

基于熵值的动力电池风险单体故障识别预警技术研究

雷建新^{1,2}, 周航^{1,2}, 钟鑫豪^{1,2}, 肖业^{1,2}, 汪帆^{1,2}

(1. 中车时代电动汽车股份有限公司, 湖南 株洲 412007; 2. 中车科技创新有限公司, 北京 100080)

摘要:针对动力电池组中单体故障难以及时识别的问题,本文提出一种基于信息熵和Z分数的故障识别预警方法。该方法通过滑动窗口计算单体电压时间序列的信息熵,以量化其波动紊乱程度;引入Z分数衡量各单体熵值相对于群体均值的偏离程度,从而实现异常程度的标准化度量。在此基础上,结合三级预警机制,对异常单体进行分级预警。实际车辆运行数据的试验验证表明,该方法在充电过程中能有效识别电压异常单体,具有较好的预警能力和可解释性。

关键词:动力电池; 信息熵; Z分数; 异常检测; 故障预警

中图分类号:U469.72; TM912 **文献标志码:**A **DOI:**10.15917/j.cnki.1006-3331.2026.03.002

Research on Entropy Based Risk Identification and Early Warning Technology for Power Battery Single Unit Faults

LEI Jianxin^{1,2}, ZHOU Hang^{1,2}, ZHONG Xinhao^{1,2}, XIAO Ye^{1,2}, WANG Fan^{1,2}

(1. CRRC Electric Vehicle Co., Ltd., Zhuzhou 412007, China;

2. CRRC Technology Innovation Co., Ltd., Beijing 100080, China)

Abstract: To address the problem that single-cell faults in a battery pack are difficult to identify promptly, this paper proposes a fault identification and early warning method based on information entropy and Z-score. This method calculates the information entropy of the single-cell voltage time series using a sliding window to quantify the degree of fluctuation disorder. It introduces the Z-score to measure the deviation of each cell's entropy value from the group mean, thereby achieving a standardized measurement of the abnormality degree. On this basis, combining with a three-level warning mechanism, abnormal cells receive graded warnings. The experimental verification using actual vehicle operation data shows that this method can effectively identify voltage-abnormal cells during charging, demonstrating good warning capability and interpretability.

Key words: power battery; information entropy; Z score; anomaly detection; fault warning

随着电动汽车的快速普及,其动力电池的安全性问题日益凸显。由动力电池故障所引发的安全事故(如车辆自燃、起火、爆炸等^[1-3]),不仅给用户带来巨大损失,也对新能源汽车产业的健康发展构成严重威胁。从结构上看,动力电池组通常由数十至数百个单体电池串并联而成^[4],其中任何一个单体发生故障(如过压、欠压、内短路等)都有可能引发发热失控,进而导致严重事故。因此,发展高效的动力电池故障预警技术,不仅是当前形势下的迫切需要,也是解决电池单体众多、工况复杂多变等工程难题的关键。

目前,电池故障的诊断方法主要分为基于模型和

数据驱动两大类^[5-6]。其中,基于模型的方法通过建立电池的等效电路模型或电化学模型,并结合状态估计算法(如卡尔曼滤波)进行异常检测。例如,吴静云^[7]等以阶梯充电电流为激励,通过建立内短路故障等效电路模型来实现电池内短路故障诊断;刘坚^[8]则提出一种基于多传感器融合的故障诊断方法,并结合电化学模型与实时数据分析来提升故障定位精度。这类方法计算简单、容易实施,但其模型精度易受参数变化和老化的影响。而数据驱动的方法则是利用机器学习(如支持向量机、神经网络)或统计分析来挖掘电池数据中的异常模式。例如,俞蒋彬^[9]等利用

收稿日期:2025-09-25。

第一作者:雷建新(1998—),男,硕士,助理工程师,主要从事车辆动力电池寿命预测及大数据安全预警相关工作。E-mail: 2692247283@qq.com。

机器学习方法建立电池故障等级预测随机森林算法, 并通过数字汽车大赛提供的数据集进行了方案验证; 范天娥^[10]等提出的基于统计分析和密度聚类的电池组短路故障诊断方法, 能有效检测和定位短路电池, 并且故障越严重, 诊断所需时间越短。这类方法不依赖于精确模型, 但通常需要大量标记数据, 且计算复杂度相对较高。

在实际应用中, 电池管理系统产生的电压、电流、温度等数据具有高维性(多达数百个单体)和强耦合性(单体之间相互影响)的特点; 另外, 传感器误差和工况波动导致的噪声也会对数据形成干扰。这些因素使得在故障早期从复杂数据中识别微弱的异常信号变得极为困难。

针对上述问题, 本文提出一种基于熵值及 Z 分数的无监督故障识别预警方法。该方法首先利用信息熵捕捉单体电压序列的紊乱程度(早期故障常表现为电压波动异常), 然后通过 Z 分数消除单体间基线差异, 进行异常程度的标准化度量, 最后采用三级预警策略以平衡误报率与漏报率。该方法直接利用采集的外部电压数据, 无需改动硬件; 同时又不依赖难以获取的正常或故障标注数据进行复杂训练, 计算负荷相对较低。与“黑箱”的深度学习模型相比, 该方法的计算及决策过程清晰透明, 可解释性相对较强。

1 相关理论

1.1 信息熵理论

信息熵由 Shannon 提出, 用于量化系统的不确定性^[11-13]。对于一个离散型随机变量 X , 其取值可能为 $x_1, x_2, \dots, x_n$, 对应的概率分别为 $P(x_1), P(x_2), \dots, P(x_n)$, 则其信息熵 $H(X)$ 定义为式(1)。

$$H(X) = - \sum_{i=1}^n P(x_i) \log_b P(x_i) \quad (1)$$

式中: $P(x_i)$ 为事件 x_i 发生的概率; b 为对数的底数, 通常取 2, 此时信息熵的单位为比特 (bit); 若取自然常数 e , 则单位为纳特 (nat); 取整数 10 时, 单位为哈特利 (hartley)。

在动力电池的充放电过程中, 其电压、电流、温度等参数会随着内部的化学反应和外部的工作条件变化而波动, 具有一定的不确定性和随机性。因此, 三者均可作为信息熵计算时的随机变量 X 。以电压数据为例, 可将其视为离散型随机变量。由于电池组中单体电池之间存在性能差异, 各单体电池的电压值具

有不一致性^[14-15], 不同电压值出现的频率即构成其概率分布。通过计算每个单体电池电压数据的信息熵, 并对这些熵值进行比较和分析, 可有效地量化评估单体电池电压数据之间的一致性程度。如果各个单体电池的信息熵值较为接近, 说明这些单体电池的电压波动特性相似, 一致性较好; 反之, 如果某些单体电池的信息熵值与其他单体电池相差较大, 则表明这些单体电池的电压波动异常, 可能存在性能问题, 需要进一步关注和检测。

1.2 Z 分数原理

Z 分数又称为标准分数, 是一种在统计学领域广泛应用的标准化指标, 主要用于衡量某个数据点相对于数据集总体均值的偏离程度, 即反映该数据点在分布中的位置^[5]。Z 分数的计算公式见式(2)。

$$Z = (x - \mu) / \sigma \quad (2)$$

式中: Z 为 Z 分数; x 为待评估数据值; μ 为数据集均值; σ 为数据集标准差。

通过 Z 分数将熵值标准化, 可将不同量级和分布的数据统一转化到一个标准的尺度上进行比较分析, 从而消除量纲影响, 使每个数据点在整个数据集中的相对位置和离散情况更加直观, 为后续的数据分析和决策提供有力支持。本文将各单体的熵值标准化, 从而实现跨单体的异常程度比较。

在正常情况下, 电池单体的各项参数(如电压、电流、温度等)受电池工作特性和外部环境的微小变化影响, 表现为在其均值附近波动。此时相应参数计算得到的 Z 分数也会在一个相对稳定的区间内分布。然而, 当电池内部出现电极材料劣化、电解液泄漏、内部短路等故障时, 会导致电池参数发生异常变化, 偏离其正常的波动范围。这些异常变化会反映在 Z 分数上, 表现为其值超出正常区间, 即达到或超过预先设定的阈值。

1.3 动力电池故障机理

动力电池常见故障包括内短路、过压、欠压、连接异常等。其中, 内短路通常由电池内部隔膜破损引起, 导致正负极发生短路, 表现为电压骤降和温度升高; 过压与欠压一般由过充、过放或单体不一致引起, 容易触发电池管理系统的自保护功能; 连接异常则可能是螺栓松动, 造成接触电阻增大, 进而引发动力电池组局部过热。以上诸多故障在发生前往往经历渐变过程, 表现为单体电压曲线出现波动加剧或响应迟滞。传统的电压阈值法设定的上下限较为固定, 难以

检测此类微弱变化,因此本文通过分析其熵值变化来对风险单体进行识别并对故障单体作出预警。不同故障类型下的电压表现及熵值变化趋势见表 1。

表 1 不同故障类型下的电压表现及熵值变化趋势

故障类型	电压表现	熵值变化趋势
内短路	骤降+波动加剧	熵值升高
过压	持续偏高	熵值降低
欠压	持续偏低	熵值降低
连接故障	异常稳定	熵值显著降低

2 基于熵值的动力电池单体故障识别预警

基于熵值的动力电池单体故障识别预警流程如图 1 所示,主要包括数据集预处理、滑动窗口划分、熵值计算、Z 分数标准化及三级预警步骤。




图 1 基于熵值的动力电池单体故障识别预警流程

2.1 数据集预处理

2016 年,我国发布了 GB/T 32960—2016《电动汽车远程服务与管理系统技术规范》(2025 年更新为 GB/T 32960—2025)^[16]。该标准要求电动汽车远程监控平台实时上报多项新能源汽车运行数据,包括整车数据、驱动电机数据、极值数据等。本研究所用数据均来自某公司的电动汽车大数据平台。该平台中的可充电储能装置电压数据项包含单体电池总数、单体电池电压列表等字段。本文具体采用电池系统所有单体电池的电压时序值,数据采样间隔为 10 s。

在实际数据采集,受外界因素及车辆行驶条件影响,所获数据常常存在缺失,质量不佳。若直接使用此类数据,会对后续分析造成严重干扰,导致结果出现偏差。因此,在进行数据分析之前,必须对数据进行预处理^[17]。针对原始数据可能出现的异常情况,本文采取了以下预处理规则:①针对短暂缺失数据(<5 帧),采用线性插值填补;②若数据连续丢包(≥5 帧),则剔除该段问题数据并标记为无效;③对连续重复数据直接删除。具体处理流程如图 2 所示。




图 2 数据集预处理流程

2.2 滑动窗口划分

在计算电池单体电压的信息熵值时,合理确定时间窗口的长度和数据区间至关重要,这直接影响到熵值计算的准确性及对电池状态变化的敏感度。时间窗口长度的选择需综合考虑电池的动态特性、数据变化的频率及计算效率等因素。如果时间窗口过短,虽然能够捕捉到电池参数的快速变化,但可能会导致数据量不足,熵值计算结果不稳定,无法准确反映电池的整体状态;反之,如果时间窗口过长,虽然可以包含更多的数据信息,使熵值计算结果更加稳定,但可能会掩盖电池在短时间内的状态变化,降低对早期故障的预警能力。

考虑到时间窗口长度需与电池故障演化时间尺度相匹配,同时窗口内也需要有足够多的数据样本以确保统计稳定性,最终确定时间窗口长度为 5 min(30 帧),滑动步长为 10 s(1 帧)^[11]。该窗口长度既能覆盖典型工况,充分捕捉电池单体电压在正常运行和异常状态下的变化特征,又能保证计算效率。同时,滑动步长足够小(与采样间隔一致),可满足预警的时效性需求。

确定时间窗口长度后,需将窗口内连续的电压数据离散化,以计算其概率分布和信息熵值。这要求对每个时间窗口的数据进行合理的区间划分。划分时需综合考虑电压数据的分布与变化范围,确保每个区间内的数据具有足够的代表性和统计意义。本文采用等间距划分的方法,根据电池单体电压的正常取值范围和实际数据的波动情况,将电压数据划分为若干个等宽的区间。该型号电池的单体电压正常范围为 3.60~4.20 V,经对所采数据分析发现,电压数据在 3.80~4.00 V 之间波动相对较小,而靠近上下限则波

动较大。因此,将电压数据以 0.04 V 为间隔划分为 15 个区间,即 $[3.60, 3.64)$, $[3.64, 3.68)$, $\dots$, $[4.16, 4.20]$ 。该划分方式具有较高的分辨率,能更好地反映电压数据的分布特征,为准确计算信息熵值提供基础。

2.3 熵值计算

在确定了时间窗口长度和数据区间后,就可以计算每个时间窗口内电池单体电压的信息熵值。在某一特定的时间窗口内,根据电压范围将电池单体电压数据等间隔离散划分为 n 个区间,每个区间的电压值为 $x_i (i=1, 2, \dots, n)$,通过统计落入每个区间的数据点数量(即频数)来计算出每个区间电压值出现的概率 $P(x_i)$ 。根据信息熵的计算公式,将每个区间的概率值代入,即可计算出该时间窗口内电池单体电压的信息熵值 $H(X)$ 。

在实际计算过程中,为避免出现 $\log_2 P(x_i)$ 无意义的情况,在不影响计算结果准确性的条件下,当概率值 $P(x_i)=0$ 时,将其替换为一个极小的正数 ε 代入,保证公式的正常计算^[18]。通过对每个时间窗口内的电池单体电压数据进行信息熵计算,得到一系列反映电池状态的熵值序列,该熵值序列将作为后续电池状态分析和故障预警的重要依据。

2.4 异常系数计算

在完成各电池单体电压的信息熵值计算后,利用 Z 分数对信息熵值进行标准化处理,以增强不同电池单体间的可比性。具体而言,在同一窗口下,计算所有单体熵值的均值 μ_E 和标准差 σ_E ,则单体 i 的 Z 分数 Z_i 可按式(3)计算。

$$Z_i = (x_i - \mu_E) / \sigma_E \quad (3)$$

Z_i 表示第 i 个电池单体的信息熵值与均值的偏离程度,以标准差为单位进行量化。 Z_i 的符号表示偏离方向($Z_i > 0$ 表示波动大于平均水平, $Z_i < 0$ 表示小于平均水平), Z_i 的绝对值大小表示偏离程度。据此,可以建立如下状态判断准则:当 $|Z_i|$ 接近于 0 时,表明该单体状态与群体一致,属于正常波动;当 $|Z_i|$ 超过预设阈值时,则表明该单体熵值显著偏离群体,可能存在异常,需要重点关注。通过 Z 分数,可以清晰量化每个单体在电池组中的相对异常程度。

在实际应用中,为提升识别效率,定义异常系数 $A_i = |Z_i|$ 。该系数与 Z 分数直接相关,能更直观地量化电池单体偏离正常状态的异常程度。具体判定依据为:若 A_i 低于预设阈值,则认为该电池单体运行正常,其内部的化学反应和物理过程较为稳定,电池性

能可靠;若 A_i 等于或高于该阈值,则表明电池单体可能已存在故障或风险(如内部短路),其信息熵值的异常变化导致了 A_i 的显著增大。

2.5 三级预警策略

风险单体判断阈值的确定是电池故障预警中的关键环节,直接影响到预警系统的准确性和可靠性。统计学上通常认为在正态分布的数据集中,约 99.7% 的数据会落在均值附近 3 个标准差的范围内。基于这一原理,初步将风险单体判断阈值设定为 3,即当电池单体的异常系数 $A > 3$ 时,认为该单体可能存在异常,需要进一步关注。

然而,初步设定的阈值还需要通过实际验证来进行优化和调整。试验发现,以阈值 3 作为判据存在误判情况,即部分正常单体的异常系数 A 偶尔也会超过 3。因此,为降低误报率与漏报率,提高预警准确性,本文对不同阈值下的预警效果进行了详细评估分析。

分析发现,当阈值设定较低时(如设为 2),系统虽然能检测出更多潜在的异常单体,降低漏报率,但会导致误报率大幅上升。这是因为在正常运行中,部分数据点会因偶然因素或测量误差使其异常系数超过 2,从而被误判为风险单体。这会导致不必要的检修工作,增加维护成本并降低用户对预警系统的信任度。相反,当阈值设定较高时(如设为 4),误报率会明显降低,因为只有异常系数超过 4 的电池单体才会被判定为风险单体,减少了误判。但此时漏报率会显著增加,一些存在潜在故障但异常系数未达到 4 的电池单体可能无法被及时检测出来,从而增加电池发生故障的风险,威胁车辆安全运行。

通过反复调整阈值,权衡误报率、漏报率和预警准确性,以优化整体预警性能。最终,将判断阈值确定为 3.5。该阈值可使预警系统在保证一定预警准确性的前提下,同时保证较低的误报率与漏报率。基于上述统计分析与实际验证,最终设定的三级预警策略见表 2。

表 2 三级预警策略

预警等级	条件	处置措施
一级(安全)	$A \leq 3.5$	系统正常 持续监控
二级(预警)	$3.5 < A < 4.0$	异常风险 延长监控
三级(报警)	$A \geq 4.0$	故障发生 立即停机

3 试验验证

3.1 数据集描述

为验证基于熵值及 Z 分数的无监督故障识别预警方法的有效性,选取某公司 2 辆纯电动城市客车(车辆 1 和车辆 2)的实际运行数据进行详细分析。数据涵盖了 2 辆车全天的运营情况:车辆 1 为 2025 年 7 月 29 日数据(总行驶里程 123 977.60 km),车辆 2 为 2025 年 7 月 18 日数据(总行驶里程 262 592.30 km),采样间隔均为 10 s。此外,2 辆车的动力电池包配置相同,均由 144 个电池单体组成,且所选数据集包含了完整的充电过程电压信息。

经过 2.1 节的数据源缺失值处理后,获得了有效的运行数据。基于此,绘制了车辆 1 与车辆 2 的 SOC、电流、里程随时间变化的曲线,如图 3 和图 4 所示。由图可知,车辆启动后, SOC 开始降低,电流呈现剧烈波动,说明车辆在运行中加速减速状态比较频繁;同时里程数稳步增加。




图3 车辆1的 SOC、电流、里程随时间变化曲线




图4 车辆2的 SOC、电流、里程随时间变化曲线

3.2 试验结果

3.2.1 故障检测效果

动力电池的充放电遵循不同能量流向:充电时能量由外部输入,放电时能量由内部输出。充电过程为可控的标准化流程,环境更稳定,能更精准地放大单

体异常信号;而放电阶段受负载波动影响大(如车辆急加速、减速),异常特征易被干扰,表征能力相对较弱。因此,按照前文所述方法,提取 2 辆车完整充电过程的电压信息进行窗口划分,并计算每个时间窗口内电池单体电压数据的信息熵值。通过对数据区间的划分和概率计算,得到各个电池单体的电压信息熵值序列,如图 5 和图 6 所示。




图5 车辆1各单体电压信息熵值序列




图6 车辆2各单体电压信息熵值序列

分别计算 2 辆车 144 个电池单体信息熵值的均值 μ_E 和标准差 σ_E , 根据 Z 分数计算公式,求得每个单体的 Z 分数,并进一步计算其异常系数 A_i 。两车各电池单体的异常系数序列如图 7 和图 8 所示。




图7 车辆1各单体异常系数序列




图8 车辆2各单体异常系数序列

根据预设的风险单体三级预警策略,可作出如下判断:在车辆1中,所有电池单体的异常系数均小于3.5,因此该时间窗口内的144个电池单体均处于正常状态;在车辆2中,第110号单体的异常系数大于4.0,且该状态持续时间较长,根据预警策略,可初步判断该单体可能存在异常,需进一步检测与分析。

3.2.2 结果验证

提取2辆车完整充电过程的电压信息进行分析,结果如图9和图10所示。由图可知,车辆1的所有单体电压在整个过程中保持同步,并呈现统一的单调变化趋势;车辆2的第110号单体在整个充电过程中,其电压值均存在明显的偏离现象,且分化趋势随时间加剧。该现象与前述基于异常系数的判断结果一致,从而验证了本文方法的有效性。




图9 车辆1各单体充电电压趋势




图10 车辆2各单体充电电压趋势

4 结束语

本文针对动力电池组中单体电池故障难以及时识别与预警的问题展开研究,通过计算车辆充电过程中电池单体电压序列的信息熵值,并结合Z分数标准化处理,实现了不同电池单体状态的有效对比和判断,从而能够有效识别早期异常单体,最后根据设定的三级预警机制对异常单体做出预警。

尽管本文对动力电池风险单体故障预警具有一定的参考意义,但仍存在一些不足,需在未来工作中加以改进。以预警误报问题为例,主要的优化方向包括以下两点:①采用数据分段处理策略,即根据充电阶段对电压数据进行分段,并独立计算各段的熵值;②引入多源参数进行融合验证,通过融合多种参数构建综合评估体系,以抑制单一电压熵可能带来的误警,提高预警性能。

参考文献:

- [1] 郭葳,黄文君,张飞. 基于数据驱动下纯电动汽车动力电池故障诊断方法研究[J]. 农机使用与维修,2023(9):111-114.
- [2] 李伟. 电动客车动力电池热失控预警技术研究[J]. 客车技术与研究,2025,47(5):1-6.
- [3] 李丹,刘继红,周恩飞,等. 基于BP神经网络的动力电池热失控预警方法研究[J]. 客车技术与研究,2024,46(5):7-10.
- [4] 单丰武,汪超仁,曾建邦,等. 基于OPTICS聚类 and 电压异常指数的动力电池单体不一致性故障程度分析方法[J]. 中国科学:技术科学,2024,54(8):1611-1624.
- [5] 孙振宇. 基于数据驱动的纯电动汽车动力电池故障诊断方法研究[D]. 北京:北京理工大学,2018:7.
- [6] 张扬. 基于数据驱动的电动汽车动力电池故障诊断方法研究[D]. 太原:中北大学,2024:5-9.
- [7] 吴静云,鄢博,戚文,等. 基于充电脉冲激励的电池内短路故障诊断方法[J]. 电源技术,2023,47(3):332-336.
- [8] 刘坚. 新能源汽车动力电池组单体故障检测与更换技术研究[J]. 汽车维修技师,2025(16):22-24.
- [9] 俞蒋彬,张欣,张永涛,等. 基于大数据的纯电动客车动力电池安全风险多维度评价[J]. 北京交通大学学报,2023,47(5):98-106.
- [10] 范天娥,唐鑫,雷浩然,等. 统计分析和密度聚类的锂离子电池组内短路故障诊断[J]. 电子测量与仪器学报,2023,37(7):93-103.
- [11] 胡杰,程雅钰,余海,等. 基于WOA-VMD和香农熵的锂电池早期故障诊断研究[J]. 汽车工程,2024,46(7):1189-1196.
- [12] 刘启全,马建,赵轩,等. 基于优化熵算法的真实场景下电动汽车动力电池系统故障诊断[J]. 中国公路学报,2024,37(10):233-248.
- [13] 刘佳庚,赵美红. 基于信息熵和模糊综合评判的动力电池性能评估[J]. 中国新技术新产品,2017(6):6-7.
- [14] 陈英亮. 电池单体不一致性诊断算法比较研究[D]. 长春:吉林大学,2022:9.

表5 乘员伤害值汇总

项目	法规值	试验结果
HIC	≤ 500	212.2
Mocy/(N·m)	≤ 57	16.69
胸部加速度/($\text{m}\cdot\text{s}^{-2}$)	≤ 294	219.0
大腿力(假人大腿受力最大值)/kN	≤ 10	1.337
WIC	—	0.522

注:表中数据为第一排左侧靠通道处假人的伤害试验结果。

5 结论

本文将客车正面碰撞加速度波形转换为等效双线性波形,分析了各特征参数对假人伤害的影响程度,在此基础上构建了RBF近似模型并采用自适应遗传算法进行优化,最终得到了满足法规要求的合理波形范围,并结合客车前部结构特点实现了正向设计。主要结论如下:

1) 将试验波形根据能量守恒定理转换成等效双线性波形。转换后的波形可直观反映前端结构的刚度变化、车体回弹时刻及总变形量,用于指导客车前端结构的骨架设计。

2) 以乘员伤害权重指数WIC为总目标,在给定一定碰撞初速度及总变形量的条件下,通过试验设计,确定了等效双线性波形各特征点对假人各部位伤害的影响程度,并给出了合理的参数取值范围。

3) 结合客车前部结构特点,构建RBF径向基函数模型并采用自适应遗传算法优化,得到满足法规要求的合理波形范围,使假人各项伤害值达标。

4) 以优化碰撞等效波形为总目标,分解得到车体结构性能子目标,通过实现子目标达成总目标,实现了客车前部耐撞结构的正向快速设计。

参考文献:

- [1] 邱少波. 汽车碰撞安全工程[M]. 北京:北京理工大学出版社,2016:3-4.
- [2] Peddi S N. Selection of optimal design parameters to achieve improve occupant performance in frontal impacts;2013-01-0756[R]. Warrendale, PA, SAE International,2013:1-8.
- [3] Huang M. Vehicle Crash Mechanics[M]. Florida: CRC Press, 2002:27-30.
- [4] 徐珍珍,尹辉俊,易超,等. 微型电动汽车正面碰撞约束系统匹配研究[J]. 广西科技大学学报,2024,35(1):26-32.
- [5] 林坡. 汽车偏置碰撞中驾驶员侧乘员约束系统优化研究[D]. 镇江:江苏大学,2018:26-33.
- [6] 司俊德,孟照雨,王铨薄. 大客车正面碰撞安全性能分析及结构改进验证[J]. 汽车实用技术,2023,48(16):80-85.
- [7] 吴长风,张君媛,那景新,等. 基于客车乘员损伤的尖顶等效方波参数研究[J]. 汽车工程,2019,41(7):785-791.
- [8] 孙婷婷. 基于客车正面碰撞加速度优化波形的车身前部结构设计[D]. 厦门:厦门理工学院,2018:43-55.
- [9] 张世哲. 基于正面碰撞驾驶员胸部有限元模型的汽车约束系统优化[D]. 秦皇岛:燕山大学,2021:55-60.
- [10] 袁庆磊. 正面碰撞双线性波形及约束系统参数的研究与优化[D]. 沈阳:沈阳化工大学,2023:40-51.
- [11] JT/T 1369—2020 客车正面碰撞的乘员保护[S].
- [12] Viano D C, Arepally S. Assessing the safety performace of occupant restraint system [R]. SAE Paper No. 902328, 1990:301-327.

(上接第15页)

- [15] 王杨宇航. 基于电动汽车运行数据的动力电池异常检测与故障预警[D]. 西安:长安大学,2024:13-17.
- [16] 虞婧. 基于数据挖掘技术的电动汽车充电安全监测与故障预警方法研究[D]. 北京:华北电力大学,2021:2-3.
- [17] 申江卫,岩川,刘永刚,等. 基于数据挖掘与大数据分析的

电池故障诊断与异常检测[J]. 电工技术学报,2024,39(24):7979-7994.

- [18] 闫湖,胡静,王哲. 退役动力电池剩余电量状态估计方法研究[J]. 电器与能效管理技术,2021(10):33-41.