99.64
2	0.32~0.48	99.55	98.23	98.89
3	0.48~0.64	98.50	99.24	98.87
4	0.64~0.80	99.17	100.00	99.58
平均值		99.37	99.35	99.36

**4.5 危险标签区域脱轨系数数值间接测量**

标签为“4”的数据对应脱轨系数在 0.64~0.80 之间,该部分样本数据中脱轨系数较大且接近标准 GB/T 5599-2019 中所规定的脱轨系数限值。因此,将此标签定义为车辆运行过程中最危险的区域,进一步网络训练与测量。

对于数据集的构建,按照 5:2:3 的比例构建训练集、验证集以及测试集。输入数据采用最佳输入变量的组合方式,即轴箱横向、垂向加速度、车体摇头角速度、一系悬挂垂向压缩位移量以及车辆运行速度全部作为网络的输入变量;输出数据为实际测得的脱轨系数。将训练集和验证集标签为“4”的输入数据集和输出数据提取出来,其中:训练集输入和输出变量的维度分别为  $5 \times 59\ 066$  和  $1 \times 59\ 066$ ;验证集输入和输出变量的维度分别为  $5 \times 23\ 626$  和  $1 \times 23\ 626$ 。将输入输出数据代入 LSTM 网络进行训练。使用随机搜索的方式寻找超参数最佳设置,最终设置一层网络层,隐藏单元节点数为 50,初始学习速率为 0.005,正则化系数取 0.001,当迭代达到 125 次时,学习速率降低为 0.001,添加丢弃层抑制过拟合现象,采用回归层进行脱轨系数的预测,输出类别为 1。同样采用“Adam”优化器进行模型训练以及 200 次迭代训练。LSTM 模型损失函数如图 16 所示。可以看出,迭代 200 次,训练集和验证集损失函数值不断下降,当训练到达 200 次时,训练集损失值为  $6 \times 10^{-4}$ ,验证集损失值为  $1 \times 10^{-3}$  左右。选取

测试集标签为“4”的样本数据作为测试数据进行测试,共  $5 \times 35\ 440$  个数据点代入模型中训练。

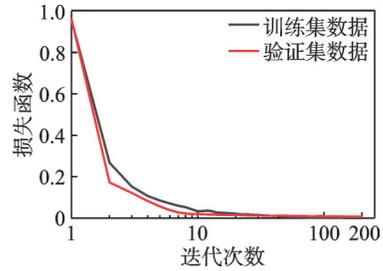


图 16 LSTM 模型损失函数

Fig.16 LSTM model loss function image

LSTM 网络测量得到的脱轨系数测量值与实际值对比如图 17 所示。可以看出:LSTM 网络可以测量出脱轨系数,更新测量的总体均方根误差  $RMSE=0.027\ 5$ ,结果接近于 0;总体相关系数  $R=0.986\ 6$ 。

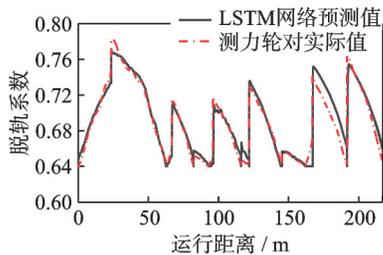


图 17 脱轨系数测量值与实际值对比

Fig.17 The derailment coefficient value and actual value

脱轨系数测量值与实际值的误差和相对误差率如图 18 所示。误差值基本在  $\pm 0.04$  之间,误差值和脱轨系数均为无量纲单位。平均相对误差率在  $\pm 8\%$  之间,该误差满足工程实际需求。

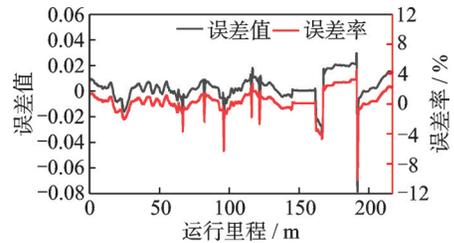


图 18 脱轨系数测量值与实际值的误差和相对误差率

Fig.18 Error value and relative error rate between measured value and actual value of derailment coefficient

通过先设置标签进行分类,找到最危险区域标签范围,再间接测量危险区域范围内脱轨系数的具体数值,可以减少网络模型的规模,提高其运行效率和实时计算速度。初筛标签分类时,测试集的训练时长仅为 4 ms 左右,再将危险区域的数据间接测量,测试集的训练时间为 52 s 左右。若直接进行脱轨系数间接测量,测试集的训练时间高达 25 min

58 s左右。可见,间接测量脱轨系数的训练时间极大缩短,效率大幅度提高,满足车辆长期服役过程中实时安全性评定以及脱轨系数间接测量的要求。

## 5 结 论

1) 通过LSTM网络预测脱轨系数标签,最终实现对脱轨系数范围精确划分。采用5种输入信号共同训练的正确率最高,损失值最小,训练集正确率达到98.29%,训练集损失函数值达到0.058;验证集正确率为98.04%,验证集损失函数值为0.098,均满足实际测量的精度要求。测试集选取不同实测线路、曲线半径及速度进行分类,基于LSTM网络进行脱轨系数标签分类的准确率、召回率以及 $F_1$ 值的平均值均在99.30%以上。

2) 筛选出脱轨系数在0.64~0.80范围内标签数据,基于LSTM网络间接测量脱轨系数网络的训练集和验证集损失值均在 $1 \times 10^{-3}$ 以下。测试集计算得到脱轨系数与实际数值的相关系数为0.986 6, RMSE为0.027 5,有利于车辆危险区域安全性评定。

3) 本研究尚未考虑轨道磨损、车轮扁疤磨耗以及车辆悬挂系统、车辆轴重等对模型的影响,此方法只是对低频轮轨力进行识别。当列车在轮轨条件恶劣的环境下运行时,将产生高频轮轨力,笔者采用的间断法测力轮对难以实现高频轮轨力的测量。

### 参考文献

- [1] 朱涛,肖守讷,阳光武,等.车辆垂向轮轨力识别方法与试验[J].振动、测试与诊断,2015,35(5):892-896. ZHU Tao, XIAO Shoune, YANG Guangwu, et al. Vertical wheel/rail force identification method for railway vehicle and its test validation[J]. Journal of Vibration, Measurement & Diagnosis, 2015, 35(5): 892-896. (in Chinese)
- [2] NORDSTROM L J L. Load identification using time domain methods[D]. Gothenburg: Chalmers University of Technology, 2003.
- [3] XIA F J, COLIN C, WOLFS P. Grey box-based inverse wagon model to predict wheel-rail contact forces from measured wagon body response[J]. Vehicle System Dynamics, 2008, 46(suppl): 469-479.
- [4] AKIRA M. A new method to measure the wheel-rail force[J]. Foreign Rolling Stock, 2013, 50(4): 30-35.
- [5] 孙善超.轨道-车辆系统轮轨力辨识及应用研究[D].北京:中国铁道科学研究院,2016.
- [6] 周亚波.基于铁道车辆振动加速度的轮轨力反演方法研究[D].成都:西南交通大学,2020.

- [7] LI Y F, LIU J X, WANG K Y, et al. Continuous measurement method of wheel/rail contact force based on neural network[C]//International conference on transportation engineering. Dalian: ICET, 2011: 2533-2537.
- [8] URDA P, ACEITUNO J F, MUÑOZ S, et al. Artificial neural networks applied to the measurement of lateral wheel-rail contact force: a comparison with a harmonic cancellation method[J]. Mechanism and Machine Theory, 2020, 153: 103968.
- [9] 国家市场监督管理总局,国家标准化管理委员会.GB/T 5599—2019 机车车辆动力学性能评定及试验鉴定规范[S].北京:中国标准出版社,2019.
- [10] 温泽峰,金学松.非稳态载荷下轮轨滚动接触及其钢轨波磨研究[J].摩擦学学报,2007,27(3):252-258. WEN Zefeng, JIN Xuesong. Analysis of rolling contact and rail corrugation under non-steady state loading[J]. Tribology, 2007, 27(3): 252-258. (in Chinese)
- [11] 王玉静,李少鹏,康守强,等.结合CNN和LSTM的滚动轴承剩余使用寿命预测方法[J].振动、测试与诊断,2021,41(3):439-446. WANG Yujing, LI Shaopeng, KANG Shouqiang, et al. Method of predicting remaining useful life of rolling bearing combining CNN and LSTM[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(3): 439-446. (in Chinese)
- [12] 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. (in Chinese)
- [13] 吴耀春,赵荣珍,靳伍银,等.面向数据不平衡的卷积神经网络故障辨识方法[J].振动、测试与诊断,2022,42(2):299-307. WU Yaochun, ZHAO Rongzhen, JIN Wuyin, et al. Intelligent fault identification method based on convolutional neural network for imbalanced data[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2): 299-307. (in Chinese)



**第一作者简介:**孙昭意,男,1997年8月生,硕士生。主要研究方向为轨道车辆系统动力学及动态检测技术。  
E-mail:sunzy15176123386@163.com