

基于恒流充电数据的锂电池容量估计方法

程伟达, 孙 硕, 尹 航, 王宗亮, 蔡 巍, 宋佳锴

(海军潜艇学院, 青岛 266199)

摘 要: 针对锂电池使用过程中容量无法直接测量的难题, 提出一种基于恒流充电数据的锂电池容量估计方法。首先, 从恒流充电阶段提取两种老化特征序列: 一是恒流充电阶段提取的充电容量特征序列, 二是等充电电压上升的时间间隔特征序列。其次, 为尽可能充分利用所测得的充电信息, 提取老化特征中关键的容量衰减因素, 构建一种新的一维卷积神经网络容量估计模型。最后, 在马里兰锂电池数据集上验证所提模型的性能。实验结果表明, 所提方法可实现电池容量准确且稳健的估计。此外, 所提模型经过少量数据迁移学习后, 可准确估计其他放电倍率下的电池放电容量, 经过前50个循环周期的迁移学习, 模型在0.5C放电倍率下的均方根误差仅为0.58%。

关键词: 锂电池; 卷积神经网络; 迁移学习; 容量估计; 恒流充电; 深度学习

中图分类号: TM911

文献标志码: A

0 引 言

锂离子电池具有能量密度高、循环寿命长、自放电率低、工作温度宽等优点, 广泛应用于清洁能源储能、新能源汽车、便携式电子设备领域^[1-3]。在锂电池的使用过程中, 由于各类副反应和机械应力的存在, 锂电池的容量会呈现非线性衰减^[4-6]。锂电池容量的衰减不仅影响用电设备的实际性能, 甚至会危及使用安全^[7]。因此, 探究如何实现锂电池容量的精准估计对锂电池安全可靠地运行具有重大的现实意义。

目前, 锂电池容量估计方法可分为直接测量法、基于模型的方法和基于数据驱动的方法3大类^[8-9]。直接测量法通过对锂电池放电电流的积分得到锂电池的容量, 该方法不仅需对锂电池进行满充满放, 还需高精度的电流传感器, 使用条件较为苛刻^[10-11], 因此常用于实验室环境下锂电池容量的精确测量, 实际场合中并不适用。一方面用电设备的电流传感器精度达不到实验室的测量精度, 另一方面在实际使用过程中锂电池的满充满放工况并不常见。同时得益于较高的测量精度, 直接测量法还可用于验证其他容量测量方法的准确性。基于模型的方法首先需要搭建化学模型^[12]、等效电路模型^[13]来反映锂电池内部发生的化学物理变化, 并通过各类自适应滤波算法估计模型参数以获得电池容量, 尽管该方法对于电池容量的估计具有较高精度, 但容量估计精度依赖于模型的精确程度, 且易受外界环境扰动, 鲁棒性较差, 这都限制了其在实际场景中的应用^[14-15]。基于数据驱动的方法无需了解电池内部复杂的电化学反应机理和构建复杂的模型^[16]。通过直接将老化测试数据或者测试数据经过简单转化后作为输入, 利用其强大的非线性拟合能力即可实现对电池容量

的估计。目前, 诸如卷积神经网络^[17-18]、高斯过程回归^[19-20]、支持向量机^[21-22]、极限学习机^[23-24]等, 已成为电池性能评估的主流方法。

由于数据驱动的方法依靠数据集来训练模型, 因此输入特征的选择影响模型的估计性能^[25]。苟斌等^[26]利用皮尔逊相关分析从充电时间中提取4个关键的健康因子作为输入, 提出一种极限学习方法和集成学习方法相结合的电池容量估计方法, 并在不同负载和温度下验证了所提方法的正确性。李晓宇等^[27]从经过高斯滤波的容量增量曲线中提取11个健康因子作为输入, 使用高斯过程回归模型不仅实现了电池容量的估计, 还给出了模型估计的不确定性。林名强等^[28]从电池数据的电压、温度、容量中提取7个健康因子作为输入, 并采用高斯过程回归、线性回归和支持向量机回归3个模型融合的方式实现了电池容量的精准估计, 均方根误差和平均绝对误差均小于1%。熊瑞等^[29]从全电压范围和部分电压范围内提取568个健康因子, 并通过皮尔逊相关系数等5种算法对健康因子进行筛选, 实验结果证明使用筛选得到的健康因子作为输入可大幅提升容量估计精度。

通过特征点作为输入可实现锂电池容量估计, 但特征点的构造是一项复杂且充满不确定性的任务。它不仅需要依据个人经验进行精心设计, 还需借助特征筛选方法筛选特征。然而, 当前并无统一的标准来确定何种特征筛选方法更为有效, 这无疑增加了特征点构造的难度。此外, 锂电池的老化是一个全局过程, 其特征并非局限于某些特定的电压点, 而是贯穿于整个充电电压区间, 只是在不同区间内表现强弱存在区别。因此, 传统的特征点方法可能无法全面捕捉电池的老化特征。为此, 本文提出使用特征序列估计容量的

方法,该方法仅需充电容量序列和等电压上升时间间隔序列两个特征序列。这两个序列能全面捕捉电池在恒流充电过程中的老化特征,原因是它们涵盖了整个恒流充电过程的信息,而不仅是某些特定的电压点。为验证所提方法的有效性,本文在马里兰大学电池老化数据集上,不仅探究其在完整恒流充电曲线上的估计效果,还进一步探讨当只有部分恒流充电数据可用时该方法对电池容量估计的能力。此外,考虑到实际应用中可能遇到的不同放电倍率情况,本文还对利用迁移模型实现对其他放电倍率下电池放电容量估计的可行性进行探究,并与现有方法进行对比实验。

1 电池数据获取

本文所使用的数据来源于马里兰大学先进生命周期工程中心公开的锂离子电池老化数据集^[30],该电池数据集使用的CS型锂离子电池额定容量为1.1 Ah,正极材料为含有少量Mn元素的LiCoO₂,负极材料为石墨。锂电池循环寿命测试实验主要分为恒流恒压充电和恒流放电两个阶段。恒流恒压充电阶段首先以0.5C的恒定电流对锂电池充电,当充电电压达到4.2 V后,以4.2 V的恒定电压对锂电池继续充电,直到充电电流降至0.05 A以下;恒流放电阶段以恒定的放电倍率对锂电池进行放电,直至锂电池放电电压达到2.7 V。其中CS2-35、CS2-36、CS2-37和CS2-38电池的放电倍率为1C,CS2-33电池的放电倍率为0.5C。

与实际应用中锂电池放电曲线的随机性相比,锂电池充电曲线一般固定不变,因此可从锂电池充电时测量的电压、电流、充电时间等信息中提取老化特征,然后利用一维卷积神经网络模型对锂电池容量进行估计。下面以CS2-35电池为例详细介绍相应的特征值及提取过程。值得注意的是,电池成组后,由于电池性能的不一致性,在恒流充电过程中可能有部分电池的电压无法到达截止电压,为保证所有电池恒流充电曲线的一致性,本文中完整恒流充电区间的上界电压设置为4.15 V;同时随着电池的老化,电池内阻逐渐增大,从而导致恒流充电起始电压逐渐增大,为保证所有电池恒流充电曲线的一致性,通过对所有充电曲线的分析,最终将完整恒流充电区间的下界电压设置为3.75 V。因此,本文中完整恒流充电区间设置为[3.75 V, 4.15 V]。

1.1 恒流充电容量

恒流充电过程中电池容量的变化通过安时积分法计算,因此某一恒流充电片段上电池的充电容量 Q 可看成是关于时间的函数,且可转化为关于电压的函数,即:

$$Q(V_i) = \int_{V_0}^{V_i} I(t) dt \quad (1)$$

式中: V_0 ——恒流充电片段开始时刻的电压,V; $I(t)$ —— t 时刻充电电流,A。

不同健康状态下锂电池充电容量变化曲线如图1所示,其中健康状态(H)表示电池的实际容量与其额定容量的比

值,计算公式如式(2)所示,用于描述锂电池的容量衰退程度^[31]。从图1可看出,在相同电压区间内,随着锂电池的不断老化,充电容量的变化逐渐减小。随着电压区间的增大,老化引起的充电容量的差距逐渐增大,表明充电容量的变化代表一段电压区间的老化特征。在整个充电片段中,当电压在[3.85 V, 3.95 V]区间内时,充电容量变化更为剧烈,且 H 越大充电容量的变化越剧烈,因此某一充电片段上的 Q 可作为模型的输入。

$$H = \frac{C_{\text{now}}}{C_{\text{rated}}} \times 100\% \quad (2)$$

式中: C_{now} ——电池当前容量,Ah; C_{rated} ——电池额定容量,Ah。




图1 不同健康状态下电池充电容量变化曲线

Fig. 1 Charging capacity curves of lithium battery under different aging conditions

1.2 等充电电压上升的时间间隔

等充电电压上升的时间间隔同样能反映锂电池的老化状态,其计算式为:

$$T(V_i) = t(V_i) - t(V_i - \Delta V) \quad (3)$$

图2展示了不同健康状态下锂电池电压每增加0.01 V所需的充电时间。与恒流充电过程中电池容量的变化代表的区间老化特征不同,电池电压变化所需充电时间代表某一电压点上的老化特征。从图2可看出,充电时间随电压的增




图2 不同健康状态下充电电压发生0.01 V变化所需充电时间变化曲线

Fig. 2 Variation curves of charging time required for every 0.01 V increase of charging voltage under different aging conditions

大呈现“M”型变化,两个峰值分别处于[3.75 V, 3.85 V]和[3.85 V, 3.95 V]电压区间内。随着电池的老化,两个峰值的大小逐渐减小,当 $H < 1.0$ 时,两个峰值均向右下角平移,当电压大于 3.95 V 时,充电时间未随电池的老化产生明显变化。

2 方 法

2.1 一维卷积神经网络

一维卷积神经网络是卷积神经网络的一种特殊结构,主要用于一维序列数据的处理。一维卷积神经网络通常由输入层、卷积层、池化层、全连接层和输出层构成,如图 3a 所示。在卷积层中,卷积核通过与感受野的卷积作用从中提取各类特征,并通过在序列数据上的滑动实现对整个序列的特征提取,卷积核生成特征图的过程如图 3b 所示,其中卷积层输出 $R = [r_1, r_2, r_3, \dots, r_q]$ 与输入矩阵 $X = [x_1, x_2, x_3, \dots, x_l]$ 的关系如式(4)、式(5)所示。由于卷积核的权值共享能力,减少了深度卷积神经网络的参数数量,从而可减少模型的计算量。在池化层中,其内核通过与前一子区域采用局部连接的方式,能在保留关键特征信息的同时有效减少序列长度和网格参数数量,并在一定程度上防止过拟合,池化层提取特征的过程如图 3c 所示,其中池化层输出 $C = [c_1, c_2, c_3, \dots, c^q]$ 与卷积层输出 $R = [r_1, r_2, r_3, \dots, r^q]$ 的关系如式(6)、式(7)所示。卷积层和池化层提取到的特征最终通过全连接层映射到输出层。




图3 一维卷积神经网络

Fig. 3 One-dimensional convolutional neural network

$$r_i^p = f_c \left(\sum_{j=i}^{j=i+h-1} w_p \cdot x_j + b_p \right), p \in [1, q] \quad (4)$$

$$r^p = [r_1^p, r_2^p, r_3^p, \dots, r_l^p] \quad (5)$$

$$c_i^p = \max(r_i^p, r_{i+1}^p, \dots, r_{i+u-1}^p) \quad (6)$$

$$c^p = [c_1^p, c_{1+u}^p, c_{1+2u}^p, \dots, c_{l/2}^p] \quad (7)$$

式中: f_c ——激活函数; h ——卷积核的长度; w_p ——第 p 个卷积核矩阵, $w_p \in R^{h \times k}$; $x_j \in R^{1 \times k}$; b_p ——第 p 个卷积核的偏置, $b_p \in R$; q ——卷积层的卷积核数量; u ——池化层核的长度; v ——池化层核的步长。

2.2 网络结构

本文使用的一维卷积神经网络结构和参数如表 1 所示。从表 1 可看出,输入层的输入序列为电压、容量和固定电压区间所需充电时间所组成的序列,数据结构为 $l \times 3$,其中 l 为电压序列长度。第 2 层为卷积层,由 16 个卷积核构成,其中卷积核的长度为 3,步长为 1,填充方式为“same”,并采用 ReLU 激活函数输出该层结果。第 3 层仍为卷积层,结构与第 2 层相同,第 4 层为池化层,池化层大小为 2,步长为 2。第 5~13 层与第 2~4 层类似。第 14 层为展平层,将第 13 层输出的多维数据转换为一维数据结构,在卷积层和全连接层之间起过渡作用。第 15 层和第 16 层为全连接层,包含隐藏节点分别为 128 和 64 个,均采用 ReLU 激活函数输出结果。第 17 层是输出层,为包含 1 个隐层节点的全连接层,输出结果为锂电池容量。

训练模型以对称平均绝对百分比误差(E_{SMAPE})为目标函数,如式(8)所示,并采用 Adam 作为最小化目标函数的优化器,初始学习率设置为 0.001,通过回调函数 ReduceLROnPlateau 调整学习率,当 10 次迭代后模型性能不再提升时,学习率衰减 0.8。此外,实验迭代次数设置为 2000。

$$E_{\text{SMAPE}} = \frac{1}{N} \sum_{i=1}^N \frac{|Y_i - Y_i^*|}{(Y_i + Y_i^*)/2} \quad (8)$$

式中: N ——总的循环次数; Y_i ——锂电池容量的真实值, Ah; Y_i^* ——锂电池容量的估计值, Ah。

2.3 锂电池容量估计流程及相关评价标准

锂电池容量的估计流程如图 4 所示,具体步骤为:

1) 根据锂电池恒流充放电过程中测得的电压、电流和时间,计算出恒流充电容量 Q 、等充电电压上升时间间隔 T 和电池容量。本文中,使用从 4.2 V 电压放电到放电截止电压的电池的放电容量来代替电池容量。然后,构造由 V 、 Q 、 T 组成的输入序列和由电池容量组成的输出序列。

2) 构建的数据序列根据电池数量分为训练集和测试集,基于 CPU(AMD 锐龙 7 4800H 2.90 GHz)、RAM 内存(32 GB)、Windows 操作系统和 Keras 环境构建如表 1 所示的 1D CNN 模型。

3) 用训练集训练 1D CNN 模型,并用测试集评估训练好的模型。为定量描述锂电池容量估计模型的性能,选取均方根误差(E_{RMSE})、平均绝对误差(E_{MAE})和最大绝对值误差(E_{MAX})作为评价指标。

表1 用于估算电池容量的一维卷积神经网络结构

Table 1 1D CNN structure for estimating battery capacity

层级	描述
第1层(输入层)	恒流充电过程中的电压、容量、固定电压区间所需充电时间 $[V_1, Q_1, T_1; V_2, Q_2, T_2; \dots; V_l, Q_l, T_l]$
第2~4层	Conv1D-16-3-1& Conv1D-16-3-1&Maxpooling1D-2-2
第5~7层	Conv1D-32-3-1& Conv1D-32-3-1&Maxpooling1D-2-2
第8~10层	Conv1D-64-3-1& Conv1D-64-3-1&Maxpooling1D-2-2
第11~13层	Conv1D-128-3-1& Conv1D-128-3-1&Maxpooling1D-2-2
第14层	Flatten
第15层	FC-128
第16层	FC-64
第17层(输出层)	FC-1




图4 锂电池容量的估计流程

Fig. 4 Flowchart of predicting lithium battery capacity

3 结果与讨论

3.1 输入特征对容量估计结果的影响

为探究不同输入特征对锂电池容量估计性能的影响,本文设计如下3种方案:

方案1:仅采用恒流充电容量作为输入特征;

方案2:仅采用等充电电压上升时间间隔作为输入特征;

方案3:将恒流充电容量和等充电电压上升时间间隔组合作为输入特征。

从图5可看出,3种方案的估计结果均能很好地接近真实值,除了在图5c中当循环寿命在50~150之间时,所有方

案均出现明显误差,其中以方案2的估计结果偏离真实值最大,方案1次之,方案3最小,这一点在图6c中更为清晰。说明在训练集数据量较小时,组合特征作为输入训练得到的模型具有更强的鲁棒性。图6中估计误差变化表明,即使在相同的实验工况下,同一模型对同种类型锂电池的容量估计误差也会表现出明显差异。3块锂电池相比,3种方案对于锂电池CS2-37的估计结果均最好,估计最大误差控制在2.01%以内,锂电池CS2-38的估计结果最差,估计最大误差控制在4.55%以内,其中组合特征能将误差控制在2.89%以内。为更加清晰地对比3种方案整体估计精度,表2给出了3种输入特征的均方根误差、平均绝对误差和最大绝对值误差。




图5 不同特征估计结果对比

Fig. 5 Comparison of estimation results of different features




图6 不同特征估计误差对比

Fig. 6 Comparison of estimation errors of different features

表2 不同输入特征估计误差统计结果

Table 2 Statistical results of estimation errors of different input features

电池		CS2-36	CS2-37	CS2-38
方案 1	$E_{\text{RMSE}}/\%$	0.85	0.54	0.87
	$E_{\text{MAE}}/\%$	0.73	0.44	0.69
	$E_{\text{MAX}}/\%$	2.92	1.76	3.25
方案 2	$E_{\text{RMSE}}/\%$	0.64	0.59	1.10
	$E_{\text{MAE}}/\%$	0.48	0.48	0.72
	$E_{\text{MAX}}/\%$	2.72	1.94	4.55
方案 3	$E_{\text{RMSE}}/\%$	0.66	0.54	0.63
	$E_{\text{MAE}}/\%$	0.49	0.41	0.48
	$E_{\text{MAX}}/\%$	2.89	2.01	2.89

方案 3 除在 CS2-37 上均方根误差与方案 1 持平,在 CS2-36 和 CS2-38 上均方根误差和平均绝对误差均优于方案 1,均方根误差分别为 0.66% 和 0.63%;与方案 1 相比,均方根误差分别降低 22.35% 和 27.59%。方案 3 作为输入在 CS2-36 上均方根误差与方案 2 电压上升的时间间隔特征作为输入相近,在 CS2-37 和 CS2-38 上均方根误差和平均绝对误差均

优于方案 2 作为输入,均方根误差分别降低 8.47% 和 42.72%。综合来看,方案 3 即组合特征作为输入优于单一特征作为输入,组合特征作为输入能有效提升估计模型的鲁棒性和估计精度。

3.2 部分恒流充电曲线的电池容量估计结果

在锂电池的实际使用过程中,由于放电深度的随机性以及固定充电装置的限制,不可能每次都能获取到完整的充电曲线。因此,验证本文所提出的电池容量估计方法在部分恒流充电曲线上的适用性十分必要。选用电压区间[3.75 V, 3.95 V]、[3.85 V, 4.05 V]、[3.95 V, 4.15 V]、[3.75 V, 4.05 V]、[3.85 V, 4.15 V]和[3.75 V, 4.15 V]作为研究对象,分别对应于测试条件案例 1~6。值得注意的是,[3.75 V, 4.15 V]可认为是完整的恒流充电电压区间,案例 6 可作为对照组使用。在电池的选择方面,将 CS2-35 和 CS2-36 电池划分为训练集,CS2-37 和 CS2-38 电池为测试集,验证本文提出的方法在部分充电片段上的可行性。图 7 为电池 CS2-37 和 CS2-38 基于不同充电区间得到的电池容量估计结果,图 8 为电池 CS2-37 和 CS2-38 基于不同充电区间得到的电池容量估计误差,其中不同充电片段对应的误差统计结果如表 3 所示。

除案例 3 的估计误差较大外,其他方案对电池容量的估计值均能很好地跟踪电池的实际容量。电池 CS2-37 和 CS2-38 的均方根误差可控制在 1.09% 以内,平均绝对误差可控制

在 0.94% 以内,最大绝对值误差控制在 6.52% 以内。其中电池 CS2-37 的估计误差更小,均方根误差和平均绝对误差可分别控制在 0.79% 和 0.63% 以内,最大绝对值误差控制在 3.06% 以内。这表明本文提出的方法在部分充电片段上仍能有效提取锂电池的老化特征,从而得到较高的模型估计精度。与完整充电曲线相比,当利用部分充电曲线估计电池容量时,估计精度均有所下降。这是因为在锂电池的充电过程中,其充电曲线上的多个区域均展现出与电池容量衰减相关的特征(如图 2 所示),只是不同区域在估计电池容量时的作






图 7 不同充电区间估计结果对比

Fig. 7 Comparison of estimation results of different charging segments



a. CS2-37



b. CS2-38

图 8 不同充电区间估计误差对比

Fig. 8 Comparison of estimation errors of different charging segments

表 3 电池容量估计误差统计结果

Table 3 Statistical results of battery capacity estimation error


案例	参数	CS2-37	CS2-38
1	$E_{RMSE}/\%$	0.58	0.81
	$E_{MAE}/\%$	0.44	0.55
	$E_{MAX}/\%$	2.78	6.52
2	$E_{RMSE}/\%$	0.79	1.09
	$E_{MAE}/\%$	0.63	0.94
	$E_{MAX}/\%$	2.45	2.75
3	$E_{RMSE}/\%$	3.89	3.16
	$E_{MAE}/\%$	2.19	2.20
	$E_{MAX}/\%$	24.14	23.96
4	$E_{RMSE}/\%$	0.55	0.80
	$E_{MAE}/\%$	0.42	0.60
	$E_{MAX}/\%$	2.19	3.70
5	$E_{RMSE}/\%$	0.77	1.01
	$E_{MAE}/\%$	0.60	0.86
	$E_{MAX}/\%$	3.06	3.24
6	$E_{RMSE}/\%$	0.43	0.68
	$E_{MAE}/\%$	0.33	0.50
	$E_{MAX}/\%$	1.61	2.49

用强度存在差异。充电片段作为完整充电曲线的一部分,提取的容量衰减特征数据减小,从而降低了模型的估计精度。从充电区间的不同长度和范围可看出,随着充电起始电压的减小,充电片段增长,模型的估计精度逐渐提高。以电池


CS2-37 为例,当电压范围在 $[3.95 \text{ V}, 4.15 \text{ V}]$ 时,电池容量估计精度最差,均方根误差为 3.89%,最大绝对值误差为 24.14%。当电压范围在 $[3.75 \text{ V}, 4.05 \text{ V}]$ 时,电池容量估计精度较高,均方根误差和平均绝对误差分别为 0.55% 和 0.42%,最大绝对值误差在 2.19% 内。这是因为与充电曲线的高电压区间相比,低电压区间的容量衰减特征变化更为明显,这一点从图 1 和图 2 中也可看出。

3.3 基于微调方法的锂电池放电容量估计结果

不同放电倍率下锂电池的放电容量有所差异^[32-33]。因此,若直接使用 3.2 节得到的电池容量估计模型来估计其他放电倍率下的锂电池放电容量,其估计精度难免会受到影响(如图 9a 中模型 1 估计结果所示),这主要是因为本文中采用 1C 放电倍率下放出的容量作为电池容量,并采用 1C 放电倍率下放出的容量训练模型,因此当容量估计模型用于其他放电倍率下放电容量估计时,由于缺乏相应数据集的训练,无法实现精准的估计。由数据驱动的原理可知,要实现不同放电倍率下电池放电容量的估计,需要添加相应放电倍率下的数据进行训练^[17]。若重新训练模型,由于放电曲线的随机性,不仅需提供不同放电倍率电池数据集,同时还需进行重复性实验,避免实验的偶然性。这不仅需要大量资金,而且需长达数年的实验周期。为此,本文提出利用迁移学习的微调方法快速实现不同放电倍率下锂电池放电容量的精准估计。首先使用电池 CS2-35、CS2-36、CS2-37 和 CS2-38 的数据集训练模型,训练得到的模型命名为模型 1,再分别使用电池 CS2-33 的前 50 和 100 个充放电周期训练迁移模型,得到的模型分别命名为模型 2 和模型 3,由于训练数据集较小,除了输出层之外的所有层都被冻结,只微调输出层的参数。同时,为比较迁移学习的效果,本文还直接使用 CS2-33 的前 100 个充放电周期训练模型,命名为模型 4。使用电池 CS2-33 剩余充放电周期验证得到的训练模型,具体结果如图 9 所示。由于模型 4 随充放电周期的增加估计误差逐渐增大,为了清晰观察模型估计误差的变化,在图 9b 中仅展示了模型 4 前 200 个充放电周期的估计误差结果。



a. 容量估计结果



b. 容量估计误差

图9 CS2-33 电池容量估计结果及误差

Fig. 9 CS2-33 battery capacity estimation results and error

从图 9 可看出,模型 1~3 的估计结果可以很好地跟随锂电池实际容量的变化趋势,除个别误差较大外,估计误差范围可控制在 2% 以内,其中模型 2 和模型 3 的跟随效果更好,估计误差范围可控制在 1% 以内,模型 4 在短期内也具有较好的估计精度,在前 200 个估计周期内误差可控制在 2% 以内,但随着充放电周期的增加,估计结果逐渐远离真实值。

从表 4 可看出,模型 3 的整体估计效果最好,均方根误差、平均绝对误差、最大绝对值误差分别为 0.49%、0.40% 和 2.11%。与模型 1 相比,模型 3 的均方根误差、平均绝对误差分别下降 64.49%、68.75%,最大绝对值误差下降 39.54%。说明在 0.5C 放电倍率下,经过对电池初期放电容量退化规律的学习,迁移模型即可获得对电池整个寿命周期内放电容量的估计,且与原模型相比,可大幅提升估计精度。从模型 4 前 100 周期和前 200 周期估计结果来看,模型 4 在前 100 周期内估计精度优于模型 1,估计精度低于模型 2 和模型 3,然而随着充放电周期的增加,模型 4 的估计精度急剧下降,这主要由于训练的数据主要反映电池初期的衰减特征,因此训练得到的模型仅能实现电池初期放电容量的估计,无法实现对电池中后期放电容量的估计,所以模型 4 仅适合于电池初期放电容量的估计。从模型 2 与模型 3 估计结果可看出,当迁

表4 不同模型估计精度对比

Table 4 Comparison of estimation accuracy of different models

模型	CS2-33		
	$E_{RMSE}/\%$	$E_{MAE}/\%$	$E_{MAX}/\%$
模型 1(1~577)	1.38	1.28	3.49
模型 2(51~577)	0.58	0.45	2.83
模型 3(101~577)	0.49	0.40	2.11
模型 4(101~200)	0.72	0.66	1.09
模型 4(101~300)	1.09	0.97	2.38

移学习的数据量由整个寿命周期的 8.66% 增加到 17.33% 时,可提高模型估计精度,但提升效果并不明显。说明在训练数据较少的情况下,迁移模型也可获得较为理想的估计结果。从对比结果看,在模型 1 基础上,本文提出的迁移学习方法,通过对 0.5C 放电倍率下初期放电容量衰减数据的学习,既可获得电池在 0.5C 放电倍率下放电容量的估计能力,而且具有较高的估计精度。

3.4 与现有电池容量估计算法对比

为了说明本文所提方法在电池容量估计方面的优越性,分别与基于向量机回归(support vector regression, SVR)^[26]、基于集成学习的极限学习机(extreme learning machines, ELMs)^[26]、动态自适应布谷鸟搜索长短期记忆神经网络(dynamic adaptive cuckoo search long short term memory, DACS-LSTM)算法^[34]进行对比。为了模型和参数的合理性,本文选取采用相同数据集的文献,直接引用对应文献的相关指标数据进行比较。由于上述文献在评价指标计算上使用健康状态计算,而不是电池容量。为了对比的科学性,对所提方法得到的评价指标进行换算。各种算法的估计精度对比如表 5 所示。从表 5 可看出,所提出的算法在所有评价指标上均处于最优。以电池 CS2-37 为例,与基于向量机回归、基于集成学习的极限学习机相比,所提方法的均方根误差分别降低 48.68% 和 43.48%,最大误差分别降低 73.36% 和 59.21%。与动态自适应布谷鸟搜索长短期记忆神经网络算法相比,所提方法的平均绝对误差降低 55.22%。从对比结果看,所提方法在电池容量估计方面具有更高的估计精度。

表 5 不同算法估计锂电池容量估计精度对比

Table 5 Comparison of estimation accuracy of lithium battery capacity

电池	方法	$E_{RMSE}/\%$	$E_{MAE}/\%$	$E_{MAX}/\%$
CS2-37	本文方法	0.39	0.30	1.46
	SVR	0.76		5.48
	ELMs	0.69		3.58
	DACS-LSTM	0.88	0.67	
CS2-38	本文方法	0.62	0.45	2.26
	SVR	0.88		3.29
	ELMs	0.86		4.00
	DACS-LSTM	1.00	0.63	

3.5 在其他公开数据集上容量估计结果

为验证所提方法在锂电池容量估计方面的适用性,在牛津大学锂电池老化数据集^[35]上进行进一步实验验证。该电池数据集包含 8 个 750 mAh 的锂电池,在 40 °C 环境中采用 Urban Artemis 驾驶模式对锂电池进行充放电循环实验。每

循环 100 次进行一次容量标定测试,使用 1C 的恒定电流对锂电池进行放电,直至锂电池电压达到 2.7 V 停止放电。本文选取编号为 Cell1~Cell6 的电池充放电数据作为训练集,编号为 Cell7 和 Cell8 的电池充放电数据作为测试集,测试结果如表 6 所示。从表 6 可看出,本文所提方法在 Cell7 和 Cell8 的锂电池上仍具有较高的容量估计精度,均方根误差、平均绝对误差、最大绝对值误差分别控制在 0.47%、0.33% 和 1.04% 以内,该结果与所提方法在马里兰大学锂电池数据集上的结果相似,说明本文所选择的输入变量与锂电池容量具有较强的相关性,构建的锂电池容量估计模型具有较强的泛化性能,即便是在牛津大学这一全新的数据集上,该方法同样能够精准地估计出锂电池的容量,充分展示了其广泛的适用性和实用性。

表 6 牛津大学锂电池容量估计误差统计结果

Table 6 Statistical results of estimation error of lithium battery capacity in Oxford University

电池	$E_{RMSE}/\%$	$E_{MAE}/\%$	$E_{MAX}/\%$
Cell7	0.47	0.33	1.04
Cell8	0.31	0.29	0.58

4 结 论

本文提出一种基于恒流充电数据的锂电池容量估计方法。通过对恒流充电阶段充电电压、电流和时间信息进行简单转化,得到与电池老化具有强相关的恒流充电容量序列和等充电电压上升的时间间隔序列,利用一维卷积神经网络序列输入优势和强大的数据拟合能力,构建了锂离子电池容量估计模型,并利用马里兰锂电池老化数据集对模型进行了验证和性能分析。实验结果表明,与单特征序列输入相比,本文所提方法选取两个特征序列作为输入,在不降低估计精度的前提下,能有效提升估计模型的鲁棒性。当利用部分恒流充电曲线获得的特征序列进行估计时,电池容量估计误差均有不同程度的增加,并且随充电起始电压的减小充电片段增长,模型的估计精度逐渐提高。在马里兰锂电池老化数据集上,还与现有容量估计方法进行了比较,该方法能有效降低电池容量估计误差,在 CS-37 电池上容量估计误差 E_{RMSE} 和 E_{MAE} 分别仅为 0.43% 和 0.33%。此外,得益于迁移学习方法,该方法得到的估计模型,仅使用 0.5C 放电倍率下前 50 个循环周期进行迁移学习,即可实现对 0.5C 放电倍率下电池放电容量的准确估计。

[参考文献]

- [1] RAHN C D, WANG C Y. Battery systems engineering [M]. Hoboken: Wiley, 2013.
- [2] REDDY T B, LINDEN D. Linden's handbook of batteries [M]. 4th ed. New York: McGraw-Hill, 2011.
- [3] 王博, 胡兵, 王小娟. 动力电池支撑架结构设计及散热

- 性能分析[J]. 太阳能学报, 2022, 43(5): 454-460.
- WANG B, HU B, WANG X J. Power battery support frame structure design and analysis of heat dissipation performance [J]. *Acta energiae solaris sinica*, 2022, 43(5): 454-460.
- [4] 陈媛, 段文献, 何怡刚, 等. 带降噪自编码器的锂离子电池健康状态估计算法[J/OL]. 电工技术学报, 1-17 [2025-01-13]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.231644>.
- CHEN Y, DUAN W X, HE Y G, et al. State of health estimation algorithm of lithium ion battery with denoising autoencoder[J/OL]. *Transactions of China Electrotechnical Society*. 1-17 [2025-01-13]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.231644>.
- [5] CAI L, MENG J H, STROE D I, et al. Multiobjective optimization of data-driven model for lithium-ion battery SOH estimation with short-term feature [J]. *IEEE transactions on power electronics*, 2020, 35(11): 11855-11864.
- [6] 吴伟丽, 卢双双, 李磊. 基于 Holt-Winters 的锂离子电池容量衰退预测[J]. 太阳能学报, 2025, 46(1): 309-318.
- WU W L, LU S S, LI L. Holt-Winters based prediction of lithium-ion battery capacity fading [J]. *Acta energiae solaris sinica*, 2025, 46(1): 309-318.
- [7] QIN H C, FAN X X, FAN Y X, et al. A computationally efficient approach for the state-of-health estimation of lithium-ion batteries[J]. *Energies*, 2023, 16(14): 5414.
- [8] YUAN J, QIN Z L, HUANG H K, et al. Progress in the prognosis of battery degradation and estimation of battery states[J]. *Science China materials*, 2024, 67(4): 1014-1041.
- [9] 杜燕, 陶晓, 苏建徽, 等. 考虑实际退役电池常用 SOC 范围的 SOH 预测[J]. 太阳能学报, 2025, 46(2): 99-105.
- DU Y, TAO X, SU J H, et al. SOH prediction considering range of SOC commonly used in actual decommissioned batteries[J]. *Acta energiae solaris sinica*, 2025, 46(2): 99-105.
- [10] 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.
- [11] NG K S, MOO C S, CHEN Y P, 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.
- [12] ALLAM A, ONORI S. Online capacity estimation for lithium-ion battery cells via an electrochemical model-based adaptive interconnected observer[J]. *IEEE transactions on control systems technology*, 2021, 29(4): 1636-1651.
- [13] LING L Y, WEI Y. State-of-charge and state-of-health estimation for lithium-ion batteries based on dual fractional-order extended Kalman filter and online parameter identification [J]. *IEEE access*, 2021, 9: 47588-47602.
- [14] LI H, FU L J, ZHANG Y. A novel hybrid data-driven method based on uncertainty quantification to predict the remaining useful life of lithium battery [J]. *Journal of energy storage*, 2022, 52: 104984.
- [15] TIAN Y, LAI R C, LI X Y, et al. A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter[J]. *Applied energy*, 2020, 265: 114789.
- [16] LI C, ZHANG H H, DING P, et al. Deep feature extraction in lifetime prognostics of lithium-ion batteries: advances, challenges and perspectives[J]. *Renewable and sustainable energy reviews*, 2023, 184: 113576.
- [17] HE N, WANG Q Q, LU Z F, et al. Early prediction of battery lifetime based on graphical features and convolutional neural networks[J]. *Applied energy*, 2024, 353: 122048.
- [18] SHEN S, SADOUGHI M, CHEN X Y, et al. A deep learning method for online capacity estimation of lithium-ion batteries [J]. *Journal of energy storage*, 2019, 25: 100817.
- [19] YANG D, ZHANG X, PAN R, et al. A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve [J]. *Journal of power sources*, 2018, 384: 387-395.
- [20] JIN H Y, CUI N M, CAI L, et al. State-of-health estimation for lithium-ion batteries with hierarchical feature construction and auto-configurable Gaussian process regression[J]. *Energy*, 2023, 262: 125503.
- [21] TAN X J, ZHAN D, LYU P X, et al. Online state-of-health estimation of lithium-ion battery based on dynamic parameter identification at multi timescale and support vector regression [J]. *Journal of power sources*, 2021, 484: 229233.
- [22] XIAO B, XIAO B, LIU L S. Rapid measurement method for lithium-ion battery state of health estimation based on least squares support vector regression [J]. *International journal of energy research*, 2021, 45(4): 5695-5709.
- [23] JIA J F, YUAN S F, SHI Y H, et al. Improved sparrow search algorithm optimization deep extreme learning machine for lithium-ion battery state-of-health prediction [J]. *iScience*, 2022, 25(4): 103988.
- [24] 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.
- [25] CHEN X, LIU X Y, SHEN X, et al. Applying machine learning to rechargeable batteries: from the microscale to the macroscale [J]. *Angewandte Chemie international edition*, 2021, 60(46): 24354-24366.
- [26] GOU B, XU Y, FENG X. An ensemble learning-based data-driven method for online state-of-health estimation of lithium-ion batteries [J]. *IEEE transactions on transportation electrification*, 2021, 7(2): 422-436.
- [27] LI X Y, YUAN C G, LI X H, et al. State of health estimation for Li-ion battery using incremental capacity analysis and Gaussian process regression [J]. *Energy*, 2020, 190: 116467.
- [28] LIN M Q, WU D G, MENG J H, et al. A multi-feature-based multi-model fusion method for state of health estimation of lithium-ion batteries [J]. *Journal of power sources*, 2022, 518: 230774.
- [29] XIONG R, SUN Y, WANG C X, et al. A data-driven method for extracting aging features to accurately predict the battery health [J]. *Energy storage materials*, 2023, 57: 460-470.
- [30] XING Y J, MA E W M, TSUI K L, et al. An ensemble model for predicting the remaining useful performance of lithium-ion batteries [J]. *Microelectronics reliability*, 2013, 53(6): 811-820.
- [31] 黄佳茵, 白俊琦, 贤燕华. 基于DOD-LN-GPR模型的锂离子电池SOH估计方法[J]. *太阳能学报*, 2025, 46(2): 60-69.
- HUANG J Y, BAI J Q, XIAN Y H. SOH estimation method of lithium-ion batteries based on DOD-LN-GPR model [J]. *Acta energiae solaris sinica*, 2025, 46(2): 60-69.
- [32] 范智伟, 乔丹, 崔海港. 锂离子电池充放电倍率对容量衰减影响研究[J]. *电源技术*, 2020, 44(3): 325-329.
- FAN Z W, QIAO D, CUI H G. Influence of charge and discharge rate on capacity fade of lithium ion battery [J]. *Chinese journal of power sources*, 2020, 44(3): 325-329.
- [33] LIU S Z, CHEN J J, ZHANG C, et al. Experimental study on lithium-ion cell characteristics at different discharge rates [J]. *Journal of energy storage*, 2022, 45: 103418.
- [34] REN P, WANG S L, CHEN X P, et al. A novel multiple training-scale dynamic adaptive cuckoo search optimized long short-term memory neural network and multi-dimensional health indicators acquisition strategy for whole life cycle health evaluation of lithium-ion batteries [J]. *Electrochimica acta*, 2022, 435: 141404.
- [35] BIRKL C R. Diagnosis and prognosis of degradation in lithium-ion batteries [D]. Oxford: University of Oxford, 2017, 1-177.

LITHIUM BATTERY CAPACITY ESTIMATION METHOD BASED ON CONSTANT CURRENT CHARGING DATA

Cheng Weida, Sun Shuo, Yin Hang, Wang Zongliang, Cai Wei, Song Jiakai

(*Naval Submarine Academy, Qingdao 266199, China*)

Abstract: Accurate estimation of lithium battery capacity is the basis for its safe and reliable operation. However, the lithium battery capacity attenuation mechanism is not clear, and its capacity shows nonlinear attenuation during use, making it extremely difficult to accurately estimate the lithium battery capacity. In order to solve these problems, this paper proposes a method to estimate the capacity of lithium batteries by using constant current charging data and a one-dimensional convolutional neural network model. Firstly, two aging feature sequences are extracted from the constant current charging stage: the constant current charging capacity and the time interval of equal charging voltage rise. Secondly, in order to make full use of the measured charging information and extract the key capacity attenuation factors in aging feature sequences, a new one-dimensional convolutional neural network capacity estimation model is constructed. Finally, the proposed capacity estimation model is verified and analyzed on the aging data set of lithium batteries in Maryland. The experimental results show that the proposed method can achieve an accurate and robust estimation of battery capacity on the complete constant current charging curve and partial constant current charging curve, which is better than other capacity estimation methods. The root mean square error (RMSE) and mean absolute error (MAE) can be controlled within 0.68% and 0.50%. Furthermore, after transfer learning with a small amount of data, the proposed model can accurately estimate battery discharge capacity at other discharge rates. After transfer learning for the first 50 cycles, the root mean square error of the model at a 0.5C discharge rate is only 0.58%.

Keywords: lithium batteries; convolutional neural networks; transfer learning; capacity estimation; constant current charging; deep learning