

数据驱动的整车道路载荷快速预测方法

冯金芝^{1,2,3} 李增宏¹ 张东东^{1,2,3} 刘东俭⁴ 赵礼辉^{1,2,3}

(1. 上海理工大学机械工程学院, 上海 200093)

(2. 机械工业汽车机械零部件强度与可靠性评价重点实验室, 上海 200093)

(3. 上海市新能源汽车可靠性评价专业技术服务平台, 上海 200093)

(4. 中汽研汽车试验场股份有限公司, 盐城 224100)

摘要: 车辆与路面间相互作用力中的车轮六分力是车路间的唯一耦合, 获取车轮六分力是开展整车可靠性与耐久性评价的关键。针对传统的车轮六分力获取方法成本高、周期长、效率低的问题, 提出数据驱动的车轮载荷快速预测的方法。首先, 针对实车道路非平稳随机信号, 采用基于自适应噪声完备集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)、排列熵(Permutation Entropy, PE)以及小波阈值降噪(Wavelet Threshold Denoising, WTD)的联合方法进行数据去噪; 其次, 以轮心加速度、减振器位移、质心加速度等容易获取且获取成本低的数据为输入, 设计包含非线性传递关系的不同神经网络架构进行多路面下车轮六分力预测, 并建立时域、频域、损伤域多维度载荷预测评估体系; 最后, 为克服训练样本大且获取代价高的缺点, 提出基于神经网络输入与输出相关性-相干性分析的输入通道压缩方法, 提出最小载荷信号片段划分指标并确定各路面最小片段时长, 进行训练集压缩。经过模型不断迭代, 车轮六分力的预测值与实测值较为接近, 载荷特征也得以保留, 计算效率提高 28.85%, 证明了最小数据集模型能够以较少的输入通道数量、较短的载荷片段时长复现较高期望的预测精度。

关键词: 轮心六分力; 载荷预测; 神经网络; 损伤评估; 疲劳耐久分析

中图分类号: U461.7¹ **DOI:** 10.16579/j.issn.1001.9669.2025.10.001

0 引言

汽车实际行驶过程所处环境复杂, 承受载荷多, 而车轮作为支撑车重、获取地面作用力、调节车辆行驶性能的重要部件, 其六分力对整车及零部件的可靠性和耐久性开发非常重要。车轮六分力作为耐久性分析最重要的基本数据, 其准确快速获取能缩短试验周期、提高开发效率、降低开发成本。目前车轮六分力的获取方法有 3 类。第 1 类是试验场道路载荷实车采集的方法^[1-4], 如徐春^[5]通过制定试验场道路载荷采集方案, 为采集试验场整车数据提供了参考。由于采集前期需要零件拆解、装车调试、应变片传感器制作、传感器安装和线缆布置等工作, 耗费大量人力物力, 而且专用六分力采集传感器价格昂贵, 研发成本高。第 2 类是通过虚拟试验场技术建立多体动力学模型进行载荷虚拟迭代, 如王超^[6]针对三维路面建模困难, 提出“人-车-路”虚拟试验场系统, 通过仿真提取了车轮六分力, 这在一定程度上缩短了试验周期。这两种方

法是基于试验场道路实施的, 试验场环境相对封闭, 对便于安装各类传感器的车辆进行试验, 而且试验场路面可用激光扫描技术进行虚拟路面建模。但对于用户道路实车采集, 安装的各类传感器会限制车辆全方位的试验, 甚至无法上路; 对于数字路面, 用户道路随机扫描建模难度大。而第 3 类是在载荷预测领域运用比较活跃的机器学习方法, 借助部分实测数据对目标载荷进行预测, 其本质上是通过机器学习找到输入与输出的复杂映射关系。在载荷预测方面, 李荣强等^[7]基于飞机的飞行数据, 建立 XGBoost、随机森林、反向传播(Back Propagation, BP)神经网络等机器学习模型对飞机左起落架垂向载荷进行预测研究, 验证了 XGBoost 模型的优越性。牟哲岳等^[8]通过 Pearson 相关系数评价机组状态数据、气象数据与机组载荷之间的相关性, 采用极端随机森林算法建立风电机组载荷预测模型, 对机组载荷进行了预测。杨博文等^[9]基于当前已有数据, 建立了概率密度参数外推法载荷预测模型, 并结合机器学习 BP 神经网络对全断面硬岩隧道掘

收稿日期: 2023-11-28 修回日期: 2024-01-14

基金项目: 国家自然科学基金项目(51705322); 产学研合作项目(H-2022-304-042)

作者简介: 冯金芝, 女, 1973 年生, 山东诸城人, 博士, 副教授, 硕士研究生导师; 主要研究方向为现代汽车设计理论; E-mail: jzfeng99@163.com。

赵礼辉(通信作者), 男, 1985 年生, 山东青岛人, 博士, 副教授, 硕士研究生导师; 主要研究方向为车辆强度可靠性设计与评价、车辆载荷特征建模与快速试验; E-mail: pheigoc@126.com。

引用格式: 冯金芝, 李增宏, 张东东, 等. 数据驱动的整车道路载荷快速预测方法[J]. 机械强度, 2025, 47(10): 1-15.

FENG Jinzhi, LI Zenghong, ZHANG Dongdong, et al. Data-driven method for rapid prediction of vehicle road load[J]. Journal of Mechanical Strength, 2025, 47(10): 1-15.

进机(Tunnel Boring Machine, TBM)主机系统关键部件超前载荷谱进行预测。而在车轮六分力获取方面,罗欢等^[10]以车型数据库建立深度卷积神经网络-长短期记忆(Deep Convolutional Neural Network-Long Short Term Memory, DCNN-LSTM)神经网络,以转向盘转角、整车形式、悬架形式等为输入,在特定场景下实现了轮心力预测并以决定系数 R^2 、平均绝对误差(Mean Absolute Error, MAE)与均方误差(Mean Square Error, MSE)的比值评价了神经网络模型的可用性。WANG等^[11]通过离线训练一组有限脉冲响应模型,利用最大似然估计分类器确定车辆当前所处的工况,从而估计车轮垂向轮心力,该方法在公共道路、街区道路实现了车轮垂向力预测。

已有研究证实了基于机器学习的数据驱动方法在载荷预测方面的可行性。在整车道路载荷预测研究上仍需进一步完善,如数据前处理工作繁杂,载荷预测评价指标单一,预测模型适用路面类型少;普适性强、精度高的驱动模型往往依赖大量的训练样本,而大量训练样本可能导致模型复杂度提升等。

综上所述,通过试验场载荷谱采集获取轮心力的方法周期长、成本高;虚拟迭代技术受限于实车行驶道路的随机性;基于部分已有数据预测轮心载荷的方法难以广泛适用于多种路面特征,这使得以车轮六分力为基础数据对整车及零部件的可靠性与耐久性开发不尽如人意。

为此,本文提出数据驱动的整车道路载荷快速预测方法,以乘用车四轮为主要研究载体,以左前轮为主要预测对象,将加速度、减振器位移等易于获得的数据作为输入,进行左前轮多路况车轮六分力预测,并对比几种非线性网络的预测精度。同时构建载荷预测多维度评价体系,将预测载荷与实测值进行时域、频域、损伤域多维度的对比,对比分析表明轮心垂向力预测精度最高,其他分力也具有较高精度且相对损伤误差均在20%以内,验证了该模型(记为初始模型)对多路面类型的普适性;并进一步分析输入载荷特征与输出载荷特征的时域相关性与频域相干性,将输入特征数量压缩后继续训练模型(记为压缩输入通道模型)预测六分力。最后,在压缩输入通道模型的基础上,将基于加速度、位移等载荷信号提取的原始载荷片段与划分后载荷片段的频域拟合程度参数及两片段的平均相对距离之和(P -value, P)等作为载荷谱最小片段划分的依据,通过压缩各路况时长,实现以最小数据集所训练的模型(记为最小数据集模型)复现初始模型的预测精度,且计算效率得到提升。这有助于实时快速预测局部危险部位载荷、提高损伤评估效率。

1 载荷采集及特征分析

1.1 实车道路载荷采集

由于实车行驶路面随机、复杂,而典型试验场道路是提取50多种社会用户道路优化组合,覆盖面广。因此,为实现神经网络对车轮六分力(x 、 y 、 z 3个方向的力和力矩)精准预测,进行试验场道路载荷采集。考虑到数据驱动模型预测精度与输入通道特征相关,采集信号主要包括轮心六分力、减振器位移,以及轮心、轴头、车身的三向加速度信号等。道路类型主要涉及石块路、卵石路、扭曲路、锯齿路、砂石路等32种。试验车辆为乘用车,传感器布置及行驶路线如图1所示。试验工况为满载2.73 t,在T8跑道上进行3次循环试验,以消除驾驶习惯、突发情况等造成的数据差异。而为保证载荷信号采集完整,采样频率一般较高,采样频率为512 Hz。其中,3次试验循环时间分别为678、710、700 s。图2为道路载荷采集卫星图,图3为前两次试验循环载荷信号。

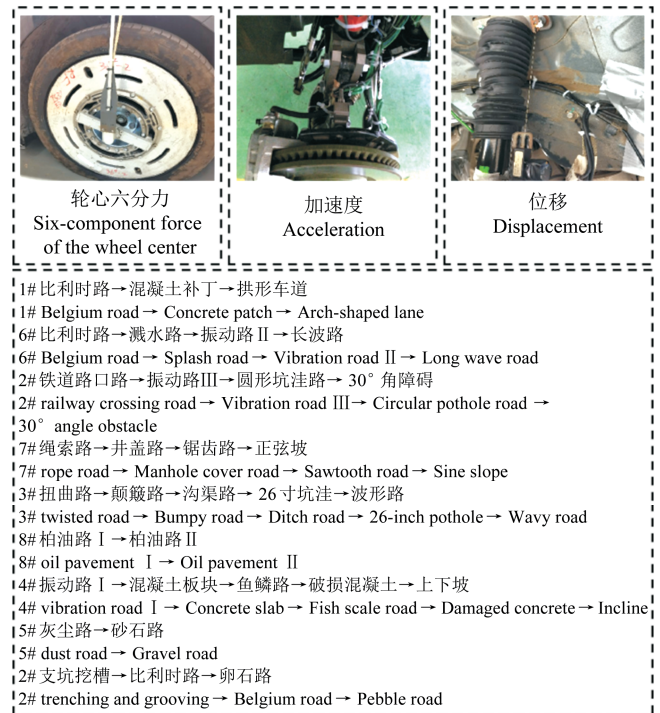


图1 传感器示意图及行驶路线

Fig. 1 Schematic diagram of the sensor and the driving route

1.2 载荷特征分析


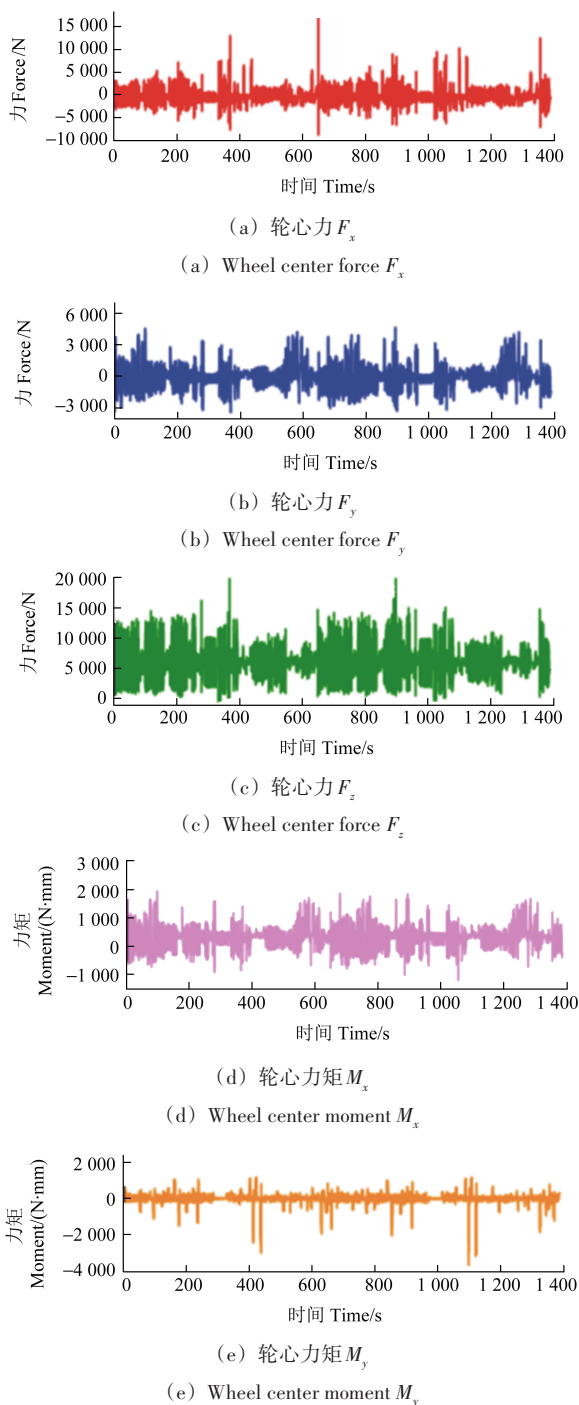
1.2.1 载荷有效性检验及采样频率确定

对采集数据进行时间历程、载荷幅值分布、功率谱密度(Power Spectral Density, PSD)和雨流计数等载荷特征的对比分析。如图4所示,以左前轮垂向加速度为例,将3次循环试验中的过渡路段一致化,各通道载荷信号在时间历程上均完整,幅值范围基本一致,没有数据缺失通道;在PSD上,载荷信号的能量分布主要集中在20 Hz以内,符合预期;在幅值分布上,载

荷数据在路面不平度激励下产生随机振动响应,均基本符合高斯正态分布规律;载荷幅值分布和雨流计数结果是损伤等效计算的重要影响因素,3次试验循环载荷信号的幅值分布和雨流计数基本一致,进一步验证了本次采集数据的有效性。



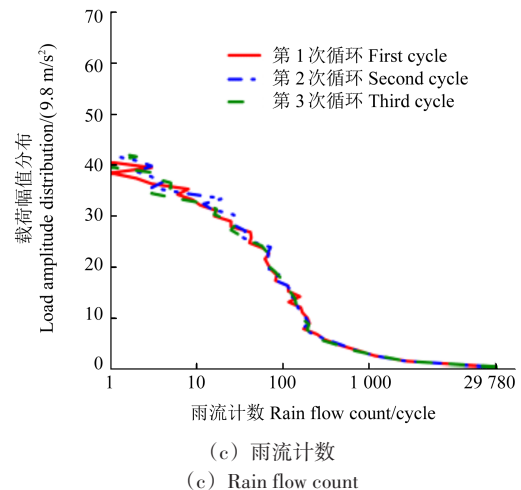
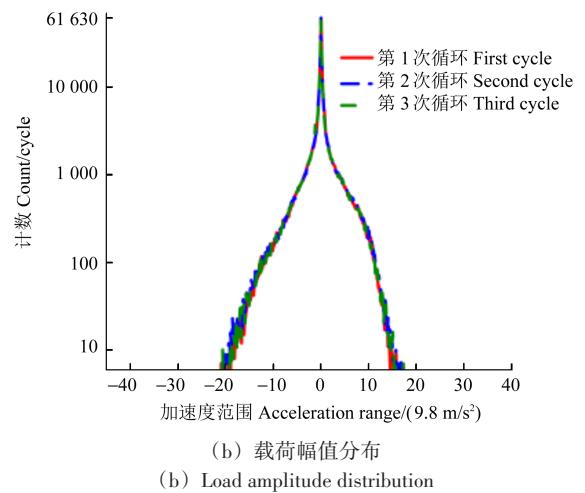

图 2 道路载荷采集卫星图
Fig. 2 Satellite map of road load collection

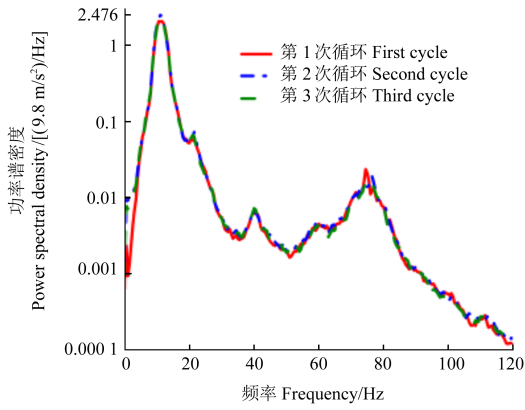


(f) 轮心力矩 M_z
(f) Wheel center moment M_z

图 3 实测轮心力载荷

Fig. 3 Measured wheel center force load





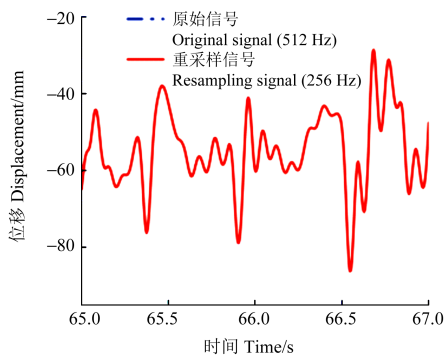
(d) 功率谱密度

(d) Power spectral density

图4 载荷有效性检验


Fig. 4 Validation testing of the load

由于采样频率较高,神经网络数据集样本量庞大。理论上,大量数据会使神经网络的泛化能力和训练效果得到提升,但增加了训练时间、内存消耗以及数据预处理的复杂性,因此对数据进行重采样。以左前轮减振器位移为例,为尽可能降低采样频率且重采样后的信号能保留原始信号95%以上的伪损伤,分别取采样频率为256、100、50、25 Hz进行重采样。重采样前、后的时域载荷信号局部放大对比如图5所示。随着采样频率的降低,信号失真程度加剧,且主要出现在峰谷值部位,而伪损伤的贡献率主要是峰谷值载荷提供的。进一步计算256、100、50、25 Hz损伤复现比,结果如表1所示。在满足95%伪损伤复现比的前提下,选用尽可能低的采样频率,因此本文采样频率为100 Hz。



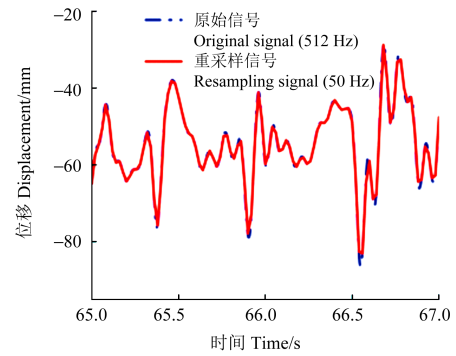
(a) 256 Hz 重采样

(a) 256 Hz resampling



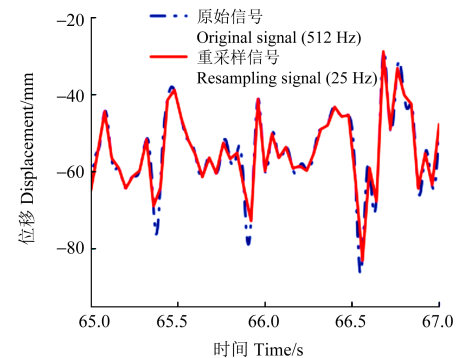
(b) 100 Hz 重采样

(b) 100 Hz resampling



(c) 50 Hz 重采样

(c) 50 Hz resampling



(d) 25 Hz 重采样

(d) 25 Hz resampling

图5 载荷重采样对比

Fig. 5 Comparison of load resampling

表1 载荷重采样损伤对比

Tab. 1 Comparison of load resampling damage

采样频率 Sampling frequency f_s /Hz	512	256	100	50	25
损伤值 Damage value/ 10^{-11}	4.53	4.49	4.28	3.71	2.44
重采样损伤值 Resampling damage value/ 10^{-11}	4.53	4.45	4.08	3.21	1.31
损伤复现比 Damage replication ratio/%	100.00	99.12	95.32	86.68	53.86

1.2.2 CEEMDAN-PE-WTD

车辆行驶过程中车速、路面不平度的变化导致载荷是非平稳的随机信号,且采集设备的可靠性和采集环境都会对采集信号的质量造成影响。为明确采集信号中是否有噪声,首先采用自适应噪声完备集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)技术对载荷信号进行模态分解,得到各个本征模态函数(Intrinsic Mode Functions, IMF)分量;其次计算各个IMF分量的排列熵(Permutation Entropy, PE)值^[12-13];进而根据噪声PE值大的特点对含噪信号进行筛选,并对含噪信号进行小波阈值降噪(Wavelet Threshold Denoising, WTD);最后将纯净信号和小波降噪后的信

号进行重构,得到降噪后的信号。以路况较为复杂的卵石路垂向力 F_z 为例,对其进行 CEEMDAN,其原始信

号及各 IMF 分量如图 6 所示,各个分量的 PE 值如表 2 所示。




图 6 原始载荷及其本征模态函数分量

Fig. 6 Original load and its IMF component

表 2 各本征模态函数分量排列熵值

Tab. 2 PE value of each IMF component

本征模态函数分量 IMF component	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅	IMF ₆	IMF ₇	IMF ₈	IMF ₉	IMF ₁₀	IMF ₁₁	IMF ₁₂	IMF ₁₃
排列熵值 PE value	0.988	0.915	0.837	0.639	0.399	0.269	0.210	0.162	0.136	0.125	0.116	0.111	0.108

通过 CEEMDAN 得到 13 个 IMF 分量和 1 个残余项,对这些分量分别计算 PE 值,PE 值越大的 IMF 分量噪声信号越多,反之 PE 值小的 IMF 分量纯净信号越多。PE 的算法如下:

1) 对一时间序列长度为 n 的信号 $X = \{x_i, i=1, 2, \dots, n\}$ 进行相空间重构,得到矩阵为

$$Y = \begin{bmatrix} x(1) & x(1+\tau) & \cdots & x[1+(r-1)\tau] \\ x(2) & x(2+\tau) & \cdots & x[2+(r-1)\tau] \\ \vdots & \vdots & & \vdots \\ x(k) & x(k+\tau) & \cdots & x[k+(r-1)\tau] \end{bmatrix} \quad (1)$$

式中, r 为嵌入维数; τ 为时间延迟; k 为重构分量的个数。

2) 将 Y 中的每一行看作 1 个重构分量,对每个重构分量的各个元素按照升序重新排列,如果出现数值相同的元素,则按照索引顺序排列。对 Y 的第 m 个分量 $\{x(m) \quad x(m+\tau) \quad \cdots \quad x[m+(r-1)\tau]\}$ 进行排序,即有索引序列:

$$S(l) = [j_1, j_2, \dots, j_r] \quad (2)$$

式中, $l=1, 2, 3, \dots, L, L \leq r!$; $x(m)$ 为重构矩阵的第 m 行分量。

3) 若维度为 r 的相空间一共有 $r!$ 种符号序列,计

算每一个序列的概率,记为 P_g ,则序列 X 的 PE 为

$$H_p(r) = - \sum_{g=1}^G P_g \ln P_g \quad (3)$$

式中, $H_p(r)$ 最大值是 $\ln(r!)$,此时 $P_g=1/r!$ 。将 $H_p(r)$ 归一化后有

$$0 \leq H_p = \frac{H_p(r)}{\ln(r!)} \leq 1 \quad (4)$$


式中, r 和 τ 的一般取值范围分别为 3~7 与 1~8。如果 r 过大,在捕捉时间序列复杂结构的同时增加了计算复杂度, r 过小会导致重构矩阵中的状态丢失,使 PE 算法无效^[14];在相同嵌入维度下, τ 对 PE 值的影响较小^[15]。而高斯白噪声的 PE 值基本在 0.9 以上^[16-17],建议 PE 阈值的范围为 0.55~0.60^[18-19],结合车辆实际行驶时会产生随机噪声的特点,本文取 $r=6, \tau=1$, PE 阈值为 0.6。将 PE 值大于 0.6 的 IMF 分量进行小波阈值降噪,根据本文载荷信号特征,选取“db4”为小波基函数,阈值计算方法选择固定阈值方法^[20],分解层数为 2。表 3 为不同阈值规则的计算结果。图 7(a) 为原始载荷信号与降噪后信号的对比。由图 7(b) 可知,损伤贡献在 20 Hz 以

内。而图7(c)中该频段内降噪数据与原始数据基本一致,20~50 Hz频段带噪信息得到明显减少,因此去噪效果良好。


表3 不同阈值计算方法的均方误差和信噪比

Tab. 3 MSE and signal to noise ratio of different threshold calculation methods

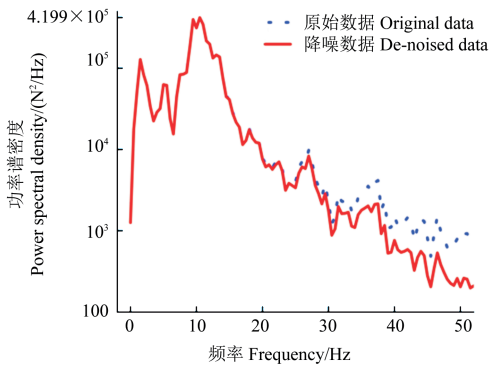
不同阈值方法 Different threshold methods	均方误差 Mean square error	信噪比 Signal to noise ratio
固定阈值 Fixed threshold	2.36	41.05
无偏风险估计阈值 Unbiased risk estimation threshold	2.43	40.93
启发式阈值 Heuristic threshold	2.39	40.98
极大极小阈值 Maximum minimum threshold	89.28	25.27



(a) 载荷信号对比
(a) Comparison of load signals



(b) 原始信号疲劳损伤谱
(b) Fatigue damage spectrum of the original signal



(c) 载荷信号频谱对比
(c) Comparison of load signal spectrums

图7 原始载荷降噪对比

Fig. 7 Comparison of original load noise reduction

2 数据驱动模型搭建及评估

2.1 LSTM神经网络

汽车实际行驶时,车轮载荷变化复杂、非线性较高,传统自回归线性模型结构简单,预测此类时序数据存在局限性。对于时序数据预测,往往要考虑不同时间维度之间的依赖关系,而长短期记忆(Long Short-Term Memory, LSTM)神经网络基于遗忘门、输入门、输出门对输入信息记忆或遗忘,能够提取长序列之间的关联关系。因此,基于多维度输入时序特征,采用LSTM神经网络,针对输入载荷特征构建一个最优车轮六分力预测方法。其中,遗忘门的输入是当前 t 时刻的 x_t 和前一时刻的 C_{t-1} ,对历史信息进行筛选并抛弃不重要的信息;输入门是决定输入中的哪些值需要更新记忆状态,并通过传入tanh函数中的历史信息 and 当前信息生成1个候选值 \tilde{C}_t ,之后进行候选值的更新;输出门是根据输入和记忆状态决定输出的值,将前一个隐藏状态 h_{t-1} 和当前输入 x_t 传递到sigmoid函数中得到 o_t ,最后将 t 时刻tanh的输出与sigmoid的输出相乘得到最终的输出。LSTM神经网络的输出过程为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t \tanh(C_t) \quad (10)$$

式中, f_t 为 t 时刻的遗忘门; i_t 为 t 时刻的输入门; \tilde{C}_t 为 t 时刻的候选值; C_t 为 t 时刻的单元状态; C_{t-1} 为 $t-1$ 时刻的单元状态; o_t 为 t 时刻的输出门的输出; h_t 为 t 时刻的最终输出值; h_{t-1} 为 $t-1$ 时刻的最终输出值; W 代表各权重; b 代表各偏置; σ 为sigmoid函数。LSTM神经网络的结构如图8所示。

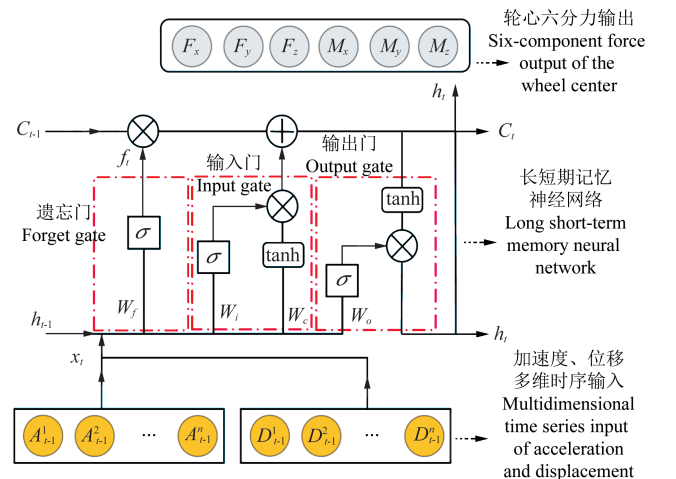


图8 长短期记忆神经网络

Fig. 8 LSTM neural network

2.2 LSTM 神经网络结构设计及训练

将前 2 次试验循环数据分别作为训练集、测试集,神经网络的初始输入通道是 16 个,分别为四车轮的减振器位移以及 4 个轮心三向加速度,预测车轮六分力,即 F_x 、 F_y 、 F_z 、 M_x 、 M_y 、 M_z 。在上文中已经对数据集进行了去噪处理,还需要进一步对数据集进行归一化处理,以消除因数据间数量级相差很大而对训练过程产生的过拟合或者不稳定。由于数据集庞大,使用传统或改进的优化算法需要大量的算力与时间,所以使用顺序优化方法从对神经网络影响最大的参数开始,逐一确定各个参数,并总结 LSTM 神经网络不同参数对预测效果的影响。将 R^2 、均方根误差 (Root Mean

Square Error, RMSE)、MAE 作为评价神经网络预测拟合程度的指标,其表达式为

$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\bar{y} - y_i)^2} \quad (11)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

式中, y 为神经网络输入的真实值; \hat{y} 为神经网络输出的预测值; \bar{y} 为神经网络输入真实值的均值; n 为样本量。不同试验结果如表 4 所示,并总结不同结构参数对神经网络预测精度的影响。

表 4 神经网络不同试验结果

Tab. 4 Different test results of neural networks

序号 No.	学习率 Learning rate	隐藏层节点数 Number of hidden layer node	迭代次数 Number of iterations	数据批量大小 Data batch size	时间步长 Time step	训练集决定系数 Training set determination coefficient $R^2/\%$	训练集平均绝对误差 MAE of training set E_{MAE}	训练集均方根误差 RMSE of training set E_{RMSE}	测试集决定系数 Testing set determination coefficient $R^2/\%$	测试集平均绝对误差 MAE of testing set E_{MAE}	测试集均方根误差 RMSE of testing set E_{RMSE}
1	0.001	80	189	1 024	7	92.39	291.21	405.35	90.98	325.43	443.59
2	0.005	80	189	1 024	7	91.04	317.88	440.02	89.04	357.48	489.1
3	0.008	80	189	1 024	7	93.21	276.9	382.96	90.87	324.277	446.39
4	0.01	80	189	1 024	7	92.72	283.23	396.47	90.93	320.95	445.05
5	0.05	80	189	1 024	7	4.96	974.93	1 433.12	5.38	964.87	1 437.48
6	0.01	16	189	1 024	7	91.06	313.13	439.46	90.94	305.69	444.81
7	0.01	32	189	1 024	7	93.21	269.29	382.85	92.30	281.80	409.99
8	0.01	64	189	1 024	7	89.15	323.06	484.18	87.97	346.12	512.52
9	0.01	80	189	1 024	7	92.72	283.23	396.47	90.93	320.95	445.05
10	0.01	128	189	1 024	7	94.80	235.54	335.00	93.31	258.10	381.99
11	0.01	80	100	1 024	7	91.15	309.51	437.23	91.15	304.82	439.6
12	0.01	80	189	1 024	7	92.72	283.23	396.47	90.93	320.95	445.05
13	0.01	80	300	1 024	7	92.03	290.49	414.81	91.22	299.5	437.72
14	0.01	80	400	1 024	7	93.33	263.09	379.52	91.99	281.27	418.23
15	0.01	80	500	1 024	7	94.05	251.95	358.46	91.84	293.56	421.93
16	0.01	80	189	128	7	94.92	232.57	331.31	92.17	258.52	413.42
17	0.01	80	189	256	7	95.66	216.05	306.15	93.01	266.02	390.61
18	0.01	80	189	512	7	94.22	251.81	353.31	91.83	302.14	422.17
19	0.01	80	189	1 024	7	92.72	283.23	396.47	90.93	320.95	445.05
20	0.01	80	189	2 048	7	91.08	307.19	439.05	89.81	335.08	471.52
21	0.01	80	189	1 024	5	91.70	304.36	423.50	90.30	334.98	460.21
22	0.01	80	189	1 024	6	93.53	264.10	373.74	91.52	303.06	430.22
23	0.01	80	189	1 024	7	92.72	283.23	396.47	90.93	320.95	445.05
24	0.01	80	189	1 024	8	92.84	282.61	393.20	91.02	320.66	442.77
25	0.01	80	189	1 024	9	90.81	319.61	445.42	89.97	340.35	467.82

由表 4 中的 1~5 号试验结果可知,学习率决定了权重更新的幅度,较大的学习率可以加快收敛速度。然而,过大的学习率可能导致训练过程不稳定,错过全局最优解。较小的学习率会减缓收敛速度,但更稳

定。由 6~10 号试验结果可知,隐藏层节点数的增加可以提高神经网络的预测能力,但也会增加神经网络的过拟合风险。通常当训练数据较少时,较少的隐藏层节点数可以更好地应对过拟合问题。当训练数据较

大时,增加隐藏层节点数可以提高神经网络的学习能力。因此,需要根据训练数据的规模和复杂性来平衡隐藏层节点数的选择。由11~15号试验结果可知,增加迭代次数可以使神经网络更充分地学习训练数据中的模式和关系,有助于提高模型的收敛性。通过更多的迭代次数,神经网络可以逐渐减小训练误差并接近最优解。然而过多的迭代次数可能导致过拟合问题,即在训练数据上表现良好但在未见过的数据上表现较差。由16~20号试验结果可知,数据批量偏小会引入更多的随机性,偏大可能会更好地利用批次内样本之间的统计信息,从而提高训练的稳定性及泛化能力,但如果数据批量过大,可能导致模型过于依赖批次内的样本之间的相关性,从而降低了模型的泛化能力。由21~25号试验结果可知,较长的时间步长可以提供更长的历史信息窗口,使神经网络能够更好地捕捉时间序列数据中的长期依赖关系。然而如果时间步长过长,会

降低网络对数据全部信息特征的获取精度。

通过上述训练结果,最终确定以下网络结构参数:1个输入层,1个隐藏层,80个神经元,激活函数为ReLU,迭代次数为200,批量大小为1 024,学习率为0.01,添加0.001的Dropout层,损失函数为MSE,优化器选择Adam。

2.3 神经网络预测效果评估

为避免单一神经网络的局限性,选择既有普适性又有高精度的神经网络模型,构建并对比LSTM、LSTM融合多头注意力机制^[21]、LSTM融合多头结构、带有外部输入的非线性自回归(Nonlinear Auto-Regressive with Exogenous Inputs, NARX)神经网络、反向传播、多层感知机(Multilayer Perceptron, MLP)等多路况六分力的预测模型^[22-24]。通过决定系数、均方根误差以及绝对平均误差初步判断预测模型的精度,表5所示为不同数据模型的六分力预测精度及效率。

表5 不同神经网络模型预测轮心力精度对比

Tab. 5 Comparison of accuracy in predicting wheel center forces by different neural network models

神经网络模型 Neural network model	轮心力 Wheel center force	决定系数 Determination coefficient R^2	均方根 误差 RMSE E_{RMSE}	平均绝 对误差 MAE E_{MAE}	计算时间 Computational time/s	神经网络模型 Neural network model	轮心力 Wheel center force	决定系数 Determination coefficient R^2	均方根 误差 RMSE E_{RMSE}	平均绝 对误差 MAE E_{MAE}	计算时间 Computational time/s
长短期记忆 LSTM	F_x	0.872 5	403.95	282.09	186.01	长短期记忆- 自注意力机制 LSTM- self-attention mechanism	F_x	0.850 7	437.18	290.24	213.45
	F_y	0.838 4	334.57	234.49			F_y	0.839 2	333.82	220.06	
	F_z	0.975 6	230.37	161.32			F_z	0.966 7	269.50	175.09	
	M_x	0.877 3	107.91	71.05			M_x	0.852 1	118.54	81.01	
	M_y	0.903 0	109.33	75.66			M_y	0.879 7	121.82	81.87	
	M_z	0.796 4	80.08	46.98			M_z	0.743 4	68.55	43.29	
长短期记忆-多头 注意力机制 LSTM-multi-head attention mechanism	F_x	0.871 0	406.39	384.84	221.92	带有外部输入 的非线性自回 归模型 NARX model	F_x	0.794 8	929.09	487.82	295.21
	F_y	0.776 6	393.43	260.70			F_y	0.695 7	663.80	391.56	
	F_z	0.971 6	248.92	177.37			F_z	0.990 3	219.58	147.04	
	M_x	0.875 9	108.56	73.02			M_x	0.676 3	165.43	103.14	
	M_y	0.899 8	111.17	74.32			M_y	0.429 0	228.22	113.95	
	M_z	0.734 6	69.71	45.32			M_z	0.799 5	75.77	52.45	
多层感知机 MLP	F_x	0.761 1	553.02	362.37	659.39	反向传播模型 BP model	F_x	0.761 1	553.02	362.37	2 523.23
	F_y	0.663 8	656.06	45.07			F_y	0.778 4	391.85	263.99	
	F_z	0.629 2	506.86	391.75			F_z	0.491 6	1 053.63	565.93	
	M_x	0.431 2	1 114.50	595.60			M_x	0.767 5	148.61	95.82	
	M_y	0.694 4	170.38	109.18			M_y	0.888 8	117.08	72.08	
	M_z	0.807 1	154.23	97.81			M_z	0.801 7	60.27	37.31	

在预测精度上,BP神经网络除 F_z 外,其余分力预测精度均在76%以上;MLP神经网络除 F_z 、 M_x 外,其余分力预测精度均在66%以上;NARX神经网络除 M_y 外,其余分力预测精度均在67%以上;LSTM神经网络六分力预测精度均在79%以上。

在预测效率上,LSTM与NARX数据模型在非线性动态载荷预测上的优势较大,计算效率高;而LSTM-自注意力机制模型以及LSTM-多头注意力机制模型,由于

添加了注意力机制结构,整体模型较复杂,计算效率及精度有所降低。综合车轮六分力预测精度、效率以及稳定性表现,LSTM神经网络是最优的。因此选择LSTM神经网络对车轮六分力的预测进行深入研究。

2.4 载荷预测多维度评价体系

将上文得到的LSTM神经网络模型记为初始模型,3个评价指标在可接受范围内,但是其预测的载荷是否符合工程要求仍需要比较原始载荷与

预测载荷的时间历程趋势、功率谱密度和损伤域的相对误差。因此建立载荷预测多维度评价体系,同时为确保上述训练过程的正确性以及训练模型的稳定性,将每次最佳参数的神经网络进行多次训练预测,避免偶然性。

2.4.1 时域对比分析

图 9 为神经网络训练误差,图 10 为预测载荷与真实载荷在时域历程上的对比。在六分力预测上,预测模型对于 F_z 的拟合程度比较高,波形趋势基本一致,基本没有突起载荷;而对于其他分力预测,在峰值上的预测载荷与真实载荷存在微小误差。在各个路况上,对于石块路和卵石路等载荷随机的路况预测效果稍有不足,而对于扭曲路和振动路等具有载荷规律性的路况预测效果较好。从整体上看,时域预测效果较好,与各自的决定系数和均方根误差能够相互体现。

2.4.2 功率谱密度对比分析

PSD 是对时域信号进行傅里叶变换转换成频域信号,描述信号在频域上的功率分布的度量。而在汽车实际行驶过程中,车辆经常面临的是低频振动和冲击

载荷,如路面不平、起伏、过坑、过凸起等,汽车整车或零部件的耐久性评价主要关注能量集中的 0~20 Hz 主频带内的分布情况。如图 11 所示,只有预测的 M_y 在 13~20 Hz 的预测值 PSD 偏高,其余分力主频带基本吻合;而在 34~42 Hz, F_y 与 M_x 预测的 PSD 偏低,但都在一个数量级内,预测载荷与真实载荷在频域上的分布特征基本一致。

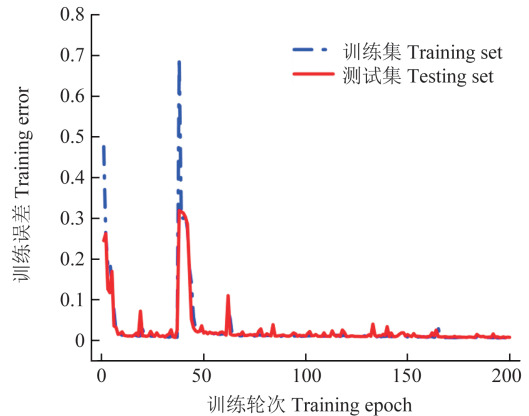


图 9 长短记忆神经网络训练误差

Fig. 9 Training error of LSTM neural network

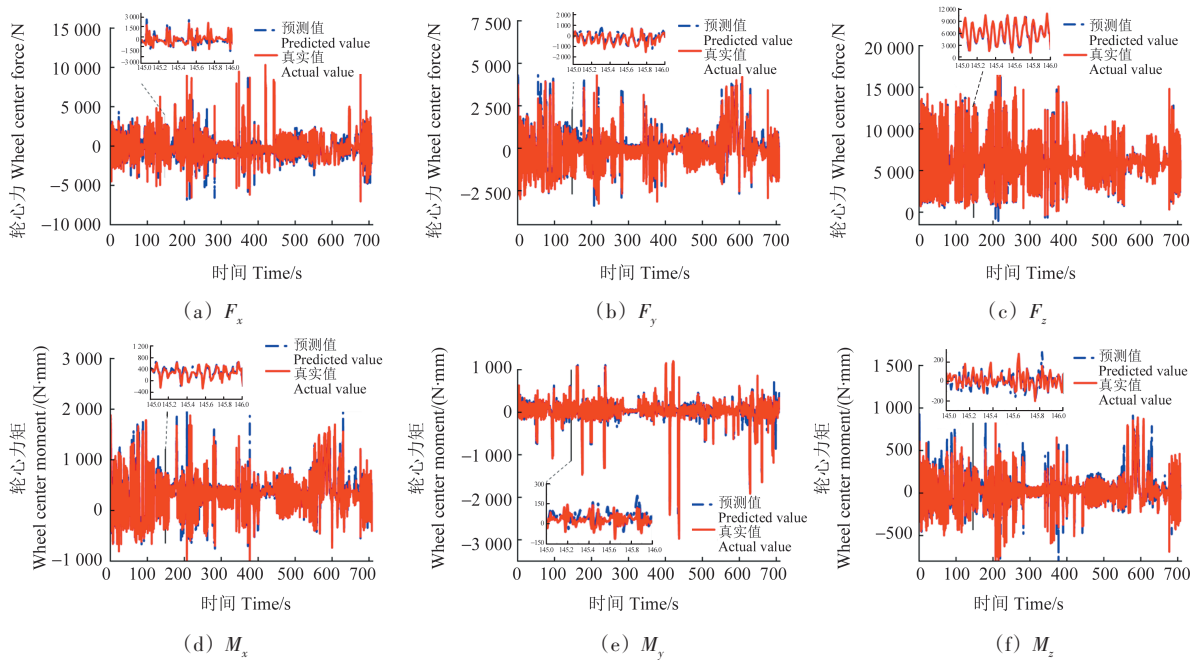



图 10 预测载荷与真实载荷时域对比

Fig. 10 Time-domain comparison between predicted loads and actual loads






图 11 预测载荷与真实载荷频域对比

Fig. 11 Frequency-domain comparison between predicted loads and actual loads

2.4.3 损伤域对比分析

预测载荷与真实载荷在时域和频域上较相符的情况下,还需要进一步确认预测载荷的伪损伤是否能够复现80%以上的真实载荷的伪损伤。Miner线性累积损伤理论常用于损伤评估与寿命预测中。一个循环载荷的总损伤计算式为

$$D = \sum_{i=1}^n \frac{1}{N_i} \quad (14)$$

式中, D 为总损伤; N_i 为第*i*个载荷作用下的疲劳寿

命^[25]。表6为真实载荷与预测载荷的伪损伤及损伤相对误差。损伤相对误差计算式为

$$\delta_D = (D_{\text{真实}} - D_{\text{预测}}) / D_{\text{真实}} \times 100\% \quad (15)$$

图12为预测载荷与真实载荷在雨流矩阵上的对比。由图12可知, F_x 、 F_y 、 F_z 、 M_x 、 M_y 、 M_z 预测的大幅值载荷比真实载荷少,而预测的小幅值载荷与真实载荷相当,使得预测载荷损伤小于真实载荷;从总体来看,轮心六分力的损伤相对误差都在20%以内,在可接受范围内。

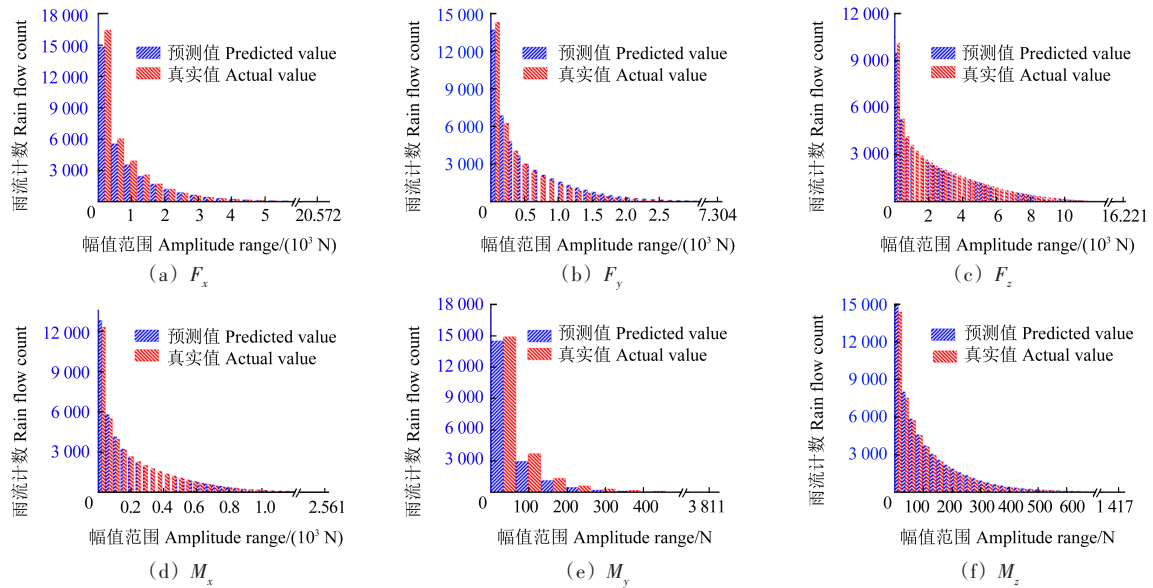


图 12 预测载荷与真实载荷雨流矩阵对比

Fig. 12 Comparison of rain flow matrices between predicted loads and actual loads

根据构建的多维度评价体系,对NARX神经网络与LSTM神经网络进行垂向力预测对比分析,如图13所示。由上文知,NARX神经网络模型的3个评价指标均要优于LSTM,从整体时频域上两者预测效果相当,而LSTM在峰值预测上略优于NARX;同时NARX预测载荷的损伤值为 1.85×10^{-4} ,其损伤略小于LSTM预测的载荷损伤,损伤相对误差为6.09%。因此,对于整车道路载荷预测,其预测精度是否准确并不能绝对依赖于神经网络的回归指标,仍需要判别其载荷损伤特征是否能够满足工程要求。

3 最小数据集的数据驱动模型构建

通过上文研究得出多道路形式的最优车轮六分力预测模型,但是数据集样本量较为庞大。考虑到对车轮六分力的快速预测,期望能够以较小的数据集复现初始预测模型的精度。因此,基于神经网络输入与输出的时域相关性与频域相干性进行输入通道压缩;提出最小载荷信号片段划分指标,并以此确定各路面最小片段时长,从而得到压缩后的数据集。

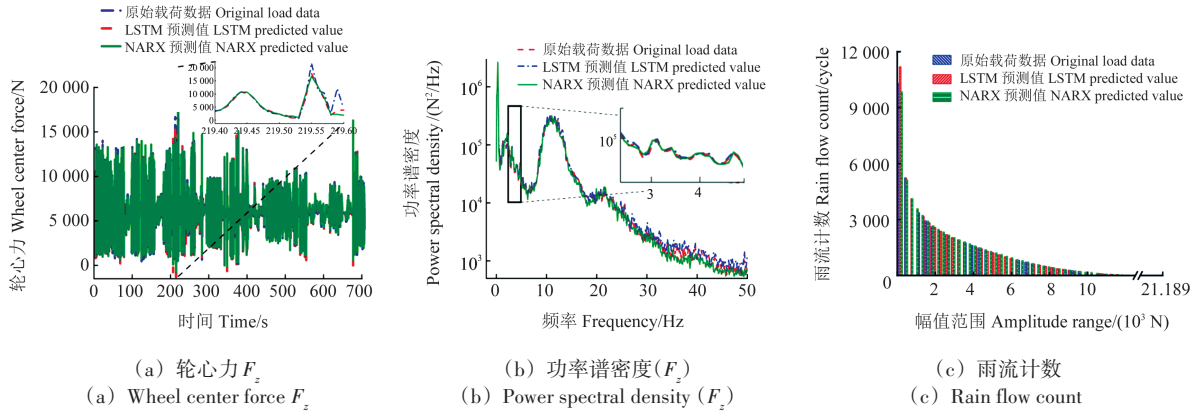


图 13 长短记忆神经网络与带外部输入的非线性自回归神经网络的多维度对比

Fig. 13 Comparison of LSTM and NARX neural networks in multiple dimensions

表 6 轮心力预测精度

Tab. 6 Prediction accuracy of wheel center forces

轮心力 Wheel center force	数据集 Data set	预测值损伤 Prediction value damage	真实值损伤 Actual value damage	损伤相对误差 Relative error of damage/%
F_x	训练集 Training set	4.82×10^{-5}	4.96×10^{-5}	2.80
	测试集 Testing set	2.73×10^{-5}	3.11×10^{-5}	12.17
F_y	训练集 Training set	5.65×10^{-7}	6.08×10^{-7}	6.98
	测试集 Testing set	6.95×10^{-7}	7.90×10^{-7}	12.00
F_z	训练集 Training set	1.71×10^{-4}	1.76×10^{-4}	3.14
	测试集 Testing set	1.90×10^{-4}	1.97×10^{-4}	3.43
M_x	训练集 Training set	3.81×10^{-9}	4.57×10^{-9}	16.66
	测试集 Testing set	6.09×10^{-9}	6.35×10^{-9}	4.07
M_y	训练集 Training set	6.17×10^{-9}	7.10×10^{-9}	12.99
	测试集 Testing set	1.16×10^{-8}	1.44×10^{-8}	18.98
M_z	训练集 Training set	1.52×10^{-10}	1.77×10^{-10}	13.83
	测试集 Testing set	2.97×10^{-10}	3.20×10^{-10}	6.94

3.1 输入通道压缩

初始输入通道是根据车载传感器的安装数量确定的,并且经过训练评估验证了初始模型的可用性。为确定哪些输入通道与左前轮轮心六分力有强相关性,求解四轮三向加速度、减振器位移、3个整车质心加速度与六分力各通道的相关系数和相干系数,结果如表 7 所示。表 7 中相关系数结果表明,六分力与四轮减振器位移有较强相关性,也与各自所在方向的质心加速度有关。而由相干性结果可知,六分力与左前轮三向加速度、减振器位移以及各自所在方向的质心

加速度有关。综合相关、相干系数,输入通道取左前轮三向加速度、左前轮减振器位移以及相关最大方向的质心加速度,共 5 个输入通道。

根据选取的 5 个输入通道数据进行模型训练,该模型为压缩输入通道模型,预测结果如表 8 所示。由表 8 可知,与初始模型的神经网络评价指标相比,计算效率提高 19.19%; F_x 、 M_y 、 M_z 预测精度较高, F_y 、 F_z 、 M_x 精度偏低。其中,除 F_z 外,其余分力的 16 个输入通道与六分力的相关系数之和有所增大;压缩后 5 个输入通道与 F_y 及 M_x 的相关系数中为负值的占比较大,而 M_y 与 16 个输入通道的相关系数之和负值较大。因此,解释了压缩输入通道模型所预测六分力的精度提升或下降。同时综合整体损伤相对误差,误差大小均低于 20%,符合工程需要,能够复现期望的预测精度。

3.2 最小数据集构建

3.2.1 最小载荷谱信号划分片段时长确定

为了以较小的数据集实现较优的预测效果,减少样本量,提高耐久性分析效率,需要进一步确定某个路况的某个片段时长为多少时,方可通过神经网络预测出其原始载荷。因此对采集到的载荷信号进行片段划分,载荷信号片段划分的基本原理如图 14 所示。从信号零点开始,分别采用不同的时间片段划分长度。为选出的每个路况最小的时间片段选用 4 个参数来进行评价,分别是 P 值、 R^2 、 R^2_{PSD} ,以及 δ_D , P 值与 R^2_{PSD} 的计算式分别为

$$P = \sum_{j=1}^6 \sum_i \left[\frac{R_{\text{真实}(i)} - P_{\text{预测}(i)}}{nR_{\text{真实}(i)}} \right] \quad (16)$$

$$R^2_{PSD}(\tilde{y}, \tilde{y}) = 1 - \frac{\sum_i [\tilde{y}^{(i)} - \tilde{y}^{(i)}]^2}{\sum_i [\tilde{y} - \tilde{y}^{(i)}]^2} \quad (17)$$

式中, P 值为划分片段所预测出六分力的值与真实六分力的值之间的平均相对距离之和; $P_{\text{预测}}$ 为划分片段所预测出的六分力值; $R_{\text{真实}}$ 为划分片段六分力的真实

表 7 输入通道与六分力的相关系数与相干系数

Tab. 7 Correlation coefficients and coherence coefficients between input channels and six-component forces

输入通道 Input channel	相关系数 Correlation coefficient						相干系数 Coherence coefficient					
	F_x	F_y	F_z	M_x	M_y	M_z	F_x	F_y	F_z	M_x	M_y	M_z
Acc1@A_X_WC_LF	0.06	-0.02	0.11	0.04	0.09	0.05	0.60	0.09	0.14	0.12	0.39	0.20
Acc1@A_Y_WC_LF	0.09	-0.27	-0.02	-0.21	0.02	-0.21	0.13	0.20	0.10	0.12	0.07	0.14
Acc1@A_Z_WC_LF	0.06	0.09	0.21	0.07	-0.01	-0.12	0.12	0.19	0.67	0.26	0.06	0.14
Acc1@A_X_WC_RF	-0.09	0.02	-0.06	-0.02	0.10	0.05	0.06	0.02	0.03	0.03	0.06	0.04
Acc1@A_Y_WC_RF	0.06	-0.19	-0.03	-0.22	-0.01	-0.09	0.04	0.09	0.04	0.07	0.02	0.08
Acc1@A_Z_WC_RF	-0.04	0.03	-0.03	0.00	-0.01	0.00	0.02	0.03	0.05	0.05	0.03	0.03
Acc1@A_X_WC_LR	-0.09	0.00	-0.02	-0.02	0.10	0.03	0.08	0.05	0.05	0.05	0.05	0.04
Acc1@A_Y_WC_LR	0.05	-0.14	-0.03	-0.15	0.00	-0.14	0.04	0.06	0.07	0.06	0.03	0.05
Acc1@A_Z_WC_LR	0.01	-0.02	0.03	-0.01	-0.01	0.01	0.04	0.06	0.09	0.07	0.02	0.04
Acc1@A_X_WC_RR	-0.09	0.02	-0.03	0.02	0.08	0.03	0.03	0.03	0.02	0.02	0.03	0.02
Acc1@A_Y_WC_RR	0.07	-0.16	-0.02	-0.17	-0.01	-0.12	0.02	0.03	0.03	0.03	0.02	0.03
Acc1@A_Z_WC_RR	-0.01	0.02	0.00	0.02	-0.01	-0.01	0.01	0.03	0.02	0.02	0.01	0.01
Acc2@A_X_CMass	0.66	-0.08	0.15	-0.03	-0.78	-0.26	0.14	0.04	0.05	0.03	0.10	0.05
Acc2@A_Y_CMass	-0.09	0.57	0.18	0.62	-0.06	0.41	0.02	0.11	0.06	0.09	0.01	0.06
Acc2@A_Z_CMass	0.09	-0.02	0.19	0.03	-0.05	-0.07	0.04	0.04	0.07	0.05	0.03	0.04
DIS@DIS_LF	-0.32	-0.16	-0.58	-0.27	0.37	0.09	0.13	0.16	0.56	0.24	0.06	0.14
DIS@DIS_RF	-0.40	0.23	0.09	0.26	0.39	0.34	0.02	0.04	0.07	0.05	0.04	0.03
DIS@DIS_LR	0.29	-0.24	0.24	-0.16	-0.30	-0.27	0.04	0.06	0.09	0.06	0.03	0.04
DIS@DIS_RR	0.22	0.23	-0.07	0.20	-0.29	0.09	0.01	0.03	0.04	0.03	0.02	0.01


表 8 压缩输入通道模型预测轮心力结果

Tab. 8 Wheel center force results predicted by the compressed input channels model


轮心力 Wheel center force	决定系数 Determination coefficient R^2	均方根误差 RMSE E_{RMSE}	平均绝对误差 MAE E_{MAE}	损伤相对误差 Relative error of damage/%	计算时间 Computational time/s
F_x	0.898 6	360.16	250.20	1.28	150.30
F_y	0.794 6	377.20	249.64	3.29	
F_z	0.916 8	426.07	292.91	7.61	
M_x	0.832 8	125.99	82.77	15.29	
M_y	0.962 4	68.06	48.59	13.28	
M_z	0.825 0	56.60	35.62	13.16	

值; n 为片段长度; R^2_{PSD} 为原始片段与划分片段两者在相同频域上的拟合程度; \tilde{y} 为原始片段在某一频带下的功率; \tilde{y} 为划分片段在该频带下的功率; $\bar{\tilde{y}}$ 为原始片段所有频带下的平均功率。以波形路[图 15(a)]、比利时路[图 15(b)]为例, P 值与伪损伤误差(六个分力总和)会随着片段长度的不断增加出现减小的趋势, 而 R^2 与 R^2_{PSD} 呈不断增加的趋势。进而根据较小的伪损伤误差与 P 值以及较高的决定系数来确定某个路况需要多长的片段载荷作为该路况的训练集。对其余路况进行相同计算, 得到各路况片段划分的最短时


长, 片段划分前、后对比如图 15(c) 所示。原始载荷信号长度总和为 678 s, 最小载荷信号长度总和为 502 s, 载荷数据样本量减少 26%。




(a) 原始信号
(a) Original signal



(b) 切片信号第 1 段
(b) First segment of the sliced signal



(c) 切片信号第 2 段
(c) Second segment of the sliced signal



(d) 切片信号第3段

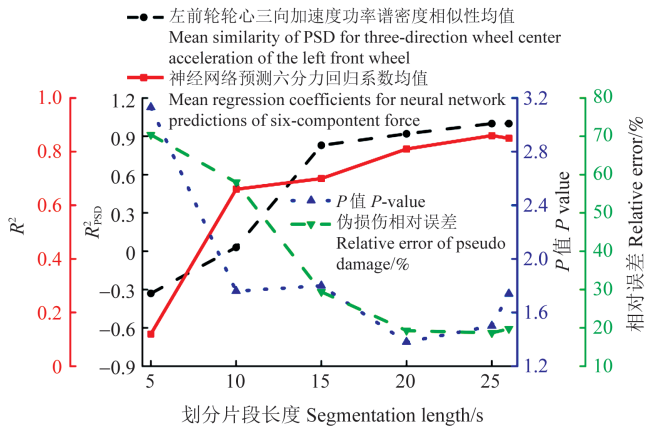
(d) Third segment of the sliced signal

图 14 载荷信号片段划分原理图

Fig. 14 Schematic diagram of the load signal segmentation

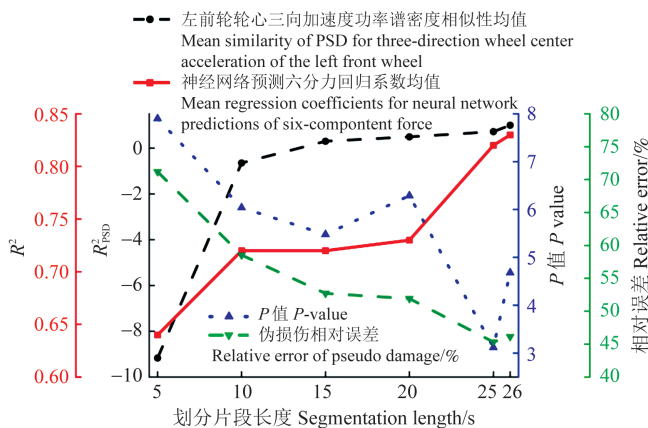
3.2.2 最小训练集预测精度复现

将各路况最短片段时间按照原始行驶路线进行拼接,拼接后训练集时长为 502 s,经过训练得到最小数据集模型,且各个六分力的预测精度如表 9 所示。同时,为确定该模型的普适性,随机打乱测试集各个路况的拼接顺序,并抽取 3 组示例。由表 9 可知,训练集减少,导致预测精度略有下降,相应的计算时间进一步缩短 9% 左右,而预测损伤仍能够复现原始载荷 80% 以上的损伤,甚至 90% 以上的损伤,且 3 次预测结果基本一致。这证明了构造的特征参数可确定各路况最小载荷谱片段时长,也验证了最小数据集模型对不同路况行驶顺序具有较高的泛化能力。



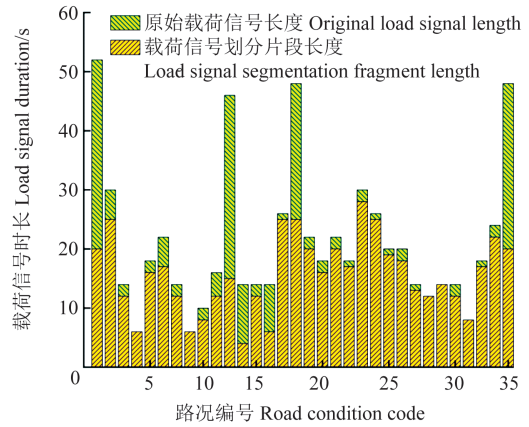
(a) 波形路特征参数

(a) Characteristics parameters of wavy road



(b) 比利时路特征参数

(b) Characteristics parameters of Belgium road



(c) 各路况片段划分结果

(c) Segmentation results of each road condition

图 15 载荷信号片段划分示意及结果

Fig. 15 Schematic and results of load segmentation

表 9 最小数据集模型预测轮心力精度

Tab. 9 Wheel center force accuracy predicted by minimum dataset model

数据集 Data set	轮心力 Wheel center force	决定系数 Coefficient of determination R^2	均方根 误差 $RMSE$ E_{RMSE}	平均绝对 误差 MAE E_{MAE}	损伤相对 误差 Relative error of damage/%	计算 时间 Computational time/s
原始行驶 路线 Original driving route	F_x	0.879 6	392.57	261.89	-8.03	132.33
	F_y	0.746 4	419.12	268	0.51	
	F_z	0.912 1	438.13	293.80	17.25	
	M_x	0.793 3	110.95	90.87	8.51	
	M_y	0.958 2	71.77	53.12	18.18	
	M_z	0.793 6	61.48	36.72	-8.46	
随机行驶 路线 1 Random driving route 1	F_x	0.880 0	391.94	261.79	-6.74	134.23
	F_y	0.746 6	419.06	268.07	4.13	
	F_z	0.912 0	438.26	300.78	17.25	
	M_x	0.793 5	140.05	90.86	6.14	
	M_y	0.958 6	71.43	53.10	18.75	
	M_z	0.793 4	61.51	36.74	-5.53	
随机行驶 路线 2 Random driving route 2	F_x	0.878 7	394.03	262.62	-5.77	135.41
	F_y	0.745 6	419.83	268.21	2.44	
	F_z	0.911 6	439.48	301.18	16.75	
	M_x	0.792 9	140.24	90.89	10.26	
	M_y	0.956 3	73.38	53.43	18.49	
	M_z	0.792 1	61.70	36.80	-8.54	
随机行驶 路线 3 Random driving route 3	F_x	0.878 6	394.23	262.58	-4.93	137.02
	F_y	0.746 4	419.26	268.21	1.62	
	F_z	0.911 4	439.76	301.25	17.17	
	M_x	0.793 3	140.13	90.92	3.19	
	M_y	0.955 8	73.87	53.44	18.05	
	M_z	0.792 9	61.59	36.79	-14.19	

4 结论

为克服试验场道路载荷实测及虚拟迭代技术获取轮心六分力方法的局限性,以轮心加速度、减振器位移和质心加速度为输入,设计了基于数据驱动的整车道路载荷快速预测模型,并对该模型进行了普适性验证。主要结论如下:

1) 基于 IMF 排列熵, 确定了原始载荷中存在白噪声; 针对噪声干扰对载荷信号进行 CEEMDAN-PE-WTD。20~50 Hz 频带噪声信息得到明显减少, 低频带有效载荷信号基本得到了保留。

2) 构建载荷预测多维度评价体系, 并对多路况初始预测模型进行了评估, 六分力预测值与实测值在时域、功率谱密度和损伤域上基本一致, 初始预测模型整体适用于各个路况, 载荷损伤误差均在 20% 以内, 符合工程要求。

3) 对 16 个输入通道特征与车轮六分力进行相关性、相干性分析。结果表明, 容易获取且成本低的输入通道特征与轮心力相关度较低, 但基于数据驱动的方法克服了这一局限性。进一步将 16 个输入通道压缩至 5 个输入通道, 减少数据冗余, 得到的压缩输入通道模型较好地复现了初始模型的预测精度。

4) 基于构造特征参数确定各路况的最小载荷信号片段, 划分片段后的训练集样本数量下降了 26%, 计算效率提高 28.85%。虽然预测精度略有降低, 但最小数据集模型在多维度评价体系中仍达到了期望的预测精度。同时, 变换车辆行驶路况顺序对于最小数据集模型预测六分力的精度影响几乎可以忽略, 验证了该模型具有较高的泛化能力。

5) 该方法在一定程度上能够加快以轮心载荷为基础的零部件以及整车的可靠性、耐久性开发与评价, 有助于快速提升汽车产品品质。

参考文献 (References)

- [1] 赵礼辉, 李佳欣, 井清, 等. 关联用户的汽车试验场耐久性评价路况循环确定方法研究[J]. 汽车工程, 2020, 42(1): 127-133. ZHAO Lihui, LI Jiaxin, JING Qing, et al. Research on the method of determining road condition cycles of durability test of correlated user automobile test field [J]. Automotive Engineering, 2020, 42(1): 127-133. (In Chinese)
- [2] 邹喜红, 凌龙, 陈静, 等. 用户关联的驱动桥试验场耐久性试验规范研究[J]. 中国机械工程, 2022, 33(14): 1670-1679. ZOU Xihong, LING Long, CHEN Jing, et al. Research on durability test specifications of user-association drive axle test fields [J]. China Mechanical Engineering, 2022, 33(14): 1670-1679. (In Chinese)
- [3] 冯金芝, 付道琪, 郑松林, 等. 悬架动态 K&C 试验典型激励谱的编制研究[J]. 机械强度, 2022, 44(4): 965-971. FENG Jinzhi, FU Daoqi, ZHENG Songlin, et al. Study on the compilation of typical excitation spectrum of suspension dynamic K&C test [J]. Journal of Mechanical Strength, 2022, 44(4): 965-971. (In Chinese)
- [4] 熊飞. 基于实车道路谱的车身疲劳寿命预测[D]. 广州: 华南理工大学, 2017: 56. XIONG Fei. The fatigue life prediction of car body structure based on real road spectrum [D]. Guangzhou: South China University of Technology, 2017: 56. (In Chinese)
- [5] 徐春. 汽车变速器道路载荷谱的采集和应用研究[D]. 北京: 北京理工大学, 2018: 28. XU Chun. Research for acquisition and application of vehicle transmission road load spectrum [D]. Beijing: Beijing Institute of Technology, 2018: 28. (In Chinese)
- [6] 王超. 基于虚拟试验场的车轮六分力提取方法研究[D]. 重庆: 重庆理工大学, 2022: 55. WANG Chao. Research on wheel six-component force extraction method based on virtual proving ground [D]. Chongqing: Chongqing University of Technology, 2022: 55. (In Chinese)
- [7] 李荣强, 连小锋, 朱睿, 等. 基于机器学习的飞机起落架着陆载荷预测模型[J]. 科学技术与工程, 2023, 23(18): 8011-8017. LI Rongqiang, LIAN Xiaofeng, ZHU Rui, et al. Prediction model of landing load of aircraft landing gear based on machine learning [J]. Science Technology and Engineering, 2023, 23(18): 8011-8017. (In Chinese)
- [8] 牟哲岳, 孙勇, 王瑞良, 等. 基于实测数据和机器学习的风电机组载荷预测模型[J]. 太阳能学报, 2023, 44(10): 414-419. MOU Zheyue, SUN Yong, WANG Ruiliang, et al. Prediction model for wind turbine loads based on experimental data and machine learning [J]. Acta Energetica Solaris Sinica, 2023, 44(10): 414-419. (In Chinese)
- [9] 杨博文, 霍军周, 张伟, 等. 服役结构超前载荷实时预测方法的研究[J]. 东北大学学报(自然科学版), 2022, 43(4): 541-550. YANG Bowen, HUO Junzhou, ZHANG Wei, et al. Research on real-time overload prediction method of in-service structures [J]. Journal of Northeastern University (Natural Science), 2022, 43(4): 541-550. (In Chinese)
- [10] 罗欢, 胡浩炬, 余家皓. 基于深度卷积-长短期记忆神经网络的整车道路载荷预测[J]. 汽车技术, 2021(7): 46-51. LUO Huan, HU Haoju, YU Jiahao, et al. Prediction of vehicle road load based on deep convolution neural network-long-short term memory [J]. Automobile Technology, 2021(7): 46-51. (In Chinese)
- [11] WANG Y, ZHENG X K, WANG L, et al. Edge-computing based soft sensors with local Finite Impulse Response models for vehicle wheel center loads estimation under multiple working conditions [J]. Control Engineering Practice, 2023, 133: 105447.
- [12] 韩雪飞, 施展, 华云松. 基于参数优化 MOMEDA 与 CEEMDAN 的滚动轴承微弱故障特征提取研究[J]. 机械强度, 2021, 43(5): 1041-1049. HAN Xuefei, SHI Zhan, HUA Yunsong, et al. Weak fault feature extraction of rolling bearing based on parameter optimized MOMEDA and CEEMDAN [J]. Journal of Mechanical Strength, 2021, 43(5): 1041-1049. (In Chinese)
- [13] ZHAO J W, NIE G Z, YAN M, et al. A novel approach to precipitation prediction using a coupled CEEMDAN-GRU-Transformer model with permutation entropy algorithm [J]. Water Science & Technology, 2023, 88(4): 1015-1038.
- [14] BANDT C, POMPE B. Permutation entropy: a natural complexity measure for time series [J]. Physical Review Letters, 2002, 88(17): 174102.
- [15] 李志军, 张鸿鹏, 王亚楠, 等. 排列熵—CEEMD 分解下的新型小波阈值去噪谐波检测方法[J]. 电机与控制学报, 2020, 24(12): 120-129. LI Zhijun, ZHANG Hongpeng, WANG Yanan, et al. Wavelet threshold denoising harmonic detection method based on permutation entropy-CEEMD decomposition [J]. Electric Machines and Control, 2020, 24(12): 120-129. (In Chinese)
- [16] 陈祥龙, 张兵志, 冯辅周, 等. 基于改进排列熵的滚动轴承故障特征提取[J]. 振动工程学报, 2018, 31(5): 902-908. CHEN Xianglong, ZHANG Bingzhi, FENG Fuzhou, et al. Fault

- feature extraction of rolling bearings based on an improved permutation entropy[J]. *Journal of Vibration Engineering*, 2018, 31(5): 902-908. (In Chinese)
- [17] ZHANG X L, CAO L Y, CHEN Y, et al. Microseismic signal denoising by combining variational mode decomposition with permutation entropy[J]. *Applied Geophysics*, 2022, 19(1): 65-80.
- [18] 徐隆, 杨军, 周龙, 等. PE-VMD 与小波阈值的干涉型光纤联合去噪方法[J]. *国外电子测量技术*, 2022, 41(10): 39-46.
XU Long, YANG Jun, ZHOU Long, et al. Joint denoising method for interferic fibers with PE-VMD and wavelet thresholds [J]. *Foreign Electronic Measurement Technology*, 2022, 41(10): 39-46. (In Chinese)
- [19] 于淼, 张耀鲁, 何禹潼, 等. 变分模态分解-排列熵方法用于分布式光纤振动传感系统去噪[J]. *光学学报*, 2022, 42(7): 62-73.
YU Miao, ZHANG Yaolu, HE Yutong, et al. Variational mode decomposition and permutation entropy method for denoising of distributed optical fiber vibration sensing system [J]. *Acta Optica Sinica*, 2022, 42(7): 62-73. (In Chinese)
- [20] 李冬毅, 覃方君, 李安, 等. 强噪声条件下原子重力仪小波降噪适应性研究[J]. *海军工程大学学报*, 2023, 35(2): 52-58.
LI Dongyi, QIN Fangjun, LI An, et al. Research on adaptability of wavelet denoising algorithm of atom gravimeter under strong noise conditions [J]. *Journal of Naval University of Engineering*, 2023, 35(2): 52-58. (In Chinese)
- [21] 宋秀兰, 董兆航, 单杭冠, 等. 基于时空融合的多头注意力车辆轨迹预测[J]. *浙江大学学报(工学版)*, 2023, 57(8): 1636-1643.
SONG Xiulan, DONG Zhaohang, SHAN Hangguan, et al. Vehicle trajectory prediction based on temporal-spatial multi-head attention mechanism [J]. *Journal of Zhejiang University (Engineering Science)*, 2023, 57(8): 1636-1643. (In Chinese)
- [22] 梁冠群, 赵通, 王岩, 等. 基于 LSTM 网络的路面不平度辨识方法[J]. *汽车工程*, 2021, 43(4): 509-517.
LIANG Guanqun, ZHAO Tong, WANG Yan, et al. Road unevenness identification based on LSTM network [J]. *Automotive Engineering*, 2021, 43(4): 509-517. (In Chinese)
- [23] 魏孟, 王桥, 叶敏, 等. 基于 NARX 动态神经网络的锂离子电池剩余寿命间接预测[J]. *工程科学学报*, 2022, 44(3): 380-388.
WEI Meng, WANG Qiao, YE Min, et al. An indirect remaining useful life prediction of lithiumion batteries based on a NARX dynamic neural network [J]. *Chinese Journal of Engineering*, 2022, 44(3): 380-388. (In Chinese)
- [24] 文昌俊, 陈哲, 邵明颖, 等. 基于改进 PSO_BP 神经网络的干燥剂可靠性预测[J]. *机械强度*, 2023, 45(2): 504-508.
WEN Changjun, CHEN Zhe, SHAO Mingying, et al. Reliability prediction of dryer based on improved PSO_BP neural network [J]. *Journal of Mechanical Strength*, 2023, 45(2): 504-508. (In Chinese)
- [25] LI D H, TIAN J W, SHI S W, et al. Lightweight design of commercial vehicle cab based on fatigue durability [J]. *Computer Modeling in Engineering & Sciences*, 2023, 136(1): 421-445.

Data-driven method for rapid prediction of vehicle road load

FENG Jinzhi^{1,2,3} LI Zenghong¹ ZHANG Dongdong^{1,2,3} LIU Dongjian⁴ ZHAO Lihui^{1,2,3}

- (1. School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)
 (2. CMIF Key Laboratory for Strength and Reliability Evaluation of Automotive Structures, Shanghai 200093, China)
 (3. Shanghai Technical Service Platform for Reliability Evaluation of New Energy Vehicles, Shanghai 200093, China)
 (4. CATARC Automotive Proving Ground Co., Ltd., Yancheng 224100, China)

Abstract: The six-component forces at the wheel-road interaction represent the sole coupling between the vehicle and the road surface, and obtaining these forces is critical for conducting reliability and durability assessments of the entire vehicle. In response to the high cost, long cycle, and low efficiency associated with traditional methods for obtaining wheel six-component forces, a data-driven approach for rapidly predicting wheel loads was proposed. Firstly, for the non-stationary random signals on real vehicle roads, a joint method of the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN), permutation entropy (PE), and wavelet threshold denoising (WTD) was applied for the data denoising. Secondly, the easily obtainable and low-cost data, such as wheel center acceleration, damper displacement, and center of mass acceleration, were used as inputs. Various neural network architectures with nonlinear transfer relationships were designed for multi-surface wheel six-component force prediction. A multi-dimensional load prediction evaluation system was established in the time domain, frequency domain, and damage domain. Finally, in order to overcome the challenges of a large and costly training dataset, an input channel compression method based on the correlation and coherence analysis of neural network inputs and outputs was proposed. Minimum load signal segment division criteria were introduced, and the minimum segment duration for each road surface was determined to compress the training dataset. Through continuous model iterations, the predicted values of the wheel six-component forces closely match the measured values, and the load characteristics are preserved. This demonstrates that the minimal dataset model can achieve a high level of prediction accuracy with fewer input channels and shorter load segment durations, resulting in a 28.85% improvement in computational efficiency.

Key words: Six-component force of the wheel center; Load prediction; Neural network; Damage assessment; Fatigue durability analysis

Corresponding author: ZHAO Lihui, E-mail: pheigoe@126.com

Fund: National Natural Science Foundation of China (51705322); Industry-Academia-Research Collaboration Project (H-2022-304-042)

Received: 2023-11-28 Revised: 2024-01-14