

DOI: 10.19783/j.cnki.pspc.221772

锂离子电池储能安全管理中的机器学习方法综述

蔡涛, 张钊诚, 袁奥特, 史致远, 张博涵

(强电磁工程与新技术国家重点实验室(华中科技大学), 湖北 武汉 430074)

摘要: 随着当前电化学储能技术的广泛应用, 电池储能电站的安全运维问题日渐突出。传统电池管理系统仅能获得各电池单体的电压、电流及温度, 并且受限于硬件处理能力、数据传输带宽及延迟等条件, 掌握海量电池单体储能系统的健康与安全运行状态成为关键技术难题。机器学习方法在锂离子电池运行状态预测领域的应用为储能电池系统安全管理创造了条件。针对锂离子电池安全管理需求, 首先对锂离子电池滥用及热失控风险机理的相关研究进行了介绍。随后, 讨论了锂离子电池管理系统架构及其应用特点, 并详细论述了机器学习方法在锂离子电池健康与安全状态分析方面的应用。最后, 对储能电站锂离子电池的安全管理进行了展望。

关键词: 锂离子电池储能; 电池健康与安全; 机器学习

Review of machine learning for safety management of li-ion battery energy storage

CAI Tao, ZHANG Zhaocheng, YUAN Aote, SHI Zhiyuan, ZHANG Bohan

(State Key Laboratory of Advanced Electromagnetic Engineering and Technology
(Huazhong University of Science and Technology), Wuhan 430074, China)

Abstract: Currently the widespread application of electrochemical energy storage technology raises prominent concern on the safety operations of battery energy storage station. The traditional battery management system (BMS) can only support measurement of battery cell's voltage, current and temperature. And due to limited hardware processing power, data bandwidth and network time delay, it is a key technical problem to master the healthy and safety of battery energy storage system with a large number of battery cells. The application of machine learning for lithium battery state prediction enables better safety management of battery energy storage system. For lithium-ion battery safety management requirements, this paper first provides an overview of related research on the mechanism of lithium battery abuse and thermal runaway. Then, the architecture of lithium-ion battery management system and its application characteristics are discussed and summarized, the usage of machine learning methods in the health and safety state analysis of lithium batteries are introduced in detail. Based on the above review, this paper provides a prospect of the safety management of lithium batteries in energy storage power stations.

This work is supported by the National Natural Science Foundation of China (No. U1966214).

Key words: li-ion battery energy storage; battery health and safety; machine learning

0 引言

在各类型的电化学储能中, 锂离子电池凭借其能量密度高、循环次数多的优点, 占据了90%的市场份额。然而, 以热失控(thermal runaway)为特征的锂离子电池系统安全事故时有发生, 严重地威胁着生命财产安全。因此, 储能电池高能量密度条件下

的高安全性是电池储能系统商业化推广应用的首要保障^[1]。现有电力储能电池管理系统技术方案大多源自于电动汽车的动力电池总成^[2-3], 其单体数量少、总体容量小、运行工况单一, 明显不适用于大规模电力储能电站的安全运维需求。储能系统具有海量的电池单体, 存在监测数据庞大、信息类型复杂、安全评估急迫等难题。同时, 因热失控特性, 导致锂离子电池一旦发生事故则难以控制, 进而可能演化成储能系统燃烧爆炸等重大安全事故。在运行维护方面, 现有储能电站普遍采用被动的定期检

基金项目: 国家自然科学基金项目资助(U1966214); 武汉强磁场学科交叉基金项目资助(WHMFC202145)

修策略,而电池从出现故障征兆到发生热失控之间往往只有数十到数百秒的时间,采用定期检修的方式难以及时发现劣化电池。

鉴于此,本文聚焦如何支撑锂离子电池储能系统的安全运维需求,从锂离子电池的滥用和退化的机理入手,分析了对锂离子电池进行预测所需要监测计算的量以及它们与热失控的关系;继而进一步详细介绍了目前主流的用于进行锂离子电池状态预测的各项机器学习方法以及其适用于分析的状况;最后,给出了对于未来研究方向的建议和指导意见,旨在为该领域研究人员提供参考借鉴。

1 锂离子电池热失控预警与安全管理

1.1 电池热失控产生机理

锂离子电池是采用储锂化合物作为正、负极材料的蓄电池。锂离子电池单体由正极(Positive electrode)、负极(Negative electrode)、隔膜(Separator)、电解液(Electrolyte)和集流体(Current collector) 5个部分组成,正极、负极浸泡在电解液中,并通过隔膜相互分隔,通过集流体将电流均匀地传输到活性材料,如图1所示。

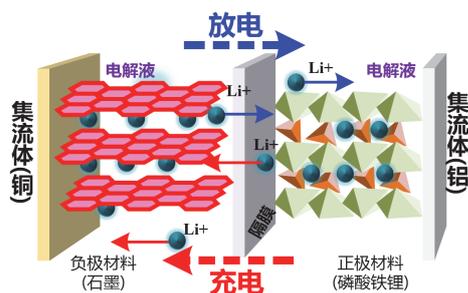


图1 锂离子电池结构及其工作原理

Fig. 1 Structure of li-ion battery and its working principle

锂离子电池的正极由含锂氧化物构成,主要包括钴酸锂(LiCoO_2)、磷酸铁锂(LiFePO_4)、三元锂(NCM、NCA)等。锂离子电池的负极主要由嵌锂材料构成,主要包括碳材料、钛酸锂、硅基材料等。在放电时,锂离子从负极材料中“脱嵌”,经过电解质和隔膜后“嵌入”正极材料中,此时正极富锂、负极贫锂;在充电时,锂离子从正极材料中“脱嵌”,经过电解质和隔膜后“嵌入”负极材料中,此时正极贫锂,负极富锂。作为储能系统的核心设备,储能电池是实现储能电站削峰填谷、负荷补偿等功能的关键。

锂离子电池能量密度大、使用寿命长,广泛用于各类电池储能技术中。然而在实际应用中,如果发生电池滥用(Abuse)状况,电池材料将受到破坏从

而产生异常发热现象,热量不断积聚加剧内部放热化学反应过程,形成正反馈,最终造成热失控。

机械滥用、电滥用和热滥用是引发锂离子电池热失控的主要诱因,均会对锂离子电池造成可逆或不可逆的损伤,如SEI(solid electrolyte interphase)膜分解、锂枝晶刺破隔膜、诱发电池内短路等,继而通过一系列电化学和物理机理引发电池内部温度异常上升,最终引起一系列电化学反应。锂离子电池热失控过程如图2所示。文献[5]研究表明电池SEI膜的分解是主要的放热反应来源。常见的分解温度在 $80\sim 120\text{ }^\circ\text{C}$ 间,放热峰值出现在 $90\text{ }^\circ\text{C}$,已经达到传感器可监测的温度范围。温度持续升高导致负极金属锂与碳酸乙烯酯($\text{C}_3\text{H}_4\text{O}_3$)、碳酸二乙酯($\text{C}_5\text{H}_{10}\text{O}_3$)、碳酸二甲酯($\text{C}_3\text{H}_6\text{O}_3$)和碳酸丙烯酯($\text{C}_4\text{H}_6\text{O}_3$)等电解液分解($120\text{ }^\circ\text{C}$ 左右)、隔膜融化($130\text{ }^\circ\text{C}\sim 140\text{ }^\circ\text{C}$)、正极分解($150\text{ }^\circ\text{C}\sim 211\text{ }^\circ\text{C}$)等反应,并引起过充热失控^[6]。

1.2 热失控特征参数与预警

锂离子电池热失控过程中释放大量的热量和可燃性气体,当可燃性气体浓度达到其爆炸极限,在外部高温的作用下会发生爆炸,严重影响储能电站的安全稳定运行^[7]。因此,迫切需要研究锂离子电池热失控特性,探究热失控早期预警方法,解决储能电站安全管控问题。

对于电力储能系统而言,其电池热失控通常因电滥用而引起的。如不适合的过充和过放条件均能够引起电池内部的各种副反应,导致电池局部过热,引发热失控。而系统设备或线路故障导致的电池外短路则是非正常状态下电池的极速放电情况。超高电流将导致电池热量累积严重,甚至极耳熔断和热失控。此外,电池衰减老化也是引发热失控事故的原因之一,老化对于锂离子电池安全性的影响主要体现在金属枝晶的生长上,随着循环次数的增加和生产过程中混入的杂质微粒的诱导,不良副反应形成的锂枝晶等尖锐物体容易刺穿隔膜,导致微观内短路的发生。

鉴于锂电池热失控的反应机理与其演化过程,现有的电池热失控的预警主要是针对电池出现热失控的临界条件对电池进行监控和预警。电池在出现热失控的过程中,其电压、电流、内阻、内部压力、温度等都会出现明显的变化,且产生特征气体,通过对其中一种或几种特征参数及特征气体的监测可以有效地对电池热失控进行预警。虽然科研人员提出了各种故障诊断和检测以及安全预警方法,但是由于数据计算量大、算法复杂、通用性差(不同种类的电池无法通用)、在线实现困难等原因,导致这些算法和方法无法应用,可用性不强。

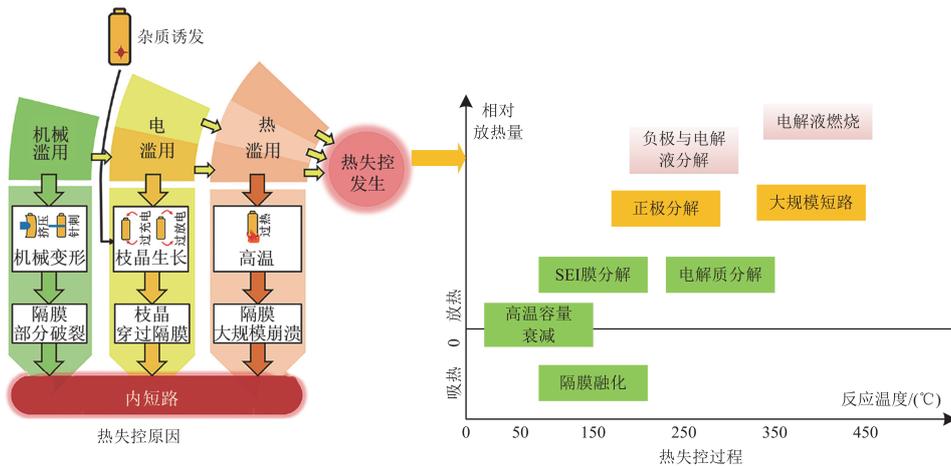


图2 锂离子电池热失控过程^[7]

Fig. 2 Procedure of li-ion battery runaway

1.3 电池安全管理系统

在电池储能系统中，相当困难的问题就是如何应用合适的监测和控制方法延长电池使用寿命以及避免突发的热失控灾难性事件。而锂离子电池的性能或健康状态表征电池相对于新电池其存储电能、能量的能力，是定量描述电池退化程度的指标。随着电池充放电次数的增加，其性能或健康状态逐渐衰减，故可能因内短路而诱发电池热失控危险。退化状态识别就是不同性能变量映射到对应健康因子(health index, HI)以确定对象系统当前健康水平的过程，是实现安全预警的前提条件。因此，业内认可的锂离子电池运行状态通常包括输出电压、荷电状态(state of charge, SOC)和健康状态(state of health, SOH)等。其中 SOH 表示电池当前的最大可用容量与初始容量之比。SOH 能较好地表征电池的安全状态，当 SOH 低于 80%时一般认为电池寿命终止，继续使用会存在安全隐患。因此对 SOH 等参数的准确估计有助于提升电池的安全性。由于电池的复杂性，准确的状态参数估计仍然是相关人员研究的难点。除了状态参数估计，通过适当的异常检测算法有效检测异常电池，能进一步提升系统的安全性。此外，电池剩余使用寿命(remaining useful life, RUL)指在当前使用条件下电池工作至报废所需要的循环次数，通常作为表征电池的健康状态的另一个重要指标。一般认为，当锂离子电池当前容量小于出厂容量的 80%时，则判定电池报废。许多学者提出了各种模型来估计 SOC、SOH、RUL、电源状态(state of power, SOP)和功能状态(state of function, SOF)。然而，精确的电池建模仍然存在着相当多的困难和挑战。

电池管理系统(battery management system, BMS)通过对电池状态参数的监测、估计和预测来控制、管理电池的充放电过程，以保持电池在不同环境下、不同操作条件下能够安全、可靠地运行，从而减少电池故障，延长电池寿命，确保系统安全可靠运行。

BMS 的组成与功能如图 3 所示，其是硬件组成与软件开发相结合的系统，集监测、预测、控制和通信于一体。电池管理单元(battery management unit, BMU)是 BMS 的基本单位，可实时监测数据并对电池 SOC、SOH 等状态量进行计算和预测，最后通过总线 CAN 总线方式与上位机通信。在异常状况下，可通过 BMS 控制电池系统进行必要的反应，如断开连接、隔离异常电池等^[6]。业内的技术研究和形成的 BMS 产品主要集中于电动汽车的动力电池管理。相对于电动汽车 BMS，电力储能系统 BMS 的发展有赖于储能产业规模的扩大，并且开发快速、高效、通用性好、可在线实现的预警策略和算法是利用 BMS 实现锂离子电池热失控预警的当务之急。

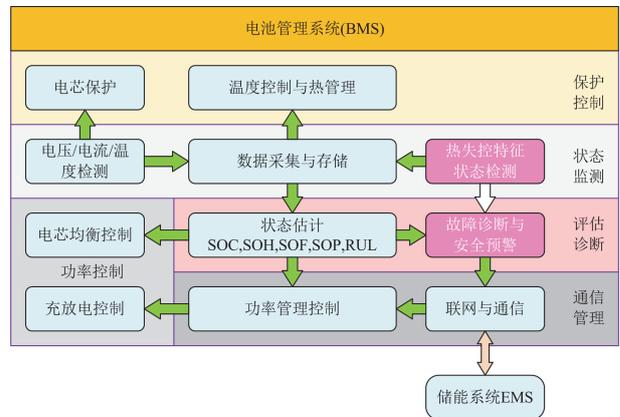


图3 锂离子电池管理系统的组成与功能

Fig. 3 Components and functions of BMS

2 电池安全管理中的机器学习方法

2.1 电池状态估计的机器学习方法

如前所述, BMS 的性能决定了锂离子电池储能电站的运营成本和运行效能^[8]。然而, BMS 中针对电池热失控风险的安全状态监测相关研究仍在发展阶段, 目前暂未形成如健康状态、预期寿命、热失控风险等标准状态描述参数, 多采用 SOC、SOH 等状态。

基于数据驱动的锂离子电池状态辨识和评估是一种新型电池管理技术, 主要是搭建一定的数学模型, 锂离子电池运行过程中通过 BMS、环境监测系统等采集的电池运行信息(电压、电流、温度等)作为模型输入并测算电池退化状态、预期寿命、健康状态等相关参数的一类方法。数据驱动建模能够为锂离子电池的安全管理提供基于历史和当前运行状态的运行预测, 对于应对电池老化劣化、预防电池滥用下的热失控等风险均有积极作用。因此, 近年来在储能系统锂离子电池安全评估应用中, 基于数据驱动的机器学习方法得到了长足进步, 其有效性得到了广泛的验证。

机器学习是人工智能(AI)和计算机科学的一个分支, 它专注于使用数据和算法来模仿人类的学习方式, 并逐步提高其准确性。1959 年 IBM 公司的亚瑟·塞缪尔(Arthur Samuel, 被誉为“机器学习之父”)就提出了机器学习的概念: 机器学习研究和构建的是一种特殊算法(而非某一个特定的算法), 能够让计算机自己在数据中学习从而进行预测。与传统方法相比, 机器学习方法具有明显优势: 1) 机器可以通过学习数据得到适合自身的细节, 减轻了人为设计的压力; 2) 当环境发生变化时, 机器可以通过学习对现有知识进行自动更新; 3) 如果外部信息足够丰富, 机器可以获得比人为设计更丰富的细节, 获得超过设计者想象的能力。

通常, 机器学习主要分为 3 类, 如图 4 所示。

1) 有监督学习。通过已有训练数据集进行数据挖掘, 获得最优模型, 借助模型将输入的所有数据向输出完全映射, 再较为简单地判断输出, 以此获得对未知数据进行分类的能力。

2) 无监督学习。亦为归纳性学习, 其思想核心是根据 K 学习方式来搭建中心, 再利用反复递减运算来缩减误差。无监督学习和有监督学习相比, 无需训练样本, 只需将未知的数据建模处理, 其中最常见的是聚类算法。

3) 强化学习。亦称为增强学习, 基于统计和动态规划技术方法, 输入通过反馈过程中计算得到的

数据信息, 与之相关有 Q-Learning 等。

可以看出, 有监督学习可适用于对电池健康因子的评估及趋势预测, 而无监督学习则适用于对电池异常状态的判定和区分。因此, 近些年来, 有相当多的研究团队探索将机器学习方法应用于储能电池的安全状态评估及预警, 以下对几类典型方法进行介绍。

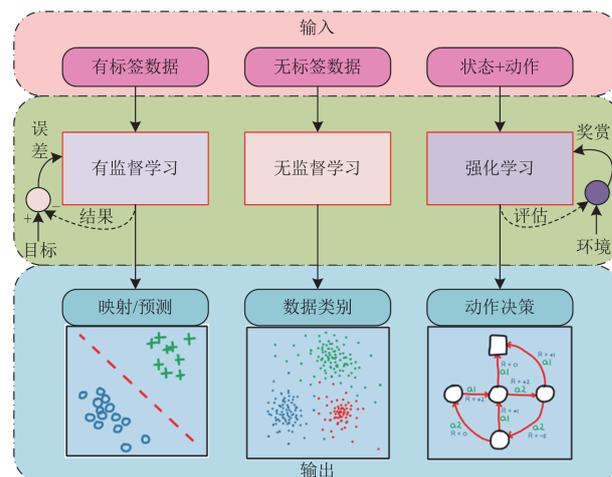


图 4 机器学习的 3 类基本方法

Fig. 4 Three types of method in machine learning

2.2 机器学习在电池安全评估中的典型应用

1) 状态空间统计滤波器

状态空间方法利用电化学模型或等效电路模型建立锂离子电池的荷电状态、负载电流与端电压的非线性动态关系, 构造状态空间方程, 并运用统计滤波器等进行电池特征参数估计。常用算法包括卡尔曼滤波(Kalman filter, KF)及其扩展方法、粒子滤波及其扩展方法等。卡尔曼滤波器的基本原理如图 5 所示。

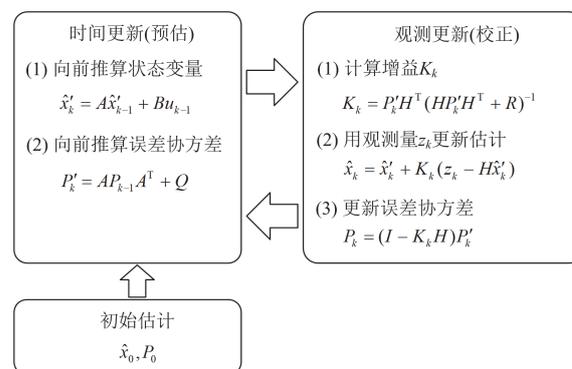


图 5 卡尔曼滤波器的基本原理

Fig. 5 Basic principle of Kalman filter

KF 方法支持线性系统的无偏最小误差方差最优估计。由于 KF 具有可以处理传感器噪声的特性,

其与锂离子电池的监测要求紧密契合，在锂离子电池荷电状态估计、健康预测等非线性问题中需要以泰勒近似方式对模型进行线性化处理，常见的如扩展卡尔曼滤波(EKF)^[8-9]、无迹卡尔曼滤波(UKF)^[10-11]、方差可变卡尔曼滤波(VVKF)^[12]和自适应扩展卡尔曼粒子滤波(AEKPF)^[13]等。

相较于传统的安时积分法、开路电压法或最小二乘法, KF 及其衍生模型对于电池 SOC 和 SOH 的估计更具优势。文献[9]设计了一种附加 RC 支路的改进 Thevenin 电池模型, 利用扩展卡尔曼滤波(EKF)算法确定了模型参数, 在此基础上设计了用于估计锂离子电池 SOC 的自适应 EKF(adapted EKF)方法, 并在联邦城市行车计划 (federal urban driving schedule, FUDS) 电池数据上取得了较好的 SOC 估算效果。文献[4]提出采用基于 SOC-OCV 曲线的 KF 预测方法, 通过可变参数电池建模及参数拟合建立基于参数可变 PNGV 模型的卡尔曼滤波 SOC 预测仿真模型。

在实际应用中, SOC、SOH、RUL 等特征值通常以耦合的方式加以分析, 如基于状态观测器的 SOC 和 SOH 联合估计流程、使用自适应扩展卡尔曼粒子滤波(AEKPF)与粒子滤波耦合的锂离子电池 SOC 和 SOH 的联合估计^[14]、采用 BP 神经网络补偿 EKF 算法实现 1 阶 RC 等效电路模型参数与 SOC 的在线联合估计等^[15]。多状态参数的联合估计方法能够提升电池 SOC、电池容量等单个特征值的预测精度。

2) 人工神经网络

人工神经网络(artificial neural network, ANN)是机器学习的重要技术, 它采用了仿生学的思想, 通过模拟生物神经网络的结构和功能来实现建模, 一般由输入层、隐层、输出层的典型结构组成。图 6 给出了用于电池健康评估的典型前馈 ANN 结构。

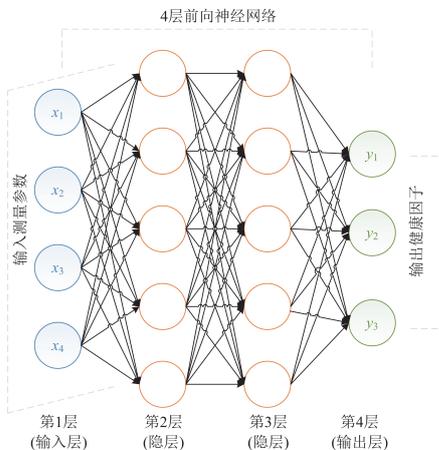


图 6 用于电池健康评估的前向神经网络

Fig. 6 A feed forward ANN for battery healthy evaluation

神经网络算法在电池状态预测领域的应用较多。在荷电状态预测方面, 文献[15]采用 BP 神经网络(BPNN), 以电池电压、电流和温度三项参数作为网络的输入, 并将通过安时计量法计算得到的 SOC 作为网络输出, 训练得到具有较好内插数据泛化性的网络。文献[16]提出了一种基于一维卷积神经网络(1D CNN)与长短期记忆(LSTM)循环神经网络(RNN)结合, 以电池电流、电压和电阻作为网络输入的电池 SOC 预测方法, 获得了相较 1D CNN 和 BPNN 更好的预测精度。文献[17]采用长短期记忆循环(long short-term memory, LSTM)神经网络(网络结构如图 7 所示)设计 SOC 预测模型, 并通过加入 Dropout 正则化方法降低网络的过拟合现象, 增强了模型的泛化能力。

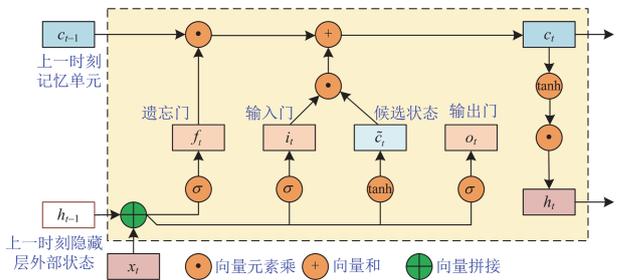


图 7 LSTM 网络结构

Fig. 7 Structure of LSTM ANN

在健康状态预测方面, 文献[18]采用深度卷积神经网络(DCNN)建立了锂离子电池的健康状态估计模型, 针对实际应用中可用训练样本数量少的问题, 采用迁移学习和集成学习理论实现了不同模型参数的迁移和集成, 提升了 SOH 估计精度。文献[19]利用非线性自回归算法, 对部分充电曲线开展电池单元 SOH 估计。

在电池寿命预测方面, 神经网络方法同样具有可行性, 如混合卷积神经网络(CNN)^[20]、递归神经网络(RNN)^[21]和空洞卷积神经网络(dilated CNN)等^[22-23]。文献[24]运用经验模态分解(empirical mode decomposition, EMD)方法将原始电池容量数据分解为若干本征模函数(intrinsic mode function, IMF)和残差, 并应用了长短时记忆(LSTM)子模型和高斯过程回归(GPR)子模型分别用于估计残差和拟合 IMF, 发现对于电池循环早期的 RUL 预测有较好的适应性。文献[20]通过结合三维和二维卷积神经网络构建了一种混合卷积神经网络(CNN)进行 RUL 预测, 并在不同充电策略下实现了较好的电池充放电循环寿命的早期预测和 RUL 估计。文献[25]建立了基于贝叶斯模型平均(Bayes model averaging, BMA)

和最优决策理论的 RUL 估计模型, 同样取得了较好的预测精度。文献[26]采用极限树(extra tree)和核支持向量回归(NuSVR), 在低至 1 个循环周期的较少循环次数基础上对不同负极材料的锂离子电池单体寿命作了预测, 并讨论了负极材料对估计精确度的影响。文献[27]建立了结合递归神经网络(RNN)与典型的单指数状态空间理论的 RUL 预测方法, 并在 NASA 电池退化数据集上取得了较好的估计性能, 在计算复杂度和精度上均优于其他双指数预测模型。文献[22]首次在 RUL 预测领域引入端到端机器学习方法, 并提出了一种基于空洞卷积神经网络(dilated CNN)的 RUL 预测模型。

3) 支持向量机

支持向量机(support vector machine, SVM)在 VC 维理论的基础上, 采用结构风险最小化作为最优准则, 能够获取全局最优解。SVM 克服了 ANN 存在局部极值、收敛速度慢、网络结构难以确定以及需要大样本进行训练等问题, 能够提高算法的泛化能力, 既能根据有限的训练样本得到小的误差, 又能够保证对独立的测试集仍保持小的误差, 并基于有限样本最终获取一个较小的预测误差。SVM 原理如图 8 所示。SVM 的计算复杂度明显比 ANN 方法要低得多。因此, SVM 及最小二乘支持向量机(LS-SVM)已经广泛应用于多种预测领域。

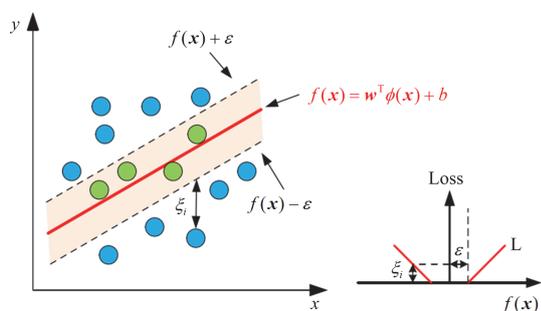


图 8 SVM 原理

Fig. 8 Principle of SVM

支持向量机及其衍生算法是常用的电池健康状态建模方法, 其基本思想是将低维线性不可分的一类问题通过核函数升维的方式映射至可找到线性可分超平面的高维空间。SVM 通过提取锂离子电池阶段性充电数据中隐含的退化特征, 基于样本数据训练和支持向量回归方法建立锂离子电池状态估计的非线性函数回归模型, 在对于小样本集的适用性、泛化能力等方面相较其他机器学习方法较有优势。

SVM 常用于锂离子电池状态和寿命的预测。对于荷电状态的预测, 文献[28]在最小二乘支持向量

机(LS-SVM)算法中引入粒子群优化算法(PSO)以提高训练效率与模型精度, 从而优化对不同健康状况电池 SOC 估计的泛化性能。文献[29]提出了一种基于 SVM 的锂离子电池 SOC 估算方法, 以电池在前一时刻的 SOC、电压、电流、温度作为当前时刻 SOC 的预测输入参数, 取得了基本符合实际工程应用的预测精度。

对于健康状态的预测, 文献[12]将 LS-SVM 作为噪声方差可变卡尔曼滤波(VVKF)的量测方程, 融合 KF 与 LS-SVM 提出一种 SOH 估计算法, 一定程度上规避了环境和工况波动对模型误差的不利影响, 提升了预测模型的精度和泛化性。文献[6]建立了锂离子电池恒压充电过程的电流曲线时间常数与恒压充电电荷量等老化特征与电池放电过程内阻测量值的非线性映射关系, 提出了电池的状态空间模型, 并基于粒子滤波算法的参数估计原理给出了 SOH 估计与电池剩余寿命(RUL)预测方法。

4) 高斯过程回归

高斯过程回归(Gaussian process regression, GPR)可以给出预测结果的不确定性表达, 是一种灵活的非参数模型, 能够实现任意线性或者非线性系统动态行为特征的建模预测, 并且可以结合状态预测先验知识, 实现基于贝叶斯框架下的状态预测。

基于 GPR 的锂离子电池 RUL 预测不需要结合实际电池模型, 而是采用高斯过程模拟电池的行为, 是一种概率式的预测方法。文献[30]利用电池等效电路元件阻抗 $R_E + R_{CT}$ 与电池剩余容量的关系, 基于 GPR 算法对电池阻抗 $R_E + R_{CT}$ 进行预测, 随后间接推算容量及 RUL 预测结果, 同步可以输出预测值的均值和方差, 给出预测结果的置信区间, 表达预测结果的不确定性。文献[31]采用指数平方协方差和周期平方协方差模拟电池行为, 通过超参数调整, 实现锂离子电池的剩余寿命预测, 同时给出 RUL 预测的置信区间。文献[32]为了提高 SOC 估计精度, 提出了基于 GPR 的锂离子电池在线估计方法, 将电流、电压、温度作为 GPR 模型的输入, SOC 作为模型的输出, 并利用梯度下降法进行参数寻优, 试验表明估计精度高于 SVM、LSSVM、神经网络等方法。

GPR 方法的主要缺点是超参数调整复杂, 计算量较大, 对于在线应用尚需深入研究。

2.3 电池安全评估的特征工程

特征工程是机器学习的关键步骤, 就是将原始数据转换为模型更容易理解的数据类型, 从而提高机器学习模型的预测准确率, 其主要包括 3 方面: 特征处理、特征选择和特征生成。电池的状态参数通常无法直接在线测量, 因此需要建立可测量参数

与关键状态量之间的映射模型，而输入特征的选择关系到模型的精确性。以 SOC 估计任务为例，由于电池的荷电状态与电压、电流、温度等参数密切相关，因此大部分文献选择 V 、 I 、 T 作为输入特征，每一个时刻的 SOC 都与当前的 V 、 I 、 T 和上一时刻的 SOC 相关，因此模型的输入为电池在每一时刻的 V 、 I 、 T ，输出为当前状态的 SOC。状态模型的典型输入为放电阶段电压、电流、温度、时间等序列的组合，直接输入可测量数据能最大程度地保留原始信息，但也会导致模型的冗余，同时对在线应用的数据采集提出了更高的要求。

电池作为丰富的数据源，蕴含大量不同类型、不同时间尺度的数据，为深度学习模型的训练提供了条件。通常可以选择原始的电压、电流、温度数据作为输入，采用深度学习分别进行电池的健康状态和剩余寿命的预测。模型的训练样本仍为电池的每一圈循环，只是输入为原始的电压、电流、温度等向量，与选择表征电池老化的特征作为输入不同，深度学习模型能从原始的数据中自动提取特征，避免了人工的特征选择。虽然深层神经网络具有从原始数据中提取深层特征的能力，但也意味着多维的原始数据需要更大的网络去拟合。网络的规模越大，所需要的训练数据也越多，计算量也更大。由统计学习

算法实现的人工智能可以从人类的监督中获益，即根据人类领域知识的初步特征选择可以提升机器学习算法的性能。因此许多学者都在探索将电池的特征选择与深度学习结合的状态估计模型，在保证深度神经网络的拟合精确性与计算速度的前提下，通过基于先验领域知识的特征选择降低网络的规模。

电池的状态可以通过特定的电化学测试手段进行表征^[33]。文献[34]使用电池的阻抗谱(electrochemical impedance spectroscopy, EIS)作为 GPR 模型的特征输入，估计电池的容量和剩余寿命。文献[35]选择电池的容量增量分析(incremental capacity analysis, ICA)图中电压区间的采样值作为 GPR 模型的输入特征，建立 ICA 的特征与 SOH 之间的映射。ICA 能从降解机理上解释电池的老化，但是要求获得特定 SOC 区间的电压数据，并且 ICA 测试需要特定的低倍率充放电，难以在线应用。上述方法的算法结构如图 9 所示，输出分别为电池 SOC(图 9(a))、SOH(图 9(b))、电池容量(图 9(c))或 RUL(图 9(d))等，输入则为特定的电化学测试特征。这些特征一般能从机理上对电池的状态进行解释，但同时一般需要特殊的测试手段，如何在线测试特征并建立鲁棒的模型是目前的一个研究方向^[36-37]。

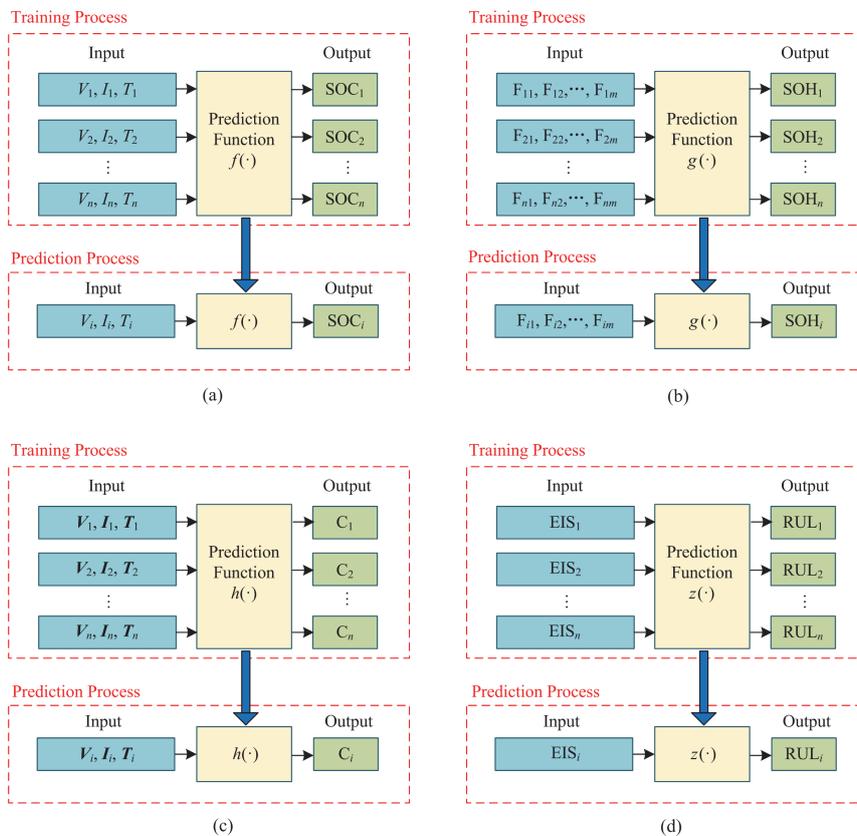


图 9 电池状态预测的特征选取方法

Fig. 9 Feature selections of different state estimation for batteries

2.4 挑战与展望

纵观现有的文献可知, 电池安全评估的机器学习方法均需要考虑应用场景来选择输入特征和学习模型。输入特征需要便于在线提取应用, 并且能在一定程度上反映电池的电化学机理。模型需要考虑训练数据的量、不确定性管理、精度要求和计算复杂度等问题。不同模型的特性总结如表 1 所示。

表 1 锂离子电池安全管理中的机器学习方法对比

Table 1 Comparison of machine learning methods in safety management of li-ion battery energy storage

建模方法	评估状态	优势	劣势	参考文献
Kalman Filter	SOC、SOH、内短路、内阻	计算实时性强; 可转化为线性问题求解	对电池模型准确性要求较高; 具有一定线性化误差	[8-15]
			模型训练对实验数据量要求高	
ANN	SOC、SOH、RUL	对电化学模型要求低; 适用于非线性系统问题	网络训练算力要求高	[15-27]
SVM	SOC、SOH	小训练样本集情况下具有较好推广性; 适用于解决非线性系统问题	模型训练对实验数据量要求高	[6,12, 28-29]
GPR	RUL、SOC、SOH	可得到预测置信区间, 关于预测点值的概率分布	超参数调整复杂, 计算量较大	[30-35]

经过数十年研究, 锂离子电池的滥用及退化机理研究已臻完善, 基于机器学习的锂离子电池安全状态估计技术已逐渐被学术界和工业界接受和认可。围绕电池滥用与退化机理、电池状态估计和电池管理系统, 对现有研究进展挑战和未来研究有如下总结:

1) 基于机器学习的储能电站锂离子电池 SOC、SOH、RUL 等参数只能以其他测得数据通过算法计算而得, 缺乏更加直接的以物理或电化学模型描述, 也缺乏通过非侵入手段直接测量电池健康状态量的手段。未来, 通过优化锂离子电池电化学模型、改进实验方法等, 并将数据驱动与模型驱动方法相结合, 从而实现更精确的电池健康与安全状态评估。

2) 目前通过数据驱动的机器学习模型评估电池健康状态的研究大多采用十余个机构的公开的电池数据或者实验室测试数据, 储能电站及其不同运行状态下的实测数据较少, 缺乏储能电站特殊工况的电池运行数据, 模型的准确性、适用性受限实验室测试条件。未来在该领域的研究中, 可通过发展工业大数据平台、深化云边协同计算来丰富储能

运维数据基础, 以期得到对我国储能电站更具普适性的模型。

3) 锂离子电池 BMS 作为电池运行状态的监测设备, 未来将纳入更多的数据分析和机器学习功能。由于储能等其他场景下锂离子电池规模的制约, 其他方向的 BMS 研究较少, 其技术路线也基本沿用动力电池 BMS。由于不同应用中的电池参数和运行工况差异较大, 需针对储能电站工况和环境特点设计适应性更强的细分领域 BMS。如果要开发普适性较强的 BMS, 则应具有灵活的自定义程序, 通过对大量运行工况数据的采集分析, 支持通过改变关键参数达到对不同电池的高效准确管理。

3 结语

本文围绕锂离子电池安全管理系统中的机器学习方法进行了较为全面的分析和探讨, 主要结论如下:

1) 电池安全核心问题来自于因电池滥用而导致的热失控过程, 从 BMS 实时测量数据出发, 利用机器学习方式可以实现对电池安全特性进行早期评估和预警。

2) 因储能系统中电池类型多样化、运行数据不完整、运行工况各异, 现有用于电池安全状态评估的机器学习方法仍然存在着不足, 亟需不断完善。

3) 储能电站 BMS 功能的优化在于将预测和实测相结合, 并且逐步以实测数据对既有机器学习算法进行优化, 以期达到对电池实时状态的跟踪预测。

参考文献

- [1] 黄沛丰. 锂离子电池火灾危险性及热失控临界条件研究[D]. 合肥: 中国科学技术大学, 2018.
HUANG Peifeng. Research on the fire risk of lithium ion battery and the critical condition of thermal runaway behavior[D]. Hefei: University of Science and Technology of China, 2018.
- [2] 胡广, 廖承林, 张文杰. 车用锂离子电池热失控研究综述[J]. 电工电能新技术, 2021, 40(2): 66-80.
HU Guang, LIAO Chenglin, ZHANG Wenjie. A review on thermal runaway of lithium-ion batteries for electric vehicle[J]. Advanced Technology of Electrical Engineering and Energy, 2021, 40(2): 66-80.
- [3] 张元星, 李斌, 颜湘武, 等. 基于电池模型的电动汽车充电故障监测与预警方法[J]. 电力系统保护与控制, 2021, 49(10): 143-154.
ZHANG Yuanxing, LI Bin, YAN Xiangwu, et al. Monitoring and early warning method of EV charging failure based on a battery model[J]. Power System Protection and Control, 2021, 49(10): 143-154.

- [4] 欧阳佳佳. 储能电池管理系统研究[D]. 杭州: 浙江大学, 2016.
OUYANG Jiajia. Research on energy storage battery management system[D]. Hangzhou: Zhejiang University, 2016.
- [5] SPOTNITZ R, FRANKLIN J. Abuse behavior of high-power, lithium-ion cells[J]. *Journal of Power Sources*, 2003, 113(1): 81-100.
- [6] 魏婧雯. 储能锂离子电池系统状态估计与热故障诊断研究[D]. 合肥: 中国科学技术大学, 2019.
WEI Jingwen. Research on states estimation and thermal fault diagnostics of lithium-ion battery based energy storage system[D]. Hefei: University of Science and Technology of China, 2019.
- [7] FENG Xuning, OUYANG Minggao, LIU Xiang, et al. Thermal runaway mechanism of lithium ion battery for electric vehicles: a review[J]. *Energy Storage Materials*, 2018, 10: 246-267.
- [8] 许守平, 侯朝勇, 胡娟, 等. 大规模储能用锂离子电池管理系统[J]. *电力建设*, 2014, 35(5): 72-78.
XU Shouping, HOU Chaoyong, HU Juan, et al. Li-ion battery management system for large-scale energy storage[J]. *Electric Power Construction*, 2014, 35(5): 72-78.
- [9] HE Hongwen, XIONG Rui, ZHANG Xiaowei, et al. State-of-charge estimation of the lithium-ion battery using an adaptive extended Kalman filter based on an improved Thevenin model[J]. *IEEE Transactions on Vehicular Technology*, 2011, 60(4): 1461-1469.
- [10] 孔祥创, 赵万忠, 王春燕. 基于BP-EKF算法的锂离子电池SOC联合估计[J]. *汽车工程*, 2017, 39(6): 648-652.
KONG Xiangchuang, ZHAO Wanzhong, WANG Chunyan. Co-estimation of lithium battery SOC based on BP-EKF algorithm[J]. *Automotive Engineering*, 2017, 39(6): 648-652.
- [11] 董祥祥, 武鹏, 葛传久, 等. 基于自适应无迹卡尔曼滤波的锂离子电池荷电状态估计[J]. *电工电能新技术*, 2021, 40(2): 58-65.
DONG Xiangxiang, WU Peng, GE Chuanjiu, et al. State of charge estimation of li-ion battery based on adaptive unscented Kalman filter[J]. *Advanced Technology of Electrical Engineering and Energy*, 2021, 40(2): 58-65.
- [12] 赵天意. 基于改进卡尔曼滤波的锂离子电池状态估计方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
ZHAO Tianyi. Lithium-ion battery state estimation method based on improved Kalman filter[D]. Harbin: Harbin Institute of Technology, 2016.
- [13] 张新锋, 姚蒙蒙, 宋瑞, 等. 基于AEKPF算法对锂离子电池SOC与SOH的联合估计[J]. *江苏大学学报(自然科学版)*, 2022, 43(1): 24-31.
ZHANG Xinfeng, YAO Mengmeng, SONG Rui, et al. Joint estimation of SOC and SOH for li-ion battery based on AEKPF algorithm[J]. *Journal of Jiangsu University (Natural Science Edition)*, 2022, 43(1): 24-31.
- [14] WANG Y, TIAN J, SUN Z, et al. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems[J]. *Renewable and Sustainable Energy Reviews*, 2020.
- [15] 廖恩华. 基于神经网络的电动汽车磷酸铁锂离子电池SOC估算方法研究[D]. 成都: 电子科技大学, 2011.
LIAO Enhua. SOC estimation method for EV lithium-ion battery based on neural network[D]. Chengdu: University of Electronic Science and Technology of China, 2011.
- [16] 倪水平, 李慧芳. 基于一维卷积神经网络与长短期记忆网络结合的电池荷电状态预测方法[J]. *计算机应用*, 2021, 41(5): 1514-1521.
NI Shuiping, LI Huifang. Battery state-of-charge prediction method based on one-dimensional convolutional neural network combined with long short-term memory network[J]. *Journal of Computer Applications*, 2021, 41(5): 1514-1521.
- [17] 明彤彤, 王凯, 田冬冬, 等. 基于LSTM神经网络的锂离子电池荷电状态估算[J]. *广东电力*, 2020, 33(3): 26-33.
MING Tongtong, WANG Kai, TIAN Dongdong, et al. Estimation on state of charge of lithium battery based on LSTM neural network[J]. *Guangdong Electric Power*, 2020, 33(3): 26-33.
- [18] SHEN S, SADOUGHI M, CHEN X, et al. A deep learning method for online capacity estimation of lithium-ion batteries[J]. *The Journal of Energy Storage*, 2019, 25.
- [19] KHALEGHI S, KARIMI D, BEHESHTI S H, et al. Online health diagnosis of lithium-ion batteries based on nonlinear autoregressive neural network[J]. *Applied Energy*, 2011, 282.
- [20] YANG Y. A machine-learning prediction method of lithium-ion battery life based on charge process for different applications[J]. *Applied Energy*, 2021, 292.
- [21] CATELANI M, CIANI L, FANTACCI R, et al. Remaining useful life estimation for prognostics of lithium-ion batteries based on recurrent neural network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70.
- [22] THOMAS J K, CRASTA H R, KAUSTHUBHA K, et al. Battery monitoring system using machine learning[J]. *The Journal of Energy Storage*, 2021, 40(1-2).

- [23] HONG J, LEE D, JEONG E R, et al. Towards the swift prediction of the remaining useful life of lithium-ion batteries with end-to-end deep learning[J]. Applied Energy, 2020, 278.
- [24] LIU K, SHANG Y, OUYANG Q, et al. A data-driven approach with uncertainty quantification for predicting future capacities and remaining useful life of lithium-ion battery[J]. IEEE Transactions on Industrial Electronics, 2021, 68(4): 3170-3180.
- [25] WANG Fujin, ZHAO Zhibin, REN Jiaxin, et al. A transferable lithium-ion battery remaining useful life prediction method from cycle-consistency of degradation trend[J]. Journal of Power Sources, 2022, 521.
- [26] PAULSON N H, KUBAL J, WARD L, et al. Feature engineering for machine learning enabled early prediction of battery lifetime[J]. Journal of Power Sources, 2022, 527.
- [27] CATELANI M, CIANI L, FANTACCI R, et al. Remaining useful life estimation for prognostics of lithium-ion batteries based on recurrent neural network[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70.
- [28] 盛瀚民, 肖建, 贾俊波, 等. 最小二乘支持向量机荷电状态估计方法[J]. 太阳能学报, 2015, 36(6): 1453-1458. SHENG Hanmin, XIAO Jian, JIA Junbo, et al. Estimation method for state of charge based on least square support vector machine[J]. Acta Energiæ Solaris Sinica, 2015, 36(6): 1453-1458.
- [29] 骆秀江, 张兵, 黄细霞, 等. 基于 SVM 的锂离子电池 SOC 估算[J]. 电源技术, 2016, 40(2): 287-290. LUO Xiujiang, ZHANG Bing, HUANG Xixia, et al. Estimation of lithium battery SOC based on SVM[J]. Chinese Journal of Power Sources, 2016, 40(2): 287-290.
- [30] KAI G, SAHA B, SAXENA A, et al. Prognostics in battery health management[J]. IEEE Instrumentation & Measurement Magazine, 2008, 11(4): 33-40.
- [31] LIU D, PANG J, ZHOU J, et al. Prognostics for state of health estimation of lithium-ion batteries based on combination Gaussian process functional regression[J]. Microelectronics Reliability, 2013, 53(6): 832-839.
- [32] 李嘉波, 魏孟, 叶敏, 等. 基于高斯过程回归的锂离子电池 SOC 估计[J]. 储能科学与技术, 2020, 9(1): 166-172. LI Jiabo, WEI Meng, YE Min, et al. SOC estimation of lithium-ion batteries based on Gauss process regression[J]. Energy Storage Science and Technology, 2020, 9(1): 166-172.
- [33] 孙丙香, 苏晓佳, 马仕昌, 等. 基于低频阻抗谱和健康特征融合的锂离子电池健康状态主动探测方法研究[J]. 电力系统保护与控制, 2022, 50(7): 23-30. SUN Bingxiang, SU Xiaojia, MA Shichang, et al. An active detection method of li-ion battery health state based on low-frequency EIS and health feature fusion[J]. Power System Protection and Control, 2022, 50(7): 23-30.
- [34] ZHANG Y, TANG Q, ZHANG Y, et al. Identifying degradation patterns of lithium ion batteries from impedance spectroscopy using machine learning[J]. Nature Communications, 2020, 11(1): 1-6.
- [35] LI Xiaoyu, YUAN Changgui, LI Xiaohui, et al. State of health estimation for li-ion battery using incremental capacity analysis and Gaussian process regression[J]. Energy, 2022, 190.
- [36] 黄志亮, 王怀兴, 阳同光, 等. 储能锂离子电池包单体内部温度压力模拟[J]. 电力系统保护与控制, 2022, 50(15): 138-146. HUANG Zhiliang, WANG Huaixing, YANG Tongguang, et al. Simulation of internal temperature and pressure for cells in an energy storage lithium-ion battery[J]. Power System Protection and Control, 2022, 50(15): 138-146.
- [37] 吕超, 张爽, 朱世怀, 等. 储能锂离子电池包强制风冷系统热仿真分析与优化[J]. 电力系统保护与控制, 2021, 49(12): 48-55. LÜ Chao, ZHANG Shuang, ZHU Shihuai, et al. Thermal simulation analysis and optimization of forced air cooling system for energy storage lithium-ion battery pack[J]. Power System Protection and Control, 2021, 49(12): 48-55.

收稿日期: 2021-03-31; 修回日期: 2021-08-25

作者简介:

蔡涛(1974—), 男, 通信作者, 博士, 副教授, 研究方向为储能系统管理与充放电控制; E-mail: caitao@hust.edu.cn

张钊诚(2002—), 男, 学士, 研究方向为电气工程及其自动化; E-mail: 2274325116@qq.com

袁奥特(1999—), 男, 硕士研究生, 研究方向为储能电池安全管理与高效充放电. E-mail: 462098649@qq.com

(编辑 魏小丽)