

基于海鸥优化算法改进深度极限学习机的 锂电池健康状态预测

靳 灿 张晓燕 孙本川

(国网山东省电力公司嘉祥县供电公司, 山东 济宁 272400)

摘要 针对锂电池健康状态预测准确度较低的问题, 本文提出一种基于海鸥优化算法优化深度极限学习机的健康状态预测方法。首先, 选取电池充放电循环的等压升充电时间和等压降放电时间作为预测健康状态的特征参数, 并采用 Pearson 相关系数定量分析其与电池健康状态的相关性。然后, 建立海鸥优化算法-深度极限学习机模型, 通过学习健康状态和特征参数的样本, 预测后续循环的健康状态值。最后, 利用公开的电池数据进行预测, 并分析预测结果, 与极限学习机、深度极限学习机和其他研究的预测结果进行对比, 引入最大绝对误差和方均根误差作为量化评价指标。结果表明, 海鸥优化算法-深度极限学习机模型相较其他常见模型具有更高的训练测试精度、更短的预测时间, 能够实现锂电池健康状态的准确预测, 最大绝对误差和方均根误差均低于 0.01, 预测准确度高、适用性强。

关键词: 锂电池; 健康状态; 海鸥优化算法; 深度极限学习机

State of health prediction for lithium batteries based on deep extreme learning machine improved by seagull optimization algorithm

JIN Can ZHANG Xiaoyan SUN Benchuan

(State Grid Jiexiang Power Supply Company, Jining, Shandong 272400)

Abstract The current methods for predicting the state of health of lithium batteries often suffer from low accuracy. This paper introduces a method for state of health prediction using a seagull optimization algorithm optimized deep extreme learning machine. Key health feature parameters, such as constant voltage charging and discharging times during battery cycles, are selected and their correlation with the battery state of health is analyzed using Pearson correlation. The proposed model predicts subsequent state of health values by learning from samples. Experiments conducted with battery data compare the proposed method with single extreme learning machine, single deep extreme learning machine, and other literature. Evaluation metrics, including maximum absolute error and root mean square error, demonstrate that the seagull optimization algorithm optimized deep extreme learning machine model achieves higher accuracy and faster prediction times, with errors below 1.1%, indicating superior prediction accuracy and applicability.

Keywords: lithium battery; state of health; seagull optimization algorithm; deep extreme learning machine

0 引言

随着规模化储能系统和电动汽车技术持续投入应用, 锂电池技术成为影响此类工程发展的重要因素^[1]。锂电池长期使用后性能逐渐下降, 因此健康

状态 (state of health, SOH) 成为衡量锂电池性能与确定其使用寿命的重要参考因素^[2], 如何准确预测锂电池 SOH, 对相关行业的在线监测和安全运行^[3-4]具有重要的影响。

近年来, 人工智能算法和深度学习技术快速发

展, 应用于锂电池 SOH 预测中^[5-6], 文献[7]利用麻雀搜索算法 (sparrow search algorithm, SSA) 改进神经网络, 在锂电池分数阶模型中进行 SOH 的相关计算。文献[8]提出一种灰狼优化算法 (grey wolf optimization, GWO) 改进最小二乘支持向量机 (least square support vector machine, LSSVM) 的预测方法, 实现了锂电池 SOH 的高精度预测。文献[9]采用粒子群优化算法 (particle swarm optimization, PSO) 来确定长短期记忆网络 (long short term memory network, LSTM) 内部各层神经元的最佳数量, 以达到电池 SOH 的有效预测。数据驱动方法在进行电池 SOH 预测时, 其精确度与特征参数的选择、算法参数的配置密切相关。如果选取的特征参数与电池 SOH 的相关度不高, 就可能导致预测误差大, 同时不当的算法选择或参数设定可能引发模型泛化能力下降、计算资源过度消耗等问题^[10-12]。因此, 在进行电池 SOH 预测时, 需要重点关注特征参数、算法的选取及后续算法的优化调整等问题^[13]。

本文基于数据驱动的方法, 提出一种利用海鸥优化算法 (seagull optimization algorithm, SOA) 优化深度极限学习机 (deep extreme learning machine, DELM) 的算法模型, 用于锂电池 SOH 的预测。采用 NASA 锂电池数据库进行验证, 并与其他单一算法模型进行量化比较。

1 相关算法

1.1 深度极限学习机

极限学习机 (extreme learning machine, ELM) 是一种专为单隐层前馈神经网络 (single hidden layer feedforward neural networks, SLFNs) 设计的高效学习算法。该算法简化了传统神经网络复杂的调参过程, 显著提升了学习速度, 并保证了良好的泛化性能, 适于处理工程应用中的分类与回归问题^[14]。ELM 算法的训练过程如下:

1) 随机初始化。输入层至隐层的权重 W 和偏置 b 通过随机方式设定。

2) 计算隐层输出。对每个输入样本矩阵 X , 其隐层输出矩阵 H 的计算公式为

$$H = g(WX + b) \quad (1)$$

式中, $g(\cdot)$ 为激活函数。

3) 计算输出层权重。通过最小二乘法求解输出层权重 β 为

$$\beta = H^*Y \quad (2)$$

式中: H^* 为隐层输出矩阵 H 的伪逆矩阵; Y 为目标输出。

4) 预测。对待预测的输入样本矩阵 X_{new} , 计算隐层输出矩阵 H_{new} 为

$$H_{\text{new}} = g(WX_{\text{new}} + b) \quad (3)$$

得到隐层输出后, 预测 X_{new} 后续值, 即预测输出矩阵 Y_{new} 为

$$Y_{\text{new}} = H_{\text{new}}\beta \quad (4)$$

在 ELM 算法中, 设定初始值后, 通过充分迭代可以获得使预测值与实际值之间误差最小的权重和偏差解。

DELM 兼具深度学习的层次化提取能力和 ELM 的高效训练特性。DELM 中每一层的输入权重和偏置均随机初始化, 每一层的输出权重通过最小二乘法解析求解, 避免了传统深度学习中的梯度下降和反向传播过程, 不需要迭代优化, DELM 的训练速度比传统 ELM 模型更快, 预测结果也更加精准^[14]。

DELM 的网络结构由输入层、多个隐层、输出层组成。输入层接收原始输入数据; 多个隐层中每一层都是一个 ELM 结构, 包含随机初始化的权重和偏置, 以及非线性激活函数; 输出层通过最小二乘法计算输出权重, 得到最终的预测结果。DELM 算法的训练过程如下:

1) 逐层训练。从第一层开始, 逐层训练 ELM, 每一层的输入是前一层提取的特征, 输出权重通过最小二乘法计算。

2) 特征传递。每个 ELM 层的输出作为下一层的输入, 逐步提取更高层次的特征, 将多个 ELM 层串联在一起, 并将最终的输出用于分类或回归, 动态调整每一层的权重, 使学习网络适应特定任务。

3) 输出层训练。最后一层的输出权重通过最小二乘法计算, 得到最终的预测结果。

在当前工程应用背景下, DELM 适合处理复杂的非线性问题, 尽管它的权重不通过迭代学习优化, 但 DELM 训练速度快, 处理大量数据时具有显著优势, 是适应性较强的深度学习模型。

1.2 海鸥优化算法

海鸥优化算法是一种模拟自然界海鸥群体觅食行为的智能优化算法, 通过数学模型有效探索解空间, 寻找全局最优解。海鸥优化算法主要步骤如下:

1) 初始化群体。随机生成一群候选解, 每个解表示问题的一个可能解决方案。

2) 评估适应度。计算每个候选解的适应度, 适应度函数通常应当满足优化问题的特定要求。

3) 迭代。按照算法规则依次迭代, 模拟海鸥群体的行为, 包括寻找食物、群体协作和探索。

4) 求候选解。模拟海鸥寻找食物的过程, 在候选解空间中寻找更好的解, 主要是在当前解附近的预设范围进行搜索, 以寻找更高适应度的解。

5) 优化。模拟海鸥协作过程, 通过信息分享, 在搜索过程中引入少量随机值, 以鼓励解空间的多样性。

6) 更新候选解。根据求解及优化的结果, 更新候选解数值。

7) 终止计算。预设终止条件(如达到最大迭代次数或找到的解符合预设条件)达成后, 结束算法。

海鸥优化算法是一种启发式算法, 通常用于求解复杂的优化问题, 如参数优化、机器学习模型调优等。

2 电池数据分析与健康量化特征选取

2.1 SOH 的定义和计算

锂离子电池的 SOH 为电池整个使用周期的健康程度, 计算方法为当前容量与额定容量的比值, 计算表达式为

$$S_{OH} = \frac{Q_n}{Q_0} \times 100\% \quad (5)$$

式中: Q_n 为电池在第 n 次使用周期的最大可用容量; Q_0 为额定容量。

2.2 电池实验数据分析

本文采用的锂离子电池退化数据源自 NASA POSE 研究中心公开发布的一组商用锂离子电池单体充放电测试数据。实验选取编号为 B0005、B0006、B0007、B0018 的 4 块电池数据, 用于研究与分析工作, 以评估电池健康状态及优化预测模型。

电池充放电实验在 24℃ 的室温下进行, 充电过程采用 1.5 A 的恒定电流 (constant current, CC) 模式对电池进行充电, 直至电池电压达到 4.2 V, 后切换至恒定电压 (constant voltage, CV) 模式继续充电, 直到充电电流降至 20 mA 时停止充电过程。放电过程使用 2 A 的恒定电流对编号为 B0005、B0006、B0007、B0018 的电池进行放电, 直至各电池电压分别下降至 2.7 V、2.5 V、2.2 V 和 2.5 V 为止。当电

池达到寿命终止 (end of life, EOL) 标准时, 实验终止。实验中, B0005、B0006、B0007 进行循环 168 次, B0018 进行循环 132 次。该组电池的容量退化曲线如图 1 所示。




图 1 锂电池组容量退化曲线

2.3 电池健康特征参数

精准的健康特征参数可以显著提高模型的预测准确度, 为提升预测准确度, 需要选取多个健康参数作为特征数据来映射电池的 SOH。以 B0005 电池为例, 根据锂电池的充电特性可以判断, 随着充电循环次数增加, 电池电量持续下降, 恒流充电所用时间有规律地缩短。结合实际应用情况, 选取电压 3.8 V 升高至 4.2 V 所用时间 (即等压升充电时间) 作为第一组健康特征参数, 记为 T_1 , 4 块电池的 T_1 随充放电循环次数的变化曲线如图 2 所示。




图 2 锂电池组等压升充电时间变化曲线

同样, 根据锂电池的放电特性可以判断随着充电循环次数增加, 受电池电量影响, 恒流放电所用时间有规律地缩短。结合实际应用情况, 选取电池电压由 4.0 V 下降至 3.6 V 所用时间 (即等压降放电时间) 作为第二组健康特征参数, 记为 T_2 , 4 块电池的 T_2 随充放电循环次数的变化曲线如图 3 所示。




图3 锂电池组等压降放电时间变化曲线

由图2、图3并结合图1可以看出， T_1 和 T_2 作为电池健康特征参数，与电池SOH的变化趋势基本相同。为进一步量化分析电池健康特征参数与电池SOH之间的相关性，选用Pearson相关系数作为量化参考指标。Pearson相关系数能够定量衡量两个变量间的相关度，其绝对值介于0~1，值接近1表示强相关，反之则相关性较弱。应用此系数，可以定量衡量不同健康特征参数与SOH之间的关联程度，从而为选取健康特征参数提供依据。Pearson相关系数的计算公式为

$$r_{X,Y} = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (6)$$

式中： X_i 为电池的健康特征参数，即 T_1 、 T_2 ； \bar{X} 为健康特征参数平均值； \bar{Y} 为SOH平均值； Y_i 为电池SOH； N 为样本数量。根据Pearson相关系数的原理，当相关系数绝对值大于0.8时，表明两组数据具有显著相关性。两组健康特征参数与电池SOH的相关系数见表1，这些特征参数与电池SOH的相关系数绝对值均接近1，表明它们与电池SOH之间存在极强的相关性，因此 T_1 、 T_2 的选取较符合预测的计算要求。

表1 健康特征参数与SOH之间的相关系数

健康特征参数	Pearson 相关系数（绝对值）			
	B0005	B0006	B0007	B0018
T_1	0.993 2	0.987 2	0.984 4	0.975 4
T_2	0.998 5	0.995 6	0.998 6	0.996 0

3 模型训练与SOH预测

3.1 数据预处理

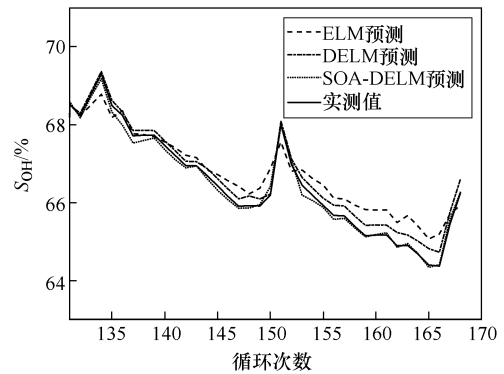
实验基于Matlab平台进行，选取NASA电池数

据集中4块锂离子电池的充放电测试数据作为实验对象，电池编号分别为B0005、B0006、B0007、B0018，其中B0005、B0006、B0007电池选取前130次（约占总体样本的77%）循环的 T_1 、 T_2 、可用容量作为学习样本数据，B0018选取前105次（约占总体样本的80%）循环的 T_1 、 T_2 、可用容量作为学习样本数据，分别剩余最后38、27次循环数据作为预测输出数据进行验证。对所有提取的数据进行归一化处理。为验证SOA-DELM进行数据预测的准确度，将其与ELM、DELM模型的预测结果进行横向比较。


3.2 模型训练和验证

将前述数据分别载入ELM、DELM、SOA-DELM模型进行预测，模型中隐层网络节点数为50，SOA算法中种群大小为20、迭代次数为50。控制以上变量，分别对SOH进行预测输出。SOH的预测结果和实测值如图4所示。

由图4可知，预测值围绕实测值在有限范围内上下波动，3组模型的预测值与实测值的变化趋势基本一致。为量化对比不同模型预测的准确程度，本文引入最大绝对误差（maximum absolute error, MAE）和方均根误差（root mean square error, RMSE）



(a) B0005



(b) B0006

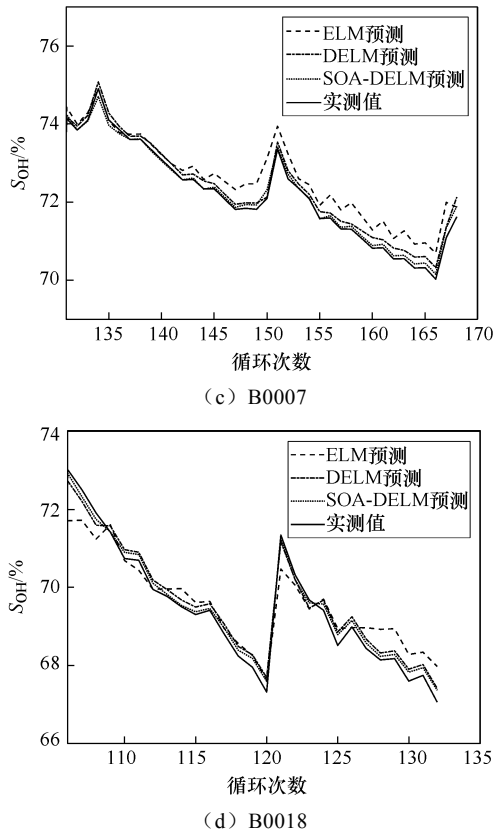


图 4 SOH 的预测结果和实测值

表 2 不同模型的评价指标

电池	MAE			RMSE		
	ELM	DELM	SOA-DELM	ELM	DELM	SOA-DELM
B0005	0.007 593 00	0.003 789 06	0.001 709 06	0.008 867 46	0.004 274 34	0.002 124 84
B0006	0.007 779 61	0.006 004 04	0.004 757 90	0.012 141 28	0.008 012 73	0.006 380 81
B0007	0.007 668 89	0.003 446 73	0.001 550 55	0.008 793 29	0.003 850 87	0.002 055 20
B0018	0.008 828 01	0.004 856 35	0.002 885 62	0.010 820 18	0.005 028 74	0.003 243 40

势,这与 SOA 的较大搜索空间、多次优化迭代的特性密不可分,意味着 SOA 优化后的 DELM 具备较高的预测准确性和稳定性,实用性更强。

4 结论

针对锂电池在实际应用中 SOH 预测方法准确度低的问题,本文提出了一种基于 SOA 优化 DELM 的模型,用于锂电池的 SOH 精确预测,并进行了实验验证和数据分析。对 4 组锂电池的充放电数据进行分析后,提取等压升充电时间和等压降放电时间作为与电池 SOH 密切相关的特征参数,利用 Pearson 相关系数定量分析特征参数与电池 SOH 的相关性,证明了能够利用这两组健康特征参数有效关联预测

作为量化评价指标,这两种指标的计算公式为

$$M_{AE} = \max |f(x_i) - y_i| \quad (7)$$

$$R_{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (f(x_i) - y_i)^2} \quad (8)$$

式中: y_i 为 SOH 实际值; $f(x_i)$ 为 SOH 预测值。

不同模型的评价指标见表 2,可以看出,在相同的电池和运算条件之下,MAE 和 RMSE 整体低于 0.013,说明在计算中没有出现过拟合等使运算结果误差较大的现象,同时模型预测结果整体误差较低,低于文献[15-17]中的普遍水平。

结合图 4 和表 2,在模型的实际预测中可以看出,ELM 对电池 SOH 的预测误差较大,且当循环次数依次增大时,预测误差也随之增大;DELM 预测性能优于 ELM,但是对实测值不同程度的波动跟踪不够精准;SOA-DELM 模型的预测性能明显优于 ELM 和 DELM。SOA-DELM 模型对样本的预测值 MAE 最低为 0.001 550 55, RMSE 最低为 0.002 055 20,说明以 SOA 优化 DELM 的预测方式与真实值之间具有较高的拟合度,能够准确定位和跟踪数据不同程度的波动,具有预测准确度高、适应性强的优

电池的 SOH。

建立了基于 SOA 优化 DELM 的 SOA-DELM 模型。为验证 SOA-DELM 模型的性能,采用 NASA 电池数据集进行预测处理,并将结果与 ELM、DELM 和其他文献相关数据进行比较,结果表明在样本量为整体数据 80%左右、节点数和迭代次数偏少时,SOA-DELM 模型的预测 MAE 低于 0.005, RMSE 低于 0.007,预测误差普遍在 0.01 以下,拟合度较高,具备预测的准确性和较强的实用性。

在后续的工程运用中,可以扩大样本数目,根据电池的实际使用情况提取健康特征参数,增加隐层节点数和 SOA 的族群数及迭代次数,进一步减少预测结果随机偏移的情况,以验证本文模型的有效性。

参考文献

- [1] SARMAH S B, KALITA P, GARG A, et al. A review of state of health estimation of energy storage systems: challenges and possible solutions for futuristic applications of Li-ion battery packs in electric vehicles[J]. *Journal of Electrochemical Energy Conversion and Storage*, 2019, 16(4): 040801.
- [2] ZHANG Qichao, LI Xue, ZHOU Chun, et al. State-of-health estimation of batteries in an energy storage system based on the actual operating parameters[J]. *Journal of Power Sources*, 2021, 506: 230162.
- [3] 关燕鹏, 刘成刚, 相洪涛, 等. 基于概率化稀疏自注意力 LSTM 的锂离子电池健康状态预测[J]. *控制工程*, 2024, 31(10): 1833-1840.
- [4] MIRZAEI H, KAMRAVA S. Estimation of internal states in a Li-ion battery using BiLSTM with Bayesian hyperparameter optimization[J]. *Journal of Energy Storage*, 2023, 74: 109522.
- [5] 赵靖英, 胡劲, 张雪辉, 等. 基于锂电池模型和分数阶理论的 SOC-SOH 联合估计[J]. *电工技术学报*, 2023, 38(17): 4551-4563.
- [6] 梁杨, 周永军, 蒋淑霞, 等. 基于改进 GWO-SVR 的锂电池 SOH 估计[J]. *电子测量技术*, 2023, 46(7): 13-18.
- [7] GUHA A, PATRA A. State of health estimation of lithium-ion batteries using capacity fade and internal resistance growth models[J]. *IEEE Transactions on Transportation Electrification*, 2018, 4(1): 135-146.
- [8] 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.
- [9] 丁同, 傅晓锦. 基于改进粒子群优化算法和极限学习机的锂离子电池健康状态预测[J]. *国外电子测量技术*, 2023, 42(5): 163-173.
- [10] 余佩雯, 郁亚娟, 常泽宇, 等. 相关向量机预测锂离子电池剩余有效寿命[J]. *电气技术*, 2023, 24(2): 1-5.
- [11] KIM J, CHUN Huiyong, KIM M, et al. Effective and practical parameters of electrochemical Li-ion battery models for degradation diagnosis[J]. *Journal of Energy Storage*, 2021, 42: 103077.
- [12] 吴铁洲, 朱俊超, 成雄帆, 等. 基于充电阶段数据与 GWO-BiLSTM 模型的锂电池 SOH 估计方法[J]. *电源技术*, 2024, 48(11): 2184-2194.
- [13] MAO Ling, HU Huizhong, CHEN Jiajun, et al. Online state-of-health estimation method for lithium-ion battery based on CEEMDAN for feature analysis and RBF neural network[J]. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 2023, 11(1): 187-200.
- [14] 于沛, 王常乐. 基于局部均值分解和极限学习机的锂电池剩余寿命预测[J]. *电气技术*, 2023, 24(1): 23-28.
- [15] 王渴心, 周军, 王岩. 基于鸚鵡优化和极限学习机的锂离子电池健康状态估计[J]. *电气应用*, 2023, 42(11): 16-25.
- [16] 毛玲, 温佳林, 赵晋斌, 等. 基于集成 ELM 的锂离子电池充电截止电压下的 SOC 和 SOH 联合估计[J]. *电力系统保护与控制*, 2023, 51(11): 86-95.
- [17] 顾天宇. 基于神经网络的锂离子电池 SOC 和 SOH 估计方法[D]. 青岛: 青岛大学, 2023.
-
- 收稿日期: 2025-02-28
修回日期: 2025-03-16
作者简介
靳 灿(1992—), 女, 山东省济宁市人, 本科, 工程师, 主要从事电力企业项目管理工作。
- (上接第 39 页)
- [13] LIU Yichang, TIAN Chunlin, LIU Tao, et al. Modal analysis of worm and worm gear based on ANSYS Workbench[J]. *MATEC Web of Conferences*, 2015, 34: 02014.
- [14] 潘东煦, 顾剑锋, 陈睿恺, 等. 30Cr2Ni4MoV 低压转子钢不同微观组织下的力学性能[J]. *金属热处理*, 2011, 36(5): 1-4.
- [15] 刘峻华. 大型汽轮发电机组轴系扭振研究[D]. 武汉: 华中科技大学, 2006.
- [16] 常雷. 高速电主轴动态特性及多工况条件对其影响的研究[D]. 天津: 天津工业大学, 2021.
- [17] 党蒲妮, 吕锦锋, 刘江华, 等. 预载荷及热环境下典型壁板结构的模态分析[C]//第十五届全国结构振动与动力学学术研讨会暨第三届全国冲击及防护工程学术研讨会, 厦门, 2023.
-
- 收稿日期: 2025-01-20
修回日期: 2025-02-28
作者简介
杨俊杰(1999—), 男, 硕士研究生, 研究方向为大型汽轮发电机组的扭振特性仿真分析。