

doi: 10.19562/j.chinasae.qcgc.2024.07.005

基于1dCNN-LSTM量化单体异常性的动力电池故障诊断方法*

陈吉清^{1,2}, 冯雨佳^{1,2}, 兰凤崇^{1,2}, 王平^{1,2}

(1. 华南理工大学机械与汽车工程学院, 广州 510640; 2. 华南理工大学, 广东省汽车工程重点实验室, 广州 510640)

[摘要] 准确的动力电池单体性能评估对保障动力电池安全具有重要意义。目前基于数据驱动的电池故障诊断算法, 大多对各单体电池进行相互比较, 根据各单体电压等特征参数之间的差异, 使用分类算法将离群单体认定为故障单体。然而当动力电池包内有多个异常表现相似的电池单体, 或所有单体性能整体恶化时, 难以区分甚至没有显著离群的个别单体, 相互比较策略的应用范围受到限制。本文提出了一种基于1dCNN-LSTM量化单体异常性的动力电池故障诊断方法, 结合车辆运动状态、驱动系统状态及动力电池电信号3类特征, 建立1dCNN-LSTM融合模型估计理想状态下的单体实时电压参考值, 根据各单体电压实测值与参考值之间的差异, 量化各单体异常性。结合实际案例表明, 对于因单体故障导致热失控的案例, 本方法可以提前7日识别故障单体相比其他单体的明显异常, 且可以在距离事故发生1年前甚至更早的放电片段中发现潜在风险; 针对无明显单体不一致的整体恶化案例, 可以实现事故发生前7日内的整体性能恶化过程跟踪。

关键词: 动力电池; 故障诊断; 单体不一致性; 融合模型; 实时电压估计

Fault Diagnosis Method for Power Battery Based on Quantification of Cell Abnormality with 1dCNN-LSTM

Chen Jiqing^{1,2}, Feng Yujia^{1,2}, Lan Fengchong^{1,2} & Wang Ping^{1,2}

1. School of Mechanical and Automotive Engineering, South China University of Technology, Guangzhou 510640;

2. South China University of Technology, Guangdong Provincial Key Laboratory of Automotive Engineering, Guangzhou 510640

[Abstract] Accurate performance evaluation of power battery cells is of great significance to ensuring the safety of power batteries. For the existing data-driven battery fault diagnosis algorithms, mostly individual cells are compared with each other and the outlier cells are identified as faulty cells by classification, based on differences in characteristic parameters such as single cell voltage. However, if there are multiple cells of similar abnormally performance in the power battery pack, or all individual batteries show an overall performance deterioration, it is difficult to distinguish individual cells or even there is no significant outliers, and the application of the mutual comparison strategy is limited. A power battery fault diagnosis method is proposed based on 1dCNN-LSTM to quantify the abnormality of a single cell in this paper. Combining the three types of characteristics of vehicle motion status, drive system status and power battery electrical signal, the 1dCNN-LSTM fusion model is established to estimate the individual cell voltage under ideal conditions as reference. The difference between the real-time voltage reference value and the measured voltage value is used to quantify the abnormality of each cell. Combined with actual cases, it is shown that for thermal runaway case due to single cell failure, the abnormal performance of the faulty cell compared to others can be identified 7 days before accident, and potential risk can be recognized in discharge processes from a year of more before the accident. For overall deterioration cases without obvious individual cells inconsistency, the

* 国家车辆事故深度调查体系(NAIS)和新能源汽车事故调查协作网项目资助。

原稿收到日期为2024年03月10日, 修改稿收到日期为2024年04月13日。

通信作者: 兰凤崇, 教授, 博士, E-mail: fclan@scut.edu.cn。

deterioration evolution within the last 7 days can be tracked.

Keywords: power battery; fault diagnosis; cell inconsistency; fused model; real-time voltage estimation

前言

车载动力电池包作为纯电动汽车及混合动力汽车的动力来源,具有较高的能量密度以满足用户的续航里程需求。而高能量密度的电化学储能系统由于其对工作温度的热敏感性、内部热量易积累且内部材料具有不稳定性等因素,在安全运行方面存在更大的风险^[1-3]。因此,针对车载动力电池包异常监控及故障诊断方法的研究,对于确保车内乘员人身安全、避免造成经济财产损失具有重要意义^[4-6]。

根据动力电池系统构成,可以将故障类型分为电池管理系统软硬件故障^[7]、电池包整体结构故障导致的接触异常或外短路等故障,以及包括内短路及不一致性导致的电池单体电芯故障^[8]。故障预警功能实现的前提是在造成严重热失控前发现潜在风险并进行修正,在传统的定期检修外,有必要进一步对所有电池单体的个体性能及各单体间的不一致性进行评估筛查。近年来,根据动力电池单体参数不一致性的故障诊断方法研究成为了研究热点^[1,9],车载电池管理系统数据分析技术^[10-11]随着云端大数据传输及存储技术的发展得到了广泛应用^[12],基于数据驱动方法的故障诊断技术具有重要的现实意义和研究前景^[13-14]。

目前用于故障诊断的电池管理系统数据项主要包括:电池单体电压、电池单体温度、电池包SOC值,以及电池充放电状态等。其中,各单体电芯的实时电压作为电池主要参数之一,被广泛应用于结合信号处理技术的数据驱动方法中,Jiang等^[15]基于小波包变换算法对电压信号进行分解重构,并根据信号特征提取结果进行相似度计算及离群对象识别,从而定位故障电池;Niu等^[16]建立自适应的电池电压信号分解方法,并自定义故障电池识别方法的阈值规则,实现不同车辆故障预警。此外,也有研究者通过增加多项特征作为数据输入,并结合聚类算法、统计模型及深度学习算法进行电池故障诊断,如Fang等^[17]结合电芯电压不一致性差值及车辆状态数据,基于DBSCAN聚类算法及LS-SVR回归模型实现单体不一致性故障的短期预测;Zhao等^[18]应用时空编

码网络的电池故障预警,针对电池数据建立双向编码器,基于早期充电数据,在多个时空维度提前捕捉电池非健康状态的异常信号;Wang等^[19]基于高斯混合模型的双层故障诊断策略,提取充电过程中的归一化特征,根据电芯概率分布情况,基于高斯混合模型提取统计特征,并根据风险累计值进行异常电芯的状态预警。

综合上述研究,对电池不一致性的评价多根据电芯单体之间的相互比较,考虑到电池本身的差异以及在不同工况下的性能表现差异,故障诊断算法的准确度因此受到限制。此外,实际应用场景下车辆工况复杂,且考虑到电池电化学性能导致的电池电信号之间的非线性关系,以及多维特征之间的耦合关系,仅考虑单体电压信号无法充分概括电池状态,需要进一步扩展相关数据项。本文提出了一种基于1dCNN-LSTM量化单体异常性的动力电池故障分析方法,建立结合一维卷积神经网络及长短时记忆网络(1dCNN-LSTM)的融合深度学习模型,提取时序数据特征,结合前序工况对当前电压值的影响,实现实时电压参考值的估计;并根据单体电压参考值,以不同角度量化单体异常性。实例应用结果表明,该方法可以识别早期潜在风险,并跟踪恶化过程。

1 实车运行数据提取及预处理

随着动力电池使用时间增加,电池性能随老化过程衰减,各单体之间的不一致性加剧。以电池放电电压代表其工作状态,根据动力电池使用时间及老化程度,对全生命周期数据中的所有放电数据片段进行划分:首先,选取车辆全生命周期中的早期放电过程,此时电池健康状态(SOH)为100%,且电池之间一致性较好;其次,建立实时电压估计模型,以此作为模型的训练及验证的标准状态数据,描述健康状态下单体电池电压对负载的响应关系;最后,以后续放电数据为待测对象,结合模型输出的电压值作为参考值,计算当前的真实电压响应值与健康状态下的响应值之间的偏离。

在实时电压估计模型中,以描述当前电池负载

状态的数据项作为输入,模型输出值为单体电压估计值。以下对实车运行数据中相关数据项进行分析。

1.1 相关数据项分析

在纯电动汽车的实车运行数据中,包括车辆运动状态特征、动力驱动系统特征及电池电信号特征。由于用以研究的车辆云端数据的采样间隔一般为10 s(0.1 Hz),而在车辆实际行驶过程中,驾驶员面对路况的变化须及时进行加速或制动,实时电流值数据的变化幅度较大。且电池电压的变化具有非即时性,不能忽略前序时间步对当前实时电压值的影响。因此,须考虑车辆运动状态特征及动力驱动系统特征,以结合在采样间隔中的电池行为,车辆行驶状态与动力电池工作状态之间的关联性如图1所示。




图1 相关特征的关联性示意图

结合动力电池总电压与电机控制器输入电压,其差值可以反映低压系统的耗电状态,从而在根据上述特征挖掘动力电池工作状态时,去除不同工况下非驱动部件的电量损耗影响。根据电机学基本原理,可以通过数学模型,描述理想状态下电机工作状态与输入电流等参数之间的关系,将驱动电机转速及转矩数据输入电压估计模型中,可以进一步提取当前动力电池的工况特征。结合对于电机系统控制的相关研究,以永磁同步电机(PMSM)为例,其负载转矩 T_l 与电流的关系可表示为

$$T_l = T_e - B_m \omega_r - T_f - J \frac{d\omega_r}{dt} \quad (1)$$

式中: T_l 与 T_e 分别表示电机的库伦摩擦转矩与电磁转矩; B_m 表示阻力摩擦系数; J 表示转动惯量^[20]。

由此,提取实车运行数据中的相关数据项,根据其描述内容可分为3类:其一,车辆运动状态特征,包括车辆行驶里程、实时车速、加速踏板及制动踏板挡位;其二,动力驱动系统特征,描述驱动电机及其控制器的工作状态;其三,动力电池特征,包括总电压、总电流、电池荷电状态(SOC)及电池包内电压及温度采样值等,具体如表1所示。

表1 相关数据项类别及具体内容

序号	车辆运动状态特征	动力驱动系统特征	动力电池参数特征
1	车辆速度	驱动电机温度	总电压
2	累计行驶里程	驱动电机转矩	总电流
3	加速踏板挡位	驱动电机转速	SOC
4	制动踏板挡位	驱动电机控制器温度	单体电芯电压值
5		电机控制器输入电压	温度探针采样值
6		电机控制器输入电流	

1.2 放电片段提取及预处理

对于全生命周期实车运行数据,除上述用于模型训练的相关数据项之外,还须结合车辆充放电状态、采样时间等信息,截取用于分析的放电数据片段,去除空值等无效数据,得到按时间排布的一系列长度及SOC范围不同的放电数据片段。此外,需要对特征中的文本状态值进行编码,如制动踏板挡位数据项的值为“是”或“否”,则分别将其对应为0与1,以便后续数据分析。由于各项多特征数据的数量级与单位存在差别,且算法中包含涉及特征点距离的计算,须进行数据预处理以去除方差等对模型效果的影响。结合数据本身的分布特点选择对应的标准化方法,如实时电流值方差较大,且对于存在制动回收过程电动汽车,在连续放电片段中总电流也为双向电流,选用标准差标准化(Z-score)方法,使其均值为0,方差为1;而SOC值及总电压值在单次放电过程中逐渐降低,选用离差标准化(Min-Max)进行线性变换至[0,1]之间即可,具体计算方法如下:

$$\begin{cases} stdFea_t^i = (F_t^i - \mu^i) / \sigma^i \\ mmFea_t^i = (F_t^i - F_{min}^i) / (F_{max}^i - F_{min}^i) \end{cases} \quad (2)$$

式中: F_{max}^i 、 F_{min}^i 及 F_t^i 分别表示第*i*维初始特征值的最大值、最小值及在时间*t*时的采样值; μ^i 及 σ^i 分别表示第*i*维初始特征值的均值及方差; $stdFea_t^i$ 表示标准差标准化后的特征值; $mmFea_t^i$ 表示离差标准化后的特征值。

对节选的放电数据片段进行预处理后,得到样本 D_r 。以某样本为例,部分特征的数值分布曲线如图2所示,其中,对于车辆行驶里程数据计算1阶微分,计算相邻采样点之间的里程变化。对于总电流数据项,制动能量回收充电时电流为负,电池输出电流驱动电机时电流为正,总电流为双向电流,在车辆运动角度,驱动与制动过程分别对应加速与减速过程;在电池机理角度,充电与放电过程对应的反应过程也存在差别。在后续分析过程中,按正负值拆分

为正值驱动电流与负值回收电流,以分别考虑两种行驶工况。由此得到描述当前车辆运行状况的各项

特征,如表2所示。

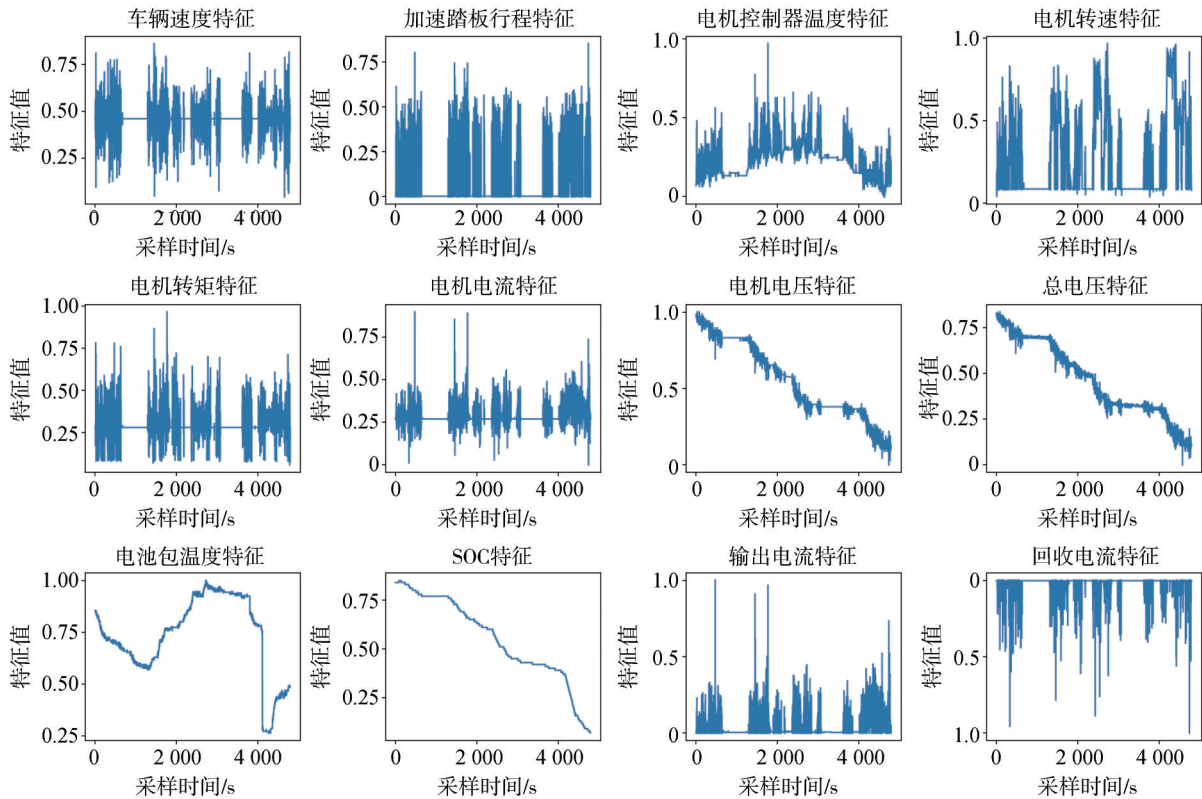


图2 预处理后的部分特征分布曲线

表2 预处理后的各项特征值示例

序号	时间	速度特征	里程特征	总电流特征	总电压特征	电机转矩特征	电机转速特征	电机电流特征	电机电压特征	SOC特征	加速特征	制动特征	温度特征	输出电流特征	回收电流特征
1	07:41:56	0.808	0.682	0	0	0.131	0.485	0.256	0.255	0.970	0.809	0.843	0.84	0	-0.048 3
2	07:42:06	0.097	0.682	0	0.45	0.131	0.084	0.278	0.268	0.970	0.814	0.849	0.84	0.004 1	0
3	07:42:16	0.602	-0.640	0.51	0	0.475	0.241	0.712	0.412	0.955	0.799	0.849	0.84	0.223 2	0

2 基于1dCNN-LSTM的单体量化

通过量化单体异常性进行动力电池故障诊断的步骤可以分为:其一,建立基于1dCNN-LSTM的实时电压估计模型,模拟健康电池对于当前工况的电压响应,得到电压参考值;其二,结合电压参考值,与当前各单体的真实采样值进行比较,通过建立评分方法,量化该单体的性能相对于健康电池的偏移。以电压参考值为参照与各单体电池进行比较,相比于单体电池电压互比较方法而言,能够适应性地结合当前的工况条件,更明确地得到当前该单体性能的偏离程度,整体流程如图3所示。

2.1 基于1dCNN-LSTM模型估计实时电压

结合车辆运行数据中的相关数据项,建立1dCNN-LSTM融合模型,估计单体电池实时电压值。车辆运行数据是具有固定采样间隔的典型时序数据,各采样点按时间顺序依次排列,选用时序数据分析模型,提取各特征项中的有效信息,估计健康状态下的电池单体电压响应值。

2.1.1 基于1dCNN提取电信号局部特征

一维卷积神经网络(1dCNN)模型是用以处理序列数据的经典深度学习模型之一,被广泛应用于自然语言处理、数字信号处理及时间序列预测中。其原理与更为常见的二维卷积神经网络模型相似,通过建立卷积核并使其在数据集上按照某种移动规则

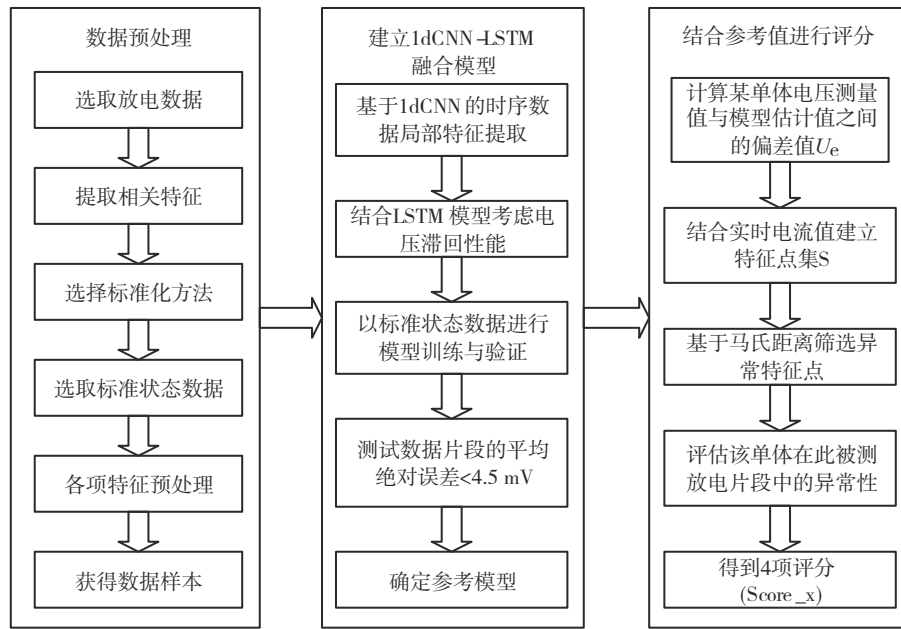


图3 单体异常性量化方法及流程示意图

移动并进行卷积计算,从而提取局部特征。

结合经典 Thevenin 等效电路模型,电池端电压 U 与电池当前开路电压值 U_{ocv} 、电池回路电流值 I 、欧姆内阻 R_0 、极化内阻 R_1 和极化电容 C_1 等参数之间的关系如式(3)所示。结合实车运行数据中的电池电信号参数,可以通过神经网络中的全连接层拟合上述非线性关系,以估计电池端电压。

$$U = U_{ocv} - IR_0 - IR_1(1 - e^{-\frac{t}{R_1 C_1}}) \quad (3)$$

对于建立的 1dCNN-LSTM 融合模型,以 1dCNN 层提取电信号局部特征,其输入数据为与电池电信号相关的 8 维特征,包括总电压、正值驱动电流、负值回收电流、电池荷电状态(SOC)值、驱动电机控制器输入电压、驱动电机控制器直流母线电流、电池包温度及驱动电机转矩。基于放电数据样本 D_T ,提取上述 8 维特征,得到对 1dCNN 神经网络的输入数据 d_c 。

对于含有 f 个卷积核的 1dCNN 网络层,其训练过程中,各卷积核权重分别更新,以上述含有 8 维特征的输入数据 d_c 为例,时间步为 t 时的输入数据为 d^t ,第 m 个卷积核 k^m 中的计算过程如下:

$$Conv(d^t, k^m) = \sum_{i=0}^l \sum_{j=0}^8 (d_{ij}^t \cdot k_{ij}^m) + b_m \quad (4)$$

式中 b_m 和 l 分别表示卷积核 k_m 的偏置量和在时间轴上的宽度。对于一次上述式(4)中的卷积计算,得到该时间步 t 下由卷积核 k^m 提取的一个特征值,输出的

特征提取结果维度与卷积核个数相同。

2.1.2 结合 LSTM 模型考虑电压滞回现象

在锂离子电池的充放电过程中,由于电池内部导电离子的扩散迁移过程非瞬时完成,离子扩散速度远小于负载电路中的电荷移动速度,且在锂离子的嵌入与脱嵌过程中,电池内部会产生机械应力,会对电压响应造成影响,从而导致电压的非线性、非即时性变化^[21]工况下,实时电流值变化剧烈,对于间隔 10 s 的相邻采样点,二者实时电流的差值可能超过 100 A,因此,在实时电压参考值估计过程中,不能忽略前序时间步对当前电压值的影响。采用长短期记忆神经网络,可以提取数据中的长期依赖信息,通过更新各门控记忆单元(遗忘门、记忆门及输出门)权重及偏置参数,提取时序数据中的前序及当前有效信息,实现特征提取及记忆功能^[22],结合电压滞回效应机理,以及实车运行数据的固有时序特性,将上述 3 类实车运行数据项输入至 LSTM 神经网络中,学习前序工况对当前电压值的影响,以提高电池电压参考值的估计精度。

通过设置 LSTM 细胞单元中隐藏神经元数量以确定目标输出维度,并基于多批次训练数据,实现各神经元权重及其偏置量的迭代更新,以提取与输出值相关的长期或短期有效信息。以某批次输入 LSTM 的数据样本 d_i 为例,在隐藏层尺寸为 u 的 LSTM 层中,其数据处理步骤如下。

①接收输入数据与记忆数据,接受当前时刻 t 时的输入数据 x_t ,上一时刻 $t-1$ 时的隐藏层状态 h_{t-1} 及记忆细胞状态 C_{t-1} 。

②筛选输入与记忆数据中的有效信息,分别结合权重矩阵 W_f 、 W_i 、 W_c 及偏置值 b_f 、 b_i 、 b_c ,并计算上一时间步记忆数据中的有效信息 f_t 、当前输入值中的有效信息 i_t 及当前输入值对细胞状态的影响 \tilde{C}_t ,其计算过程可表示为

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \end{cases} \quad (5)$$

式中: σ 表示sigmoid激活函数,将计算映射到 $(0, 1)$ 区间; \tanh 表示双曲正切激活函数,将计算结果映射到 $(-1, 1)$ 区间。sigmoid及tanh激活函数的表达方法如式(6)和式(7)所示。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7)$$

③估计结果输出与记忆信息更新,基于上述有效信息及细胞状态相关数据计算得更新后的当前细胞状态值 C_t ,并根据输出矩阵 W_o 及偏置值 b_o 计算当前时刻输出值 O_t ,最后结合当前细胞状态值 C_t 及当前时刻输出值 O_t 更新当前状态下的隐藏层状态值 h_t 。其运算过程可表示为

$$\begin{cases} c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \end{cases} \quad (8)$$

由此,建立1dCNN-LSTM融合模型,包含下述两个子模块:其一,基于1dCNN子模型提取电池电信号数据的局部特征,并增加全连接层拟合如式(3)所示的非线性等效电路模型,实现电池端电压的预估计;其二,应用LSTM模块的记忆特性,输入车辆行驶、电机驱动及电池电信号三维数据,考虑采样间隔内的车辆运行状态,以及前序时间步对当前电压值的影响,进一步提升电池端电压的估计精度。该单体电压估计值模型在结构上属于双输入融合模型,具有两个输入接口,分别对1dCNN与LSTM输入其目标数据项。此外,以早期标准状态数据作为模型的训练及验证数据,此时单体电池均处于健康状态,且各电池单体测量值几乎全部相同。在此有监督回归模型的训练过程中,可以将单体平均值作为模型输出真值。在内有 a 个电池单体的电池包中,某采样点实时测量值的平均值 u_{aver} 可以表示为

$$u_{aver} = \frac{1}{a}(u_1 + u_2 + \dots + u_a) \quad (9)$$

2.2 单体电池异常性量化方法

应用上述单体电池电压估计模型,得到健康单体电池在当前工况下的电压响应值,以此作为电压参考值,与各单体的实时电池测量值结合,评估测量值与电压参考值之间的差异,量化各单体相对健康状态的异常偏离。在异常性的量化过程中,建立异常性评分值,将某电池在某放电片段中若干采样点的性能表现,概括为下述各项评分值,以实现单体电池异常性的评估。对不同放电片段中的不同单体的评分值进行比较,可以实现异常单体的定位,以及评分恶化过程的跟踪。其步骤包括:其一,以实时电流及电压偏差值为特征,对于放电片段内各采样点建立特征点集;其二,筛选异常采样点,结合马氏距离(Mahalanobis Distance)计算特征点之间的距离,得到临界值及异常点;其三,计算异常性评分,结合异常采样点的统计特征,量化该片段内电池性能表现的异常程度。

2.2.1 结合电流及电压偏差值构建特征点集

由于早期的健康电池之间一致性较好,同一放电片段内各单体的电压响应相同。随着电池使用时间增加,各电池单体性能发生不同程度的变化。对于一个待测放电片段,基于上述模型进行电压参考值 U_{ref} 的估计,将其与电池包内所有单体的真实测量值比较,以此评估各单体性能偏移。由于电池的老化程度随着电池使用时间增加,当前电池状态与早期健康状态相比,存在整体性能的下降。对于某放电数据片段,以 U 与 u 分别表示某项电压的数据序列与各采样点的电压值,如以 u_{ref} 表示电压参考值序列 U_{ref} 中某时刻的一个电压参考值,含有 n 个采样点的电压序列,可以表示为

$$U_{ref} = (u_{ref}^1, u_{ref}^2, \dots, u_{ref}^n) \quad (10)$$

由此,对于某时刻的电压真实测量值 u_t ,将其相对参考值 u_{ref} 的偏离分为两部分:本放电片段内性能的整体偏移情况 u_b ,表示电池性能的平均偏移量;以及该时刻实时工况下的电压异常表现 u_e ,反映电池在各采样点的实时异常,表示如下:

$$u_t - u_{ref} = u_b + u_e \quad (11)$$

对于某电池单体,在某放电数据片段中,计算各采样点电压参考值 u_{ref} 与真实测量值 u_t 之间的误差,得到误差序列 U_b 。计算误差序列均值,得到描述该片段内整体性能偏移的平均偏移量 \bar{U}_b ,对误差序列进行零均值化处理,得到均值为0的电压偏差值 u_e ,上述关系可表示为

$$u_e = u_r - u_{ref} - \bar{U}_b = u_r - u_{ref} - \frac{1}{n} \sum_{i=1}^n (u_r^i - u_{ref}^i) \quad (12)$$

由于实时电流值对当前电池单体电压的影响显著,且锂离子电池实时电流与电压之间存在非线性关系,在实时电流较大时会出现采样点模型估计误差增大的现象。为了增强算法的鲁棒性,结合实时电流值与电压偏差值建立特征点,以共同评估当前采样值的异常情况。建立标准状态及临界状态以筛选异常点,当实时电流很大但电压偏差值为0时,认为此刻电池参考值与真实状态完全相同,电池无性能偏离,以此为标准状态;结合实时电压估计模型验证中,估计值与真值的平均绝对误差一般不超过5 mV,当实时电流为0且电压偏差值超过10 mV时,认为此刻电池性能出现明显偏移,以此为临界状态。此外,大电流采样点相对较少,为了优化样本点分布,将标准点表示在坐标轴中心,构建实时电流映射关系,基于实时电流值 $Curr$ 构建电流特征值 C ,如式(13)所示,从而得到基于实时电流工况与电压偏差值的特征点集 $S[C, U_e]$,如图4(a)所示。

$$C = \begin{cases} 1 - 0.01 \times Curr, & Curr < 100 \text{ A} \\ 0, & Curr \geq 100 \text{ A} \end{cases} \quad (13)$$

在实时特征点集 S 的基础上增设两个参考特征点,对于上述标准状态与临界状态,分别设置标准点 $S_{std}(0, 0)$ 与临界点 $S_{lim}(1, 0.01)$,特征点集分布的优化效果对比,以及增设的参考特征点示意图,如图4(b)所示。

2.2.2 应用马氏距离筛选异常点


以标准点 S_{std} 及临界点 S_{lim} 之间的距离作为临界距离 $Dist_{lim}$,计算点集 S 中各点与 S_{std} 之间的距离,与临界值进行比较,将超过 $Dist_{lim}$ 的采样点标记为异常点。其中,如图4(b)所示,特征点二维特征的分布情况不同,且电压偏离值与当前电流之间可能存在相关性,须结合特征的协方差,以更准确地度量特征点之间的差异。以马氏距离进行特征点距离计算,可以避免不同特征项数据分布情况不同带来的影响。以上述特征点集 S 中的某特征点 S_0 与 S_1 为例,马氏距离的计算方法如下:

$$Dist(S_0, S_1) = \sqrt{(S_0 - S_1)^T \Sigma^{-1} (S_0 - S_1)} \quad (14)$$


式中 Σ 指特征 C 与特征 U_e 的协方差矩阵。

由此,计算点集 S 中各特征点与标准点 S_{std} 的马氏距离,将其距离大于临界距离 $Dist_{lim}$ 的特征点标记为异常特征点,得到异常特征点集 S_e ,如图4(c)


所示。



(a) 基于原数据的初始特征点分布



(b) 应用电流映射后的特征点分布



(c) 基于马氏距离的异常点筛选结果

图4 特征点集及其优化与筛选示意图

2.2.3 建立单体异常性评分方法

对于某放电数据片段,为了进一步描述某单体电池性能的异常程度,设立4项异常评分值,从不同方面量化该片段内的电压偏离情况,包括:单体电池整体偏移评分(Score-b)、采样点平均异常程度评分(Score-mm)、采样点最大异常程度评分(Score-ma),以及采样点异常频率评分(Score-mf)。

以单体电池整体偏移评分(Score-b)表示此片段中电压实测值与参考值的整体偏移程度,以评估长期老化过程中的性能变化。该评分等于某片段内所有采样点的误差平均值,与平均偏移量 \bar{U}_b 相等,Score-b可表示为

$$Score_b = \frac{1}{n} \sum_{i=1}^n (u_r^i - u_{ref}^i) \quad (15)$$

式中 n 表示此数据片段的采样点个数。

为了进一步评估单体电池异常性,概括某片段内各采样点的实时异常,结合上述基于实时电流值与电压偏差值构建的特征点集 $S[C, U_e]$,以采样点

平均异常程度评分(Score-mm)、采样点最大异常程度评分(Score-ma)及采样点异常频率评分(Score-mf),分别评估异常特征点集的平均异常程度、最大异常程度及出现异常的频率,共同描述某电池在此放电片段中的采样点异常情况。其中,对于Score-mm,等于 S_e 中各异常特征点的马氏距离超出临界距离 $Dist_{lim}$ 的平均值,表示为

$$Score_mm = \frac{1}{n_e} \sum_{i=1}^{n_e} (Dist_i - Dist_{lim}) \quad (16)$$

以Score-mf评估采样点异常频率,为异常特征点集 S_e 中异常特征点的个数与点集 S 中全部特征点个数的比值,其计算方法为

$$Score_mf = n_e / n \quad (17)$$

式中: n_e 与 n 分别表示异常特征点集 S_e 及总特征点集 S 中的特征点个数; $Dist_i$ 表示第 i 个异常特征点与标准特征点 S_{std} 之间的马氏距离。将异常点集中与标准点距离最远的点定义为最大异常点,该距离为最大异常距离,以Score-ma表示最大异常距离 $Dist_{max}$ 超出临界距离 $Dist_{lim}$ 的比例:

$$Score_ma = (Dist_{max} - Dist_{lim}) / Dist_{lim} \quad (18)$$

综上所述,通过建立实时电压估计模型,模拟健康单体电池的电压响应,以此作为电压参考值,与待测数据中的单体电池电压采样值进行比较。对于某放电片段,建立概括该片段内单体电池表现的4项评分,从而得到各单体异常性的量化结果。

3 模型验证及案例分析

以某实车运行数据为例,介绍上述提出的单体异常性量化方法的应用流程。将本方法应用于动力电池热失控事故案例中,评估结果显示,对于由单体异常或整体恶化导致的两类热失控事故,本方法均具有显著的应用效果。

3.1 单体异常性量化方法的应用

对于上述建立的单体异常性量化方法,首先,结合实车运行数据,训练并验证1dCNN-LSTM融合模型,比较实时单体电压值的估计精度,验证考虑车辆行驶特征的必要性。其次,结合某放电数据片段,设置SOC间隔值,将较长的放电过程划分为若干个SOC子片段,以进一步结合电池荷电状态评估单体异常性。由此,对某次放电过程,结合SOC值以及电池单体序号等两项标签,对各单体在各SOC下的电压序列进行评估,得到该放电过程的异常性评分矩

阵,后续将根据此矩阵实现异常单体序号的定位。

3.1.1 1dCNN-LSTM模型训练及验证示例

以某起动力电池热失控事故为例,定义此事故车辆为1号车,其车载电池包内有串联的96个单体电池。选取若干个标准状态数据片段,进行模型的训练与验证。模型训练过程中,以式(9)定义的各单体实时测量值的平均值 u_{aver} 作为该时刻的模型真值,各采样点的平均值序列表示为 U_{aver} 。结合网格搜索法(GridSearch)确定模型超参数,采用k折(k-fold)交叉验证法进行模型训练与权重更新,并以决定系数R2-score评分值及平均绝对误差(MAE)共同评价模型性能。其中,R2-score通过计算模型估计值与真实值之间的误差平方和与真实值方差之间的比值的互补数,来衡量模型误差的可解释性,R2-score值在区间 $[0, 1]$ 中,越大表示性能越佳,R2-score与MAE的表示方法如下:

$$\begin{cases} R^2 = 1 - \frac{\sum_{i=0}^n (u_{aver}^i - u_{ref}^i)^2}{\sum_i (u_{aver}^i - \bar{u}_{aver})^2} \\ MAE = \frac{1}{n} \sum_{i=0}^n |u_{aver}^i - u_{ref}^i| \end{cases} \quad (19)$$

式中: l 为训练数据样本长度; i 为采样点序号。

以模型的某测试数据为例,模型估计值与真值曲线的对比情况如图5所示。由图可见,融合模型可以有效识别实车数据中的不同工作状态,在启动待机状态与行驶状态下均有较好的使用效果,可以实现实时电压估计值的估计。在此验证数据中,R2-score评分结果值为0.9968,其值接近1表示模型完成了真实值的有效拟合;MAE评分结果值为0.0038,即模型的平均绝对误差为4mV,满足本算法的精度要求。由此确定1dCNN-LSTM融合模型的各项超参数,在一维卷积神经网络模型中,包含两个卷积核个数分别为8和6的1dCNN层,最后为单元数分别为6和1的两个全连接层,基于电信号输出电压估计值;在LSTM子模型中,以包含16个单元的全连接层作为输入层,连接两层记忆单元数为32及8的LSTM层,并最终输出维度为1的全连接层作为输出层。激活函数选用LeakyReLU函数,优化器选择Adam优化器,学习率为0.001。

此外,通过对比模型MAE及R2-Score值,对有无结合车辆运行状态的电压估计效果进行比较,并验证增加LSTM模块的有效性,如表3所示。由此可见,建立的1dCNN-LSTM融合模型的估计精度更高,尤其对于测试片段3而言,结合实车运行数据大幅提升了实时单体电压的估计精度,结合记忆特性后进

一步降低了模型的估计误差,融合模型在面对运行工况复杂的实车数据时,具有更好的估计效果。




图5 基于1dCNN-LSTM实时电压估计结果示例

表3 结合车辆运行特征及LSTM记忆修正功能的优化效果

测试片段	仅考虑电池电信号特征 (1dCNN)		结合车辆运行特征 (1dCNN)		结合车辆运行特征 (1dCNN-LSTM)	
	MAE/mV	R2-Score/%	MAE/mV	R2-Score/%	MAE/mV	R2-Score/%
某完整放电片段	5.43	99.86	4.88	99.89	4.43	99.91
某SOC下降10%的子片段-1	4.72	94.22	4.28	95.50	3.68	96.56
某SOC下降10%的子片段-2	5.62	93.86	4.57	96.19	4.16	96.47

3.1.2 根据SOC划分子片段并量化异常性

应用上述单体电池异常性评分方法,可以对某放电片段中的电池性能进行评估。结合SOC值进行放电片段的划分,以比较不同荷电状态下的电池性能。以10%作为一个子片段的SOC变化跨度,将某放电数据划分为 x 个SOC片段,目标数据片段及其子片段可表示为

$$D_T = \begin{cases} D_T^{SOC1} = (Fea_i^{SOC1}, \dots, Fea_{ni}^{SOC1}, U_r^{SOC1}) \\ \vdots \\ D_T^{SOCx} = (Fea_i^{SOCx}, \dots, Fea_{ni}^{SOCx}, U_r^{SOCx}) \end{cases} \quad (20)$$

式中 Fea_i^{SOCx} 及 U_r^{SOCx} 分别表示第 x 个SOC段中的第 i 维数据特征和所有单体电池的实测电压数据值。

进一步得到各SOC子片段中各单体电池的4项评分结果,以热力图形式进行评分结果可视化,并根据热力图对电池包故障种类及程度进行分析。以1号车事故发生1年前的某数据样本片段为例,可视化结果如图6所示。由图可见,在前期正常使用阶段,偶然存在个别单体在部分SOC段的较高评分,整体无明显异常。

3.2 案例1 单体电池故障定位

进一步对上述1号车进行分析,该车自2021年8月开始投入使用,2023年5月4日发生热失控事故。在其全生命周期数据中,每月随机抽取一个放电数据片段样本,评估样本片段中各单体电池的异

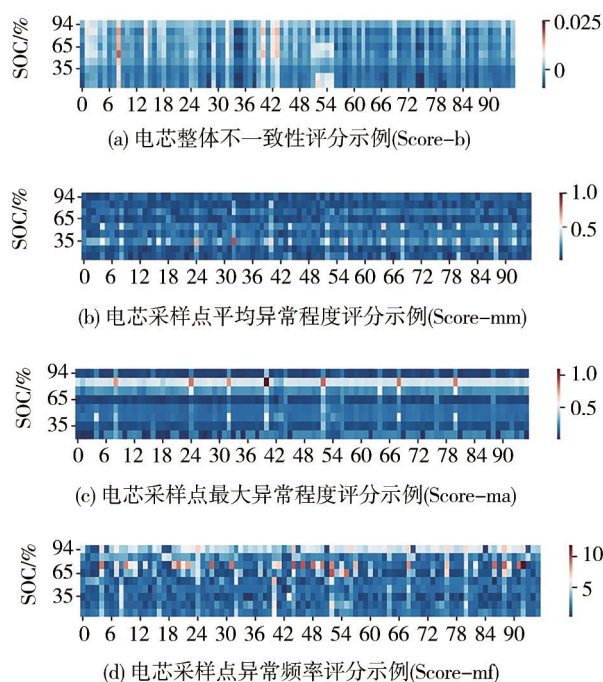


图6 SOC间隔值为10%的4项评分热力图示例

常性。结合电池单体整体不一致性评分(Score-b)的计算结果进行分析,在2021年9月至2021年12月内的4个放电数据片段样本中,对于SOC从100%降低至30%的7个子片段,在96个单体的Score-b评分值中,77号电池的该项评分值一直是最低的。由此

可见,在使用初期,77号单体电池的整体电压表现持续低于其他单体。此外,该车热失控后的动力电池包拆包勘验结果表明,最先热失控的单体为M20模块的77号单体。结合Score-b评分结果以及勘验结论,该单体早期评分值出现持续的明显异常,有极大可能存在制造缺陷,从而导致最终的热失控事故。


对事故发生前的最后一次完整放电过程进行分析,发现Score-mm评分值在SOC的30%~40%范围内存在明显数据异常的电池单体中,就包括值得关注的M20模组内的77号电池。进一步提取事故发生7日前及1年前的放电数据进行分析,分别如图7(a)和图7(b)所示,发现此SOC范围中也出现了类似的情况,在电池组中存在部分单体出现明显的评分异常,且此异常有从高SOC段到低SOC段评分恶化的明显趋势。对比图7(a)与图7(b),动力电池使用1年后,Score-mm在同比例尺下性能恶化明显。

比较模组内电池单体的不一致性,其中,1号车动力电池组排布方式为4个电池单体组成一个模


组,计算各评分在模组内的最大最小差值以评估模组不一致性。以事故发生前7日的放电数据为例,对24个模组内的四维评分根据不一致性差值进行排序,差值最大的前5个模组及其差值如表4所示。其中,4项评分下的异常模组结果近似,模组M20、M17、M10、M6、M8均得到了可能存在风险的评价。这表明上述模组在实时电压最大离群值、实时电压离群频率、实时电压平均离群值及单体平均不一致性值4个维度均得到了可能存在风险的评价,评分结果如表4所示。

表4 4项评分差值的最高值及其对应模组编号

序号	Score-b		Score-ma		Score-mm		Score-mf	
	模组编号	组内差值	模组编号	组内差值	模组编号	组内差值	模组编号	组内差值
1	2	0.008 1	20	0.802	10	0.306	13	11.280
2	13	0.004 1	17	0.780	6	0.231	2	9.400
3	6	0.002 9	10	0.769	17	0.229	10	4.834
4	10	0.002 8	8	0.766 3	20	0.220	8	3.671
5	17	0.002 6	6	0.749	8	0.210	20	3.491



(a) 事故发生1年前Score-mm分布情况



(b) 事故发生7日前Score-mm分布情况

图7 部分单体电池Score-mm评分显著异常(案例1)

由此可见,在事故发生7日前部分模组已经出现了明显的异常状态,提取事故发生前1周、事故发生前1个月及事故发生前5个月的放电过程数据进行评分比较,其Score_ma评分值的恶化结果明显,热力图中代表较差评分值的红色色块在SOC中段具有明显的蔓延扩散趋势,如图8所示。

结合事故后的拆包勘验结果,最早热失控的模组即为M20模组,由此可见,该方法可以实现恶化演变过程的跟踪,并可以在早期正常使用中识别潜在

的异常单体。

3.3 案例2 电池包整体恶化过程分析

以因动力电池包热失控导致火灾事故的2号车为例,将该方法应用于电池包内单体电池整体恶化失控的事故中。

提取事故发生前的若干个待测的放电数据片段,进行单体异常性的量化,计算各单体在各子片段中的评分值。评分结果表明,临近事故发生时,所有单体的Score-mf评分值出现明显的升高趋势。将某

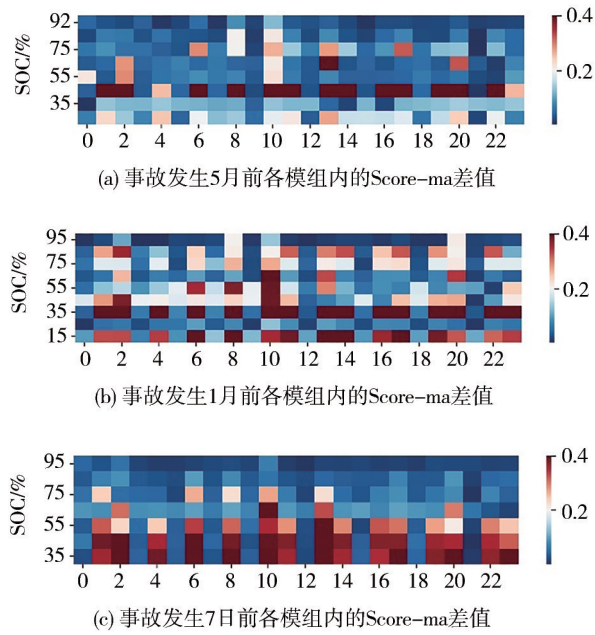


图8 Score-ma 差值随时间出现恶化蔓延

2次充电之间动力电池SOC值逐渐降低的过程作为1个放电过程,以cycle0表示事故发生前的最后1次放电过程,cycle1表示事故发生前的倒数第2次放电过程,在2号车事故发生前7日中,共包含6次放电过程,结合上述放电过程的表示方法,2号车最后6次放电的Score-mf评分的最大值如表5所示。

表5 Score-mf评分最大值

序号	cycle5	cycle4	cycle3	cycle2	cycle1	cycle0
Score-mf	3.726 7	7.888 6	7.235 0	12.854 4	11.059 9	16.920 2

由此可见,临近事故发生,Score-mf评分值有明显的增长趋势,且cycle0中Score-mf评分值的最大值约为cycle5的4.5倍。结合式(17)中对于该项评分值的定义,在事故发生前7天内,各单体电池出现异常采样点的频率明显增加。

以热力图形式,对电池包内所有单体在各SOC子片段中的Score-mf评分情况进行可视化,为了更直观地显示整个电池包异常状态的演变,采用相同的数值-颜色对应规则,事故发生7日、3日、1日前及事发当日的Score-mf评分如图9所示。在较早的cycle5中暂未出现红色色块,在cycle_3中开始出现浅红色评分值,并在cycle_1中红色色块数量增多,颜色加深,出现明显的整体恶化现象。

此外,与1号车不同的是,2号车动力电池包在热失控事故发生前,各单体电池电芯之间的不一致

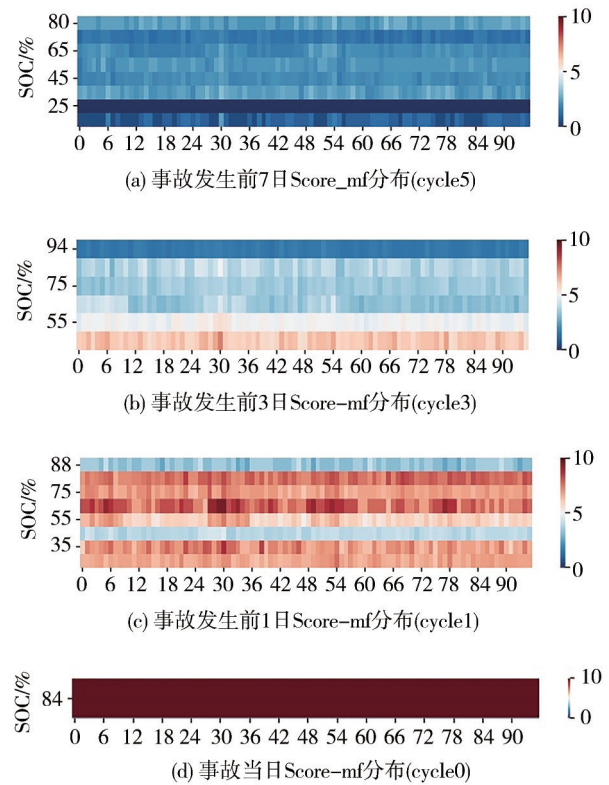


图9 不同放电过程Score-mf评分的对比

性不明显。通过传统的单体电池电压信号对比聚类难以得到异常结论。应用单体异常性量化方法,以评分值量化当前单体的性能表现,从而实现不同放电片段之间的比较。

4 结论

随着大数据传输及存储相关软硬件技术的发展与应用,基于电动汽车云端实车运行数据,研究动力电池故障诊断技术,对保障实车安全运行具有重要意义。本文提出的基于1dCNN-LSTM量化单体异常性的故障分析方法,可以有效识别电池包及单体电池的异常状态。本文研究结果表明:

(1)该方法可以得到更清晰的单体异常性量化结果,相比单体电池互比较方法,本方法以早期健康状态作为参照,量化各单体电池对于相同参照的性能偏移,从而得到更准确的单体异常性评估结果;

(2)该方法适用于分析动力电池包整体恶化故障,通过对不同放电过程中异常程度的比较,可以得到相同单体在不同放电过程中的不同表现,从而实现恶化过程的跟踪;

(3)该方法可以结合放电过程的日期与SOC子片段的划分,标注该单体电池在某放电片段的荷电状态及老化状态,从而分析单体异常性评分值的变化趋势。

此外,恶劣评分电芯序号之间存在某种等差关联性,这有可能与长时间使用过程中,电池包模组结构、冷却系统排布及电池管理系统的模组均衡管理算法有关,本方法可为电池管理系统的软硬件进一步优化提供参考。后续将进一步结合健康老化的实车数据及更多热失控故障数据,扩展本方法的应用范围。

参考文献

- [1] TIAN J, FAN Y, PAN T, et al. A critical review on inconsistency mechanism, evaluation methods and improvement measures for lithium-ion battery energy storage systems [J]. *Renewable and Sustainable Energy Reviews*, 2024, 189: 113978.
- [2] LI J, LI T, FANG D, et al. Internal fault diagnosis method for lithium batteries based on a failure physical model [J]. *Engineering Failure Analysis*, 2023, 154: 107714.
- [3] HU Y, LAN F, CHEN J, et al. Effectiveness of heat insulation and heat dissipation for mitigating thermal runaway propagation in lithium-ion battery module [C]. *CEEPE*, 2022: 192-198.
- [4] LIU H, LI L, DUAN B, et al. Multi-fault detection and diagnosis method for battery packs based on statistical analysis [J]. *Energy (Oxford)*, 2024, 293: 130465.
- [5] LI J, YE M, MA X, et al. SOC estimation and fault diagnosis framework of battery based on multi-model fusion modeling [J]. *Journal of Energy Storage*, 2023, 65: 107296.
- [6] YU Q, DAI L, XIONG R, et al. Current sensor fault diagnosis method based on an improved equivalent circuit battery model [J]. *Applied Energy*, 2022, 310: 118588.
- [7] YAN Y, LUO W, WANG Z, et al. Fault diagnosis of lithium-ion battery sensors based on multi-method fusion [J]. *Journal of Energy Storage*, 2024, 85: 110969.
- [8] 李致远, 鲁锐华, 余庆华, 等. 动力电池热失控特征及防控技术研究分析 [J]. *汽车工程*, 2024, 46(1): 139-150.
LI Z Y, LU R H, YU Q, et al. Research and analysis of thermal runaway characteristics and prevention and control technology of power battery [J]. *Automotive Engineering*, 2024, 46(1): 139-150.
- [9] HE H, ZHAO X, LI J, et al. Voltage abnormality-based fault diagnosis for batteries in electric buses with a self-adapting update model [J]. *Journal of Energy Storage*, 2022, 53: 105074.
- [10] 兰凤崇, 陈继开, 陈吉清, 等. 实车数据驱动的锂电池剩余使用寿命预测方法研究 [J]. *汽车工程*, 2023, 45(2): 175-182.
LAN F C, CHEN J K, CHEN J Q, et al. Research on lithium battery remaining useful life prediction method driven by real vehicle data [J]. *Automotive Engineering*, 2023, 45(2): 175-182.
- [11] 杨世春, 王潇, 陈飞, 等. 锂离子电池故障预测及健康管理技术研究进展 [J/OL]. *北京航空航天大学学报*: 1-14 [2024-3-07].
YANG S C, WANG X, CHEN F, et al. Advances in prognosis and health management technologies of lithium-ion batteries [J/OL]. *Journal of Beijing University of Aeronautics and Astronautics*: 1-14 [2024-3-07].
- [12] MACHLEV R. EV battery fault diagnostics and prognostics using deep learning: review, challenges & opportunities [J]. *Journal of Energy Storage*, 2024, 83: 110614.
- [13] 郭文超, 杨林, 邓忠伟, 等. 云端数据驱动的锂电池故障分级预警研究 [J]. *汽车工程*, 2023, 45(9): 1677-1687, 1701.
GUO W C, YANG L, DENG Z W, et al. Research on multi-level fault warning method for lithium-ion batteries driven by cloud data [J]. *Automotive Engineering*, 2023, 45(9): 1677-1687, 1701.
- [14] ZHAO H, CHEN Z, SHU X, et al. Online surface temperature prediction and abnormal diagnosis of lithium-ion batteries based on hybrid neural network and fault threshold optimization [J]. *Reliability Engineering & System Safety*, 2024, 243: 109798.
- [15] JIANG J, ZHANG R, WU Y, et al. A fault diagnosis method for electric vehicle power lithium battery based on wavelet packet decomposition [J]. *Journal of Energy Storage*, 2022, 56: 105909.
- [16] NIU L, DU J, LI S, et al. An online fault diagnosis method for lithium-ion batteries based on signal decomposition and dimensionless indicators selection [J]. *Journal of Energy Storage*, 2024, 83: 110590.
- [17] FANG W, CHEN H, ZHOU F. Fault diagnosis for cell voltage inconsistency of a battery pack in electric vehicles based on real-world driving data [J]. *Computers and Electrical Engineering*, 2022, 102: 108095.
- [18] ZHAO J, FENG X, WANG J, et al. Battery fault diagnosis and failure prognosis for electric vehicles using spatio-temporal transformer networks [J]. *Applied Energy*, 2023, 352: 121949.
- [19] WANG S, WANG Z, CHENG X, et al. A double-layer fault diagnosis strategy for electric vehicle batteries based on Gaussian mixture model [J]. *Energy*, 2023, 281: 128318.
- [20] 滕青芳, 崔宏伟, 朱建国, 等. 基于无电流传感器的永磁同步电机系统模型预测控制 [J]. *电机与控制学报*, 2019, 23(5): 119-128.
TENG Q F, CUI H W, ZHU J G, et al. Current sensorless-based model predictive control for PMSM drive system [J]. *Electric Machines and Control*, 2019, 23(5): 119-128.
- [21] SCHMITT J, HORSTKÖTTER I, BÄKER B. A novel approach for modelling voltage hysteresis in lithium-ion batteries demonstrated for silicon graphite anodes: comparative evaluation against established Preisach and Plett model [J]. *Journal of Power Sources Advances*, 2024, 26: 100139.
- [22] GAO H, HAO F, ZHANG Y, et al. Application of Novel SN-IDCNN-LSTM framework in small sample oil and gas pipeline leakage detection [J]. *Franklin Open*, 2024, 6: 10007.