

考虑历史退化信息融合的电池健康状态估计研究*

周定华¹ 左培文² 朱仲文¹ 仇昕¹ 马启龙¹

(1. 合肥工业大学汽车与交通工程学院, 合肥 230009; 2. 中汽信息科技(天津)有限公司, 天津 300000)

【摘要】为了精确估计锂离子电池的健康状态,提出一种基于策略优化算法(SOA)和记忆增强型长短期记忆神经网络(MELSTM)的估计方法。首先,采用变分自编码器(VAE)处理原始数据,减少冗余信息并提取健康因子,精确表征电池退化信息。其次,提出一种基于策略优化算法和记忆增强型长短期记忆神经网络结合的模型来估计电池的健康状态。最后,在CACLE和NASA两个锂离子电池老化公共数据集上验证所提出的估计方法的有效性。试验结果证明,所提出的方法相较于传统LSTM算法在RMSE指标上提升了30%以上,为实现精确的锂离子电池健康状态估计提供了新的思路和解决方案。

关键词: 锂离子电池 健康状态 特征提取

中图分类号:U46;TP18;TN303.1 文献标志码:A DOI: 10.19620/j.cnki.1000-3703.20250111

Research on Battery State of Health Estimation with Historical Degradation Information Fusion

Zhou Dinghua¹, Zuo Peiwen², Zhu Zhongwen¹, Qiu Xin¹, Ma Qilong¹

(1. School of Automotive and Transportation Engineering, Hefei University of Technology, Hefei 230009; 2. China Automotive Information Technology (Tianjin) Co., Ltd., Tianjin, 300000)

【Abstract】In order to accurately estimate the State of Health (SOH) of lithium-ion batteries, this paper proposes an advanced SOH estimation method that integrates Strategic Optimization Algorithm (SOA) with Memory-Enhanced Long Short-Term Memory (MELSTM) neural network. Firstly, a Variational AutoEncoder (VAE) is utilized to process raw data, reducing redundant information and extracting health indicators, thereby achieving a precise representation of battery degradation information. Subsequently, a hybrid model combining SOA and MELSTM is proposed to estimate SOH of lithium-ion batteries. Finally, effectiveness of the proposed method is validated using 2 public datasets for lithium-ion battery aging, namely CACLE and NASA. Experimental results demonstrate that the proposed method improves RMSE indicators by over 30% compared with conventional LSTM algorithm, offering new insights and solutions for accurate SOH estimation of lithium-ion battery.

Key words: Lithium-ion battery, State of Health (SOH), Feature extraction

【引用格式】周定华,左培文,朱仲文,等.考虑历史退化信息融合的电池健康状态估计研究[J].汽车技术,2025(6):28-35.

ZHOU D H, ZUO P W, ZHU Z W, et al. Research on Battery State of Health Estimation with Historical Degradation Information Fusion[J]. Automobile Technology, 2025(6): 28-35.

1 前言

锂离子电池因具有自放电率低、循环寿命长、能量密度高、功率密度高、放电平稳、工作温度范围宽、无记忆效应和环保等优势^[1-3],广泛应用于电动汽车、大型储能系统、航空等领域^[4]。然而,锂离子电池在循环过程中会出现老化现象^[5],此外复杂工况和极端环境条

件也会加剧电池老化过程并可能引发故障^[6]。电池管理系统(Battery Management System, BMS)通过控制充放电循环过程来防止过充过放,并监测电池健康状态,保障电池安全稳定运行^[7-8]。电池健康状态(State of Health, SOH)是BMS的关键指标,反映电池老化程度^[9]。然而,由于锂电池复杂的电化学和非线性时变特性,增大了电池SOH估计的难度^[10]。因此,准确估计

*基金项目:安徽省科技重大专项(202203a05020006);中央高校基本科研业务费专项资金(JZ2024HG TB0234)。

通信作者:朱仲文(1988—),研究员级高级工程师,博士生导师,主要研究方向为新能源汽车整车控制、动力电池/燃料电池控制技术, zhuzhongwen@hfut.edu.cn。

电池健康状态是当前电动汽车 BMS 应用和安全性研究的重点和难点。

目前国内外研究人员已开展大量关于锂离子电池 SOH 估计的研究,主要可归纳为三类:直接测量法、模型法和数据驱动法^[11]。Wang 等人^[12]采用安时积分法测算电池容量,操作简单易于实现,但作为离线方法,不适用于在线 SOH 估计。Lai 等人^[13]使用递归最小二乘法在线识别和更新电池模型参数,并结合卡尔曼滤波进行 SOH 估计,效果突出,但该方法依赖模型精度且易受外部环境变化影响。Ma 等人^[14]利用卷积神经网络(Convolutional Neural Networks, CNN)从锂电池充电电压曲线中提取特征,并通过迁移学习减少训练与测试数据的分布差异。Ma 等人^[15]结合改进的差分灰狼优化方法优化长短期记忆神经网络(Long Short-Term Memory, LSTM)的超参数,实现了锂离子电池复杂退化机制下的高效 SOH 估计。尽管 LSTM 在实际应用中表现良好,但其仍面临历史退化信息遗忘速度快的问题,影响 SOH 估计的准确性和鲁棒性。

针对上述问题,本文提出一种新的 SOH 估计方法。首先,采用变分自编码器剔除冗余训练数据,提取关键健康因子信息。然后,建立基于策略优化算法和记忆增强型长短期记忆神经网络实现 SOH 估计。与其他方法相比,该方法具有更强的泛化能力和更准确的 SOH 估计效果,为实现精确的锂离子电池健康状态估计提供了新的思路和解决方案。

2 数据处理和特征提取


2.1 试验数据

锂离子电池的健康状态通常通过当前电池容量与额定容量的百分比来表示:


$$S_t = \frac{C_t}{C_0} \times 100\% \quad (1)$$

式中: S_t 为 t 时刻电池的 SOH 值, C_t 为 t 时刻电池的容量, C_0 为电池的初始容量。

本文采用 2 个公共锂离子电池数据集,分别来自美国国家航空航天局(National Aeronautics and Space Administration, NASA)卓越预测中心^[16]和美国马里兰大学高级生命周期工程研究中心(Center for Advanced Life Cycle Engineering, CALCE)^[17]。2 个数据集的锂离子电池的容量衰减曲线如图 1 所示,其中包括 CALCE 数据集的 4 组数据(CS2_35、CS2_36、CS2_37、CS2_38)和 NASA 数据集的 4 组数据(B0005、B0006、B0007、B0018)。



(a) CALCE 数据集电池容量退化曲线



(b) NASA 数据集电池容量退化曲线

图1 电池容量退化曲线


如图 2 所示,在试验中所有电池的充电过程采用恒流-恒压充电模式进行。在 CALCE 数据集中,电池的额定容量约为 1.1 A·h,充电时先进行 0.5 A 恒流充电,直到电压达到 4.2 V,然后进行 4.2 V 恒压充电,直到电流降至 20 mA;放电时以 1 A 恒流放电,直到电压降至 2.7 V。在 NASA 数据集中,电池额定容量为 2.0 A·h,充电时首先以 1.5 A 恒流充电至电压达到 4.2 V,随后切换为恒压模式,维持 4.2 V 直至充电电流降至 50 mA;放电阶段则以 2.0 A 恒流放电,直至电池电压下降至 2.5 V。每个充放电循环均记录电压、电流、温度及容量数据,用于分析电池在不同老化阶段的性能衰减规律。

锂离子电池的老化是一个长期过程,电池容量变化无法直接获得。因此,需要通过充放电过程中的电流、电压、温度和阻抗的变化来评估电池的健康状态。具体来说,虽然不同充电曲线的整体趋势在退化过程中未发生显著变化,但曲线下的面积随着时间的推移发生了变化,同时,充电阶段的极值点也会发生位移。


此外,增量容量分析可以用来探测电池退化过程中电化学反应的微小变化,这些变化可以通过电压曲线获得,计算公式为:

$$\frac{dQ}{dV} = I \cdot \frac{dt}{dV} \quad (2)$$

式中: Q 为当前电池容量, V 为电压, I 为充电电流。



(a)CALCE 充、放电曲线



(b)NASA 充、放电曲线

图2 电池充放电曲线

在充电过程中,尽管恒流-恒压阶段的电压极值(如截止电压4.2 V)固定不变,但电池老化会导致充电曲线形态发生变化。具体表现为:极值点位移,恒流阶段结束时的电压上升速率减缓,导致达到截止电压所需时间延长,对应充电容量减少;曲线面积变化,退化过程中,相同电压区间内的充电时间缩短,曲线下面积减小;增量容量峰值偏移,通过式(2)计算增量容量曲线,发现峰值电压随老化向低电压方向偏移。

为了定量评估SOH,本文选取的反应电池老化和退化的健康因子包括电压曲线极值、充电时间差和增量容量曲线(Incremental Capacity, IC)峰值。电压曲线极值为恒流阶段结束时刻的电压值,随时间逐渐降低;充电时间差是恒流阶段从3.8 V至4.2 V的时间差,随电池老化而缩短;IC曲线峰值则反映电池内部电化学活性物质损失。

2.2 基于变分自编码器的数据表征

在锂离子电池健康状态估计过程中,退化信息的选择对模型的性能至关重要。然而在实际工程应用中,由于电池退化过程的复杂非线性特性,研究人员通常需要依据经验选择健康因子。这一过程具有高度的主观性,

不同研究者可能关注不同的电池参数,导致SOH评估结果存在差异,并增加了计算复杂度和估计的不确定性。

针对这一问题,本文采用变分自编码器(Variational Autoencoder, VAE)对原始电池数据进行处理,以减少冗余信息并提取关键健康因子,从而实现电池退化信息的自适应表征图3为VAE无监督学习模型,由编码器(Encoder)和解码器(Decoder)组成。编码器将输入数据投影到低维隐空间(Latent Space),提取数据的抽象特征,而解码器则用于从隐空间重构原始数据。其数学关系可表示为:

$$x \approx \hat{x} = f(z; \theta) \quad (3)$$

式中: x 为输入数据的真实值, \hat{x} 为输入数据的估计值, z 为隐变量空间, θ 为变分自编码器的参数。

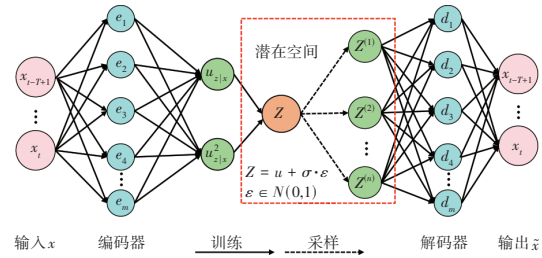


图3 VAE结构

VAE的目标是在最小化重构误差的同时,学习到最优的隐变量表示。在VAE的理论框架下,假设输入数据 x 由隐变量 z 生成,并且 $p(x|z)$ 是给定 z 时 x 的条件概率分布, $p(z)$ 是 z 的先验概率分布,则边缘似然估计可以表示为:

$$p_{\theta}(x) = \int p_{\theta}(z) p_{\theta}(x|z) dz \quad (4)$$

由于隐变量 z 和参数 θ 均未知,直接计算边缘似然较为复杂,因此引入近似分布 $q_k(z|x)$ 来逼近 $p_{\theta}(z|x)$ 。最终,VAE的优化目标可表示为最大化边缘对数似然:

$$\log p_{\theta}(x) = E_z[\log p_{\theta}(x|z)] - D_{KL}(q_k(z|x) || p_{\theta}(z)) + D_{KL}(q_k(z|x) || p_{\theta}(z|x)) \geq L(\theta, k, x) \quad (5)$$

式中: $D_{KL}(\cdot)$ 为KL散度(Kullback-Leibler Divergence),用于衡量近似分布与真实分布之间的差异; $L(\theta, k, x)$ 为VAE的损失函数,包括 $q_k(z|x)$ 和 $p_{\theta}(z|x)$ 之间的KL散度,以及期望重构误差两部分。

因此,VAE的优化目标可由下式给出:

$$\theta^*, k^* = \arg \max_{\theta, k} \sum_i L(\theta, k, x_i) \quad (6)$$

在优化过程中,采用随机梯度变分贝叶斯方法进行参数 θ^* 和 k^* 的更新。

通过VAE编码后的隐变量信息能够有效捕捉锂离子电池复杂的退化模式,同时避免了传统方法中由于健康因子选择主观性导致的不确定性。因此,本文利用

VAE从原始电池数据中提取健康因子,并将其作为SOH估计模型的输入,以提高SOH估计的准确性和鲁棒性。

3 基于SOA和MELSTM的SOH估计方法

3.1 改进的长短期记忆神经网络

LSTM广泛应用于时间序列数据的建模,能够有效捕捉电池退化过程中长期的时间依赖关系。但是传统LSTM无法有效减缓历史退化信息的遗忘速率,导致电池退化信息未能得到充分利用,进而影响了SOH估计的准确性和鲁棒性。

本节提出记忆增强型长短期记忆神经网络(Memory-Enhanced Long Short-Term Memory, MELSTM)用于锂离子电池的健康状态估计,其模型结构如图4所示。从图中可以看出,MELSTM通过引入过去3个时间步的历史信息,增强对历史退化过程的记忆能力。具体而言,在传统LSTM的基础上,通过将前3个时间步的隐藏状态($h_{t-3}, h_{t-2}, h_{t-1}$)和单元状态($c_{t-3}, c_{t-2}, c_{t-1}$)进行拼接,接着采用全连接层和Sigmoid激活函数对这些历史信息进行加权聚合,以获得临时输入信息 h'_{t-1} 和 c'_{t-1} ,最后通过计算得到当前时刻的退化信息输出 h_t 和单元状态 c_t 。




图4 MELSTM模型结构

MELSTM的计算过程如下:

通过聚合前3个时间步的隐藏状态($h_{t-3}, h_{t-2}, h_{t-1}$)和单元状态($c_{t-3}, c_{t-2}, c_{t-1}$),将更长时间步的信息传递给当前时间步,增强模型对长期依赖的捕捉能力。得出临时隐藏状态 h'_{t-1} 和临时细胞状态 c'_{t-1} 的公式如下:

$$h'_{t-1} = \sigma(\mathbf{W}_t^h [h_{t-1}, h'_{t-2}, h'_{t-3}] + \mathbf{b}_t^h) \quad (7)$$

$$c'_{t-1} = \sigma(\mathbf{W}_t^c [c_{t-3}, c_{t-2}, c_{t-1}] + \mathbf{b}_t^c) \quad (8)$$

式中: \mathbf{W}_t^h 、 \mathbf{W}_t^c 、 \mathbf{b}_t^h 和 \mathbf{b}_t^c 为退化信息和新引入的门细胞状态的权重矩阵和偏置矩阵。

对前3个时间步的隐藏状态和细胞状态进行聚合,将这些信息传递给LSTM的门控结构。计算公式如下:

$$f_t = \sigma(\mathbf{w}_f [h'_{t-1}, x_t] + b_f) \quad (9)$$

$$i_t = \sigma(\mathbf{w}_i [h'_{t-1}, x_t] + b_i) \cdot \tanh(\mathbf{w}_c [h'_{t-1}, x_t] + b_c) \quad (10)$$

$$o_t = \sigma(\mathbf{w}_o [h'_{t-1}, x_t] + b_o) \quad (11)$$

式中: f_t 为遗忘门的输出; i_t 为输入门的输出; o_t 为输出

门的输出; $\mathbf{w}_f, \mathbf{w}_i, \mathbf{w}_c, \mathbf{w}_o$ 为权重矩阵,用于将输入数据映射到不同的门; b_f, b_i, b_c, b_o 偏置项,用于调整计算结果; σ 为Sigmoid激活函数,用于引入非线性,从而控制信息流动。

通过门控机制结合临时隐藏状态 h'_{t-1} 和当前输入 x_t ,进一步更新当前的状态。

$$c_t = f_t \cdot c'_{t-1} + i_t \quad (12)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (13)$$

式中: $f_t \cdot c'_{t-1}$ 为遗忘门控制的旧细胞状态信息; h_t 为隐藏状态更新,基于输出门 o_t 和当前细胞状态 c_t 对外输出模型结果。

在电池SOH估计中,MELSTM能够更精确地捕捉电池在不同老化阶段的性能变化,尤其是在处理高维非线性数据时表现出色。结合SOA优化的网络结构和超参数设置,MELSTM的记忆能力得到了进一步增强,能够显著提升SOH预测的精度和泛化能力。

3.2 策略优化算法

在SOH估计过程中,VAE用于减少冗余信息并提取健康因子,而MELSTM用于建模退化信息。为了提升锂离子电池健康状态估计模型的性能,本文提出了策略优化算法(Strategic Optimization Algorithm, SOA),用于VAE和MELSTM的超参数。

SOA是一种基于军事战略的优化算法,灵感来源于古代战争中的攻击策略和防守策略。SOA通过模拟战争中的战略决策过程,动态调整超参数,从而增强模型的全局搜索能力和收敛性能。该算法的假设包括:士兵在战场上随机分布,指挥官具有最强的攻击力,军队的阵型可以根据指挥官和国王的位置进行动态调整。具体的优化过程包括以下步骤:

首先利用立方体混沌映射方法初始化参数,包括士兵种群 U ,最大迭代次数 T ,超参数的上界 U_b 和下界 L_b 。神经网络的超参数信息包含在种群 U 中,其表达式如下:

$$U = [lr_i, h_{zi}, h_{vaei}, h_{li}] \quad (14)$$

式中: lr_i 为第 i 个个体的学习率, h_{zi} 为VAE编码器的神经元数, h_{vaei} 为VAE解码器的神经元数, h_{li} 为MELSTM的神经元数。

计算每个士兵当前位置的适应度值,本文采用训练集的 $-R^2$ 作为适应度函数,计算公式如下:

$$-R^2 = \frac{\sum_{i=1}^n (\hat{S}_i - S_i)^2}{\sum_{i=1}^n (S_i - \bar{S}_i)^2} - 1 \quad (15)$$

根据以下公式确定士兵的最佳位置,并根据适应度

更新士兵的等级,计算公式如下:

$$f_0 = r_2 e^{(-d_r \frac{t}{m} - 1)} \quad (16)$$

$$X_i(t+1) = X_i(t) + 2r_1(C - K) \cdot f_0 + r_1(W_i K - X_i(t)) \quad (17)$$

$$X_i(t+1) = X_i(t) + 2\rho(K - X_r(t)) \cdot f_0 + r_1 W_i(c - X_i(t)) \quad (18)$$

式中: f_0 为引入的一种改进的非线性收敛函数, m 为最大迭代次数, ρ , r_1 和 r_2 是在0到1之间的随机数, d_r 为衰减因子; $X_i(t)$ 为在第 t 次迭代时士兵的位置, $X_r(t)$ 表示士兵在第 t 次迭代时的随机位置, C 和 K 为指挥官和国王的位置, W_i 为国王的权重参数。

当达到最大迭代次数或满足提前停止标准时,退出循环,并输出最优的超参数空间。最后,利用最优超参数构建最优模型,在训练集中进行SOH估计,利用测试集实现对锂离子电池的SOH预测。本文采用策略优化算法(Strategic Optimization Algorithm, SOA)同时对VAE和MELSTM的超参数进行调整,实现SOH估计的协同优化。优化过程如图5所示。

通过这种优化过程,SOA能够在多个任务中实现MELSTM和VAE的协同优化。优化的超参数包含学习率、VAE编码器和解码器的神经元数量以及MELSTM中的神经元数量。

3.3 SOH估计过程

本节描述了基于SOA和MELSTM的SOH估计方法的整体流程如图6所示,包括退化信息的表征、SOH估计模型的离线优化与构建,以及SOH估计的在线分析过程。首先,通过VAE从锂离子电池的充放电数据中提取极值和充放电曲线中的差异,这些特征作为健康因子输入VAE;利用VAE重建的退化信息作为输入,训练基于MELSTM的SOH估计模型。其次,使用SOA算法优化MELSTM和VAE的超参数,提高SOH估计的精度

和鲁棒性。在训练完成后,使用测试数据对所获得的最优模型进行SOH的在线估计。

4 试验结果与分析

4.1 评估标准

如前所述,锂离子电池的健康状态估计被视为时间序列回归任务。因此,本研究使用了一些常见的评估指标来衡量SOH估计的性能,包括决定系数 R^2 、均方根误差(Root Mean Square Error, RMSE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)。这些评估指标的计算过程如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{S}_i - S_i)^2}{\sum_{i=1}^n (S_i - \bar{S}_i)^2} \quad (19)$$

$$M = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{S}_i - S_i)^2} \quad (20)$$

$$A = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{S}_i - S_i}{S_i} \right| \quad (21)$$

式中: M 为均方根误差RMSE, A 为平均绝对百分比误差MAPE, \hat{S}_i 为SOH的预测结果, S_i 为SOH的真实结果, \bar{S}_i 为SOH的平均结果, n 为样本数。

R^2 的值在0至1的范围之内,值越大,模型的拟合效果越好。RMSE和MAPE值越小,表明该方法的估计性能越好。

4.2 数据集试验

利用CALCE的4组数据(CS2_35、CS2_36、CS2_37、CS2_38)和NASA的4组数据(B0005、B0006、B0007、B0018)来验证所提出方法的有效性。其中,CS2_37和B0005分别作为CALCE和NASA的验证集,其余3组电池数据作为训练集。

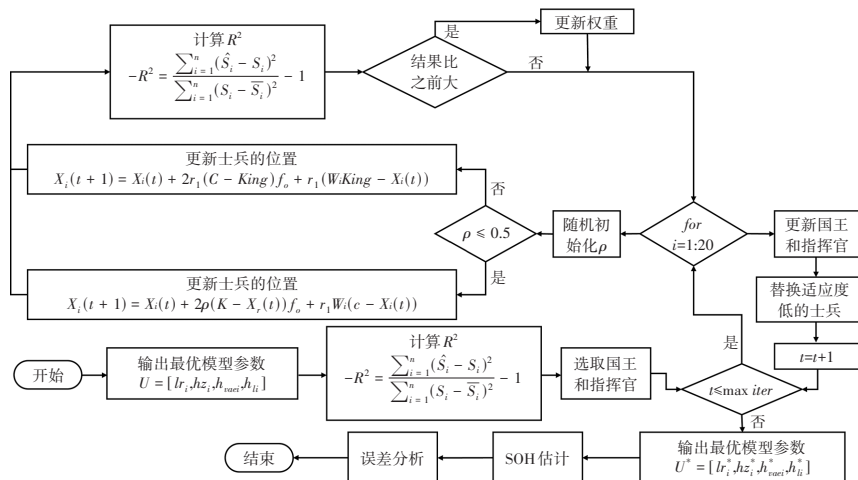


图5 改进的战争策略优化的优化过程

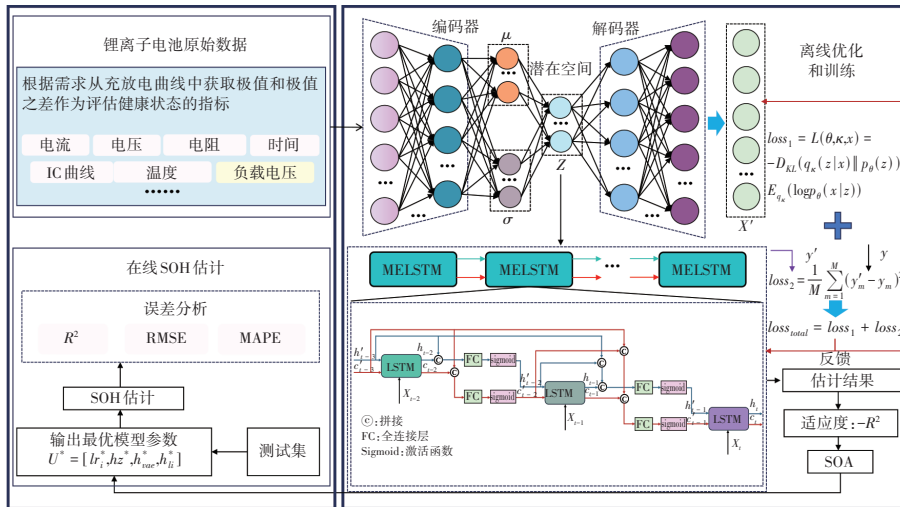


图6 SOA-MELSTM算法流程

为了从模型角度验证所提出方法的有效性和优越性,分别引入了LSTM和SOA进行SOH估计和优化方面的比较。为确保试验的公平性,LSTM仅代替MELSTM使用。试验结果如图7和表1所示。

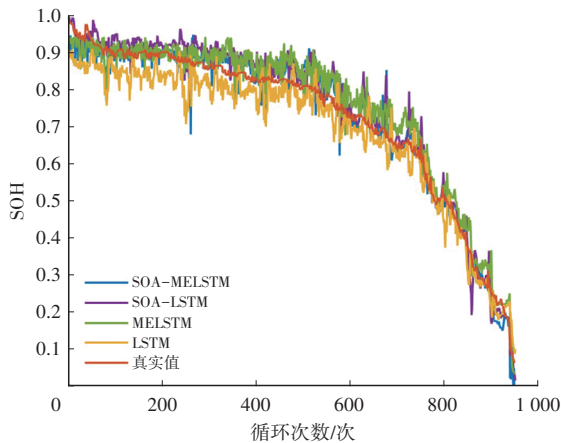


图7 基于CALCE数据集的消融试验结果

表1 基于CALCE数据集的不同模块对比结果

算法	R^2	RMSE	MAPE
SOA-MELSTM	0.973 0	0.038 3	0.049 4
SOA-LSTM	0.962 8	0.044 9	0.053 9
MELSTM	0.954 6	0.049 6	0.064 0
LSTM	0.940 7	0.056 7	0.068 4

图7比较了4种不同的模型SOA-MELSTM、SOA-LSTM、MELSTM和LSTM在SOH估计中的表现。可以观察到,SOA-MELSTM的估计结果最接近真实值,表现最佳。

试验结果表明,相比于LSTM,未使用优化算法的MELSTM R^2 指标提高了1.5%,RMSE降低了14.3%,这表明将历史信息引入当前时刻可以有效缓解LSTM在SOH预测任务中的快速遗忘问题。值得注意的是,采用SOA优化算法后,SOH预测性能得到了显著提升。

SOA-MELSTM相较于MELSTM,其 R^2 指标提高了1.9%,RMSE降低了29.5%,这表明在模型中同时考虑历史退化信息和自身参数优化的必要性。这也进一步证明了本文所提出的SOA-MELSTM算法在锂电池SOH预测任务中的应用潜力。

同时,为了进一步验证SOA-MELSTM算法在多工况条件下的泛化性能,我们在NASA数据集上开展了同样的消融试验验证。试验结果如图8和表2所示。

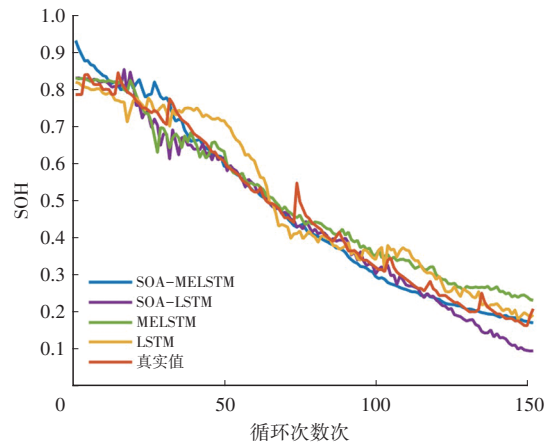


图8 基于NASA数据集的消融试验结果

表2 基于NASA数据集的不同模块对比结果

算法	R^2	RMSE	MAPE
SOA-MELSTM	0.975 5	0.037 5	0.054 2
SOA-LSTM	0.966 5	0.043 8	0.088 5
MELSTM	0.963 1	0.046 0	0.109 8
LSTM	0.949 2	0.054 0	0.098 1

试验结果表明,本文算法在NASA数据集上同样展现出较为不错的预测性能,其效果与CALCE数据集相当,SOA-MELSTM在 R^2 、RMSE和MAPE三个评价指标上均优于SOA-LSTM、MELSTM和LSTM。

为了进一步验证本文算法的泛化性和优越性,我们

基于CALCE和NASA两个数据集分别进行本文算法与基于鲸鱼优化算法的双向长短期记忆网络(Bi-Directional Long Short-Term Memory assisted by Whale Optimization Algorithm, WOA-BiLSTM)、基于沙猫种群优化算法的自适应提升树(Adaptive Boosting Trees assisted by Sand Cat Swarm Optimization, SCSO-Adaboost)和CNN等数据驱动算法的对比试验。试验结果如表3和表4所示。

表3 基于CALCE数据集的对比试验结果

算法	R^2	RMSE	MAPE
SOA-MELSTM	0.973 0	0.038 3	0.049 4
WOA-BiLSTM	0.971 7	0.039 1	0.058 4
SCSO-Adaboost	0.970 2	0.047 5	0.065 7
CNN	0.968 5	0.048 8	0.059 7

表4 基于NASA数据集的对比试验结果

算法	R^2	RMSE	MAPE
SOA-MELSTM	0.975 5	0.037 5	0.054 2
WOA-BiLSTM	0.974 3	0.038 4	0.077 0
SCSO-Adaboost	0.970 7	0.307 5	0.015 7
CNN	0.971 8	0.038 8	0.079 9

试验结果表明,在CALCE数据集上,SOA-MELSTM在 R^2 、RMSE和MAPE3个评价指标上均优于WOA-BiLSTM、SCSO-Adaboost和CNN,展现出最优的综合性能。值得注意的是,在NASA数据集中,SCSO-Adaboost在MAPE指标上表现最佳,这可能是因为Adaboost算法是一个专注于最小化预测偏差的模型,由此可以将减少模型偏差作为后续改进优化模型性能的一个方向。

在实际应用中,由于电池数据获取成本高、周期长,模型在小样本条件下的泛化能力是决定其工程实用性的关键因素之一。故此,我们基于NASA数据集分别进行了2组小样本试验。试验结果如图9和表5所示。




图9 基于NASA数据集的小样本SOH预测结果

表5 基于NASA数据集的小样本试验结果

训练样本量	R^2	RMSE	MAPE
单电池数据训练	0.962 9	0.046 1	0.074 1
双电池数据训练	0.971 4	0.040 5	0.077 0
三电池数据训练	0.975 5	0.037 5	0.054 2

试验结果表明,与3块电池训练相比,在训练样本量减少66.7%(1块电池)和33.3%(2块电池)的情况下,SOA-MELSTM算法仍能保持较高预测精度。

5 结束语

本文提出了一种新型的改进战争优化算法结合改进的长短期记忆神经网络的方法,用于锂离子电池的健康状态估计。为了准确表示锂离子电池的退化信息,本研究采用了变分自编码器来去除冗余退化信息,并实现了从高维到低维的退化信息编码,以便于在SOH估计模型中更有效地利用这些信息。为了解决传统长短期记忆网络在SOH估计任务中的退化信息遗忘问题,本文提出一种新型的记忆增强型长短期记忆网络,通过综合考虑历史时刻的退化信息,减缓LSTM模型的遗忘速度。此外,本研究基于策略优化算法提出新的适应性函数,旨在提高算法的全局搜索能力,从而构建锂离子电池退化信息的自适应表示,确保SOH的准确估计。通过在CALCE和NASA公共数据集上的试验验证,所提出的方法在 R^2 、RMSE和MAPE等估计指标上展现出较好的预测结果。本文提出的方法可以准确估算电池的SOH,适用于电池管理系统中的电池健康状态监测。

参考文献

- [1] 张夏韦,梁军,王要强,等.电动汽车充电负荷时空分布预测研究综述[J].电力建设,2023,44(12):161-173.
ZHANG X W, LIANG J, WANG Y Q, et al. Research Review on the Spatiotemporal Distribution Prediction of Electric Vehicle Charging Load[J]. Electric Power Construction, 2023, 44(12): 161-173.
- [2] 杨斌,樊立萍,高迎慧,等.超高功率密度锂离子电池放电性能及容量预估研究[J].太阳能学报,2023,44(11):419-425.
YANG B, FAN L P, GAO Y H, et al. Research on the Discharge Performance and Capacity Estimation of Ultra-High Power Density Lithium-Ion Batteries[J]. Journal of Solar Energy, 2023, 44(11): 419-425.
- [3] 刘鹏,李云伍,梁新成.基于遗忘递推最小二乘与自适应无迹卡尔曼滤波的锂电池SOC估计[J].汽车技术,2022(2):21-27.
LIU P, LI Y W, LIANG X C. Lithium Battery SOC Estimation Based on Forgetting Recursive Least Squares and

- Adaptive Unscented Kalman Filter[J]. *Automobile Technology*, 2022(2): 21–27.
- [4] 张頔, 马彦, 柏庆文. 基于自适应卡尔曼滤波的锂离子电池SOC估计[J]. *汽车技术*, 2011(8): 42–45+50.
ZHANG D, MA Y, BO Q W. SOC Estimation of Lithium-Ion Batteries Based on Adaptive Kalman Filtering[J]. *Automobile Technology*, 2011(8): 42–45+50.
- [7] 徐乐, 邓忠伟, 谢翌, 等. 锂离子电池高精度机理建模、参数辨识与寿命预测研究进展[J]. *机械工程学报*, 2022, 58(22): 19–36.
XU L, DENG Z W, XIE Y, et al. Research Progress on High-Precision Modeling, Parameter Identification, And Life Prediction of Lithium-Ion Batteries[J]. *Journal of Mechanical Engineering*, 2022, 58(22): 19–36.
- [6] DENG Z, XU L, LIU H, et al. Prognostics of Battery Capacity based on Charging Data and Data-Driven Methods for On-Road Vehicles[J]. *Applied Energy*, 2023, 39.
- [7] 赵轩, 李美莹, 余强, 等. 电动汽车动力锂电池状态估计综述[J]. *中国公路学报*, 2023, 36(6): 254–283.
ZHAO X, LI M Y, YU Q, et al. A Review of State Estimation for Power Lithium Batteries in Electric Vehicles[J]. *China Journal of Highway and Transport*, 2023, 36(6): 254–283.
- [8] 张青松, 赵启臣. 过充循环对锂离子电池老化及安全性影响[J]. *高电压技术*, 2020, 46(10): 3390–3397.
ZHANG Q S, ZHAO Q C. Effects of Overcharge Cycling on Aging and Safety of Lithium-Ion Batteries[J]. *High Voltage Engineering*, 2020, 46(10): 3390–3397.
- [9] VIGNESH S, CHE H S, SELVARAJ J, et al. State of Health (SOH) Estimation Methods for Second Life Lithium-Ion Battery—Review and Challenges[J]. *Applied Energy*, 2024, 369.
- [10] SUI X, HE S, VILSEN 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(3).
- [11] CHE Y, HU X, LIN X, et al. Health Prognostics for Lithium-Ion Batteries: Mechanisms, Methods, and Prospects[J]. *Energy & Environmental Science*, 2023, 16(2): 338–371.
- [12] WANG Y H, HUANG H H, WANG H X, et al. A fastest Estimation Method for State-of-Health of Retired Batteries Based on Health Features[J]. *Journal of Energy Storage*, 2023, 72.
- [13] LAI X, WENG J, HUANG Y, et al. A Joint State-of-Health and State-of-Energy Estimation Method for Lithium-Ion Batteries through Combining the Forgetting Factor Recursive Least Squares and Unscented Kalman Filter[J]. *Measurement*, 2022, 205.
- [14] MA G, XU S, YANG T, et al. A Transfer Learning-based Method for Personalized State of Health Estimation of Lithium-Ion Batteries[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 35: 759–769.
- [15] MA Y, SHAN C, GAO J, et al. A Novel Method for State of Health Estimation of Lithium-Ion Batteries Based on Improved LSTM and Health Indicators Extraction[J]. *Energy*, 2022, 251.
- [16] DAI H, ZHAO G, LIN M, et al. A Novel Estimation Method for the State of Health of Lithium-Ion Battery Using Prior Knowledge-Based Neural Network And Markov Chain[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(10): 7706–7716.
- [17] TIAN J, XIONG R, YU Q. Fractional-Model-Based Incremental Capacity Analysis for Degradation State Recognition of Lithium-Ion Batteries[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(2): 1576–1584.

(责任编辑 王 一)

修改稿收到日期为2025年3月28日。