

锂离子电池健康状态估计及寿命预测研究进展综述

熊庆, 邸振国, 汲胜昌

(西安交通大学电工材料电气绝缘全国重点实验室, 西安 710049)

摘要: 随着锂离子电池的应用越来越广泛, 锂电池健康状态的精确估计和剩余寿命的实时预测对于锂电池系统的安全运行和降低运维成本具有重要意义。锂电池内部复杂的物理化学反应和外部复杂工作条件, 使得实现精准的健康状态估计和寿命预测具有挑战性。该文综述近年来锂电池健康状态估计和剩余使用寿命预测方法的研究现状, 分析基于物理/数学模型、数据驱动、模型法和数据驱动融合, 以及多种数据驱动融合的锂电池健康状态估计方法的优缺点及适用条件, 并对比分析不同数据驱动类型的锂电池寿命预测方法。指出锂电池健康状态估计及寿命预测尚存在的问题, 并对未来研究方向进行展望, 对完善锂电池健康状态估计和寿命预测算法理论体系、指导实际应用技术具有重要意义。

关键词: 锂离子电池; 状态估计; 寿命预测; 电化学模型; 数据驱动技术

Review on Health State Estimation and Life Prediction of Lithium-ion Batteries

XIONG Qing, DI Zhenguo, JI Shengchang

(State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: With the increasing application of the Lithium-ion batteries (LIBs), the accurate estimation of state-of-health (SOH) and real-time prediction of the remaining life of an LIB are of great significance to the safe operation of the LIB system and the reduction of the maintenance cost. The complex physical and chemical reactions inside the LIB and the outside complex operating conditions make it a challenge to achieve accurate SOH estimation and life prediction. Consequently, we reviewed the research status of methods for the LIB SOH estimation and the remaining useful life (RUL) prediction in recent years. We analyzed the advantages and disadvantages of the LIB SOH estimation methods and suitable conditions based on the physical/mathematical model, the data driven, the fusion of model and data driven, and the fusion of multiple data driven methods. We analyzed and compared the LIB life prediction methods of three different data-driven types. Moreover, we pointed out the existing problems of the LIB SOH estimation and the life prediction, and put forward prospects in the future research directions. The conclusions can improve the theoretical system of the LIB SOH estimation and life prediction algorithm and have important significance for the practical application technology.

Key words: lithium-ion battery; state estimation; life prediction; electrochemical model; data driven technology

0 引言

随着可再生能源和分布式储能的迅速发展以及“碳达峰、碳中和”目标的提出, 电动汽车和储能电站应用前景广阔。中国汽车工业协会数据显示, 仅 2021 年上半年, 全球电动汽车销量超 250 万辆。与 2020 年全年 312.5 万辆相比, 电动汽车销量出现爆发式增长^[1]。电化学储能是解决电动汽车能源问题的重要技术^[2]。相比于铅酸电池、镍镉电池等,

锂离子电池(lithium-ion battery, LIB)由于其高能量密度、低自放电率、长使用寿命、无记忆和环境友好等卓越性能, 在动力电池和储能电池技术中占据主导地位, 广泛应用于民用及军工领域^[3-4]。

锂离子电池在其充放电循环过程中, 其内部会发生不可逆的物理化学过程, 形成固体电解质中间相(solid-electrolyte interphase, SEI)^[5]。活性锂的丢失和恶劣的外部工作条件(例如高温或低温环境)严重影响了电池内部电化学反应, 导致电池内阻升高和容量持续下降, 这一现象称为电池退化^[6]。电池退化会带来电池性能下降、电池使用寿命缩短等一系列安全与可靠性问题, 甚至导致用电设备性能下降或系统故障, 引发火灾爆炸事故。据不完全统计,

基金资助项目: 国家自然科学基金(52007149); 电工材料电气绝缘全国重点实验室资助(EIPE22123); 碑林区科技计划(GX2226)。Project supported by National Natural Science Foundation of China (52007149), State Key Laboratory of Electrical Insulation and Power Equipment (EIPE22123), Science and Technology Project of Beilin District (GX2226).

从 2011 年到 2021 年这 10 年间, 全球共计发生 32 起储能电站爆炸起火事故。其中, 25 起事故是在锂电池储能电站中发生的^[7]。因此, 对电池进行准确的健康状态估计和剩余使用寿命预测对延长电池的使用寿命、降低系统维护成本和保障系统安全运行具有重要意义。

电池管理系统(battery management system, BMS)通过控制充放电循环来监测电池状态和参数以保证电池耐久性^[8]。其中状态包括电池电压、电流、温度、荷电状态(state of charge, SOC)、电源状态、健康状态等。健康状态(state of health, SOH)和剩余使用寿命(remaining useful life, RUL)作为 BMS 最基础的指标, 无法通过传感器直接测量。利用可测量参量对锂离子电池的 SOH 和 RUL 进行精准估计和预测成为多学科交叉的研究热点, 受到国内外学者的广泛关注。

国内外研究人员针对锂离子电池健康状态估计和寿命预测方法开展了大量的研究, 获得了许多成果。本文综述锂电池 SOH 估计和 RUL 预测方法的研究进展, 对比阐述不同估计和预测方法的特点与不足, 梳理目前研究中尚存在的问题, 并提出对未来工作的展望, 以利于锂电池安全性发展, 提高其可靠性。

1 锂离子电池 SOH 估计方法

SOH 常用电池内阻或容量来定义^[9], 按电池容量衰减定义为锂电池实时容量 Q_0 与额定容量 Q_N 的比值, 健康状态 S_{SOH} 计算式如式(1)所示。与 SOC 描述电池剩余存储电荷不同, SOH 表征电池退化水平, 且随着使用时间或循环次数的增加而减小。

$$S_{SOH} = \frac{Q_0}{Q_N} \quad (1)$$

SOH 与电池内部复杂的电化学反应有关^[10]。研究表明, 锂电池老化的具体机理可以归结为发生在锂离子电池阳极的副反应消耗大量锂离子和电解质溶剂, 形成不可溶解的 SEI 中间相。同时, 副反应产物在阳极与隔膜界面聚集形成沉积层堵塞孔隙, 隔离了阳极材料参与反应导致“死锂”的产生。随着 SEI 和沉积层的不断增大, 加速了活性锂和电池容量的损失, 最终导致 SOH 下降^[11]。活性锂的损失具有时变性和非线性, 使得依赖于电池的动态运行条件很难准确确定电池的化学过程。因此, 无法通过直接测量电池容量或内阻判断电池的 SOH。在

电池退化过程中, 通常伴随着松弛效应的发生。松弛效应是指当锂电池容量下降到阈值时的容量再生现象^[12]。容量再生是电池衰退的“自我充电”过程, 表现为电池在下一周期的容量明显高于前一周期, 同时之后出现加速退化的现象。在进行电池 SOH 估计时需特别注意容量再生现象造成的干扰。

国内外研究人员针对电池 SOH 估计方法开展了大量研究。估计方法可以分为基于物理/数学模型的方法、数据驱动的方法、模型与数据驱动融合以及多种数据驱动融合的方法, 如图 1 所示。

1.1 基于模型的方法

电池的物理模型又称为“白盒模型”, 描述电池内部的扩散、迁移和反应动力学。基于物理模型的方法首先通过搭建空间状态模型表征电池内部电化学反应机理或外部电行为特征, 通常需要利用非线性状态估计器或自适应滤波技术, 如卡尔曼滤波(Kalman filtering, KF)^[13]和粒子滤波(particle filter, PF)^[14]更新所建立模型的参数, 在电池 SOH 估计方面具有较高的准确性。基于数学模型的方法则构建与电池容量退化相关量(如增量容量或开路电压等)的数学方程或描述相关量变化的函数曲线, 通过对数学特征进行拟合分析或利用深度学习算法提取曲线中的健康因子, 揭示锂电池内部的健康状态。

1.1.1 物理模型

物理模型可进一步分为电化学模型(electrochemical model, EM)和等效电路模型(equivalent circuit model, ECM)。基于 EM 的方法利用复杂偏微分方程模拟电池内部发生的电化学反应过程, 有助于了解电池潜在的退化机制, 在固有物理表征方面优于 ECM。而基于 ECM 的方法使用

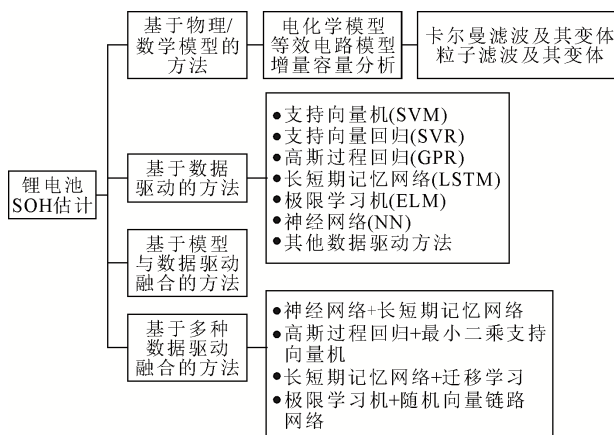


图 1 锂电池 SOH 估计方法分类

Fig.1 Classification of SOH estimation methods for LIB

电阻、电容等电路元件描述电池的动态行为，其准确性受等效电路开发过程中采取的假设的影响。锂电池的一阶戴维宁等效电路如图 2 所示，图中 U_0 为电池的端电压， U_{soc} 为电池静置时的开路电压， R_0 为欧姆内阻，极化电阻 R_1 和极化电容 C_1 组成的回路代表电池内的极化过程， U_c 为极化电压。

1) 电化学模型

德国亚琛工业大学 Hosseininasab S. 等人提出了一种基于分数阶电池 EM 模型的估计方法，同时以电池容量和内阻作为健康因子估计 SOH。首先从控制伪二维模型的偏微分方程推导出分数阶电池模型。其次，采用基于迭代模型的观测器进行电阻估计，实现对电池容量和电阻的自适应估计。最后，利用不同老化程度、动态负载分布和初始化误差的实验数据验证了新方法的有效性。该方法避免了由于校准参数少而导致的高计算成本，同时保持了较高的估计精度^[15]。美国奥本大学 Bi Y. 等人提出了一种基于降阶电化学生命周期模型的 SOH 和老化参数在线估计方法。该模型由伪二维模型和两种副反应(SEI 形成和镀锂)的退化模型组成。通过重构递归老化模型，并利用实时电流和终端电压测量的粒子滤波，实现了 SOH 和老化参数的估计，从而能够预测由于体积和局部老化机制造成的电池失效。实验验证了所提出方法在不同温度下容量和功率衰退的估计误差分别在 3% 和 4% 以内^[16]。

上海交通大学高一钊等人提出了一种基于增强型降解电化模型和双非线性滤波器的锂电池 SOH 估计方法。充分考虑了锂离子损失、活性材料丢失和内阻增加 3 个关键退化因素。实验结果表明，当 SOH 在 71%~100% 范围内时，估计结果保持较高的准确性，在范围之外存在较大误差的原因可能是未考虑温度的影响^[11]。东南大学徐志成等人提出了一种基于简化电化模型的锂电池 SOH 估计方法。采用一个极简电化模型来描述电池内部锂含量的分布，并将 SOH 与锂的不可逆损耗相关联。利用递归最小二乘在线识别模型参数，无迹卡尔曼滤波器估计电池状态。实验结果表明，该方法估计平均误差在 2% 左右^[17]。

2) 等效电路模型

巴基斯坦拉合尔管理科学大学 Amir S. 等人提出了一种基于动态等效电路模型估计电池 SOH 的方法。该模型将开路电压(open-circuit voltage, OCV) 视为 SOC 的函数，采用非线性最小二乘曲线拟合逼




图 2 锂电池一阶戴维宁等效电路

Fig.2 First-order Thevenin equivalent circuit model of LIB

近模型参数，模型能适应并捕捉 SOH 动态变化，且反映了温度对电池退化的影响。结果表明，该模型能在较低的均方根误差(root mean square error, RMSE)下实现 SOH 估计。所提出的 2-RC 模型较 1-RC 模型计算复杂度降低，且性能优于 N-RC 模型^[18]。

江苏大学杨驹丰等人在简化二阶 RL 网络 ECM 基础上，提出了一种基于恒流充电电流解耦动态特性的 SOH 估计方法。与传统非线性最小二乘法相比，该文提出的动态解耦方法具有较低的计算量和较高的参数识别精度。值得注意的是，虽然使用归一化健康因子(health indicator, HI)可以减少由于电池不一致性对 SOH 估计精度的影响，但实验结果表明，估计的电池容量与实际容量之间仍存在明显差异^[19]。西安交通大学陈猛等人选用一阶 RC 等效电路为基础，利用电池欧姆内阻、极化内阻与极化电容构造多因子等效电路模型。通过 KF 在线辨识模型参数，提出了基于多因子 ECM 的综合 SOH 估计方法。该方法对同一型号电池的估计误差在 1% 左右，但对不同型号电池的泛化性需进一步研究^[20]。

1.1.2 数学模型

增量容量分析(incremental capacity analysis, ICA)方法是一种数学模型方法，其中包含的与电池容量高度相关的特征被广泛应用于锂电池 SOH 估计^[21]。增量容量与开路电压之间的关系为：

$$\left. \frac{dQ}{dU_{oc}} \right|_k \approx \frac{\Delta Q_k}{\Delta U_{oc,k}} = \frac{Q_k - Q_{k-1}}{U_{oc,k} - U_{oc,k-1}} \quad (2)$$

式中： Q 为实测的电池容量； U_{oc} 为实测的电池开路电压； ΔQ_k 为第 k 个循环周期与上一个循环周期实测电池容量之差； $\Delta U_{oc,k}$ 为第 k 个循环周期与上一个循环周期实测电池开路电压之差； Q_k 为第 k 个循环周期后的电池容量； $U_{oc,k}$ 为第 k 个循环周期后的电池开路电压。

典型的 IC 曲线如图 3 所示，其表示电池充放电过程中容量随电压的变化速率^[22]。可以看出，IC 曲线的峰值随循环次数的增加呈下降趋势，表明电




图3 不同循环次数下的增量容量曲线

Fig.3 Incremental capacity curves under different cycles

池活性物质损失。通过提取 IC 曲线中的特征,可以揭示电池内部的健康状态。如 IC 曲线的峰值面积、位置和幅度的演变与电池内部的锂化和脱锂过程的相关性和平衡密切相关。因此,可利用 ICA 来评估锂离子电池的老化状态。特别地,在某些情况下,IC 曲线变化剧烈的区域可选择多个特征点以降低随着电池老化而失去单一特征的风险。

瑞典皇家理工学院边小雷等人提出了一种开路电压模型和 ICA 结合的锂电池 SOH 估计方法。通过重构搭建的 OCV 模型得到无干扰的 IC 曲线,提取与 SOH 相关性强的特征实现 SOH 估计。实验结果表明,该方法在部分充电条件下对不同类型的锂电池均可进行 SOH 准确估计^[23]。意大利萨勒诺大学 Ospina A. B. 等人分析了从大电流 IC 曲线中提取的 3 个峰值特征与电池容量之间的相关性,证明了以大电流 IC 曲线主峰下的面积作为健康因子的鲁棒性。在电池使用寿命范围内,即从电池初始容量的 100% 下降到 80%,主峰面积与电池满容量呈线性关系。将该方法与基于欧姆电阻的 SOH 估计方法进行比较,结果表明其具有更高的推广潜力,适用于智能电网等综合能源系统中锂电池的状态估计。此外,所提出的估计方法所需计算量较小,能够在低成本设备上实现^[24]。

四川大学孟锦豪等人综合评估了 ICA 作为 SOH 估计和识别潜在退化机制工具的潜力。通过加速循环试验研究了老化、电流、温度对 ICA 估计精度的影响。结果表明,即使在较大电流和高温条件下,ICA 仍是估计二次电池生命周期 SOH 很有前景的方法^[25]。武汉理工大学杨胜杰等人通过实验发现

SOH 对 IC 曲线不同峰值区间的健康因子敏感程度不同。在不同电池的各自敏感区间内进行 SOH 估计具有较高准确性^[26]。

在电池建模准确的前提下,基于物理/数学模型的方法可以精确地估计电池的 SOH。模型法能够较好地解释电池内部复杂的电动力学过程。然而,为了准确地模拟电池,研究人员通常需要对电池的电化学特性有一个全面、深入的了解,对于较为复杂的电池系统,所搭建的模型通常是十分复杂的。其次,基于模型的方法缺少人工智能算法的支撑,计算成本高,可能非常耗时。最后,模型的参数辨识过程通常依赖于滤波算法的收敛性与收敛速度,同时受环境温度、电池类型等外界条件影响,识别构成一个准确模型的所有重要参数是非常具有挑战性的。因此,基于模型的方法并不总是适用于所有类型的电池。

1.2 基于数据驱动的方法

随着大数据和人工智能技术的快速发展,数据驱动技术突破了复杂非线性系统难以建模的束缚,已成为当前电池 SOH 估计的主要研究手段。基于数据驱动的 SOH 估计技术通过测量电池的电流、电压和温度等参数,提取与 SOH 变化高度相关的特征,并将其作为训练数据构建估计模型,从而实现锂电池 SOH 的实时估计。相比于基于模型的分析方法,数据驱动不需要对电池内部复杂的电化学机理进行精确建模,无需进行电池自身参数的辨识,具有较高的可迁移性、鲁棒性与泛化性。

数据驱动技术实现锂电池 SOH 精确可靠估计的前提是准确提取与电池容量退化高度相关的特征参量/健康因子。美国阿拉巴马大学 Xia Z. 等人通过实验发现,当锂电池 SOH 的健康因子多样化,或用于训练开发 SOH 估计算法的输入特征多样化时,SOH 估计性能可以得到显著提高^[27]。因此,研究人员尝试通过提取多种特征参量来提高估计方法的精度。

1.2.1 支持向量机(support vector machine, SVM)与支持向量回归(support vector regression, SVR)

SVM 作为一种有监督的机器学习算法,被广泛应用于解决分类和回归问题。用于解决回归问题时,SVM 被用作 SVR 的预测工具。SVM 通过在高维空间中构造超平面,将一类数据从另一类中分离出来。当超平面到任何类的数据点几何间隔最大化时,就获得最佳的分离边界,其工作原理如图 4 所示。SVR

作为一种基于贝叶斯的稀疏核算法，提供了对数据的概率解释，适用于小数据样本。

澳大利亚斯威本科技大学 Tian J.等人提出了一种基于锂电池表面温度和 SVR 的 SOH 估计方法。实验表明，与基于 ICA 的方法结合能够以较小的计算成本提高 SOH 估计的精度与鲁棒性^[28]。韩国蔚山科学技术大学 Nagulapati V. M.等人提出了基于多电池数据组合 SVM 模型的电池容量和健康状态估计方法。将放电周期的电压、电流和温度数据进行关联来估计容量退化，并对单传感器和多传感器数据的估计精度进行比较。研究表明，SVM 模型在 RMSE 值较低的情况下对电池容量的准确估计具有显著的优势，且多传感器数据可提高估计方法的精度和鲁棒性^[29]。

针对实际应用中存在的不完全充放电而导致充电起始和截止点不确定的问题，上海交通大学卢地华等人提出了一种基于双充电状态因子粒子群优化(particle swarm optimization, PSO)-SVR 模型锂电池 SOH 估计方法^[30]。提取恒压充电前端的平均电流和恒流充电末端的等值压降作为 HIs，通过在线监测当前循环的 HI 实现 SOH 估计。结果表明，该方法可以对电池容量衰退过程中出现的容量再生现象进行有效跟踪。

1.2.2 高斯过程回归(Gaussian process regression, GPR)

GPR 是使用高斯过程先验对数据进行回归分析的非参数模型。同时，GPR 可提供预测结果的后验概率，是一个具有泛化性和可解析性的概率模型。因此，可利用 GPR 模型对锂电池的 SOH 进行估计并给出置信区间。

重庆大学邓忠伟等人提出了一种基于稀疏高斯过程回归的锂电池 SOH 估计方法。首先从局部充电过程中提取随机容量增量序列，然后将容量增量的平均值和标准差作为健康因子，构造稀疏 GPR 模型来实现 SOH 估计^[31]。引入的稀疏机制解决了常规 GPR 过拟合问题，减小了算法的时间复杂度，提高了估计精度。通过实验对比发现 GPR 比 SVM 和 SVR 的估计精度更高，且具有置信区间输出。天津大学韩乔妮等人针对不同温度条件，提出了一种基于间接健康因子和改进 GPR 的锂电池 SOH 估计方法。该方法通过引入二次协方差为核函数，利用共轭梯度法对 GPR 进行优化^[32]。实验表明，所提出的方法在电池单体和电池组的不同工况下均可实

现精确估计，模型泛化能力强，但无法实现对电池组中单个电池的 SOH 估计。

1.2.3 长短期记忆网络(long short-term memory, LSTM)

LSTM 是递归神经网络(recursive neural network, RNN)的一种变体，旨在解决远程依赖的 RNN 中伴随的梯度消失和梯度爆炸问题^[33]。LSTM 的典型结构由输入门、输出门、遗忘门和存储单元组成，总体架构如图 5 所示，图中 x_t 为输入， h_t 和 h_{t-1} 为隐藏层输出和过去一段时间隐藏层输出， c_t 为记忆单元。LSTM 网络凭借其处理复杂非线性问题的出色能力被广泛应用于锂电池 SOH 估计中^[34]。

英国蒂赛德大学 El-Dalahmeh M.等人比较了非线性自回归神经网络(nonlinear autoregressive neural network, NANN)，卷积神经网络(convolutional neural networks, CNN)和 LSTM 3 种数据驱动算法的 SOH 估计性能。实验表明，在不同的操作条件下，LSTM 在估计准确性上优于其他两种算法，最




图 4 SVM 工作原理图

Fig.4 Principle diagram of SVM

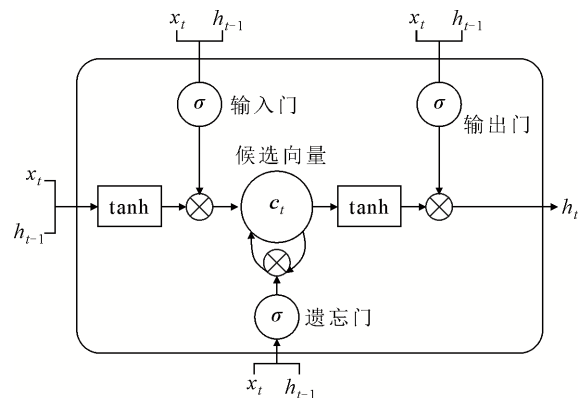


图 5 LSTM 总体架构图

Fig.5 Overall architecture diagram of LSTM

大均方根误差为 0.5%, 平均绝对误差(mean absolute error, MAE)仅为 0.36%^[34]。为了解决电池退化周期长度不均匀的问题, 新加坡科技设计大学 Zhou K. 等人提出一种基于 LSTM 周期同步的 SOH 估计方法。利用动态时间规整(dynamic time warping, DTW)改变现有坐标系来实现周期同步, 采用 LSTM 作为 SOH 基本估计模型。该方法对于周期非均匀电池 SOH 的估计精度较传统 LSTM 显著提升 30%以上^[35]。

国防科技大学张亚军等人将 ICA 与 LSTM 融合, 仅利用恒流充电阶段的数据, 将 IC 曲线中包含的电池退化信息具体化为模型的参数。选择合适的 HIs 作为 LSTM 的输入。实验结果表明, 该方法能够获得准确的 SOH 估计结果, 最大平均绝对误差在 2%以内。然而, 在短期预测中, 该方法估计的 SOH 值比真实值小, 适合 SOH 的长期依赖估计^[36]。为估计锂电池组的健康状态, 武汉大学张朝龙等人将电池组中各单体的电压信息熵和平均温度作为表征容量损失的健康因子, 利用 PSO 优化的 LSTM 方法对电池组(容量 14.4 Ah)的健康状态进行估计。试验结果表明, 其平均估计误差在 1%以内, 且可应用于电池单体^[37]。

1.2.4 极限学习机(extreme learning machine, ELM)

ELM 是一种具有一个隐藏层的神经网络快速训练算法。它允许网络参数的随机选择, 且在训练过程中不需调整, 整个 ELM 过程不需要任何迭代步骤, 最大程度地减少了网络参数的确定时间。因此, 它可以在保证学习精度的前提下, SOH 估计比传统学习算法更快、更准确。

南洋理工大学刘威等人将等时间间隔电压方差作为 HI, 提出了一种基于 ELM 层次集成的 SOH 估计方法, 该方法的平均均方根误差 $<0.5%$ ^[38]。意大利都灵理工大学 Ezemobi E. 等人提出了一种利用并行层极限学习机(parallel layer, PL)-ELM 算法增强锂电池 SOH 估计泛化性的方法。PL-ELM 模型使用电压、荷电状态和电池可释放能量等变量的离散化特征来表征 SOH。实验验证了该模型的 RMSE 在 0.046%~0.473%之间, MAE 在 0.034%~0.355%之间, 实时执行时间为 93 μ s。模型具有较低的复杂度和较高的计算效率, 适合于电动汽车锂电池健康状态的在线估计^[39]。

西安交通大学 FU Y. 等人提出了一种基于快速阻抗计算和正则化 ELM 的串联电池 SOH 估计方法。首先利用改进快速傅里叶变换(fast Fourier

transform, FFT)降低信号频谱的计算复杂度, 提取 6 个与电池 SOH 相关的电化学阻抗谱特征。然后利用正则化 ELM 建立了 SOH 估计模型^[40]。所采集的数据来源于电池内部的特征, 克服了外部信号受环境条件、设备性能以及测量方法的影响。实验结果表明, 该方法可以在 35 s 内实现锂电池 SOH 的准确估计, 误差 $<2%$ 。该方法的不足之处在于特征信号来源于电池内部, 受设备和内部环境的限制, 采集较为困难。

1.2.5 神经网络(neural network, NN)

神经网络由众多的神经元可调的连接权值连接而成, 具有大规模并行处理、良好的自组织自学习能力、灵活性大等特点, 可用于处理锂电池的 SOH 估计这一非线性问题。

韩国浦项科技大学 Kim J. 等人提出了一种基于参考性能实验数据和神经网络结合的 SOH 实用估计方法。将电池连续的 SOH 估计问题转化为分类问题, 不仅可以缓解测试实验对锂电池造成的退化, 还可以节省锂电池全寿命周期测试的时间和成本^[41]。

陕西科技大学王凡等人提出了一种基于注意力改进双向门控循环单元的锂电池 SOH 估计方法。从电池充放电曲线中提取 HI, 经自编码神经网络降维。利用双向门控循环单元学习 HI 与 SOH 的依赖关系。结果表明, 不同类型电池的 SOH 估计结果均方根误差均在 1.1%以下, 具有一定的泛化能力, 然而该方法尚未考虑温度和放电深度的影响^[42]。河北工业大学李文华等人考虑在六自由度振动的老化条件下, 提出了一种基于遗传算法(genetic algorithm, GA)-Elman 神经网络的锂电池 SOH 估计方法。该方法可以区分锂电池的不同老化模式, 且估计误差在 5%以内, 其局限性在于对其他振动老化条件和充放电条件的泛化性需深入研究^[43]。

1.2.6 其他数据驱动方法

丹麦奥尔堡大学 Vilsen S. B. 等人提出了一种基于核均值匹配迁移学习的锂电池 SOH 估计方法, 使用多元线性回归(multiple linear regression, MLR)和自举随机向量函数链(bootstrapped random vector functional link, BRVFL)模型在源域(实验室)和目标域(实际应用)均实现了 SOH 良好估计^[44]。然而该方法存在无法解释的误差, 即 BRVFL 会预测到电池容量的下降, 而 MLR 则没有预测到这一现象。由于无法直接测量电池容量, 这种容量衰退无法确认是真实存在还是预测误差, 故方法的可信度无法验

证。瑞典查尔默斯理工大学 Dong G 等人提出了一种基于动态贝叶斯网络的锂电池退化建模和 SOH 估计的概率方法。利用动态贝叶斯处理电池健康指标并提取特征的相关性。利用 PF 推理进行模型在线自学习以估计 SOH。研究表明,该方法对电池运行特征信息不完整的实际场景具有较强泛化性。由于该方法是在恒流/恒压条件下提出的,对实际快充条件下的适用性有待研究,且没有考虑温度的影响^[45]。

香港科技大学 Tang X 等人提出了一种基于平衡电流比率的锂电池组(容量 45 Ah)内所有串联电池的 SOH 有效估计方法。该方法将平均平衡电流与平均电池组电流的比率引入到估计算法中,并开发了相应的加权融合策略。与传统的估计方法相比,由于集成了无模型平衡控制,对单体级电池模型的依赖性降低了至少 83%^[46]。同济大学叶壮等人提出了一种基于迁移学习对抗网络的电池 SOH 估计方法,以解决不同域间数据分布不一致的问题。该方法通过密集连接双向门控循环单元提高特征学习能力,用两个特征对齐指标最大化域不变性(maximizing for domain invariance, MMD)和相关性对齐(correlation alignment, CORAL)集成算法生成不同域的公共特征参与对抗训练以达到自适应。结果表明,该方法较其他迁移学习方法具有更好的知识转移性能,可在不同电池不同工况下实现电池 SOH 精准估计^[47]。

1.3 基于模型法与数据驱动融合的方法

模型法预测精度较低,基于 ICA 的方法泛化能力差,但具有内在机理的可解释性;而数据驱动方法动态准确性和泛化性高,但缺乏机理性描述。因此,研究人员越来越青睐于将二者融合进行锂电池 SOH 估计,同时兼顾了估计精度和泛化性,以及模型的可解释性,是未来的主流研究方向。

瑞典皇家理工学院的 Bian X 等人提出了一种基于模型方法的特征提取和基于数据驱动的状态估计相融合的锂电池 SOH 估计方法。首先提出新的基于模型的电压重构方法,以消除离群数值的影响和对温度的敏感性。其次,从重构的 IC 曲线中提取相关特征,利用数据驱动实现 SOH 的估计。该方法对电池单体不一致性、温度不确定性及噪声干扰均具有良好鲁棒性。实验结果表明,模型阶数对 SOH 估计精度基本无影响,因此从纯计算角度,可适当降低阶数以获得低计算成本。若考虑电池内部

复杂的老化机制,则需更高的模型阶数^[48]。

天津大学张吉昂等人提出了一种基于等效电路模型和数据驱动方法融合的锂电池 SOH 估计方法。提取充电电压片段的等压升时间作为 HI,建立了最小二乘支持向量机(least square support vector machines, LSSVM)融合模型实现 SOH 估计^[49]。昆明理工大学陈峥等人提出了一种基于自回归移动平均(autoressive moving average, ARMA)模型和 Elman 神经网络融合的 SOH 估计方法。利用经验模态分解处理容量退化数据,消除容量再生现象的影响。采用 ARMA 预测与历史观测值相关性较高的内禀模态函数,用 Elman 神经网络预测与健康因子和周期数相关性较强的残差。结果表明,与单一模型相比,融合方法能够更精准地实现锂电池 SOH 估计^[50]。

1.4 基于多种数据驱动融合的方法

单一数据驱动方法存在计算成本高、估计精度低等问题。研究人员提出了融合多种数据驱动算法的估计方法。利用一种算法估计电池容量的全局退化趋势,另一种算法描述电池局部容量再生现象,估计精度大幅提升。

福州大学王英楷等人提出了一种基于融合一维卷积神经网络与 LSTM 网络的锂电池 SOH 估计方法。将每个充放电周期的电压、电流、温度进行平均化处理形成高维特征。利用一维 CNN 提取特征,输入到 LSTM 网络实现 SOH 估计。结果表明,该方法较单一数据驱动方法平均绝对误差更小^[51]。昆明理工大学舒星等人将 LSTM 和迁移学习相结合来估计电池组的 SOH。为评估电池单体之间的一致性,使用 LSTM 作为单元差异模型,通过识别单元差异的最小估计值以确定电池组的 SOH。该方法仅在容量较小的电池组上进行了验证,对大容量电池组预测的准确性还需进一步验证^[52]。

1.5 需要深入开展的研究内容

基于模型和数据驱动的锂离子电池 SOH 估计技术目前已比较成熟,不同的 SOH 估计方法具有各自优点与适用场景,表 1 总结了锂电池不同 SOH 估计方法的优缺点。

电池的健康状态与电池容量密切相关,但在实际应用中,直接获取电池容量十分困难,且计算结果存在累积误差。基于模型的方法在外部条件相对稳定时可以获得较高的估计精度,但复杂的工作条件和耦合退化机制使得建立精确的模型具有挑战

表1 不同锂电池 SOH 估计方法优缺点比较

Table 1 Comparison of advantages and disadvantages of different SOH estimation methods for LIB

锂电池 SOH 估计方法	参考文献	优点	缺点
模型法	EM [11, 15-17]	具备内在机理的可解释性	建模困难、鲁棒性差
	ECM [18-20]	利用电路元件建模简单	精度受模型参数影响、鲁棒性差
	ICA [23-26]	可实现性强、简单易行	泛化能力差
数据驱动方法	SVM [29]	精度高、计算速度快	超参数选择困难、核函数选择问题、缺乏输出置信区间
	SVR [28, 30]	精度高、具有不确定性输出	长期预测效果不佳、适用于小数据样本
	GPR [31-32]	精度高、输出具有概率分布	计算复杂度高、在线更新能力差
	LSTM [34-37]	精度高、无梯度消失和梯度爆炸问题	计算复杂度高、模型训练时间长
	ELM [38-40]	计算速度快时间短、有一定泛化能力	精度较差、无置信区间输出、鲁棒性差
	NN [41-43]	精度高、建模容易	计算复杂度高、小样本数据精度有限、不能实时估计
模型法与数据驱动方法融合	[48-50]	精度更高、增加了模型的可解释性	计算复杂度高
多种数据驱动方法融合	[51-52]	精度更高、泛化能力更强	计算复杂度高、更多参数的识别变得困难

性。对于由单体电池构成的电池组, 尚未构建出合理的电化学模型。考虑电池单体的不一致性, 提出基于模型的电池组整体 SOH 估计方法, 对理解电池复杂退化机理和电池的平衡管理具有重要意义。

基于数据驱动的 SOH 估计方法忽略了电池内部结构, 只需提取与电池退化相关的健康因子, 利用数据驱动算法建立二者的映射关系, 避免了物理建模和参数辨识过程, 对 SOH 动态变化的适应和跟踪能力强。然而, 数据驱动方法的准确性很大程度上依赖于实验数据的数量和质量, 对电池 SOH 估计的实现通常需要对原始数据进行适当的预处理, 且实验室数据并不总是与实际情况相符, 用于训练模型的实验数据需与预期的实际应用场景相似。此外, 一些数据驱动的方法也存在固有的局限性, 例如不当的训练模式易导致算法陷入过拟合和局部优化, 存在计算成本高、训练复杂度高不足。未来研究的热点在于将模型法与数据驱动方法相结合, 提高估计精度的同时提高方法整体的可解释性。此外, 随着人工智能的发展, 将多种数据驱动方法融合成为未来锂电池 SOH 估计方法的主流。根据训练数据与计算能力自主配置算法, 达到估计精度与计算复杂度之间的平衡是未来研究的重点方向。

2 锂离子电池 RUL 预测方法

由于电池阳极和阴极电解液中的电化学反应, 以及受机械应力、制造工艺缺陷、环境温度等外界因素的影响, 电池的退化成为一个复杂的问题。确定电池在不同运行条件下的 RUL 对准确估计更换电池周期或维护电池有重要意义。锂离子电池的 RUL 是指在一定的充放电条件下, 电池性能或健康状态退化到不能满足设备继续工作或失效阈值之前

所经历的充放电循环次数。RUL 预测是在 SOH 估计的基础上和锂电池一定的运行状态下, 预测锂电池后期使用寿命的长短。准确高效的 SOH 估计可以为后续 RUL 精确预测提供很好的保障。锂电池 SOH 和 RUL 的关系如图 6 所示。一般认为, 当锂离子电池实时容量下降到额定容量的 80% 时, 即达到电池失效的临界值^[53]。

锂电池 RUL 预测方法分类如图 7 所示。目前已经提出的锂电池 RUL 预测方法可分为直接法和间接法。直接法采用库伦计数或阻抗谱来预测剩余寿命, 存在累积误差和预测时间长等局限性; 间接法则利用电压、电流等测量参量实现锂电池的 RUL 预测。其中间接法包括模型法和数据驱动法。用于电池 RUL 预测的模型方法大多依赖于电池内部时变非线性的电化学反应以及复杂参数计算, 预测难度较大, 且实用性与动态准确性差。另一方面, 数据驱动方法由于不需要了解电池内部复杂机理, 在文献中被大量提出。因此本文仅针对基于数据驱动的锂电池 RUL 预测方法进行详细介绍, 所讨论的数据驱动方法具体可以分为粒子滤波及其变体、机器学习(machine learning, ML)和融合方法。

2.1 粒子滤波及其变体方法

粒子滤波即通过寻找状态空间中的一组随机样本来近似表示概率密度函数, 获得系统状态的最小方差估计的过程。粒子滤波可以处理大多数非线性和非高斯动态系统问题。利用粒子滤波来预测锂电池的 RUL 成为近年来的研究热点。

新加坡科技设计大学 Raghavan N. 等人对粒子滤波框架中 4 种主要的重采样技术(剩余系统重采样、系统重采样、分层重采样和多项式重采样)进行了研究, 比较了它们在 RUL 预测精度和计算效率

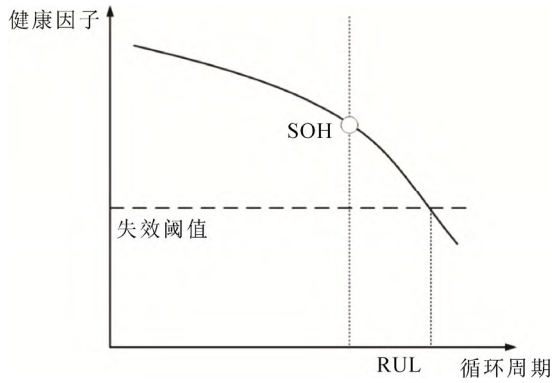


图6 锂电池 SOH 和 RUL 的关系

Fig.6 Relationship between SOH and RUL of LIB

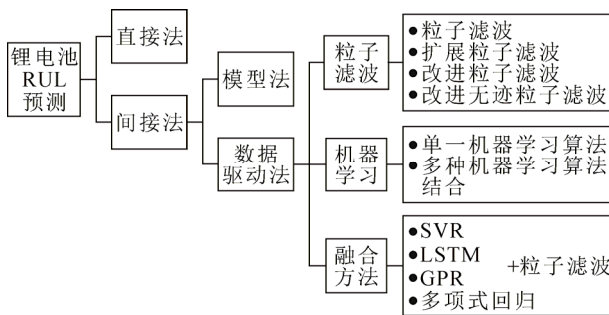


图7 锂电池 RUL 预测方法分类

Fig.7 Classification of RUL prediction methods for LIB

方面的性能。研究表明，剩余系统重采样方法因其只在权重小于 $1/N$ 的粒子上执行，性能最好。而分层重采样在准确性和精度方面具有边际优势，可用于电池寿命后期预测^[54-55]。传统 PF 存在后验概率密度函数在预测期间无法更新的问题，加拿大湖首大学 Ahwiadi M.等人提出了一种增强粒子法，在改进的 PF 结构中引入了一种进化模糊预测器，以解决在预测期间缺乏新的电池测量数据的问题。所提出的算法可以检测样本退化，处理低重量粒子以更好地表征概率密度函数，并通过仿真验证了该技术的有效性^[56]。

广西大学的欧阳天成等人将同步输入和状态估计算法引入到电池容量在线预测中，提出了一种基于高斯-埃尔米特扩展粒子滤波的方法，结果表明该方法对电池单体及电池组的 RUL 均能进行有效预测^[57]。桂林电子科技大学焦自权等人提出了一种改进粒子滤波算法的锂电池 RUL 预测方法。采用状态跟踪训练优化后的量测信息更新提议分布以改善粒子退化现象，利用马尔可夫链-蒙特卡洛理论中 M-H 抽样算法改良重采样过程。然而该方法无法有效跟踪电池容量衰退过程中的容量再生现象^[58]。由

于粒子的简并性，传统粒子滤波算法存在预测精度不高的缺陷。北京科技大学焦瑞华等人提出了一种基于条件变分自编码器的新型粒子滤波框架用于锂电池 RUL 预测。在粒子重采样过程中引入了一种重加权策略，防止粒子多样性损失。与传统方法相比，该方法提高了预测精度，与此同时，由于集成了深度学习，计算复杂度也大幅提升^[59]。

2.2 机器学习方法

与电池 SOH 的估计类似，极限学习机、支持向量机、支持向量回归、长短期记忆网络、人工神经网络等机器学习方法同样可以对锂电池 RUL 进行预测。单一方法存在预测精度不高，泛化性差的问题，因此研究人员越来越倾向于将多种机器学习算法融合对锂电池的 RUL 进行预测。机器学习融合算法在一定程度上减小了预测误差，缩短了预测时间，在今后的研究中有广阔应用前景。

韩国釜山大学 Ali U. M.等人提出了一种基于局部放电数据的 SVM 模型对锂电池 RUL 进行预测。该方法从电池局部放电的电压和温度中提取关键特征训练 SVM 模型。利用 SVM 的分类和回归属性对 RUL 进行分类和预测。实验结果表明，基于局部放电数据特征训练的 SVM 分类回归模型能够准确预测 BMS 上存储压力较低的 RUL，该方法可用于电动汽车用锂电池的 RUL 在线估计^[60]。比利时布鲁塞尔自由大学 Khaleghi S.等人基于部分充电电压曲线提取的健康指标，提出了一种具有外源性输入的非线性自回归神经网络，用于电池 RUL 预测。利用估计的 SOH 作为预测特征，建立了基于相似度的预测模型。所提出的方法对不同老化模式电池的 RUL 预测绝对误差在置信区间内与锂电池的运行条件无关。该方法具有在电池管理系统中实时运行的潜力^[61]。英国华威大学 Liu K.等人提出了一种基于 LSTM 网络和 GPR 融合的锂电池 RUL 预测方法。利用 LSTM 子模型估计残差，GPR 子模型拟合不确定性水平。结果表明，所提出的融合方法可以对锂电池进行一步或多步超前容量预测，在电池生命周期早期即可实现 RUL 预测并给出不确定性水平^[62]。

华北电力大学梁海峰等人提出了一种 CNN 与双向 LSTM 网络融合的锂电池 RUL 预测方法。提出的方法同时考虑了多种电池寿命衰退特征与时序信息，模型所需参数更少^[63]。北京航空航天大学任磊等人同样提出了一种基于改进 CNN 和 LSTM 网

络融合的锂电池 RUL 预测方法。利用自编码器增加数据的维数, 滤波器对预测值进行平滑处理。在真实数据集上的训练结果表明预测结果的 RMSE 为 4.8%^[64]。太原理工大学乔建树等人提出了一种基于经验模态分解、LSTM 和深度神经网络(deep neural networks, DNN)融合的锂电池 RUL 预测方法。通过经验模态分解将放电容量分解为全局退化和局部容量再生。其中 DNN 用于预测电池容量衰退的整体趋势, 而 LSTM 用于预测容量再生现象。结果表明, 该方法平均绝对误差下降 75%, 均方根误差下降 90.8%^[65]。

2.3 融合方法

单一的寿命预测方法往往表现出明显的不足, 目前, 基于粒子滤波和机器学习融合的方法成为锂电池 RUL 预测领域的研究热点, 融合方法能够实现两者的优势互补, 进一步提升预测算法的精度和泛化性^[66]。

美国福特汽车公司 Dong H.提出了一种基于 DST 理论和 SRV-PF 融合的锂电池 RUL 预测方法, 提高了在锂电池可用数据相对稀疏情景的预测能力^[67]。新加坡科技设计大学 Pugalenthi K.等人利用自适应贝叶斯学习的权重正则化神经网络融合方法进行锂电池 RUL 预测。首先采用改进正则化的贝叶斯框架(粒子滤波算法)估计网络参数(权重和偏差)。然后将网络参数的估计分布输入 NN 预测模型中来实现 RUL 预测。通过采用传统重采样策略进行权值正则化, 提升了方法的计算效率和鲁棒性, 有助于克服神经网络模型中常见的优化和收敛问题^[68]。

哈尔滨工程大学潘大为等人提出了一种基于迁移学习的 LSTM 网络和 PF 融合的 RUL 预测方法。基于迁移学习的 LSTM 网络能够处理不同应力下的 RUL 预测问题, 提升了预测方法的泛化能力。而 PF 提供了预测结果的不确定度表示。在数据长度为 50%时, 该方法的预测相对误差 <5%^[69]。北京交通大学的张彩萍等人针对锂电池退化后期出现的容量再生现象, 将改进容量经验退化模型与改进无迹粒子滤波相结合, 利用 GPR 得到模型修正误差, 实现了锂电池 RUL 的预测。与单一无迹粒子滤波或 GPR 相比, 融合方法的预测结果绝大多数位于 95%置信区间以内, 而对异常或故障的锂电池寿命预测结果则存在较大误差^[70]。

2.4 需要深入开展的研究工作

对锂电池 RUL 的准确预测可以及时更换劣化

电池, 降低运维成本, 避免事故发生。表 2 对比了目前提出的锂电池 RUL 预测方法的应用效果。所提出的 RUL 预测方法大多受训练数据长度的限制, 对于实际中非满充满放的情况, 难以准确预测 RUL, 并且需要提高预测方法对小数据样本的适应性。电池的容量和寿命对环境温度十分敏感, 将温度因素考虑在内, 对于提升预测方法的准确度至关重要。此外, 温度会与放电倍率等因素相互耦合作用, 准确判断某一因素单独作用的影响变得困难。深入研究单一变量解耦方法是亟需解决的问题。

电池固有的松弛效应会严重影响 RUL 预测方法的精度, 深入理解电池退化过程中容量再生现象的机理, 掌握其变化规律, 可有效减小预测方法的误差。由于提出的 RUL 预测方法大多基于实验室数据, 当实际数据集与训练数据集的运行条件映射不对应时, 往往出现较大误差。随着云连接设备的出现, 锂电池运行数据可以被记录, 包括锂电池实际应用中的退化数据。利用云平台实际数据, 提出预测能力精准、计算复杂度低的电池寿命预测方法成为可能。

3 总结与展望

本文综述了锂电池 SOH 估计和 RUL 预测方法的最新进展, 介绍了各种方法的基本原理以及优缺点。SOH 估计方法主要分为基于物理/数学模型、数据驱动法、模型法与数据驱动融合以及多种数据驱动融合的方法。应用于 RUL 预测的数据驱动方法有粒子滤波及其变体、机器学习和二者的融合方法。基于模型和数据驱动的 SOH 估计方法已经被大量应用, 取得了显著效果。为了更好地解决锂离子电池健康状态估计和寿命预测的准确性和泛化性等问题, 保障系统安全可靠运行, 需要在以下 4 个方面开展深入研究:

1) 现有研究主要针对单体电池的 SOH 估计, 在锂电池组中, 由于充放电循环后电池性能的改变, 以及制造工艺、工作条件的不同, 使串并联的各电池内阻不一致, 精确估计电池组中每个电池的 SOH 成为一个具有挑战性的问题。基于物理模型的估计方法中, 对电池组中每个单体电池搭建模型比较困难, 随着模型精度的增加, 计算复杂度也增加。建立考虑容量再生的电池模型, 并在模型精度和计算复杂度之间达到平衡是需要深入研究的方向。

2) 锂电池 RUL 预测的挑战在于实验室测试条

表 2 不同锂电池 RUL 预测方法应用效果对比

Table 2 Comparison of application effects of different RUL prediction methods for LIBs

RUL 预测方法	具体方法	参考文献	应用场景	预测效果
粒子滤波及其变体	增强粒子法	[56]	解决传统 PF 存在后验概率密度函数在预测期间无法更新的问题	相对误差: 0.6%
	高斯-埃尔米特扩展粒子滤波	[57]	解决预测精度与算法复杂度之间的平衡问题	最小相对误差: 0.4%
	改进粒子滤波	[58]	为改善传统粒子滤波的粒子退化现象	相对误差: <5%
	基于条件变分自编码器的粒子滤波	[59]	为解决传统粒子滤波的粒子简并问题	均方根误差: <3%
机器学习方法	SVM	[60]	解决电动汽车锂电池 BMS 上存储压力较低时的 RUL 预测问题	均方根误差: <0.5%
	具有外源输入的非线性自回归神经网络	[61]	在锂电池管理系统中实时运行	相对误差: 0.9%
	LSTM 网络与 GOR 融合	[62]	解决在电池生命周期早期实现 RUL 预测的问题	均方根误差: <0.5%
	CNN 与双向 LSTM 网络融合	[63]	解决锂电池 RUL 预测过程中模型参数过多的问题	均方根误差: <0.3%
	改进 CNN 和 LSTM 网络融合	[64]	解决在锂电池真实数据集上 RUL 预测性能较差的问题	均方根误差: 4.8%
融合方法	LSTM 网络与 DNN 融合	[65]	解决锂电池退化后期出现的容量再生现象问题	均方根误差: <0.4%
	SVR 与粒子滤波融合	[67]	解决在锂电池可用数据相对稀疏情景的预测问题	相对误差: 3.1%
	NN 与粒子滤波融合	[68]	解决神经网络模型中常见的优化和收敛问题	均方根误差: 4%
	LSTM 网络与粒子滤波融合	[69]	解决锂电池在不同应力下的 RUL 预测问题	相对误差: <5%
	GPR 与无迹粒子滤波融合	[70]	解决锂电池退化后期出现的容量再生现象问题	平均绝对误差: <0.4%

件与实际工况有很大的差距。例如, 实验室通常为单一条件下的恒应力测试, 而实际环境通常为复杂动态运行条件下的复合应力作用。利用实验室数据建立的 RUL 预测模型在实际环境中的准确性缺乏保证。因此, 在动态运行条件下, 如何进行锂电池 RUL 的准确预测是今后研究的重点。

3) 锂电池 SOH 估计或 RUL 预测通常被分别研究, 事实上, 电池的 RUL 与 SOH 密切相关, 单独研究锂电池的 SOH 而不考虑电池寿命的容量再生, 会造成 SOH 估计不准确, 将两者相结合可提高 SOH 评估和 RUL 预测的有效性。随着锂电池对快充需求越来越迫切, 在快充条件下锂电池的 SOH 估计和 RUL 预测值得进一步研究。

4) 需要加强对锂电池失效机制的研究, 从机理上建立完善的模型来对锂电池 SOH 和 RUL 做出精准预测是未来研究的重点。同时将锂电池状态监测、故障诊断、寿命预测以及对应的维护策略相结合, 从系统级层面建立完善的锂电池诊断机制是需要深入研究的方向。

参考文献 References

- [1] 中国汽车工业协会. 上半年全球电动汽车销量超过 250 万辆 [EB/OL]. (2021-08-09). http://www.caam.org.cn/search/con_5234332.html.
China Association of Automobile Manufacturers. More than 2.5 million electric vehicles were sold globally in the first half of the year [EB/OL]. (2021-08-09). http://www.caam.org.cn/search/con_5234332.html.
- [2] 牛志远, 金阳, 孙磊, 等. 预制舱式磷酸铁锂电池储能电站燃爆事故模拟及安全防护仿真研究[J]. 高电压技术, 2022, 48(5): 1924-1932.
- [3] NIU Zhiyuan, JIN Yang, SUN Lei, et al. Safety protection simulation research and fire explosion accident simulation of prefabricated compartment lithium iron phosphate energy storage power station [J]. High Voltage Engineering, 2022, 48(5): 1924-1932.
- [4] 王铭民, 孙磊, 郭鹏宇, 等. 基于气体在线监测的磷酸铁锂电池模组过充失控特性[J]. 高电压技术, 2021, 47(1): 279-286.
- [5] WANG Mingmin, SUN Lei, GUO Pengyu, et al. Overcharge and thermal runaway characteristics of lithium iron phosphate energy storage battery modules based on gas online monitoring [J]. High Voltage Engineering, 2021, 47(1): 279-286.
- [6] 郭自清, 熊庆, 梁博航, 等. 基于桥接电容电流特性的锂离子电池组一致性检测方法[J]. 高电压技术, 2022, 48(5): 1933-1942.
- [7] GUO Ziqing, XIONG Qing, LIANG Bohang, et al. Consistency detection approach for lithium-ion battery pack based on current characteristics of bridging capacitors [J]. High Voltage Engineering, 2022, 48(5): 1933-1942.
- [8] 戴海峰, 张艳伟, 魏学哲, 等. 锂离子电池剩余寿命预测研究[J]. 电源技术, 2019, 43(12): 2029-2035.
- [9] DAI Haifeng, ZHANG Yanwei, WEI Xuezhe, et al. Prediction of residual life of lithium ion batteries [J]. Chinese Journal of Power Sources, 2019, 43(12): 2029-2035.
- [10] OJI T, ZHOU Y L, CI S, et al. Data-driven methods for battery SOH estimation: survey and a critical analysis [J]. IEEE Access, 2021, 9: 126903-126916.
- [11] 国际能源网. 10 年全球 32 起着火爆炸事故! 国内外储能电站火灾或爆炸事故统计与分析 [EB/OL]. (2021-04-22). <https://mnewenergy.in-en.com/html/newenergy-2404888.shtml>.
International Energy Network. Statistics and analysis of fire or explosion accidents in energy storage power stations at home and abroad - International New Energy network [EB/OL]. (2021-04-22). <https://mnewenergy.in-en.com/html/newenergy-2404888.shtml>.
- [12] 唐文杰, 姜欣, 刘昊琰, 等. 基于气液逸出物图像识别的锂离子电池火灾早期预警[J]. 高电压技术, 2022, 48(8): 3295-3304.
- [13] TANG Wenjie, JIANG Xin, LIU Haoyan, et al. Early warning of lithium-ion battery fire based on image recognition of gas-liquid escape [J].

- High Voltage Engineering, 2022, 48(8): 3295-3304.
- [9] 杨启帆, 马宏忠, 段大卫, 等. 基于气体特性的锂离子电池热失控在线预警方法[J]. 高电压技术, 2022, 48(3): 1202-1211.
YANG Qifan, MA Hongzhong, DUAN Dawei, et al. Thermal runaway online warning method for lithium-ion battery based on gas characteristics[J]. High Voltage Engineering, 2022, 48(3): 1202-1211.
- [10] 张青松, 曲奕润, 郝朝龙, 等. 三元锂离子电池热失控气体原位分析[J]. 高电压技术, 2022, 48(7): 2817-2825.
ZHANG Qingsong, QU Yirun, HAO Chaolong, et al. In-situ analysis of thermal runaway gas in ternary lithium-ion battery[J]. High Voltage Engineering, 2022, 48(7): 2817-2825.
- [11] GAO Y Z, LIU K L, ZHU C, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model[J]. IEEE Transactions on Industrial Electronics, 2022, 69(3): 2684-2696.
- [12] XU X D, YU C Q, TANG S K, et al. State-of-health estimation for Lithium-ion batteries based on wiener process with modeling the relaxation effect[J]. IEEE Access, 2019, 7: 105186-105201.
- [13] 陈剑, 肖振锋, 刘顺成, 等. 基于 EKF-SVSF 的锂离子电池 SOC 和 SOH 准确估计[J]. 电源技术, 2020, 44(10): 1483-1487.
CHEN Jian, XIAO Zhenfeng, LIU Shuncheng, et al. Accurate estimation of SOC and SOH of Li-ion battery based on EKF-SVSF[J]. Chinese Journal of Power Sources, 2020, 44(10): 1483-1487.
- [14] CHEN Y, HE Y G, LI Z, et al. Remaining useful life prediction and state of health diagnosis of lithium-ion battery based on second-order central difference particle filter[J]. IEEE Access, 2020, 8: 37305-37313.
- [15] HOSSEININASAB S, LIN C W, PISCHINGER S, et al. State-of-health estimation of lithium-ion batteries for electrified vehicles using a reduced-order electrochemical model[J]. Journal of Energy Storage, 2022, 52: 104684.
- [16] BI Y L, YIN Y L, CHOE S Y. Online state of health and aging parameter estimation using a physics-based life model with a particle filter[J]. Journal of Power Sources, 2020, 476: 228655.
- [17] XU Z C, WANG J, LUND P D, et al. Co-estimating the state of charge and health of lithium batteries through combining a minimalist electrochemical model and an equivalent circuit model[J]. Energy, 2022, 240: 122815.
- [18] AMIR S, GULZAR M, TARAR M O, et al. Dynamic equivalent circuit model to estimate state-of-health of lithium-ion batteries[J]. IEEE Access, 2022, 10: 18279-18288.
- [19] YANG J F, CAI Y F, MI C C. State-of-health estimation for lithium-ion batteries based on decoupled dynamic characteristic of constant-voltage charging current[J]. IEEE Transactions on Transportation Electrification, 2022, 8(2): 2070-2079.
- [20] 陈猛, 乌江, 焦朝勇, 等. 锂离子电池健康状态多因子在线估计方法[J]. 西安交通大学学报, 2020, 54(1): 169-175.
CHEN Meng, WU Jiang, JIAO Chaoyong, et al. Multi-factor online estimation method for health status of lithium-ion battery[J]. Journal of Xi'an Jiaotong University, 2020, 54(1): 169-175.
- [21] HE J T, WEI Z B, BIAN X L, et al. State-of-health estimation of lithium-ion batteries using incremental capacity analysis based on voltage-capacity model[J]. IEEE Transactions on Transportation Electrification, 2020, 6(2): 417-426.
- [22] SHE C Q, LI Y, ZOU C F, et al. Offline and online blended machine learning for lithium-ion battery health state estimation[J]. IEEE Transactions on Transportation Electrification, 2022, 8(2): 1604-1618.
- [23] BIAN X L, WEI Z B, LI W H, et al. State-of-health estimation of lithium-ion batteries by fusing an open circuit voltage model and incremental capacity analysis[J]. IEEE Transactions on Power Electronics, 2022, 37(2): 2226-2236.
- [24] AGUDELO B O, ZAMBONI W, MONMASSON E. Application domain extension of incremental capacity-based battery SOH indicators[J]. Energy, 2021, 234: 121224.
- [25] MENG J H, CAI L, STROE D I, et al. An automatic weak learner formulation for lithium-ion battery state of health estimation[J]. IEEE Transactions on Industrial Electronics, 2022, 69(3): 2659-2668.
- [26] 杨胜杰, 罗冰洋, 王菁, 等. 基于容量增量曲线峰值区间特征参数的锂离子电池健康状态估算[J]. 电工技术学报, 2021, 36(11): 2277-2287.
YANG Shengjie, LUO Bingyang, WANG Jing, et al. State of health estimation for lithium-ion batteries based on peak region feature parameters of incremental capacity curve[J]. Transactions of China Electrotechnical Society, 2021, 36(11): 2277-2287.
- [27] XIA Z Y, QAHOUQ J A A. Lithium-ion battery ageing behavior pattern characterization and state-of-health estimation using data-driven method[J]. IEEE Access, 2021, 9: 98287-98304.
- [28] TIAN J P, XIONG R, SHEN W X. State-of-health estimation based on differential temperature for lithium ion batteries[J]. IEEE Transactions on Power Electronics, 2020, 35(10): 10363-10373.
- [29] NAGULAPATI V M, LEE H, JUNG D, et al. A novel combined multi-battery dataset based approach for enhanced prediction accuracy of data driven prognostic models in capacity estimation of Lithium ion batteries[J]. Energy and AI, 2021, 5: 100089.
- [30] 卢地华, 陈自强. 基于双充电状态的锂离子电池健康状态估计[J]. 上海交通大学学报, 2022, 56(3): 342-352.
LU Dihua, CHEN Ziqiang. State of health estimation of lithium-ion batteries based on dual charging state[J]. Journal of Shanghai Jiaotong University, 2022, 56(3): 342-352.
- [31] DENG Z W, HU X S, LI P H, et al. Data-driven battery state of health estimation based on random partial charging data[J]. IEEE Transactions on Power Electronics, 2022, 37(5): 5021-5031.
- [32] 韩乔妮, 姜帆, 程泽. 变温度下 IHF-IGPR 框架的锂离子电池健康状态预测方法[J]. 电工技术学报, 2021, 36(17): 3705-3720.
HAN Qiaoni, JIANG Fan, CHENG Ze. State of health estimation for lithium-ion batteries based on the framework of IHF-IGPR under variable temperature[J]. Transactions of China Electrotechnical Society, 2021, 36(17): 3705-3720.
- [33] KHAN N, ULLAH F U M, AFNAN N, et al. Batteries state of health estimation via efficient neural networks with multiple channel charging profiles[J]. IEEE Access, 2021, 9: 7797-7813.
- [34] EL-DALAHMEH M D, LILLYSTONE J, AL-GREER M, et al. State of health estimation of lithium-ion batteries based on data-driven techniques[C]//2021 56th International Universities Power Engineering Conference. Middlesbrough, UK: IEEE, 2021: 1-6.
- [35] ZHOU K Q, QIN Y, LAU B P L, et al. Lithium-ion battery state of health estimation based on cycle synchronization using dynamic time warping[C]//IECON 2021—47th Annual Conference of the IEEE Industrial Electronics Society. Toronto, Canada: IEEE, 2021: 1-6.
- [36] ZHANG Y J, CAO M D, WANG Y, et al. A fusion method to estimate the state-of-health of lithium-ion batteries[C]//2021 Global Reliability and Prognostics and Health Management. Nanjing, China: IEEE, 2021: 1-6.
- [37] 张朝龙, 赵筛筛, 何怡刚. 基于信息熵与 PSO-LSTM 的锂电池组健康状态估计方法[J]. 机械工程学报, 2022, 58(10): 180-190.
ZHANG Chaolong, ZHAO Shaishai, HE Yigang. State-of-health estimate for lithium-ion battery using information entropy and PSO-LSTM[J]. Journal of Mechanical Engineering, 2022, 58(10):

- 180-190.
- [38] LIU W, XU Y, FENG X. A hierarchical and flexible data-driven method for online state-of-health estimation of Li-ion battery[J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 14739-14748.
- [39] EZEMOBI E, TONOLI A, SILVAGNI M. Battery state of health estimation with improved generalization using parallel layer extreme learning machine[J]. Energies, 2021, 14(8): 2243.
- [40] FU Y M, XU J, SHI M J, et al. A fast impedance calculation-based battery state-of-health estimation method[J]. IEEE Transactions on Industrial Electronics, 2022, 69(7): 7019-7028.
- [41] KIM J, CHUN H, KIM M, et al. Data-driven state of health estimation of Li-ion batteries with rpt-reduced experimental data[J]. IEEE Access, 2019, 7: 106987-106997.
- [42] 王凡, 史永胜, 刘博亲, 等. 基于注意力改进 BiGRU 的锂离子电池健康状态估计[J]. 储能科学与技术, 2021, 10(6): 2326-2333. WANG Fan, SHI Yongsheng, LIU Boqin, et al. Health state estimation of lithium-ion batteries based on attention augmented BiGRU[J]. Energy Storage Science and Technology, 2021, 10(6): 2326-2333.
- [43] 李文华, 邵方旭, 暴二平, 等. 六自由度振动老化条件下锂离子电池的衰退机理诊断与 SOH 预测[J]. 仪器仪表学报, 2021, 42(8): 62-69. LI Wenhua, SHAO Fangxu, BAO Erping, et al. Diagnosis of degradation mechanism and SOH prediction of lithium-ion batteries under 6-DOF vibration and aging conditions[J]. Chinese Journal of Scientific Instrument, 2021, 42(8): 62-69.
- [44] VILSEN S B, STROE D I. Transfer learning for adapting battery state-of-health estimation from laboratory to field operation[J]. IEEE Access, 2022, 10: 26514-26528.
- [45] DONG G Z, HAN W J, WANG Y J. Dynamic Bayesian network-based lithium-ion battery health prognosis for electric vehicles[J]. IEEE Transactions on Industrial Electronics, 2021, 68(11): 10949-10958.
- [46] TANG X P, GAO F R, LIU K L, et al. A balancing current ratio based state-of-health estimation solution for lithium-ion battery pack[J]. IEEE Transactions on Industrial Electronics, 2022, 69(8): 8055-8065.
- [47] YE Z, YU J B. State-of-health estimation for lithium-ion batteries using domain adversarial transfer learning[J]. IEEE Transactions on Power Electronics, 2022, 37(3): 3528-3543.
- [48] BIAN X L, WEI Z B, HE J T, et al. A novel model-based voltage construction method for robust state-of-health estimation of lithium-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2021, 68(12): 12173-12184.
- [49] 张吉昂, 王萍, 程泽. 基于充电电压片段和融合方法的锂离子电池 SOC-SOH-RUL 联合估计[J]. 电网技术, 2022, 46(3): 1063-1072. ZHANG Ji'ang, WANG Ping, CHENG Ze. A joint estimation framework of SOC-SOH-RUL for lithium batteries based on charging voltage segment and hybrid method[J]. Power System Technology, 2022, 46(3): 1063-1072.
- [50] CHEN Z, XUE Q, XIAO R X, et al. State of health estimation for lithium-ion batteries based on fusion of autoregressive moving average model and Elman neural network[J]. IEEE Access, 2019, 7: 102662-102678.
- [51] 王英楷, 张红, 王星辉. 基于 1DCNN-LSTM 的锂离子电池 SOH 预测[J]. 储能科学与技术, 2022, 11(1): 240-245. WANG Yingkai, ZHANG Hong, WANG Xinghui. Hybrid 1DCNN-LSTM model for predicting lithium ion battery state of health[J]. Energy Storage Science and Technology, 2022, 11(1): 240-245.
- [52] SHU X, SHEN J W, LI G, et al. A flexible state-of-health prediction scheme for lithium-ion battery packs with long short-term memory network and transfer learning[J]. IEEE transactions on Transportation Electrification, 2021, 7(4): 2238-2248.
- [53] 蔡艳平, 陈万, 苏延召, 等. 锂离子电池剩余寿命预测方法综述[J]. 电源技术, 2021, 45(5): 678-682. CAI Yanping, CHEN Wan, SU Yanzhao, et al. Review of remaining useful life prediction for lithium ion batteries[J]. Chinese Journal of Power Sources, 2021, 45(5): 678-682.
- [54] BI J K, LIU H, LEE J C. Estimation of remaining useful life of Li-ion battery based on charging characteristic data[C]//2021 Global Reliability and Prognostics and Health Management. Nanjing, China: IEEE, 2021: 1-5.
- [55] PUGALENTHI K, RAGHAVAN N. A holistic comparison of the different resampling algorithms for particle filter based prognosis using lithium ion batteries as a case study[J]. Microelectronics Reliability, 2018, 91: 160-169.
- [56] AHWIADI M, WANG W. An enhanced particle filter technology for battery system state estimation and RUL prediction[J]. Measurement, 2022, 191: 110817.
- [57] OUYANG T C, XU P H, CHEN J X, et al. An online prediction of capacity and remaining useful life of lithium-ion batteries based on simultaneous input and state estimation algorithm[J]. IEEE Transactions on Power Electronics, 2021, 36(7): 8102-8113.
- [58] 焦自权, 范兴明, 张鑫, 等. 基于改进粒子滤波算法的锂离子电池状态跟踪与剩余使用寿命预测方法[J]. 电工技术学报, 2020, 35(18): 3979-3993. JIAO Ziquan, FAN Xingming, ZHANG Xin, et al. State tracking and remaining useful life predictive method of Li-ion battery based on improved particle filter algorithm[J]. Transactions of China Electrotechnical Society, 2020, 35(18): 3979-3993.
- [59] JIAO R H, PENG K X, DONG J. Remaining useful life prediction of lithium-ion batteries based on conditional variational autoencoders-particle filter[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(11): 8831-8843.
- [60] ALI M U, ZAFAR A, NENGROO S H, et al. Online remaining useful life prediction for lithium-ion batteries using partial discharge data features[J]. Energies, 2019, 12(22): 4366.
- [61] KHALEGHI S, HOSEN M S, KARIMI D, et al. Developing an online data-driven approach for prognostics and health management of lithium-ion batteries[J]. Applied energy, 2022, 308: 118348.
- [62] LIU K L, SHANG Y L, 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.
- [63] 梁海峰, 袁芃, 高亚静. 基于 CNN-Bi-LSTM 网络的锂离子电池剩余使用寿命预测[J]. 电力自动化设备, 2021, 41(10): 213-219. LIANG Haifeng, YUAN Peng, GAO Yajing. Remaining useful life prediction of lithium-ion battery based on CNN-Bi-LSTM network[J]. Electric Power Automation Equipment, 2021, 41(10): 213-219.
- [64] REN L, DONG J B, WANG X K, et al. A data-driven auto-CNN-LSTM prediction model for lithium-ion battery remaining useful life[J]. IEEE Transactions on Industrial Informatics, 2021, 17(5): 3478-3487.
- [65] QIAO J S, LIU X F, CHEN Z H. Prediction of the remaining useful life of lithium-ion batteries based on empirical mode decomposition and deep neural networks[J]. IEEE Access, 2020, 8: 42760-42767.
- [66] ZHANG C L, ZHAO S S, HE Y G. An integrated method of the future capacity and RUL prediction for lithium-ion battery pack[J]. IEEE Transactions on Vehicular Technology, 2022, 71(3): 2601-2613.

- [67] DONG H C. Prediction of the remaining useful life of lithium-ion batteries based on Dempster-Shafer theory and the support vector regression-particle filter[J]. IEEE Access, 2021, 9: 165490-165503.
- [68] PUGALENTHI K, PARK H, HUSSAIN S, et al. Remaining useful life prediction of lithium-ion batteries using neural networks with adaptive Bayesian learning[J]. Sensors, 2022, 22(10): 3803.
- [69] PAN D W, LI H F, WANG S J. Transfer learning-based hybrid remaining useful life prediction for lithium-ion batteries under different stresses[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3501810.
- [70] CONG X W, ZHANG C P, JIANG J C, et al. A hybrid method for the prediction of the remaining useful life of lithium-ion batteries with accelerated capacity degradation[J]. IEEE Transactions on Vehicular Technology, 2020, 69(11): 12775-12785.



熊庆

1990—, 女, 博士, 副教授, 硕导
研究方向为新能源系统故障特性和诊断技术
E-mail: xq_xjtu@163.com

XIONG Qing
Ph.D.

Associate professor



邸振国(通信作者)

1999—, 男, 博士生
研究方向为直流系统故障诊断和等离子体炬
E-mail: dzg_xjtu@163.com

DI Zhenguo

Ph.D. candidate

Corresponding author



汲胜昌

1976—, 男, 博士, 教授, 博导
研究方向为电力设备故障诊断与状态评估
E-mail: jsc@xjtu.edu.cn

JI Shengchang
Ph.D., Professor

收稿日期 2022-11-07 修回日期 2023-10-11 编辑 程子丰