

基于健康因子提取和 IDBO-BiLSTM 模型的锂电池 SOH 预测

徐云涛, 张 梅, 司梦婷

安徽理工大学 电气与信息工程学院, 安徽 淮南 232001

摘 要:目的 锂离子动力电池的健康状态(SOH)估计是当前研究领域的重要课题之一。对于确保电动汽车的正常运行和维护锂电池的寿命,精确的 SOH 估计至关重要。针对锂电池 SOH 预测的研究中,研究者们面临的健康特征选取困难、预测精度不高等挑战,拟构建一种基于健康因子提取与 IDBO-BiLSTM 模型的锂电池 SOH 预测模型。方法 首先从 NASA 数据中提取健康因子,运用 PCA 算法对特征进行降维融合;接着用 CEEMDAN 算法将融合特征分解成多个模态分量,并筛选出有效模态;随后利用改进蜣螂优化算法(IDBO)对 BiLSTM 模型参数寻优,得到最优 BiLSTM 模型;最后将提取的有效特征作为该模型的输入进行 SOH 预测,并且为了表现该方法的适用性,利用 NASA 数据集中三组电池进行对比实验。结果 基于 IDBO-BiLSTM 的预测模型在估计 SOH 方面表现出色,其预测的均方误差值(MSE)均在 $4e-4$ 以下,拟合度(R^2)在 0.98 以上。结论 此方法有效验证了其在提高锂电池健康状态预测精度方面的优越性和可行性。

关键词:锂电池;SOH 预测;BiLSTM 模型;IDBO 算法;CEEMDAN 分解

中图分类号:TM912;TP18 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2026.0004.017

Lithium Battery SOH Prediction Based on Health Factor Extraction and the IDBO-BiLSTM Model

XU Yuntao, ZHANG Mei, SI Mengting

School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, Anhui, China

Abstract: Objective The estimation of the state of health (SOH) of lithium-ion power batteries is an important research topic in the current field. Accurate SOH estimation is crucial for ensuring the normal operation of electric vehicles and maintaining the lifespan of lithium batteries. To address the challenges in lithium battery SOH prediction, such as difficulty in selecting health features and low prediction accuracy, a lithium battery SOH prediction model based on health factor extraction and the IDBO-BiLSTM model is proposed. **Methods** First, health factors were extracted from NASA data, and principal component analysis (PCA) was applied to reduce dimensionality and fuse features. Next, the fused features were decomposed into multiple modal components using the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN), from which the effective modes were selected. Subsequently, an improved dung beetle optimizer (IDBO) was used to optimize the parameters of the BiLSTM model to obtain the optimal BiLSTM model. Finally, the extracted effective features were fed into the optimal BiLSTM model for SOH prediction. To demonstrate the applicability of the method, comparative experiments were conducted using three battery datasets from NASA. **Results** The results show that the IDBO-BiLSTM-based prediction model performs well in SOH estimation, achieving a mean squared error (MSE) below $4e-4$ and a coefficient of determination (R^2) above 0.98 in all test cases.

收稿日期:2024-06-14 **修回日期:**2024-09-18 **文章编号:**1672-058X(2026)04-0126-09

基金项目:国家自然科学基金资助项目(52374154)。

作者简介:徐云涛(1999—),男,安徽亳州人,从事锂电池健康预测研究。

通信作者:张梅(1979—),女,安徽宿州人,副教授,从事智能检测与电气设备故障诊断研究。Email:1785927839@qq.com。

引用格式:徐云涛,张梅,司梦婷.基于健康因子提取和 IDBO-BiLSTM 模型的锂电池 SOH 预测[J].重庆工商大学学报(自然科学版),2026,43(4):126-134.

Xu Yuntao, Zhang Mei, Si Mengting. Lithium battery SOH prediction based on health factor extraction and the IDBO-BiLSTM model[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(4): 126-134.

Conclusion The proposed model demonstrates superior performance and feasibility in improving the accuracy of lithium battery SOH prediction.

Keywords: lithium battery; SOH prediction; BiLSTM model; IDBO algorithm; CEEMDAN decomposition

随着绿色、高效能和低碳增长理念的普及,电动汽车已经开始进入公众视野,因此锂离子电池成为最常用的储能设备之一。另外,锂离子电池作为电动汽车能量转换、存储和管理过程中的重要组成部分,其与铅酸、镍铬、镍氢等常用电池相比,具有比能量高、功率密度高、循环寿命长等优势^[1-3]。然而,在日常生活的使用中,随着电池不断地充放电循环,受到内部化学反应或外界因素的影响,电池的寿命将逐步缩短,直至失效^[4]。因此,及时预测锂电池健康状态(State of Health, SOH)有利于规划和管理电池,从而降低事故发生概率,确保设备安全可靠地运行^[5-6],对于锂离子电池使用领域具有重要意义。

目前,国内外对锂离子电池健康状态进行估计的方法通常可归纳为模型驱动型和数据驱动型两大类。由于外部环境条件的不可预测性,建立精确的机理模型存在较大难度,导致基于模型的估计方法难以实现^[7-9]。因此,基于数据驱动的电池 SOH 预测备受关注。数据驱动的方法无需依赖电池退化模型,仅需分析电池的退化数据,并从中提取适当的健康特征进行模型训练。通过这一过程,能够获得高度准确的 SOH 预测。其中,常见的算法有 SVR 模型、LSTM 模型、BiLSTM 模型等^[10-12]。在 Zhang 等^[13]的研究中,通过从锂离子电池的相关充电数据中提取四个健康退化特征,并在 SVR 模型中增加了一种误差补偿策略,用于增加预测模型的稳定性。Qu 等^[14]提出了一种新方法,该方法融合了长短期记忆(LSTM)网络、粒子群优化算法以及注意力机制,以提升锂离子电池健康状态(SOH)的预测精度,但由于模型只能单次预测导致预测精度有所下降。文献[15]提出基于 BiLSTM 模型在电池不同内部状态下进行 SOH 预测。方斯顿等^[16]采用鲸鱼优化算法优化 BiLSTM 模型,并通过提取电压、电流、温度的间接特征作为模型的输入进行 SOH 预测,用来提升 SOH 估计精度。但在常见的方法中,存在着健康特征之间信息复杂易产生数据冗余以及算法优化模型超参数时易产生局部最优解等问题。

基于此,本文提出了一种基于健康因子提取和 IDBO-BiLSTM 模型的锂电池 SOH 预测方法:首先使用

PCA 算法对锂电池间接特征进行降维融合,并对融合后的健康因子通过自适应白噪声完备经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)进行降噪处理,筛选出新的健康序列;然后,使用改进蜣螂算法(Improved Dung Beetle Algorithm, IDBO)对双向长短期记忆网络(Bidirectional Long Short-term Memory, BiLSTM)进行参数优化,构建 IDBO-BiLSTM 预测模型;最后将新的健康序列输入 IDBO-BiLSTM 模型,实现锂电池 SOH 预测。

1 锂电池 SOH 估计方法

1.1 算法原理

针对锂电池 SOH 预测,本文提出了一种基于健康因子提取和 IDBO-BiLSTM 模型的算法,其算法原理如图 1 所示。




图 1 锂电池 SOH 估计算法原理图

Fig. 1 Principle diagram of the lithium battery SOH estimation algorithm

由图 1 可知,本文所提出的 SOH 预测算法由特征提取、参数寻优和 SOH 预测三部分组成,具体如下:

(1) 特征提取。首先从数据集中提取 8 个能够表征电池退化特征的间接数据,并通过主成分分析算法对间接数据进行特征融合,生成一个包含更多健康特征的融合健康因子;接着利用 CEEMDAN 将融合健康因子分解为多个模态分量 IMFs 与一个残差信号 $R(t)$ 。考虑分解后的模态分量较多,这里通过计算融合健康

因子与分解所得模态分量间的相关系数,选取相关系数大于关联阈值的模态分量,将其与残差组合成新的健康序列。

(2) 参数寻优。利用 Chebyshev 初始化映射、改进滚球蜣螂位置和引入 Levy 飞行策略来改进蜣螂优化算法,并利用其对 BiLSTM 模型进行参数寻优,得到最优 BiLSTM 模型。

(3) SOH 预测。使用特征提取出的健康序列作为特征输入,电池容量退化数据作为特征输出,将数据按 1:1 划分为训练集和测试集,对 IDBO-BiLSTM 预测模型进行训练和测试,并对模型进行性能评价,以获得精确的 SOH 预测模型。

1.2 CEEMDAN 分解

CEEMDAN 是一种非线性和非平稳信号分解方法,能够有效抑制容量回升的现象,它是对传统分解方法的改进^[17]。

为了对特征信号进行去噪处理,采用 CEEMDAN 方法对融合后的健康因子进行分解。

(1) 在融合的健康因子序列中加入高斯白噪声,以增强信号的随机性。

$$x_i(t) = x(t) + \theta Z_i(t) \quad (i=1, 2, \dots, n) \quad (1)$$

其中, $x_i(t)$ 为加入第 i 次白噪声后的序列, θ 表示信噪比, $Z_i(t)$ 为服从正态分布的高斯白噪声。

(2) 使用 EMD 对时间序列进行分解,并将结果平均化得到第一个 IMF 分量。

$$\text{IMF}_1(t) = \frac{1}{n} \sum_{i=1}^n \text{IMF}_{1i}(t) \quad (2)$$

其中, n 为样本数, $\text{IMF}_1(t)$ 为模态分量个数。

(3) 计算残差 $R_1(t)$

$$R_1(t) = x(t) - \text{IMF}_1(t) \quad (3)$$

其中, $R_1(t)$ 为第一个残差。

(4) 紧接着为了得到第二个 IMF 分量和残差信号,对剩余信号进行处理:减去 $\text{IMF}_1(t)$,加入正负高斯白噪声并重新分解。

$$R_2(t) = R_1(t) - \text{IMF}_1(t) \quad (4)$$

$$\text{IMF}_2(t) = \frac{1}{n} P_1 \{ R_1(t) + \theta P_1 [Z_i(t)] \} \quad (5)$$

其中, p_k 为序列 EMD 分解的 k 阶分量。

(5) 重复上一步,直到残差信号无法再分解为止,从而完成 CEEMDAN 分解。此时得到 k 个分量和一个残差信号。

$$R(t) = x(t) - \sum_{k=1}^k \text{IMF}_k \quad (6)$$

(6) 考虑分解后的模态分量较多,可能会导致预测精度较低,通过计算 HFS 与分解所得数组间的相关系数,设置关联阈值,用于选取相关系数大于关联阈值的模态分量,将具有强相关性的 k 组模态分量与残差组合成新的健康预测数据组,进行预测。

1.3 BiLSTM 模型

BiLSTM 模型是由双向的 LSTM 组成,可以同时正向和逆向学习,从而更好地抓住数据内部的时序规律和抽象特征。因此,本文使用 BiLSTM 模型进行 SOH 预测,可以深入挖掘锂电池健康变化的时序特征和趋势,提高对锂电池健康序列的时序预测能力。BiLSTM 模型主要由输入层、前进层、隐藏层、反向层、输出层五部分构成,其网络结构如图 2 所示。




图 2 BiLSTM 模型网络结构图

Fig. 2 Network structure of the BiLSTM model

图 2 中,前进隐藏层输出 $h(t)$ 为

$$h(t) = \delta(w_1 x(t) + w_2 h(t-1) + b h(t)) \quad (7)$$

其中, $x(t)$ 为输入层, w 为权重系数。

反向隐藏层输出 $j(t)$ 为

$$j(t) = \delta(w_3 x(t) + w_4 j(t-1) + b j(t)) \quad (8)$$

输出层输出 $Y(t)$ 为

$$Y(t) = \delta(w_5 h(t) + w_6 j(t-1) + b Y(t)) \quad (9)$$

1.4 改进蜣螂优化算法

蜣螂优化算法 (DBO) 是一种由 Xue 等^[18] 于 2022 年提出,受蜣螂的滚球、跳舞、偷窃、觅食和繁殖行为启发,可用于优化 BiLSTM 模型的参数,以提高预测准确率。由于原始 DBO 算法存在的收敛速度慢、全局搜索和局部开发不平衡等问题,本文提出了一种改进蜣螂算法,具体改进方法如下:

(1) Chebyshev 初始化映射。在算法中,初始种群的质量对算法性能至关重要。为了改善初始种群质

量,本文使用了 Chebyshev 混沌映射来初始化个体,使其种群分布更均匀。其公式如下:

$$x_{i+1} = \cos(k \arccos x_i) \tag{10}$$

其中, i 为种群个体, x_i 为第 i 个 Chebyshev 映射个体, $x_i \in [-1,1], k$ 为阶数。

(2) 改进滚球蛱螂位置。根据算法中蛱螂利用太阳在滚动的粪球中进行导航的特性,本文通过应用黄金正弦算法对滚动的粪球蛱螂的位置进行优化,从而扩展搜寻解空间的范围,提高算法的全局寻优能力。其公式如下:

$$x_i(t+1) = x_i(t) \mid \sin(r_1) \mid + r_2 \sin(r_1) M \tag{11}$$

$$M = \mid x_1 x_i^b(t) - x_2 x_i(t) \mid \tag{12}$$

$$x_1 = -\pi + (1-\theta) 2\pi \tag{13}$$

$$x_2 = -\pi + \theta 2\pi \tag{14}$$

其中, t 是当前迭代次数, $x_i(t)$ 为第 i 只滚球蛱螂在第 t 次迭代时的位置, $x_i^b(t)$ 是第 t 代个体 i 最优位置, r_1, r_2 分别为 $[0, 2\pi], [0, \pi]$ 的随机数, θ 为黄金分割系数, x_1, x_2 为由 θ 得到的系数。

(3) 引入 Levy 飞行策略。Levy 飞行是服从莱维分布的随机搜索方法,其能够增强算法的搜索能力,可以帮助算法在优化过程中跳出局部最优解。Levy 飞行策略的公式表示为

$$L_{Levy(\alpha)} = 0.01 \times \frac{r_1 \times \lambda}{\mid r_2 \mid^{(1/\alpha)}} \tag{15}$$

式(15)中, r_1, r_2 为 $[0, 1]$ 范围内的正态分布随机数, α 为 1.5。 λ 的计算公式如下:

$$\lambda = \left(\left(\frac{\Gamma(1+\alpha) \times \sin(\pi\alpha/2)}{\Gamma((1+\alpha)/2) \times \alpha \times 2^{(\alpha-1)/2}} \right) \right)^{(1/\alpha)} \tag{16}$$

式(16)中, $\Gamma(x) = (x-1)!$ 。

通过对滚转蛱螂的定位信息进行 Levy 飞行,对其进行定位更新,并对其进行目标函数的求解,实现脱离局部最优、增强寻优能力的目标。其原理如下:

$$X_{x_i(t+1)} = x_i(t) + \beta \oplus Levy(\alpha) \tag{16}$$

其中, β 是 1 的步长控制因子; $\oplus$ 为矢量运算, $Levy(\alpha)$ 是 Levy 分布的公式。

2 数据获取与健康因子分析

2.1 数据获取

本文的数据来自 NASA 电池数据集,选取额定容量 2 Ah 的 B0005、B0006、B0007 电池数据用于方法验证。电池基本信息及运行参数如表 1 所示。

表 1 NASA 电池基本信息及运行参数

Table 1 Basic information and operating parameters of NASA batteries

电池编号	温度/℃	充电电流/A	放电电流/A	循环次数
B0005	24	1.5	2	168
B0006	24	1.5	2	168
B0007	24	1.5	2	168

SOH 是电池管理系统中的一个重要参数,它表示电池储存和释放容量的能力,其定义如下:

$$S_{SOH} = \frac{Q_{max}}{Q_{new}} \tag{17}$$

式(18)中, Q_{max} 为锂电池最大可用容量, Q_{new} 为锂电池标称容量。

所选数据集包含了电池的电压、电流、阻抗值和温度。充电过程采用恒流恒压方式,放电过程以 2 A 的恒定电流来放电。并且在实验过程中,锂电池的最大可用容量会随着锂电池的不断老化而逐渐降低。B0005、B0006、B0007 三组电池在上述工况下的电池容量衰减曲线如图 3 所示。




图 3 电池容量衰减曲线


Fig. 3 Battery capacity attenuation curves

由图 3 可知,通过反复进行充放电循环实验,电池的老化过程并不是简单的持续递减。特别是在电池放电后,电池内部的容量会出现一定程度的回升现象。这种现象表明电池的性能随着充放电循环而发生复杂的变化,不仅仅是简单的衰减过程,还含有容量回升现象。该现象将会影响锂电池 SOH 预测的准确度,因此需要对其数据进行必要的处理。


2.2 健康因子分析

锂电池在长时间的充放电循环中,会发生大量的电化学反应,从而使电池的性能逐步退化。复杂的电化学反应机理使电池健康状态的直接性能参数难以获得^[19]。因此,本文选择从电池充放电过程的电流、电


压、温度曲线中提取间接特征做锂电池 SOH 预测。以 B0005 号电池为例,不同循环下的充放电电压、电流、温度曲线如图 4 所示。




(a) 充电电压曲线




(b) 放电电压曲线




(c) 充电电流曲线



(d) 放电电流曲线



(e) 充电温度变化曲线



(f) 放电温度变化曲线

图 4 不同充放电过程中 B0005 号电池的电压、电流、温度变化曲线

Fig. 4 Voltage, current, and temperature variation curves of B0005 battery during charging and discharging processes

由图 4 可知,本文从以上数据中提取等压升时间、充电初始电压、恒流充电时间、等温升放电时间、平均放电电压与放电电压最低点时刻、放电平均温度、恒流阶段的温度变化率等 8 个间接特征作为锂电池 SOH 预测的健康因子^[20-21]。

3 算法验证与分析

为验证所提出方法的可行性,本文进行了健康因子提取与 SOH 预测实验,并对所得模型进行了性能评价。

3.1 健康因子提取结果与分析

针对从电池的充放电参数中直接提取的等压升时间、充电初始电压、恒流充电时间等 8 个间接特征,如果直接用于 SOH 预测,会造成特征冗余、预测精度不高等情况。因此,本文首先利用 PCA 算法对其进行降维融合处理,然后利用 CEEMDAN 进行健康因子筛选,从而实现特征信号的降维与去噪。

3.1.1 间接特征相关性分析

为了验证上述 8 个间接特征与电池容量衰减相关性,采用 Pearson 相关系数来计算各间接特征与容量之

间的相关性,其计算公式如下:

$$P_{pearson} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)} \sqrt{E(Y^2) - E^2(Y)}} \quad (18)$$

式(19)中,X,Y 分别表示间接特征数据与电池容量数据,其中绝对值越大说明相关性越强,当绝对值为 1 时,表明完全相关。

以 B0005 电池为例,图 5 为各个间接特征与容量之间的 pearson 计算结果。




图 5 B0005 电池健康因子相关性

图 5 中的特征 1-特征 8 分别为等压升时间、充电初始电压、恒流充电时间、等温升放电时间、平均放电电压与放电电压最低点时刻、放电平均温度、恒流阶段的温度变化率等 8 个间接特征。从图 5 中可以看出提取的间接特征之间存在高度相关性,导致信息重叠和冗余。因此,采用 PCA 算法将数据降维融合,得到一个涵盖更多信息的融合健康因子,并计算主成分的特征值、方差贡献率以及累计贡献率对降维维度选择进行分析。

3.1.2 基于 PCA 的健康因子降维结果与分析

PCA 降维技术是目前常用的数据预处理以及数据提取的方法,能够有效解决参数特征重叠以及特征信息不足的问题。主成分分析法主要原理是将所提取到的间接健康序列进行标准化处理得到矩阵 X,并计算矩阵 X 的相关系数矩阵 C 式:

$$C = \frac{1}{n} X^T X \quad (19)$$

然后,计算其特征值与特征向量,从大到小排列;并计算每个特征值对主成分的贡献率以及累计贡献率,选取累计贡献率大于 90%的主成分,确定主成分个数和相应主成分,作为锂电池健康预测的新的健康因子。经 PCA 降维后,其结果如表 2 所示。

表 2 PCA 分析结果表

Table 2 PCA analysis results

主成分	特征值	方差贡献率/%	累计贡献率/%
1	10.532 9	99.30	99.30
2	6.842 1	0.55	99.85
3	0.038 2	0.12	99.91
4	0.018 5	0.08	99.96
5	0.001 9	0.03	99.99
6	0.000 7	0.01	100
7	0.000 3	0.00	100
8	0.000 1	0.00	100

由表 2 可知,第一个主成分的贡献率就达 95% 以上,说明融合成一维健康因子时就已经包含了间接特征的大多数信息,故选择降至一维。融合健康因子与电池容量退化曲线如图 6 所示。




图 6 融合健康因子与电池容量退化曲线

Fig. 6 Fused health factor and battery capacity degradation curves

通过对 PCA 降维后的融合健康因子进行 Pearson 相关系数计算得知,其相关系数为 0.998 75,相较于图 5 中 8 个健康特征的相关性,其与电池容量退化数据具有更强的相关性,达到了降低信息冗余的目的。另外,从图 6 中可知,融合健康因子与电池退化曲线基本一致,可以作为预测输入,但是容量回升仍存在,为此将使用 CEEMDAN 方法对融合的健康因子进行分解和去噪处理,建立新的健康序列,从而提高预测精度。

3.1.3 基于 CEEMDAN 的去噪处理

针对 PCA 降维后的特征,利用 CEEMDAN 进行模态分解,得到 5 个模态分量以及残差,其结果如图 7 所示。由图 7 可知,模态分量处于上下波动状态,残差为一个严格递减的曲线,有效抑制了容量回升现象。




图 7 B0005 融合健康因子 CEEMDAN 分解图

Fig. 7 CEEMDAN decomposition of the fused health factor for B0005

利用 Pearson 算法计算融合健康因子与模态分量以及残差之间的相关系数,计算结果如表 3 所示。

表 3 模态分量与残差的相关系数

Table 3 Correlation coefficients between modal components and residuals

模态分量	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅	$R(t)$
相关系数	0.017	0.038	0.030	0.051	0.005	0.997 08

计算关联阈值 Q_{PT} , 其公式为

$$Q_{PT} = \max(\text{IMF}_k) / N \quad (20)$$

经计算, PT 为 0.026。由表 3 可知, IMF_2 、 IMF_3 、 IMF_4 均大于关联阈值, 因此将其与残差组合成新的特征样本集, 作为 SOH 预测模型的输入, 进一步提高了模型预测精度。

经 CEEMDAN 分解去噪后得到的特征, 与未分解前数据相比如图 8 所示。从图 8 可知, 经 CEEMDAN 分解后的数据曲线与未分解前的数据曲线相比, 其容量回升现象大幅降低, 有效抑制了容量回升现象对锂电池健康预测精度的影响。





图 8 CEEMDAN 分解前后对比图

Fig. 8 Comparison before and after CEEMDAN decomposition


3.2 锂电池 SOH 估计结果与分析

将得到的上述特征集按 1:1 的比例分为训练集和测试集。将训练集作为输入进行训练, 利用 IDBO 算法进行 BiLSTM 模型参数寻优。再利用测试集对所得到的模型进行模型评估。


这里对 B0005、B0006、B0007 号电池的循环数据进行处理, 删除无效数据后, 利用前 83 个循环数据训练模型, 以第 84 个循环作为预测起点, 预测后续 83 个循环的 SOH。分别采用 PCA-BiLSTM、PCA-CEEMDAN-BiLSTM 以及 PCA-CEEMDAN-DBO-BiLSTM 方法进行对比实验, 其 SOH 预测结果如图 9 所示。



(a) B0005



(b) B0006



(c) B0007

图 9 三组电池的 SOH 估计的预测结果

Fig. 9 SOH prediction results for three battery groups

由图 9 可知,对比上述方法得到的 SOH 预测结果,经 PCA 及 CEEMDAN 分解处理的 SOH 较于没有分解处理的 SOH 预测结果更好,另外,经算法改进后的模型具有更高的 SOH 预测精度。

为了定量分析不同方法的性能。提出了四种误差评估准则,均方根误差 (MSE)、平均绝对误差 (MAE)、均方根误差 (RMSE) 以及拟合优度 (R^2)。不同方法的预测结果如表 4 所示。

表 4 不同方法的误差结果
Table 4 Error results from different methods

电 池	方 法	MSE	MAE	RMSE	R^2
B0005	PCA-CEEMDAN-IDBO-BiLSTM	1.0686e-04	0.007 0	0.009 5	0.983 5
	PCA-CEEMDAN-DBO-BiLSTM	1.8561e-04	0.010 7	0.019 2	0.971 4
	PCA-CEEMDAN-BiLSTM	2.0652e-04	0.012 1	0.023 4	0.968 2
	PCA-BiLSTM	3.8810e-04	0.015 9	0.029 7	0.940 2
B0006	PCA-CEEMDAN-IDBO-BiLSTM	3.5822e-07	0.000 6	0.005 0	0.991 6
	PCA-CEEMDAN-DBO-BiLSTM	4.3835e-04	0.014 3	0.020 9	0.953 2
	PCA-CEEMDAN-BiLSTM	6.2236e-04	0.017 9	0.024 9	0.905 3
	PCA-BiLSTM	9.7615e-04	0.023 0	0.031 2	0.828 2
B0007	PCA-CEEMDAN-IDBO-BiLSTM	6.477e-05	0.004 4	0.008 0	0.997 5
	PCA-CEEMDAN-DBO-BiLSTM	9.8957e-05	0.006 4	0.009 9	0.975 0
	PCA-CEEMDAN-BiLSTM	1.2178e-04	0.007 0	0.011 0	0.969 4
	PCA-BiLSTM	4.3443e-04	0.019 1	0.020 8	0.891 0

由表 4 可知,文中所提方法相较于 PCA-BiLSTM、PCA-CEEMDAN-BiLSTM 以及 PCA-CEEMDAN-DBO-BiLSTM 等方法,具有更小的估计误差。对于 B5 号电池,文中所提的 PCA-CEEMDAN-IDBO-BiLSTM 方法相较于其他方法,MSE 分别降低了 72.5%、52.2%、46.8%,MAE 分别降低了 56%、32.8%、23.9%,RMSE 分别降低了 68.1%、35.4%、21.2%, R^2 也分别有所提高。对于 B0006、B0007 两组电池,本文所提出的方法也有更高的预测精度。

4 结 论

为进一步提升锂电池 SOH 估计精度,本文提出了一种基于健康因子提取和 IDBO-BiLSTM 模型的锂电池 SOH 预测方法,具体创新及结论如下:

- (1) 对比现有数据处理的方法,采用 PCA 算法将电池的健康因子进行降维与融合,可有效减少数据冗余造成的影响;
- (2) 为了有效抑制 SOH 序列回升现象,提升预测精度,将融合后的特征通过 CEEMDAN 分解,并通过相关性分析筛选出有效分量,重构特征数据集;
- (3) 为了进一步提高 SOH 预测的准确性,通过改进 DBO 算法来优化 BiLSTM 模型的超参数,使模型具

有更好的预测效果。
(4) 经上述改进后所得 SOH 预测精度相较于 PCA-BiLSTM、PCA-CEEMDAN-BiLSTM 以及 PCA-CEEMDAN-DBO-BiLSTM,本文所使用的 PCA-CEEMDAN-IDBO-BiLSTM 算法具有更高的预测精度,能更精确地预测锂电池的 SOH。

参考文献(References):

[1] Campi T, Cruciani S, Maradei F, et al. Magnetic field mitigation by multicoil active shielding in electric vehicles equipped with wireless power charging system[J]. IEEE Transactions on Electromagnetic Compatibility, 2020, 62(4): 1398-1405.

[2] 胡晓亚, 郭永芳, 张若可. 锂离子电池健康状态估计方法研究综述[J]. 电源学报, 2022, 20(1): 126-133.
Hu Xiaoya, Guo Yongfang, Zhang Ruoke. Review of State-of-health estimation methods for Lithium-ion battery[J]. Journal of Power Supply, 2022, 20(1): 126-133.

[3] Fan S, Liu J, Wu Q, et al. Optimal coordination of virtual power plant with photovoltaics and electric vehicles: a temporally coupled distributed online algorithm[J]. Applied Energy, 2020, 277: 115583.

[4] Shen S, Sadoughi M, Li M, et al. Deep convolutional neural

- networks with ensemble learning and transfer learning for capacity estimation of lithium-ion batteries[J]. *Applied Energy*, 2020, 260: 114296.
- [5] Duan H, Xia W, Shao J, et al. Remaining useful life prediction of lithium batteries based on optimization of charging health factors and data-driven approach[J]. *Automotive Engineering*, 2024(1): 20–26.
- [6] 杨彦茹, 温杰, 史元浩, 等. 基于 CEEMDAN 和 SVR 的锂离子电池剩余使用寿命预测[J]. *电子测量与仪器学报*, 2020, 34(12): 197–205.
- Yang Yanru, Wen Jie, Shi Yuanhao, et al. Remaining useful life prediction for lithium-ion battery based on CEEMDAN and SVR[J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34(12): 197–205.
- [7] 史永胜, 施梦琢, 丁恩松, 等. 基于 CEEMDAN-LSTM 组合的锂离子电池寿命预测方法[J]. *工程科学学报*, 2021, 43(7): 985–994.
- Shi Yongsheng, Shi Mengzhuo, Ding Ensong, et al. Combined prediction method of lithium-ion battery life based on CEEMDAN-LSTM[J]. *Chinese Journal of Engineering*, 2021, 43(7): 985–994.
- [8] Cheng G, Wang X, He Y. Remaining useful life and state of health prediction for lithium batteries based on empirical mode decomposition and a long and short memory neural network[J]. *Energy*, 2021, 232: 121022.
- [9] Zheng W M, Xu L D, Pan J S, et al. Cluster head selection strategy of WSN based on binary multi-objective adaptive fish migration optimization algorithm[J]. *Applied Soft Computing*, 2023, 148: 110826.
- [10] Pang B, Chen L, Dong Z. Data-driven degradation modeling and SOH prediction of Li-ion batteries[J]. *Energies*, 2022, 15(15): 5580.
- [11] Xing L, Liu X, Luo W, et al. State of health estimation for lithium-ion batteries using IAO-SVR[J]. *World Electric Vehicle Journal*, 2023, 14(5): 122.
- [12] Golla-schindler U, Zeibig D, Prickler L, et al. Characterization of degeneration phenomena in lithium-ion batteries by combined microscopic techniques[J]. *Micron*, 2018, 113: 10–19.
- [13] Zhang J, Wang P, Gong Q, et al. SOH estimation of lithium-ion batteries based on least squares support vector machine error compensation model[J]. *Journal of Power Electronics*, 2021, 21(11): 1712–1723.
- [14] Qu J, Liu F, Ma Y, et al. A neural-network-based method for RUL prediction and SOH monitoring of lithium-ion battery[J]. *IEEE Access*, 2019, 7: 87178–87191.
- [15] 王义, 刘欣, 高德欣. 基于 BiLSTM 神经网络的锂电池 SOH 估计与 RUL 预测[J]. *电子测量技术*, 2021, 44(20): 1–5.
- Wang Yi, Liu Xin, Gao Dexin. The SOH estimation and RUL prediction of lithium battery based on BiLSTM[J]. *Electronic Measurement Technology*, 2021, 44(20): 1–5.
- [16] 方斯顿, 刘龙真, 孔赖强, 等. 基于双向长短期记忆网络含间接健康指标的锂电池 SOH 估计[J]. *电力系统自动化*, 2024, 48(4): 160–168.
- Fang Sidun, Liu Longzhen, Kong Laiqiang, et al. State-of-health estimation for lithium batteries incorporating indirect health indicators based on bidirectional long short-term memory networks[J]. *Automation of Electric Power Systems*, 2024, 48(4): 160–168.
- [17] 牛群峰, 袁强, 王莉, 等. 基于 CEEMDAN-RVM-LSTM 模型的锂电池剩余寿命预测[J]. *电源技术*, 2023, 47(10): 1313–1318.
- Niu Qunfeng, Yuan Qiang, Wang Li, et al. Remaining life prediction of lithium-ion batteries based on CEEMDAN-RVM-LSTM model[J]. *Chinese Journal of Power Sources*, 2023, 47(10): 1313–1318.
- [18] Xue J, Shen B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. *The Journal of Supercomputing*, 2023, 79(7): 7305–7336.
- [19] 马君, 万俊杰. 基于健康特征筛选与 GWO-LSSVM 的锂电池健康状态预测[J]. *电气技术*, 2024, 25(2): 37–44.
- Ma Jun, Wan Junjie. Prediction of state of health for lithium battery based on health feature screening and GWO-LSSVM[J]. *Electrical Engineering*, 2024, 25(2): 37–44.
- [20] Zhang M, Chen W, Yin J, et al. Lithium battery health factor extraction based on improved Douglas-peucker algorithm and SOH prediction based on XGboost[J]. *Energies*, 2022, 15(16): 5981.
- [21] 吴伟丽, 卢双双. 基于 PCA-CEEMDAN 和改进 SVR 的锂电池 RUL 预测[J]. *电源学报*, 2025, 36(6): 267–280.
- Wu Weili, Lu Shuangshuang. Lithium Battery RUL Prediction Based on PCA-CEEMDAN and Improved SVR[J]. *Journal of Power Supply*, 2025, 23(6): 267–280.

责任编辑:陈 芳