

DOI: 10.19783/j.cnki.pspc.240715

退役动力锂离子电池健康状态及剩余使用寿命预测技术研究

陈宏宇¹, 陶志军^{1,2}, 朱永利², 胡仁宗^{1,2}, 袁斌^{1,2}

(1. 华南理工大学材料科学与工程学院, 广东 广州 510641; 2. 广东华菁新能源科技有限公司, 广东 佛山 528313)

摘要: 准确估计退役动力锂离子电池的健康状态和预测其剩余使用寿命, 对保障其安全运行及促进梯次利用具有重要意义。传统的健康状态检测方法效率低, 且缺乏有效评估退役电池价值的方法。基于数据驱动的人工智能方法在此领域有着独特的应用优势。从实际应用的角度出发, 综述了近年来国内外在电池健康状态估计和剩余使用寿命预测方面的最新进展。首先介绍了锂电池健康状态估计以及剩余使用寿命预测方法, 着重总结了基于数据驱动的剩余使用寿命预测方法的研究现状, 对比了不同方法的优缺点。最后, 针对当前研究中存在的关键问题提出了一些解决思路, 并对未来的发展方向进行了展望。

关键词: 退役锂离子电池; 健康状态估计; 剩余使用寿命预测; 梯次利用

Research on health status and remaining useful life prediction technology for retired lithium-ion power batteries

CHEN Hongyu¹, TAO Zhijun^{1,2}, ZHU Yongli², HU Renzong^{1,2}, YUAN Bin^{1,2}

(1. School of Materials Science and Engineering, South China University of Technology, Guangzhou 510641, China;

2. Guangdong Huajing New Energy Technology Co., Ltd., Foshan 528313, China)

Abstract: Accurately estimating the state of health (SOH) and predicting the remaining useful life (RUL) of retired lithium-ion power batteries is of great significance for ensuring their operational safety and promoting secondary utilization. Traditional SOH detection methods are inefficient and lack effective ways for evaluating the value of retired batteries. Data-driven artificial intelligence methods offer unique advantages in this field. From a practical application perspective, this paper reviews the latest research progresses in SOH estimation and RUL prediction. First, the methods for estimating SOH and predicting RUL of lithium-ion batteries are introduced, with a focus on data-driven approaches. Then, the advantages and disadvantages of different methods are compared. Finally, key issues in current research are presented, potential solutions are proposed, and future development directions are discussed.

This work is supported by the Excellent Young Scientists Team Fund of Natural Science Foundation of Guangdong Province (No. 2023B1515040011).

Key words: retired lithium-ion battery; state of health estimation; prediction of remaining useful life; secondary utilization

0 引言

自2015年以来,为实现“碳中和、碳达峰”目标,在国内相关政策支持下,新能源汽车产业持续高速发展。根据中国汽车工业协会的统计数据,2023年全年新能源乘用车累计销量达949.5万辆,同比增长37.9%。一般认为,当动力电池容量下降到额定容量的80%时,便不再符合汽车使用要求,需要

退役处理。动力电池使用年限通常为5~8年^[1],较早投入使用的汽车动力电池已开始逐步退役,每年的退役量逐年增加,并将在未来几年内迅猛增长。尽管退役动力电池不再适合作为动力电池使用,但大部分退役电池仍有50%甚至更高的剩余容量。符合一定标准的退役电池可以进行降级梯次利用,例如应用于旅游观光车、三轮电动自行车或基站备电等对电池要求较低的场景中,从而最大化其剩余价值^[2]。

处理退役电池的关键步骤是筛选出符合梯次利用标准的电池。目前,企业在电池单体容量测试中

基金项目: 广东省自然科学基金卓越青年团队项目资助(2023B1515040011)

面临效率瓶颈。实际生产中主要依赖分容柜直接测试剩余容量, 这导致一次电池单体容量测试耗时约 10 h, 效率极低。因此, 开发高效、快速的电池健康状态(state of health, SOH)检测及剩余使用寿命(remaining useful life, RUL)预测方法, 对相关产业的快速发展至关重要。近年来, 人工智能算法发展迅速, 已广泛应用于各行各业^[3]。汽车行业也不例外, 尤其是在新能源汽车的电池管理系统(battery management system, BMS)中, 依靠各种算法为驾驶员提供车况和电源信息已成为标配。这些算法同样可以应用于电池 SOH 的快速检测及 RUL 预测领域。有些算法基于电池老化机理; 有些则以数据驱动为出发点, 不依赖于电池内部反应机理; 当然也有一些结合了前两类算法的融合方法。准确快速的电池 SOH 估计可以帮助电池回收企业提高退役电池的分筛效率, 节约时间成本; 而精确的 RUL 预测则可以帮助企业评估退役电池的利用价值及其适用的再利用场景。本文综述了电池的老化机理以及电池 SOH 快速估计、RUL 预测方面的一些最新研究方法及其优缺点, 为后续研发和企业实际生产应用提供有益参考。

1 锂离子电池老化机理

要实现快速评估电池健康状态及预测其剩余寿命, 首先需要了解其老化的内在机理。如图 1 所示, 电池的老化现象是其循环过程中内部多种物理和化学变化综合作用的集中体现, 主要可以包括电极材料损耗、固体电解质界面(solid electrolyte interface, SEI)膜分解、电解液消耗以及隔膜老化。电池老化主要表现为电池可逆容量衰减、功率性能下降、充放电效率降低及热稳定性下降。电池老化在外特性上的主要表现是电池容量下降和内阻增加。此外, 由于内阻变化的不一致性, 电池组中的各单体会出现温升不一致的现象, 增加了电池组系统热管理的难度和热失控的风险。

与电极材料相关的电池老化主要受多种因素影响, 包括电极活性材料损失、集流体溶解、锂枝晶生长等。电极材料中负极损失和活性锂损失的主要原因是负极析锂。在较低的工作温度、较高的电荷状态(state of charge, SOC)或较高的充电速率下, 负极的过电位要高于 Li/Li^+ 氧化还原电对, 锂离子优先得到电子成为金属锂沉积到电极表面^[4]。沉积的部分锂形成锂枝晶或被 SEI 隔离, 称为“死锂”, 导致活性锂减少^[5]。沉积的锂金属形成锂枝晶时, 还可能刺穿隔膜, 造成电池内部短路^[6]。循环过程中, 材料内部温差和体积变化造成的局部应力会导

致电极裂纹, 进而导致容量的不可逆衰减^[7-8]。严重情况下, 电极与集流体分离, 电池内阻因两者接触面积减少而增加。当电池过放时, 负极集流体铜箔溶解, 在电极上形成枝晶, 这影响活性锂嵌入电极并可能造成内部短路^[9]。当电池过充时, 正极集流体铝箔被腐蚀^[10], 导致其与电极活性材料之间的附着力减弱, 并增大电池内阻^[11]。

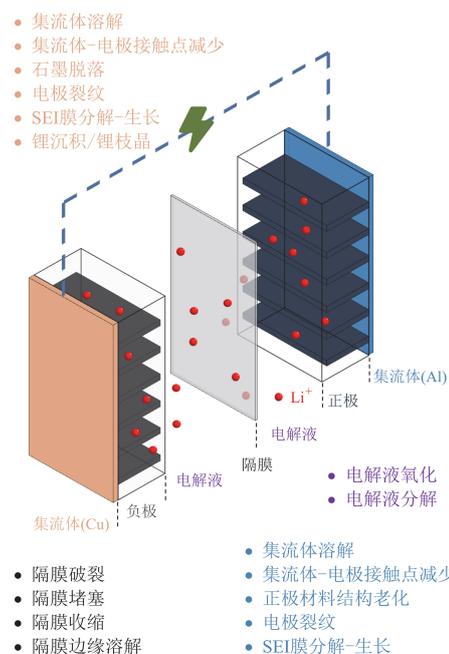


图 1 导致锂电池老化的内部机理示意图

Fig. 1 Internal mechanism diagram of lithium battery aging

SEI 膜是在电池初次充放电循环过程中形成的一层钝化膜, 它的生成会消耗电极活性物质和电解质^[12], 因此稳定的 SEI 膜对锂离子电池系统至关重要。在电池使用过程中, 由于电极体积变化、自身热分解以及锂枝晶等因素的影响, SEI 膜会出现裂纹, 导致其失效。失效处的负极材料失去保护, 直接与电解质接触, 两者再次发生反应, 这一过程导致负极活性物质和电解质的损耗增加。SEI 膜的反复失效-形成, 使其变得不均匀, 最终导致内阻、容量及功率性能的恶化^[13]。

电解液作为锂离子在正负极之间的传输介质, 随着循环次数的增加, 其成分会因氧化或分解导致浓度下降, 进而降低其传质能力、增加电池内阻。不同研究者对使用过的商用电池样品进行了深入分析, 结果都证明电解液发生了不同程度的损耗^[14-15]。电解液的损耗不仅增加电池内阻, 还导致电池容量和充放电功率的下降, 对电池的老化有着显著影响^[16]。

隔膜的主要作用是隔离正负两极, 避免电池内

部出现接触短路,同时确保电解质中的锂离子在充放电过程中自由转移^[17]。不同的研究均表明,电池老化过程中,溶解并沉积在隔膜上的电极活性物质会导致电池阻抗增加和功率性能下降^[18-19]。此外,隔膜自身的膨胀导致的孔隙减小及机械应变也会增加离子通过的阻力^[19-20]。一般来说,隔膜面积比正负极片更大,以保证两者不发生直接接触。当隔膜边缘溶解或收缩时,会导致正负极直接接触,形成内部短路^[21]。更严重的情况下,锂枝晶生长刺穿隔膜,导致内部短路^[22],电池容易起火甚至爆炸。因此,隔膜的老化失效不仅会影响电池性能,更是危及电池安全性的一大关键因素。

2 退役锂电池 SOH 快速估计技术研究现状

SOH 可定量描述电池内部各种物化反应导致的老化。由于电池老化主要表现为容量衰减和内阻增加,因此 SOH 通常用电池容量或内阻来定义。在实际研究中,以容量定义 SOH 更为常见^[23]。SOH 的容量定义为

$$S_{OH} = \frac{c_i}{c_N} \times 100\% \quad (1)$$

式中: c_N 为电池的额定容量; c_i 为当前电池的实际容量,实际容量是在标准充放电条件下测试得到的。当电池全新时,当前实际容量即为额定容量,SOH 为 100%。相似地,SOH 的内阻定义^[4]为

$$S_{OH} = \frac{R_{EOL} - R_i}{R_{EOL} - R_0} \times 100\% \quad (2)$$

式中: R_{EOL} 为电池寿命终止(end of life, EOL)时刻的内阻; R_0 为电池的初始内阻; R_i 为电池的当前内阻。然而,由于电池内阻存在不一致性且其变化具有一定随机性,难以确定 R_0 和 R_{EOL} , 因此内阻定义的 SOH 并不常用。

SOH 估计是通过测量电池运行数据并进行分析计算得出的。根据是否需要脱离正常工作状态,SOH 估计可分为在线估计和离线估计。在线估计通常通过各种电子产品和新能源汽车上的 BMS 实现,通过电池运行数据估计电池当前的健康状态,方便使用者和维护者即时了解电池状况;而离线估计则应用于各种电池的检测场景,例如对退役电池进行 SOH 检测,并以此为依据判断其是否符合梯次利用标准。目前,锂电池 SOH 估计方法主要可以分为直接测量方法、基于模型的估计方法、基于数据驱动的估计方法和融合方法。

2.1 直接测量方法

直接测量方法包括直接测量剩余容量及内阻

来估计电池 SOH。

直接测量容量通常使用分容柜,通过将电池充电至 SOC 为 100%,而后按照测试标准倍率恒流放电到截止电压,从而获得电池当前的容量。该方法的准确性依赖于测试设备对电池充放电电流的测量精度和对 SOC 估计的准确性^[23]。测试获得电池的剩余容量后,根据 SOH 的容量定义计算得到准确的 SOH。此类容量测试通常需耗时 3~8 h,具体耗时受测试设定的充放电倍率和搁置时间等参数影响。尽管通过容量测试获取 SOH 耗时较长,但这是最准确的方法。通常,将通过这种方法获得的 SOH 作为标准值,为其他估计方法提供参考值,并评价其准确性。

直接测量内阻的变化通常利用电化学阻抗谱。根据电化学阻抗谱测试结果绘制 Nyquist 图,可以从中识别电池内部的阻抗信息^[25],从而根据 SOH 的内阻定义估计 SOH。更多情况下,利用电化学阻抗谱估计 SOH 时需要结合等效电路模型^[26]。

2.2 基于电池模型的 SOH 估计方法

用于估计 SOH 的模型方法主要有两种:等效电路模型和电化学模型。模型基于反映电池内部变化的物理化学机理建立,因而此类方法具有较强的可解释性。在实际应用中,评价模型的优劣主要从精确度和复杂度两个方面出发。两者通常存在矛盾,高精度的模型往往较为复杂,因此理想模型在满足精确度要求的同时应尽可能简单。

等效电路模型将电池抽象为一个相对简单的等效电路^[27],常用的等效电路模型包括内阻模型、PNGV 模型和二阶电阻-电容(resistance capacitance, RC)模型等^[28]。利用模型可以得到电路参数,如内阻、开路电压和 SOC,再结合卡尔曼滤波等方法,可以较为准确地估计 SOH,估计相对误差(relative error, RE)小于 1%^[29]。由于等效电路模型复杂度低且预测精度较高,非常适合应用于 BMS 中^[30]。

相比之下,电化学模型要复杂得多。电化学模型通常是基于电池内部老化的某种机理建立,需要充分考虑电池内部各种因素的变化,并输入大量物理化学参数进行求解,计算复杂^[31]。通常需要对电化学模型进行简化以降低求解难度后才能加以利用^[28,32]。常用的电化学模型有伪二维模型^[33]和单粒子模型^[28]等。此外,电化学模型的建立往往针对特定电池种类及工况,适应性较差。加之其求解计算量较大,不适合应用于 BMS 的在线检测;但是对于特定电池的离线检测,由于不受 BMS 计算能力的限制,在精确度上更具有优势。

2.3 基于数据驱动的 SOH 快速估计方法

基于数据驱动的 SOH 快速估计方法无须考虑锂电池内部复杂的反应过程, 将锂电池视作黑箱系统, 通过分析大量电池运行或测试数据, 挖掘其中能够反映电池健康状态的特征信息进行 SOH 估计。与目前企业在实际生产中通过分容柜直接测试电池容量获得 SOH 的方法相比, 基于数据驱动的 SOH 快速估计方法, 只需要测试部分电压范围的充放电数据或进行简单测试获得电池内阻等外特性数据, 以这些数据作为输入即可高效估计出 SOH。目前, 分容柜直接测试电池容量获得 SOH 的效率低下, 主要原因是容量测试耗时长, 而基于数据驱动的快速估计方法通过减少电池测试项目耗时来实现高效 SOH 估计^[34]。

用于 SOH 快速估计算法训练以及 SOH 快速估计输入的数据可以是电池在线运行时的数据, 也可以是离线测试得到的数据。在线运行数据包括电池使用过程中的充放电电流曲线、电压曲线及温度曲线等, 也可以是这些原始数据进一步处理后的特征数据, 例如通过容量增量分析(incremental capacity analysis, ICA)法或差分电压分析(differential voltage analysis, DVA)法得到的 IC 和 DV 曲线的峰位、峰高和包络面积等特征数据^[35]。离线测试的数据可以是和上述在线运行数据一样的电流、电压等数据外, 还可以是一些需要单独测试的外特性数据, 如开路电压和电池内阻等。

数据驱动方法可分为数理统计方法和人工智能方法两大类。

数理统计方法主要包括高斯过程回归(Gaussian process regression, GPR)及其衍生方法。GPR 可以通过核函数将低维的非线性问题转换到高维空间, 变成线性问题^[36], 其需要的学习参数较少, 且训练耗时短, 适用于小样本的应用场景^[37]。

人工智能方法是通过数据集训练, 提取特征值(或称健康因子), 并建立其与 SOH 之间的映射关系, 从而估计 SOH, 流程如图 2 所示。常用的算法包括人工神经网络(artificial neural network, ANN)^[38]、支持向量机(support vector machine, SVM)^[39]和卷积神经网络(convolutional neural network, CNN)^[40]等。在训练数据集足够大的情况下, 这些方法可以较精确地估计 SOH。例如, 文献[41]利用 ICA 和 DVA 方法分析得到 4 个特征值, 用于简单的多层 ANN 训练, 所得模型估计 SOH 的平均绝对误差(mean absolute error, MAE)均不超过 0.01Ah。文献[39]使用 SVM 对选取的 15%长度的充放电曲线进行相似性分析和 ICA, 实现 95%的测试样本 SOH 估计相对

误差小于 3%。类似地, 文献[40]使用 CNN, 仅利用完整充电 9000 s 数据中的 1000 s 数据, 实现 SOH 估计, MAE 不超过 1.73%; 使用 250 s 数据时, MAE 仍不超过 2.88%, 根据该研究推算, 若在实际测试中使用此方法, 电池测试时间可以缩短至原来的 10%左右, 相比直接测试容量得到 SOH, 实现了高效快速的 SOH 估计。表 1 总结了 4 种基于数据驱动的单方法能够达到的精度以及所采用的特征值。

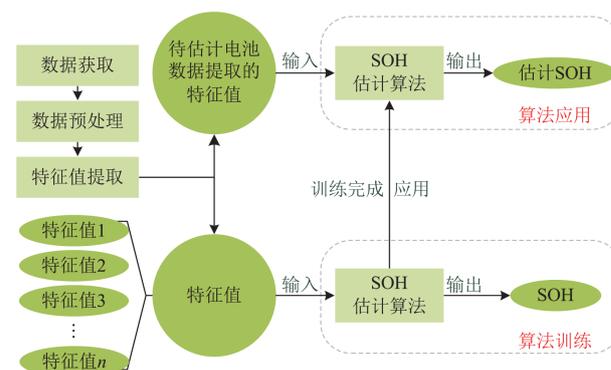


图 2 基于人工智能方法的电池 SOH 估计流程图

Fig. 2 Flowchart of battery SOH estimation based on artificial intelligence methods

表 1 部分文献所用方法 SOH 估计精度、特征值比较

Table 1 Comparison of the accuracy and eigenvalues of SOH estimation in some reported methods

方法	精度指标	特征值	参考文献
MLP	MAE 小于等于 0.0075	IC、DV 曲线特征	[41]
ANN	RE 小于等于 3.09%	IC 曲线特征	[38]
SVM	RE 小于等于 3% (95%的估计案例)	充电曲线片段	[39]
CNN	MAE 小于等于 1.73%	充电曲线片段	[40]

目前, 很少有研究者使用单一算法的数据驱动方法, 大多数情况下是将数据驱动方法与模型方法进行结合, 或将不同的数据驱动方法融合, 这被称为融合方法。融合方法结合了不同方法的优点, 表现出比单一方法更加优异的性能^[42]。文献[43]采用分数阶粒子群算法结合交叉学习方法识别锂电池等效电路模型的参数, 并对所得参数与 SOH 进行相关性分析, 选取具有代表性的模型参数作为附加特征值, 训练视觉变换器(vision transformer, VIT)网络, 所提方法在多个电池样本上验证, SOH 估计平均 MAE 仅为 0.36%。

为提高 SOH 估计算法在不同电池上的适应性, 研究者们开始关注迁移学习在 SOH 估计领域的应用^[44-46]。文献[44]基于 5 个不同的数据集, 设计验证了一种基于深度学习-迁移学习框架的 SOH 估计

方法,该方法能够在仅使用源域标签数据的情况下实现目标域的无标签训练,SOH 估计绝对误差不超过 8.87%,且 89.4%的样本绝对误差控制在 3%以内。

总的来说,选择合适的特征值作为算法输入,在训练数据充足的情况下,利用数据驱动算法对单一类型电池 SOH 进行估计,现有方法都可以达到优秀的估计精度。此外,研究者们也开始关注 SOH 估计算法在不同型号电池上的通用性。数据驱动算法估计 SOH 具有获取所需数据测试时间短的优势,可以实现 SOH 快速估计,在精度满足实际生产需要的情况下,具有实际应用潜力。

2.4 动力电池 SOH 快速估计面临的挑战

目前,BMS 中应用的 SOH 在线估计方法已非常成熟。在正常使用电池的过程中,通过 BMS 记录的充放电曲线就可以很好地估计电池 SOH。然而,脱离 BMS、没有历史运行数据的离线 SOH 快速估计存在极大挑战。

首先,基于模型的 SOH 估计方法的性能依赖于对锂电池中复杂电化学过程的准确描述,但由于内部结构和外部工作条件的时变性,模型中的描述方程及状态参数难以对这些变化作出准确响应,从而使估计的准确性降低。其次,虽然基于数据驱动的 SOH 快速估计方法无须通过电池内部相关机理构建预测模型,但这些算法通常需要大量训练数据和算力资源。SOH 估计的精度与所需算力资源往往是矛盾的,因此如何利用有限的算力资源快速准确地实现 SOH 估计一直是科研工作者努力的方向。最后,用于 SOH 快速估计算法训练的电池数据难以快速获取。在线估计方法可以从记录的在线运行数据中获得训练数据集,但在离线情况下,这些数据需要通过大量测试积累。如何在无历史数据情况下快速积累用于算法训练的数据集,成为实现离线 SOH 快速估计亟待解决的关键问题。

3 退役锂电池 RUL 预测技术研究现状

锂电池 RUL 指在一定工况条件下,电池 SOH 衰减到特定阈值的循环次数。例如,对于汽车动力电池,这个阈值为 80%;而对于梯次利用电池,这个阈值因应用场景不同而有所不同,最低为 30%。电池 RUL 的预测通常以 SOH 估计为基础,通过分析 SOH 的衰减趋势来预测 RUL。对于梯次利用产业来说,RUL 的准确预测具有重要的实用价值和研究意义,因为 RUL 反映了退役动力电池的剩余价值,是判断退役电池适用于何种梯次利用场景或是直接拆解回收的主要标准,关系到企业的经济效益。

SOH 是 RUL 预测的主要依据,RUL 的预测方

法与 SOH 的估计方法类似,大致可分为基于模型的预测方法、基于数据驱动的预测方法以及融合方法。目前主流的 RUL 预测方法多以数据驱动方法为基础,通过结合多种数据驱动方法或结合模型形成融合方法。

3.1 模型驱动方法

模型驱动的 RUL 预测方法与基于电池模型的 SOH 估计方法类似,均通过物理化学原理建立相应的机理模型,包括等效电路模型和电化学模型等。不同的是,SOH 估计主要通过模型参数来估计电池的 SOH,而 RUL 预测则通过模型参数在电池老化过程中的演变来预测 SOH 的衰减趋势和 RUL。

卡尔曼滤波(Kalman filter, KF)算法、粒子滤波(particle filter, PF)算法及其变体等滤波方法,需要建立状态转移模型和观测模型,因此也属于模型方法。通常,滤波方法可以结合已建立的简单经验模型或机理模型来预测电池 RUL,并量化结果的不确定性^[47-52]。

文献[47]基于 3 种不同的经验模型,使用 PF 更新模型参数,并利用 PF 变体交互多模型粒子滤波进行 RUL 预测,提高了经验模型的预测精度,预测结果 MAE 不超过 0.0384,在输入超过 80 个循环的情况下(所选取的电池数据共 250 个循环,EOL 位于约第 210 个循环),绝对误差(absolute error, AE)不超过 16 个循环,最大 RE 约为 12.31%。文献[48]基于相似思路,以经验模型为基础,使用无迹卡尔曼滤波(unscented Kalman filter, UKF)、PF 和线性优化实现多重采样进行 RUL 预测,相比单一滤波方法,在输入 40 个循环数据的条件下,其预测结果的均方根误差(root mean square error, RMSE)从 0.096 73 减小到 0.036 89,RE 从 13.90%减小到 4.60%。另外,文献[49]基于经验退化模型结合改进 PF,在以 350 个循环作为预测起点的情况下,实现了预测 RE 小于等于 2.52%,AE 不超过 13 个循环。

利用机理模型预测 RUL,通常需要结合滤波方法进行机理模型参数的预测更新。文献[50]在构建基于 PF 的预测算法状态方程和观测方程时结合了简化电化学模型,使得反映容量的状态变量具有明确的物理意义,在预测起点为第 80 个循环(所选取的电池 EOL 为第 250 个循环)的情况下,RUL 预测 AE 为 12 个循环,RE 为 7.06%。文献[50]中采用的数据来自作者设计的循环老化实验,每 20 个老化周期识别一次电池的模型参数,这是目前一些开源数据集不具备的。文献[51]利用增强单粒子模型的参数估计出 SOH,再将估计得到的 SOH 输入到 PF 算法预测 SOH 后续衰减得到 RUL,该文献中使用的

数据同样来自作者自行设计的电池老化实验。文献[52]利用单粒子模型将锂电池的活性锂损失、正极活性物质损失和负极活性物质损失3种退化机制量化表达,结合改进PF预测估计模型参数演化,在1000个循环作为预测起点的情况下,实现了RUL预测AE不超过10个循环。

然而,模型驱动方法存在明显的缺陷:首先,机理模型的建模难度大且泛化能力差,而经验模型精度较低;其次,模型驱动方法无法直接使用现有的开源电池数据集,因为这些不同模型参数需要在电池循环老化测试中加入针对性的测试项目进行识别,这是开源数据集无法提供的。因此,开发基于模型的预测方法通常需要花费大量时间进行针对性的电池循环老化实验以获取所需数据。

3.2 数据驱动方法

数据驱动方法通过相应算法处理测试得到的各种电池历史数据并提取出特征值,以此训练模型,直接建立历史数据与RUL之间的映射关系,或通过图3所示的迭代或非迭代方式,得到历史数据与剩余循环容量衰减曲线之间的关系,实现对RUL的间接预测。直接建立历史数据与RUL映射关系的方法,尽管其模型结构更加直接、简单,但其存在无法预测电池容量衰减的趋势、精度不高的缺陷。因此,本部分主要讨论基于预测剩余循环容量衰减曲线的间接RUL预测方法,并将数据驱动方法概括为基于随机过程、基于时间序列、基于人工智能的3类方法进行详细讨论。

3.2.1 基于随机过程的方法

锂电池的衰减具有很强的随机性和不确定性,因此可以用随机过程来描述。在RUL预测中,主要采用GPR和维纳过程两种方法。

1) GPR

GPR是一种基于贝叶斯推理的非参数统计方法,通过先验知识和观测数据建立电池性能衰减的概率模型,并提供预测结果及其不确定性。文献[53]将充放电曲线转化为IC曲线,提取特征值,并利用皮尔逊相关性分析不同特征值与电池容量之间的相关性,分析后的特征值作为基于GPR容量预测模型的输入量,输出预测的电池退化曲线,得到RUL预测结果的RMSE小于等于0.0175,在预测起点为第60个循环(所选取的电池数据共168个循环)的情况下,RE约为14%,预测起点为第100个循环的情况下,RE约为3.33%。文献[54]从充放电数据中提取了4个特征值,并利用主成分分析法进行降维处理,将降维处理后的特征值作为改进GPR模型的输入量,在使用前60%的数据作为训练集的情况下,

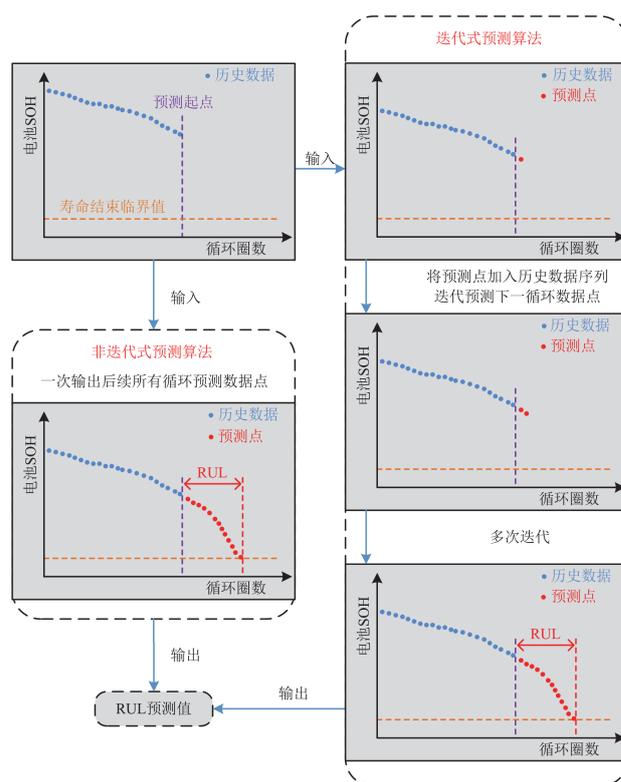


图3 数据驱动方法间接预测电池RUL的流程图
Fig. 3 Flowchart of indirect prediction of battery RUL using data-driven methods

预测结果的RMSE小于等于0.0117,平均绝对百分比误差(mean absolute percentage error, MAPE)小于等于0.67%。

2) 维纳过程

维纳过程是一种典型的随机过程,被广泛应用于衰减过程的模拟中^[55]。文献[56]提出了一种具有随机时变协变量的非线性维纳过程模型,用于预测不同产品(电池、室外涂料)的RUL,该模型用于预测电池RUL时MAE小于等于0.0132^[56]。文献[57]基于维纳过程,提出了一种二元随机参数评估模型,利用极大似然估计算法估计参数后,得到了RUL的概率密度函数及对电池当前可靠性的评价。此外,更常见的是维纳过程与其他方法相结合进行RUL预测^[58]。

3.2.2 基于时间序列的方法

基于时间序列的RUL预测方法中,自回归(autoregressive, AR)模型及其变体应用最为广泛。电池的衰退是非线性的,而AR模型是线性的,因此常用的是AR模型的非线性变体或其与其他算法的结合体。差分整合移动平均自回归模型是AR模型的重要变种之一。文献[59]针对NASA电池数据集中

明显的容量再生现象, 利用经验模态分析(empirical mode decomposition, EMD)将原始 SOH 分解为包括全局退化趋势和容量再生等多个部分, 分别利用差分整合移动平均自回归模型预测其变化, 最后将各部分结果叠加实现 SOH 预测, 并间接得到 RUL 的预测值, 预测结果 AE 最大为 15 个循环, MAPE 约为 9.94%。文献[60]利用 PF 算法跟踪锂离子电池容量下降过程, 修正 AR 模型中的状态方程参数及观测值, 提高了 AR 模型的预测精度, RUL 预测结果 RMSE 小于等于 0.018 48。AR 模型及其变体显著的特点是复杂度低、计算量小、参数少, 但这也意味着 AR 模型难以捕捉数据中更复杂的模式和关系, 因此其预测精度不可避免地较差。

3.2.3 基于人工智能的方法

人工智能方法具有强大的非线性拟合能力和发掘数据中潜在信息的能力, 能够基于输入数据中的潜在信息预测电池容量的衰减, 无须考虑电池衰退机理, 是目前最受关注的电池 RUL 预测方法之一。本节主要讨论国内外几类热门的人工智能预测电池 RUL 方法。

1) ANN 及其变体

ANN 是一种模仿生物神经网络结构和功能的数学模型, 用于映射关系的估计或拟合。在 ANN 的基础上, 衍生出了递归神经网络(recursive neural network, RNN)、长短期记忆神经网络(long short-term memory, LSTM)、深度神经网络(deep neural network, DNN)和极限学习机(extreme learning machine, ELM)等多种改进算法。文献[61]提出了一种在深度学习框架下拥有多核心层的递归神经网络预测 RUL 方法, 即使面对电池老化过程中充放电工况的不确定性也能有良好的预测性能, 在训练数据集充分的情况下, 使用仅占完整寿命数据 3.8% 的输入时, 对三元锂电池和磷酸铁锂电池 RUL 预测的中位 RE 小于等于 7.20%。LSTM 是为解决一般的 RNN 存在的长期依赖问题改进而来的, 适用于锂电池 RUL 的长期预测。文献[62]以 LSTM 模型为基础, 输入为由容量、电压、电流和温度组成的多变量向量, 输出为预测容量, 构建了一种从多变量到容量的预测框架, 充分利用多维数据信息, 相比传统的容量到容量的预测方式精度更高, 在使用 30% 的循环数据用于训练的情况下, 预测 MAPE 小于等于 2.88%。文献[63]利用 11 个特征值, 首先通过一个包含 5 个隐藏层的 DNN 预测电池容量, 再将该预测结果输入另一个包含 65 个隐藏层的 DNN, 用于预测 RUL, 由于包含数十个隐藏层, 其计算量相比传统人工神经网络大幅度增加, 但预测效果没有明

显改善, RE 小于等于 7.63%, 是效费比偏低的一种方法。ELM 是一种由前馈神经网络发展而来的算法, 其模型参数初始化具有随机性, 但训练因子少, 学习速度快, 泛化能力强。文献[64]以特定放电电压区间放电时间、放电电压平均值、放电电池平均温度及当前循环周数作为新颖的健康状态指标, 经过相关性分析筛选后, 输入 ELM 算法中对电池容量衰减进行预测, 在输入 70 个循环数据的条件下, RUL 预测结果 RE 小于等于 3.23%。ELM 存在容易陷入局部最优解、因参数初始化随机性导致隐藏层神经元冗余的缺点, 容易出现精度降低及计算量增加的问题, 因此, 通常结合粒子群优化算法、灰狼优化算法等, 在训练过程中对 ELM 模型的超参数进行优化, 使预测算法达到较高的精度^[64-65]。

2) 支持向量机(support vector machine, SVM)及支持向量回归(support vector regression, SVR)

SVM 是一种用于二元分类的机器学习算法, 当其应用于数据回归分析时被称为支持向量回归 SVR。相比 ANN, SVM 不容易陷入局部最优解, 且适合小样本训练^[66]。文献[66]先利用 SVM 算法对电池进行粗略分类, 再对接近 EOL 时刻的电池使用 SVR 算法粗略估计 RUL; 该文献对模型进行了多种数据场景的模拟应用, 包括使用不同放电电流和截止电压的电池分别训练验证、单一电池训练验证以及不同温度下运行电池训练验证, 证明该分类-回归预测模型具有良好的适应性, 但预测精度不高, RMSE 最大为 0.8681, 最大 RE 为 10.75%。文献[67]通过提取等充电电压差的时间间隔、等放电电压差的时间间隔作为特征值, 并结合特征向量选择处理数据集以减少训练集数据量, 在预测误差基本保持不变的情况下, 提高了 SVR 模型的训练和预测效率(约 30%)。

3) 相关向量机(relevance vector machine, RVM)

RVM 是一种用于回归和分类的贝叶斯稀疏核方法, 通常用于短期预测, 长期预测能力较差。相比 SVM, RVM 还可以提供概率预测, 并且在相近精度下 RVM 需要的训练时间更短。文献[68]在 IC 曲线上提取特征值, 通过相关性分析筛选后得到两个健康因子, 并用贝叶斯算法优化 RVM 核函数超参数, RUL 短期预测(前 60%数据用于训练)MAE 不超过 0.0118, RE 不超过 5.45%, 长期预测(前 30%数据用于训练)MAE 不超过 0.0128, RE 不超过 7.29%。文献[69]利用多个核函数的线性组合提高 RVM 对电池 SOH 衰减的拟合能力, 并通过粒子群优化算法优化核函数参数, 提高了预测精度, 在以 40 个循环为起点进行预测时, 预测结果 RE 不超过 2.90%, 相

比单核算法的 5.90% 有显著提升。

3.3 融合方法

为了弥补单一算法或模型的不足, 并充分发挥各算法的优势及特点, 从而得到更精准的预测结果^[70], 使用融合方法已成为 RUL 预测的发展趋势。融合方法可分为两大类: 模型与数据驱动方法融合; 两种或多种数据驱动方法融合。

3.3.1 模型与数据驱动融合方法

等效电路模型和电化学模型通常将其模型参数作为数据驱动方法的输入特征值, 与数据驱动方法进行结合使用^[63,68,71]。更常见的是滤波方法与数据驱动方法的融合。

在融合方法中, 可以将不同特点、不同功能的算法作为完整预测算法的子模块, 最后由两个或多个子模块共同实现预测算法的完整功能。图 4 为融合 RUL 预测方法的模块化示意图, 一个完备的融合预测方法可以包含图中的所有子模块, 也可以只有部分子模块。当融合方法中存在滤波模块, 则可视为模型与数据驱动融合方法。

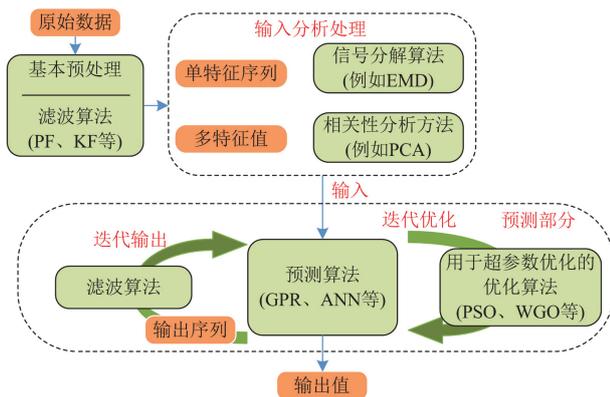


图 4 融合方法模块化示意图

Fig. 4 Modular schematic of fusion methods

原始数据可以经过简单的预处理得到单一的时序容量序列或几个和容量相关的特征值序列, 也可以添加滤波算法平滑输入序列减小噪音影响^[68]; 同样, 预测算法输出的预测序列也可以通过滤波算法处理后, 再作为观测值输入回预测算法进行迭代。

文献[68]中使用高斯滤波(Gaussian filter, GF)减弱了噪音的影响, 提高了模型的预测精度, 严格来说, 其所提方法也属于融合方法。文献[72]则是将最小二乘支持向量机(least squares support vector machine, LSSVM)的输出值作为无迹粒子滤波算法的观测值, 同时更新 LSSVM 的模型参数, 多步迭代预测容量衰减, 改善了 LSSVM 模型不适合长期预测的缺点, 提高了对电池长期 RUL 预测的精确度, 经过

不同数据集的检验, 预测结果最大 RMSE 不超过 0.0876, 虽然长期预测 RE 仍超过 10%, 但是解决了单纯 LSSVM 完全无法进行长期预测的问题。文献[73]利用自适应 UKF 实现过程噪声协方差和观测噪声协方差的自适应更新并提高滤波精度; 另一方面, 采用 SVR 实现多步预测, 并通过参数更新提高了 SVR 算法的预测精度。

3.3.2 数据驱动融合方法

单一数据驱动方法往往存在一定的局限性, 通过加权或其他方式组合两种或两种以上数据驱动的方法, 可以改善单一算法的局限性。在实际研究工作中, 很少用到单一方法, 大部分文献使用的数据驱动方法也并非严格意义上的单一方法^[47-48,58-60,64-65,67-69,73]。为介绍各类型具体的方法, 本文按照方法中起主要作用的部分总结到相应的方法类别中。

当融合方法中没有使用滤波方法等涉及建模的模块时, 可以将其视作数据驱动融合方法。输入分析处理部分可以根据需求选择性添加一个或多个数据处理方法, 也可以选择不对输入数据进行处理, 直接将其输入模型。信号分解算法可以将原始数据中的容量分解成多个部分^[59], 例如长期稳定部分和容量再生部分等; 而相关性分析方法则可以用于筛选与待预测值相关性高的特征值, 也可以用于数据降维^[54], 减少数据量。预测算法模块中, 也可以有多种方法融合协调工作^[74], 例如神经网络类型的算法可以融合不同变种的神经网络层^[75]。此外, 预测算法的核函数通常包含较多的超参数, 手动调参困难, 以粒子群优化为代表的优化算法可以在训练过程中实现自动优化模型参数^[64]。

文献[74]研究了 EMD、GPR 和 LSTM 在不同组合方式下预测锂离子电池 RUL 的性能, 其中 EMD 用于分解原始容量数据, GPR 能够捕捉到局部波动并量化容量再生现象造成的不确定性, LSTM 则可以实现容量衰减的长期预测, 上述模型单独应用和不同组合方式下应用的预测结果如表 2 所示, 同时也给出了各算法的精度比较。从表 2 可以看出, 相较单一算法, 融合方法的优势明显, 尤其是 LSTM + GPR + EMD 方法, 在给出了不确定性的同时预测精度在 5 种方法中同样是最高的, 最大 RE 不超过 3.26%。而文献[75]结合了 CNN 和 LSTM 的优点, 其提出的混合神经网络中包含两个 CNN 层和一个 LSTM 层, 其中 CNN 层用于挖掘数据中隐含的特征信息, LSTM 层实现容量衰减的长期预测, 预测的 AE 小于等于 6 个循环, 此外, 还利用假近邻法优化了输入数据的窗口大小。另外, 文献

[76]将经过多种相关性分析的健康因子输入 ELM 中,得到预测的容量衰减情况,再将 ELM 的输出值输入到 RVM 中获得不确定表达,并添加粒子群优化算法优化 RVM 和 ELM 的参数以提高预测性能,在预测起点为第 60 个循环(所选取的电池 EOL 为第 268 个循环)的情况下,预测结果 RE 小于等于 7.81%。文献[77]针对数据有限且稀疏的场景,利用局部加权回归(locally weighted scatterplot smoothing, LOWESS)对稀疏电压数据的缺失部分进行重构,以重构数据作为 LSTM 模型输入实现高精度 RUL 预测,RE 不超过 9.45%,平均 RE 仅为 3.30%。

表 2 不同算法结合方式的精度指标比较^[74]

Table 2 Comparison of accuracy in various algorithm fusion methods^[74]

模型方法	RMSE
GPR	0.1826
LSTM	0.0049
GPR + EMD	0.0036
LSTM + EMD	0.0034
LSTM + GPR + EMD	0.0032

近年来,越来越多的研究者开始关注 RUL 预测算法的适应性^[78-79]。迁移学习、半监督学习和无监督学习在 RUL 预测领域逐渐受到广泛关注。文献[80]提出了一种基于 Transformer 框架的结合视觉的半监督集成学习方法用于 RUL 预测,该方法在捕捉电池局部老化信息方面表现出色,并结合迁移学习实现了良好的适应性,经过不同开源数据集验证,RUL 估计的最大相对误差不超过 6.98%^[80]。

上述研究成果充分证明数据驱动融合方法在退役锂离子电池 RUL 预测领域中的优越性,无论在预测性能还是应用场景适应性方面均表现出色。

3.4 目前 RUL 预测的局限性和未来发展方向

3.1—3.3 节对目前各类型的 RUL 预测方法进行了详细分析,表 3 总结了前文讨论的不同预测方法的预测精度及其优缺点。精度指标中, RMSE 和 MAE 反映的是预测的容量衰减曲线与实际容量衰减曲线的符合程度,而 RE、AE 以及 MAPE 则直接反映 RUL 预测结果的准确性。由于部分文献中仅提供部分指标,表 3 中所总结的精度指标中有部分值为根据文献中的数据推测而来。本节主要讨论目前 RUL 预测研究领域存在的局限性,并指出未来可能的发展方向。

1) 目前的 RUL 预测研究中,忽视了算法实际应用效果,且算法的泛化应用适应性有待进一步验证。

大多数研究者所提算法的训练和验证使用的基本上都是知名的开源锂离子电池老化数据集,例

如美国 NASA 数据集和马里兰大学 CALCE 数据集。鲜有研究者对其建立的算法进行泛化性应用的尝试。笔者对现阶段使用开源数据集训练得到的算法在实际应用时的预测效果持谨慎态度,尤其是使用 NASA 数据集作为训练数据的算法。NASA 数据集因其所测试的电池型号老旧,大部分电池只有 200 左右的测试循环,已经与目前高速发展的动力电池技术存在很大的差距。相比之下,目前的商用电池拥有数千甚至上万个循环的循环寿命。因此,许多新数据集相继公开^[81-82],最新研究更倾向于使用新的数据集^[83-84]。

此外,电池的实际工况会比实验数据集的工况复杂得多,在复杂的实际工况下,这些算法的预测精度可能会下降。未来的研究者应更多地尝试在实际运行的电池系统中验证所建立模型的预测效果。

大多数文献所用的算法使用单一数据集,无法体现算法在应用场景中对其他型号电池进行预测时的适应性,并且使用单一数据集训练模型存在过拟合的可能性。

2) 如何快速采集电池信息也是一个亟待解决的关键问题。在线预测方法可以从记录的在线运行数据中挖掘用于 RUL 预测的特征值。然而,对于离线预测应用场景,如何高效快速地获得所需特征值仍需深入研究,这对提高预测效率至关重要。

3) 目前多数关于 RUL 预测的研究更关注算法的精度,对于算法训练和预测所需的算力资源鲜少讨论。然而,算法消耗的算力资源反映了算法效率,亦应受到足够的重视。若 RUL 预测算法大幅增加模型复杂度、而精度提高有限,在实际应用中是不可接受的。因此,未来的研究应加强对 RUL 预测算法效率的讨论。

4) 大多数锂电池 RUL 预测研究以应用于 BMS 为出发点,旨在为车辆动力电池 SOH 提供准确评估并及时提示更换电池。目前,退役汽车动力电池的数量正快速增长,梯次利用可最大限度发挥其价值。退役动力电池 RUL 是评判其剩余价值的主要指标,但是鲜有研究者以此为目标进行相关研究。一般认为,动力电池的退役标准是 SOH 降低至 80%,而在梯次利用场景下,对 SOH 的要求可以进一步降低,这对 RUL 预测模型提出了挑战。一方面,对预测模型的长期容量预测提出更高要求,需要算法在预测长期电池 SOH 衰减时保持较好的精度;另一方面,对预测模型的适应性提出更高要求,退役动力电池种类繁多,不同厂商不同型号的动力电池存在差异,为每款电池设计专用 RUL 预测算法是不实际的,因此开发对不同型号退役动力电池有较大包容

表 3 各类电池 RUL 预测算法的预测精度比较

Table 3 Comparison of predictive accuracy in various battery RUL prediction algorithms

方法类别	具体方法	精度指标	数据集	参考文献	优点	缺点	
模型驱动方法	滤波	MAE \leq 0.0384, RE \leq 12.31% (输入 80 个循环), RE \leq 6.15% (输入 100 个循环)	CALCE	[47]	可提高预测精度	难以独立应用于 RUL 预测, 需要结合其他模型	
		RE \leq 2.52%, AE \leq 13 (预测起点: 350 个循环, 实际寿命约 550 个循环)	CALCE	[49]			
		RMSE \leq 0.036 89, RE \leq 4.60%(输入 40 个循环); RMSE \leq 0.021 89, RE \leq 2.40%(输入 70 个循环)	NASA	[48]			
	机理模型	电化学模型 + PF	AE = 12 个循环, RE=7.06% (预测起点: 80 个循环); AE = 5 个循环, RE = 5.56% (预测起点: 160 个循环)	实验室自测数据集	[50]	可解释性强 意义明确	难以利用已有开源数据, 需要使用特定测试的数据, 适用性差
		增强单粒子模型 + PF	—	实验室自测数据集	[51]		
		单粒子模型 + PF 变体	AE \leq 10, (预测起点: 1000 个循环, 实际寿命约 2400 个循环)	实验室自测数据集	[52]		
数据驱动方法	随机过程	RMSE \leq 0.0175, AE \leq 10 (预测起点: 60 个循环, 实际 RUL 约 70 个循环); AE \leq 1 个循环(预测起点: 100 个循环, 实际 RUL 约 30 个循环)	NASA	[53]	适合小样本	计算量大, 超参数调整困难	
		RMSE \leq 0.0117, MAPE \leq 0.67% (前 60%数据作为训练集)	NASA	[54]			
		WP 及其变体	MAE \leq 0.0132 —	NASA 实验室自测数据集	[56] [57]	有不确定性表达能力	不适用于非线性和时间不均匀的数据
	时间序列	AR 及其变体	RMSE \leq 0.0504, AE \leq 15 个循环, MAPE 约为 9.94%	NASA	[59]	适合小样本 计算量小	精度低
			RMSE \leq 0.018 48	CALCE	[60]		
	人工智能	ANN	中位 RMSE \leq 0.024, 中位 RE \leq 7.20% (仅使用前 3.8%的数据)	实验室自测数据集, 斯坦福数据集	[61]	自主学习能力强, 算法精度高	缺乏不确定性表达能力, 需要样本量大
		ANN 变体(LSTM)	MAPE \leq 2.88% (前 30%数据作为训练集)	NASA	[62]		
		ANN 变体(DNN)	RE \leq 7.63%	NASA	[63]		
		ANN 变体(ELM)	RMSE \leq 0.0082, RE \leq 3.23%(输入 70 个循环)	NASA	[64]		
		ANN 变体(ELM)	RMSE \leq 0.0097 (输入 50 个循环); RMSE \leq 0.0043 (输入 70 个循环)	NASA	[64-65]		
		SVM/SVR	RMSE \leq 0.8681, RE \leq 10.75% RMSE \leq 0.0151, RE \leq 7.55% RMSE \leq 0.0351, RE \leq 2.90% (预测起点: 40 个循环)	NASA NASA,CALCE NASA	[66] [67] [69]		
	融合方法	数据驱动 + 模型	RVM + GF	MAE \leq 0.0128, RE \leq 7.29% (前 30%数据作为训练集); MAE \leq 0.0118, RE \leq 5.45% (前 30%数据作为训练集)	CALCE	[68]	提高数据驱动方法精度
KF 变体结合 SVR			RMSE \leq 0.036 89, RE \leq 4.60% (输入 40 个循环)	NASA	[73]		
多数据驱动		LSTM + GPR	RMSE \leq 0.0032, RE \leq 3.26%	NASA, CALCE	[74]	集合不同方法优点, 实用价值高	
		LSTM + CNN	AE \leq 6 个循环	NASA, CALCE	[75]		
		ELM+RVM	RE \leq 7.81% (预测起点: 60 个循环); RE \leq 4.55% (预测起点: 80 个循环)	NASA, CALCE	[76]		
		LOWESS + LSTM	RE \leq 9.45%, 平均 RE 为 3.30%(使用 20%数据)	牛津数据集, CALCE	[77]		
		集成学习	RE \leq 6.98%	NASA, CALCE, 牛津数据集	[80]		

性的预测算法非常必要。

此外,与在BMS中的应用不同,退役动力电池的RUL预测是离线进行的,不要求实时性,并且可以避免BMS算力有限的问题。这意味着,对于梯次利用电池的RUL预测,可以采用更为复杂的算法。

5) 根据技术路线的不同,目前主流的商用电池主要可以分为磷酸铁锂电池和三元锂电池。由于正极材料不同,两类电池在使用过程中的衰退速度及各模型特征随电池衰退变化的程度存在差异。即使在同一技术路线下,不同公司和型号的电池因所使用的电解液、隔膜等材料不同,同样会存在上述差异,这对RUL预测算法的适应性提出了挑战。为应对这一挑战,未来RUL预测算法设计可以做以下尝试:(1) 使用已有的不同锂电池衰退数据集训练同一个算法模型,使训练后的算法对不同类型的电池具有适应性;(2) 构建适应性更强的健康因子,即所构建的健康因子对于电池的类型不敏感,可以用于不同类型电池衰退程度的评价;(3) 尝试结合机器学习中的迁移学习概念,通过A类型电池数据训练算法,实现B类型电池衰退趋势的预测。

4 总结

本文从实际应用和服务于梯次利用的角度出发,总结了退役锂离子电池的老化机理、SOH快速估计及RUL预测方法。重点总结了近几年国内外关于锂离子电池RUL预测的研究成果,介绍了多类数据驱动方法和融合方法及其优缺点。最后,针对目前RUL预测研究现状,从算法实际应用、数据收集、特征值提取和梯次利用的角度提出了一些看法。总的来说,由于锂离子电池体系及实际工况的复杂性,数据驱动方法在RUL预测时具有突出的优势,融合方法可以弥补单一方法的不足,更具发展前景。

目前主流的商用锂离子电池主要可以分为三元锂电池和磷酸铁锂电池,两类电池衰退的差异性对SOH快速估计和RUL预测算法的适应性提出了很大的挑战。随着退役动力电池梯次利用的检测分类需求日益增加,亟需开发一种对不同型号电池有较强适应性且满足梯次利用需求的SOH快速估计及RUL预测技术。基于数据驱动的机器学习方法最具实用前景,它避免了复杂的机理建模过程,通过数据集学习SOH与特征值之间的映射关系以及SOH的衰减趋势,实现SOH快速估计和RUL预测。然而,算法对不同种类、不同型号的退役电池适应性较差、训练数据集获取困难,是其实际应用面临的主要障碍。

参考文献

- [1] 王斑. 我国新能源汽车动力电池回收体系的发展现状及建议[J]. 物流科技, 2019, 42(2): 72-75.
WANG Ban. Development status and suggestions of power battery recovery system for new energy vehicles in China[J]. Logistics Sci-Tech, 2019, 42(2): 72-75.
- [2] 刘坚. 电动汽车退役电池储能应用潜力及成本分析[J]. 储能科学与技术, 2017, 6(2): 243-249.
LIU Jian. Second use potential of retired EV batteries in power system and associated cost analysis[J]. Energy Storage Science and Technology, 2017, 6(2): 243-249.
- [3] SHARMA N, SHARMA R, JINDAL N. Machine learning and deep learning applications—a vision[J]. Global Transitions Proceedings, 2021, 2(1): 24-28.
- [4] HU D, CHEN L, TIAN J, et al. Research progress of lithium plating on graphite anode in lithium-ion batteries[J]. Chinese Journal of Chemistry, 2021, 39(1): 165-173.
- [5] BUGGA R V, SMART M C. Lithium plating behavior in lithium-ion cells[J]. ECS Transactions, 2010, 25(36): 241.
- [6] QIAN S, CHEN H, ZHENG M, et al. Complementary combination of lithium protection strategies for robust and longevous lithium metal batteries[J]. Energy Storage Materials, 2023, 57: 229-248.
- [7] LIU H, WOLFMAN M, KARKI K, et al. Intergranular cracking as a major cause of long-term capacity fading of layered cathodes[J]. Nano Letters, 2017, 17(6): 3452-3457.
- [8] ZHU X, CHEN Y, CHEN H, et al. The diffusion induced stress and cracking behaviour of primary particle for Li-ion battery electrode[J]. International Journal of Mechanical Sciences, 2020, 178.
- [9] HANF L, DIEHL M, KEMPER L S, et al. Accessing copper oxidation states of dissolved negative electrode current collectors in lithium ion batteries[J]. Electrophoresis, 2020, 41(18-19): 1568-1575.
- [10] MA T, XU G, LI Y, et al. Revisiting the corrosion of the aluminum current collector in lithium-ion batteries[J]. The Journal of Physical Chemistry Letters, 2017, 8(5): 1072-1077.
- [11] GUO L, THORNTON D B, KORONFEL M A, et al. Degradation in lithium ion battery current collectors[J]. Journal of Physics: Energy, 2021, 3(3).
- [12] VERMA P, MAIRE P, NOVÁK P. A review of the features and analyses of the solid electrolyte interphase in Li-ion batteries[J]. Electrochimica Acta, 2010, 55(22): 6332-6341.
- [13] PALACÍN M R, DE GUIBERT A. Why do batteries fail?[J]. Science, 2016, 351.
- [14] HENSCHER J, HORSTHEMKE F, STENZEL Y P, et al. Lithium ion battery electrolyte degradation of field-tested electric vehicle battery cells—a comprehensive analytical

- study[J]. *Journal of Power Sources*, 2020, 447.
- [15] QIAO Y, WANG S, GAO F, et al. Toxicity analysis of second use lithium-ion battery separator and electrolyte[J]. *Polymer Testing*, 2020, 81.
- [16] SIEG J, SCHMID A U, RAU L, et al. Fast-charging capability of lithium-ion cells: influence of electrode aging and electrolyte consumption[J]. *Applied Energy*, 2022, 305.
- [17] KALNAUS S, WANG Y, TURNER J A. Mechanical behavior and failure mechanisms of li-ion battery separators[J]. *Journal of Power Sources*, 2017, 348: 255-263.
- [18] GAO T, BAI J, OUYANG D, et al. Effect of aging temperature on thermal stability of lithium-ion batteries: part A—high-temperature aging[J]. *Renewable Energy*, 2023, 203.
- [19] NORIN L, KOSTECKI R, MCLARNON F. Study of membrane degradation in high-power lithium-ion cells[J]. *Electrochemical and Solid-state Letters*, 2002, 5(4).
- [20] CANNARELLA J, ARNOLD C B. Ion transport restriction in mechanically strained separator membranes[J]. *Journal of Power Sources*, 2013, 226: 149-155.
- [21] HENDRICKS C, WILLIARD N, MATHEW S, et al. A failure modes, mechanisms, and effects analysis (FMMEA) of lithium-ion batteries[J]. *Journal of Power Sources*, 2015, 297: 113-120.
- [22] YUAN C, WANG L, YIN S, et al. Generalized separator failure criteria for internal short circuit of lithium-ion battery[J]. *Journal of Power Sources*, 2020, 467.
- [23] NG K S, MOO C, CHEN Y, et al. Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries[J]. *Applied Energy*, 2009, 86(9): 1506-1511.
- [24] WANG T, ZHU C, PEI L, et al. The state of arts and development trend of SOH estimation for lithium-ion batteries[C] // 2013 IEEE Vehicle Power and Propulsion Conference (VPPC), October 15-18, 2013, Beijing, China: 359-364.
- [25] GALEOTTI M, CINÀ L, GIAMMANCO C, et al. Performance analysis and SOH (state of health) evaluation of lithium polymer batteries through electrochemical impedance spectroscopy[J]. *Energy*, 2015, 89: 678-686.
- [26] ANDRE D, MEILER M, STEINER K, et al. Characterization of high-power lithium-ion batteries by electrochemical impedance spectroscopy II: modelling[J]. *Journal of Power Sources*, 2011, 196(12): 5349-5356.
- [27] YANN LIAW B, NAGASUBRAMANIAN G, JUNGST R G, et al. Modeling of lithium ion cells—a simple equivalent-circuit model approach[J]. *Solid State Ionics*, 2004, 175(1): 835-839.
- [28] CEN Z, KUBIAK P. Lithium-ion battery SOC/SOH adaptive estimation via simplified single particle model[J]. *International Journal of Energy Research*, 2020, 44(15): 12444-12459.
- [29] VENNAM G, SAHOO A, AHMED S. A novel coupled electro-thermal-aging model for simultaneous SOC, SOH, and parameter estimation of lithium-ion batteries[C] // 2022 American Control Conference (ACC), June 8-10, 2022, Atlanta, GA, USA: 5259-5264.
- [30] REN H, ZHAO Y, CHEN S, et al. Design and implementation of a battery management system with active charge balance based on the SOC and SOH online estimation[J]. *Energy*, 2019, 166: 908-917.
- [31] VICHARD L, RAVEY A, VENET P, et al. A method to estimate battery SOH indicators based on vehicle operating data only[J]. *Energy*, 2021, 225.
- [32] MASTALI MAJDABADI M, FARHAD S, FARKHONDEH M, et al. Simplified electrochemical multi-particle model for LiFePO₄ cathodes in lithium-ion batteries[J]. *Journal of Power Sources*, 2015, 275: 633-643.
- [33] GU R, MALYSZ P, YANG H, et al. On the suitability of electrochemical-based modeling for lithium-ion batteries[J]. *IEEE Transactions on Transportation Electrification*, 2016, 2(4): 417-431.
- [34] 黄健, 李建林, 李征. 退役锂离子电池健康状态快速评估方法[J]. *电力系统保护与控制*, 2021, 49(12): 25-32.
- HUANG Jian, LI Jianlin, LI Zheng. A state of health rapid assessment method for decommissioned lithium-ion batteries[J]. *Power System Protection and Control*, 2021, 49(12): 25-32.
- [35] 岳家辉, 夏向阳, 吕崇耿, 等. 计及健康特征信息量的锂离子电池健康状态与剩余寿命预测研究[J]. *电力系统保护与控制*, 2023, 51(22): 74-87.
- YUE Jiahui, XIA Xiangyang, LÜ Chonggeng, et al. Research on the prediction of state of health and remaining useful life of lithium-ion batteries considering the amount of health factors information[J]. *Power System Protection and Control*, 2023, 51(22): 74-87.
- [36] SU X, SUN B, WANG J, et al. Fast capacity estimation for lithium-ion battery based on online identification of low-frequency electrochemical impedance spectroscopy and Gaussian process regression[J]. *Applied Energy*, 2022, 322.
- [37] BO P, LI C, ZUOMIN D. Data-driven degradation modeling and SOH prediction of li-ion batteries[J]. *Energies*, 2022, 15(15).
- [38] JIANPING W, XING C, XIANGHE L, et al. SOH prediction of lithium battery based on IC curve feature and BP neural network[J]. *Energy*, 2022, 261.
- [39] FENG X, WENG C, HE X, et al. Online state-of-health estimation for li-ion battery using partial charging segment based on support vector machine[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(9): 8583-8592.

- [40] RUAN H, WEI Z, SHANG W, et al. Artificial intelligence-based health diagnostic of lithium-ion battery leveraging transient stage of constant current and constant voltage charging[J]. *Applied Energy*, 2023, 336.
- [41] 晋殿卫, 顾则宇, 张志宏. 锂电池健康度和剩余寿命预测算法研究[J]. *电力系统保护与控制*, 2023, 51(1): 122-130.
JIN Dianwei, GU Zeyu, ZHANG Zhihong. Lithium battery health degree and residual life prediction algorithm[J]. *Power System Protection and Control*, 2023, 51(1): 122-130.
- [42] YAO L, XU S, TANG A, et al. A Review of lithium-ion battery state of health estimation and prediction methods[J]. *World Electric Vehicle Journal*, 2021, 12(3): 113.
- [43] CHEN L, XIE S, LOPES A M, et al. A new SOH estimation method for lithium-ion batteries based on model-data-fusion[J]. *Energy*, 2024, 286: 129597.
- [44] LU J, XIONG R, TIAN J, et al. Deep learning to estimate lithium-ion battery state of health without additional degradation experiments[J]. *Nat Commun*, 2023, 14(1): 2760.
- [45] ZHAO X, LIU S, LI E, et al. A transfer learning-based ensemble learning model for electric vehicles lithium-ion battery capacity estimation using electrochemical impedance spectroscopy[J]. *Sustainable Energy Technologies and Assessments*, 2024, 68.
- [46] YANG Y, XU Y, NIE Y, et al. Deep transfer learning enables battery state of charge and state of health estimation[J]. *Energy*, 2024, 294.
- [47] SU X, WANG S, PECHT M, et al. Interacting multiple model particle filter for prognostics of lithium-ion batteries[J]. *Microelectronics Reliability*, 2017, 70: 59-69.
- [48] ZHANG H, MIAO Q, ZHANG X, et al. An improved unscented particle filter approach for lithium-ion battery remaining useful life prediction[J]. *Microelectronics Reliability*, 2018, 81: 288-298.
- [49] 刘博, 尹杰, 李然. 基于改进粒子滤波的锂离子电池剩余寿命预测[J]. *电力系统保护与控制*, 2024, 52(9): 123-131.
LIU Bo, YIN Jie, LI Ran. Improved particle filter algorithm for remaining useful life prediction of lithium-ion batteries[J]. *Power System Protection and Control*, 2024, 52(9): 123-131.
- [50] LIU Q, ZHANG J, LI K, et al. The remaining useful life prediction by using electrochemical model in the particle filter framework for lithium-ion batteries[J]. *IEEE Access*, 2020, 8: 126661-126670.
- [51] KHODADADI SADABADI K, JIN X, et al. Prediction of remaining useful life for a composite electrode lithium ion battery cell using an electrochemical model to estimate the state of health[J]. *Journal of Power Sources*, 2021, 481.
- [52] EL-DALAHMEH M, AL-GREER M, EL-DALAHMEH M, et al. Physics-based model informed smooth particle filter for remaining useful life prediction of lithium-ion battery[J]. *Measurement*, 2023, 214.
- [53] PANG X, LIU X, JIA J, et al. A lithium-ion battery remaining useful life prediction method based on the incremental capacity analysis and Gaussian process regression[J]. *Microelectronics Reliability*, 2021, 127.
- [54] XING J, ZHANG H, ZHANG J. Remaining useful life prediction of lithium batteries based on principal component analysis and improved Gaussian process regression[J]. *International Journal of Electrochemical Science*, 2023, 18(4).
- [55] ZHAI Q, YE Z. RUL prediction of deteriorating products using an adaptive wiener process model[J]. *IEEE Transactions on Industrial Informatics*, 2017, 13(6): 2911-2921.
- [56] ZHANG S, ZHAI Q, LI Y. Degradation modeling and RUL prediction with Wiener process considering measurable and unobservable external impacts[J]. *Reliability Engineering & System Safety*, 2023, 231.
- [57] ZHU Y, LIU S, WEI K, et al. A novel based-performance degradation Wiener process model for real-time reliability evaluation of lithium-ion battery[J]. *Journal of Energy Storage*, 2022, 50.
- [58] CHEN X, LIU Z. A long short-term memory neural network based Wiener process model for remaining useful life prediction[J]. *Reliability Engineering & System Safety*, 2022, 226.
- [59] ZHOU Y, HUANG M. Lithium-ion batteries remaining useful life prediction based on a mixture of empirical mode decomposition and ARIMA model[J]. *Microelectronics Reliability*, 2016, 65: 265-273.
- [60] LIN J, WEI M. Remaining useful life prediction of lithium-ion battery based on auto-regression and particle filter[J]. *International Journal of Intelligent Computing and Cybernetics*, 2021, 14(2): 218-237.
- [61] LU J, XIONG R, TIAN J, et al. Battery degradation prediction against uncertain future conditions with recurrent neural network enabled deep learning[J]. *Energy Storage Materials*, 2022, 50: 139-151.
- [62] PARK K, CHOI Y, CHOI W J, et al. LSTM-based battery remaining useful life prediction with multi-channel charging profiles[J]. *IEEE Access*, 2020, 8: 20786-20798.
- [63] LEE C, KIM B, KWON M, et al. Real-time prediction of capacity fade and remaining useful life of lithium-ion batteries based on charge/discharge characteristics[J]. *Electronics*, 2021, 10(7).
- [64] ZHANG C, WANG S, YU C, et al. Improved particle swarm optimization-extreme learning machine modeling strategies for the accurate lithium-ion battery state of health estimation and high-adaptability remaining useful

- life prediction[J]. Journal of the Electrochemical Society, 2022, 169(8).
- [65] ZHU J, TAN T, WU L, et al. RUL prediction of lithium-ion battery based on improved DGWO-ELM method in a random discharge rates environment[J]. IEEE Access, 2019, 7: 125176-125187.
- [66] PATIL M A, TAGADE P, HARIHARAN K S, et al. A novel multistage support vector machine based approach for li-ion battery remaining useful life estimation[J]. Applied Energy, 2015, 159: 285-297.
- [67] ZHAO Q, QIN X, ZHAO H, et al. A novel prediction method based on the support vector regression for the remaining useful life of lithium-ion batteries[J]. Microelectronics Reliability, 2018, 85: 99-108.
- [68] FAN Y, QIU J, WANG S, et al. Incremental capacity curve health-indicator extraction based on gaussian filter and improved relevance vector machine for lithium-ion battery remaining useful life estimation[J]. Metals, 2022, 12(8).
- [69] TIAN Q, LIU X, DING S, et al. The particle swarm optimization multi-kernel relevance vector machine for remaining useful life prediction of lithium-ion batteries[C]// 2022 IEEE 6th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), October 3-5, 2022, Beijing, China: 938-943.
- [70] 张朝龙, 赵筛筛, 何怡刚. 基于集成经验模态分解与集成机器学习的锂离子电池剩余使用寿命预测方法[J]. 电力系统保护与控制, 2023, 51(13): 177-186.
ZHANG Chaolong, ZHAO Shaishai, HE Yigang. Remaining useful life prediction method for lithium-ion batteries based on ensemble empirical mode decomposition and ensemble machine learning[J]. Power System Protection and Control, 2023, 51(13): 177-186.
- [71] ZHOU W, LU Q, ZHENG Y. Review on the selection of health indicator for lithium ion batteries[J]. Machines, 2022, 10(7).
- [72] LI X, MA Y, ZHU J. An online dual filters RUL prediction method of lithium-ion battery based on unscented particle filter and least squares support vector machine[J]. Measurement, 2021, 184.
- [73] XUE Z, ZHANG Y, CHENG C, et al. Remaining useful life prediction of lithium-ion batteries with adaptive unscented Kalman filter and optimized support vector regression[J]. Neurocomputing, 2020, 376: 95-102.
- [74] 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.
- [75] MA G, ZHANG Y, CHENG C, et al. Remaining useful life prediction of lithium-ion batteries based on false nearest neighbors and a hybrid neural network[J]. Applied Energy, 2019, 253.
- [76] YAO F, HE W, WU Y, et al. Remaining useful life prediction of lithium-ion batteries using a hybrid model[J]. Energy, 2022, 248.
- [77] QU J, WANG Y, ZHENG R, et al. A novel sequential estimation framework for battery state of health and remaining useful life based on sparse and limited data[J]. Journal of Energy Storage, 2024, 99.
- [78] COUTURE J, LIN X. Image- and health indicator-based transfer learning hybridization for battery RUL prediction[J]. Engineering Applications of Artificial Intelligence, 2022, 114.
- [79] CHOU J, WANG F, LO S. Predicting future capacity of lithium-ion batteries using transfer learning method[J]. Journal of Energy Storage, 2023, 71.
- [80] WANG Y, ZHAO S, WANG S, et al. Enhanced vision-transformer integrating with semi-supervised transfer learning for state of health and remaining useful life estimation of lithium-ion batteries[J]. Energy and AI, 2024: 100405.
- [81] LI W, SENGUPTA N, DECHENT P, et al. One-shot battery degradation trajectory prediction with deep learning[J]. Journal of Power Sources, 2021, 506.
- [82] ATTIA P M, GROVER A, JIN N, et al. Closed-loop optimization of fast-charging protocols for batteries with machine learning[J]. Nature, 2020, 578(7795): 397-402.
- [83] SOHN S, BYUN H, LEE J H. Two-stage deep learning for online prediction of knee-point in li-ion battery capacity degradation[J]. Applied Energy, 2022, 328.
- [84] WANG T, ZHU Y, ZHAO W, et al. Capacity degradation analysis and knee point prediction for lithium-ion batteries[J]. Green Energy and Intelligent Transportation, 2024.

收稿日期: 2024-06-10; 修回日期: 2024-10-09

作者简介:

陈宏宇(1999—), 男, 硕士研究生, 研究方向为锂离子电池健康状态快速检测及剩余使用寿命预测; E-mail: hychen_1999@163.com

袁斌(1977—), 男, 通信作者, 博士, 教授, 研究方向为锂离子电池材料及绿色回收、金属功能材料、电催化材料、材料计算。E-mail: apsheng@scut.edu.cn

(编辑 周金梅)