

改进全局 ZOA 优化 MVMD-SCN 的锂电池 SOH 估算^{*}

郭喜峰 黄裕海 单丹 原宝龙 宁一

(沈阳建筑大学电气与控制工程学院 沈阳 110168)

摘要: 锂电池健康状态(SOH)的准确估算对电池系统的健康管理起着重要作用,为提高 SOH 的估算精度,提出一种将参数优化后的多元变分模态分解(MVMD)和随机配置网络(SCN)相结合的 SOH 估算方法。从锂电池充放电过程中提取多个健康因子(HF)作为 SOH 估算模型的输入,在斑马优化算法(ZOA)全局阶段引入自适应权重和最优领域波动策略,提高其全局搜索能力,得到改进全局的斑马优化算法(IGZOA),利用它对 MVMD 和 SCN 参数进行寻优,最后在 9 个基准函数测试 IGZOA 性能,在 NASA 和 CALCE 数据集上将所提方法与不同方法进行锂电池 SOH 的估算对比,结果表明,所提方法的均方根误差和绝对误差的平均值分别为 0.84%,0.93%,具有更高的预测精度和泛化性。

关键词: 锂电池;健康状态;多元变分模态分解;改进斑马优化算法;随机配置网络

中图分类号: TM912 **文献标识码:** A **国家标准学科分类代码:** 510.80

Improved global ZOA optimization of MVMD-SCN for
lithium battery SOH estimation

Guo Xifeng Huang Yuhai Shan Dan Yuan Baolong Ning Yi

(School of Electrical and Control Engineering, Shenyang Jianzhu University, Shenyang 110168, China)

Abstract: Accurate estimation of the state of health (SOH) of lithium batteries plays an important role in the health management of battery systems. In order to improve the accuracy of SOH estimation, a SOH estimation method that combines the parameter-optimized multivariate variational modal decomposition (MVMD) and stochastic configuration network (SCN) is proposed. Multiple health factors (HF) are extracted from the lithium battery charging and discharging process as inputs to the SOH model, and adaptive weights and optimal domain fluctuation strategies are introduced in the global stage of the Zebra Optimization Algorithm (ZOA) to improve its global searching ability, to obtain the Improved Global Zebra Optimization Algorithm (IGZOA), which is utilized to search for the optimization of the MVMD and the SCN parameters, and finally, the MVMD and SCN parameters are tested in nine benchmark functions IGZOA performance, the proposed combined method is compared with different methods for lithium battery SOH estimation on NASA and CALCE datasets, and the results show that the average values of root mean square error and absolute error of the proposed method are 0.84% and 0.93%, respectively, and the proposed method has higher prediction accuracy and generalizability.

Keywords: lithium battery; state of health; multivariate variational modal decomposition; improved global zebra optimization algorithm; stochastic configuration network

0 引言

锂电池作为一种具有快充电速率,长使用寿命,小体积和高能量密度的清洁能源,被广泛应用于在新能源汽车,生活电子用品和军事等多个领域。然而,随着充放电使用次数的增加,锂电池会逐渐老化,其性能和安全性会逐渐衰

退^[1-2]。所以,锂电池健康状态(state of health, SOH)的准确估算对于电池的安全使用和能量管理具有关键意义。对于锂电池而言,SOH 是衡量电池状态的关键指标,其通常定义为可用容量与额定容量之间的比值^[3]。

锂电池 SOH 估算的方法主要包括两类:构建模型方法与数据驱动方法^[4]。数据驱动方法无需和构建模型方

法一样,需要考虑电池材料特性和失效机理等因素的变化,建模复杂且泛化适用性不高,所以目前大多数研究 SOH 估算是基于数据驱动方法估算的,该方法直接在电池历史数据中电压、电流和温度等参数变化中提取健康特征(health factor, HF)作为数据模型输入建立 SOH 估计模型^[5]。陈璐等^[6]利用粒子群优化算法(particle swarm optimization, PSO)和改进的支持向量机(support vector machines, SVM)对锂电池进行估算。梁杨等^[7]采用灰狼优化算法(grey wolf optimizer, GWO)和高斯过程回归(gaussian process regression, GPR)进行 SOH 估算。这些结合方法有效的提高了 SOH 的估算精度,给锂电池 SOH 估算提供了一种有力的框架,但优化算法的寻优能力和结合算法的性能对于 SOH 估算起着关键作用。随机配置网络(stochastic configuration network, SCN)相比 GPR 和 SVM 等线性或是局部线性模型,SCN 可以通过学习过程中调整网络结构和权重,从而实现对数据的自适应建模,这种灵活性使得它在处理锂电池复杂非线性的数据时更具优势^[8]。而 GWO 存在陷入局部最优解和调参复杂的问题,PSO 也有算法易早熟收敛,惯性权重和加速系数等参数需选择的问题。斑马优化算法(zebra optimization algorithm, ZOA)具有预设参数少,收敛速度快等优点,但是分析 ZOA 过程中发现在全局搜索阶段存在缺陷,收敛速度和还是会有陷入局部最优解的情况,因此加入自适应权重和最优领域波动策略进行改进,提出了改进全局斑马优化算法 IGZOA。

采用信号分解方法可以减少锂电池数据的复杂性,郑雪莹等^[9]将变分模态分解(variational modal decomposition, VMD)和核极限学习机(Kernel Based Extreme Learning Machine, KELM)相结合进行锂电池 SOH 的估算,实验证明 VMD 能够有效减少原始锂电池复杂数据的噪声干扰,提高模型估算精度,这种结合方法充分考虑了锂电池数据的模态分解和时空关联特性。但是上述的 VMD 包括一般的分解方法,在分解多输入数据时,需要逐一分解,而多元变分模态分解(multivariate variational mode decomposition, MVMD)能够通过联合分解多个特征输入,这使得 MVMD 能够更全面地考虑多个特征之间的相互关系,保持数据整体结构的一致性,提高了分解的精度和鲁棒性。

综上所述,提出了一种将 MVMD,改进全局的斑马优化算法(improved global zebra optimization algorithm, IGZOA)和 SCN 相结合的锂电池 SOH 估算方法。文中主要阐述了健康因子的选取,IGZOA 算法的构建和在不同基函数的性能验证,最后在 NASA 的 B5 数据集和 CALCE 的 CS2-34 数据集上对提出方法与不同方法进行实验验证。结果表明,所提方法具有更好的 SOH 估算性能,这为 SCN 在锂电池 SOH 估算领域的应用及推广提供了实验依据。

1 数据处理

1.1 锂电池数据集及健康特征选取

在本文的实验中,选取了 NASA 的 B5 数据集进行实验,电池的充放电具体过程如下^[10]:

1)充电:电池额定容量 2.0 A·h,以恒流 1.5 A 给锂电池充电,让其电压到达 4.2 V,再以恒压 4.2 V 继续充电操作,直至电池电流减少至 20 mA。

2)放电:以恒流 2 A 进行放电,直至 B5,电压分别减少到 2.7 V。

3)反复充放电操作,直至 SOH 减少到 0.7,即容量到达失效阈值 1.4 A·h。

其为表明所提方法在估算数据增多时依旧具有可靠性,估算加入 CALCE 中的 CS2-34 数据集,其有 700 个充电循环周期数据远高于 NASA 的 B5,数据集 168 个周期,其具体操作过程与 B5 类似,不同的是充电阶段电流为恒流 0.45 A,放电阶段是以恒流 0.45 A 放电使电池电流减少至 0.05 A。图 1 为 CS2-34 的 SOH 衰减曲线。




图 1 CS2-34 的 SOH 衰减曲线

图 2(a)、(b)分别为 B5 的恒流充、放电时间的曲线变化。如图 2(a)所示,随着充放电操作的增加,B5 电池恒流充电时间慢慢减少。这意味着它隐含了电池性能退化的特征,可以作为电池健康状况的间接健康因子(health factors, HF)。所以选择恒流充电时间作为 HF1,同理由图 2(b)看出恒流放电时间可作为健康因子,记为 HF2。




图 2 B5 恒流充放电时间的曲线变化

1.2 相关性分析

使用 Pearson 系数来分析其和 SOH 的相关程度。Pearson 系数可表示如式(1)所示。

$$Pearson = \frac{E(\alpha\beta) - E(\alpha)E(\beta)}{\sqrt{E(\alpha) - (E(\alpha))^2} \sqrt{E(\beta) - (E(\beta))^2}} \quad (1)$$

式中: E 为期望值; 相关系数值越趋近 1 表征数据之间相关性越高。

NASA 的 B5 的数据集和 CALCE 的 CS2-34 的数据集的 HF1、HF2 分别与 SOH 的相关系数, 如表 1 所示。

表 1 健康因子与 SOH 的相关系数

特征	B5	CS2-34
HF1	0.969 0	0.971 3
	0.940 1	0.960 5
HF2	0.991 8	0.975 2
	0.981 3	0.988 6

由表 1 可知, 可以看出 Pearson 系数都在 0.9~1.0 之中, 说明所提取的健康因子与 SOH 相关性较为紧密, 可以作为描述电池 SOH 的健康因子。

2 MVMD-IGZOA-SCN 模型构建

2.1 多元变分模态分解

MVMD 可以同时分解 HF1 和 HF2, 连接了两个输入特征的时域和频域特性, 确保它们分解后模态数和频率尺度的一致性, 其分解步骤如下^[11]:

1) 有 c 个输入特征通道, 即 $x(t) = [x_1(t), x_2(t), \dots, x_c(t)]$, 提取 k 个多变量振荡 $u_k(t)$, 使得:

$$x(t) = \sum_k u_k(t) \quad (2)$$

式中: $u(t) = [u_1(t), u_2(t), \dots, u_k(t)]$ 。

2) 通过希尔伯特变换得到 $u_k(t)$ 中各个振荡的解析信号, 记为 $u_k^+(t)$, 将解析信号调制成对应的中心频率 w_k , 每个固有模态函数(IMF)分量的中心带宽通过解析 $u_k^+(t)$ 的梯度函数的 L_2 范数来估算。MVMD 的目的为让每个 IMF 分量的预估带宽相加最小且全部 IMF 分量信号求和等于原始信号, 以此构造约束变分函数如下:

$$\begin{cases} \min_{\{u_{k,c}\}, \{\omega_k\}} \left\{ \sum_k \sum_c \|\partial_t [u_{k,c}^{k,c}(t) e^{-j\omega_k t}] \|^2 \right\} \\ s.t. \quad x_c(t) = \sum_k u_{k,c}(t) \end{cases} \quad (3)$$

式中: ∂_t 为对 t 求偏导数; $u_k(t)$ 为第 k 个 IMF 分量。 $u_{k,c}^{k,c}(t)$ 为对应 c 通道中 $u_k(t)$ 每个振荡的解析信号。

3) MVMD 引入 Lagrange 乘子 $\lambda(t)$ 和二次惩罚项 α , $\lambda(t)$ 起到增强变分约束条件约束强度的目的, α 保证了分解信号重新构成后的精度。增广 Lagrange 函数公式如下:

$$L(\{u_{k,c}\}, \{\omega_k\}, \lambda_c) = \alpha \sum_k \sum_c \|\partial_t [u_{k,c}^{k,c}(t) e^{-j\omega_k t}] \|^2 + \sum_c \|x_c(t) - \sum_k u_{k,c}(t)\|_2^2 + \sum_c \langle \lambda_c(t), x_c(t) - \sum_k u_{k,c}(t) \rangle \quad (4)$$

4) 通过交替方向乘法更新 $u_k(t)$, w_k , 更新条件为式(5), 中心频率更新条件为式(6):

$$\hat{u}_{k,c}^{n+1}(w) = \frac{x\hat{u}_c(w) - \sum_{i \neq k} u\hat{u}_{i,c}(w) + \frac{\lambda_c(w)}{2}}{1 + 2\alpha(w - w_k)^2} \quad (5)$$

$$w_k^{n+1} = \frac{\sum_c \int_0^\infty w |u\hat{u}_{k,c}(w)|^2 dw}{\sum_c \int_0^\infty |u\hat{u}_{k,c}(w)|^2 dw} \quad (6)$$

2.2 随机配置网络

SCN 是一种随机权神经网络, 与前馈神经网络相似, 包括输入层、隐含层、输出层。通过监督机制, SCN 采用最小二乘法分配随机隐含层参数, 增量地构建隐藏节点, 确保所建模型具备万能逼近性质。对于给定的目标函数: $f: R^d \rightarrow R^m$, 具有 $L-1$ 个隐藏节点的 SCN 可表示为^[12]:

$$f_{L-1}(x) = \sum_{j=1}^{L-1} \beta_j g_j(w_j, b_j, x) \quad (7)$$

式中: g_j 为第 j 个隐藏节点的基函数, w_j, b_j 为第 j 个隐藏节点的权重和偏置, β_j 为第 j 个隐藏节点和输出节点之间的权重。 $f_{L-1}(x)$ 代表当前的输出。

在达到可容忍误差之前, SCN 通过监督机制在之前的网络上增量构建节点, 构建的新网络如式(8)所示。

$$f_L(x) = f_{L-1}(x) + \beta_L g_L \quad (8)$$

增加节点之前网络的误差如式(9)所示。

$$e_{L-1} = f_{L-1} - f_{L-1} = [e_{L-1,1}, \dots, e_{L-1,m}] \quad (9)$$

输出权重可由式(10)得出:

$$\beta_{L,q} = \frac{\langle e_{L-1,q}, g_L \rangle}{\|g_L\|^2}, q = 1, 2, \dots, m \quad (10)$$

监督机制为假如 $\forall g \in \Gamma$, 有 $0 < r < 1$ 和非负实数序列 $\{\mu_L\}$, 且有 $\lim_{L \rightarrow +\infty} \mu_L = 0$ 和 $\mu_L \leq 1 - r$ 。对于隐藏节点 $L = 1, 2, \dots$, 可表示为:

$$\delta_{L,q} = (1 - r - \mu_L) \|e_{L-1,q}\|^2, q = 1, 2, \dots, m \quad (11)$$

假如随机生成的基函数 g_L 满足式(12):

$$\langle e_{L-1,q}, g_L \rangle^2 \geq b_k^2 \delta_{L,q}, q = 1, 2, \dots, m \quad (12)$$

可以得出 $\lim_{L \rightarrow +\infty} \|f - f_L\| = 0$ 。

2.3 斑马优化算法

ZOA 于 2022 年 Trojovská 等^[13]提出的一种模仿斑马行为的新优化算法, 具备强大的寻优能力和快速的收敛速度等特点, 其寻优具体步骤如下:

1) 初始化阶段: 随机初始化斑马种群的位置, 如式(13)所示。

$$x_{i,j} = lb_j + r \cdot (ub_j - lb_j) \quad (13)$$

式中: $x_{i,j}$ 为第 i 个斑马在维度 j 的位置; lb_j, ub_j 为寻优上下边界; r 为 $[0, 1]$ 的随机数。

2) 觅食行为(全局搜索阶段): 在 ZOA 中, 先锋斑马被视为种群中的佼佼者。它的任务是发现具有植被的地点, 并引导其他群体成员迅速朝向这个在搜索空间中的位置。觅食行为用式(14)、(15)描述。

$$x_{i,j}^{new,P1} = x_{i,j} + r \cdot (PZ_j - I \cdot x_{i,j}) \quad (14)$$

$$X_i = \begin{cases} X_i^{new,P1}, & F_i^{new,P1} < F_i \\ X_i, & \text{其他} \end{cases} \quad (15)$$

式中: r 是 $[0, 1]$ 内的随机数; I 随机选取 1 或 2, I 等于 1 代表斑马种群流动性较小, 反之较大; PZ_j 为先锋斑马的第 j 个维位置; $F_i^{new,P1}$ 为基于第一阶段更新后的第 i 个斑马的目标函数值; $X_i^{new,P1}$ 为第 i 个斑马新位置; $x_{i,j}^{new,P1}$ 为第 i 个斑马的第 j 维新位置。

3) 针对不同捕食者的防御行为(局部搜索阶段), ZOA 模拟了斑马在面对捕食者攻击时的防御策略, 以更新斑马种群成员在搜索空间中的位置。在 ZOA 设计中, 假设以下两种情况以相同的概率发生:

(1) 狮子攻击斑马, 斑马选择逃跑; (2) 其他捕食者攻击斑马, 斑马选择攻击。

在第 1 种情况中, 斑马在受到狮子攻击时会选择在当前位置附近躲避。可以使用式(6)中的 S_1 来表示。而在第 2 种情况中, 当其他捕食者攻击斑马时, 其他斑马会靠近被攻击的斑马, 并反击捕食者, 用式(16)中的 S_2 进行表示。更新条件为式(17)。

$$x_{i,j}^{new,P2} = \begin{cases} S_1: x_{i,j} + R(2r-1) \cdot \left(1 - \frac{t}{T}\right) \cdot x_{i,j}, & P_S \leq 0.5 \\ S_2: x_{i,j} + r \cdot (AZ_j - I \cdot x_{i,j}), & \text{其他} \end{cases} \quad (16)$$

$$X_i = \begin{cases} X_i^{new,P2}, & F_i^{new,P2} < F_i \\ X_i, & \text{其他} \end{cases} \quad (17)$$

式中: T 为最大迭代次数; t 为迭代次数; t 是 $[0, 1]$ 的随机数; R 为 0.01 的常数; $F_i^{new,P2}$ 为在第 2 阶段更新后第 i 个斑马目标函数值。 $X_i^{new,P2}$ 为第 i 个斑马的新位置; $x_{i,j}^{new,P2}$ 为第 i 个斑马第 j 维的新位置, AZ_j 为被攻击斑马的第 j 维位置, P_S 为遇到两种防御行为的概率。

2.4 改进全局的斑马优化算法

通过分析发现, ZOA 在收敛速度和全局搜索能力上还存在一定缺陷, 因此在全局搜索阶段引入自适应权重和最优领域波动策略, 提升算法的全局寻优能力。

1) 自适应权重

在位置更新中加入一个随迭代次数 t 变化的惯性权重 w 。使得随着 t 的增加, 让最优斑马位置的影响力由弱到强, 这样不仅可以提升算法在前期的全局搜索能力, 而且在后期也使得其他斑马能够快速收敛到最优斑马的位置, 提升了算法的收敛速度。权重公式如式(18)。改进后的觅食阶段更新公式为式(19)。

$$w(t) = 0.2 \cos\left(\frac{\pi}{2} \cdot \left(1 - \frac{t}{t_{\max}}\right)\right) \quad (18)$$

$$x_{i,j}^{new,P1} = w(t) \cdot x_{i,j} + r \cdot (PZ_j - I \cdot x_{i,j}) \quad (19)$$

2) 最优领域波动

ZOA 更新位置时, 最优位置只有在出现优于它的位置时才会更新, 导致算法搜寻效率不够高。因此引入最优邻域波

动策略, 对最优位置的附近进行一次随机搜索, 从而得到更佳的全局值, 借此提升了算法的收敛速度, 还避免算法出现局部最优解。邻域波动公式如式(20)所示, 位置更新式(21)如下:

$$\tilde{X}_i^{new,P1} = \begin{cases} X_i^{new,P1} + 0.5 \cdot rand1 \cdot X_i^{new,P1}, & rand2 < 0.5 \\ X_i^{new,P1}, & \text{其他} \end{cases} \quad (20)$$

式中: $rand1$ 和 $rand2$ 为 $[0, 1]$ 中相同概率产生的随机数, $\tilde{X}_i^{new,P1}$ 为生成第 i 个斑马的新位置。

$$X_i = \begin{cases} \tilde{X}_i^{new,P1}, & \tilde{F}_i^{new,P1} < F_i^{new,P1} \\ X_i^{new,P1}, & \text{其他} \end{cases} \quad (21)$$

式中: $\tilde{F}_i^{new,P1}$ 为新生成的第 i 个斑马的目标函数值。

2.5 模型估算流程

综上, 图 3 为构建的 MVMD-IGZOA-SCN 方法估算流程, 步骤描述如下:




图 3 电池 SOH 模型估算流程

1) 提取 HF1, HF2, 分解 HF 和 SOH 数据, 划分数据集为训练集和测试集。

2) 在训练集中, IGZOA 训练出 MVMD 和 SCN 参数, 得出最优 SOH 退化关系数据模型。

3) 用测试集作为数据模型输入, 得出最后的 SOH 估算结果且进行评价指标计算, 用于评价估算模型性能。

3 实验结果与对比分析

3.1 误差评价指标

实验采用平均值 (average, Ave), 标准差 (standard deviation, Std) 对优化算法性能进行分析^[14]。用均方根误差 (root mean square error, RMSE), 平均绝对误差 (mean absolute error, MAE) 误差指标对模型估算效果进行评估分析^[15]。

$$Ave = \frac{1}{N} \sum_{i=1}^N |f(X^*) - f(X_{opt})|, Std = \sqrt{\sum_{i=1}^N (f(X^*) - f(X_{opt}))^2 / N}$$

(22)

式中： $f(X^*)$ 为新生成的适应度值， $f(X_{opt})$ 为理论上的最优解。

$$RMSE = \sqrt{\sum_{i=1}^N (\hat{C}_0(t+1) - C_0(t+1))^2 / N}$$
$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{C}_0(t+1) - C_0(t+1)|$$

(23)

式中： $\hat{C}_0(t+1)$ 为 $t+1$ 时刻的估算容量， $C_0(t+1)$ 为 $t+1$ 时刻的实际容量。

3.2 IGZOA 性能测试

为了测试 IGZOA 的收敛速度和全局开发能力,选取 9 种目标函数^[15],包括单峰(f1~f5)和高维多峰函数(f6~f9),与 7 种优化算法 ZOA,SSA,GWO,PSO,WOA,ABC,MPA 进行测试对比,9 种目标函数如表 2 所示,各种算法参数一致,种群规模 $N=30$,迭代次数为 500 次,评估指标对比如表 3 所示,图 4 为各优化算法的收敛曲线图。

表 2 目标函数表

公式	定义域	最优值
$f_1(x) = \sum_{i=1}^n x^2$	$[-100,100]$	0
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10,10]$	0
$f_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)$	$[-100,100]$	0
$f_4(x) = \max\{ x_i , 1 \leq x_i \leq n\}$	$[-100,100]$	0
$f_5(x) = \sum_{i=1}^n ix^4 + random[0,1)$	$[-1.28,1.28]$	0
$f_6(x) = -\sum_{i=1}^n (x_i(\sin \sqrt{x_i}))$	$[-500,500]$	-12 569.5
$f_7(x) = \sum_{i=1}^n (x^2 - 10\cos 2\pi x_i + 10)^2$	$[-5.12,5.12]$	0
$f_8(x) = -20\exp(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n}\sum_{i=1}^n \cos 2\pi x_i) + 20 + e$	$[-100,100]$	0
$f_9(x) = \frac{1}{4\,000}\sum_{i=1}^n (x_i - 100)^2 - \prod_{i=1}^n \cos \frac{x_i - 100}{\sqrt{i}} + 1$	$[-100,100]$	0

表 3 评估指标

函数	维度	误差	IGZOA	ZOA	SSA	GWO	PSO	WOA	ABC	MPA
f_1	30	Ave	0.00×10^0	5.24×10^{-65}	2.92×10^{-119}	1.30×10^{-27}	1.76×10^1	1.40×10^{-77}	3.05×10^0	1.46×10^{-23}
		Std	0.00×10^0	1.71×10^{-64}	6.53×10^{-119}	1.54×10^{-27}	8.32×10^0	2.91×10^{-77}	9.74×10^{-1}	1.49×10^{-23}
f_2	30	Ave	0.00×10^0	3.35×10^{-46}	9.02×10^{-55}	5.33×10^{-17}	1.12×10^1	4.07×10^{-53}	1.95×10^{-51}	2.59×10^{-13}
		Std	0.00×10^0	7.50×10^{-46}	2.01×10^{-54}	2.46×10^{-17}	3.44×10^0	8.69×10^{-56}	7.00×10^{-2}	3.92×10^{-13}
f_3	30	Ave	0.00×10^0	3.95×10^{-72}	9.49×10^{-57}	3.53×10^{-6}	4.47×10^2	5.24×10^4	3.69×10^4	2.48×10^{-5}
		Std	0.00×10^0	8.82×10^{-72}	2.12×10^{-56}	2.94×10^{-6}	1.39×10^2	9.39×10^3	2.78×10^3	4.54×10^{-5}
f_4	30	Ave	1.70×10^{-316}	2.50×10^{-46}	4.22×10^{-29}	6.38×10^{-7}	6.48×10^0	4.97×10^1	4.96×10^1	2.71×10^{-9}
		Std	0.00×10^0	5.59×10^{-46}	9.43×10^{-29}	4.88×10^{-7}	8.61×10^{-1}	3.13×10^1	4.16×10^0	4.79×10^{-10}
f_5	30	Ave	6.15×10^{-5}	2.25×10^{-3}	2.47×10^{-4}	1.57×10^{-3}	7.60×10^{-1}	2.69×10^{-3}	2.50×10^{-1}	1.86×10^{-3}
		Std	2.87×10^{-5}	3.54×10^{-3}	2.27×10^{-4}	1.02×10^{-3}	2.22×10^{-1}	3.14×10^{-3}	4.99×10^{-2}	7.93×10^{-4}
f_6	30	Ave	-1.18×10^4	-6.72×10^3	-9.26×10^3	-6.41×10^3	-2.37×10^3	-1.07×10^4	-5.19×10^3	-8.76×10^3
		Std	1.03×10^3	1.53×10^2	2.51×10^3	5.14×10^2	0.00×10^0	1.90×10^3	2.96×10^2	3.60×10^2
f_7	30	Ave	0.00×10^0	0.00×10^0	0.00×10^0	4.67×10^0	1.07×10^2	0.00×10^0	2.25×10^2	0.00×10^0
		Std	0.00×10^0	0.00×10^0	0.00×10^0	5.06×10^0	1.57×10^1	0.00×10^0	1.59×10^1	0.00×10^0
f_8	30	Ave	4.44×10^{-16}	4.44×10^{-16}	4.44×10^{-16}	1.04×10^{-13}	5.49×10^0	2.58×10^{-13}	1.98×10^0	1.30×10^{-12}
		Std	0.00×10^0	0.00×10^0	0.00×10^0	1.11×10^{-14}	8.60×10^{-1}	3.18×10^{-15}	6.86×10^{-1}	9.14×10^{-13}
f_9	30	Ave	0.00×10^0	0.00×10^0	0.00×10^0	8.48×10^{-3}	4.96×10^{-1}	2.63×10^{-2}	1.02×10^0	0.00×10^0
		Std	0.00×10^0	0.00×10^0	0.00×10^0	7.88×10^{-3}	5.78×10^{-2}	5.88×10^{-2}	1.74×10^{-2}	0.00×10^0




图 4 优化算法收敛曲线

从表 3 可以看出 IGZOA 在各个基函数上测试上的精度都在各个优化算法中最高,且标准差较低,表明了 IGZOA 的稳定性。只有在 f7、f8、f9 上 ZOA、SSA 和 IGZOA 达到了相同精度,其中在 f1~f2, f7~f9 都达到了理论最优值。从图 4 可以看出,IGZOA 的收敛速度基本优于其他算法,且一般都能收敛到每个基函数的全局最优解。其他算法在 f1~f6 上都陷入了局部最优解,而 IGZOA 由于在全局阶段引入自适应权重和最优邻域波动策略而避免了这个问题。实验结果表明,IGZOA 无论是解决单目标还是高维多目标问题,都有着较好的性能。

3.3 IGZOA-MVMD 分解实验和参数设置

在整个构建过程中,候选层节点的权重和偏差初始化取决于尺度因子 λ ,而在监督机制中计算不等式约束会取决于正则化参数 r ,还有随机配置次数和最大隐藏节点数

也影响 SCN 训练的精度和效率。

经过多次实验和 IGZOA 不断寻优,得出 SCN 的参数设置如下: k 设置为 30,每次增量节点为 1,最大隐藏层节点数设置为 150,最大允许误差 ϵ 设置为 1×10^{-3} ,SCN 的 r 和 λ 分别由 $[0.90, 0.99]$ 和 $[0.5, 250]$ 自动确定。

MVMD 仍然需要人为设置分解个数 k 和惩罚因子 α ,不适当的 k 和 α 会导致数据过分解或者分解不充分的问题,最终导致分解后数据的模式混叠和特征丢失。经过不断分解实验,IGZOA 最终寻优得 MVMD $k=5$, $\alpha=1504$ 为最优解。以 B5HF1 为例,图 5(a)为 HF1 经过分解后各分量的时域图,然后利用 B5 电池前 50%数据集作为训练集,后 50%作为测试集继续对 IGZOA-MVMD 的有效性进行具体实验验证,并与各分解方法相结合的 IGZOA-SCN 方法进行对比,证明 IGZOA-MVMD 对于模型估算

能力的提升,图 5(b)为估算曲线,表 4 为估算误差。




图 5 B5HF1 的 IGZOA-MVMD 结果

图 5(a)中 IMF1 的稳定单调下降反应了锂电池的整体老化趋势,IMF2~IMF5 有效表示了各个周期频段数据变化情况,反应了容量再生现象,明显可以看出 HF1 被分解成了不同频率的分量。

表 4 不同分解方法的估算误差

方法	MAE	RMSE
EMD-IGZOA-SCN	0.017 4	0.018 2
LMD-IGZOA-SCN	0.015 5	0.016 4
CEEMDAN-IGZOA-SCN	0.010 8	0.011 6
VMD-IGZOA-SCN	0.009 8	0.010 6
MVMD-IGZOA-SCN	0.009 1	0.009 9

从图 5(b),表 2 中可以看出,IGZOA-MVMD 估算曲线准确的跟踪了锂电池退化的趋势,拟合程度最好,估算精度最高。IGZOA-MVMD 对比其他方法中估算效果最好的 VMD,MAE, RMSE 降低了 7.1%,6.6%。综合以上实验,证明了 IGZOA-MVMD 相对于其他分解方法可以更充分提取锂电池健康特征中隐藏的寿命信息,更适用于多

特征分解,可以有效的提高模型估算效果。

3.4 实验结果分析

本文在 NASA 的 B5 数据集和 CALCE 的 CS2-34 数据集上将 MVMD-IGZOA-SCN 与其他方法进行对比分析。健康特征 HF1, HF2 作为模型的输入,模型输出为 SOH 值。分别利用 B5 的前 50%,60%数据集和 CS2-34 前 505,前 605 个数据作为训练集,剩下的作为测试集进行实验。不同方法不同测试集的 B5,CS2-34 的 SOH 估算曲线如图 6(a)、(b),图 7(a)、(b)所示,估算误差如表 5 所示。

从图 6、7 和表 5 中可以看出,IGZOA, MVMD 优化 SCN 参数有效提升了模型估算效果。对 CS2-34 数据集来说,随着训练数据增加,模型估算精度也随之提高。对于





图 6 不同方法不同测试集的 B5 的 SOH 估算曲线






图 7 不同方法不同测试集的 CS2-34 的 SOH 估算曲线

B5 数据集,除 RVFL 外,60%数据集作为训练集的模型估算效果普遍优于 50%数据集作为训练集的模型估算效果。不同数据集中 RVFL 的估算曲线上下浮动普遍最大,估算精度最低。SCN 曲线波动相对 RVFL 曲线波动来,有所降低,但是误差依旧较高,表明数据没有经过分解预处理和估算模型参数没有经过优化时,估算精度较低。多组合方法在不同数据集上的实验表现良好,其中 MVMD-IGZOA-SCN 达到了最优估算效果,和真实值曲线拟合程度最高,估算精度最高,其 MAE,RMSE 平均误差分别只有 0.008 4,0.009 3,相比于其他多组合方法中表现最好的 MVMD-ZOA-SCN 依旧降低了 20.19%,17.88%。

表 5 估算误差

型号	训练集	估算方法	MAE	RMSE
B5	50%数据集	RVFL	0.032 3	0.037 4
		SCN	0.022 1	0.026 7
		ZOA-SCN	0.020 4	0.024 8
		MVMD-PSO-SCN	0.015 4	0.017 6
		MVMD-ZOA-SCN	0.011 2	0.012 1
	60%数据集	MVMD-IGZOA-SCN	0.009 1	0.009 9
		RVFL	0.034 2	0.038 7
		SCN	0.021 3	0.025 6
		ZOA-SCN	0.019 1	0.023 9
		MVMD-PSO-SCN	0.014 9	0.017 2
CS2-34	505 个数据	MVMD-ZOA-SCN	0.010 8	0.011 4
		MVMD-IGZOA-SCN	0.008 8	0.009 2
		RVFL	0.025 8	0.031 5
		SCN	0.018 5	0.022 9
		ZOA-SCN	0.015 6	0.017 3
	605 个数据	MVMD-PSO-SCN	0.013 7	0.015 6
		MVMD-ZOA-SCN	0.010 6	0.011 7
		MVMD-IGZOA-SCN	0.008 2	0.009 5
		RVFL	0.024 4	0.029 6
		SCN	0.017 2	0.021 3

4 结 论

本文提出了一种用于锂电池 SOH 估算的 MVMD-IGZOA-SCN 方法。在锂电池充放电过程中提取能够表示电池性能退化的间接健康因子作为 SOH 估算模型输入,并利用 Pearson 系数求出健康因子与电池 SOH 的相关程度。使用 IGZOA 对 MVMD 分解个数,惩罚因子和 SCN

正则化因子和尺度因子等参数寻优,建立起了精准的估算模型,最后实现了锂电池的 SOH 准确估算。经过在 NASA 和 CALCE 数据集将提出方法和其他方法估算结果进行对比,MVMD-IGZOA-SCN 在不同数据集上都达到了最优估算效果,具有较好的估算精度和稳定性。在未来的研究中,会考虑锂电池不同的复杂工况对与电池 SOH 估算的影响,从而实现更准确全面的锂电池 SOH 估算。

参考文献

- [1] TIAN J, LIU X, LI S, et al. Lithium-ion battery health estimation with real-world data for electric vehicles[J]. Energy, 2023, 270: 126855.
- [2] 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.
- [3] 李强龙, 孙建瑞. 基于 IALO-SVR 的锂电池健康状态预测[J]. 电子测量与仪器学报, 2022, 36(1): 204-211.
- [4] 李文华, 邵方旭, 暴二平, 等. 六自由度振动老化条件下锂离子电池的衰退机理诊断与 SOH 预测[J]. 仪器仪表学报, 2021, 41(8): 62-69.
- [5] DONG G, HAN W, WANG Y. Dynamic Bayesian network based lithium-ion battery health prognosis for electric vehicles[J]. IEEE Transactions on Industrial Electronics, 2020, 68(11): 10949-10958.
- [6] 陈璐, 于仲安, 熊莹燕. 不同温度下基于 PSO-LSSVM 的锂电池 SOH 估计与 RUL 预测[J]. 传感器与微系统, 2023, 42(6): 141-145.
- [7] 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.
- [8] WANG D H, LI M. Stochastic configuration networks: fundamentals and algorithms[J]. IEEE Transactions on Cybernetics, 2017, 47(10): 3466-3479.
- [9] 郑雪莹, 邓晓刚, 曹玉苹. 基于能量加权高斯过程回归的锂离子电池健康状态预测[J]. 电子测量与仪器学报, 2020, 34(6): 63-69.
- [10] 郭喜峰, 王凯泽, 单丹, 等. 多角度基于 CEEMDAN-CNN-BiLSTM 模型的锂离子电池 RUL 预测[J]. 太阳能学报, 2023, 9(10): 1299-1306.
- [11] 崔素晓, 崔彦平. 基于 MVMD-MOMEDA 的齿轮箱故障诊断方法[J]. 河北科技大学学报, 2023, 44(6): 551-561.
- [12] 廖子豪, 于丽娅, 李少波, 等. 基于 SCN 的锂电池剩余寿命预测[J]. 组合机床与自动化加工技术, 2022, (5): 146-150.
- [13] TROJOVSKÁ E, DEHGHANI M, TROJOVSKY P. Zebra optimization algorithm: A new bio-inspired optimization algorithm for solving optimization algorithm[J]. IEEE Access, 2022, 10: 49445-49473.
- [14] 徐佳宁, 倪裕隆. 基于改进支持向量回归的锂电池剩余寿命预测[J]. 电工技术学报, 2021, 36(17): 3693-3704.
- [15] 严爱军, 于小. 基于混沌反馈乌燕鸥优化算法的随机配置网络参数优化[J]. 北京工业大学学报, 2023, 49(7): 746-757.

作者简介

郭喜峰, 博士, 教授, 主要研究方向为新能源负荷管理和储能研究。

E-mail: guoxifeng@stu. sjzu. edu. cn

黄裕海, 硕士研究生, 主要研究方向为锂电池储能和健康状态预测。

E-mail: hai15877178782@163. com

单丹(通信作者), 博士, 副教授, 主要研究方向为能源负荷管理。

E-mail: shandan0405@stu. sjzu. edu. cn

原宝龙, 硕士研究生, 高级工程师(教授级), 主要研究方向为电池储能技术。

E-mail: yuanbaolong@stu. sjzu. edu. cn

宁一, 博士, 讲师, 主要研究方向为能源负荷管理和新能源发电。

E-mail: vipningyi@stu. sjzu. edu. cn