



基于随机充电片段和DBFN-ML的锂电池健康状态估计

张 钰, 赵志衡, 周海睿

(哈尔滨工业大学电气工程及自动化学院, 黑龙江 哈尔滨 150001)

摘要: 准确估计锂电池健康状态 (state of health, SOH) 对保障储能系统的稳定运行至关重要。在实际应用场景中, 电池充电过程通常呈现非完整与非固定特性, 导致可获取的充电数据多为随机片段, 使得传统 SOH 估计方法难以有效应对。针对该问题, 本研究提出一种基于双分支融合网络 (dual-branch fusion network, DBFN) 与元学习 (meta-learning, ML) 的 SOH 估计方法。首先, 将原始充电数据划分为多个电压区间片段, 从中提取增量容量 (incremental capacity, IC) 平均值、充电容量及充电时间作为健康特征 (health feature, HF), 并将初始与结束电压作为片段位置信息特征。其次, 构建 DBFN 模型, 通过 2 个独立分支分别处理上述 2 类特征, 以捕捉与电池退化相关的健康信息及片段上下文位置信息, 并借助融合模块实现基于随机充电片段的 SOH 估计。进一步引入元学习, 利用少量样本进行多电池任务学习, 从而快速优化 DBFN 参数并增强模型泛化能力。最后, 基于美国国家航空航天局 (National Aeronautics and Space Administration, NASA) 锂电池数据集进行实验验证, 将本研究模型与其他模型进行对比。实验结果表明, 所提方法在 SOH 估计方面表现优异, 最优均方误差为 0.00012, 平均绝对误差为 0.00892, 平均绝对百分比误差为 1.14%。

关键词: 锂电池; 随机充电片段; 健康状态估计; 增量容量; 双分支融合网络; 元学习

doi: 10.19799/j.cnki.2095-4239.2025.1021

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (2026) 06-2368-12

Estimation of lithium-ion battery state of health based on random charging segments and DBFN-ML

ZHANG Yu, ZHAO Zhiheng, ZHOU Hairui

(School of Electrical Engineering and Automation, Harbin Institute of Technology, Harbin 150001, Heilongjiang, China)

Abstract: Accurate estimation of the state of health (SOH) lithium batteries is crucial for ensuring the stable operation of energy-storage systems. In practical applications, the battery-charging process often exhibits incomplete and non-stationary characteristics, resulting in predominantly random segments of charging data. This poses significant challenges to traditional SOH-estimation methods. To address this issue, in this paper we propose an SOH-estimation method based on a dual-branch fusion network (DBFN) and meta learning (ML). First, we divide the raw charging data into multiple voltage-interval segments, and we extract from them the average incremental capacity, charging capacity, and charging time as health features. We utilize the initial and terminal voltages of each segment as positional-information

收稿日期: 2025-11-12; 修改稿日期: 2026-01-04。

基金项目: 2020 年工业互联网创新发展工程项目 (TC200H037)。

第一作者: 张钰 (2001—), 男, 硕士研究生, 研究方向为锂电池状态估计与寿命预测, E-mail: 1198708113@qq.com; 通信作者: 赵志衡, 教授, 研究方向为锂电池管理系统智能算法, E-mail: zhzhhe@hit.edu.cn。

引用本文: 张钰, 赵志衡, 周海睿. 基于随机充电片段和 DBFN-ML 的锂电池健康状态估计[J]. 储能科学与技术, 2026, 15(6): 2368-2379.

Citation: ZHANG Yu, ZHAO Zhiheng, ZHOU Hairui. Estimation of lithium-ion battery state of health based on random charging segments and DBFN-ML[J]. Energy Storage Science and Technology, 2026, 15(6): 2368-2379.

features. Subsequently, we construct a DBFN model that includes two independent branches designed to process the aforementioned two types of features. This approach captures both the health-related information associated with battery degradation and the contextual positional information from the segments. We then employ a fusion module to estimate the SOH based on the random charging segments. Furthermore, we introduce ML to facilitate multi-battery task learning with limited samples, thereby rapidly optimizing the DBFN parameters and enhancing the capability for generalizing the model. Finally, we performed experimental validation using the NASA lithium-battery dataset and compared the proposed model with other benchmark models. Our results demonstrate that the proposed method excels in SOH estimation, achieving an optimal mean square error of 0.00012, a mean absolute error of 0.00892, and a mean absolute percentage error of 1.14%.

Keywords: lithium-ion batteries; random charging segments; health status estimation; incremental capacity; dual-branch fusion network; meta-learning

在全球新能源产业快速发展的背景下, 锂电池由于其高能量密度、重量轻、低放电率等优点, 被广泛应用于储能系统的能量供应^[1]。然而, 在高温、高负荷、过充放电等复杂工况的长期使用下, 锂电池性能和容量会逐渐衰减。当衰减程度加剧时, 甚至可能引发热失控、燃烧或爆炸等安全事故^[2]。因此, 准确评估锂电池的 SOH 对于优化电池运行维护策略、延长其使用寿命、保障系统安全稳定运行具有重要意义^[3]。

目前, SOH 估计方法可以分为基于模型的方法和基于数据驱动的方法^[4]。基于模型的方法可进一步划分为经验模型、等效电路模型、电化学模型。经验模型通过拟合可用容量与循环次数之间的衰减趋势, 构建误差最小的数学表达式, 但其参数利用不充分, 估计精度有限^[5]。等效电路模型可以有效表征电池的动态和稳态特性^[6]。电化学模型则从电化学反应机理出发揭示电池老化过程^[7]。等效电路和电化学模型二者具有明确的物理化学意义, 但由于内部反应过程复杂, 模型参数辨识困难、计算复杂度较高。

为提升电化学模型的实用性, 近期研究开始聚焦于机理驱动的使用寿命设计与优化。文献[8]提出了一种失效机理驱动的逆向设计与优化流程, 通过参数敏感性分析与多目标优化, 识别出影响电池寿命的关键设计参数(如电极面积密度、颗粒半径、界面特性), 并实现了 70.97%~138.41% 的寿命提升预测。这类工作体现了机理模型在电池设计阶段的指导价值, 也为数据驱动方法提供了可解释的物理

基础。

基于数据驱动的方法以大量的锂电池运行数据为基础, 依托机器学习算法的强大非线性映射能力, 无需深入探究锂电池内部反应机理, 即可实现较高精度的 SOH 估计, 展现出良好的应用前景^[9]。典型方法包括高斯过程回归(Gaussian process regression, GPR)、遗传算法、支持向量机(support vector machine, SVM)及各类神经网络模型等^[10]。该类方法的核心在于从电池外部可测参数中提取与 SOH 高度相关的 HF, 并建立从 HF 到 SOH 的映射关系。因此, 设计与 SOH 强相关的 HF 成为该方法的关键环节^[11]。

在实际应用中, 电池放电过程受负载变化影响较大, 具有不确定性^[12]; 而充电过程通常在受控条件下进行, 更易于从中提取稳定的 HF 用于 SOH 估计^[13-14]。基于电池充电过程提取的 HF 主要包括恒流充电时间、恒流充电能量、恒压充电时间、恒压充电能量、平均充电电流降、平均充电电压降、充电电压曲线斜率、充电温度到达峰值时间等^[15-20]。文献[21]提取恒流恒压充电过程的能量和等电压差能量作为 HF, 并采用 GPR 算法实现 SOH 估计。另有研究通过神经网络等算法自动从原始数据中提取特征^[22]。文献[23]设计了一维卷积神经网络(convolutional neural networks, CNN), 通过一维卷积层自动从充电过程中的电压、电流、温度曲线提取特征, 来实现 SOH 估计。尽管上述方法取得了良好效果, 但其均依赖于完整充电过程或固定充电片段的数据。

然而,在实际运行条件下,受运行工况等因素影响,往往难以获取完整或固定长度的充电数据,从而限制了现有方法的适用性^[24]。同一HF在不同充电片段中的表现各异,难以与SOH建立稳定有效的直接映射关系。为此,部分研究尝试采用自动特征提取方法充分挖掘片段数据中的信息,并通过构建高维特征空间实现随机片段的SOH估计。文献[25]使用多段分割和CNN相结合的方法,自动提取片段数据特征,在统一模型下实现多片段的SOH估计。但该方法对数据量与质量要求较高,易导致过拟合及泛化能力不足。文献[26]结合物理知识,人工提取了30种直接与间接特征,并借助相关性分析与递归特征剔除-交叉验证筛选冗余特征,但在建模过程中未对不同类型特征进行针对性处理。文献[27]提出了一种融合深度学习与物理模型的混合框架,仅需从任意SOC开始的11个充电点(约2.5 min),即可预测无极化ICA曲线。该方法在噪声、老化状态变化下仍保持强鲁棒性,展现了极短片段诊断在实际应用中的巨大潜力。然而,该方法仍依赖于高质量标注数据与复杂的物理模型耦合,且在特征异构性处理与跨电池泛化方面尚未深入优化。

这些特征在尺度、物理意义及与SOH的相关性模式上存在显著差异,构成了异构特征空间。传统的单分支神经网络或机器学习模型(如GPR、SVM)通常将这些特征简单拼接后输入,未能充分考虑其内在差异性,导致模型难以充分挖掘异构特征间的互补信息,限制了特征表达的效能与估计精度的进一步提升。

此外,锂电池的退化轨迹因制造差异、运行工况不同而呈现出个体特性,导致数据分布在不同电

池间存在偏移。现有的模型训练多采用传统范式,即在固定数据集上训练后应用于测试集。这种训练方法难以适应跨电池任务中“小样本、新分布”的挑战,从而限制了模型的泛化性能。

针对上述问题,本研究提出了一种基于随机充电片段特征提取和DBFN-ML的锂电池SOH估计方法。该方法能够利用随机充电片段提取电池健康特征,降低对数据完整性的依赖;通过设计DBFN模型以及引入ML方法,进一步提升SOH估计精度与模型泛化能力。主要工作及创新点如下:

(1) 针对实际电池使用中间歇性充电的特点,将充电过程进行分段处理并提取特征,使算法能够适应随机充电片段数据。

(2) 提出了一种基于DBFN的SOH估计方法,通过双分支结构针对性处理2种特征,再经融合模块实现信息互补与协同,从而提高估计性能。

(3) 在模型优化方面引入元学习方法,通过内外循环机制在不同电池任务间快速优化DBFN的临时参数与初始参数,增强模型跨电池泛化能力。

本研究方法的整体框架如图1所示,主要分为3个部分:特征处理、模型构建和模型测试。

首先,采集锂电池各循环的充电数据,采用固定电压片段长度与滑动步幅对原始数据进行分割,并结合增量容量分析等方法提取健康特征和位置特征。然后,构建DBFN模型,通过独立双分支结构针对性处理2种输入特征进行SOH估计,并引入ML方法划分训练与测试任务,通过内外循环优化DBFN模型的参数并进行训练。最后,进行模型评估。将测试数据输入训练好的模型中,输出估计的SOH值,通过多种评价指标验证模型的性能,同时与其他模型估计结果进行对比。




图1 整体方法流程图

Fig. 1 The overall methodology flowchart

1 锂电池数据分析和特征处理

1.1 数据分析

本研究使用的数据来自 NASA 锂电池数据集的 BatteryAgingARC-FY08Q4 数据包^[28], 由 4 个 LG 生产的 18650 圆柱形 $\text{LiCoO}_2/\text{LiNiCoAlO}_2$ 电池 (负极是石墨) 组成, 4 个锂电池 (B0005、B0006、B0007 和 B0018) 在室温 24°C 下进行了 3 种不同操作模式 (充电、放电和阻抗) 的测试。充电过程以 1.5 A 的恒定电流模式进行, 直到电池电压达到 4.2 V, 然后转为恒定电压模式, 直到充电电流降至 20 mA。放电过程以 2 A 的恒定电流进行, 直到电池电压分别降至 2.7 V、2.5 V、2.2 V 和 2.5 V (对应 B0005、B0006、B0007 和 B0018)。实验在电池达到寿命终止 (end of life, EOL) 标准时停止, 额定容量从 2 Ah 降至 1.4 Ah, 即容量衰减了 30%。以 B0005 号电池为例, 图 2(a)、(b) 展示了在第 40、80、120、160 次循环的充电电压和电流曲线。图 2(c) 为 4 块电池的容量衰减曲线。通过对

比图 2(a)、(b) 所示的不同循环下的充电曲线可以看出, 随着循环次数的增加, 充电过程更早地进入恒压阶段, 从而导致充电电流提前下降。这些随循环而产生的变化, 可在一定程度上反映电池的容量衰减。将图 2(c) 中各电池每个循环的当前容量与标称容量进行对比, 得到每个循环的 SOH 值。

1.2 特征处理

由于特征提取和 SOH 估计均基于随机充电片段, 因此先对原始充电数据进行分段处理。在该数据集中, 电池在早期循环中的充电电压范围为 3.4~4.2 V; 随着容量衰减, 起始充电电压逐渐上升至 3.8 V 以上。为确保所选充电片段能够覆盖电池全寿命周期中的老化过程, 选定 3.9~4.2 V 电压区间进行分段处理。在此区间内, 采用 0.1 V 的片段长度与 0.01 V 的滑动步长, 以滑动窗口方式采样片段数据, 如式(1)所示。

$$M = \frac{V_{\text{end}} - V_{\text{start}} - I}{s} + 1 \quad (1)$$

式中, M 为采样的片段数; I 为片段长度; s 为滑动步长。




图2 NASA 锂电池数据集: (a) 充电电压曲线; (b) 充电电流曲线; (c) 容量衰减曲线

Fig. 2 NASA lithium battery dataset: (a) Charging voltage curve; (b) Charging current curve; (c) Capacity degradation curve

依据上述方法, 充电曲线在 3.9~4.2 V 区间将被划分为 21 个长度为 0.1 V 的片段。只要充电过程的电压覆盖某一电压片段, 即可利用该片段进行 SOH 估计。

1.2.1 特征提取

锂电池容量衰减的根本原因在于活性锂离子和活性材料的损耗。通过 IC 曲线分析电池充电过程中容量随电压变化的微分特性, 可有效识别电池内部的电化学反应。IC 曲线的峰值、位置和形状, 为 SOH 估计提供了丰富的健康信息。增量容量计算一般以一阶微分的形式进行, 如式(2)所示。

$$\frac{dQ}{dV} = \frac{Q_{t+1} - Q_t}{V_{t+1} - V_t} \quad (2)$$

式中, Q_t 是 t 时刻的容量; V_t 是 t 时刻的电压。

在采样过程中, 受环境干扰与传感器测量精度影响, 数据中常包含噪声。由于 IC 曲线对噪声较为敏感, 直接使用难以获得良好结果, 因此需对数据进行降噪处理。本研究采用 Savitzky-Golay 滤波器进行平滑去噪, 并设定最小电压间隔阈值, 以避免因采样间隔过小产生阶跃信号。该方法在有效抑制噪声的同时, 能够保持数据原有的形状与宽度, 不影响 IC 曲线的有效信息含量。Savitzky-Golay 滤波器的计算公式如下:

$$y_n = \sum_{k=-m}^m c_k x_{n+k} \quad (3)$$

式中, y_n 是滤波后的结果; x_{n+k} 是滤波前的输入数据; 窗口长度为 $2m+1$; c_k 为 Savitzky-Golay 系数。

Savitzky-Golay 系数是对窗口内的数据进行局部最小二乘多项式拟合得到的, 无需额外设置参数。经过测试, 窗口长度设为 21, 最小电压间隔设为 0.004 V 时处理效果最佳。图 3(a)、(c) 为 B0005 和 B0006 号电池不同循环的原始 IC 曲线热图, 图 3(b)、(d) 则为经上述方法处理后的 IC 曲线

热图。由图 3 可知, 随着循环次数的增加, 电池充电起始电压逐渐上升, IC 曲线峰值逐渐降低并向高电压方向移动, 反映出电池容量呈衰减趋势。此外, IC 曲线形态由双峰逐渐过渡为单峰, 是负极从非平衡态相变向准平衡态相变过渡的结果。这一转变反映了电极材料在循环过程中逐渐趋于均质化, 并伴随着不可逆的老化进程。对比图 3(a)、(b), 处理后 IC 曲线的整体趋势与关键特征得以有效保留, 同时噪声干扰显著降低, 有利于后续特征的提取与分析。




图3 IC曲线热图: (a) B0005原始曲线; (b) B0005处理后曲线; (c) B0006原始曲线; (d) B0006处理后曲线
Fig. 3 IC curve heatmap: (a) Original curve of B0005; (b) Processed curve of B0005; (c) Original curve of B0006; (d) Processed curve of B0006

多数研究以 IC 曲线的峰值及其对应电压作为 SOH 估计的 HF。然而, 在随机充电片段条件下, 无法保证始终捕捉到 IC 峰值。因此, 本研究提取 IC 均值作为 HF_1 , 计算公式如下:

$$HF_1 = \frac{1}{n} \sum_{i=1}^n IC_i \quad (4)$$

式中, n 为该片段数据中的样本数。

容量-电压(Q-V)曲线通过电池在不同电压下所获得的充电容量来反映电池的老化机制。该曲线易于分析, 提供宏观信息, 直观但灵敏度低, 而 IC 曲线通过微分放大微观变化, 识别隐藏的老化信

息, 两者具有互补性。图 4 是 B0005 和 B0006 号电池的 Q-V 曲线热图。由图 4 可知, 电池在低电压区间内容量增长缓慢, 随着电压升高, 容量增速加快, 而后再次趋缓。随着循环次数的增加, 初始充电电压升高, 相同电压区间内的容量增长速度减缓。

从 Q-V 曲线片段中提取充电容量作为 HF_2 , 计算公式如下:

$$HF_2 = Q_n - Q_1 \quad (5)$$

式中, Q_1 为充电片段的初始容量; Q_n 为充电片段的结束容量。




图4 Q-V曲线热图: (a) B0005曲线; (b) B0006曲线
Fig. 4 Q-V curve heatmap: (a) Curve of B0005; (b) Curve of B0006

然后提取充电时间为 HF_3 , 如式(6)所示。

$$HF_3 = t_n - t_1 \quad (6)$$

此外, 为增强片段的位置辨识能力, 将片段的初始电压 V_{start} 和结束电压 V_{end} 作为位置特征。

1.2.2 特征相关性分析

经过上述处理, 每一循环21个长度为0.1V的充电片段都包含了 HF_1 、 HF_2 、 HF_3 、初始电压和结束电压5个特征。为验证所选特征的合理性, 本研究采用斯皮尔曼相关系数评估其与SOH之间的相关性。

斯皮尔曼相关系数是一种用来衡量2个变量之间相关性的统计方法, 适用于评估单调关系的强度和方向。其计算不依赖于数据的具体分布形式, 因此可以应用于各种类型的数据, 具有较好的鲁棒

性。计算公式如下:

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (7)$$

式中, n 为数据个数; d_i 为第 i 个样本对的位次值之差。

斯皮尔曼相关系数取值区间为 $[-1, 1]$ 。当系数为0时, 表示特征与SOH之间无单调相关关系; 系数绝对值越大, 表明相关性越强。对各充电片段中的HF与SOH进行斯皮尔曼相关系数计算, 结果如图5所示。由图5可知, 提取的 HF_1 、 HF_2 、 HF_3 在各片段上的相关系数绝大多数高于0.9, 少部分为0.8~0.9, 说明与SOH之间有较强的相关性, 能够有效表征SOH的变化。




图5 斯皮尔曼相关系数热力图: (a) B0005; (b) B0006
Fig. 5 Heatmap of Spearman correlation coefficient: (a) B0005; (b) B0006

2 基于DBFN-ML的SOH估计模型

2.1 DBFN设计

为应对随机充电片段带来的挑战，并有效利用从片段中提取的异构特征，本研究设计了专用于SOH估计的双分支融合网络（DBFN）。该网络主要由位置编码分支与健康特征编码分支构成，通过独立的参数化路径分别处理2类输入——反映片段在全局电压曲线中位置信息的特征，以及表征电池内部老化机理的健康特征，最终经由融合与回归模块实现精确的SOH估计。

位置编码分支的作用是将片段的电压区间信息映射为高维上下文嵌入，该信息对于校正不同电压区间下健康特征的物理含义至关重要。该分支由一个2层的前馈神经网络实现，式(8)、式(9)为计算公式。

$$h_{\text{pos}} = \text{ReLU}(W_1 x_{\text{pos}} + b_1) \quad (8)$$

$$z_{\text{pos}} = W_2 h_{\text{pos}} + b_2 \quad (9)$$

式中， x_{pos} 为位置特征；ReLU为神经网络的激活函数； W 和 b 为权重和偏置； z_{pos} 为位置嵌入向量，编码当前充电片段在整体曲线中的上下文信息。

健康特征编码分支负责深入挖掘HF中与电池退化相关的单调趋势及非线性映射关系。相较于位置编码分支，该分支首先将输入特征投影到高维空间，并引入层归一化（layer normalization）以提升模型稳定性并加速训练收敛。层归一化通过对单个样本的所有特征值进行均值和方差归一化，有效缓解内部协变量偏移问题。健康特征编码分支计算公式如下：

$$h_{\text{HF}} = \text{ReLU}[\text{LayerNorm}(W_3 x_{\text{HF}} + b_3)] \quad (10)$$

$$z_{\text{HF}} = W_4 h_{\text{HF}} + b_4 \quad (11)$$

式中， z_{HF} 是健康特征嵌入向量，蕴含了表征SOH退化的关键信息。

为综合2类特征的互补信息，在融合层将位置嵌入向量和健康特征嵌入向量在特征维度上进行拼接，并且将融合后的结果输入回归器，得到SOH的估计结果。

2.2 ML优化

传统训练方法导致模型在不同电池上的泛化性较差，为了解决这一问题，本研究引入ML优化模型的训练。ML不同于传统训练方法只关注单一任务的表现，而是通过多个任务的学习来提升其在新

任务上的学习能力。ML的目标是通过学习一种通用的学习策略，使模型能够利用少量样本或计算资源快速适应新任务。

元学习采用内外双层优化结构，并将任务划分为支持集和查询集。内循环是在每个任务内部进行的训练，在支持集上进行多次梯度下降，更新临时参数。而外循环则是元学习的目标，在查询集上评估临时参数性能并更新初始参数，使得在所有任务上的内循环训练后的效果最好。所以外循环负责优化元参数，内循环负责在具体任务上的适应。ML内循环和外循环的计算过程如下：

对于每个电池任务 T_i ，使用内循环公式[式(12)]在支持集上进行梯度计算并更新模型临时参数。

$$\theta'_i = \theta - \alpha \nabla_{\theta} L_{T_i}(f_{\theta}) \quad (12)$$

式中， θ'_i 为内循环更新后的临时参数； θ 为模型的初始参数； α 为内循环学习率； L_{T_i} 为电池任务 T_i 的损失函数； f_{θ} 是参数为 θ 的模型函数； ∇_{θ} 是对参数 θ 的梯度算子。

多步内循环扩展公式（内循环包括 K 步更新）如下：

$$\theta_i(k) = \theta_i(k-1) - \alpha \nabla_{\theta_i(k-1)} L_{T_i}(f_{\theta_i(k-1)}), k = 1, 2, \dots, K \quad (13)$$

基于所有电池任务的查询集损失，使用式(14)更新模型初始参数 θ 。

$$\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{T_i \sim p(T)} L_{T_i}(f_{\theta_i}) \quad (14)$$

式中， β 为外循环学习率； $p(T)$ 为电池任务分布； $\nabla_{\theta} L_{T_i}(f_{\theta_i})$ 为外循环梯度项，需通过二阶导数计算。

外循环梯度项可利用Hessian向量积计算：

$$\nabla_{\theta} L_{T_i}(f_{\theta_i}) = \nabla_{\theta_i} L_{T_i}(f_{\theta_i}) \cdot \nabla_{\theta}(\theta'_i) \quad (15)$$

将式(15)代入式(12)：

$$\nabla_{\theta} L_{T_i}(f_{\theta_i}) = \nabla_{\theta_i} L_{T_i} \cdot [I - \alpha \nabla_{\theta_i}^2 L_{T_i}(f_{\theta_i})] \quad (16)$$

式中， $\nabla_{\theta_i}^2$ 为Hessian矩阵。

2.3 DBFN-ML模型参数设置

DBFN由2个分支和融合层构成，位置编码分支由1个两层的前馈神经网络实现。健康特征编码分支在两层前馈神经网络前加入层归一化。而后经过融合层将2种信息整合，并输出SOH估计结果。DBFN参数配置如表1所示，分支1为位置编码分支，分支2为健康特征编码分支。

然后，引入ML方法对DBFN进行参数调优。将数据集中3块电池作为元训练任务，剩余电池作

表 1 DBFN 参数配置

Table 1 DBFN parameter configuration

参数	配置
分支 1 嵌入维度	32
分支 1 全连接层维度	16
分支 2 嵌入维度	64
分支 2 全连接层维度	32
融合层维度	32

为元测试任务。在元训练任务中，每块电池随机提取 70 个循环，再从每个循环中随机提取 15 个片段作为该任务的支持集。查询集则由 60 个循环中各随机抽取 10 个片段构成。此类随机划分策略可避免模型对特定循环的过拟合。具体的参数配置如表 2 所示。

表 2 ML 参数配置

Table 2 ML parameter configuration

参数	配置
内循环轮次	5
内循环批大小	512
外循环轮次	4
外循环批大小	512

模型训练过程中，采用 Adam 优化器并且设置学习率为 3×10^{-4} ，迭代轮次为 600，每 100 轮次学习率衰减为当前的 0.6。损失函数使用均方误差函数。每轮次迭代中，支持集先经 5 次内循环更新 DBFN 的临时参数，随后将临时参数传递至查询集计算损失，最后综合各元训练任务的查询损失，通过 4 次外循环更新 DBFN 的初始参数。该机制使得模型能够利用有限数据实现多电池任务的快速适应。

3 实验和结果分析

3.1 评价指标

为了评价 SOH 估计模型的性能，选用均方误差 (mean square error, MSE)、平均绝对误差 (mean absolute error, MAE)、平均绝对百分误差 (mean absolute percentage error, MAPE) 作为评价指标。MSE、MAE、MAPE 的计算公式如下：

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i^* - y_i)^2 \quad (17)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i^* - y_i| \quad (18)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i^* - y_i}{y_i} \right| \times 100\% \quad (19)$$

式中， y_i^* 为算法输出结果； y_i 为真实结果； n 为总样本数。这 3 个指标越接近于 0，代表模型估计误差越小，精度越高。

3.2 SOH 估计结果分析

为了验证 DBFN-ML 模型的估计性能，基于 NASA 锂电池数据集展开实验评估。测试采用交叉验证的方式，分别以 B0005、B0006、B0007、B0018 为测试任务，剩余 3 块电池数据为训练任务。图 6~图 8 分别展示了各电池在不同电压片段上的 MSE、MAE 和 MAPE 结果，以热图形式呈现。图中纵轴为测试电池编号，横轴为划分的 21 个电压片段，颜色深浅反映误差大小：深红色表示误差较大，浅黄色表示误差较小。分析热图可知，B0005 电池的估计效果最佳，B0007 电池的误差略大。此外，模型在低电压片段上表现更优，而在高电压片段上误差有所上升，这源于高电压区间中电池内部反应更为复杂，且受极化效应与充电策略影响，导致特征与 SOH 之间的映射关系变弱。




图 6 DBFN-ML 模型估计结果的 MSE 热图

Fig. 6 MSE heatmap of the DBFN-ML model estimation results




图7 DBFN-ML 模型估计结果的MAE 热图

Fig. 7 MAE heatmap of the DBFN-ML model estimation results




图8 DBFN-ML 模型估计结果的MAPE 热图

Fig. 8 MAPE heatmap of the DBFN-ML model estimation results

表3列出了各电池在最优与最差片段下的误差结果。B0005电池的估计精度最高，其最优MAPE仅为1.14%，最差情况下亦不超过2.16%。B0006、B0007与B0018电池的最优MAPE约为2%，而在高电压片段的最差MAPE约为5%。总体而言，DBFN-ML模型在绝大多数电压片段上的MAPE低于3%，仅少数片段超过5%，表现出较高的估计精度。

表3 各电池最小和最大误差结果

Table 3 Minimum and maximum error results of each battery

电池	MSE	MAE	MAPE
B0005_best	0.00012	0.00892	1.14%
B0005_worst	0.00035	0.01691	2.16 %
B0006_best	0.00043	0.01584	2.09%
B0006_worst	0.00185	0.03911	5.25%
B0007_best	0.00038	0.01599	1.94%
B0007_worst	0.00249	0.04723	5.66%
B0018_best	0.00040	0.01583	1.97%
B0018_worst	0.00150	0.03525	4.44%

为进一步评估模型性能，图9展示了4块电池在最优片段下的SOH估计曲线与真实曲线的对比。图中黑色曲线表示真实SOH值，红色、蓝色、绿色与紫色曲线分别对应B0005（片段21）、B0006

（片段3）、B0007（片段4）及B0018（片段13）的估计结果。可见，DBFN-ML模型的估计曲线与真实值高度吻合，且能准确捕捉锂电池的非线性衰减趋势及容量再生现象。




图9 DBFN-ML 模型最优估计曲线

Fig. 9 Optimal estimation curve of the DBFN-ML model

3.3 不同估计模型对比

为验证DBFN-ML模型的有效性，本研究将其与3种对比模型进行实验比较：DBFN（无元学习）、BPNN-ML（反向传播神经网络结合元学习）以及CNN-LSTM。图10展示了各模型在4块电池上的SOH估计曲线，其中估计结果为21个片段的平均值。




图 10 不同模型在各电池上的 SOH 估计结果对比: (a) B0005; (b) B0006; (c) B0007; (d) B0018

Fig. 10 Comparison of SOH estimation results by different models across batteries: (a) B0005; (b) B0006; (c) B0007; (d) B0018

实验结果表明, DBFN-ML 模型在所有电池上均取得最优的估计性能, 其估计曲线与真实值最为接近。具体而言, 在 B0005、B0006、B0007 和

B0018 电池上, DBFN-ML 的 MAPE 分别为 1.21%、3.10%、3.58% 和 2.49%, 其 MSE 与 MAE 亦显著低于其他模型。BPNN-ML 模型的估计精度有所下

降,且估计曲线波动较为明显,平均MAPE上升至约5%,说明其单分支结构难以有效融合异构特征。DBFN(无元学习)模型由于缺乏元学习机制的优化,跨电池适应能力受限,性能也有所下降。而新加入的CNN-LSTM模型在所有电池上的表现均为最差,MAPE为5.69%~8.32%,其缺乏跨电池适应能力,同时在异构特征处理方面也存在不足。

综上所述,DBFN-ML模型通过双分支结构与元学习机制的协同设计,显著提升了SOH估计的精度与稳定性,在不同电池数据上均表现出优越的泛化能力。

4 结 论

为实现基于随机充电数据片段的电池健康状态估计,本研究提出了一种基于DBFN-ML的估计方法。该方法首先将原始充电数据按电压区间划分为多个片段,并从中提取3类健康特征——增量容量均值、充电容量与充电时间,同时将片段的起始电压与结束电压作为位置特征。在此基础上,构建了由位置编码分支和健康特征编码分支组成的DBFN模型,通过双分支结构分别提取2类特征的高维嵌入表示,并借助融合与回归模块实现SOH的端到端估计。为进一步提升模型在跨电池场景下的适应能力,引入元学习机制,使模型能够基于有限样本在多电池任务中实现快速优化与泛化。在NASA公开锂电池数据集上的实验表明,DBFN-ML模型能够实现较高的估计精度,其最优MAPE可达1.14%,平均MAPE控制在4%以内。与其他模型相比,DBFN-ML表现最佳,这主要得益于以下两方面的创新。

针对异构特征的有效融合机制:本研究设计的双分支结构并非对特征进行简单处理,而是通过独立的分支网络分别编码具有明确物理意义的健康特征与关键位置特征。这实现了异构信息的高效融合,克服了单分支模型或传统方法在混合特征处理上的缺陷,从而在随机片段中建立了更稳健的HF-SOH映射关系。

面向跨电池场景的快速适应能力:引入的元学习机制通过在模拟的跨电池任务中进行元训练,使模型学会了从有限样本中快速捕捉新电池的退化特性。这显著增强了模型在实际应用中应对电池个体差异与多变工况的泛化能力,突破了传统训练范式

对数据同分布的依赖。

本方法在电压区间相对稳定的片段上表现良好,但对于跨越多个电压区间的极短或极长片段,其适用性可能需要进一步验证。本研究通过引入多电池任务学习与随机片段采样策略,旨在增强模型对不同分布老化模式的适应能力与泛化性。但这并不代表其能够适应未知分布的数据,为了获得好的结果,仍需要更多元的训练数据。在后续研究中,将进一步考虑实际应用中高电压区间对特征的影响,探索不同充电阶段下健康特征的提取策略。同时,将引入更多工况条件下的电池数据以验证方法的鲁棒性,推动该估计模型在实际电池管理系统中的工程应用。

参 考 文 献

- [1] 朱振威,苗嘉伟,祝夏雨,等.基于机器学习方法的锂电池剩余寿命预测研究进展[J].储能科学与技术,2024,13(9):3134-3149.
ZHU Z W, MIAO J W, ZHU X Y, et al. Research progress in lithium-ion battery remaining useful life prediction based on machine learning[J]. Energy Storage Science and Technology, 2024, 13(9): 3134-3149.
- [2] HE Y, BAI W Y, WANG L L, et al. SOH estimation for lithium-ion batteries: An improved GPR optimization method based on the developed feature extraction[J]. Journal of Energy Storage, 2024, 83: 110678. DOI:10.1016/j.est.2024.110678.
- [3] WANG Y J, XU R L, ZHOU C J, et al. Digital twin and cloud-side-end collaboration for intelligent battery management system[J]. Journal of Manufacturing Systems, 2022, 62: 124-134. DOI: 10.1016/j.jmsy.2021.11.006.
- [4] SUI X, HE S, VILSEN S B, et al. A review of non-probabilistic machine learning-based state of health estimation techniques for Lithium-ion battery[J]. Applied Energy, 2021, 300(C): DOI: 10.1016/j.apenergy.2021.117346.
- [5] CHAE S G, BAE S J, OH K Y. State-of-health estimation and remaining useful life prediction of lithium-ion batteries using DnCNN-CNN[J]. Journal of Energy Storage, 2025, 106: 114826. DOI:10.1016/j.est.2024.114826.
- [6] YANG J F, CAI Y F, PAN C F, et al. A novel resistor-inductor network-based equivalent circuit model of lithium-ion batteries under constant-voltage charging condition[J]. Applied Energy, 2019, 254: 113726. DOI:10.1016/j.apenergy.2019.113726.
- [7] XIONG W, MO Y M, YAN C. Online state-of-health estimation for second-use lithium-ion batteries based on weighted least squares support vector machine[J]. IEEE Access, 2021, 9: 1870-1881. DOI:10.1109/ACCESS.2020.3026552.
- [8] XI R Y, PENG Y Y, LI J H, et al. Failure-mechanism-driven inverse design and optimization procedure for battery lifetime extension[J]. Angewandte Chemie (International Ed in English),

- 2025, 64(49): e202518502. DOI:10.1002/anie.202518502.
- [9] 陈峥, 多功东, 申江卫, 等. 基于容量增量分析与VMD-GWO-KELM的锂电池健康状态估计[J]. 储能科学与技术, 2025, 14(6): 2476-2487.
- CHEN Z, DUO G D, SHEN J W, et al. State of health estimation for lithium battery based on incremental capacity analysis and VMD-GWO-KELM[J]. Energy Storage Science and Technology, 2025, 14(6): 2476-2487.
- [10] GU X Y, SEE K W, LI P H, et al. A novel state-of-health estimation for the lithium-ion battery using a convolutional neural network and transformer model[J]. Energy, 2023, 262: 125501. DOI: 10.1016/j.energy.2022.125501.
- [11] 戴彦文, 于艾清. 基于健康特征参数的CNN-LSTM&GRU组合锂电池SOH估计[J]. 储能科学与技术, 2022, 11(5): 1641-1649. DOI: 10.19799/j.cnki.2095-4239.2021.0623.
- DAI Y W, YU A Q. Combined CNN-LSTM and GRU based health feature parameters for lithium-ion batteries SOH estimation[J]. Energy Storage Science and Technology, 2022, 11(5): 1641-1649. DOI:10.19799/j.cnki.2095-4239.2021.0623.
- [12] 周岷, 宋显华, 卢文斌, 等. 基于日常片段充电数据的锂电池健康状态实时评估方法研究[J]. 中国电机工程学报, 2019, 39(1): 105-111. DOI:10.13334/j.0258-8013.pcsee.181026.
- ZHOU D, SONG X H, LU W B, et al. Real-time SOH estimation algorithm for lithium-ion batteries based on daily segment charging data[J]. Proceedings of the CSEE, 2019, 39(1): 105-111. DOI:10.13334/j.0258-8013.pcsee.181026.
- [13] ZHU J G, WANG Y X, HUANG Y, et al. Data-driven capacity estimation of commercial lithium-ion batteries from voltage relaxation[J]. Nature Communications, 2022, 13: 2261. DOI: 10.1038/s41467-022-29837-w.
- [14] LU J H, XIONG R, TIAN J P, et al. Deep learning to estimate lithium-ion battery state of health without additional degradation experiments[J]. Nature Communications, 2023, 14: 2760. DOI: 10.1038/s41467-023-38458-w.
- [15] ZHANG M, YANG D F, DU J X, et al. A review of SOH prediction of Li-ion batteries based on data-driven algorithms[J]. Energies, 2023, 16(7): 3167. DOI:10.3390/en16073167.
- [16] CHE Y H, HU X S, LIN X K, et al. Health prognostics for lithium-ion batteries: Mechanisms, methods, and prospects[J]. Energy & Environmental Science, 2023, 16(2): 338-371.
- [17] ZHANG C L, ZHAO S S, YANG Z, et al. A reliable data-driven state-of-health estimation model for lithium-ion batteries in electric vehicles[J]. Frontiers in Energy Research, 2022, 10: 1013800. DOI:10.3389/fenrg.2022.1013800.
- [18] 李英顺, 阚宏达, 郭占男, 等. 基于数据预处理和VMD-LSTM-GPR的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(10): 3244-3258. DOI:10.19595/j.cnki.1000-6753.tces.230210.
- LI Y S, KAN H D, GUO Z N, et al. Prediction of remaining useful life of lithium-ion battery based on data preprocessing and VMD-LSTM-GPR[J]. Transactions of China Electrotechnical Society, 2024, 39(10): 3244-3258. DOI: 10.19595/j.cnki.1000-6753.tces.230210.
- [19] 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. DOI:10.1016/j.energy.2022.125503.
- [20] YANG Y L, CHEN S Y, CHEN T, et al. State of health assessment of lithium-ion batteries based on deep Gaussian process regression considering heterogeneous features[J]. Journal of Energy Storage, 2023, 61: 106797. DOI:10.1016/j.est.2023.106797.
- [21] GONG D L, GAO Y, KOU Y L, et al. State of health estimation for lithium-ion battery based on energy features[J]. Energy, 2022, 257: 124812. DOI:10.1016/j.energy.2022.124812.
- [22] JIANG Y Y, CHEN Y, YANG F F, et al. State of health estimation of lithium-ion battery with automatic feature extraction and self-attention learning mechanism[J]. Journal of Power Sources, 2023, 556: 232466. DOI:10.1016/j.jpowsour.2022.232466.
- [23] 李超然, 肖飞, 樊亚翔, 等. 基于卷积神经网络的锂离子电池SOH估算[J]. 电工技术学报, 2020, 35(19): 4106-4119.
- LI C R, XIAO F, FAN Y X, et al. An approach to lithium-ion battery SOH estimation based on convolutional neural network[J]. Transactions of China Electrotechnical Society, 2020, 35(19): 4106-4119.
- [24] DENG Z W, HU X S, XIE Y, et al. Battery health evaluation using a short random segment of constant current charging[J]. iScience, 2022, 25(5): 104260. DOI:10.1016/j.isci.2022.104260.
- [25] 申江卫, 折亦鑫, 舒星, 等. 基于短时随机充电数据和优化卷积神经网络的锂电池健康状态估计[J]. 储能科学与技术, 2025, 14(4): 1585-1595.
- SHEN J W, SHE Y X, SHU X, et al. State of health estimation for lithium batteries based on short-term random charging data and optimized convolutional neural network[J]. Energy Storage Science and Technology, 2025, 14(4): 1585-1595.
- [26] 江银锋, 宋文祥, 施语. 基于随机充放电片段和稀疏高斯过程回归的电池健康状态估计[J]. 电工技术学报, 2025, 40(19): 6359-6377. DOI:10.19595/j.cnki.1000-6753.tces.241763.
- JIANG Y F, SONG W X, SHI Y. Battery state of health estimation using sparse Gaussian process regression based on random partial charge and discharge data[J]. Transactions of China Electrotechnical Society, 2025, 40(19): 6359-6377. DOI:10.19595/j.cnki.1000-6753.tces.241763.
- [27] TIAN Y, LIN C, MENG X F, et al. Accelerated commercial battery electrode-level degradation diagnosis via only 11-point charging segments[J]. eScience, 2025, 5(1): 100325. DOI: 10.1016/j.esci.2024.100325.
- [28] SAHA B, GOEBEL K. Battery data set[DB]. NASA AMES prognostics data repository, 2007.