

DOI: 10.13382/j.jemi.B2306330

统计分析和密度聚类的锂离子电池组内 短路故障诊断*

范天斌^{1,2} 唐 鑫¹ 雷浩然¹ 李鹏华^{1,2}

(1. 重庆邮电大学自动化学院 重庆 400065; 2. 工业互联网与网络控制教育部重点实验室 重庆 400065)

摘 要:随着锂离子电池系统在电动汽车中的广泛应用,电池组短路引起的安全问题日益凸显,因此动力电池的状态监测与故障诊断备受关注。针对当前非模型故障诊断方法存在的泛用性低、抗干扰性差和电池组不一致性突出等问题,提出了一种基于统计分析和密度聚类的电池组短路故障诊断方法。首先根据遗忘机制,利用核密度估计的相对熵和相关系数提取电池组的故障信息,用于识别短路引起的电池电压和温度变化;接着采用基于密度的空间噪声聚类算法(DBSCAN)自动识别短路故障电池。该方法的鲁棒性在噪声干扰和电池组较大不一致性的条件下得到了有效验证。随后,在不同程度的微短路情况下(短路电阻分别为 1、5 和 10 Ω)进行故障诊断,结果表明在 10 Ω 短路情况下故障诊断的准确率能够达到 92.17%。最后通过对比分析,表明该诊断方法能够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。

关键词: 电池组短路故障诊断;相对熵;相关系数;DBSCAN

中图分类号: TH707 **文献标识码:** A **国家标准学科分类代码:** 530.4130

Internal short-circuit fault diagnosis of lithium-ion battery pack based on statistical analysis and density clustering

Fan Tian'e^{1,2} Tang Xin¹ Lei Haoran¹ Li Penghua^{1,2}

(1. College of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. Key Laboratory of Industrial Internet of Things and Networked Control, Ministry of Education, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: With the wide application of lithium-ion battery systems in electric vehicles, the safety issue caused by short-circuit fault of battery pack is becoming more serious. Therefore, the studies on state monitoring of battery pack and fault diagnosis are receiving more attention. To deal with the issues of low generality, poor anti-interference capacity and critical inconsistency of battery pack existed in non-model-based fault diagnosis methods, a short-circuit fault diagnosis method based on statistical analysis and density clustering is proposed for battery packs in this paper. Firstly, the fault information of battery pack is extracted by using the relative entropy of kernel density estimation (KDE) and correlation coefficient, based on a forgetting mechanism. The fault information is used to identify the changes of batteries' voltage and temperature caused by short-circuit fault. Then, the short-circuit battery can be automatically identified by adopting the density-based spatial clustering of applications with noise (DBSCAN) algorithm. The robustness of the proposed method is validated under conditions of noise interference and serious inconsistency. Furthermore, the effectiveness of the proposed method is verified under different short-circuit degree with 1, 5 and 10 Ω short-circuit resistors, and the accuracy of short-circuit fault diagnosis can reach 92.17% in the case of a 10 Ω short-circuit resistor. By comparative analysis, the results show that the proposed diagnosis method can effectively detect and locate short-circuit batteries, and the more severe the fault, the shorter the diagnosis time required.

Keywords: battery short-circuit fault diagnosis; relative entropy; correlation coefficient; DBSCAN

收稿日期: 2023-03-10 Received Date: 2023-03-10

* 基金项目: 国家自然科学基金(52272388)、中国博士后科学基金面上项目(2021M693766)、重庆市自然科学基金面上项目(cstc2021jcyj-msxmX0503)资助

0 引言

在全球气候变暖和实现 2030 年“碳达峰”与 2060 年“碳中和”目标的背景下,以电化学储能为代表的新型储能电池迎来了大规模发展,成为新能源领域的重要支撑。作为当前新能源领域典型的储能器件,锂离子电池被认为是最具前景的一类电池。锂离子电池因具有能量密度高、循环寿命长、无记忆效应等优点,在电子设备、新能源动力汽车、工程动力、通信、电动船舶、家用储能、电力储能等领域得到了广泛应用^[1-2]。然而,随着锂离子电池在各个领域的广泛普及,其带来的安全问题和安全隐患也日益突出。近年来,由锂离子电池引发的起火、爆炸等安全事故频发,对人们的生命、财产安全造成了巨大威胁。

引发锂离子电池出现安全问题的原因有电池自然老化和电池滥用,其中电池滥用是引发电池安全事故的主要因素。电池滥用会导致电池系统发生各种故障,加速电池退化,严重时会导致电池热失控。热失控是由于电池出现放热连锁反应引起电池温升速率急剧变化的过热现象^[3-4]。单个电池发生热失控后,若不及时处理,高温会引发相邻电池发生热失控,形成链式反应,从而造成整个电池组的热失控^[5]。触发电池热失控的主要原因是电池内部短路,根据短路电阻或短路电流大小可将短路分为微短路和严重短路^[6]。从发生微短路到出现热失控会经历一个很长的过程,而发生严重短路或短路后期,短路电阻只有毫欧大小,会立即导致热失控事故,检测结果将毫无意义。因此,如果在微短路或短路的早期阶段,如短路电阻在 $100/10/1\ \Omega$,其发热量低,有反应时间应对发生的事故能对电池短路故障进行诊断和安全性预警,将有利于减少电池热失控的发生,从而降低由锂离子电池引发的安全事故^[7-8]。

对电池系统进行故障诊断是电池管理系统(battery management systems, BMS)的核心功能之一,通过 BMS 采集的电池电压、电流和温度等信息可以对电池系统进行诊断。常用的电池故障诊断方法有 2 种:基于模型的方法和基于非模型的方法。

基于模型的方法需要辨识电池模型参数。通过估计模型的输出与实际测量值形成残差,该残差通常是电压、温度、SOC(state of charge, SOC)或容量的残差,以残差作为故障信号根据一定评估规则进行故障隔离与定位^[9-11]。例如文献[12]提出了一种基于模型的多故障诊断方法,对电池组的传感器故障、连接故障和短路故障进行诊断,该方法在模型残差评估部分利用累积和和样本熵来区别短路和连接故障。但是基于模型的方法对于不同型号的电池需要辨识不同的电池模型参数,且如果阈值设定不合适可能会导致误诊或漏诊的情况。此外,基

于单个电池的模型用于电池组故障诊断中具有较大的不确定性。

基于数据驱动的方法是根据传感器采集的数据进行统计分析,或建立机器学习模型进行故障分类。根据电池发生故障时的信息熵或者相关系数与正常运行时的明显变化,可利用信息熵或相关系数的方法进行故障诊断^[13-15]。例如文献[16]提出了一种基于交叉电压测量和统计学分析的方法,将单个电池的电压反映在两个电压表上,通过相关系数分析电池组电压传感器故障、连接故障和短路故障。基于机器学习的方法需要大量电池数据作为训练样本,且在不同型号电池上需要训练不同诊断模型。例如文献[17-18]利用处理后的电压数据进行聚类分析,从而得到异常电池单元。文献[19]采用随机森林分类器实时检测电池内部短路,该方法通过机械滥用诱导内部短路,通过在电池端口上加外部电阻,生成包含和不包含短路故障的训练特征集。当前这些基于信息熵和统计分析的故障诊断方法容易受到噪声和不一致性的干扰,而基于机器学习的故障分类方法对数据的质量和数量要求较高,且泛化能力差。

本研究针对目前锂离子电池系统短路故障诊断方法存在的问题,提出了一种将统计分析与密度聚类相结合的短路故障诊断方法。该方法的核心思想是,首先通过基于核密度估计(kernel density estimation, KDE)的相对熵和相关系数,从电池组的测量电压和温度数据中提取故障信息;然后使用 DBSCAN 算法进行聚类分析,自动识别短路电池。最后通过仿真实验验证了该方法的诊断效率和鲁棒性。本文提出的方法优点在于:1)可以直接根据传感器测量的电压和温度值实时提取信息和聚类分析,无需大量故障数据训练模型和设置故障检测阈值;2)结合相对熵及相关系数的故障信息提取,提高了诊断方法在存在干扰和电池组不一致性条件下的能力;3)提出的诊断方法具有轻量化的特点,具有在线部署的潜力,只需微调诊断方法的参数即可适用于不同运行环境。

1 电池组短路故障诊断方法

相对熵和相关系数方法在故障检测中被广泛使用,在提取数据信息方面具有良好的效果。由于电池组具有不一致性,传统基于相对熵的诊断方法(采用直方图估计的频率分布)容易出现误诊断,而相关系数能够较好的提取故障信息。但是,在测量噪声影响下,相关系数无法准确提取电池组的故障信息。因此,本文提出一种改进的相对熵(核密度估计的频率分布)方法来减小提取故障信息的干扰,同时结合相关系数进一步挖掘电池组的故障信息。此外,为了提高诊断效率,采用参考电池的方式来计算相对熵和相关系数。最后,为了避免故障阈值设

置过大或过小引起的问题,本文采用一种基于聚类的方法来自动识别和定位短路电池。

1.1 电池组故障信息提取

1) 电池组相对熵

相对熵在信息论和数据挖掘领域中已经得到了广泛的应用,相对熵(Kullback-Leibler, KL)散度是一种衡量两个概率分布之间差异的方法^[20]。对于离散随机变量 $X = (x_1, x_2, \dots, x_n)$, 它的两个概率分布为 $P(x)$ 和 $Q(x)$, 满足:

$$\sum P(x) = 1, \sum Q(x) = 1 \quad (1)$$

相对熵的计算公式如式(2)所示,其中 RE 表示概率分布 P 对 Q 的相对熵,相对熵越大,两个概率分布之间的相似性越低。而当两个分布完全相同时,则 RE 等于 0。

$$RE(P \parallel Q) = \sum P(x) \log \frac{P(x)}{Q(x)} \quad (2)$$

为了在电池组中实时计算各电池的电压或温度相对熵,采用基于滑动窗口的遗忘机制来达到获取每个采样时刻的相对熵。以电池组电压为例,在时间 $t_1 \sim t_2$ 内的电池组电压为:

$$U = \begin{bmatrix} u_1^1 & u_2^1 & \cdots & u_n^1 \\ u_1^2 & u_2^2 & \cdots & u_n^2 \\ \vdots & \vdots & & \vdots \\ u_1^m & u_2^m & \cdots & u_n^m \end{bmatrix} \quad (3)$$

其中, n 表示电池组电池个数, m 为滑动窗口时间内电压数据个数。 u_i^j 是第 i 个电池在滑动窗口时间内第 j 个电压数据。可以得到矩阵的最大值 U_{\max} 和最小值 U_{\min} 。

为了计算频率矩阵,首先定义次数矩阵 C :

$$C = \begin{bmatrix} c_{1,1} & c_{1,2} & \cdots & c_{1,n} \\ c_{2,1} & c_{2,2} & \cdots & c_{2,n} \\ \vdots & \vdots & & \vdots \\ c_{k,1} & c_{k,2} & \cdots & c_{k,n} \end{bmatrix} \quad (4)$$

其中, k 表示划分的区间个数。需要说明的是, k 值会影响计算结果的大小但基本不会影响相对熵的变化趋势,本文选择 k 值为 10。 $c_{x,i}$ 表示在 $t_1 \sim t_2$ 时间内,电池 i 的电压在区间 $(U_{\min} + (x-1) \frac{U_{\max} - U_{\min}}{k}, U_{\min} + x \frac{U_{\max} - U_{\min}}{k})$ 的次数,其中 $x = 1, 2, \dots, k$ 。至此可以得到频率矩阵 P :

$$P = \begin{bmatrix} p_{1,1} & p_{1,2} & \cdots & p_{1,n} \\ p_{2,1} & p_{2,2} & \cdots & p_{2,n} \\ \vdots & \vdots & & \vdots \\ p_{k,1} & p_{k,2} & \cdots & p_{k,n} \end{bmatrix}, p_{x,i} = \frac{c_{x,i}}{\sum_{x=1}^k c_{x,i}} \quad (5)$$

矩阵 P 是通过平均划分区间来求频率分布,其计算量小但在实际测试中的抗干扰能力有着较大缺陷,因此改进为 KDE 方式计算概率分布,通常核函数选择高斯核函数有着较好的效果。考虑到相对熵的非负性,在确保概率分布之和为 1 的同时,其具体的 KDE 估计如下式:

$$f_h(x) = \frac{1}{N\sqrt{2\pi}h^2} \sum_{i=1}^N e^{-\frac{(x-x_i)^2}{2h^2}}, x \in R \quad (6)$$

式中: N 是数据点个数, h 表示带宽。

2) 电池组相关系数

在电池组故障诊断中,相关系数可以用于分析电池单体之间的相关性,进而判断电池单体的健康状况。常见的相关系数分析方法包括如下几种:

(1) 单体电压相关性分析:通过计算电池组中各个单体之间的电压相关系数,可以判断电池单体之间的电压偏差是否存在异常。如果单体之间的电压相关性较差,可能意味着电池单体之间存在电压异常或接触不良等问题。

(2) 单体温度相关性分析:通过计算电池组中各个单体之间的温度相关系数,可以判断电池单体之间的温度偏差是否存在异常。如果单体之间的温度相关性较差,可能意味着电池单体之间存在温度异常或传感器故障等问题。

(3) 电压和温度相关性分析:分别计算电池组中各个单体之间电压的相关系数和温度的相关系数,可以综合分析电池单体的健康状况。如果两种相关系数较差,可能意味着电池单体短路故障。

考虑到斯皮尔曼秩相关系数(Spearman)不需要数据满足正态分布或线性关系等条件,因此适用于各种类型的数据集。此外,它还不受变量的度量尺度(连续或离散)的限制,而且在处理异常值方面相对较为稳健。本文使用 Spearman 相关系数作为故障信息提取的一种方法。对于两个变量 $X = [X_1, \dots, X_n]$ 和 $Y = [Y_1, \dots, Y_n]$ 其计算公式可表示为:

$$\rho_{\text{spearman}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (7)$$

式中: x_i 和 y_i 代表 X 和 Y 排序后的元素 \bar{x} 和 \bar{y} 分别对应其均值。

为了减小计算量,避免整个电池组中单体电池相互计算相对熵或相关系数,本文选取测量电压为中值的电池作为参考电池。这个电池能够代表整个电池组的运行状况。因此根据滑动窗口,可以得到每一时刻的电池组故障信息,表示为:

$$D_1 = [re_{1,mean} \quad \cdots \quad re_{n,mean}]^T \quad (8)$$

$$D_2 = [\rho_{1,mean} \cdots \rho_{n,mean}]^T \tag{9}$$

1.2 基于 DBSCAN 的电池组短路诊断策略

通过以上方法提取电池组电压和温度的相对熵和相关系数,传统的方法是通过提前设定阈值来判断电池故障。但由于不同电池、不同老化状态、工况以及温度等条件的影响,导致判断方式会存在误报或漏报的情况。因此本文采用 DBSCAN 算法对电池进行自动检测和故障定位。DBSCAN 算法是一种基于密度的空间聚类算法,该方法可以根据数据点之间的距离对具有相似特征的数据集进行分类,而不需要预先确定类别。目前该算法已经成功应用于锂离子电池故障诊断中^[17-18]。本文采用 DBSCAN 算法,设置好 DBSCAN 算法的两个重要参数(邻域半径 *eps* 和最小样本点 *minPts*)完成短路电池自动识别。对于给定样本集 *D*,DBSCAN 的进行短路检测的实现过程可以归纳为算法 1。DBSCAN 的核心思想是:从任意核心对象出发,计算所有从该对象密度可达的样本,将其作为同一类,直到所有样本均被计算,从而得到聚类结果。在异常检测的聚类结果中,通常会得到两类,即正常点集合和异常点集合,对应本文故障诊断中的正常和短路类型。需要注意的时,DBSCAN 算法的计算量取决于输入数据的规模和算法参数的设置。对于每个数据

点,需要计算其邻域中的所有点,这意味着算法的时间复杂度至少为 $O(n^2)$ 。然而,在实践中,由于 DBSCAN 算法可以跳过噪声点,因此算法的实际复杂度通常比 $O(n^2)$ 低。对于不同电池组来说其单体电池数量不同,可通过适当调整算法的参数来减小计算时间,从而达到实时诊断的目的。

算法 1 DBSCAN 聚类分析流程

输入:数据集 *D*,半径参数 *eps*,最小样本数 *minPts*

1. 初始化标记数组 *visited_points*(所有点都未被访问过的状态);
2. 初始化聚类计数器 *cluster_id*;
3. 在数据集 *D* 中对每个未被访问的点 *p* 执行以下操作:
 - a. 将 *p* 标记为 *visited*;
 - b. 找到 *p* 的 *eps* 邻域内的所有点集合 *N*;
 - c. 如果 *N* 的大小小于 *minPts*,则将 *p* 标记为噪声点。否则,创建新的类 *C*,将 *p* 加入 *C* 中,并将所有在 *N* 中的点加入 *C* 中;
 - d. 递归地遍历 *N* 中的每个点,将其加入 *C* 中,并将其标记为 *visited*;
 - e. 设置聚类 *C* 的标识符,增加 *cluster_id* 的值;
4. 输出所有被标记为噪声点的数据点。

在本文提出的诊断方法中,首先根据相对熵和相关系数提取故障信息,然后采用 DBSCAN 算法识别短路电池,诊断流程如图 1 所示。

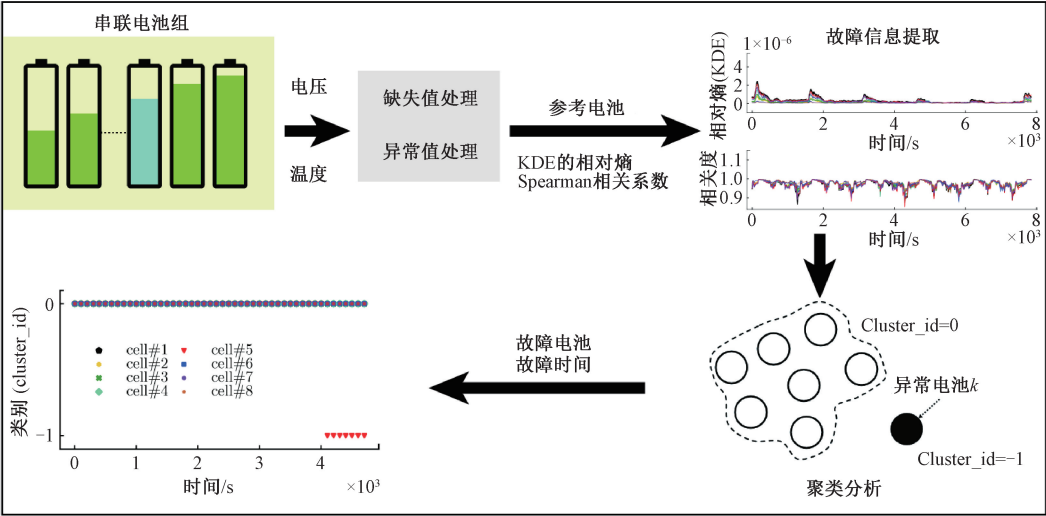


图 1 短路故障诊断的框架图

Fig. 1 Frame diagram of short-circuit fault diagnosis

2 仿真测试

2.1 仿真平台

实验平台为计算机(i5-10400, RX560, Windows11), 本文采用 AutoLion-ST 软件和 Simulink 进行仿真,前者用于锂离子电池的电化学热耦合计算,后者用于电池离子

组的短路模拟以及数据的采集。测试中所用锂离子电池的结构和性能参数列于表 1。有关 AutoLion-ST 电化学模型的参数可参考文献[12,21-24],模型的准确性已通过实验得到了验证。

图 2 展示了在环境温度 25 ℃(298.15 K),负载工况为 FUDS(federal urban driving schedule)下 8 个电池单体串联时的充放电仿真过程。本文仿真中的电池组不一致性设置为 3%。为了模拟真实环境,在电压和温度测量

表 1 三元锂离子电池参数

| 参数 | 值 |
|----------|-----------------|
| 正极材料 | 三元锂离子电池(NCM111) |
| 负极材料 | 石墨 |
| 直径×高度/mm | 18.6×65.2 |
| 重量/g | 43.39 |
| 额定容量/Ah | 2.15@1C |
| 额定电压/V | 3.65 |
| 充电截至电压/V | 4.2 |
| 放电截止电压/V | 2.5 |

数据上分别添加标准差为 3 mV 和 0.03 ℃ 的高斯白噪声。此外为了对提出的短路诊断方法进行验证,本文基于该仿真平台分别进行 1、5 和 10 Ω 的短路测试,短路电池的编号为 5 号,3 种短路情况均在 4 000 s 时触发。所有测试环境均为 25 ℃,采样时间为 1 s。

2.2 滑动窗口影响

故障诊断的效果需要综合准确性和效率进行考虑,其中滑动窗口大小对提出的方法影响较大。以正常运行时电池 5 为例,图 3 是不同窗口大小计算得到的最大相

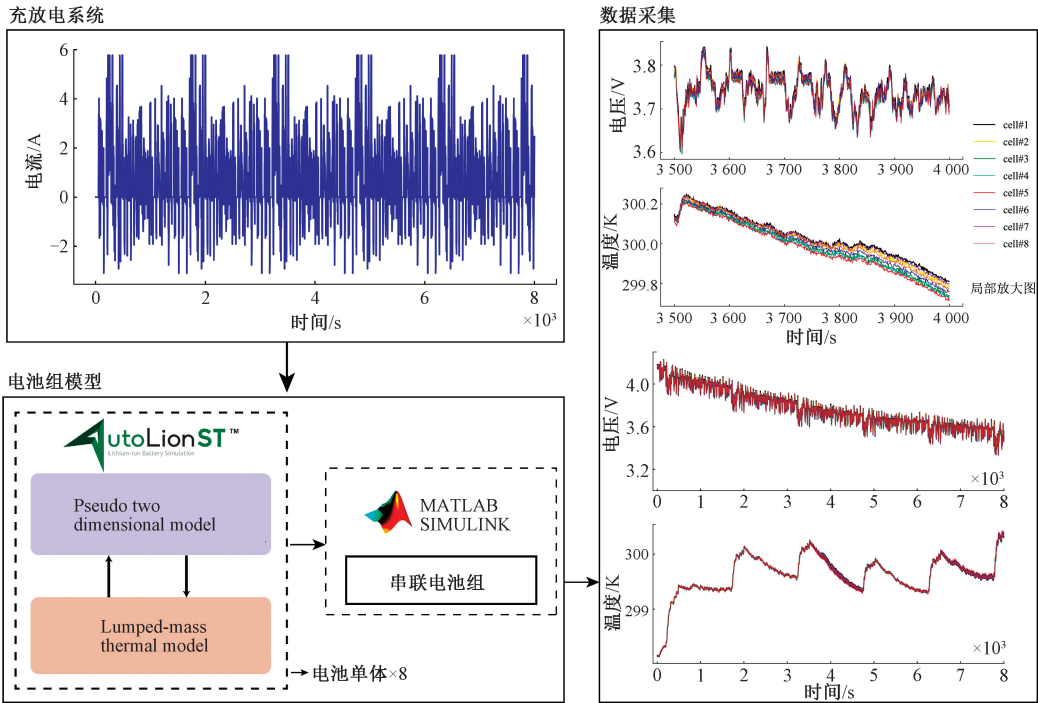


图 2 电池仿真测试平台示意图

Fig. 2 Schematic diagram of battery simulation test platform

对熵值 ReRE_MAX, 以及每一步计算所消耗的时间 Time。滑动窗口过小会造成信息波动过大,不利于信息的提取,而窗口过大会造成较大的资源浪费。对于相关系数的滑动窗口选择也是作类似的选择,通过试验试错本文选择滑动窗口长度为 150。

此外,eps 和 minPts 参数的选择需要根据具体的数据集来确定。当 eps 取值过小时,很多数据点可能会被认为是噪声点而被排除在聚类之外,即容易造成误诊;而当 eps 取值过大时,则会将很多不相关的数据点合并到同一簇中,导致聚类效果不佳,即容易造成漏诊。而 minPts 也具有类似的影响,因此,本文是基于正常电池与短路电池在提取故障信息(相对熵和相关系数)后的最大距离进行选择,本文分别取 eps = 0.5, minPts = 4。




图 3 滑动窗口对相对熵和计算时间的影响

Fig. 3 Influence of sliding window on relative entropy and calculation time

3 故障诊断结果

3.1 鲁棒性分析

本节分析了相对熵和相关系数在不同情形下的提取故障信息的效果,下面以电压为例分析相对熵和相关系数。图 4 为正常运行时对电池 5 施加干扰时绘制的曲线,其中噪声在 2 500 s 时加入,持续 500 s。可以看出由 KDE 估计的相对熵在干扰下的波动和由原始不一致性造成的波动区别很小,而普通相对熵在整个时间段的波

动剧烈。由相关系数计算得到故障信息非常容易受到噪声的干扰,表现出相关度大幅下降。

当电池组的不一致性提升到 6% 后,无故障时绘制的 3 种曲线如图 4 所示。两种相对熵都对电池组不一致性敏感,其值出现了较大的变化,而相关系数在整体上可以看出对不一致性具有较好的抑制作用。因此本文最终选择 KDE 估计的相对熵和相关系数提取电池组的故障信息,以此作为聚类分析的特征输入。需要说明的是,电池组在实际使用时的不一致性通常不会过大,当一致性成为电池组故障问题时,需要由 BMS 的均衡进行管理。

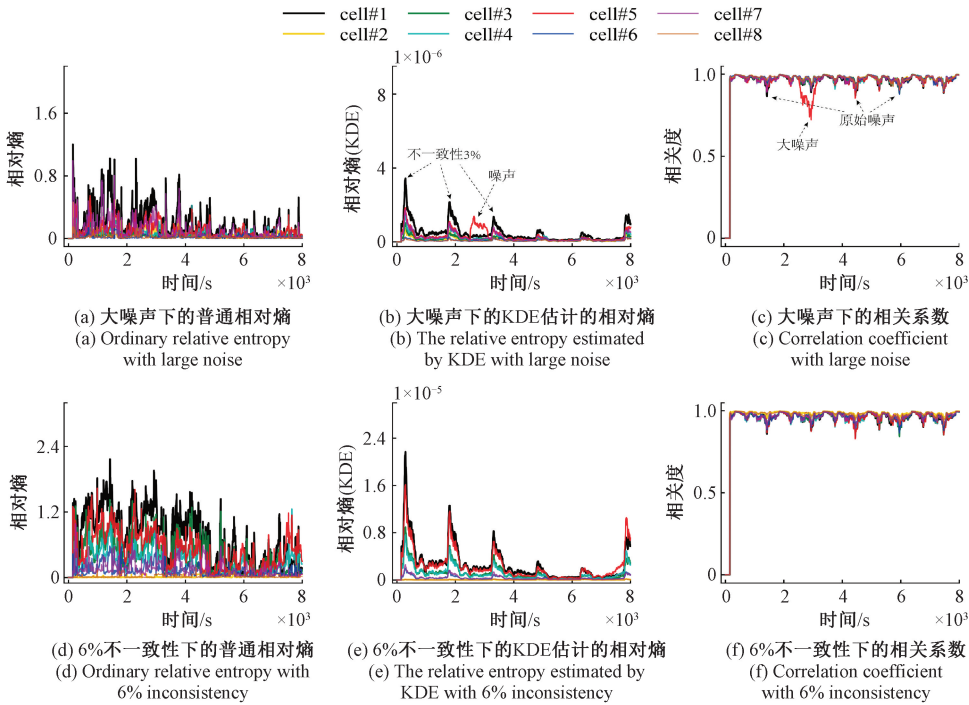


图 4 噪声和不一致性对相对熵和相关系数的影响

Fig. 4 Influence of noise and inconsistency on relative entropy and correlation coefficient

图 5 是在加入噪声后短路时的聚类结果图,提出的方法在 2 500~3 000 s 并未将电池 5 误诊为短路电池。而在 4 000 s 时并联电阻后,提出的方法在短路后 211 s 检测到电池 5 发生短路。当有持续的噪声干扰时,通过对诊断方法的微调(例如 ϵ_{ps} 、 $\min Pts$ 以及判定规则)可以将持续大的干扰检测为传感器异常。

3.2 不同程度短路诊断结果

图 6 是 1 Ω 短路时的串联电池组的各电池电压和温度曲线,以及通过相对熵和相关系数提取的故障信息。图 7 是每个采样点的聚类结果。可以看出对于 1 Ω 短路而言,电池的电压和温度变化明显,对于多数方法能够有效检测。在不一致性和噪声干扰下,基于 KDE 的相对熵能够在 10 s 内捕捉到电池 5 的故障特性。而温度的相对熵需要较长时间检测,这是因为电池的热特性不具有和




图 5 噪声下短路 5 Ω 的诊断结果

Fig. 5 Diagnosis results of short circuit 5 Ω under noise

电压一样的瞬时变化,但后续能够以较大的值区分其他电池。相关系数与相对熵在电压和温度方面具有类似的现象,即检测到短路时温度的变化总是要比电压慢。综合聚类分析结果,提出的诊断方法能够快速定位短路电

池。图 8 是短路 10 Ω 的故障信息提取结果,图 9 是聚类分析结果。从图中可以看到,由于短路相对较轻,电池的短路故障特征在前期并不明显,仅仅根据相关系数和阈

值的方式很容易造成漏诊和误诊。这是由于在短路前期,测量噪声和不一致性的干扰容易掩盖短路时的电压和温度。

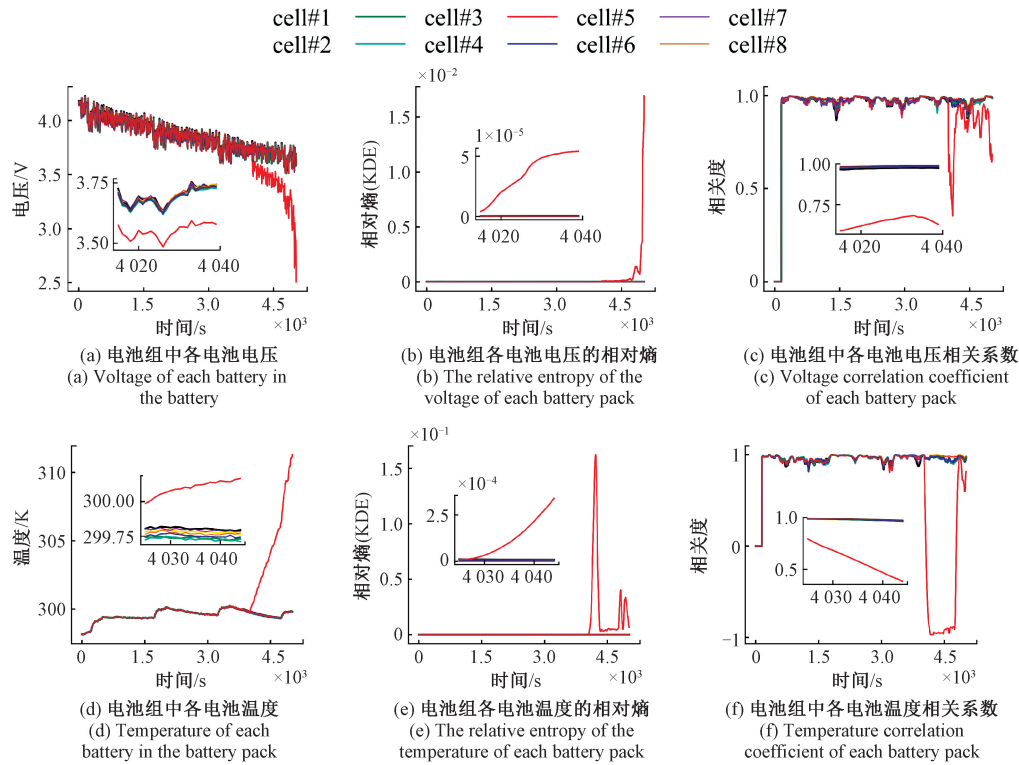


图 6 1 Ω 短路时电压和温度故障信息提取结果

Fig. 6 Extraction results of voltage and temperature fault information in 1 Ω short circuit




图 7 1 Ω 短路时的聚类结果

Fig. 7 Clustering results of 1 Ω short circuit

表 2 是 3 种故障的检测结果,提出的方法均能够有效定位短路电池。表中 T_d 表示故障发生到检测到的时间, Δt 表示检测方法在每个采样点间消耗的计算时间。可以看到,短路程度越深其检测时间越短,从电压和温度的故障信息提取能看出相对熵和相关系数可以将这种信息不同程度的放大。此外,提出的方法在所使用的平台上的计算时间基本保持在 0.055 s,均小于采样时间,说明本文提出的方法具有在线应用的潜力。

3.3 对比分析结果

对于短路故障诊断,可以将其看作二分类问题,即正

表 2 3 种短路情况下的诊断结果

Table 2 Diagnostic results under three short-circuit conditions

| 短路阻值/Ω | 定位故障电池 | T_d/s | $\Delta t/s$ |
|--------|-----------|---------|--------------|
| 1 | 是(Cell5) | 36 | 0.053 2 |
| 5 | 是(Cell5) | 211 | 0.056 2 |
| 10 | 是(Cell5) | 552 | 0.055 3 |

常和故障两类,本文引入混淆矩阵如表 3 所示。为了对比不同方法的效果,选用准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F1score 作为对比指标,其计算如下:

$$\left\{ \begin{aligned} Accuracy &= \frac{TP + TN}{TP + TN + FP + FN} \\ Precision &= \frac{TP}{TP + FP} \\ Recall &= \frac{TP}{TP + FN} \\ F1_{score} &= \frac{2 \times TP}{2 \times TP + FP + FN} \end{aligned} \right. \quad (10)$$

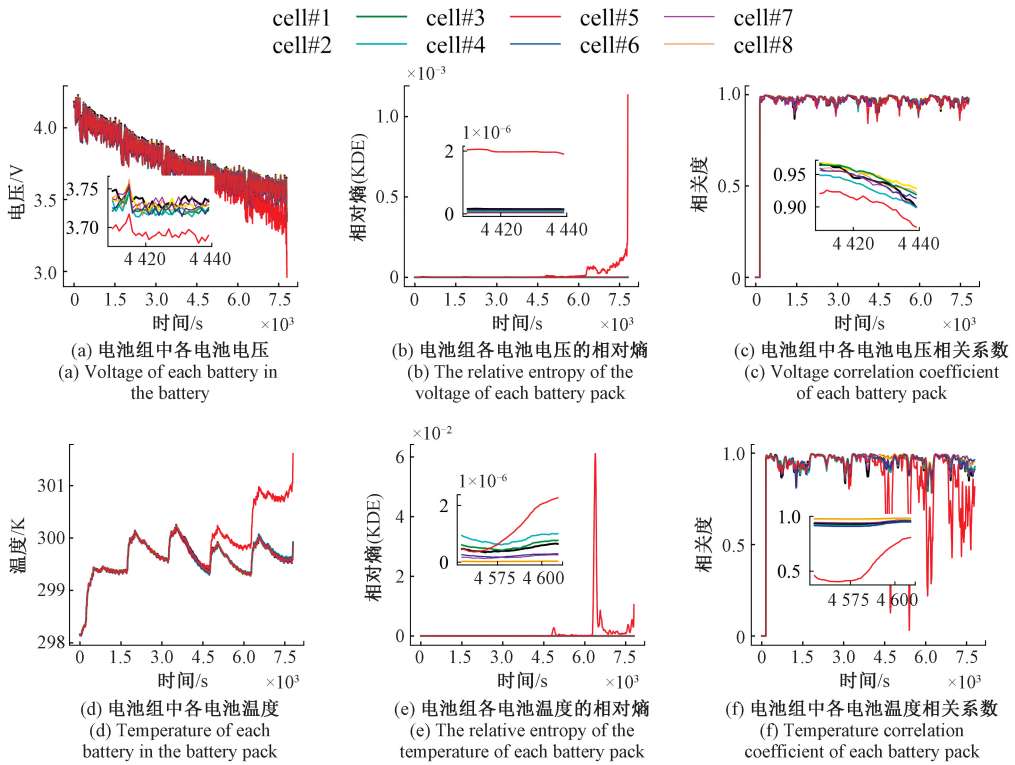


图 8 10 Ω 短路时电压和温度故障信息提取结果

Fig. 8 Extraction results of voltage and temperature fault information in 10 Ω short circuit




图 9 10 Ω 短路时的聚类结果

Fig. 9 Clustering results of 10 Ω short circuit

表 3 混淆矩阵
Table 3 Confusion matrix

| | 预测正类 | 预测反类 |
|------|------|------|
| 真实正类 | TP | FN |
| 真实反类 | FP | TN |

熵、相关系数和 DBSCAN 是目前短路故障诊断中常用的基于非模型的故障诊断方法^[14, 17-18, 25-27], 而基于参数或状态估计得到残差, 然后根据残差阈值进行故障诊断是基于模型的常用方法。为了突出聚类方法在避免诊断时设置阈值问题的优势, 采用基于模型残差的方法进行对比。在 3.1 节已经分析了 KDE 方法相比传统方法的相对熵, 在抗干扰上的优势, 本小节对比了仅采用 KDE

的相对熵进行诊断的结果。为了体现本文提出的方法中两种故障信息提取的优势, 还对比了直接根据测量电压和温度进行诊断的结果。在相同工况短路下与 3 种方法进行了对比, 表 4 是 3 种短路情况下的不同方法的检测结果, 可以看出对比的 3 种方法在电池组正常运行期间均未出现误报, 即召回率为 1。表中 ReRE+CC+DBSCAN 表示本文提出的方法, 利用相对熵和相关系数提取故障信息, 然后采用 DBSCAN 判断故障电池。V+T+DBSCAN 表示直接使用原始数据进行聚类分析的结果, 可以看到其计算时间更少。从结果可以看出只有在 1 Ω 短路时其效果稍好于本文的方法, 当短路阻值增大时, 其性能出现明显下降。这是因为 1 Ω 时, 电压和温度会出现剧烈变化, 而短路电阻减小, 仅仅依靠测量值难以及时发现故障信息, 例如在 10 Ω 短路后的 300 s 内, 电池组的最小电压和温度与中值的差值仅为 0.032 V 和 0.034 ℃。


ShannonRE (KDE) 表示通过核密度估计概率分布改进香农熵的诊断方法, 香农熵如式 (11) 所示。在确保式中概率分布之和为 1 时, 其概率分布由式 (6) 计算得到。图 10 是在 5 Ω 短路下的电池组电压和温度的香农熵。通过电压的香农熵检测, 在电池组充放电前期时短路的效果并不明显, 只有当短路持续到 SOC 值较小时, 这种故障信息才能被较好检测到。因此通过香农熵来检测短路故障效果并不好, 且随着短路阻值增大, 诊断效果逐渐变差。

表 4 3 种短路情况下各种方法的对比结果


Table 4 Comparison results of different methods under three short-circuit conditions

| 短路阻值/ Ω | 诊断方法 | T_d/s | $\Delta t/s$ | Accuracy | Precision | Recall | $F1_{score}$ |
|----------------|-----------------|---------|--------------|----------|-----------|--------|--------------|
| 1 | ReRE+CC+DBSCAN | 36 | 0.053 2 | 0.992 8 | 0.991 1 | 1 | 0.995 5 |
| | V+T+DBSCAN | 33 | 0.003 6 | 0.993 4 | 0.991 8 | 1 | 0.995 9 |
| | ShannonRE(KDE) | 60 | 0.029 7 | 0.988 1 | 0.985 2 | 1 | 0.992 6 |
| | FFRLS-EKF | 98 | 0.000 4 | 0.980 5 | 0.976 1 | 1 | 0.987 9 |
| 5 | Re+CC+DBSCAN | 211 | 0.056 2 | 0.970 1 | 0.949 9 | 1 | 0.974 3 |
| | V+T+DBSCAN | 654 | 0.003 8 | 0.906 1 | 0.858 0 | 1 | 0.923 5 |
| | ShannonRE(KDE) | 778 | 0.029 8 | 0.889 7 | 0.837 2 | 1 | 0.911 4 |
| | FFRLS-EKF | 710 | 0.000 4 | 0.899 3 | 0.849 3 | 1 | 0.918 5 |
| 10 | Re+CC+DBSCAN | 552 | 0.055 3 | 0.921 7 | 0.878 7 | 1 | 0.935 5 |
| | V+T+DBSCAN | 1030 | 0.003 8 | 0.852 5 | 0.776 7 | 1 | 0.874 3 |
| | ShannonRE(KDE) | 2287 | 0.029 0 | 0.706 8 | 0.636 2 | 1 | 0.777 7 |
| | FFRLS-EKF | 1143 | 0.000 4 | 0.853 5 | 0.777 8 | 1 | 0.875 0 |

$$ShannonRE(X) = - \sum_i^n p(x_i) \log p(x_i) \tag{11}$$



(a) 5 Ω 短路下的电压香农熵
(a) Shannon entropy of voltage under 5 Ω short circuit



(b) 5 Ω 短路下的温度香农熵
(b) Shannon entropy of temperature under 5 Ω short circuit

图 10 KDE 估计的香农熵

Fig. 10 Shannon entropy estimated by KDE

FFRLS-EKF 是基于模型的故障诊断方法。本文使用带遗忘因子的最小二乘法辨识参考电池的二阶等效电路模型参数作为单体电池模型的参数。通过扩展卡尔曼滤波实时估计各电池电压,并通过与测量值的残差来判断是否发生故障。需要说明的是,实际中检测短路故障通常需要与温度结合进行判断。电池模型的 OCV-SOC 特性曲线通过 12 阶多项式拟合,系数列于表 5,拟合误差为 0.002。图 11 是 5 Ω 短路下的单体电池 SOC 估计和

端电压的残差。通过表 4 可以看出这种方法在计算时间上非常有优势,但故障诊断准确性并不高。综合对比分析,本文提出的方法在 3 种短路情况下均有较好的效果,且随着短路阻值的增加,在检测时间和准确性上更具有优势。

表 5 OCV-SOC 曲线 12 阶多项式拟合系数

Table 5 Fitting coefficient of 12th-order polynomial of OCV-SOC curve

| 参数 | 值 |
|-----|--------------------------|
| a1 | $-3.185\ 78 \times 10^4$ |
| a2 | $2.027\ 288 \times 10^5$ |
| a3 | $-5.707\ 54 \times 10^5$ |
| a4 | $9.364\ 46 \times 10^5$ |
| a5 | $-9.928\ 71 \times 10^5$ |
| a6 | $7.130\ 11 \times 10^5$ |
| a7 | $-3.534\ 65 \times 10^5$ |
| a8 | $1.209\ 55 \times 10^5$ |
| a9 | $-2.806\ 86 \times 10^4$ |
| a10 | $4.248\ 67 \times 10^3$ |
| a11 | $3.926\ 54 \times 10^2$ |
| a12 | $2.071\ 05 \times 10^1$ |
| a13 | 2.936 27 |

4 结 论

本文提出了一种基于统计分析和密度聚类的电池组短路故障诊断方法。该方法通过遗忘机制,在电池组的电压和温度中计算核密度估计的相对熵和相关系数,并将其作为故障特征信息。然后采用基于密度的空间聚类算法(DBSCAN)自动识别短路故障电池。通过仿真实验对比分析,该方法具有较高的鲁棒性和准确性。在阻值较大的短路情况下具有更高的准确率。该方法不需要大量故障数据训练模型和设置故障检测阈值,具有轻量化

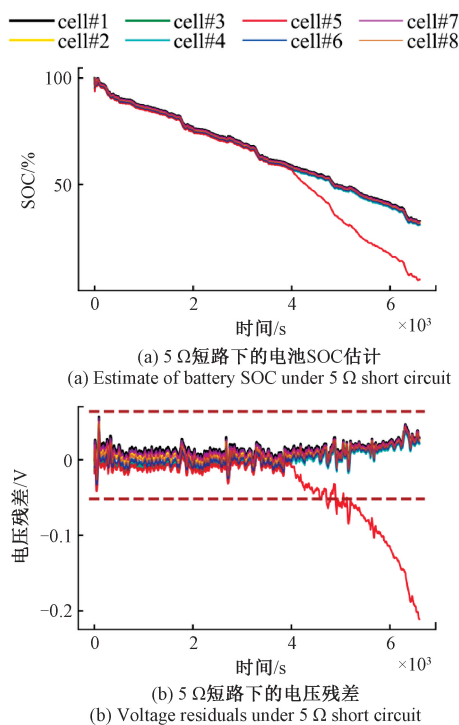


图 11 FFRLS-EKF 估计的结果

Fig. 11 Results of FFRLS-EKF estimation

的特点,具有在线部署的潜力,只需微调诊断方法的参数即可适应不同环境。综上所述,本文提出的短路故障诊断方法具有实际应用的潜力,可以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。将来会在更大电池数量上改进提出的方法,并在实车上验证并完善本文提出的方法。

参考文献

- [1] 骆凡,黄海宏,王海欣. 基于电化学阻抗谱的退役动力电池荷电状态和健康状态快速预测[J]. 仪器仪表学报, 2021, 42(9): 172-180.
LUO F, HUANG H H, WANG H X. Rapid prediction of the state of charge and state of health of decommissioned power batteries based on electrochemical impedance spectroscopy [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 172-180.
- [2] 高峰,贾建芳,元淑芳,等. 基于 GRU-UKF 的锂离子电池 SOC 估计方法研究[J]. 电子测量与仪器学报, 2022, 36(11): 160-169.
GAO F, JIA J F, YU S H F, et al. Research on SOC estimation method of lithium-ion battery based on GRU-UKF [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 160-169.
- [3] CHEN Y Q, KANG Y Q, ZHAO Y, et al. A review of lithium-ion battery safety concerns: The issues,

- strategies, and testing standards [J]. Journal of Energy Chemistry, 2021, 59: 83-99.
- [4] 冯旭宁. 车用锂离子动力电池热失控诱发与扩展机理、建模与防控[D]. 北京: 清华大学, 2016.
FENG X N. Thermal runaway induction and expansion mechanism, modeling and prevention and control of vehicle lithium-ion power battery [D]. Beijing: Tsinghua University, 2016.
- [5] 孙振宇, 王震坡, 刘鹏, 等. 新能源汽车动力电池系统故障诊断研究综述[J]. 机械工程学报, 2021, 57(14): 87-104.
SUN ZH Y, WANG ZH P, LIU P, et al. Review of fault diagnosis research of new energy vehicle power battery system [J]. Journal of Mechanical Engineering, 2021, 57(14): 87-104.
- [6] SEO M, PARK M, SONG Y, et al. Online detection of soft internal short circuit in lithium-ion batteries at various standard charging ranges [J]. IEEE Access, 2020, 8: 70947-70959.
- [7] OUYANG M G, ZHANG M X, FENG X N, et al. Internal short circuit detection for battery pack using equivalent parameter and consistency method [J]. Journal of Power Sources, 2015, 294: 272-283.
- [8] ZHENG Y J, SHEN A Q, HAN X B, et al. Quantitative short circuit identification for single lithium-ion cell applications based on charge and discharge capacity estimation [J]. Journal of Power Sources, 2022, 517: 230716.
- [9] LIN T T, CHEN Z Q, ZHENG C W, et al. Fault diagnosis of lithium-ion battery pack based on hybrid system and dual extended Kalman filter algorithm [J]. IEEE Transactions on Transportation Electrification, 2020, 7(1): 26-36.
- [10] XIONG R, YU Q Q, SHEN W X, et al. A sensor fault diagnosis method for a lithium-ion battery pack in electric vehicles [J]. IEEE Transactions on Power Electronics, 2019, 34(10): 9709-9718.
- [11] WEI J W, DONG G Z, CHEN Z H. Lyapunov-based thermal fault diagnosis of cylindrical lithium-ion batteries [J]. IEEE Transactions on Industrial Electronics, 2020, 67(6): 4670-4679.
- [12] ZHANG K, HU X S, LIU Y G, et al. Multi-fault detection and isolation for lithium-ion battery systems [J]. IEEE Transactions on Power Electronics, 2022, 37(1): 971-989.
- [13] ZHANG X Y, HONG J C, XU X M. Fault diagnosis of real-scenario battery systems based on modified entropy algorithms in electric vehicles [J]. Journal of Energy

- Storage, 2023, 63: 107079.
- [14] QIU Y H, CAO W J, PENG P, et al. A novel entropy-based fault diagnosis and inconsistency evaluation approach for lithium-ion battery energy storage systems[J]. Journal of Energy Storage, 2021, 41: 102852.
- [15] SHANG Y L, LU G P, KANG Y Z, et al. A multi-fault diagnosis method based on modified sample entropy for lithium-ion battery strings[J]. Journal of Power Sources, 2020, 446: 227275.
- [16] KANG Y Z, DUAN B, ZHOU Z K, et al. A multi-fault diagnostic method based on an interleaved voltage measurement topology for series connected battery packs[J]. Journal of Power Sources, 2019, 417: 132-144.
- [17] LI D, ZHANG Z S, LIU P, et al. DBSCAN-based thermal runaway diagnosis of battery systems for electric vehicles[J]. Energies, 2019, 12(15): 2977.
- [18] QIAO D D, WEI X X, FAN W J, et al. Toward safe carbon-neutral transportation: Battery internal short circuit diagnosis based on cloud data for electric vehicles [J]. Applied Energy, 2022, 317: 119168.
- [19] NAHA A, KHANDELWAL A, AGARWAL S, et al. Internal short circuit detection in Li-ion batteries using supervised machine learning [J] Scientific Reports, 2020, 10(1): 1301.
- [20] SUN Z Y, WANG Z P, CHEN Y, et al. Modified relative entropy-based lithium-ion battery pack online short-circuit detection for electric vehicle [J]. IEEE Transactions on Transportation Electrification, 2022, 8(2): 1710-1723.
- [21] GU W B, WANG C Y. Thermal and electrochemical coupled modeling of a lithium-ion cell[C]. Proceedings of the ECS, 2000, 99: 748-762.
- [22] SRINIVASAN V, WANG C Y. Analysis of electrochemical and thermal behavior of Li-ion cells[J]. Journal of the Electrochemical Society, 2002, 150(1): A98.
- [23] SMITH K, WANG C Y. Power and thermal characterization of a lithium-ion battery pack for hybrid-electric vehicles [J]. Journal of Power Sources, 2006, 160(1): 662-673.
- [24] FANG W, KWON O J, WANG C Y. Electrochemical-thermal modeling of automotive Li-ion batteries and experimental validation using a three-electrode cell[J]. International Journal of Energy Research, 2010, 34(2): 107-115.
- [25] SUN Z Y, WANG Z P, LIU P, et al. Relative entropy based lithium-ion battery pack short circuit detection for electric vehicle [C]. 2020 IEEE Energy Conversion

Congress and Exposition (ECCE). IEEE, 2020: 5061-5067.

- [26] SUN Z Y, HAN Y, WANG Z P, et al. Detection of voltage fault in the battery system of electric vehicles using statistical analysis [J]. Applied Energy, 2022, 307: 118172.
- [27] LIN T T, CHEN Z Q, ZHOU S Y. Voltage-correlation based multi-fault diagnosis of lithium-ion battery packs considering inconsistency [J]. Journal of Cleaner Production, 2022, 336: 130358.


作者简介



范天娥 (通信作者), 2018 年于厦门大学获得博士学位, 现为重庆邮电大学副教授, 硕士研究生导师, 主要研究方向为锂离子电池健康管理系统与故障诊断研究。

E-mail: fante@cqupt.edu.cn

Fan Tian'e (Corresponding author), received her Ph. D. degree from Xiamen University in 2018. Now she is an associate professor and postgraduate supervisor of Chongqing University of Posts and Telecommunications. Her main research interests include lithium battery health management system and fault diagnosis.



唐鑫, 现为重庆邮电大学硕士研究生, 主要研究方向为锂离子电池的故障诊断与故障预测研究。

E-mail: tangx_98@163.com

Tang Xin now is a M. Sc. candidate of Chongqing University of Posts and Telecommunications. His main research interests include fault diagnosis and fault prediction of lithium batteries.



雷浩然, 现为重庆邮电大学硕士研究生, 主要研究方向为锂离子电池的故障诊断与故障预测研究。

E-mail: 1227391860@qq.com

Lei Haoran is now a M. Sc. candidate of Chongqing University of Posts and Telecommunications. His main research interests include fault diagnosis and fault prediction of lithium batteries.



李鹏华, 2012 年于重庆大学获得博士学位, 现为重庆邮电大学教授, 博士生导师, 主要研究方向为锂离子电池健康管理系统与故障诊断研究。

E-mail: liph@cqupt.edu.cn

Li Penghua received his Ph. D. degree from Chongqing University in 2012. Now he is a professor and doctoral supervisor of Chongqing University of Posts and Telecommunications. His main research interests include lithium battery health management system and fault diagnosis.