

DOI: 10.3901/JME.2021.14.141

# 数据驱动的锂离子电池健康状态综合评分 及异常电池筛选\*

贾俊<sup>1</sup> 胡晓松<sup>1</sup> 邓忠伟<sup>1</sup> 徐华池<sup>2</sup> 肖伟<sup>2</sup> 韩锋<sup>3</sup>

(1. 重庆大学汽车工程学院 重庆 400044;

2. 清华四川能源互联网研究院 成都 610213;

3. 重庆长安新能源汽车科技有限公司 重庆 401133)

**摘要:** 锂离子电池是电动汽车和储能系统最重要的组成部分,其故障预测和健康管理对于运行维护至关重要。数据驱动的方法较基于模型的方法更适合大规模工程应用,针对实际应用中工况复杂和数据质量较差的场景,提出数据驱动的健康状态综合评分及异常筛选算法,具有较强的适应性。首先,针对电池实际运行工况提出一种新的特征提取方案,可适用于非恒流的不稳定工况。开发了基于多维特征和混合聚类算法的健康状态综合评分体系,该方案采用无监督学习的算法框架,对可提取特征的数量和质量要求不高,无需进行事先的模型训练和复杂的超参数调整。然后,在麻省理工学院和斯坦福大学提供的公开数据集进行了算法验证,基于电池生命周期各阶段特征集进行健康度等级预测,并应用于健康度高低分选,均能达到92%以上的准确率。在某用户侧储能电站实现了该算法的应用,采用早期运行数据即可快速筛选异常电池,有利于尽早维护,提高电池系统的安全性和经济性。

**关键词:** 锂离子电池;特征提取;健康状态;异常电池筛选;故障预测和健康管理

**中图分类号:** TM912

## Data-driven Comprehensive Evaluation of Lithium-ion Battery State of Health and Abnormal Battery Screening

JIA Jun<sup>1</sup> HU Xiaosong<sup>1</sup> DENG Zhongwei<sup>1</sup> XU Huachi<sup>2</sup> XIAO Wei<sup>2</sup> HAN Feng<sup>3</sup>

(1. Department of Automotive Engineering, Chongqing University, Chongqing 400044;

2. Tsinghua Sichuan Energy Internet Research Institute, Chengdu 610213;

3. Changan New Energy Automobile Technology Co., Ltd., Chongqing 401133)

**Abstract:** Lithium-ion batteries are the most important part of electric vehicles and energy storage systems, and their health management and fault identification are critical to operation and maintenance. The data-driven method is more suitable for large-scale engineering applications than the model-based method. Aiming at scenarios with complex working conditions and poor data quality in practical applications, a data-driven comprehensive evaluation of lithium-ion battery state of health and abnormal battery screening algorithm is proposed. First, a novel feature extraction scheme is proposed for the actual operating conditions of batteries, which can be applied to unstable working conditions with non-constant current. A comprehensive state of health scoring system based on multi-dimensional features and hybrid clustering algorithms is developed. This scheme is an algorithm framework for unsupervised learning, which does not require high quantity and quality of extractable features, without prior model training and complicated hyper parameter adjustment. Then, the algorithm is verified at the public data set of Massachusetts Institute of Technology and Stanford. Based on the feature set of each stage of the battery life cycle, the health level prediction can be achieved, and the accuracy is more

\* 国家自然科学基金(51875054)、重庆市杰出青年科学基金(cstc2019jcyj0010)和重庆市技术创新与应用发展专项重点(cstc2019jscx-mbxdX0029)资助项目。20200614 收到初稿,20210220 收到修改稿

than 92% when applied to classify the health level. Finally, the proposed algorithm is implemented in a user-side energy storage power station. Early operation data can be used to quickly screen abnormal batteries, which is beneficial to early maintenance, and improve the safety and economy of the battery system.

**Key words:** lithium-ion battery; feature extraction; state of health; abnormal battery screening; prognostics and health management

## 0 前言

随着锂离子电池技术的发展,越来越多的电动汽车和储能系统采用锂离子电池,故障预测和健康管理(Prognostics and health management, PHM)对电池系统的运行维护至关重要。从电池管理的角度来讲,故障预测的重点是对导致系统运行欠佳或失效的异常之处进行分析,而健康管理着重于估计当前状态(如容量、内阻)与初始状态的比值,即健康状态(State of health, SOH)估计<sup>[1]</sup>。两者均是其性能退化的表现,PHM 技术致力于找出性能退化的部件及原因<sup>[2]</sup>。多年来,许多学者从不同角度提出了多种方案。其中,以基于模型的方法占多数<sup>[3-4]</sup>。基于等效电路模型的方法通过对模型参数进行辨识,实现 SOH 估计,或根据测量值和模型估计值的差异进行故障辨识<sup>[5-6]</sup>。基于电化学机理模型的方法采用高阶微分方程式描述锂离子电池内部的电化学变化过程,通过识别关键电化学参数实现 PHM<sup>[7-8]</sup>。这两类方法从理论上为锂离子电池的应用提供了指导性建议,意义重大。然而,这两类方法通常需要较为稳定的工况,对数据的采集精度要求较高,并且模型的建立与计算难度较大<sup>[9]</sup>,难以进行工程应用。

随着大数据技术的兴起,基于测试或传感器数据的数据驱动 PHM 方法逐渐获得重视并取得快速发展,成为 PHM 领域的重要研究热点<sup>[10]</sup>,这类算法通过对运行数据进行各类特征提取,进一步分析特征量的关联和变化来实现 PHM,在一定程度上不受限于数据质量的限制,无须建立复杂的模型,已在工程中得到了应用。文献[11]基于海量车辆运行数据提取容量增量曲线的特征,实现了基于高斯过程回归的在线 SOH 估计。依托北京国家电动汽车服务管理中心,文献[12]实现了基于离群点检测算法的故障诊断及验证,采用  $3\sigma$  多级筛选策略检测电池组中电池端电压的异常变化。文献[13]提出了基于熵的热失控预测方案,采用  $z$  记分法对电池组内的温度故障进行定量评价,通过设定异常系数对异常温度进行检测。MIT 及 Stanford 的研究人员<sup>[14]</sup>设计了 124 个单体电池的老化试验,以容量下降至额定容量的 80%时的循环圈数是否大于给定阈值作为健

康度等级高低的判断依据,提取早期循环数据的多维健康特征作为输入,以健康度等级的高低作为输出,建立逻辑回归模型实现了基于早期数据的健康度等级预测。在大规模电池应用场景,从早期运行数据对未来的运行性能好坏进行分类具有重要的工程意义,可尽早实现异常电池的筛选和维护。然而,在工程应用中,多数电芯难以实施长达数年的老化试验,无法建立监督学习模型<sup>[15]</sup>。即使得到模型,实际应用场景的工况也与实验室有所差别,且数据质量相对较差,模型所需的特征难以提取。

针对当前多数工程应用中工况复杂、采集精度低、计算条件差的现状,本文提出了数据驱动的锂离子电池健康状态综合评分及异常筛选算法。首先对比了试验数据与工程数据的差异,针对工程数据的应用限制,提出了一种新的特征提取方案。其次,提出了基于多维特征和混合聚类算法的健康评分体系,并在 MIT-Stanford 公开数据集进行了验证。最后,将特征提取方案及健康评分体系在某用户侧储能电站进行落地应用,实现异常电池的筛选。

## 1 数据描述

### 1.1 MIT-Stanford 公开数据集

文献[14]采用额定容量为 1.1 A·h 的 18650 磷酸铁锂单体电池,置于 30 °C 恒温箱,在充电阶段以不同倍率的恒流快充组合形成 72 种充电模式,放电过程统一采用 4C 倍率。部分充电模式采用两个电芯作为对比,最终产生了如图 1 所示的 124 个电池数据集,有效循环共 96 700 个。若以容量衰减到额定容量的 80%为退役阈值,该数据集的最终循环寿命范围为[150, 2 300]。




图 1 各电池前 1 000 个循环的放电容量曲线

两个案例如图 2 所示, 80%荷电状态(State of charge, SOC)之前由两个恒流充电阶段组成, 通过排列组合倍率和转折点使电池按不同的速度衰退; 80%SOC 以后均为 1C 的恒流恒压工况。




图 2 MIT-Stanford 公开数据集工况示例

## 1.2 用户侧储能电站

某用户侧储能电站于 2019 年 6 月建成, 夏、冬季的用电高峰月份启动运行, 减轻输配电网负荷。在夜间用电低谷充电, 日间用电高峰放电, 每天完成一次充放电循环。该站使用磷酸铁锂电池, 标准倍率的电流为 200 A。各电池舱由 6 个电池簇并联而成。每簇由 19 个模组串联, 各模组由 12 个单体串联, 集成 4 个温度探头。各簇配置一个能量转换系统与配电网交互, 独立接收调度指令进行充放电, 因此各簇工况不同。舱内安装空调系统, 设定环境温度为 25 ℃。由于具体的充放电行为依据用户侧需求而制定, 故同一个电池簇每天的工况也不固定, 例如图 3 所示的某模组 8 月前 3 天的数据。




图 3 某模组 8 月前 3 天的工况

## 1.3 工程数据的分析应用难点

如表 1 所示, 试验工况与工程场景存在很大的差异。MIT-Stanford 数据集工况稳定、采集精度高, 代表了大部分试验数据, 多数算法均采用这样的数据集。储能电站工况复杂、采集精度低, 并且在传

输和存储的过程中出现大量错误、遗漏。

表 1 MIT-Stanford 数据集与储能电站数据对比

| 数据集              | 工况稳定性                  | 环境温度   | 采集精度  |
|------------------|------------------------|--------|---|
| MIT-Stanford 数据集 | 同一个电池以固定的工况循环充放电       | 高性能恒温箱 | 电压: $\pm 0.0001$ V<br>电流: $\pm 0.0001$ A<br>温度: $\pm 0.001$ ℃ |
| 储能电站数据           | 各簇独立接收调度指令, 且每天的循环均不相同 | 普通空调   | 电压: $\pm 0.01$ V<br>电流: $\pm 0.1$ A<br>温度: $\pm 1$ ℃          |

## 2 特征提取方案

文献[14]的部分特征如表 2 所示,  $c_1$ 、 $c_2$  表示某个循环数。其中  $C_{max}$  为最大容量,  $C_{c1}$  为  $c_1$  循环的容量,  $C_{rate}$  为额定容量,  $Q_{c2} - Q_{c1}$  在第 2.1 节指出。

表 2 基于 MIT-Stanford 数据集的特征

| 类别                     | 名称            | 描述  |
|------------------------|---------------|---|
| 温度<br>(Temperature, T) | $sumT_{c1}$   | $c_1$ 温度数据的累加和(sum)、最大值(max)、平均值(avg)             |
|                        | $maxT_{c1}$   |   |
|                        | $avgT_{c1}$   |   |
| 容量<br>(Capacity, C)    | $C_{ini}$     | 初始容量  |
|                        | $C_{ini,c1}$  | $C_{ini,c1} = C_{ini} - C_{c1}$                   |
|                        | $C_{max,ini}$ | $C_{max,ini} = C_{max} - C_{ini}$                 |
|                        | $L_1$         | 当 $C_{c1} / C_{rate} = 0.95$ 时, $L_1 = c_1$       |
|                        | $L_2$         | 当 $C_{c1} / C_{max} = 0.95$ 时, $L_2 = c_1$        |
|                        | $VAR_{c1,c2}$ | 方差: $VAR_{c1,c2} = \text{Var}(Q_{c2} - Q_{c1})$   |
|                        | $MIN_{c1,c2}$ | 最小值: $MIN_{c1,c2} = \text{Min}(Q_{c2} - Q_{c1})$  |
|                        | $SKE_{c1,c2}$ | 偏度: $SKE_{c1,c2} = \text{Skew}(Q_{c2} - Q_{c1})$  |
|                        | $KUR_{c1,c2}$ | 峰度: $KUR_{c1,c2} = \text{Kur t}(Q_{c2} - Q_{c1})$ |

### 2.1 电量变化量方差特征

电量方差特征( $VAR_{c1,c2}$ )描述了同一个电芯在不同循环的放电曲线的差异, 如图 4 两次循环的  $V-Q$  曲线( $c_2 > c_1$ ), 随着电池的老化, 同一电压下放出的累积电量明显减少, 充放电曲线产生形变。电压对齐后计算电量差值序列  $Q_{c2} - Q_{c1}$ , 该序列的方差即为该特征。如图 5 所示, 选择  $c_1=10$ ,  $c_2=100$ , 绘制各个电池该特征与最终寿命的散点图。Pearson 相关系数反映了两个变量之间的线性相关程度[16], 方差和寿命的 Pearson 系数为 -0.849 9, 可见两者有较强的负相关性。

由图 3 可见, 在实际运行过程中存在倍率突变, 导致  $V-Q$  曲线无法绘制。以放电过程为例, 当倍率突增时造成大电流冲击, 电压随之跳跃式降低, 导致横坐标  $V$  不连续; 当倍率突降时, 受冲击的电压回升, 出现与倍率突增前相同的电压数据, 导致横坐标  $V$  冲突。因此在一次放电过程中, 部分电压片段不存在, 部分电压片段出现多次数据。并且, 多

次突变的倍率不适合进行电量计算,故 $Q$ 不能获取。此外,工程循环一般不是满充满放,导致表2中容量类特征均较难获取。




图4 等电压间隔内电量变化量计算示意图




图5 散点图

针对上述限制,本文基于电压间隔的电量变化量的差异描述两次充放电过程的差异,如图4所示。该示意图仅用于描述电压间隔内电量的求取过程,事实上本文采用的工程数据无法绘制 $V$ - $Q$ 曲线。以放电过程为例,设最大电压为 $V_{max}$ ,最小电压为 $V_{min}$ ,选取合适的电压间隔 $V_{interval}$ ,得到间隔起止点序列:  $[V_{max}, V_{max} - 1 \times V_{interval}, V_{max} - 2 \times V_{interval}, \dots, V_{max} - (k-1) \times V_{interval}]$ ,其中 $k = (V_{max} - V_{min}) / V_{interval}$ 。

根据该序列可获得 $k-1$ 个电压间隔,查找两次循环在各电压间隔下存在的片段数据。计算各个片段数据中电流的最大值和最小值之差 $I_d$ ,若大于阈值 $I_{dmax}$ 则舍弃该片段,保证片段内电流较为平稳。对剩下的片段求取电流平均值 $\bar{I}$ ,若同一电压间隔的一对片段的 $\bar{I}$ 之差大于阈值 $\bar{I}_{dmax}$ ,则舍弃这两个片段,保证两次循环的对应片段有相似的倍率。满足相似条件的片段数据称为共有片段,设 $c1$ 、 $c2$ 的共有片段分别为:  $[(V_{c1}^1, I_{c1}^1), (V_{c1}^2, I_{c1}^2), \dots, (V_{c1}^N, I_{c1}^N)]$ 和  $[(V_{c2}^1, I_{c2}^1), (V_{c2}^2, I_{c2}^2), \dots, (V_{c2}^N, I_{c2}^N)]$ ,其中 $N$ 为可获取共有片段的数量。对各个共有片段进行安时积分,求

得该片段的电量变化值 $Q_d$ ,某间隔下的案例如图4中的一对 $Q_d$ 。最终,获得两次循环的电量变化序列及其差值序列 $\Delta Q_d$

$$Q_{d,c1} = (Q_{d,c1}^1, Q_{d,c1}^2, \dots, Q_{d,c1}^N) \quad (1)$$

$$Q_{d,c2} = (Q_{d,c2}^1, Q_{d,c2}^2, \dots, Q_{d,c2}^N) \quad (2)$$

$$\Delta Q_d = Q_{d,c2} - Q_{d,c1} = (\Delta Q_d^1, \Delta Q_d^2, \dots, \Delta Q_d^N) \quad (3)$$

式中,  $\Delta Q_d$  的方差为该电池在 $c1$ 和 $c2$ 两次循环下的电量变化量方差特征,为了与电量差区分,后续表示为 $VAR'_{c1,c2}$ 。由于工程场景下 $N$ 一般较小,故不提取其最值、偏度、峰度,以避免引入误差。

若两个电池性能相同,在相同电压平台以相似倍率得到的放电量应该较为接近,  $VAR'_{c1,c2}$  较小。由于 MIT-Stanford 数据集的充电过程即为多个倍率切换的非恒流工况,因此可采用其充电过程验证  $VAR'_{c1,c2}$  是否能反映性能的衰退。以图6所示的三个电池为例,选择 $c1=1, c2=1, 2, \dots$ 进行特征提取,容量和特征的 Pearson 系数分别是 $-0.9622$ ,  $-0.9892$ ,  $-0.9980$ ,可见该特征与容量衰减相关性很高。




图6  $VAR'_{c1,c2}$ 与容量衰减

本方案的优势在于以下三点:若电压数据出现冲突或缺失,则该片段数据不参与计算;仅需片段数据内的倍率相同,不要求整个放电过程倍率稳定;仅对片段内稳定电流进行安时积分,避免倍率跳变引入的误差。

## 2.2 极差与不一致性特征

在工程场景中,通常将电池成组后使用,而成组电池可提取描述多个单体(对于电池簇,则是多个模组)协同运行的特征<sup>[17]</sup>。由于静置过程中温度和电压一般不发生变化,故提取充放电数据进行计算,假设循环 $c1$ 共得到 $p$ 个运行数据点,温差和压差序列为



$$\mathbf{T}_{cl}^{diff} = (T_{cl,diff}^1, T_{cl,diff}^2, \dots, T_{cl,diff}^p) \quad (4)$$

$$\mathbf{V}_{cl}^{diff} = (V_{cl,diff}^1, V_{cl,diff}^2, \dots, V_{cl,diff}^p) \quad (5)$$

式中,  $\mathbf{T}_{cl}^p$  为第  $p$  个数据点的最高温度和最低温度之差,  $\mathbf{V}_{cl}^p$  为该点最高电压和最低电压之差。

此外, 对各个时间点所有温度或单体电压数据求取样本熵, 可描述其不一致性特征<sup>[18-19]</sup>, 温度熵和电压熵序列为

$$\mathbf{TE}n_{cl} = (TEn_{cl}^1, TEn_{cl}^2, \dots, TEn_{cl}^p) \quad (6)$$

$$\mathbf{VE}n_{cl} = (VE n_{cl}^1, VE n_{cl}^2, \dots, VE n_{cl}^p) \quad (7)$$

式中,  $\mathbf{TE}n_{cl}^p$  为第  $p$  个数据点的所有温度数据的样本熵,  $\mathbf{VE}n_{cl}^p$  为该点所有电压数据的样本熵。

相对于方差, 样本熵对个别数据异常点不敏感, 并且通过合适的参数调整, 可使样本熵保持在 $[0, 5]$ 范围, 而方差在计算单体电压等数据级较低的数据时, 其数量级仅为  $10^{-4}$ , 不利于后续计算。对上述的差值和熵序列求取其极值、极差、方差等, 即可得到相关特征。

### 2.3 适用于工程数据的特征提取方案

综上所述, 本文提出的部分特征如表 3 所示。

表 3 适用于工程数据的特征

| 类别                    | 名称                             | 描述  |
|-----------------------|--------------------------------|---|
| 温度                    | $\max \mathbf{TE}n_{cl}$       | $\max \mathbf{TE}n_{cl} = \text{Max}(\mathbf{TE}n_{cl})$        |
|                       | $\text{avg} \mathbf{TE}n_{cl}$ | $\text{avg} \mathbf{TE}n_{cl} = \text{Mean}(\mathbf{TE}n_{cl})$ |
|                       | $\text{var} \mathbf{TE}n_{cl}$ | $\text{var} \mathbf{TE}n_{cl} = \text{Var}(\mathbf{TE}n_{cl})$  |
|                       | $\max T_{cl}^{diff}$           | $\max T_{cl}^{diff} = \text{Max}(T_{cl}^{diff})$                |
|                       | $\text{avg} T_{cl}^{diff}$     | $\text{avg} T_{cl}^{diff} = \text{Avg}(T_{cl}^{diff})$          |
|                       | $\text{avg} T_{cl}^{\max}$     | $\text{avg} T_{cl}^{\max} = \text{Avg}(T_{cl}^{\max})$          |
| 电压<br>(Voltage, $V$ ) | $\max \mathbf{VE}n_{cl}$       | $\max \mathbf{VE}n_{cl} = \text{Max}(\mathbf{VE}n_{cl})$        |
|                       | $\text{avg} \mathbf{VE}n_{cl}$ | $\text{avg} \mathbf{VE}n_{cl} = \text{Mean}(\mathbf{VE}n_{cl})$ |
|                       | $\text{var} \mathbf{VE}n_{cl}$ | $\text{var} \mathbf{VE}n_{cl} = \text{Var}(\mathbf{VE}n_{cl})$  |
|                       | $\max V_{cl}^{diff}$           | $\max V_{cl}^{diff} = \text{Max}(V_{cl}^{diff})$                |
|                       | $\text{avg} V_{cl}^{diff}$     | $\text{avg} V_{cl}^{diff} = \text{Avg}(V_{cl}^{diff})$          |
|                       | $\text{avg} V_{cl}^{\max}$     | $\text{avg} V_{cl}^{\max} = \text{Avg}(V_{cl}^{\max})$          |
| 容量                    | $VAR'_{cl,e2}$                 | $VAR'_{cl,e2} = \text{Var}(\Delta Q_d)$                         |

在工程应用中, 针对实际情况还可提取其他特征, 例如容量增量曲线<sup>[20]</sup>的峰值、温升速率等。但本文的数据不支持计算, 在此不过多赘述。

## 3 基于混合聚类算法的综合健康评分及健康度等级预测

### 3.1 算法框架描述

本文开发了图 7 所示的无监督学习算法框架, 对可提取特征的数量和质量要求不高, 无需进行事

先的模型训练和复杂的超参数调整, 可直接应用于工程场景。

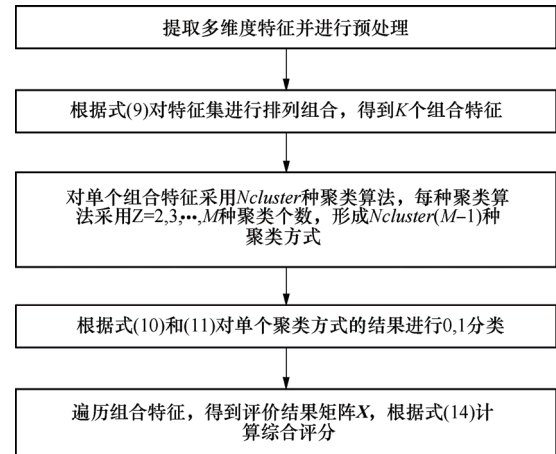


图 7 基于混合聚类算法的综合健康评分流程图

首先, 假设电池集共有  $m$  个电池。对  $m$  个电池提取多维特征量, 进行如下预处理。

(1) 数量级近似化: 对于数量级极小的特征量, 如  $VAR_{cl,e2}$  在  $10^{-3}$  以下; 数量级极大的特征量, 如  $\text{sum} T_{cl}$  在  $10^4$  以上, 进行式(8)的操作, 以保留有效数据位, 避免计算过程中造成截断误差。

$$F' = \lg F \quad (8)$$

式中,  $F$  为某个特征,  $F'$  为经过对数操作后的特征。

(2) 相关性方向统一化: 基于工程背景知识, 对特征值与电池健康状态成正比的特征进行求倒操作, 使得所有的特征均与电池健康状态成反比。

(3) 特征值归一化: 将各特征进行 $[0, 1]$ 归一化。

(4) 特征降维: 某些特征量之间存在着较强的关联度, 同时使用不会显著提高精度, 反而会降低计算速度。采用主成分分析法进行降维, 选取信息度贡献最大的前几个特征, 获得新的特征矩阵, 可在减轻计算量的同时保持相对较高的准确率<sup>[21]</sup>。

(5) 特征组合: 设降维后有  $F_1, F_2, \dots, F_k$  共  $k$  个特征, 对特征集进行排列组合, 根据式(9)可获得  $K$  种特征组合。例如, 三个  $F$  的组合结果为 $(F_1)$ 、 $(F_2)$ 、 $(F_3)$ ;  $(F_1, F_2)$ 、 $(F_1, F_3)$ 、 $(F_2, F_3)$ ;  $(F_1, F_2, F_3)$ 。

$$K = C_k^1 + C_k^2, \dots, C_k^k = 2^k - 1 \quad (9)$$

然后, 针对每个特征组合, 根据图 7 形成多种聚类方式, 每种聚类方式将电池集合分为多类。单次聚类仅会给出分类结果, 不会给各类打上标签。本文根据特征量平均值  $\bar{F}$  对分类结果进行判断, 采用 0 和 1 按照类别进行评价。假设某次计算采用的特征组合共有  $h$  个特征, 记  $F_i$  为其中的第  $i$  个特征量。电池集合被分为  $Z$  类, 各类记为  $Z_1, Z_2, \dots, Z_j, \dots$ ,

各类有  $n_1, n_2, \dots, n_j, \dots$  个电池, 求取各类的  $\bar{F}$ , 例如对  $Z_j$  类进行计算

$$\bar{F}_j = \left( \sum_{l=1}^{n_j} \sum_{i=1}^h F_{k,i} \right) / n_j \quad (10)$$

式中,  $l=1, 2, \dots, n_j$ ,  $F_{k,i}$  为第  $Z_j$  类中第  $k$  个电池的第  $i$  个特征值。

由于在前述预处理中, 已经通过改变相关性方向使得特征值与电池健康状态成反比, 因此  $\bar{F}$  较大类中的电池健康状态较差。以图 8 为例, 对  $\text{sum}T_{100}$ 、 $\text{VAR}_{10,100}$  预处理后分别记为特征一和特征二,  $\bar{F}$  较大的  $Z_1$  类中大多数散点颜色相对较深, 对应电池寿命较短, 将该类中的电池标记为 0。基于此规律, 根据式(11)选择  $\bar{F}$  排名靠前的  $N$  类中的电池标记为 0, 其余类中的电池标记为 1, 单次聚类结果即是一次模拟智能体的投票行为。

$$N = \begin{cases} C/2 & C = 2, 4, 6, \dots \\ (C-1)/2 & C = 3, 5, 7, \dots \end{cases} \quad (11)$$




图 8 特征与循环寿命

每个聚类方式得到一个由 0,1 组成的  $m$  维评价向量  $\mathbf{X}_i$ , 对单个特征组合遍历聚类方式可得到  $(M-1) \cdot N_{\text{cluster}}$  个评价向量。遍历所有特征组合, 得到评价结果矩阵

$$\mathbf{X} = (\mathbf{X}_1^T, \mathbf{X}_2^T, \dots, \mathbf{X}_z^T) = \begin{pmatrix} x_{11} & \dots & x_{1z} \\ \vdots & & \vdots \\ x_{m1} & \dots & x_{mz} \end{pmatrix} \quad (12)$$

$$z = K \cdot (M-1) \cdot N_{\text{cluster}} \quad (13)$$

其次, 基于当次循环特征得到的评价结果矩阵进行一次综合评分。行向量  $\mathbf{Y}_n = (x_{n1}, x_{n2}, \dots, x_{nz})$  记录了第  $n$  个电池的各个特征组合下所有聚类方式得到的评价结果, 计算该电池的好评率

$$s_n = (\sum \mathbf{Y}_n) / z \quad (14)$$

计算  $c$  循环下  $m$  个电池的好评率, 得到综合评分向量为  $\mathbf{S}_c = (s_{1c}, s_{2c}, \dots, s_{mc})^T$ 。

最后, 对于固定工况的试验数据, 可依据  $\mathbf{S}_c$  预测健康度等级。对于不稳定的实际应用工况, 可随着运行循环次数的增多, 根据式(15)更新综合评分矩阵  $\mathbf{S}$ , 进一步分析各个电池的相对健康状态。

$$\mathbf{S} = (\mathbf{S}_1, \mathbf{S}_2, \dots, \mathbf{S}_c) = \begin{pmatrix} s_{11} & \dots & s_{1c} \\ \vdots & & \vdots \\ s_{m1} & \dots & s_{mc} \end{pmatrix} \quad (15)$$

### 3.2 基于 MIT-Stanford 公开数据集的算法验证

常见的聚类算法有 K 均值聚类、模糊 C 聚类、高斯混合聚类、均值偏移聚类、层次聚类<sup>[22]</sup>, 各算法从不同的角度对数据集进行划分, 在特定的数据集下能取得最佳的效果。然而, 我们无从得知具体的工程数据集特性, 应该尽量避免复杂的算法超参数调整。前三类算法分别从欧氏距离、模糊隶属度、概率密度的角度进行类别划分, 且无需进行复杂的超参数调整即可应用于大部分数据集, 因此我们采用这三种聚类算法, 每种算法下采用  $C=2$ ,  $N=1$  和  $C=3$ ,  $N=1$  形成多种聚类方式。基于表 2 中的特征, 总结出四类不同场景以验证算法, 如表 4 所示。

表 4 四类不同场景的特征列表

| 场景分类 | 特征   |
|------|--|
| 早期   | $C_{ini}, KUR_{4,5}, MIN_{4,5}, SKE_{4,5}, VAR_{4,5}, \text{Sum}T_4, \text{avg}T_4, \text{max}T_4$                             |
| 中期   | $C_{ini,100}, KUR_{10,100}, MIN_{10,100}, SKE_{10,100}, VAR_{10,100}, \text{sum}T_{100}, \text{avg}T_{100}, \text{max}T_{100}$ |
| 后期   | $C_{max,100}, L_1, L_2$  |
| 工程场景 | $VAR_{1,5}, VAR_{4,5}, VAR_{10,100}, \text{avg}T_{10}, \text{avg}T_{100}$  |

对于后期特征, 由于多数电池出现初期的容量回升, 实际的最大容量不在早期出现, 故将  $C_{max,ini}$  视作后期特征。对于工程可获取特征, 容量参数较难获得, 而且数据质量对温度极值与累加和计算的影响较大, 因此只采用  $VAR_{c1,c2}$  和  $\text{avg}T_{c1}$ 。由文献[14]可知有两个电池的数据记录存在问题, 故不参与计算。此处以后期特征集产生的评价结果为例, 由式(13)可知, 共有 42 次不同角度的评价结果, 见表 5。

表 5 基于后期特征集的多次评价结果及综合评分

| 电池  | 评价次数 |   |     |    |    |    | 好评数   | 综合评分 |
|-----|------|---|-----|----|----|----|-------|------|
|     | 1    | 2 | ... | 41 | 42 |    |       |      |
| 1   | 1    | 1 | ... | 1  | 1  | 42 | 100   |      |
| 2   | 0    | 0 | ... | 0  | 1  | 23 | 54.76 |      |
| 3   | 0    | 1 | ... | 1  | 1  | 32 | 76.19 |      |
| ... |      |   |     |    |    |    |       |      |
| 122 | 1    | 1 | ... | 1  | 1  | 42 | 100   |      |

舍弃数个寿命过长的电池后,图9按照评分高低对电池重新编号,绘制评分与最终寿命的对比图。可以看出两者有一定的关联度,尽管不能定量预测准确的寿命,但是基本可以预测相对健康状况。




图9 综合评分与循环寿命

为了对结果进行量化分析,我们依据综合评分进行健康度等级的高低分类预测,采用与文献[14]相同的分类准则,即电池最终寿命是否大于550。按照该阈值共有41个电池为较低的健康度等级,因此预测评分较低的41个电池未来健康度等级为低。同时,将单次评价所得的(1,0)分类视作健康度高低分类,记录下各个算法下单次评价结果的最高准确率,最终各类特征集的分选准确率如表6所示。

表6 单个算法下最高准确率与混合聚类算法的准确率(%)

| 场景分类 | $K$ 均值 | 模糊 $C$ | 高斯混合  | 混合聚类算法 |
|------|--------|--------|-------|--------|
| 早期   | 87.70  | 90.98  | 91.80 | 94.26  |
| 中期   | 94.26  | 82.79  | 94.26 | 92.62  |
| 后期   | 96.72  | 98.36  | 96.72 | 95.90  |
| 工程场景 | 89.34  | 89.34  | 94.26 | 92.62  |

本文算法在各类场景的特征下,均能实现92%以上的分选准确率,可见其对特征种类和数量的适应性较强。在仅采用 $VAR_{cl,c2}$ 和 $avgT_{cl}$ 的工程场景下,达到92.6%的准确率,与文献[14]采用完整特征训练的 classifier 在测试集的准确率相同。引入其他聚类算法可进一步提高准确率,但超参数需随着应用场景的改变重新调整,若设置不当可能导致结果错误。因此,基于兼顾准确率和通用性的考虑,本文未采用超参数较难调整的聚类算法。

虽然单个算法能在某个特定的特征组合和聚类个数下取得极高的分类准确率,但是这在实际应用是无法复现的。以 $K$ 均值聚类的后期特征结果为例,表7记录 $K$ 均值聚类在单次评价结果下的分类结果。尽管有两种聚类方案获得了优于本文算法的结果,但是仍然难以归纳出最优的特征组合和聚类个数。在工程应用中,如果选择了错误的方案,那

么准确率可能会非常低。此外,单次分选结果是根据特征组合的性质进行的类别划分,不应以固定阈值得到的分类结果作为唯一评价标准。

表7  $K$  均值算法在后期特征集的单次分选准确率(%)

| 特征组合                 | 聚类总数     | 选择个数 | 准确率   |
|----------------------|----------|------|-------|
| $(L_1)$              | 2        | 1    | 96.72 |
| $(L_1, L_2)$         | 2        | 1    | 95.90 |
| $(L_1)$              | 4        | 2    | 95.08 |
|                      | $\vdots$ |      |       |
| $(L_2)$              | 5        | 2    | 68.03 |
| $(C_{max,ini}, L_2)$ | 3        | 1    | 68.03 |

本文提出的算法无需关注选用或舍弃哪些特征,只需要尽可能对可提取的特征进行利用即可。此外,根据式(13)可知丰富聚类算法的混合度和增大 $M$ 能从更多的角度进行评价,有助于提高准确率。经过验证,本案例采用的三种聚类算法和两种聚类个数已能满足大部分场景的计算速度和精度需求。

### 3.3 基于储能电站数据集的应用

获取储能电站8月1日至27日的有效数据,将算法应用于各簇的19个模组。首先,提取表3所述的多维特征。对同一簇19个模组提取 $VAR'_{cl,c2}$ 时,需要保证同一模组的两次循环工况满足相似条件且同一次循环的19个模组也满足相似条件,才能进行横向对比。因此,需要提取38个循环曲线的共有片段。可见其计算条件比较苛刻,故采用滚动配对的方式充分利用已产生的数据,如图10所示。




图10 滚动提取 $VAR'_{cl,c2}$

随着系统运行,选定最新循环 $L$ 作为被比较循环,依次与已有的多个循环进行对比。本次计算选取 $V_{max}=41\text{ V}$ ,  $V_{min}=38.5\text{ V}$ ,  $V_{interval}=0.1\text{ V}$ ,  $\bar{I}_{dmax}$ 和 $I_{dmax}=10\text{ A}(0.05\text{ C})$ ,进行该特征的提取。若满足该特征提取条件的循环对较多,则选择相距循环 $L$ 最远的2次循环得到的该特征,以避免相邻两次循环的数据采集误差掩盖了实际的放电曲线差异。

然后,提取每次循环的极值特征、不一致性特



征, 获得特征组合集。采用与第 3.2 节相同的三种聚类算法和两种聚类个数, 对每次循环产生的特征集进行一次综合评分, 根据式(15)得到某簇的  $S$  为

$$\begin{pmatrix} 84.27 & 90.31 & \cdots & 35.73 \\ 21.05 & 33.42 & \cdots & 8.18 \\ \vdots & \vdots & \ddots & \vdots \\ 62.89 & 72.50 & \cdots & 59.24 \end{pmatrix}_{19 \times 27}$$

如图 11 所示, 由于每天的工况均不相同, 各个模組的综合评分会随着工况变化。在工况较为恶劣的时候, 多数电池性能表现均较差, 因此得分普遍偏低。尽管如此, 我们仍然可以轻易辨别出 2 号模組在多数循环下得到较低的评价。




图 11 某簇各模組的综合评分变化图

在实际运行中, 2 号模組运行到 8 月底(循环 27 次以后)出现了严重的故障, 无法继续运行。如图 12 所示, 该模組有个别单体与其他单体性能差异逐渐增大, 最终压差远远超过国家标准, 且还有持续增大的趋势。然而该模組在运行早期, 其总电压、电流和温度场分布均未出现明显异常, 早期的压差也在国家标准范围之内, 若对上述运行特征同时监控, 难以实现异常电池筛选, 而本算法在早期就已经识别出该异常模組。




图 12 各模組的压差变化趋势

除本案例以外, 本算法在该储能电站和搭载三

元锂电池的电动汽车上实现了多次故障电池筛选。由于本算法综合考虑了各个运行特征, 任一特征出现异常均会导致对应电池出现较低评分, 而任何异常最终都导致出力不足或出现安全隐患, 对于大规模电池运行场景, 筛选出较差的电池进行维护具有重要意义。

综上所述, 本文提出的无监督学习算法与已有的有监督学习算法的对比如表 8 所示。

表 8 本文算法与已有算法的对比

| 学习方式   | 已有算法, 以文献[14]为例   | 本文算法  |
|--------|---|---|
|        | 有监督学习   | 无监督学习   |
| 应用流程   | (1) 对某款电池进行老化循环试验, 以实验数据建立模型;<br>(2) 在应用时, 基于运行数据提取模型所需的特征作为输入, 实现分类。 | (1) 无需进行模型的训练, 直接基于工程数据尽可能多地提取特征, 进行综合评分;<br>(2) 评分结果可反映各个电池的相对健康度等级。 |
| 硬件能力需求 | (1) 模型训练需较高要求的硬件支持;<br>(2) 利用已建立的模型进行应用, 对硬件要求不高。                     | (1) 视用户对精度的需求, 可对特征集进行取舍和降维;<br>(2) 特征数量适中时, 常规硬件配置即可满足计算要求。          |

通过以上对比可知, 有监督学习方法的主要优点是模型精度较高, 且应用模型时的硬件需求相对较低。然而该模型无法应用在其他型号的电池, 普适性较差, 并且模型在训练过程中指定了特征输入的种类, 若应用时某些特征无法提取则模型无法使用; 此外, 进行试验设计和实施需耗费较多的时间和精力。而本方案属于无监督学习框架, 无需对电池进行事先的工况设计和试验, 可降低工程人员的工作负担, 且非常适用于类似本文中并无试验数据可用的应用场景。此外, 对特征输入的种类要求不高, 可直接应用在工程场景。经过实践验证, 在本文描述的储能电站进行应用, 经过特征降维后保留七个左右特征即可得到满意的结果, 普通配置的服务器已满足计算需求。

## 4 结论

本文基于实际工程的迫切需求和工程数据的质量限制, 提出了数据驱动的锂离子电池健康状态综合评分及异常电池筛选算法, 主要结论如下。

(1) 针对工程数据工况复杂多变、质量较差的问题, 提出了具有较强适应性的特征提取方案。

(2) 大规模场景的异常电池筛选有利于运行维护, 本文提出的综合评分体系可实现健康度等级预测, 进一步筛选可能出现故障的电池, 该算法无需



进行模型训练,具有较强的通用性,可应用于多数电池型号和应用场景。

(3) 对特征提取方案及综合评分算法进行了验证和应用。基于 MIT-Stanford 公开数据集,仅采用前 100 个循环的少数特征即可实现 92% 以上的健康度等级高低预测准确率。应用于储能电站,可提前实现异常电池筛选。

未来将进一步优化算法框架,提高计算速度。同时,研究各个特征量对聚类结果的权重影响,有望实现故障类型辨识。

## 参 考 文 献

- [1] 戴海峰,周艳新,顾伟军,等. 电动汽车用动力锂离子电池寿命问题研究综述[J]. 电源技术, 2014(10): 182-184, 212.  
DAI Haifeng, ZHOU Yanxin, GU Weijun, et al. A review of researches on the life of power lithium-ion batteries for electric vehicles [J]. Power Technology, 2014(10): 182-184, 212.
- [2] HU Xiaosong, ZHANG Kai, LIU Kailong, et al. Advanced fault diagnosis for lithium-Ion battery systems[J/OL]. TechRxiv. Preprint. [2020-03-02]. <https://doi.org/10.36227/techrxiv.11777448.v1>
- [3] 胡晓松,唐小林. 电动车辆锂离子电池建模方法综述[J]. 机械工程学报, 2017, 53(16): 34-45.  
HU Xiaosong, TANG Xiaolin. Review of modeling techniques for lithium-ion traction batteries in electric vehicles[J]. Journal of Mechanical Engineering, 2017, 53(16): 20-31.
- [4] QIANG Jiayi, AO Guoqiang, YANG Lin. Estimation method on the battery state of charge for hybrid electric vehicle[J]. Chinese Journal of Mechanical Engineering, 2008, 21(3): 20-25.
- [5] LIU Zhentong, HE Hongwen. Model-based sensor fault diagnosis of a lithium-ion battery in electric vehicles[J]. Energies, 2015, 8(7): 6509-6527.
- [6] ODENDAAL H M, JONES T. Actuator fault detection and isolation: An optimised parity space approach[J]. Control Engineering Practice, 2014, 26: 222-232.
- [7] 任东生,冯旭宁,韩雪冰,等. 锂离子电池全生命周期安全性演变研究进展[J]. 储能科学与技术, 2018, 7(6): 9-18.  
REN Dongsheng, FENG Xuning, HAN Xuebing, et al. Research progress on the life cycle safety evolution of lithium-ion batteries[J]. Energy Storage Science and Technology, 2018, 7(6): 9-18.
- [8] 徐兴,徐琪凌,王峰,等. 车用锂离子动力电池电化学模型修正方法[J]. 机械工程学报, 2019, 55(12): 128-136.  
XU Xing, XU Qiling, WANG Feng, et al. Modification method of electrochemical model of lithium ion power battery for vehicles[J]. Journal of Mechanical Engineering, 2019, 55(12): 128-136.
- [9] 戴海峰,孙泽昌,魏学哲. 利用双卡尔曼滤波算法估计电动汽车用锂离子动力电池的内部状态[J]. 机械工程学报, 2009, 45(6): 95-101.  
DAI Haifeng, SUN Zechang, WEI Xuezhe. Using dual Kalman filtering algorithm to estimate the internal state of lithium ion power battery for electric vehicles[J]. Journal of Mechanical Engineering, 2009, 45(6): 95-101.
- [10] 彭宇,刘大同. 数据驱动故障预测和健康管理的综述[J]. 仪器仪表学报, 2014(3): 3-17.  
PENG Yu, LIU Datong. Overview of data-driven fault prediction and health management[J]. Journal of Chinese Instrumentation, 2014(3): 3-17.
- [11] XIAO W, XU H C, JIA J, et al. State of health estimation framework of li-on battery based on improved Gaussian process regression for real car data[J]. IOP Conference Series: Materials Science and Engineering, 2020(793): 012063.
- [12] ZHAO Y, LIU P, WANG Z, et al. Fault and defect diagnosis of battery for electric vehicles based on big data analysis methods[J]. Applied Energy, 2017(207): 354-362.
- [13] HONG J, WANG Z, LIU P. Big-data-based thermal runaway prognosis of battery systems for electric vehicles[J]. Energies, 2017, 10: 919.
- [14] SEVERSON K A, ATTIA P M, JIN N, et al. Data-driven prediction of battery cycle life before capacity degradation[J]. Nature Energy, 2019, 4(5): 1-9.
- [15] HU Xiaosong, XU Le, LIN Xianke, et al. Battery lifetime prognostics[J]. Joule, 2020(4): 1-37.
- [16] 廖芹,郝志峰,陈志宏. 数据挖掘与数学建模[M]. 北京: 国防工业出版社, 2010.  
LIAO Qin, HAO Zhifeng, CHEN Zhihong. Data mining and mathematical modeling[M]. Beijing: National Defense Industry Press, 2010.
- [17] FENG F, HU X, HU L, et al. Propagation mechanisms and diagnosis of parameter inconsistency within Li-ion battery packs[J]. Renewable and Sustainable Energy Reviews, 2019(112): 102-113.
- [18] ZHENG Y, HAN X, LU L, et al. Lithium ion battery pack power fade fault identification based on Shannon entropy in electric vehicles[J]. Journal of Power Sources, 2013 (223): 136-146.
- [19] HU X, JIANG J, CAO D, et al. Battery health prognosis for electric vehicles using sample entropy and sparse

(下转第 159 页)

模型[J]. 吉林大学学报, 2011, 41(2): 333-337.

SONG Xianmin, JIN Sheng, WANG Dianhai, et al. Vehical-following model considering lateral offset[J]. Journal of Jinlin University, 2011, 41(2): 333-337.

- [24] 曾小华, 王振伟, 宋大风, 等. 基于多岛遗传算法的功率分流式双模混合动力客车参数优化[J]. 机械工程学报, 2020, 56(2): 98-105.

ZENG Xiaohua, WANG Zhenwei, SONG Dafeng, et al. Parameter optimization of dual-mode power-split hybrid electric bus based on MIGA algorithm[J]. Journal of

Mechanical Engineering, 2020, 56(2): 98-105.

作者简介: 田勇, 男, 1985 年出生, 博士, 副教授。主要研究方向为无线电能传输、电池管理技术。

E-mail: ytian@szu.edu.cn

朱泽, 男, 1995 年出生。主要研究方向为电动汽车无线电能传输技术。

E-mail: 2170285305@email.szu.edu.cn

田劲东, 男, 1973 年出生, 博士, 教授。主要研究方向为无线电能传输、光学检测技术与系统。

E-mail: jindt@szu.edu.cn

向利娟(通信作者), 女, 1989 年出生, 博士。主要研究方向为无线电能传输、电磁场建模与仿真。

E-mail: xianglijuan@szu.edu.cn



(上接第 149 页)

bayesian predictive modeling[J]. IEEE Transactions on Industrial Electronics, 2015, 63(4): 2645-2656.

- [20] WENG C, CUI Y, SUN J, et al. On-board state of health monitoring of lithium-ion batteries using incremental capacity analysis with support vector regression[J]. Journal of Power Sources, 2013, 235: 36-44.

- [21] MALHI A, GAO R X. PCA-based feature selection scheme for machine defect classification[J]. IEEE Transactions on Instrumentation & Measurement, 2004, 53(6): 1517-1525.

- [22] 孙吉贵, 刘杰, 赵连宇. 聚类算法研究[J]. 软件学报, 2008, 19(1): 48-61.

SUN Jigui, LIU Jie, ZHAO Lianyu. Research on clustering algorithms [J]. Journal of Software, 2008, 19 (1): 48-61.

作者简介: 贾俊, 男, 1995 年出生。主要研究方向为数据驱动的锂电池健康管理算法及应用。

E-mail: junjia@cqu.edu.cn

邓忠伟(通信作者), 男, 1990 年出生, 博士, 博士后, 助理研究员。主要研究方向为动力电池及储能系统管理控制技术。

E-mail: dengzhongw@cqu.edu.cn