

DOI: 10.11883/bzycj-2024-0318

数据驱动的动力电池包侧面柱碰撞安全性预测方法*

马骋浩, 庄梓傲, SHIN Jonghyeon, 邢伯斌, 夏 勇, 周 青
(清华大学智能绿色车辆与交通全国重点实验室, 北京 100084)

摘要: 电动汽车电池包在侧面柱碰撞下极易失效并可能发生着火。为准确、快速地评估电池包在侧面柱碰撞下安全性, 本文采用了区域细化的电池包模型, 在不同的碰撞速度、碰撞角度、碰撞位置, 车辆装载状态下开展仿真分析, 采用了优化拉丁超立方采样策略设计了仿真矩阵, 并通过图像识别的方法批量提取电池包碰撞响应生成数据集。对研究参数进行组合生成了新特征, 并对参数进行相关性分析确定了模型训练的输入特征。采用了支持向量机 (Support vector machine, SVM)、随机森林方法 (random forest, RF) 和误差反向传播神经网络机器学习 (back propagation neural networks, BPNN) 方法建立了数据驱动的预测模型。结果表明, 支持向量机模型性能最优, 模型预测参数的平均决定系数 R^2 为 0.96。为训练数据集引入标准差不同的高斯噪声, 以对模型鲁棒性进行检验, BPNN 的鲁棒性较优。建立的数据驱动模型能预测电池包侧面柱碰撞下的变形情况, 评估电池包碰撞安全性。

关键词: 电池包; 碰撞安全性; 侧面柱碰撞; 机器学习; 有限元仿真

中图分类号: O383; U469.72

国标学科代码: 1303530

文献标志码: A

Data-driven safety prediction of battery pack under side pole collision

MA Chenghao, ZHUANG Ziao, SHIN Jonghyeon, XING Bobin, XIA Yong, ZHOU Qing

(National Key Laboratory of Intelligent Green Vehicles and Transportation, Tsinghua University, Beijing 100084, China)

Abstract: The battery pack of electric vehicles is highly susceptible to failure under side pole collision. To accurately and quickly evaluate the safety of battery packs under such conditions, this paper introduces a local region refined battery pack model that can effectively characterize the deformation and mechanical response of the jellyroll of battery. Simulation analyses were conducted under varying impact velocity, angles, positions, and vehicle loading configuration, with the latter achieved by uniformly applying mass compensation to the side wall of the battery pack. A simulation matrix was designed using an optimized Latin hypercube sampling (LHS) strategy, and a dataset was generated through image recognition methods. This dataset includes parameters such as the maximum intrusion depth, intrusion location, intrusion width of the battery pack side wall, and the deformation of the jellyroll of battery. New features, including collision energy and velocity components in the x and y directions, were derived and selected as input features for model training through correlation analysis. Support vector machine (SVM), random forest (RF), and back propagation neural networks (BPNN) were employed to build a data-driven predictive model. The SVM model demonstrated superior performance, achieving an average R^2 of 0.96 across prediction parameters. The prediction of the maximum intrusion depth of the battery pack side wall was particularly accurate, with an R^2 exceeding 0.95 for all three models. Additionally, the robustness of the models was tested by introducing Gaussian noise, where the BP neural network exhibited better robustness. Even with the addition of Gaussian noise with a standard deviation of 0.5, the BP model maintained an average R^2 of 0.91 for the prediction parameters. The established data-driven model can effectively predict mechanical response of battery packs under side pole collisions and provide a reliable tool for evaluating battery pack safety.

Keywords: battery pack; crash safety; side pole collision; machine learning; finite element simulation

* 收稿日期: 2024-08-31; 修回日期: 2024-10-16

第一作者: 马骋浩 (2002—), 男, 博士研究生, mch23@mails.tsinghua.edu.cn

通信作者: 夏 勇 (1976—), 男, 博士, 副研究员, xiaiyong@tsinghua.edu.cn

随着电动汽车在汽车市场中占比逐年增加,其碰撞安全性已经成为实际应用中不可忽视的问题^[1]。电动汽车在发生侧面柱碰撞后,动力电池包极易失效,引发电池内部短路和热失控,造成财产损失并威胁人员生命安全。因此,电池包在侧面柱碰撞工况下的碰撞安全性受到了广泛的关注。

针对电池碰撞变形,Li 等^[2]和 Lai 等^[3]分别揭示了电池在受到面外和面内方向挤压后变形模式和力学行为。Sahraei 等^[4-5]建立了电池失效与电池发生内短路之间的相关性。Xiao 等^[6]揭示了方壳电池变形失效导致内短路的原因是电池单体中隔膜被刺穿以及电池电解液的泄漏。

研究人员通过建立有限元模型来模拟电池包的力学行为。Xia 等^[7]建立了底部碰撞工况下电池组有限元模型,揭示了电池受底部冲击下的变形失效机理。Kukreja 等^[8]提出了一种电池组配置方式,该方法有助于提高电池包在碰撞的能量吸收效果,并建立了整车有限元模型进行碰撞分析。Zhang 等^[9]采用拓扑优化的方法对电动汽车车身结构进行了设计,建立了车身的有限元模型,优化了传力路径进而提高了耐撞性。Chen 等^[10]采用有限元模型揭示了电池排布方式对电池包失效的影响规律,并提出了一种新的电池单体错落排布方式,该错落排布方式提升了电池包在侧面碰撞工况下的安全性。

物理实验需要耗费大量的资源和时间,有限元模型的计算时间长,均难以应用于电池包碰撞安全性的快速预测。近年来,采用机器学习方法建立的数据驱动模型因其快速性和准确性,被广泛应用于对仿真结果的快速预测^[11]。通过有限元仿真获得大量数据来训练机器学习模型,保证模型的预测精度。Zhang 等^[12]依托有限元仿真数据,结合机器学习开发了多目标结构优化设计框架,设计了 C 截面双稳态复合材料结构。Pan 等^[13]基于有限元仿真数据建立了电池包数据驱动模型,用于预测电池包在受挤压时的最大应力和变形。Xu 等^[14]建立了电池包在底部锥形壁障冲击工况下机械安全性的评估模型,并在模型中加入了高斯噪声来验证了模型的鲁棒性。

本文中,提出一种数据驱动的动力电池包侧面柱碰撞安全性的预测方法,在输入碰撞的速度、角度、位置以及当前车辆的整备状态后,能快速预测电池包的损伤和电池卷芯的变形情况,评估电池包的碰撞安全性。本文中建立能表征电池变形的电池包有限元模型,采用优化超拉丁立方采样策略确立仿真矩阵,通过图像识别的方法批量提取结果并生成数据集,进而通过相关性分析确定模型训练的输入特征,并比较不同机器学习算法的训练效果,得到预测模型。以期采用该数据驱动的预测模型,可以实时快速准确地预测出电池包侧面碰撞安全性风险。

1 有限元模型

1.1 电池包碰撞仿真模型与边界条件设置

现行的 C-NCAP 法规^[15]和 GB/T 37337—2019《汽车侧面柱碰撞的乘员保护》^[16]中规定侧面柱碰撞工况是整车以 32 km/h 的碰撞速度和 75°的碰撞角度,撞向固定的直径为 254 mm 的圆柱障碍物。考虑到整车仿真成本高,难以进行大规模的仿真,本文中采用电池包层级有限元仿真,其有限元模型在 Ls-Dyna 平台中建立,构建过程与文献 [17] 中的类似。电池包有限元模型如图 1 所示,包含 27 个方壳电池模组,2 个横梁将电池包划分为 3 个区域,模型质量为 386 kg。

为考察电池包在侧面柱碰撞动态冲击工况下的风险,电池模组的建模包含了电池卷芯、端盖、侧板、垫片、集流板等部件,电池模组的构建方案采用了 Qu 等^[18]构建方法。考虑计算效率,电池包采用了区域细化的布置方案,方案与文献 [17] 的方案一致,如图 1 所示。在靠近载荷一侧采用电池模组的精细模型,在侧面碰撞远端采用了简化模型和替代模型,模组模型如图 2 所示。电池包仿真中未设置地面,不考虑重力的影响。电池包以一定的初速度与固定的刚体圆柱面碰撞,并在电池包螺栓孔上施加质量补偿,以模拟车辆的装载情况。仿真时间步长设置为 0.36 μs ,因限定时间步长带来的模型质量增加为 3.2%,处于可接受范围。本研究主要关注电池包从开始碰撞到回弹开始阶段,因此仿真时间设置为 30 ms。

预测模型选取了碰撞速度 v 、碰撞角度 θ 、质量补偿 m 、障碍物直径 d 以及碰撞位置 p 作为输入参数。碰撞速度和质量补偿影响电池包的初始动能和电池包结构的塑性变形情况,其中碰撞速度范围为

27~52 km/h, 碰撞角度范围为 90°~75°, 质量补偿范围为 100~300 kg, 均匀地施加在电池包侧壁 14 个螺栓孔上。电池包耐撞性在横梁位置较好, 邻近的电池变形风险小, 处于两横梁之间的电池模组碰撞变形风险大。碰撞位置初始位置如图 1(b) 所示, 障碍物位置沿 x 方向的变化范围为 0~120 mm。在整车碰撞中, 障碍物侵入电池包时, 由于周边结构的作用, 电池包侧壁变形涉及区域的特征尺寸会大于障碍物直径^[19], 因此将障碍物直径作为仿真矩阵的参数, 范围为 254~354 mm。




图 1 仿真模型和设置

Fig. 1 Simulation model and configuration




图 2 不同电池模组模型

Fig. 2 Different types of battery model module

1.2 仿真矩阵与优化拉丁超立方采样方法

电池包模型中建立了考虑卷芯层级变形的精细电池模组, 仿真矩阵包含了 5 个参数, 为控制仿真算例个数, 并保证模型训练的输入数据在所涉及的参数范围内分布合理, 需引入仿真矩阵参数设计策略, 以减少仿真算例数量, 并保证数据采集的完整性。尽管传统拉丁超立方方法保证了样本点在样本空间分布的均匀性, 但会有空间填充性能差的问题^[20]。因此, 本研究采用了优化拉丁超立方采样方法, 使样本点更加离散, 占据整个样本空间。

优化的目标是最大化 2 个样本点之间的最小特征距离, 样本点之间的特征距离定义为:

$$\max : \min d(x_i, x_j) = \left(\sum_{k=1}^M |x_{ik} - x_{jk}|^t \right)^{1/t} \quad t = 1 \text{ or } 2 \quad (1)$$

式中: x_i 和 x_j 为 2 个样本点; M 为维度, 本研究中有 5 个参数, 因此样本空间共有 5 个维度; t 在本研究中取 2。为保证每个参数在优化过程中的影响程度相同, 在对最小特征距离进行优化之前需要对样本数据下式进行归一化处理:

$$x'_{ik} = \frac{x_{ik} - x_{\text{down}}}{x_{\text{up}} - x_{\text{down}}} \quad (2)$$

式中: x_{ik} 和 x'_{ik} 分别为归一化前后的样本值, x_{up} 和 x_{down} 分别为对应参数范围的上限和下限。

本研究按优化拉丁超立方采样方法共生成了 200 组样本点, 样本点的分布和核密度估计函数图如图 3 所示, 图中右上角为样本分布的散点图, 对角线为频率直方图, 左下角为核密度函数图。频率直方图显示样本点在各个区间分布均匀。散点图和核密度函数图显示样本点分布是离散的, 样本空间的填充效果良好。优化前后的最小特征距离分别为 0.07 和 0.16, 表明采用优化超拉丁立方采样方法的样本点分布更离散。优化的超拉丁立方采样方法设计的输入特征相互依赖性较弱, 可以减少多重共线性问题对模型稳定性和准确性的影响。

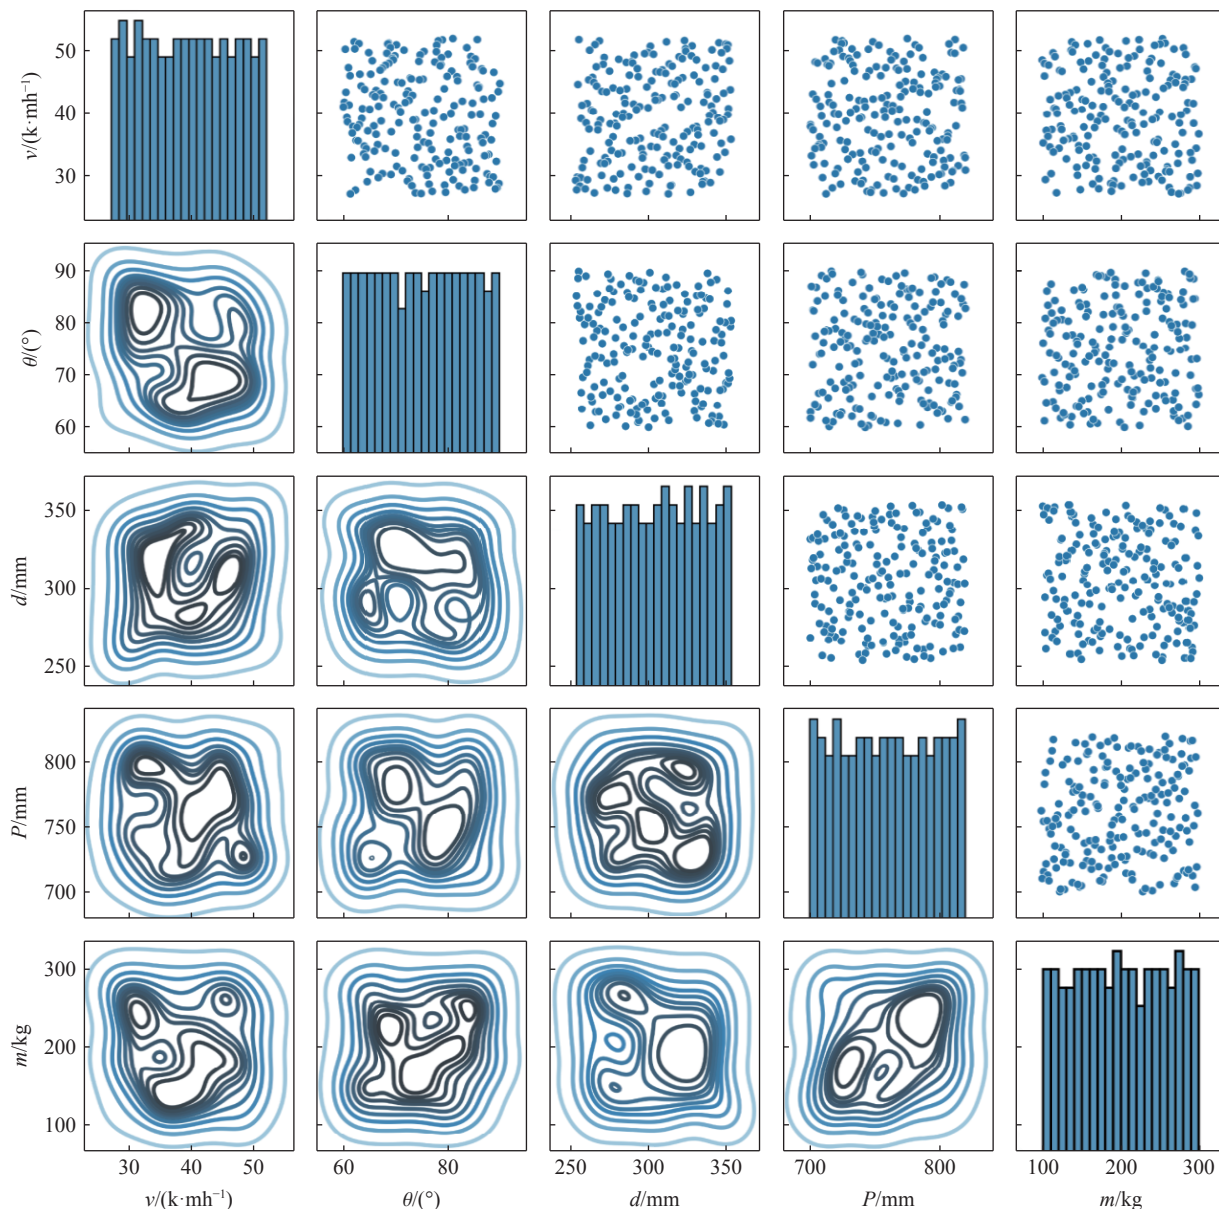


图 3 优化拉丁超立方采样生成的仿真矩阵样本分布

Fig. 3 Sample distribution of simulation matrix generated by optimized Latin hypercube sampling

2 数据集的搭建

2.1 指标的选择和提取

依据设计的仿真矩阵开展了 200 组仿真, 选取了碰撞速度 39.6 km/h、碰撞角度 89.1°、障碍物直径 288.2 mm、碰撞位置 110.9 mm 和质量补偿 110.9 kg 的仿真结果进行分析。该组仿真中, 电池包侧面柱碰

撞结果如图 4 所示。在电池包受到侧面柱碰撞冲击过程中, 电池包的变形损伤具有局部性。电池包横梁结构为主要传力部件, 用于传递冲击载荷。其中电池包侧壁响应体现了碰撞的严重程度, 电池卷芯的侵入量体现了短路失效的风险。因此, 本研究中采用侧壁侵入宽度 W 、最大侵入深度 I_1 、最大侵入位置 X_{\max} 以及卷芯最大侵入量 I_2 作为评价损伤情况和碰撞风险的指标。以电池包作为参考系, 侧壁的右下角 O 点作为原点, 建立直角坐标系, 可以得到电池包侧壁下边界曲线, 如图 5 所示。其中最大侵入深度 I_1 定义为该曲线的最大值, 最大侵入位置 X_{\max} 定义为该曲线的最大值的横坐标, 最大侵入宽度 W 定义为 AB 的长度, 卷芯的最大侵入量 I_2 定义为图 5 中卷芯 9 个位置侵入量的最大值, 卷芯的侵入量定义为 CD 长度的变化量。




图 4 电池包侧面柱碰撞仿真结果
Fig. 4 Simulation result of battery pack side pole collision




图 5 电池包仿真结果后处理示意图
Fig. 5 Schematic diagram of post-processing of battery pack simulation results

随后, 采用图像识别的方法对仿真矩阵中碰撞后电池包侧壁几何结果进行批量提取。首先, 利用自适应直方图均衡化增强图像对比度; 之后, 进行高斯滤波和中值滤波去除图像噪声; 随后, 采用高斯平滑使得边界更加光滑, 并采用 Canny 边缘检测算法识别出包含电池包碰撞后侧壁下边界的边界曲线; 最后, 基于得到的边界曲线建立新坐标系以提取上述指标参数, 生成数据集。

2.2 相关性分析和特征工程

在进行机器学习前, 通过数据预处理识别提取出高度相关的特征, 能提升模型预测的准确性。在电池包侧面柱碰撞工况中, 碰撞速度和质量补偿直接决定电池包的初始动能, 从而对电池包结构的塑性变形和损伤情况产生影响。因此, 引入电池包初始动能 e 作为新特征:

$$e = \frac{1}{2}(m_0 + m)v^2 \quad (3)$$

式中: m_0 为电池包初始质量。

同时通过对碰撞速度和碰撞角度的组合, 引入了新特征 v_x 和 v_y , 分别为碰撞速度在 x 和 y 方向的分量。Pearson 相关系数能够表征不同变量之间的相关关系:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4)$$

式中: r 为 Pearson 相关系数, n 为样本数量, x_i 和 y_i 为第 i 个观测值, \bar{x} 和 \bar{y} 分别为 x 和 y 的均值。Pearson 相关系数绝对值越接近于 0, 表明相关性越弱。计算数据集中输入特征和预测特征之间的 Pearson 相关系数, 得到图 6 所示的热力图。




图 6 Pearson 相关系数分析热力图

Fig. 6 Pearson correlation coefficient analysis heat map

由图 6 可以看出, 输入特征与待预测参数之间的相关性较高, 即输入特征能够很好地解释待预测参数的变化。同时, 由于障碍物尺寸与待预测指标相关性弱, 不将其作为输入特征。同质量补偿 m 相比, 引入的特征电池包初始动能 e 与待预测参数的相关性更高。与碰撞速度 v 和碰撞角度 θ , 速度的分量 v_x 和 v_y 与待预测参数的相关性较高。因此, 选取碰撞位置、电池包初始动能、 x 方向碰撞速度与 y 方向碰撞速度作为机器学习模型训练的输入特征。

3 数据驱动模型

3.1 机器学习方法

机器学习的方法在各个领域已广泛运用。本研究选取了 3 种常用的机器学习算法, 包括支持向量机方法 (SVM), 随机森林方法 (RF) 和误差逆向传播神经网络方法 (BPNN)。支持向量机是一种监督学习算法, 通过核函数将数据映射到高维特征空间进行线性回归。该算法可以通过核函数捕捉电池包侧面柱碰撞边界条件和待预测的仿真结果之间的非线性关系, 实现高精度的预测。BP 神经网络是一种模拟生物神经系统的计算模型, 由多个层次的人工神经元组成。每个神经元接收输入信号并经过加权处理, 传递到下一层, 最终在输出层生成结果。神经网络善于处理非线性问题, 能准确预测电池包侧面柱碰撞复杂的变形和损伤模式。随机森林方法是一种基于决策树的集成学习方法, 通过构建多棵决策树, 将每棵树的预测结果进行综合, 减少过拟合的风险, 提高模型的整体预测性能。

机器学习模型输入特征为仿真的边界条件特征, 结合相关性分析的结果, 分别为碰撞位置 p 、碰撞速度分量 v_x 、 v_y 与电池包初始动能 e 。模型的输出为仿真结果, 包括电池包侧壁侵入深度 I_1 、侵入宽度 W 、最大侵入位置 X_{max} 和电池卷芯侵入深度 I_2 。这些指标反映了电池包侧面柱碰撞的安全性和风险。流程图如图 7 所示, 各类机器学习算法超参数解释和取值如表 1 所示。

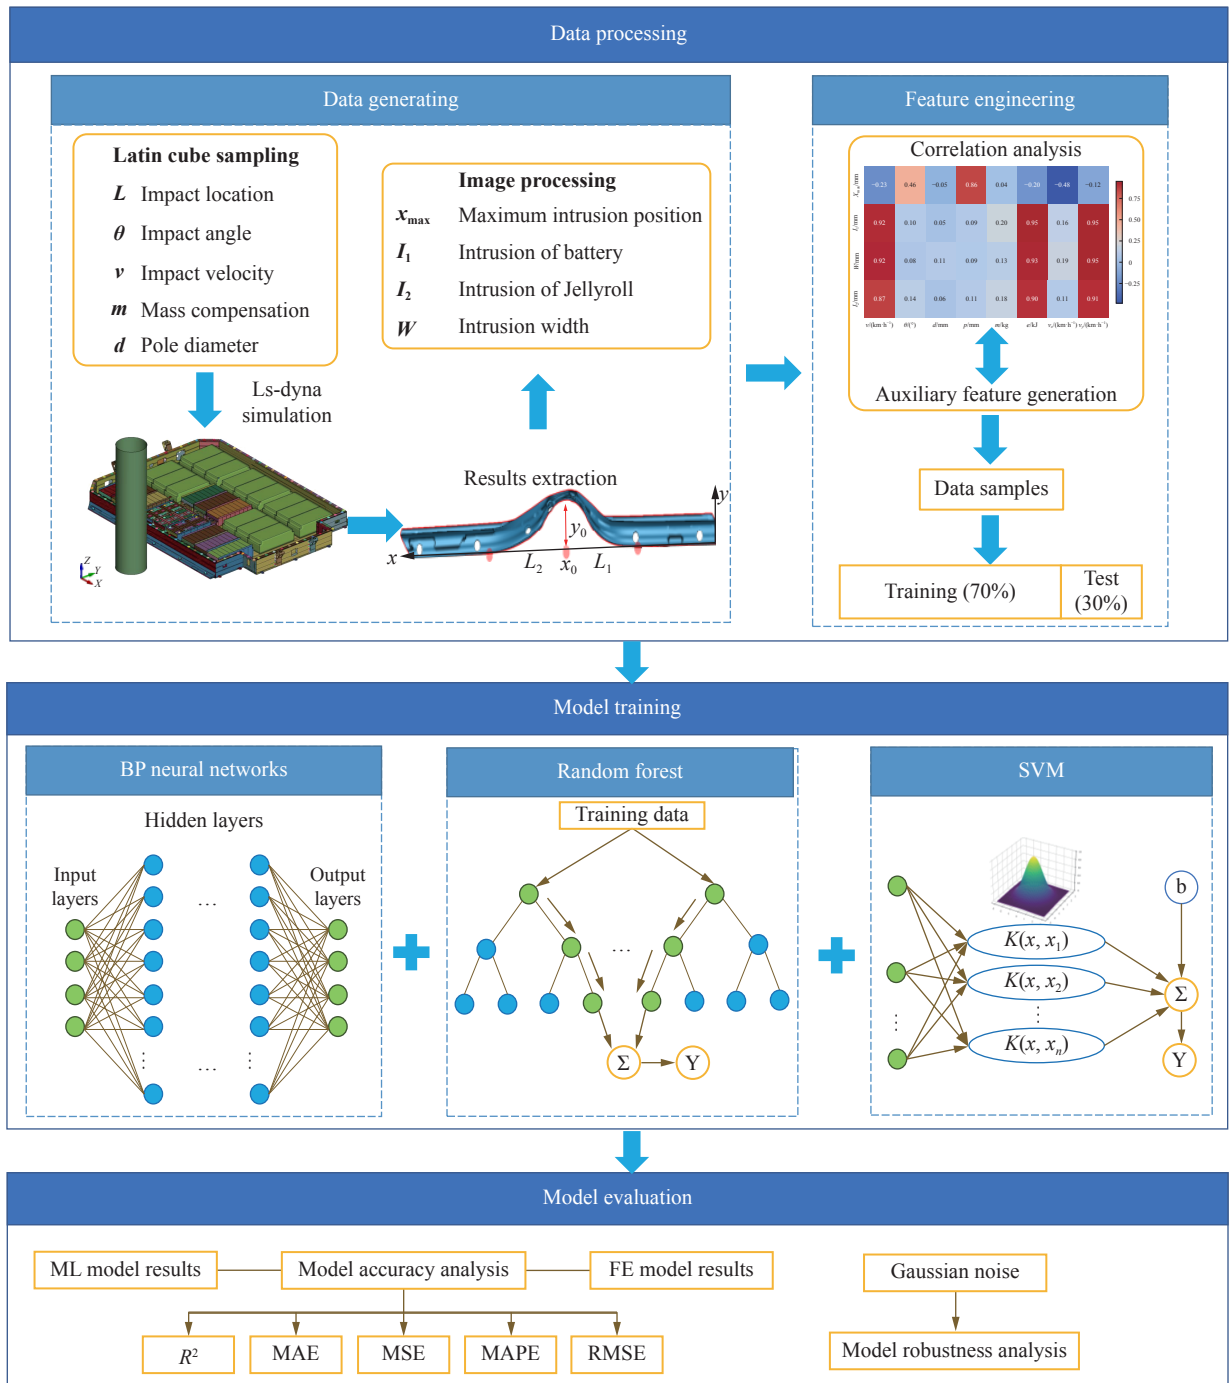


图 7 数据驱动模型建立流程图

Fig. 7 Data-driven model building flowchart

表 1 机器学习模型超参数组合

Table 1 Machine learning model hyperparameter selection

算法	超参数	取值
随机森林	随机森林中树的数量	100
	控制树的最大深度	None
	分割内部节点所需的最小样本数	2
	叶子结点上所需的最小样本数	1

表 1 (续)
Table 1 (Continued)

算法	超参数	取值
支持向量机	控制回归模型的惩罚程度	100
	误差惩罚边界	0.5
	核函数	'rbf'
BP神经网络	隐藏层	(50,50)
	线性激活函数	'identity'

3.2 结果与讨论

建立的各类机器学习模型对电池包碰撞安全性预测效果如图 8~10 所示。图中横轴表示仿真结果,纵轴表示模型预测值,散点的颜色表示相对误差,相对误差超过 10% 的数据点均显示为红色。该图展示了预测结果与仿真结果之间的差异。由图 8 可知,大部分数据点落在直线 $y=x$ 附近,模型的预测值接近仿真值,对电池包侧壁的最大侵入位置、最大侵入量、侵入宽度以及卷芯的最大侵入量整体预测效果良好。在对卷芯侵入位置的预测中,相对误差较大,原因是在碰撞速度和碰撞能量较低的工况中,电池卷芯并未受到挤压,此时卷芯侵入量为零,导致相对误差较高。

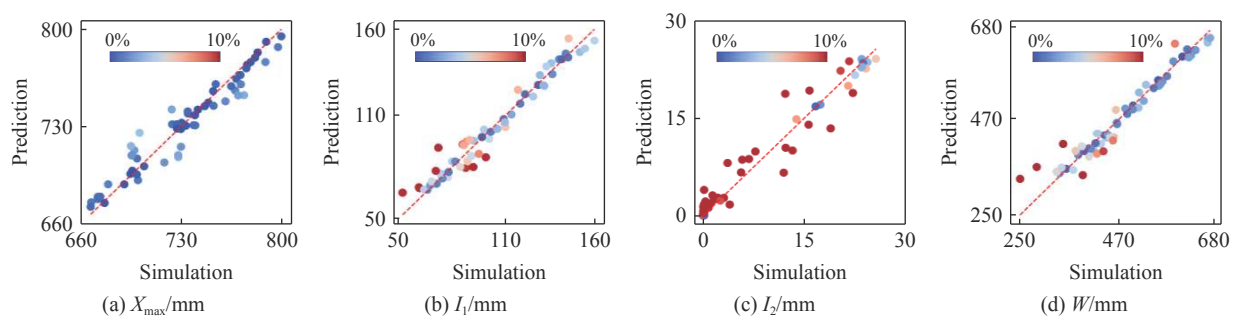


图 8 随机森林模型预测结果与仿真结果的比较

Fig. 8 Comparison between RF model prediction results and simulation results

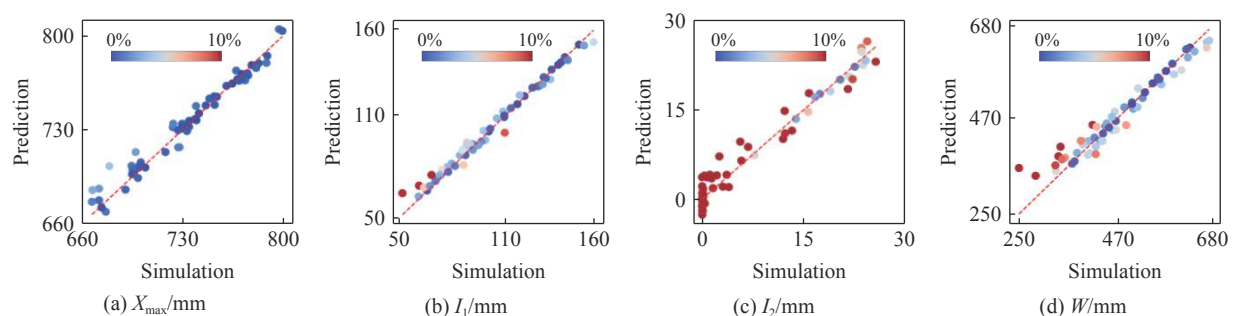


图 9 支持向量机模型预测结果与仿真结果比较图

Fig. 9 Comparison between SVM model prediction results and simulation results

为更全面地展示机器学习模型的预测效果,引入不同模型预测结果的决定系数 R^2 、平均绝对误差(MAE)、均方根误差(RMSE)、均方误差(MSE)、平均绝对误差(MAPE)等 5 个参数作为评价指标,各模型指标值如表 2 所示。3 种机器学习方法的平均决定系数均在 0.94 以上。其中卷芯侵入量 I_2 预测的平均相对误差大,但其平均绝对误差低于 2.6 mm,在可接受范围内。其余 3 项待预测参数的效果良好,其中电池包侧壁侵入量 I_1 的预测效果最优,最高 R^2 能达到 0.98 以上。3 种机器学习算法中,支持向量机方

法的综合效果最优, R^2 均在 0.93 以上, R^2 平均值能达到 0.96 以上, 说明该算法能很好反应电池包的侧面柱撞的碰撞变形情况, 预测碰撞安全性。BP 神经网络对于卷芯侵入量 I_2 的预测效果较差, 但对其他参数预测效果较好。

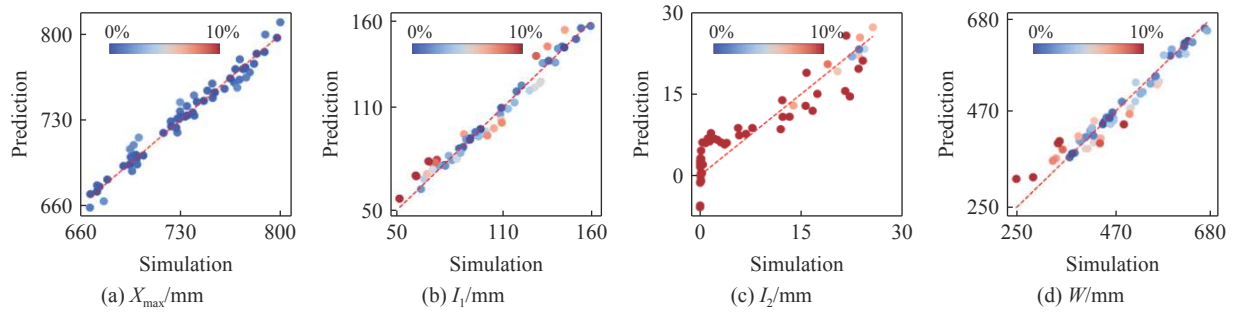


图 10 BP 神经网络模型预测结果与仿真结果比较图

Fig. 10 Comparison between BPNN model prediction results and simulation results

表 2 机器学习模型预测效果

Table 2 Accuracy analysis of ML models

机器学习模型	预测参数	R^2	MSE	RMSE	MAE	MAPE
随机森林	X_{\max}	0.9312	92.47	9.616	7.352	1.009
	I_1	0.9569	33.02	5.747	4.594	5.043
	W	0.9440	589.6	24.28	17.63	4.312
	I_2	0.9540	3.954	1.989	1.338	130.5
支持向量机	X_{\max}	0.9640	48.38	6.955	5.195	0.723 5
	I_1	0.9839	12.33	3.512	2.556	2.946
	W	0.9373	659.8	25.69	18.73	4.656
	I_2	0.9636	3.127	1.768	1.416	306.4
BP神经网络	X_{\max}	0.9678	43.27	6.578	5.233	0.715 1
	I_1	0.9694	23.46	4.843	3.826	4.110
	W	0.9483	544.4	23.33	18.55	4.424
	I_2	0.8849	9.898	3.146	2.573	591.2

为进一步反映模型的回归预测能力, 对 3 种模型开展了鲁棒性分析。通常对训练数据集中加入均值为 0, 有一定标准差 σ 的随机值作为高斯噪声^[21]来模拟实际过程中出现的误差和异常值。加入了标准差 σ 为 0.5 噪声后各类机器学习模型预测效果如表 3 所示, 可以发现预测效果仍然良好, 表明 3 种算法具有较高的鲁棒性。在添加标准差 σ 为 0.5 的高斯噪声后, BPNN 模型的预测效果最好, 预测参数的 R^2 平均值仍能达到 0.91, 鲁棒性明显优于其他算法。图 11 显示了增加不同标准差的高斯噪声后, 3 种机器学习模型的预测效果。

表 3 为所有训练集数据添加噪声($\sigma=0.5$)后各类机器学习模型预测效果

Table 3 Accuracy analysis of ML models after adding Gaussian noise ($\sigma=0.5$) to all training data

机器学习模型	预测参数	R^2	MSE/mm	RMSE/mm	MAE/mm	MAPE/mm
随机森林	X_{\max}	0.9171	111.3973	10.5545	8.7621	1.208 1
	I_1	0.8941	81.1519	9.0084	7.5526	8.5254
	W	0.8498	1580.4298	39.7546	32.2293	7.5761
	I_2	0.9358	5.5154	2.3485	1.6952	179.265 2

表 3 (续)
Table 3 (Continued)

机器学习模型	预测参数	R^2	MSE/mm	RMSE/mm	MAE/mm	MAPE/mm
支持向量机	X_{\max}	0.9097	121.4039	11.0183	8.3659	1.1563
	I_1	0.9286	54.7504	7.3993	5.7387	6.2406
	W	0.8989	1063.2993	32.6083	24.4519	5.935
	I_2	0.8638	11.7067	3.4215	2.8056	732.7073
BP神经网络	X_{\max}	0.9308	92.951	9.6411	7.9584	1.0837
	I_1	0.9415	44.8129	6.6942	5.524	6.1102
	W	0.9084	964.28	31.0529	24.8844	5.8305
	I_2	0.8673	11.4063	3.3773	2.8312	575.6947




图 11 增加高斯噪声后机器学习模型预测效果

Fig. 11 Machine learning model prediction after adding Gaussian noise

4 结 论

基于有限元仿真和机器学习算法,构建了一个能够表征电池卷芯力学响应、分区域细化的电池包碰撞模型。通过优化拉丁超立方采样策略设计仿真矩阵,生成了训练数据集,并采用相关性分析确定输入特征,利用 3 种机器学习算法进行模型训练和预测。尽管本文中提出的机器学习模型在电池包侧面柱碰撞中的预测效果良好,但所涉及的车型和电池包结构形式较单一。未来工作将扩展到更多车型和不同类型电池包的研究,以验证模型的普适性。得到的主要结论如下:

(1) 通过对比 3 种机器学习模型的预测效果,支持向量机(SVM)模型表现最佳,4 个预测参数的平均

决定系数(R^2)达到了 0.96, 显示了其出色的预测能力。电池包侧壁最大侵入深度的预测效果最佳, 平均 R^2 为 0.97; 卷芯最大侵入深度的预测效果相对较差, 平均 R^2 为 0.93。其他 2 种模型, 即随机森林(RF)和 BP 神经网络(BPNN)也表现良好, 平均 R^2 均在 0.94 以上。

(2) 在鲁棒性分析方面, 通过为训练数据引入不同标准差的高斯噪声, 验证了 3 种模型的鲁棒性。当标准差为 0.5 时, BPNN 模型表现出最强的鲁棒性, 4 个预测参数的平均 R^2 仍然保持在 0.91, 而 SVM 和 RF 模型的表现有所下降。该结果表明 BPNN 鲁棒性好, 适合处理噪声较大的实际工况。

(3) 在应用方面, SVM 预测精度最佳(R^2 达到 0.96), 其适用于对精度要求较高且数据规模较小的场景。然而, SVM 的计算资源需求较大, 不适合大规模数据集。BPNN 的鲁棒性较强, 特别适合处理噪声较大的数据集和复杂的多变量问题。在大规模仿真数据集的应用中, BPNN 可以提供更稳定的预测结果。RF 模型计算效率高, 且具备良好的解释性, 适合快速生成初步的预测模型。

参考文献:

- [1] CHEN P W, XIA Y, ZHOU Q. Inclined battery cells for mitigating damage in undercarriage collision [J]. *International Journal of Crashworthiness*, 2024, 29(3): 508–520. DOI: 10.1080/13588265.2023.2258645.
- [2] LI W, XIA Y, CHEN G H, et al. Comparative study of mechanical-electrical-thermal responses of pouch, cylindrical, and prismatic lithium-ion cells under mechanical abuse [J]. *Science China Technological Sciences*, 2018, 61(10): 1472–1482. DOI: 10.1007/s11431-017-9296-0.
- [3] LAI W J, ALI M Y, PAN J. Mechanical behavior of representative volume elements of lithium-ion battery modules under various loading conditions [J]. *Journal of Power Sources*, 2014, 248: 789–808. DOI: 10.1016/j.jpowsour.2013.09.128.
- [4] SAHRAEI E, BOSCO E, DIXON B, et al. Microscale failure mechanisms leading to internal short circuit in Li-ion batteries under complex loading scenarios [J]. *Journal of Power Sources*, 2016, 319: 56–65. DOI: 10.1016/j.jpowsour.2016.04.005.
- [5] SAHRAEI E, CAMPBELL J, WIERZBICKI T. Modeling and short circuit detection of 18650 Li-ion cells under mechanical abuse conditions [J]. *Journal of Power Sources*, 2012, 220: 360–372. DOI: 10.1016/j.jpowsour.2012.07.057.
- [6] XIAO F Y, XING B B, XIA Y. Mechanical response of laterally-constrained prismatic battery cells under local loading: SAE Technical Paper 2020-01-0200 [R]. SAE, 2020. DOI: 10.4271/2020-01-0200.
- [7] XIA Y, WIERZBICKI T, SAHRAEI E, et al. Damage of cells and battery packs due to ground impact [J]. *Journal of Power Sources*, 2014, 267: 78–97. DOI: 10.1016/j.jpowsour.2014.05.078.
- [8] KUKREJA J, NGUYEN T, SIEGMUND T, et al. Crash analysis of a conceptual electric vehicle with a damage tolerant battery pack [J]. *Extreme Mechanics Letters*, 2016, 9: 371–378. DOI: 10.1016/j.eml.2016.05.004.
- [9] ZHANG J Y, NING L N, HAO Y M, et al. Topology optimization for crashworthiness and structural design of a battery electric vehicle [J]. *International Journal of Crashworthiness*, 2021, 26(6): 651–660. DOI: 10.1080/13588265.2020.1766644.
- [10] CHEN P W, XIA Y, ZHOU Q, et al. Staggered layout of battery cells for mitigating damage in side pole collisions of electric vehicles [J]. *eTransportation*, 2023, 16: 100238. DOI: 10.1016/j.etrans.2023.100238.
- [11] LI W, ZHU J E, XIA Y, et al. Data-driven safety envelope of lithium-ion batteries for electric vehicles [J]. *Joule*, 2019, 3(11): 2703–2715. DOI: 10.1016/j.joule.2019.07.026.
- [12] ZHANG Z, ZHOU H P, MA J Y, et al. Space deployable bistable composite structures with C-cross section based on machine learning and multi-objective optimization [J]. *Composite Structures*, 2022, 297: 115983. DOI: 10.1016/j.compstruct.2022.115983.
- [13] PAN Y J, ZHANG X X, LIU Y, et al. Dynamic behavior prediction of modules in crushing via FEA-DNN technique for durable battery-pack system design [J]. *Applied Energy*, 2022, 322: 119527. DOI: 10.1016/j.apenergy.2022.119527.
- [14] XU D X, PAN Y J, ZHANG X X, et al. Data-driven modelling and evaluation of a battery-pack system's mechanical safety against bottom cone impact [J]. *Energy*, 2024, 290: 130145. DOI: 10.1016/J.ENERGY.2023.130145.
- [15] 中国汽车技术研究中心有限公司. C-NCAP 管理规则 (2024 版) [R/OL]. 天津, 2024. <https://www.c-ncap.org.cn/article-detail/1747900203303780353?type=2>.
China Automotive Technology and Research Center Co., Ltd. C-NCAP management rules (2024 Edition) [R/OL]. Tianjin, 2024. <https://www.c-ncap.org.cn/article-detail/1747900203303780353?type=2>.

- [16] 国家市场监督管理总局, 国家标准化管理委员会. GB/T 37337-2019 汽车侧面柱碰撞的乘员保护 [S]. 北京: 中国标准出版社, 2019.
State Administration of Market Supervision and Administration of the People's Republic of China, Standardization Administration of the People's Republic of China. GB/T 37337-2019 Protection of the occupants in the event of a lateral pole collision [S]. Beijing: Standards Press of China, 2019.
- [17] 马骋浩, 申宗炫, 汪俊, 等. 侧面柱碰撞工况电池包碰撞安全性快速预测 [J]. 汽车工程, 2024.
MA C H, SHEN Z X, WANG J, et al. Fast prediction of battery pack safety under side pole collision [J]. *Automotive Engineering*, 2024.
- [18] QU Y L, GE Y L, XING B B, et al. Development of detailed model and simplified model of lithium-ion battery module under mechanical abuse: SAE Technical Paper 2022-01-7120 [R]. SAE, 2022. DOI: [10.4271/2022-01-7120](https://doi.org/10.4271/2022-01-7120).
- [19] 陈涛, 李宁宁, 李卓, 等. 侧面柱碰撞条件下电动汽车电池系统结构优化 [J]. *中国机械工程*, 2020, 31(9): 1021–1030. DOI: [10.3969/j.issn.1004-132X.2020.09.002](https://doi.org/10.3969/j.issn.1004-132X.2020.09.002).
CHEN T, LI N N, LI Z, et al. Structural optimization of electric vehicle battery systems under pole side impacts [J]. *China Mechanical Engineering*, 2020, 31(9): 1021–1030. DOI: [10.3969/j.issn.1004-132X.2020.09.002](https://doi.org/10.3969/j.issn.1004-132X.2020.09.002).
- [20] YI J, LI X Y, XIAO M, et al. Construction of nested maximin designs based on successive local enumeration and modified novel global harmony search algorithm [J]. *Engineering Optimization*, 2017, 49(1): 161–180. DOI: [10.1080/0305215X.2016.1170825](https://doi.org/10.1080/0305215X.2016.1170825).
- [21] RAUTELA M, GOPALAKRISHNAN S. Ultrasonic guided wave based structural damage detection and localization using model assisted convolutional and recurrent neural networks [J]. *Expert Systems with Applications*, 2021, 167: 114189. DOI: [10.1016/j.eswa.2020.114189](https://doi.org/10.1016/j.eswa.2020.114189).

(责任编辑 张凌云)