

基于振动响应与卷积长短期记忆模型的路基沉降智能识别

张 驰¹, 李 冲¹, 何文龙²

¹内蒙古大学交通学院, 内蒙古 呼和浩特

²天津职业技术师范大学汽车与交通学院, 天津

收稿日期: 2026年8月21日; 录用日期: 2026年9月12日; 发布日期: 2026年9月22日

摘 要

路基不均匀沉降是诱发无砟轨道结构变形、影响高速列车运行安全与平稳性的核心病害。针对传统路基沉降监测方法效率偏低、成本较高、难以实现全天候实时精准评估的技术短板, 本文提出一种基于CNN-LSTM混合神经网络的无砟轨道路基沉降智能识别方法。以CRTS II型双块式无砟轨道为研究载体, 搭建车辆-轨道-路基垂向耦合动力学仿真模型, 系统分析不同沉降病害工况下高速列车车辆系统的动力振动响应规律。通过多工况动力响应数据对比分析, 筛选出车体垂向加速度、车体点头角速度、钢轨垂向位移等对路基沉降高度敏感的核心特征参数。融合CNN特征提取优势与LSTM时序数据拟合能力, 构建路基沉降状态智能识别模型, 完成不同沉降工况的精准识别与分类, 并通过仿真试验验证模型的有效性与稳定性。试验结果表明, 所构建的CNN-LSTM识别模型整体准确率可达99.26%, 能够精准、高效地识别无砟轨道路基沉降病害状态, 可为高速铁路路基沉降智能化监测、病害预警及运维整治提供全新的技术支撑。

关键词

CNN-LSTM, 动力学仿真, 沉降识别, 振动响应

Intelligent Identification of Subgrade Settlement Based on Vibration Responses and a Convolutional Long Short-Term Memory Model

Chi Zhang¹, Chong Li¹, Wenlong He²

¹Transportation Institute of Inner Mongolia University, Hohhot Inner Mongolia

²Automobile and Transportation School of Tianjin University of Technology and Education, Tianjin

文章引用: 张驰, 李冲, 何文龙. 基于振动响应与卷积长短期记忆模型的路基沉降智能识别[J]. 动力系统与控制, 2026, 15(4): 347-360. DOI: 10.12677/dsc.2026.154035

Abstract

Uneven subgrade settlement is a critical form of deterioration that induces structural deformation of ballastless tracks and affects the operational safety and ride comfort of high-speed trains. To address the limitations of conventional subgrade settlement monitoring methods, such as low efficiency, high cost, and the difficulty of achieving real-time, accurate, and all-weather assessment, this study proposes an intelligent identification method for ballastless track subgrade settlement based on a CNN-LSTM hybrid neural network. Taking the CRTS II double-block ballastless track as the research object, a vertical coupled vehicle-track-subgrade dynamic model is established to systematically investigate the dynamic vibration response characteristics of the high-speed train vehicle system under different subgrade settlement conditions. Through comparative analysis of dynamic response data under multiple operating conditions, key feature parameters that are highly sensitive to subgrade settlement, including car-body vertical acceleration, car-body pitching angular velocity, and rail vertical displacement, are identified. By integrating the feature extraction capability of CNNs with the time-series data fitting capability of LSTMs, an intelligent subgrade settlement state identification model is developed to accurately identify and classify different settlement conditions. The effectiveness and stability of the proposed model are further validated through numerical simulation experiments. The results demonstrate that the proposed CNN-LSTM identification model achieves an overall accuracy of 99.26%, enabling accurate and efficient identification of ballastless track subgrade settlement conditions. The proposed method can provide new technical support for intelligent monitoring, early warning, and maintenance of subgrade settlement in high-speed railways.

Keywords

CNN-LSTM, Dynamic Simulation, Settlement Identification, Vibration Response

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着高速铁路从“大规模建设”转向“长期运营”，既有运维体系面临严峻挑战。路基作为铁路工程的基础结构层，在列车循环荷载与环境因素(如温度变化)的耦合作用下易发生不均匀沉降。无砟轨道刚度较高，易与路基产生非协调变形并诱发沉降，从而改变轨道几何形态，加剧轨道不平顺，影响列车运行的平稳性和安全性[1]。若不及时处理，将加速轨道结构劣化、增加维护成本，甚至可能诱发重大安全事故。因此，实现路基沉降的实时监测与精准识别具有重要工程意义[2]。

现有检测技术在精度、效率与智能化方面仍有不足。围绕沉降作用下车辆-轨道-路基耦合动力学，国内外学者开展了大量研究。裴国史[3]利用时间序列分析、神经网络模式识别、BP神经网络和径向基函数四种方法，以车辆动力响应识别谐波型几何不平顺波形；彭飞等[4]以车辆动态响应为输入，提出多源车载数据驱动的智能识别方法，用于轨道垂向与横向不平顺识别；孙宪夫等[5]建立并验证车轨耦合模型，确定高速下轨道不平顺敏感波长，建议400 km/h检测长波截止波长不小于150 m，并经实测验证。设计捷联惯性检测系统，实车试验满足高速检测要求；石慧等[6]建立车辆-轨道耦合模型，获取不同CA砂

浆脱空工况下的车辆动力响应，结合 PSO-SVM 与模型融合算法识别脱空长度与宽度；陈宪麦等[7]采用非线性弹簧模拟 CA 砂浆脱空，利用一维卷积神经网络(1D-CNN)识别脱空位置；Ren 等[8]建立车辆 - 轨道 - 路基垂向耦合模型，结合特征提取与 SVM、CNN，识别扣件失效、路基沉降等多种病害；Xu 等[9]选用车体垂向加速度、构架加速度及轮对加速度，通过 1D-CNN 识别无砟轨道路基不均匀沉降；Li 等[10]提出 CNN-LSTM 深度学习模型，通过分析车辆 - 轨道动态响应数据，实现路基不均匀沉降的精准识别；高建敏等[11]以钢轨垂向振动加速度为输入，采用 BP 神经网络识别损伤位置与离缝程度；杨文等[12]融合 AI 与计算机视觉，构建混合注意力机制的重载钢轨伤损识别系统，结合随机森林分类，有效提升探伤精度与效率。但受数据与场景限制，误报率及特殊伤损识别仍有优化空间。




Figure 1. Technical roadmap
图 1. 技术路线图

此外，研究通过在轨枕、钢轨或轨道板上安装传感器获取振动信号，直接利用轨道结构振动响应进行

病害诊断。田秀淑等[13]采用落锤冲击下的轨道板速度 - 导纳响应, 基于“三指标” 阈值模型识别砂浆层脱空位置与长度; 李自法等[14]通过拾音器采集列车通过时的声音信号, 结合梯度回归树算法识别脱空损伤; 任娟娟等[15]基于车辆 - 轨道耦合动力学模型提取损伤特征, 经主成分分析降维后输入 PSO-SVM 模型实现脱空识别; 侯博文等[16]针对扣件失效问题, 提出脉冲激励下钢轨振动响应的识别算法, 并在京沈高铁完成验证; 刘潇等[17]利用一维卷积神经网络分析钢轨与道床振动加速度的时频特征, 建立四种病害识别模型; 华莉等[18]以轨枕振动信号为输入, 采用变分模态分解、多尺度排列熵与 BP 神经网络进行病害识别。

近期研究(如 Ren 等[8]与 Xu 等[9])已尝试利用车辆动力响应进行路基沉降检测, 但车体动态响应存在时滞与信号干扰问题, 单一系统难以全面表征高速列车运行状态。此外, Xu 等[9]未考虑随机轨道不平顺, 方法上侧重于空间波形特征, 忽略了路基沉降的时空关联特性。为此, 本研究融合随机不平顺条件下的车辆与轨道振动响应, 构建混合 CNN-LSTM 模型以提取时空特征, 实现更稳健、精准的不均匀路基沉降识别。如图 1 所示, 该模型通过联合训练车辆与轨道振动数据, 有效提升了沉降识别的性能。

2. 建立考虑路基沉降影响下的车辆 - 轨道 - 路基耦合模型

在高速铁路无砟轨道体系中, 车辆、轨道与路基构成一个高度耦合且相互作用的复杂动力学系统。路基作为轨道结构的主要承载层, 其不均匀沉降会改变轨道的几何形态, 进而降低列车运行的平顺性与安全性, 加速轨道结构劣化。因此, 为了准确评估无砟轨道在沉降工况下的服役性能, 本文通过 MATLAB 软件建立反映路基沉降作用机制的高速铁路 - 无砟轨道 - 路基耦合动力学模型。其总体结构如图 2 所示。




Figure 2. Vehicle-track-subgrade coupled system
图 2. 车辆 - 轨道 - 路基耦合图

车辆、无砟轨道及路基的关键参数详见表 1。

Table 1. Basic parameters of the vehicle, ballastless track, and subgrade
表 1. 车辆、无砟轨道、路基的基本参数

轨道参数/单位	取值	车辆参数/单位	取值
钢轨弹性模量	$2.059 \times 10^{11} \text{ Pa}$	车体质量	33,766 kg
钢轨截面惯性矩	$3.217 \times 10^{-5} \text{ m}^4$	转向架质量	2400 kg

续表

钢轨每延米质量	60.64 kg	轮对质量	1850 kg
扣件间距	0.65 m	轴距	2.5 m
扣件垂向刚度	2.5×10^7 N/m	车辆定距	17.5 m
道床板密度	2500 kg/m^3	车体点头转动惯量	$1.6545 \times 10^6 \text{ kg/m}^2$
道床板弹性模量	3.6×10^{10} Pa	转向架点头转动惯量	$1.314 \times 10^3 \text{ kg/m}^2$
道床板界面尺寸	0.728 m	一系悬挂刚度	2.352×10^6 N/m
支承层密度	2500 kg/m^3	一系悬挂阻尼	$2 \times 10^4 \text{ N*s/m}$
支承层弹性模量	2.55×10^{10} Pa	二系悬挂刚度	0.52×10^6 N/m
支承层截面尺寸	0.588 m	二系悬挂阻尼	$2.4 \times 10^5 \text{ N*s/m}$
路基支承刚度	$1.9 \times 10^8 \text{ Pa/m}$	车轮滚动圆半径	0.43 m

基于 Guo 等人[19]所述的方法, 不均匀路基沉降采用单波余弦函数进行建模, 曲线表达式如式(1)所示。

$$Z_0(x) = \frac{A}{2} \left(1 - \cos\left(\frac{2\pi x}{l}\right) \right) \quad (1)$$

式中, Z_0 为路基沉降量, x 为路基位置的坐标, A 为路基沉降幅值, l 为路基沉降波长。

本研究仅针对沿线路纵向的路基不均匀沉降现象展开分析, 并假设路基在横向方向上的沉降分布为均匀状态。在模型中, 钢轨被简化为两端简支的欧拉梁, 而扣件和路基则通过离散支承的弹簧-阻尼系统进行模拟。其中, 钢轨的振动模态函数用 $Y_h(x_i)$ 表示, 钢轨的振动特性基于简支梁的振型函数, 其具体表达式如式(2)所示。

$$Y_h(x_i) = \sqrt{\frac{2}{m_r l}} \sin\left(\frac{k\pi x}{l}\right) \quad (2)$$

使用阶梯函数 H_b 表示各时刻轨道与路基的接触状态, 当轨道垂向位移 $Z_b(x_i, t)$ 大于路基位移 $Z_0(x_i)$ 时接触, 小于时脱空, 接触函数值为 0, 表达式如(3)所示。

$$H_b(x_i) = \begin{cases} 1, & \text{for } Z_b(x_i, t) > Z_0(x_i) \text{ (接触)} \\ 0, & \text{for } Z_b(x_i, t) \leq Z_0(x_i) \text{ (脱空)} \end{cases} \quad (3)$$

为实现微分方程组高精度与高效求解, 本文选用翟氏法快速显式积分方案[20]。该方法简化常规数值积分流程, 将求解问题纳入递归矩阵运算框架, 结合自适应时间步长调控与实时动态反馈, 搭建适配实时监测的反馈体系, 兼顾计算精度、稳定性与效率, 适用于在线实时仿真及复杂动态系统分析。

3. 路基沉降作用下识别样本准备

3.1. 数据获取

本研究所用数据来源于建立的车辆-轨道-路基耦合动力学数值仿真模型。为保证研究结果的代表性与工程适用性, 选取我国高速铁路典型车型 CRH380A 作为研究对象, 列车运行速度设定为 350 km/h, 以反映高速运行条件下的动力学特征。轨道不平顺激励依据中国高速铁路不平顺谱生成, 以较为真实地再现列车运行过程中的轨道激励环境。

在沉降工况设计中，采用余弦函数形式模拟路基不均匀沉降的空间分布特征，并同时考虑沉降波长与幅值的联合影响。波长范围设定为 10~30 m，幅值范围为 10~20 mm，通过不同参数组合共构建 9 种典型沉降工况，以覆盖实际运营中可能出现的沉降情形。针对每种工况，均生成 200 个模拟样本，共计获得 1800 个路基沉降样本。完整数据集按 7:3 的比例随机划分为训练集和测试集。各工况参数组合见表 2。

Table 2. Case settings
表 2. 工况设置表

工况	沉降波长和幅值	工况	沉降波长和幅值	工况	沉降波长和幅值
1	10 m, 10 mm	4	20 m, 10 mm	7	30 m, 10 mm
2	10 m, 15 mm	5	20 m, 15 mm	8	30 m, 15 mm
3	10 m, 20 mm	6	20 m, 20 mm	9	30 m, 20 mm

3.2. 相关性分析

从车辆系统和轨道系统中筛选敏感的动力响应指标，对于准确识别路基沉降至关重要。为此，本文通过相关性分析评估了多个关键参数之间的关联性，包括车辆垂直加速度(V)、点头角速度(N)、转向架框架加速度(F)、轮对加速度(W)、钢轨位移(D)以及路基沉降量(S)。车辆振动响应数据采集自列车前端段，轨道振动数据则从余弦形沉降曲线的最低点提取。相关性分析结果如图 3 所示。




Figure 3. Correlation analysis of subgrade settlement
图 3. 路基沉降相关分析图

已有文献规定[10]相关系数大于 0.7 通常被视为具有强关联性的标志。本文研究计算得出，路基沉降与车辆垂直加速度、点头角速度及钢轨位移之间的相关系数分别为 0.86、0.83 和 0.71。因此，将垂向加速度、点头角速度及钢轨位移选定为构建多源数据融合模型的敏感性指标。

3.3. 不同沉降工况下车辆与轨道动力响应指标可视化

基于上述仿真参数与沉降工况设定，开展多组动力学仿真计算。在沉降波长保持 20 m 不变的条件

下,分析不同沉降幅值(0~20 mm)对应的车体垂向加速度、车体点头角速度及钢轨位移时程响应,其中 0 m~0 mm 表示无路基沉降工况;同时,在沉降幅值保持 20 mm 不变的条件下,分析不同沉降波长(0~30 m)下各动力响应指标的变化规律,结果分别见图 4 和图 5。

随着路基沉降幅值增大,车体垂向加速度、点头角速度及钢轨位移的峰值均呈明显增加趋势。其中,车体垂向加速度对沉降幅值变化最为敏感,响应幅值增长最为显著;点头角速度同样表现出较好的变化规律,但响应增幅略低于车体垂向加速度;钢轨位移则随沉降幅值增加逐渐增大,其变化能够直接反映轨道结构受沉降影响后的变形特征。这表明,沉降幅值的增加会加剧车辆-轨道系统的动力响应,使不同沉降工况对应的动力学特征差异更加明显。

在沉降幅值保持不变的情况下,沉降波长同样对车辆-轨道动力响应具有显著影响。随着沉降波长变化,各动力响应指标的时程波形及峰值均发生不同程度变化。其中,较短波长沉降会导致车辆系统受到更为剧烈的激励,响应波动更加明显;随着波长增加,车辆及轨道动力响应逐渐趋于平缓,但仍保持较好的规律性变化。这说明,沉降波长不仅影响车辆振动强度,同时还改变了动力响应信号的时域特征。

综上所述,车体垂向加速度、点头角速度及钢轨位移均能够较好地表征路基沉降幅值和波长变化所引起的动力学差异,不同沉降工况下的响应信号在峰值大小、波形特征及时间历程等方面均存在一定差异,具有良好的可区分性。因此,选取上述三种动力响应作为 CNN-LSTM 模型的输入特征,能够为后续多源特征学习及路基沉降状态识别提供可靠的数据基础。




Figure 4. Analysis of vehicle body vibration responses under different amplitudes at the same wavelength
图 4. 相同波长不同幅值车体振动响应分析




Figure 5. Analysis of vehicle body vibration responses under different wavelengths at the same amplitude
图 5. 相同幅值不同波长车体振动响应分析

4. CNN-LSTM 网络结构设计

4.1. CNN 网络




Figure 6. CNN architecture
图 6. CNN 网络结构图

卷积神经网络(CNN)主要由输入层、卷积层、池化层、全连接层及输出层构建而成。每个层的功能更不相同,卷积层通过滤波器对输入数据进行滑动卷积操作,提取局部特征并生成高维特征图;池化层则通过对卷积层的输出进行降采样,同时保留重要的特征;全连接层将池化层的输出展开成一维向量,进行分类或回归任务。CNN模型通过这些网络层获取有效信息,自动生成数据的特征向量,减少了特征提取和数据重构的难度,提升了数据特征的质量。其结构如图6所示。

卷积运算的数学表达式如式(4)所示。

$$X_i^l = f(W_i^l * X^{(l-1)} + b_i^l) \quad (4)$$

式中: X_i^l 表示第 l 层的输出值的第 i 个特征; W_i^l 表示第 l 层的输出值的第 i 个卷积核的权重矩阵; $*$ 运算符表示卷积运算; $X^{(l-1)}$ 为第 $(l-1)$ 层的输出; b_i^l 表示偏置项; 函数 f 表示输出的激活函数。

池化层则主要用于数据体空间尺寸的缩减,有效减少了模型参数的数量,进而降低了网络计算的复杂。在池化函数的选择上,本文采用最大池化函数,以保留特征图的关键信息并减少噪声的干扰。其表达式如(5)所示。

$$P = \max_w \{A^l\} \quad (5)$$

式中: l 为特征数据宽度, A 为输出的特征矩阵, w 为池化核尺寸, P 为池化后特征矩阵。

全连接层与输出层共同完成卷积神经网的分类任务。全连接层将卷积层和池化层提取的局部特征进行整合与映射,并将处理后的信息传递至输出层。输出层基于这些信息进行类别判断,生成最终的分类结果。

4.2. LSTM 网络

LSTM 网络本质上是一种全连接神经网络,通过引入自循环反馈机制与记忆单元,能够高效处理时序数据。其结构基于循环神经网络(RNN)框架,利用循环连接实现序列数据的处理与上下文依赖关系的捕捉。与传统 RNN 相比, LSTM 专门针对梯度消失与梯度爆炸问题进行了优化,因而具备更强的长期时序依赖建模能力。网络结构如图7所示。每个 LSTM 单元由遗忘门、输入门和输出门三部分构成,通过门控机制实现对信息的选择性更新、保留与遗忘。其中,遗忘门使用 Sigmoid 函数决定前一细胞状态的保留程度;输入门结合当前输入与上一隐藏状态生成候选细胞状态,用于更新记忆;输出门则对更新后的细胞状态进行非线性变换,生成当前隐藏状态。LSTM 的运行流程如下:遗忘门调整前一细胞状态,输入门生成候选状态并完成记忆更新,输出门确定传递至下一步的记忆比例。该网络通常采用时序反向传播算法进行训练,该算法是标准反向传播在时间维度上的扩展,通过梯度计算对网络内部参数进行优化。其数学表达式见公式(6)。

$$\begin{cases} f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \\ C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \\ o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \\ h_t = o_t \times \tanh(C_t) \end{cases} \quad (6)$$

其中, f_t 、 i_t 、 o_t 分别为门控计算结果, σ 与 $\tanh$ 为激活函数, W_t 是门控结构的权重矩阵, b 为偏置变量, W_o 表示权重矩阵, h 为 LSTM 的输出结果, C_t 为记忆单元状态, $\tilde{C}_t$ 为候选状态。




Figure 7. LSTM neuron structure
图 7. LSTM 神经元结构

4.3. 模型参数及超参数设置

表 3 为本文构建的 CNN-LSTM 混合网络模型参数, 模型由卷积特征提取、时序建模与全连接分类三模块组成。其中特征提取阶段包含三层一维卷积和两层池化, 第一层用 64 个 3×1 卷积核(步长 1×1)进行初始编码, 捕获整体特征; 第二、三层连续堆叠, 卷积核尺寸均为 3×1 , 第三层步长调整为 2×1 、核数增至 128, 实现特征逐层细化与抽象, 增强模型对故障细微特征的识别能力。

Table 3. Structural parameter settings of the CNN-LSTM model
表 3. CNN-LSTM 模型结构参数设定

编号	网络层	卷积核大小	步长	数目
1	卷积层 1	3×1	1×1	64
2	池化层 1	2×1	2×1	—
3	卷积层 2	3×1	1×1	64
4	卷积层 3	3×1	2×1	128
5	池化层 2	2×1	2×1	—
6	LSTM	—	—	100
7	全连接层 1	—	—	128
8	全连接层 2	—	—	32

输入层的输入数据为列车通过模拟沉降区域过程中采集的时序振动响应数据, 其数据长度对应于该运行过程的时间序列长度 5144×1 , 为降低特征维度并提升鲁棒性, 在第一、三卷积层后分别引入最大池化(核大小与步长均为 2×1)。卷积输出经 reshape 后输入含 100 个神经元的 LSTM 层, 通过门控机制提取时序动态特征。随后, 将 LSTM 输出的时序特征输入由 128 个和 32 个神经元组成的两层全连接网络, 通过逐级映射实现高层特征融合与维度压缩。为降低模型过拟合风险, 在全连接层之间引入 Dropout 正则化。最终, 通过 Softmax 分类器输出不同路基沉降工况对应的类别概率, 并根据最大概率确定模型的最终识别结果。

模型训练过程中采用交叉熵损失函数衡量预测结果与真实标签之间的差异, 并以损失函数作为模型

参数优化的重要依据。通过反向传播算法不断更新网络权重，使模型逐步学习不同路基沉降工况与车辆振动响应特征之间的非线性映射关系。模型训练所采用的主要超参数设置如表 4 所示。

Table 4. Hyperparameter settings of the CNN-LSTM model

表 4. CNN-LSTM 模型超参数设置

实验参数	设置值
学习率	0.001
激活函数	Relu
训练次数	200
分类器函数	softmax
优化器	adam
批大小	64

5. 基于 CNN-LSTM 路基沉降识别

5.1. 数据归一化处理

为提高算法的计算效率、降低模型训练的复杂度并加速网络收敛，本文对数据特征中的两个车体动力学响应变量进行了归一化处理。由于其量纲和物理意义不同，为提高算法的计算效率、降低模型训练的复杂度并加速网络收敛，需对数据进行归一化处理。本文采用 min-max 标准化方法，将车体垂向加速度和点头角速度的数值线性映射到[0, 1]区间内，其数学表达式为(7)所示：

$$x'_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (7)$$

式中： x_i 表示原始数据； x_i 中的最小值 $\min(x)$ ；最大值 $\max(x)$ ； x'_i 表示归一后的新数据。

5.2. 评价指标

为了验证 CNN-LSTM 模型的可靠性，本研究采用了准确率(Accuracy)、精确率(Precision)和召回率(Recall)三个性能评估指标。准确率 A 衡量的是模型正确分类样本的比例，精确率 P 评估的是模型预测正类的准确性，而召回率 R 则反映了模型识别正类样本的能力。这些指标共同为模型的分类性能提供了全面的评估。他们的表达式如(8)~(10)。

$$A = \frac{TP + TN}{TP + FP + FN + TN} \quad (8)$$

$$P = \frac{TP}{TP + FP} \quad (9)$$

$$R = \frac{TP}{TP + FN} \quad (10)$$

式中： TP 表示模型正确识别出的特定类别的样本数， FP 代表错误地将其他类别样本识别为某一特定类别的数目。 FN 模型未能识别出真正属于某一类别的样本数， TN 对每个类别来说，是模型正确识别为非该类别的样本总数。

5.3. 仿真结果分析

在本研究中, 基于 CNN-LSTM 混合神经网络的智能识别模型, 用于对九种典型路基沉降工况进行分类。训练过程如图 8(a)所示: 分类准确率曲线表明, 经过 200 个训练周期后, 模型在测试集上达到了 99.26% 的最终识别准确率, 展现出卓越的特征提取与模式识别能力。图 8(b)所示的损失函数曲线快速收敛并稳定在较好水平, 表明模型预测输出与真实标签之间具有高度一致性。以上结果充分验证了该模型在联合提取关键时空特征方面的有效性, 凸显了其在路基沉降识别中高效性与可靠性并重的优势特征。




Figure 8. CNN-LSTM identification results
图 8. CNN-LSTM 识别结果

5.4. 总指标可视化对比与模型综合性能分析




Figure 9. Comparison of overall identification performance of different models
图 9. 不同模型识别总性能对比

尽管分类别评价能够反映模型在不同沉降工况下的识别差异,但从工程应用角度出发,整体识别效果更能够体现模型在多工况条件下的综合判别能力与稳定性。图 7 给出了 CNN、LSTM 与 CNN-LSTM 三种模型在 9 类路基不均匀沉降工况下的整体识别性能对比结果,包括精确率、召回率及 F1 值。

如图 9 所示, CNN、LSTM 与 CNN-LSTM 三种模型的精确率、召回率及 F1 值差异较小,均能稳定完成路基不均匀沉降识别任务,说明数据集与评价体系合理,模型训练稳定性良好。其中, CNN-LSTM 模型在三项指标上均达 0.996 左右,综合性能最优; LSTM 次之,指标值降低约 2 个百分点; CNN 相对最低,降低约 4 个百分点。该差异主要源于网络结构的特征融合机制: CNN 模块提取振动信号中的局部空间特征, LSTM 模块建模时序依赖关系,二者结合实现了对时-空关联特征的联合学习。综上, CNN-LSTM 混合网络在识别精度、稳定性和特征学习能力上均表现更优,有效克服了单一模型在复杂动力响应特征建模中的局限性,为后续模型鲁棒性与泛化能力分析奠定了基础。

6. 结论

(1) 基于车辆-轨道-路基耦合动力学模型,系统分析了不同路基沉降工况对车体与轨道动力响应特征的影响规律。通过相关性分析评估了多个关键参数之间的关联性,筛选出车体垂向加速度、点头角速度及钢轨位移作为沉降识别的敏感特征,可作为网络模型的输入。

(2) 考虑到路基沉降为非线性时序特征,本文提出了一种基于 CNN-LSTM 的路基沉降识别方法。该方法充分结合卷积神经网络(CNN)与长短期记忆网络(LSTM)的优势。实验结果表明,该方法对路基沉降的识别精度达到 99.26%,验证了所提模型的有效性与优越性。

(3) 从对比结果来看, CNN-LSTM 模型在精确率、召回率及 F1 值三项整体评价指标上均保持最优水平,三项指标均达到 0.996 左右; LSTM 模型次之,各项指标较 CNN-LSTM 降低约 2 个百分点; CNN 模型识别效果相对最低,较 CNN-LSTM 降低约 4 个百分点。这一优势主要源于 CNN-LSTM 模型有效融合了 CNN 对局部空间特征与 LSTM 对时序依赖关系的联合建模能力,克服了单一模型在复杂动力响应特征学习中的局限性。

尽管本文提出的 CNN-LSTM 路基沉降识别方法在数值仿真条件下取得了较高的识别精度,但仍存在进一步改进的空间。本文研究主要基于仿真数据,后续研究可引入实际线路监测数据,对模型在复杂服役环境下的泛化能力与鲁棒性进行进一步验证与提升。同时,针对列车速度变化、轨道长期劣化及环境扰动等复杂工况对识别性能的影响,未来可开展跨工况与非同分布条件下的系统性验证,以全面评估模型的泛化能力与鲁棒性。

基金项目

国家自然科学基金(52502533)、天津市自然科学基金(25JCQNJC00050)、内蒙古自治区自然科学基金(2024MS05035)。

参考文献

- [1] Guo, Y. and Zhai, W.M. (2018) Long-Term Prediction of Track Geometry Degradation in High-Speed Vehicle-Ballastless Track System Due to Differential Subgrade Settlement. *Soil Dynamics and Earthquake Engineering*, **113**, 1-11. <https://doi.org/10.1016/j.soildyn.2018.05.024>
- [2] Zhang, K.P., Zhang, X.H. and Zhou, S.H. (2021) Effect of Lateral Differential Settlement of High-Speed Railway Subgrade on Dynamic Response of Vehicle-Track Coupling Systems. *Structural Engineering and Mechanics*, **80**, 491-501.
- [3] 裴国史. 基于神经网络与车辆系统动力响应特征的高速铁路谐波型几何不平顺识别研究[D]: [硕士学位论文]. 成都: 西南交通大学, 2018.
- [4] 彭飞, 谢清林, 陶功权, 等. 多源车载数据驱动的地铁轨道不平顺智能识别方法[J]. 中南大学学报(自然科学版),

- 2024, 55(6): 2432-2445.
- [5] 孙宪夫, 陈仕明, 孙加林, 等. 400 km/h 高速铁路轨道动态不平顺检测关键技术[J]. 中国铁路, 2025(6): 51-58.
- [6] 石慧. 无砟轨道 CA 砂浆脱空智能感知算法研究[D]: [博士学位论文]. 北京: 北京交通大学, 2019.
- [7] 陈宪麦, 李鑫海, 徐磊, 等. 基于 1D-CNN 的无砟轨道 CA 砂浆脱空识别[J]. 铁道科学与工程学报, 2024, 21(4): 1645-1655.
- [8] Ren, J.J., Liu, W., Du, W., et al. (2023) Identification Method for Subgrade Settlement of Ballastless Track Based on Vehicle Vibration Signals and Machine Learning. *Construction and Building Materials*, **369**, Article 130573. <https://doi.org/10.1016/j.conbuildmat.2023.130573>
- [9] Xu, W.Q., Guo, Y. and You, M.X. (2024) Intelligent Identification of Differential Subgrade Settlement of Ballastless Track System Based on Vehicle Dynamic Responses and 1D-CNN Approach. *Transportation Geotechnics*, **48**, Article 101302. <https://doi.org/10.1016/j.trgeo.2024.101302>
- [10] Li, C. and Guo, Y. (2025) Intelligent Identification of Ballastless Track Subgrade Settlement Based on Vehicle-Rail Vibration Data. *Scientific Reports*, **15**, Article No. 23288. <https://doi.org/10.1038/s41598-025-05202-x>
- [11] 高建敏, 金忠凯. 基于 BP 神经网络的高速铁路无砟轨道砂浆层离缝损伤识别[J]. 铁道学报, 2022, 44(7): 135-144.
- [12] 杨文, 郭江龙, 李建友, 等. 基于混合注意力机制的重载钢轨伤损智能识别系统[J]. 中国铁路, 2025(10): 114-122.
- [13] 田秀淑, 杜彦良, 赵维刚. 基于瞬态冲击响应特性的无砟轨道砂浆层脱空的检测和识别[J]. 振动与冲击, 2019, 38(18): 148-153.
- [14] 李自法, 谢维波, 刘涛. 一种基于 GBRT 算法的 CA 砂浆脱空检测方法[J]. 铁道科学与工程学报, 2018, 15(2): 292-301.
- [15] 任娟娟, 杜威, 叶文龙, 等. 基于 PSO-SVM 的板式无砟轨道 CA 砂浆脱空损伤识别[J]. 中南大学学报(自然科学版), 2021, 52(11): 4021-4031.
- [16] 侯博文, 李佳静, 高亮, 等. 基于脉冲激励下钢轨振动响应的扣件失效识别方法[J]. 工程力学, 2021, 38(2): 122-133.
- [17] 刘潇, 王少林, 闫宇智, 等. 城轨轨道结构病害室内试验模拟与识别方法研究[J]. 铁道科学与工程学报, 2025, 22(5): 2333-2345.
- [18] 华莉, 杨俭, 袁天辰, 等. 基于 VMD 和 BP 神经网络的轨道病害诊断方法[J]. 电子科技, 2022, 35(4): 40-46.
- [19] Guo, Y., Zhai, W.M. and Sun, Y. (2018) A Mechanical Model of Vehicle-Slab Track Coupled System with Differential Subgrade Settlement. *Structural Engineering and Mechanics*, **66**, 15-25.
- [20] Zhai, W.M. (1996) Two Simple Fast Integration Methods for Large-Scale Dynamic Problems in Engineering. *International Journal for Numerical Methods in Engineering*, **39**, 4199-4214. [https://doi.org/10.1002/\(sici\)1097-0207\(19961230\)39:24<4199::aid-nme39>3.0.co;2-y](https://doi.org/10.1002/(sici)1097-0207(19961230)39:24<4199::aid-nme39>3.0.co;2-y)