doi:10.6041/j.issn.1000-1298.2025.01.044

基于胎内周向应变的非道路轮胎垂向载荷反演优化算法研究

王亚东[1]　宋寅东[2]　王彦民[3]　张　剑[4]　何志祝[1]　李　臻[1]

(1. 中国农业大学工学院, 北京 100083; 2. 现代农装科技股份有限公司, 北京 100083;
3. 石家庄中兴机械制造股份有限公司, 石家庄 051530; 4. 贵州轮胎股份有限公司技术中心, 贵阳 550201)

摘要: 非道路轮胎具有结构尺寸大、工况恶劣多变、载荷波动明显等典型特征,其垂向载荷显著影响车辆的纵向、垂向、侧向动力学特性。针对非道路轮胎垂向载荷获取困难、传统物理模型推演精度不足的问题,提出了一种基于应变信息与机器学习技术的垂向载荷反演算法。以 R-1 型人字花纹非道路轮胎为研究对象,设计了由大量程柔性应变传感器、低功耗数据采集及无线传输模块组成的轮胎应变信息采集系统。以胎压、速度、载荷等参数为变量,在转鼓试验台上开展了多种典型工况测试,分析了轮胎接地点的应变变化规律。在此基础上,构建了面向轮胎垂向载荷估计的深度神经网络模型,并基于 AdamW 优化器与网格搜索法开展了算法参数优化。试验结果表明,基于 AdamW 优化器的深度神经网络模型对非道路轮胎垂向载荷预测表现出较高的精度,各工况下最大平均相对误差由 4.10% 降至 0.30%。此外,针对模型泛化能力的测试结果显示,深度神经网络模型平均归一化均方根误差较 SVR 模型降低 55.91%,泛化性能优越。研究表明,所提出基于 AdamW 优化器的深度神经网络模型可对以应变信息为输入的非道路轮胎垂向载荷进行准确反演,为非道路车辆的动力学控制系统提供可靠的轮胎力学关键参数获取依据。

关键词: 非道路轮胎; 周向应变; 载荷估计; 智能轮胎; 机器学习

中图分类号: U481　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)01-0463-11　　**OSID**:

Inverse Optimization Algorithm for Vertical Load of Non-road Tire Based on In-tire Circumferential Strain

WANG Yadong[1]　SONG Yindong[2]　WANG Yanmin[3]　ZHANG Jian[4]　HE Zhizhu[1]　LI Zhen[1]

(1. *College of Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Modern Agricultural Equipment Co.*, *Ltd.*, *Beijing* 100083, *China*
3. *Shijiazhuang Zhongxing Machinery Manufacture Co.*, *Ltd.*, *Shijiazhuang* 051530, *China*
4. *Technology Center*, *Guizhou Tyre Co.*, *Ltd.*, *Guiyang* 550201, *China*)

Abstract: Non-road tires have typical characteristics such as large structural size, harsh and changeable working conditions, and obvious load fluctuations. Its vertical load significantly affects the longitudinal, vertical and lateral dynamic characteristics of the vehicle. Aiming at the problem of difficulty in obtaining the vertical load of non-road tires and the insufficient accuracy of traditional physical model deductions, a vertical load inversion algorithm was proposed based on strain information and machine learning technology. Taking the R-1 herringbone pattern non-road tire as the research object, a tire strain information collection system consisting of a large-range flexible strain sensor, low-power data collection and wireless transmission module was designed. Using parameters such as tire pressure, speed, load as variables, a variety of typical working condition tests were carried out on the drum test bench, and the strain change pattern of the tire contact point was analyzed. On this basis, a deep neural network model for tire-oriented vertical load estimates was built. The algorithm parameter optimization was carried out

收稿日期: 2024-08-10　修回日期: 2024-09-21

基金项目: 国家重点研发计划项目(2022YFD2000300)、国家自然科学基金项目(52175259)和拼多多-中国农业大学研究基金项目(PC2023B01005)

作者简介: 王亚东(1999—),男,硕士生,主要从事农机装备地面力学研究,E-mail: wangyd_1@163.com

通信作者: 李臻(1988—),男,副教授,博士生导师,主要从事农机装备智能传感与控制技术研究,E-mail: zhenli@cau.edu.cn

based on the AdamW optimizer and grid search method. The test results showed that the deep neural network model based on AdamW optimizer showed a high accuracy on the prediction of the non-road tire vertical load prediction. Under the trial conditions, the maximum average relative error was reduced from 4.10% to 0.30%. Test results for the generalization capacity of models showed that the average naturalization of deep neural network models was reduced by 55.91% compared with the SVR model, and the generalization performance was superior. Studies showed that the deep neural network model proposed based on the AdamW optimizer had accurate reaction to the non-road tire vertical load. This method provided the basis for the acquisition of reliable key parameters of tire mechanics for the dynamic control system of non-road vehicles.

Key words: non-road tire; circumferential strain; load estimation; intelligent tire; machine learning

0 引言

非道路车辆的通过性和动载性能优异,适用于多种恶劣地形和复杂环境条件。轮胎作为非道路车辆承载与驱动的核心部件,在工程、农业、军事等领域中发挥着重要作用,常受交变重载和复杂地形冲击,其工作状态直接影响整车动态特性[1]。其中,轮胎垂向载荷在非道路车辆控制与行驶稳定性评估中占据重要地位。其不仅是轮胎与复杂路面间维持接触的关键参数,更是确保车辆在极端行驶条件下实现精确操控的基础。获取垂向载荷分布对优化非道路车辆的制动、加速及转弯性能,减少车身振动,提升行驶安全性具有重要意义。然而,传统测量方法面临试验系统复杂、测试设备昂贵及参数获取困难等诸多挑战。智能轮胎与机器学习技术的出现,为垂向载荷的测量提供了可能性[2]。

智能轮胎作为信息传感与轮胎技术的融合体,能基于敏感元件信号输出在线检测轮胎的工作状态。相关研究通过部署加速度式[3-4]、压电式[5-6]、应变式[7]、声波式[8-9]等传感器,实现了对轮胎侧偏角[10]、摩擦因数[11]、轮胎力[12-13]等关键信息估计。其中,关于轮胎力反演,国内外建立了 LuGre 模型[14]、Brush 模型[15]、SWIFT TIRE 模型[16-17]等多种估计模型。如王国林等[18]通过分析胎内加速度信号与轮胎接地角间关联性,结合轮胎柔性环模型建立了接地角-垂向力关系,实现了轮胎垂向力估计。DAKHLALLAH 等[19]采用扩展卡尔曼滤波器与摩擦模型实现了轮胎纵向力与横向力估计,并基于此进行了摩擦因数与侧滑角估计。但上述基于物理模型的轮胎载荷估计方法需进行大量轮胎及道路参数标定,实际应用中识别条件要求苛刻。并且由于系统非线性强、复杂度高、时变性与不确定性强的特点,导致识别精度底,难以实现轮胎力的实时解算[20]。近年来机器学习技术在轮胎载荷估计中的应用快速发展。赵健等[21]基于加速度信号特征值,采用神经网络模型对轮胎垂向力与纵向力进行了预测。但所使用 BP(Back propagation)神经网络结构相对简单,用于验证的数据集较少,无法充分反映预测效果。刘庆纲等[22]引入 Adam 优化的卷积神经网络,结合仿真获取的加速度数据对轮胎纵向力、侧向力和垂向力进行了预测,但未详细讨论优化算法对模型拟合结果的提升效果。相较于物理模型,机器学习算法在轮胎力估计中展现出低成本优势,在实时应用中具有较大潜力[23],但上述研究在模型优化、识别精度上具有提升空间,且数据外推能力未得到充分验证。

与道路轮胎相比,非道路轮胎具有大应变、高承载等特点,其行驶环境较铺装道路更加复杂,真实运行工况模拟困难。部分研究通过仿真手段开展理论验证[24-25],如 YANG 等[26]通过 DEM-FEM 联合仿真计算了越野轮胎与颗粒地形之间的主变形,且有效预测了越野轮胎在颗粒地形上的牵引性能。刘钇汛等[27]建立了重载轮胎的有限元模型,采用支持向量回归模型与周向应变数据,开展了垂向载荷的仿真结果估计。上述研究仅通过仿真进行理论验证,难以完全复现轮胎复杂工作环境,缺少针对实物试验的原理性分析。此外,关于非道路轮胎的研究以探究轮-土相互作用[28]或接地印痕与牵引特性间的关系[29]为主,缺乏对于真实轮胎载荷的估计与测量,导致非道路车辆整机性能优化缺少基础数据支持。因此,针对非道路轮胎,研究实物测试中的参数感知与载荷估计方法具有重要意义。

考虑到非道路轮胎中,农用轮胎的使用环境覆盖了全等级随机路面[30],本文以 R-1 型人字花纹轮胎为非道路轮胎典型代表,搭建多工况室内测试平台,采用基于 AdamW 算法优化的深度神经网络模型,开展轮胎垂向载荷反演算法研究。

1 轮胎应变采集试验系统设计

由于商用应变传感器受循环大应变下量程及使用寿命的限制,基于前期开发的柔性液态金属传感器感知轮胎内表面应变信息,并开发配套低功耗应

变采集与传输单元。为提高应变数据采集的精度和效率，确保试验条件的可控性，搭建非道路轮胎室内试验平台，开展针对 R－1 型人字花纹轮胎典型使用工况的台架试验。

1.1　感知系统与应变采集

基于前期研究工作[31]，采用拉伸量程达 400% 的柔性液态金属传感器作为敏感元件，搭建轮胎应变感知系统，以满足非道路轮胎大量程应变的测试需求，保证测试结果的可靠性。设计了如图 1 所示的低功耗胎内信号采集与传输装置，主要包括直流稳压模块、信号放大模块、集成 ADC 与蓝牙的采集与传输模块及射频天线。该装置由锂电池供电，满负荷工作电流为 10 mA，配备通用锂电池，可满足长时间无线测试要求，无需频繁拆装轮胎。直流稳压模块为系统和传感器提供稳定电源，采集与传输模块使用 ADC 芯片以采样频率 200 Hz 进行数据采集，并将数据存储于寄存器中，由主控芯片读取，通过蓝牙传输至上位软件进行记录。

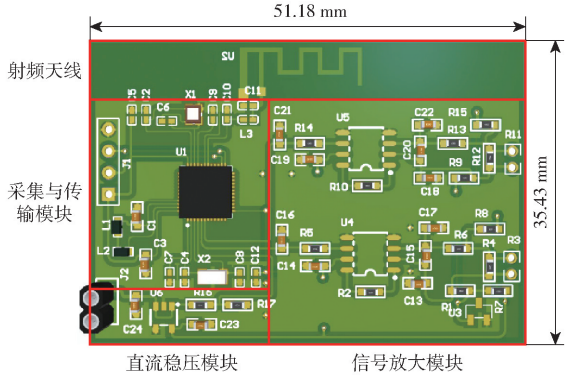

图 1　信号采集与传输装置

Fig. 1　Signal acquisition and transmission device

1.2　试验系统搭建

考虑到轮胎内衬层中心位置处对应变响应较为显著，结合被试轮胎内部纹理特征，将柔性应变传感单元部署在轮胎中心无花纹区域，数据采集单元及锂电池固定于其旁(图 2)。试验对象为某型号 R－1 型人字花纹子午线轮胎。如图 3 所示的室内轮胎转鼓试验装置用于轮胎加载试验，通过操作面板设置加载质量与速度，实现变工况响应测试。

1.3　试验工况设置

农用轮胎作业过程中需应对复杂地形条件和变负载工况，胎压、速度和载荷等关键参数对轮胎滑转率、牵引性能及作业效率有直接影响。因此，试验在保证被试轮侧偏角和外倾角恒定的条件下，探究了在不同胎压、速度、载荷下轮胎的动态应变响应行为。为确保轮胎初始温度一致，在试验测试前进行 15 min 滚动预热。具体试验工况设置速度为 5.0、7.5、10.0、12.0 km/h，胎压为 140、160、180、210 kPa。

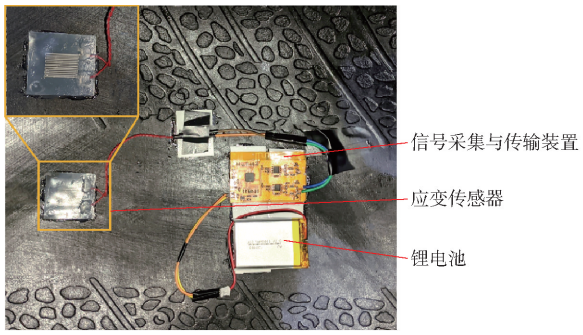

图 2　信号采集与传输装置胎内布置

Fig. 2　In-tire arrangement of signal acquisition and transmission device

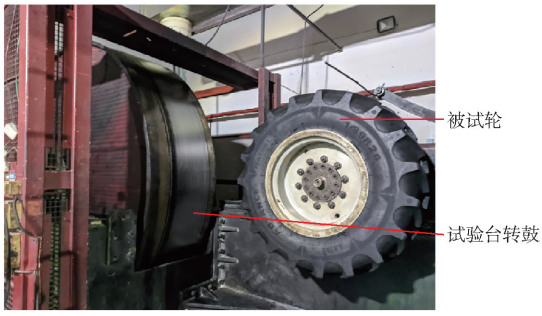

图 3　试验测试系统

Fig. 3　Test system for trial

其中，在同一胎压和速度下，轮胎载荷区间设置为 800～2 400 kg，步进载荷为 400 kg，各工况测试时间为 5 min。

2　数据分析与处理

2.1　试验数据分析

根据测试工况，针对不同速度、胎压、载荷工况下获取的轮胎应变数据进行分析，分析应变变化规律，为选取符合机器学习算法的数据特征提供依据。

试验共采集完整测试数据 4 979 组，单次测试工况设定为固定速度和胎压，考虑变载荷情况。由图 4 可知，载荷与纵向应变数据之间呈现显著的关联性，随载荷增加，传感器输出电压峰值相应增加，整体呈现阶梯状波形。为提取关键特征信息，对不同工况下应变传感器的响应情况作进一步分析。图 4 为恒定试验胎压(210 kPa)和载荷(800 kg)下，不同速度对应变的影响。结果表明，随着轮胎速度的提升，单位时间内的峰值出现次数呈现增长趋势，这与逐渐增加的轮胎速度相对应。此外，在相同的胎压和载荷条件下，不同速度下的应变曲线显示相对一致的峰值和谷值，并未观察到显著数值变化。

在胎压为 160 kPa、速度为 5.0 km/h 工况下，不同载荷对轮胎应变响应的影响如图 5 所示。结果表

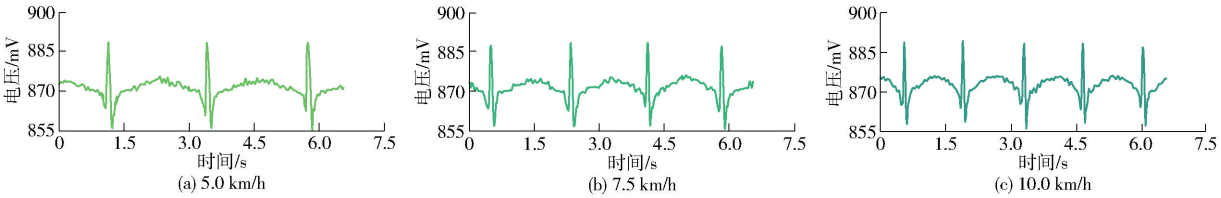

图 4 不同速度下周向应变信号变化曲线

Fig. 4 Variation curves of downward strain signal at different speeds

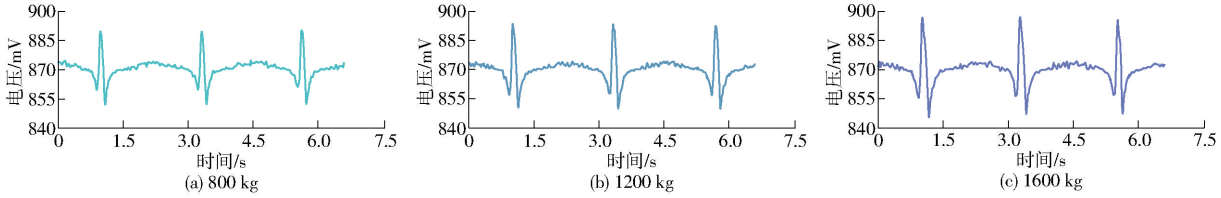

图 5 不同载荷下周向应变信号变化曲线

Fig. 5 Variation curves of downward strain signal under different loads

明,随载荷逐渐增大,应变曲线峰值呈现等间隔增大趋势,而两谷值则呈现降低趋势。这是由于轮胎在接地区域中心部位及接地点前后区域经历了更大的拉伸与挤压形变所导致。

在恒定速度 5.0 km/h、垂向载荷 1 200 kg 工况下,变胎压对应变传感器的响应规律如图 6 所示。随胎压逐渐增大,应变峰值呈现减小趋势,而两谷值则表现出增大趋势。此外,反映轮胎接地印痕长度的两谷值间距呈现下降趋势。该现象归因于胎压增加引起轮胎刚度的增加。在相同载荷下,轮胎接地点处的拉伸变形减小,对应应变曲线的峰值降低。同时,轮胎接地点两侧的压缩区域变形减小,导致曲线最小值增大。同时,在较大胎压下轮胎内衬的拉伸量相应增大,因此应变传感器初始值呈现上升趋势。

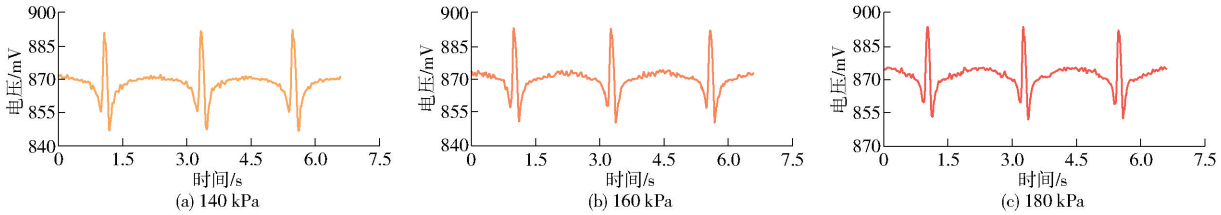

图 6 不同胎压下周向应变信号变化曲线

Fig. 6 Variation curves of downward strain signal with different tire pressures

2.2 数据预处理

为构建非道路轮胎垂向载荷估算模型,抑制原始数据噪声影响,并提升模型收敛速度,通过滤波、特征提取和归一化操作对试验数据进行预处理。

(1)滤波

小波降噪滤波器的多分辨率和时频局部化等特性可有效区分并去除信号中的噪声成分,保留原始信号的主要特征,减少噪声对后续数据分析的潜在影响。因此,采集的传感器纵向应变数据通过小波降噪滤波器对其进行处理,可表示为

$$W(a,b)=\int_{-\infty}^{\infty}f(t)\psi_{a,b}(t)\mathrm{d}t \tag{1}$$

$$\hat{W}(a,b)=\mathrm{Threshold}(W(a,b)) \tag{2}$$

$$\hat{f}(t)=\frac{1}{C_\psi}\int_{-\infty}^{\infty}\int_{0}^{\infty}\frac{1}{a^2}\hat{W}(a,b)\psi_{a,b}(t)\mathrm{d}a\mathrm{d}b \tag{3}$$

式中 $W(a,b)$——小波变换后数据

$f(t)$——原始信号

$\psi_{a,b}(t)$——小波基函数

a——尺度参数 b——平移参数

$\mathrm{Threshold}(\ )$——阈值选择函数

$\hat{W}(a,b)$——阈值处理后信号

$\hat{f}(t)$——降噪后信号

C_ψ——小波基函数容许性常数

由式(1)对原始数据进行小波变换,通过式(2)对小波系数进行阈值处理,去除信号噪声成分,并由式(3)将处理后的小波系数进行逆变换,得到降噪数据。

(2)特征提取

基于对被试轮应变数据的分析,选取用于机器学习的特征(图 7),具体包括以下指标:①波峰峰值(h_1),用于量化轮胎最大拉伸应变量。②两波谷谷值(h_2,h_3),分别表示轮胎接地区域两侧压缩变形量。③波峰与两波谷的差值(h_4,h_5),描述轮胎接地过程中压缩量绝对值。④两谷值差值(h_6),轮胎接触与离去过程中压缩变形量差值。⑤波峰与两波谷

间距(t_1,t_2),用于描述应变在时间维度上的变化特征。⑥轮胎速度(v)与胎压(p),轮胎测试状态参数。

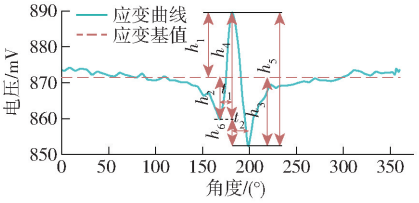

图 7　轮胎周向应变特征

Fig. 7　Tire circumferential strain characteristics

(3)归一化

为消除特征值间的量纲差异,提升机器学习模型训练效果与泛化能力,采用 Min - Max 归一化方法预处理数据。此方法通过线性变换将数据按比例缩放至特定区间。针对本研究中模型,各特征值归一化至[0,1]区间,而目标向量则归一化至[-1,1]区间。

3　垂向载荷估计模型构建

使用预处理试验数据,构建基于 AdamW 算法优化的深度神经网络模型(Deep neural network, DNN)。为评估该模型预测准确性,进一步建立支持向量回归模型(Support vector regression, SVR)进行对比分析。

3.1　深度神经网络构建

构建具有三隐藏层的前馈神经网络模型,结构如图 8 所示。在参数配置中,神经元数量设定显著影响预测误差。为寻找符合特征数据的最优神经元参数,采用网格搜索法对不同神经元组合进行参数调优,设置神经元数量选择区间为 5 ~ 60。为提升计算效率,步进参数设为 5。单组模型训练完成后,计算并记录其平均相对误差作为评价指标。共进行 1 728 组训练,系统评估不同神经元组合下误差分布情况。确定最优配置,选取具有最小平均相对误差的神经元组合(具体为 60、20、50 的 3 层神经元数量

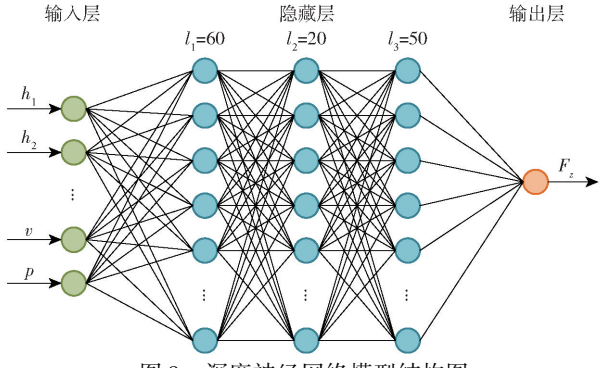

图 8　深度神经网络模型结构图

Fig. 8　Deep neural network model structure

分布),并将其设定为模型的最优参数集。

为兼顾模型收敛速度与载荷预测精度,引入非线性估计部分,选取 Swish 函数作为各隐藏层激活函数。分析可知,Swish 函数具有梯度平滑特点,可有效避免输出值的跳跃现象,减少深层神经网络中梯度消失现象,从而提升模型稳定性。同时,针对应用于回归的神经网络模型,选取均方误差作为损失函数。设置损失函数目标为 10^{-12},确保训练结果精度满足要求,并选取模型训练轮数为 4 000 轮,保证其有足够的机会学习并优化相关参数权重。为防止过拟合,设置最大失败次数为 6 次。将数据划分为训练集(70%)、验证集(15%)和测试集(15%),用于模型训练及参数调优。

3.2　深度神经网络模型优化

DNN 模型训练常采用随机梯度下降法(Stochastic gradient descent, SGD),其更新规则为[32]

$$\boldsymbol{\theta}_{t+1}=\boldsymbol{\theta}_t-\eta\boldsymbol{h}_t \tag{4}$$

其中

$$\boldsymbol{h}_t=\frac{\partial L_i}{\partial\boldsymbol{\theta}_j}=(y_i-\hat{y}_i)\frac{\partial\hat{y}_i}{\partial\boldsymbol{\theta}_j} \tag{5}$$

式中　$\boldsymbol{\theta}_t$——t 步模型参数向量

$\boldsymbol{\theta}_{t+1}$——$t+1$ 步模型参数向量

η——学习率

$\boldsymbol{h}_t$——目标函数在参数 $\boldsymbol{\theta}_j$ 处随机梯度

t——迭代次数

L_i——样本(x_i,y_i)处损失函数

y_i——真实观测值

$\hat{y}_i$——模型预测值

分析式(4)、(5)可知,SGD 算法每次对少量样本计算梯度并进行参数更新,虽提高了计算效率,但在迭代过程可能导致整体梯度方向偏离全局最优路径,从而增加模型收敛至最优解的难度,影响预测准确率。

考虑到 SGD 算法存在的不足,采用能够动态调整梯度方向与学习率的参数自适应算法来解决这一问题。由 KINGA 等[33]提出的 Adam 算法是利用梯度的一阶矩估计和二阶矩估计动态调整学习率,计算式为

$$\boldsymbol{\theta}_{t+1}=\boldsymbol{\theta}_t-\frac{\alpha}{\sqrt{\boldsymbol{v}_t}+\varepsilon}\boldsymbol{m}_t \tag{6}$$

其中

$$\boldsymbol{m}_t=\beta_1\boldsymbol{m}_{t-1}+(1-\beta_1)\boldsymbol{g}_t \tag{7}$$

$$\boldsymbol{v}_t=\beta_2\boldsymbol{v}_{t-1}+(1-\beta_2)\boldsymbol{g}_t^2 \tag{8}$$

式中　α——学习率

$\boldsymbol{v}_t$——t 步二阶动量估计,用于梯度方差估计

ε——数值稳定常数

$\boldsymbol{m}_t$——t 步一阶动量估计,用于累计梯度信息

β_1——一阶动量指数衰减率

$\boldsymbol{g}_t$——第 t 步梯度

β_2——二阶动量指数衰减率

算法利用校正后的一阶矩与二阶矩,结合式(6)可实现学习率自适应调整。然而,在出现梯度消失等问题时,算法存在不收敛情况。为解决该问题,LOSHCHILOV[34]引入加权衰减思想,并提出优化的 AdamW 算法。改进后迭代公式为

$$\boldsymbol{\theta}_{t+1}=\boldsymbol{\theta}_t-\frac{\alpha}{\sqrt{\boldsymbol{v}_t}+\varepsilon}\boldsymbol{m}_t-\alpha\lambda\boldsymbol{\theta}_t \tag{9}$$

式中 λ——权重衰减系数

对比式(6)、(9)可知,AdamW 算法在参数更新时减去 $\alpha\lambda\boldsymbol{\theta}_t$项,避免了权重惩罚不足现象,使得权重衰减更为有效,进一步提升了模型收敛速度与泛化能力。鉴于以上优点,选择 AdamW 算法作为深度神经网络模型优化算法,并设置学习率 $\alpha=0.01$、指数衰减率 $\beta_1=0.9$、$\beta_2=0.999$、权重衰减系数 $\lambda=0.01$ 作为初始参数,进而构建优化的深度神经网络模型。

3.3 对比模型构建

为评估 AdamW-DNN 模型对非道路轮胎载荷估计的准确性,进一步构建用作对比分析的支持向量回归模型。选取 ε-不敏感损失函数,其表达式为

$$L(y_\theta,f(x))=\begin{cases}0 & (|y_\theta-f(x)|\leqslant\varepsilon_\theta)\\ |y_\theta-f(x)|-\varepsilon_\theta & (|y_\theta-f(x)|>\varepsilon_\theta)\end{cases} \tag{10}$$

式中 y_θ——目标值

$f(x)$——模型预测值

ε_θ——不敏感区域大小,取 0.074 1

此外,选择径向基函数(Radial basis function,RBF)作为模型核函数,旨在将输入数据映射至高维空间执行线性回归,以提升模型对非线性问题的求解能力。SVR 模型中正则化参数 C 与核函数参数 γ 的设置至关重要。参数 C 控制误差容忍度,平衡模型的复杂性与稳定性;γ 影响核函数宽度,决定模型捕捉非线性特征的能力,调整数据点对模型决策的影响范围。为获取模型最佳性能,通过网格搜索法探索预定义参数空间中 C 与 γ 的最优组合。在 0.001~1 000 范围内,按照在对数坐标系中的分布均匀地选取 100 个点作为参数 C 的取值,而 γ 则在 10^{-2}~10^{2}范围内选取对数空间中的 100 个点作为取值范围。基于验证集数据,通过网格搜索历遍所有参数组合,以平均相对误差(Mean relative error,MRE)作为性能评价指标选择最优参数组合。最终确定模型最优参数组合 γ 为 0.24,C 为 1.87。

4 预测结果分析

为探究非道路轮胎载荷估计准确性,将 SVR 模型、SGD-DNN 模型与 AdamW-DNN 模型进行对比分析,围绕估计结果与误差分布等数据对模型预测准确性开展深入分析。

4.1 结果分析

不同胎压、载荷工况下模型预测结果,以均方根误差(Root mean square error,RMSE)、平均绝对误差(Mean absolute error,MAE)、平均绝对百分比误差(Mean absolute percentage error,MAPE)作为评估指标,将 SVR 模型载荷估计结果汇总(表 1)。其中,均方根误差为 32.09~46.28 kg,平均绝对误差为 31.91~36.39 kg,平均绝对百分比误差为 1.51%~4.10%。绘制不同载荷工况箱线图(图 9),图中显示,各工况预测值围绕真实值均匀分布,且预测值平均误差均保持在 10.43 kg 以内,最小值仅为 1.45 kg。

表 1 SVR 模型各工况载荷误差

Tab.1 Error of SVR model under each working condition

工况	RMSE/kg	MAE/kg	MAPE/%
胎压 140 kPa	38.64	33.06	2.33
胎压 160 kPa	38.93	31.91	2.30
胎压 180 kPa	46.28	36.39	2.42
胎压 210 kPa	43.00	35.11	2.46
载荷 800 kg	32.09	32.83	4.10
载荷 1 200 kg	39.02	33.02	2.75
载荷 1 600 kg	42.05	33.31	2.08
载荷 2 000 kg	44.87	35.11	1.76
载荷 2 400 kg	44.18	36.15	1.51

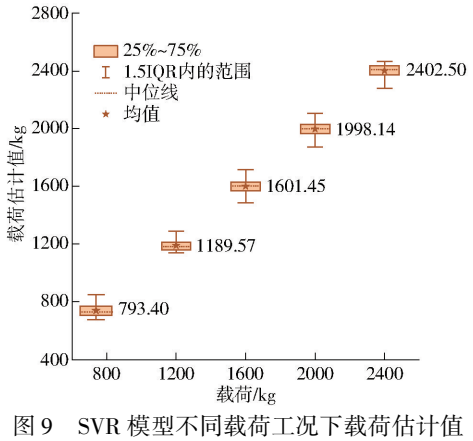

图 9 SVR 模型不同载荷工况下载荷估计值

Fig.9 Estimated values of SVR model under different load conditions

SGD-DNN 模型预测误差如表 2 所示。纵向对比各工况误差,不同胎压下均方根误差最大值为 31.32 kg、平均绝对误差最大值为 15.38 kg、平均绝

对百分比误差最大值为 0.97%，对应工况为 180 kPa。不同载荷工况下，预测结果最大均方根误差为 30.38 kg，最大平均绝对误差为 16.91 kg，最大平均绝对百分比误差为 1.06%，对应工况为 1 600 kg。此外，将 SVR 模型与 SGD－DNN 模型进行横向对比，分析 3 项评价指标可以看出，SGD－DNN 模型估计精度较 SVR 模型均有提升，且 SGD－DNN 各误差最大值均小于 SVR 模型误差最小值。

表 2　SGD－DNN 模型各工况载荷误差

Tab. 2　Error of SGD－DNN model under each working condition

工况	RMSE/kg	MAE/kg	MAPE/%
胎压 140 kPa	18.77	10.48	0.74
胎压 160 kPa	23.29	12.56	0.84
胎压 180 kPa	31.32	15.38	0.97
胎压 210 kPa	24.09	12.14	0.77
载荷 800 kg	10.09	5.95	0.74
载荷 1 200 kg	24.95	14.20	1.04
载荷 1 600 kg	30.38	16.91	1.06
载荷 2 000 kg	29.38	14.80	0.74
载荷 2 400 kg	21.60	10.05	0.43

SGD－DNN 模型载荷估计值分布箱线图（图 10）显示，模型最大均值误差为 2.54 kg，相比 SVR 模型下降 75.65%。不同载荷下四分位间距（IQR）先升高后降低，最大间距为 20.92 kg，且各工况下 IQR 均小于 SVR 模型。得益于模型结构不同，基于本试验数据下采用传统优化算法（SGD）的 DNN 模型载荷估计结果分布更为集中，估计性能优于 SVR 模型。

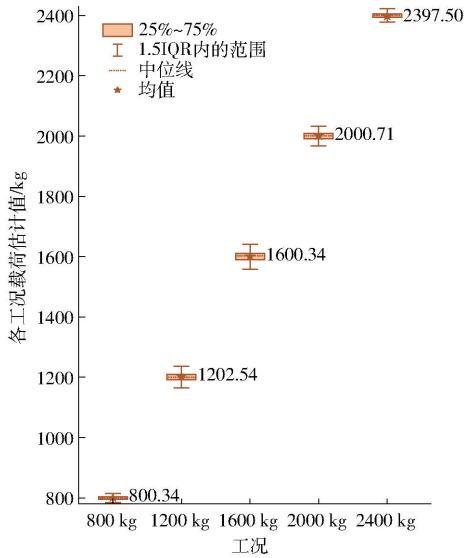

图 10　SGD－DNN 模型不同载荷工况下载荷估计值

Fig. 10　Estimated values of SGD－DNN model under different load conditions

进一步分析采用 AdamW 优化算法的 DNN 模型载荷预测结果。各载荷与胎压工况下，均方根误为 2.68 ~ 23.26 kg，平均绝对误差为 1.04 ~ 4.80 kg，平均绝对百分比误差为 0.10% ~ 0.30%（表 3）。与 SVR 模型及 SGD－DNN 模型相比，该模型 3 项误差评价指标均为最优。此外，变载荷工况下模型预测值箱线图（图 11）显示，各载荷工况中估计值的 IQR 在 4.50 kg 以内，较 SVR 模型降低 92.99%、较 SGD－DNN 模型降低 78.49%。结合以上数据可知，AdamW－DNN 模型在载荷预测准确性上优于 SVR 模型与 SGD－DNN 模型。

表 3　AdamW－DNN 模型各工况载荷误差

Tab. 3　Error of AdamW－DNN model under each working condition

工况	RMSE/kg	MAE/kg	MAPE/%
胎压 140 kPa	7.66	1.67	0.12
胎压 160 kPa	6.35	2.23	0.15
胎压 180 kPa	15.26	3.44	0.21
胎压 210 kPa	23.26	4.68	0.29
载荷 800 kg	2.68	1.04	0.13
载荷 1 200 kg	9.05	2.45	0.20
载荷 1 600 kg	14.80	4.80	0.30
载荷 2 000 kg	22.34	4.10	0.22
载荷 2 400 kg	16.03	2.34	0.10

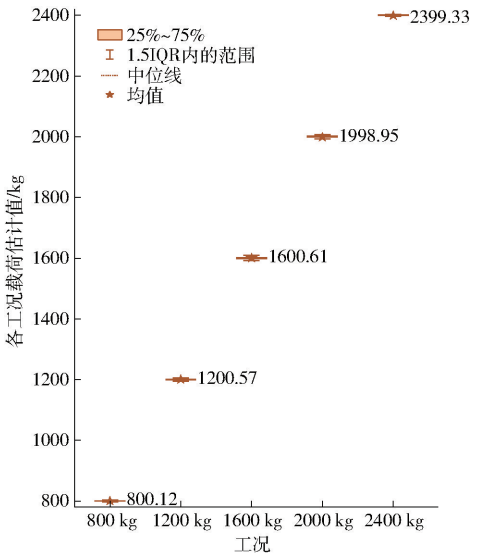

图 11　AdamW－DNN 模型不同载荷工况下载荷估计值

Fig. 11　Estimated values of AdamW－DNN model under different load conditions

统计 AdamW－DNN 模型预测值误差分布，结果如图 12 所示。整体误差分布呈现正态分布特征，主要误差区间集中在 -5 ~ 5 kg 之间，且该区间内的误差频率累计高达 91.20%。与 SVR 模型相比，AdamW－DNN 模型预测值误差分布更为集中，由此可知基于 AdamW 优化的 DNN 模型在载荷估计中具有更高的稳定性。

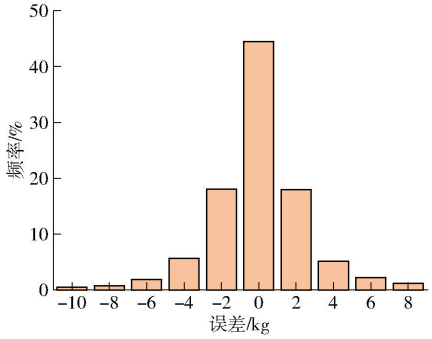

图 12 AdamW－DNN 模型误差分布

Fig. 12 Error distribution of AdamW－DNN model

为更直观展示 AdamW－DNN 模型在垂向载荷预测准确性方面的优势,绘制不同模型平均绝对误差对比图(图 13)做进一步分析。结果显示,在完整测试工况中,AdamW－DNN 模型的最大平均绝对误差仅为 4.80 kg(发生在载荷 1 600 kg 工况),相较于 SVR 模型的最大平均绝对误差 36.15 kg(发生在载荷 2 400 kg 工况)及 SGD－DNN 模型的最大平均绝对误差 16.91 kg(发生在载荷 1 600 kg 工况)均有降低。此外,在载荷 800 kg 工况下,AdamW－DNN 模型相较于 SVR 模型的误差下降率最大可达 96.83%,且其余工况下降率均超过 80%。而对比 SGD 优化算法,应用 AdamW 算法的 DNN 模型误差下降率均高于 70%,最大下降率可达 82.75%。该结果进一步验证了 AdamW－DNN 模型在非道路轮胎垂向载荷估计中的性能表现优于 SGD－DNN 模型与 SVR 模型。

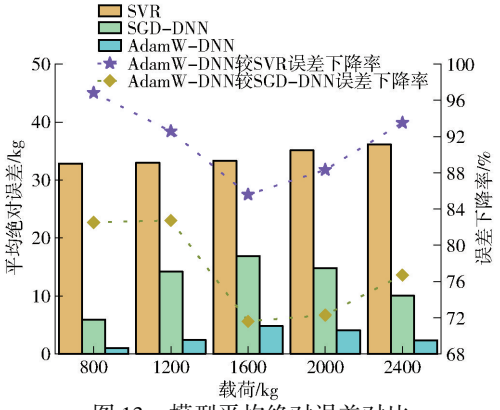

图 13 模型平均绝对误差对比

Fig. 13 Comparison of mean absolute errors of models

4.2 泛化能力对比

模型泛化能力可表示模型对未知数据进行准确预测或分类的能力,其中交叉验证(Cross-validation,CV)法是评估模型泛化能力的有效方法[10]。考虑到 10 折交叉验证可充分利用数据集,减少评估结果受特定数据划分方式产生的影响,本文采用该方法对 AdamW－DNN 模型和 SVR 模型的外推性能进行分析。10 折交叉验证中,将完整试验数据集均匀划分为 10 个子集。每次迭代选取 9 个子集作为训练集,剩余 1 个子集作为独立的测试集用于评估模型性能。通过迭代,确保每个子集均被用作测试集。在每次迭代后,计算测试集的归一化均方根误差(Normalized root mean square error, NRMSE)以量化模型数据外推性能。表 4 为 3 种模型 NRMSE,图 14 为 3 种模型泛化能力对比。分析数据可知,SVR 模型 NRMSE 集中于 6.24% ~8.01% 之间,平均值为 6.85%,SGD－DNN 模型误差则分布于 2.39% ~6.68%,平均值降低至 3.80%。相比之下,AdamW－DNN 模型 NRMSE 为 1.87% ~3.57%,且平均值仅为 3.02%。此外,AdamW－DNN 模型各折下拟合误差均低于 SVR 模型,平均 NRMSE 下降 55.91%。同时,与 SGD 优化算法相比,采用 AdamW 优化算法的 DNN 模型数据外推时误差分布更为集中,且在交叉验证测试中有 70% 误差结果优于 SGD 算法。验证结果表明,AdamW－DNN 模型较 SVR 模型与 SGD－DNN 模型在不同数据子集中均展现出更为优异的数据外推能力。

表 4 10 折交叉验证误差对比

Tab. 4 Ten fold cross-validation error comparison

%

折数	SVR	SGD－DNN	AdamW－DNN
1	6.78	6.68	2.84
2	6.98	3.55	2.96
3	6.27	2.64	3.33
4	6.42	4.18	3.31
5	6.93	3.59	3.28
6	6.24	3.76	2.67
7	6.48	2.88	3.57
8	7.23	2.39	2.99
9	7.14	5.35	3.44
10	8.01	3.03	1.87

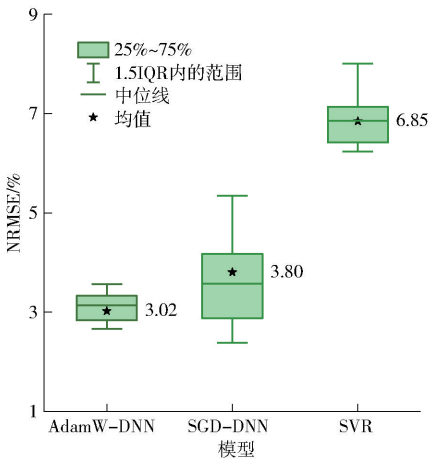

图 14 模型泛化能力对比

Fig. 14 Comparison of generalization ability of models

考虑数据量对 3 种模型泛化能力的影响,对其

做进一步对比。针对不同载荷工况，随机抽取各工况下完整数据集的 30% 和 60% 用作模型外推性能分析，并对抽取数据进行 10 折交叉验证测试，交叉验证的平均归一化均方根误差见表 5。在 30% 完整数据集的小样本测试中，3 个模型估计误差均保持在 11.18% 内，且 AdamW－DNN 模型计算的平均 NRMSE 较其余模型最大减小 26.20%。将数据集增加至 60% 完整数据，AdamW－DNN 模型估计效果依然优于其余 2 个模型，但随数据量增加，3 个模型估计误差下降率逐渐减小，总体误差均值逐渐接近。进一步将数据集由 60% 增加至 100%，由于模型结构特点，SVR 模型误差下降率低于其余 2 个模型，但训练速度优于二者。同时，采用 AdamW 优化算法的模型估计效果与误差下降率依然优于 SGD 算法。通过对比可知，本文采用的 AdamW－DNN 模型在不同数据量下相较于传统 SGD－DNN 模型与 SVR 模型均表现出更为优异的数据外推能力。

表 5　不同数据量归一化均方根误差对比

Tab.5　Normalized root mean square error comparison of different data volumes　%

数据集占比/%	SVR	SGD－DNN	AdamW－DNN
30	11.18	9.30	8.25
60	7.29	6.72	6.05
100	6.85	3.80	3.02

针对数据特征对 3 个模型泛化能力的影响，在原有 10 组输入特征基础上进行筛选，分别设置 4 组特征、7 组特征进行对比。在 4 组特征选取中，考虑到最大拉伸应变峰值 h_1、最大压缩应变峰值 h_3、两谷值间距 (t_1+t_2)、轮胎压力 p 共 4 组参数与轮胎受载变形关联最为密切，故选其作为第 1 组对比工况。在此基础上补充可进一步反映轮胎应变的特征参数：谷值 h_2、峰值与谷值间差值 h_4、h_5。由上述 7 个特征作为第 2 组对比工况。对 3 组工况进行 10 折交叉验证对比，记录平均归一化均方根误差（表 6）。3 组不同特征数量对比中，Adamw－DNN 模型拟合误差在 3 组模型中均为最低，且相较于其余两模型误差下降率超 20.15%。随特征数量减小，3 组模型误差均呈现增大趋势，但基于 AdamW 优化算法的深度神经网络模型增长率仅为 37.75% 与 80.05%，增加趋势较其余两模型更为缓慢。因此，在确保基础特征前提下，减小特征数量对 AdamW－DNN 模型影响最小，并且可有效降低模型训练时间，减小模型训练成本。

表 6　不同特征归一化均方根误差对比

Tab.6　Normalized root mean square error comparison of different features　%

特征数	SVR	SGD－DNN	AdamW－DNN
4	15.01	9.80	7.49
7	9.53	5.21	4.16
10	6.85	3.80	3.02

5　结论

（1）针对非道路轮胎接地区域的大应变特征，应用大量程柔性应变传感器，开发了低功耗信号采集与传输装置，为非道路轮胎应变获取提供了可靠的信息感知与传输路径。同时，基于轮胎转鼓试验台搭建了动载测试平台，为增加数据采集的准确性、提升试验效率提供了可控的测试环境，并以胎压、速度、载荷等参数为变量，开展了多种典型工况测试。

（2）考虑不同试验工况下轮胎接地区域特点，深入分析了应变数据的变化规律，并系统地对原始数据开展了滤波、特征提取和归一化处理。基于预处理数据提出了用于非道路轮胎垂向载荷估计的深度神经网络模型，并结合 AdamW 算法开展了模型优化。在此基础上，进一步建立了用作对比分析的支持向量回归模型。

（3）通过 AdamW－DNN 模型与 SVR 模型开展了非道路轮胎垂向载荷预测，并将 2 个模型预测结果与误差分布进行了对比分析。结果显示，AdamW－DNN 模型在均方根误差、平均绝对误差和平均绝对百分比误差 3 项评价指标中均优于 SVR 模型与 SGD－DNN 模型，且误差分布更为集中。同时，在泛化能力评估中，交叉验证结果显示，AdamW－DNN 模型的平均归一化均方根误差较 SVR 模型降低 55.91%，并且在小样本数据量及特征中均有良好数据外推能力。研究结果表明，提出的基于 AdamW 优化器的深度神经网络模型在非道路轮胎载荷反演中可有效反演轮胎垂向力，可为非道路车辆动力学性能研究和稳定性控制提供数据支撑和理论依据。

参　考　文　献

[1] XU R, WANG W. Establishment and analysis of passingness evaluation index of off-road vehicle based on PCA[J]. IOP Conference Series Earth and Environmental Science, 2020, 440:032110.

[2] XIONG Y, YANG X. A review on in-tire sensor systems for tire-road interaction studies[J]. Sensor Review, 2018, 38(2): 231－238.

[3] BARBOSA B H G, XU N, ASKARI H, et al. Lateral force prediction using Gaussian process regression for intelligent tire

systems[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 52(8): 5332 - 5343.
[4] KIM H J, HAN J Y, LEE S, et al. A road condition classification algorithm for a tire acceleration sensor using an artificial neural network[J]. Electronics, 2020, 9(3): 404.
[5] MENDOZA-PETIT M F, GARCIA-POZUELO D, DIAZ V, et al. A strain-based method to estimate tire parameters for intelligent tires under complex maneuvering operations[J]. Sensors ,2019, 19(13):2973.
[6] BAI N, WANG L, WANG Q, et al. Graded intrafillable architecture-based iontronic pressure sensor with ultra-broad-range high sensitivity[J]. Nature Communications, 2020, 11(1): 209.
[7] MENDOZA-PETIT M F, GARCÍA-POZUELO D, DÍAZ V, et al. A strain-based intelligent tire to detect contact patch features for complex maneuvers[J]. Sensors, 2020, 20(6): 1750.
[8] LONGORIA R G, BRUSHABER R, SIMMS A. An in-wheel sensor for monitoring tire-terrain interaction: development and laboratory testing[J]. Journal of Terramechanics, 2019, 82: 43 - 52.
[9] EUN K, LEE K J, LEE K K, et al. Highly sensitive surface acoustic wave strain sensor for the measurement of tire deformation [J]. International Journal of Precision Engineering and Manufacturing, 2016, 17: 699 - 707.
[10] XU N, HUANG Y, ASKARI H, et al. Tire slip angle estimation based on the intelligent tire technology [J]. IEEE Transactions on Vehicular Technology, 2021, 70(3): 2239 - 2249.
[11] MENDOZA-PETIT M F, GARCIA-POZUELO D, DIAZ V, et al. Characterization of the loss of grip condition in the strain-based intelligent tire at severe maneuvers[J]. Mechanical Systems and Signal Processing, 2022, 168: 108586.
[12] JEONG D, KIM S, LEE J, et al. Estimation of tire load and vehicle parameters using intelligent tires combined with vehicle dynamics[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1 - 12.
[13] GARCIA-POZUELO D, OLATUNBOSUN O, YUNTA J, et al. A novel strain-based method to estimate tire conditions using fuzzy logic for intelligent tires[J]. Sensors, 2017, 17(2): 350.
[14] YAMASHITA H, MATSUTANI Y, SUGIYAMA H. Longitudinal tire dynamics model for transient braking analysis: ANCF-LuGre tire model[J]. Journal of Computational and Nonlinear Dynamics, 2015, 10(3): 031003.
[15] CARCATERRA A, ROVERI N. Tire grip identification based on strain information: theory and simulations[J]. Mechanical Systems and Signal Processing, 2013, 41(1 - 2): 564 - 580.
[16] 黄小靖, 张峰, 张士文, 等. 智能轮胎的垂向载荷测量[J]. 汽车工程, 2020, 42(9): 1270 - 1276.
HUANG Xiaojing, ZHANG Feng, ZHANG Shiwen, et al. Vertical load measurement of automotive intelligent tire [J]. Automotive Engineering, 2020, 42(9): 1270 - 1276. (in Chinese)
[17] 孙瑞,王亚东,李怡宁,等. 基于粒子群算法的农用轮胎柔性环模型参数辨识方法[J]. 农业机械学报,2024,55(4): 402 - 410.
SUN Rui, WANG Yadong, LI Yining, et al. Parameter identification method for agricultural tire flexible ring model based on particle swarm optimization algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(4):402 - 410. (in Chinese)
[18] 王国林, 韩桐, 周海超, 等. 应用模型的智能轮胎垂向力估计算法[J]. 汽车工程, 2021, 43(12): 1865 - 1870.
WANG Guolin, HAN Tong, ZHOU Haichao, et al. Intelligent tire vertical force estimation algorithm based on model[J]. Automotive Engineering, 2021, 43(12): 1865 - 1870. (in Chinese)
[19] DAKHLALLAH J, SÉBASTIEN, MAMMAR S, et al. Tire-road forces estimation using extended Kalman filter and sideslip angle evaluation[C]// American Control Conference. IEEE, 2008.
[20] 曾俊玮,季元进,任利惠,等. 卡尔曼滤波器与神经网络串行的轮胎载荷识别模型[J]. 振动与冲击, 2023, 42(11):262 - 270.
ZENG Junwei, JI Yuanjin, REN Lihui, et al. A serial tire load identification model based on Kalman filter and neural network [J]. Journal of Vibration and Shock, 2023, 42(11): 262 - 270. (in Chinese)
[21] 赵健, 路妍晖, 朱冰, 等. 内嵌加速度计的智能轮胎纵/垂向力估计算法[J]. 汽车工程, 2018, 40(2): 137 - 142.
ZHAO Jian, LU Yanhui, ZHU Bing, et al. Estimation algorithm for longitudinal and vertical forces of smart tire with accelerometer embedded[J]. Automotive Engineering, 2018, 40(2): 137 - 142. (in Chinese)
[22] 刘庆纲,郭昊,魏旭明,等. 基于轮胎加速度信号的胎路作用力估算模型[J]. 天津大学学报(自然科学与工程技术版), 2023,56(2):177 - 183.
LIU Qinggang,GUO Hao,WEI Xuming, et al. Tire-road force estimation model based on a tire acceleration signal[J]. Journal of Tianjin University(Science and Technology), 2023,56(2):177 - 183. (in Chinese)
[23] YANG S, CHEN Y, SHI R, et al. A survey of intelligent tires for tire-road interaction recognition toward autonomous vehicles [J]. IEEE Transactions on Intelligent Vehicles, 2022, 7(3): 520 - 532.
[24] VASQUEZ F, LOT R, RUSTIGHI E, et al. Tyre forces estimation for off-road motorcycles[J]. Mechanical Systems and Signal Processing, 2021, 150: 107228.
[25] EL-SAYEGH Z, EL-GINDY M, JOHANSSON I, et al. Development and validation of off-road tire-gravelly soil interaction using advanced computational techniques[J]. Journal of Terramechanics, 2020, 91:45 - 51.
[26] YANG P, ZANG M, ZENG H, et al. The interactions between an off-road tire and granular terrain: GPU-based DEM - FEM simulation and experimental validation[J]. International Journal of Mechanical Sciences, 2020, 179: 105634.

[27] 刘钇汛,刘志浩,高钦和,等. 基于周向应变分析的重载轮胎垂向力估计算法[J]. 上海交通大学学报, 2023, 57(10): 1273 – 1281.
LIU Yixun, LIU Zhihao, GAO Qinhe, et al. Vertical force estimation of heavy-loaded radial tire based on circumferential strain analysis[J]. Journal of Shanghai Jaotong University, 2023, 57(10):1273 – 1281. (in Chinese)
[28] MITUSCH S K, FUNKE S W, KUCHTA M. Hybrid FEM – NN models: combining artificial neural networks with the finite element method[J]. Journal of Computational Physics, 2021, 446: 110651.
[29] DE MENDONKA W S, ZIMMERMANN G G, MORENO F G, et al. Validation of an electro-hydraulic press for dynamic measurement of elastic deformations in agricultural tires[J]. Smart Agricultural Technology, 2023, 6: 100329.
[30] LI Z, MITSUOKA M, INOUE E, et al. Parameter sensitivity for tractor lateral stability against Phase I overturn on random road surfaces[J]. Biosystems engineering, 2016, 150: 10 – 23.
[31] DONG H, WANG Z, YANG C, et al. Liquid metal-based flexible sensing and wireless charging system for smart tire strain monitoring[J]. IEEE Sensors Journal, 2024, 24(2): 1304 – 1312.
[32] 常禧龙,梁琨,李文涛. 深度学习优化器进展综述[J]. 计算机工程与应用,2024,60(7):1 – 12.
CHANG Xilong, LIANG Kun, LI Wentao. Review of development of deep learning optimizer[J]. Computer Engineering and Applications, 2024, 60(7): 1 – 12. (in Chinese)
[33] KINGA D, ADAM J B. A method for stochastic optimization[C]// International Conference on Learning Representations (ICLR), 2015.
[34] LOSHCHILOV I. Decoupled weight decay regularization[J]. arXiv Preprint, arXiv:1711.05101, 2017.

(上接第 462 页)

[34] HOPKINS D L, LAMB T A, KERR M J, et al. Examination of the effect of ageing and temperature at rigor on colour stability of lamb meat[J]. Meat Sci., 2013, 95(2): 311 – 316.
[35] 王琳琳, 陈炼红, 张岩. 不同部位牦牛肉宰后成熟过程中肉色稳定性研究[J]. 食品与发酵工业, 2022, 48(20): 29 – 35.
WANG Linlin,CHEN Lianhong,ZHANG Yan. Study on the flesh color stability of different parts of yak meat during postmortem aging[J]. Food and Fermentation Industries,2022,48(20): 29 – 35. (in Chinese)
[36] HE X, LIU R, NIRASAWA S, et al. Effect of high voltage electrostatic field treatment on thawing characteristics and post-thawing quality of frozen pork tenderloin meat[J]. Journal of Food Engineering, 2013, 115(2): 245 – 250.
[37] DOMÍNGUEZ R, PATEIRO M, MUNEKATA P E S, et al. Protein oxidation in muscle foods: a comprehensive review[J]. Antioxidants, 2021, 11(1):60.
[38] OCAÑO-HIGUERA V M, MAEDA-MARTÍNEZ A N, MARQUEZ-RÍOS E, et al. Freshness assessment of ray fish stored in ice by biochemical, chemical and physical methods[J]. Food Chemistry, 2011, 125(1): 49 – 54.
[39] GE S, CHEN Y, DING S, et al. Changes in volatile flavor compounds of peppers during hot air drying process based on headspace – gas chromatography – ion mobility spectrometry (HS – GC – IMS)[J]. Journal of the Science of Food and Agriculture, 2020, 100(7): 3087 – 3098.
[40] FENG Y, CUI C, ZHAO H, et al. Effect of koji fermentation on generation of volatile compounds in soy sauce production[J]. International Journal of Food Science & Technology, 2013, 48(3): 609 – 619.
[41] MAHMOUD M A A, BUETTNER A. Characterisation of aroma-active and off-odour compounds in german rainbow trout (*Oncorhynchus mykiss*). Part Ⅱ: case of fish meat and skin from earthen-ponds farming[J]. Food Chemistry, 2017, 232: 841 – 849.
[42] 张凯华, 臧明伍, 张哲奇, 等. 水浴复热时间对猪肉糜制品挥发性风味的影响[J]. 食品科学, 2019, 40(2): 186 – 191.
ZHANG Kaihua, ZANG Mingwu, ZHANG Zheqi, et al. Effects of water-bath reheating time on volatile compounds in cooked minced pork[J]. Food Science, 2019, 40(2): 186 – 191. (in Chinese)
[43] 赵玉欣, 韩丽娟, 葛世鹏, 等. 基于 GC – IMS 分析不同提取方法对藏羊油脂挥发性风味的影响[J/OL]. 中国油脂, https://doi.org/10.19902/j.cnki.zgyz.1003-7969.230517.