

DOI:10.19651/j.cnki.emt.2417444

基于改进白鲸算法优化 BiTCN-BiGRU 的 锂电池 SOC 估计

柳 博^{1,2} 吴松荣^{1,2} 付 聪^{1,2} 王少惟^{1,2} 张 驰^{1,2}

(1. 磁浮技术与磁浮列车教育部重点实验室 成都 610031; 2. 西南交通大学电气工程学院 成都 611756)

摘要: 电池荷电状态(SOC)是电动汽车锂电池管理的核心参数之一,本文提出一种基于改进白鲸算法优化 BiTCN-BiGRU 的锂电池 SOC 估计模型。首先搭建双向时域卷积网络(BiTCN)和双向门循环单元(BiGRU)组合的 SOC 估计模型,然后使用白鲸算法(BWO)对 BiTCN-BiGRU 模型超参数寻优以充分发挥组合网络模型的优势,并且分别在传统 BWO 的探索阶段和鲸落阶段引入改进策略以解决传统 BWO 容易陷入局部最优且收敛速度慢的问题。最后基于开源锂电池充放电数据集验证改进后 SOC 估计模型的性能,结果表明在 3 种温度的标准化城市循环工况下,改进白鲸算法优化 BiTCN-BiGRU 模型的 SOC 估计平均绝对误差为 0.428%,均方根误差为 0.38%,能很好的应用于锂电池 SOC 估计。

关键词: 锂电池;SOC 估计;BiTCN 网络;BiGRU 网络;白鲸优化算法

中图分类号: TM912;TN98 **文献标识码:** A **国家标准学科分类代码:** 470.40

SOC estimation of lithium batteries based on BiTCN-BiGRU optimized by improved beluga whale algorithm

Liu Bo^{1,2} Wu Songrong^{1,2} Fu Cong^{1,2} Wang Shaowei^{1,2} Zhang Chi^{1,2}

(1. Key Laboratory of Magnetic Suspension Technology and Maglev Vehicle, Ministry of Education, Chengdu 610031, China;

2. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China)

Abstract: The state of charge (SOC) of the battery is one of the core parameters for managing lithium batteries in electric vehicles. This paper proposes a lithium battery SOC estimation model based on an improved white whale algorithm optimized BiTCN-BiGRU. Firstly, a SOC estimation model combining bidirectional time domain convolutional network (BiTCN) and bidirectional gated recurrent unit (BiGRU) is constructed. Then, the beluga whale optimization (BWO) is used to optimize the hyperparameters of the BiTCN-BiGRU model to fully leverage the advantages of the combined network model. Improvement strategies are introduced in the exploration and whale fall stages of traditional BWO to solve the problem of traditional BWO easily falling into local optima and slow convergence speed. Finally, the performance of the improved SOC estimation model was verified based on the open-source lithium battery charging and discharging dataset. The results showed that under standardized urban cycling conditions at three temperatures, the improved white whale algorithm optimized the BiTCN-BiGRU model SOC estimation with an average absolute error of 0.428% and a root mean square error of 0.38%, which can be well applied to lithium battery SOC estimation.

Keywords: Lithium batteries;SOC estimation;BiTCN network;BiGRU network;beluga whale optimization algorithm

0 引言

近年来,锂电池广泛应用于电动汽车行业,对其状态进行监测是确保电动汽车高效和安全运行的重要保障^[1]。荷电状态(state of charge, SOC)作为反映锂电池状态的关键

参数,准确估计 SOC 不仅能够有效防止电池过充或过放,避免电池失效引发的安全事故,还能优化充放电策略,提升电池使用效率和经济性,从而满足电动汽车对高效能量管理和长期稳定运行的迫切需求。

目前常用的 SOC 估计方法包括直接测量法、模型法和

数据驱动法。直接测量法属于开环估计的一种,其典型方法包括开路电压法与安时积分法^[2]。基于开路电压法的 SOC 估计方法中,需要长时间电池静置而难以满足实时估计要求^[3]。安时积分法是目前常作为理论参考值的 SOC 估计方法,它具有计算简单、易于实现等优点,但该方法对 SOC 初值精度要求较高,随着时间的推移,低精度的 SOC 初始值将导致 SOC 估计误差的累积^[4]。模型法在 SOC 估计中对电池建模和参数识别要求严格^[5-6],因此操作复杂度较高。数据驱动法无需复杂的建模过程,同时具有较好的估计精度,但现有组合模型在处理长时间序列数据时仍面临梯度消失,缺乏高效的超参数优化算法等问题。张心成等^[7]将一维卷积层嵌入门控循环单元(gated recurrent unit, GRU),经 SOC 估计实验结果表明,该模型在多种工况下有良好的估计精度。周丹等^[8]使用双向门控循环神经网络(bidirectional gated recurrent unit, BiGRU)对电池 SOC 进行估计,BiGRU 可以对时间序列信息进行双向学习,能更好的捕捉锂电池动态特性以提高估计精度。王升晖等^[9]将卷积神经网络(convolutional neural networks, CNN)与 GRU 进行组合,通过 CNN 模块提取局部特征与 GRU 模块提取时序特征结合起来进行锂电池的 SOC 估计,实验结果证明该组合模型的估计精度要优于单一模型。然而组合模型可能出现梯度消失和梯度爆炸的问题,且计算效率不够高、难以捕捉长时间序列数据的依赖关系。时序卷积网络(temporal convolutional network, TCN)作为 CNN 模型的变体,很大程度上缓解了梯度消失或梯度爆炸的影响,能够更好地捕捉长期的时序关系,为组合网络模型提供了新的思路^[10]。针对单一 TCN 无法学习当前特征项

与后面特征项之间的关联,卞玉露等^[11]提出的双向时域卷积网络(bidirectional temporal convolutional networks, BiTCN)可以从两个方向提取时序特征。此外,网络超参数对 SOC 的预测结果也有显著影响,刘齐等^[12]使用改进后的麻雀搜索算法寻找预测模型的最优参数,提高了模型对 SOC 的估计精度。综上,组合网络模型对锂电池充放电长时间序列数据的特征提取能力和全局信息捕捉能力更强,但需要性能良好的超参数寻优算法选取组合网络模型的最优超参数以提高 SOC 估计精度。

因此,本文提出基于改进白鲸算法(improved beluga whale optimization, IBWO)优化 BiTCN-BiGRU 的电池 SOC 估计方法。针对白鲸算法存在局部探索不足和在迭代后期会陷入局部最优等问题,采用 Circle 映射改进种群位置初始化策略和柯西高斯变异策略提高白鲸优化算法的超参数寻优性能,以充分发挥 BiTCN-BiGRU 组合网络提取特征以及挖掘时间序列信息相关性的能力,进一步提高估计精度。最后基于开源锂电池数据集对比分析 GRU、BiTCN-BiGRU、BWO-BiTCN-BiGRU 以及 IBWO-BiTCN-BiGRU 4 种 SOC 估计模型,结果表明改进得到的 IBWO-BiTCN-BiGRU 模型具有良好的稳定性和估计精度。

1 基于 BiTCN-BiGRU 组合网络的 SOC 估计

1.1 BiTCN-BiGRU 组合网络

本文将 BiTCN 与 BiGRU 组合作为 SOC 估计的基础模型,其主要结构如图 1 所示。BiTCN-BiGRU 组合网络由 BiTCN 模块、Dropout 层、展平层、BiGRU 模块和全连接层组成。

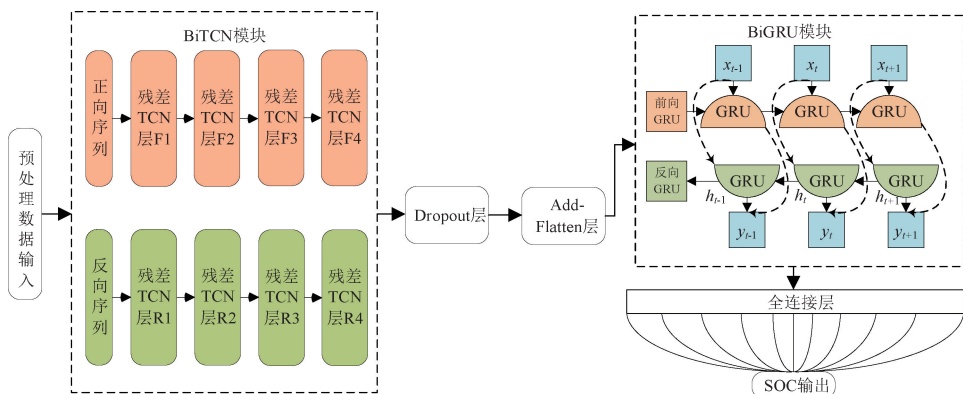


图 1 BiTCN-BiGRU 组合网络模型结构

Fig. 1 BiTCN-BiGRU combinatorial network model structure

图 1 中 BiTCN 模块用于对数据进行特征提取。Dropout 层是一种常用的深度学习正则化技术,其作用为每次迭代随机关闭一部分神经元(通常是全连接层)使其不参与计算,可有效防止模型过拟合。展平层把 BiTCN 模块的多维输出数据转换为一维的向量,便于后续数据输入 BiGRU 模块进行学习。全连接层输出预测结果,其与

BiGRU 模块输出的状态信息一一对应。上述神经网络层将 BiTCN 模块与 BiGRU 模块组合,以发挥 BiTCN-BiGRU 组合网络的优势:

1) BiTCN 模块获取正反两个传播方向之间数据的依赖关系,加强了组合网络的特征提取能力。BiTCN 模块在 TCN 的基础上保留因果膨胀卷积和残差连接^[13]。一方面

通过正向数据学习数据从前到后的依赖关系,另一方面通过逆向数据学习数据从后到前的依赖关系,然后将两个方向提取到的特征融合并输入到 BiGRU 模块。

2)BiGRU 模块捕捉长时间序列正反向信息,更全面地理解时序数据,进而提高组合网络预测精度。BiGRU 模块本质上由双层 GRU 网络组成,其中前向 GRU 层通过前向传播将时间序列输入到网络中,挖掘数据的前向关联特性。在逆向 GRU 层中,输入序列通过反向传播进行训练,挖掘数据的逆向相关性^[14]。

1.2 基于 BiTCN-BiGRU 的 SOC 估计流程

搭建基于 BiTCN-BiGRU 组合网络的 SOC 估计模型,以电池的电压、电流、温度作为模型输入,电池 SOC 为输出。首先对电池数据进行预处理划分为训练集和测试集,然后将训练集输入到 BiTCN-BiGRU 组合网络中进行训练,最后将测试集输入到训练好的网络得到 SOC 估计结果,整体 SOC 估计流程如图 2 所示。

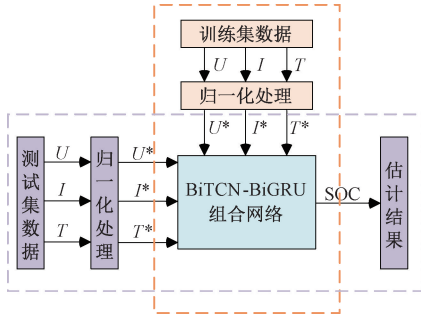


图 2 基于 BiTCN-BiGRU 的估计流程

Fig. 2 Estimation process based on BiTCN-BiGRU

对于本文所搭建的 BiTCN-BiGRU 组合网络模型,其超参数直接影响着网络的性能,而超参数通常依据经验设定,缺乏统一标准,泛化性能较差。因此,为提高 BiTCN-BiGRU 组合网络模型的 SOC 估计性能,需重点关注其超参数的优化选取问题。

2 基于改进 BiTCN-BiGRU 的 SOC 估计

本文采用改进的种群优化算法对 BiTCN-BiGRU 组合网络进行超参数寻优,以提升 SOC 的估计模型的估计精度。

2.1 多策略改进传统白鲸优化算法

传统白鲸优化算法 (beluga whale optimization, BWO) 通过模拟白鲸的觅食行为,从探索、开发和鲸落 3 个阶段,建立位置更新数学模型以求解优化问题,其相比众多传统优化算法有更好的寻优性能^[15]。但传统 BWO 在对复杂模型寻优时存在陷入局部最优且收敛速度慢的问题,为了进一步提升算法的求解能力,本文在传统 BWO 的探索阶段和鲸落阶段进行改进。BWO 算法及其改进过程如下:

1) 引入 Circle 映射的种群初始化

传统 BWO 算法在探索阶段采用随机初始化操作生成初始种群,根据位置的奇偶数采用不同的位置更新,其公式为:

$$\begin{cases} X_{i,j}^{T+1} = X_{i,p}^T + (X_{r,p}^T - X_{i,p}^T)(1 + r_1)\sin(2\pi r_2), j \text{ 为偶数} \\ X_{i,j}^{T+1} = X_{i,p}^T + (X_{r,p}^T - X_{i,p}^T)(1 + r_1)\sin(2\pi r_2), j \text{ 为奇数} \end{cases} \quad (1)$$

式中: $X_{i,j}^{T+1}$ 为 i 白鲸在 j 维上的位置; $X_{i,p}^T$ 为 i 白鲸在 p 维上的位置, p 是从维度中选取的随机数; $X_{i,p}^T$ 和 $X_{r,p}^T$ 分别为 i 和 r 白鲸的当前位置; r_1 和 r_2 为 $(0,1)$ 的随机数; T 为当前迭代次数。

然而传统 BWO 的随机初始化操作会导致生成的初始种群在整个解空间上分布不均匀,因此本文采用 Circle 映射对初始化方法进行改进。Circle 映射可用于生成 $0 \sim 1$ 之间的混沌数,且生成的混沌序列有较高的区域覆盖性,改进的初始化策略的公式为:

$$X_{n+1} = \text{mod}\left(X_n + 0.5 - \frac{0.2}{2\pi}\sin(2\pi X_n), 1\right) \quad (2)$$

式中: X_n 为第 n 个混沌数, mod 为取余函数。改进前后白鲸种群均匀性对比如图 3 所示,对比可知提出的改进初始化策略能够使 BWO 算法的初始种群更加充分且均匀地分布在解空间内。




图 3 改进前后白鲸种群均匀性对比

Fig. 3 Comparison of beluga whale population uniformity before and after improvement

2) 基于平衡因子过渡的局部开发阶段

在传统 BWO 算法中平衡因子 B_f 在全局探索阶段与局部开发阶段之间起过渡作用,当平衡因子 $B_f > 0.5$ 时,白鲸进入探索阶段;当平衡因子 $B_f < 0.5$ 时,进入开发阶段。其公式为:

$$B_f = B_0 \cdot \left(1 - \frac{T}{T_{\max}}\right) \quad (3)$$

式中: T 为当前迭代次数; T_{\max} 为最大迭代次数; B_0 在每次迭代时在 $(0,1)$ 之间随机变化。

在平衡因子 $B_f < 0.5$ 时,进入白鲸觅食的开发阶段,此阶段白鲸通过相互共享位置信息来捕食,从而引入最佳位置和其他位置,其数学模型公式为:

$$X_i^{T+1} = r_3 X_{\text{best}}^T - r_4 X_i^T + C_1 L_F (X_r^T - X_i^T) \quad (4)$$

$$L_F = 0.05 \times \frac{u \times \sigma}{|v|^{1/\beta}} \quad (5)$$

$$\sigma = \left(\frac{\Gamma(1+\beta) \times \sin(\pi\beta/2)}{\Gamma((1+\beta)/2) \times \beta \times 2^{(\beta-1)/2}} \right)^{1/\beta} \quad (6)$$

式中: X_i^T 和 X_r^T 分别为 i 白鲸和随机白鲸的当前位置;

X_i^{T+1} 为 i 白鲸的更新位置; X_{best}^T 为白鲸中最佳位置; r_3 和 r_4 为 $(0,1)$ 的随机数; C_1 为 Levy 飞行的随机跳跃强度; u 和 v 为正态分布的随机数; β 为 1.5 的默认常量。

3) 采用柯西高斯进化最优白鲸个体

传统 BWO 算法在经历探索、开发阶段后, 还要经过鲸落阶段来得到最优的参数, 该阶段模拟每次迭代中鲸落的行为, 利用白鲸的位置和鲸落的步长来建立更新位置。该数学模型的公式为:

$$X_I^{T+1} = r_5 X_i^T - r_6 X_r^T + r_7 X_{step} \quad (7)$$

$$X_{step} = (u_b - l_b) \exp\left(-\frac{C_2 T}{T_{max}}\right) \quad (8)$$

式中: r_5 、 r_6 和 r_7 为 $(0,1)$ 的随机数; X_{step} 为鲸落的步长; u_b 和 l_b 分别为优化问题的上下限; C_2 为与鲸落概率和种群规模有关的阶跃因子。在模型中, 将鲸落的概率 W_f 用线性函数表示的公式为:

$$W_f = 0.1 - 0.05 \cdot \frac{T}{T_{max}} \quad (9)$$

由式(9)可知, 传统 BWO 算法在每次迭代中都存在白鲸坠落的概率, 会造成迭代过程中白鲸种群的局部最优停滞, 全局搜索能力大幅下降。因此本文通过引入柯西高斯变异策略来进化种群中的最优个体, 并将其位置作为下一次迭代的起点^[16]。高斯分布(Gauss)和柯西分布(Cauchy)均适合作为数据扰动的方法, 高斯、柯西分布的公式分别为:

$$G(\alpha_1) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{\alpha_1^2}{2\sigma^2}} \quad (10)$$

$$C(\alpha_2) = \frac{1}{\pi(\alpha_2^2 + 1)} \quad (11)$$

式中: α_1 为 $[0,1]$ 之间的随机数; σ 是标准差; α_2 为 $[-\infty, +\infty]$ 之间的随机数。柯西高斯突变进化策略有助于白鲸算法更好地逃离局部最优, 并进一步提升算法的性能和优化能力。变异进化策略的公式为:

$$X_{best}^{T+1} = X_{best}^T [1 + s_1 \text{Cauchy}(0, \eta^2) + s_2 \text{Gauss}(0, \eta^2)] \quad (12)$$

$$\eta = \begin{cases} 1, f(X_{best}^T) < f(X_i^T) \\ \exp\left(\frac{f(X_{best}^T) - f(X_i^T)}{|X_{best}^T|}\right), f(X_{best}^T) \geq f(X_i^T) \end{cases} \quad (13)$$

式中: X_{best}^{T+1} 是变异后的最佳白鲸位置; X_{best}^T 是当前迭代中最佳白鲸位置; $\text{Cauchy}(0, \eta^2)$ 是柯西随机变量; $\text{Gauss}(0, \eta^2)$ 是高斯分布随机变量; η^2 为柯西高斯变异的标准差; s_1 和 s_2 分别为自适应迭代参数。

结合 BWO 算法的基本步骤以及上述改进策略, 即可得 IBWO 算法, 其主要流程如图 4 所示。

2.2 IBWO 算法的有效性验证

采用的 3 种标准测试函数分别为单峰测试函数 F_1 、多峰测试函数 F_2 以及固定多峰测试函数 F_3 , 其公式为:

$$F_1 = \sum_{i=1}^n x_i^2 \quad (14)$$

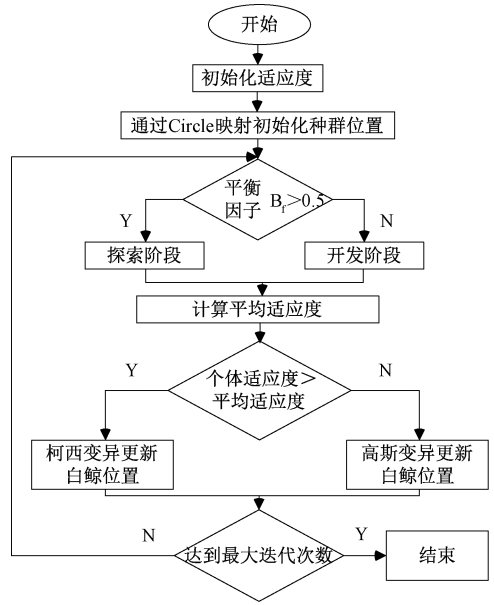


图 4 IBWO 算法主要流程

Fig. 4 Main process of the IBWO algorithm

$$F_2 = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10] \quad (15)$$

$$F_3 = \left(\frac{1}{500} + \sum_{i=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right)^{-1} \quad (16)$$

其中, 函数 F_1 用于测试算法在局部探索和开发方面的能力, 函数 F_2 用于测试全局搜索和局部最优逃逸方面的能力, 函数 F_3 用于测试稳定性^[17]。

现将改进的白鲸优化算法 (IBWO) 与传统白鲸优化算法 (BWO)、鲸鱼优化算法 (WOA) 和粒子群算法 (PSO) 进行实验分析对比以验证改进算法的有效性, 所得的测试函数实验结果如表 1 所示。

表 1 测试函数模型实验结果

Table 1 Test function experimental results				
评价指标	算法	F_1	F_2	F_3
最佳值	BWO	0	0	0
	PSO	0	8.88×10^{-16}	0
	WOA	0	8.88×10^{-16}	0
	IBWO	0	0	0
平均值	BWO	2.00×10^{-75}	0	4.44×10^{-16}
	PSO	1.07×10^2	8.89×10^2	2.01×10^{-1}
	WOA	1.15×10^{-27}	1.33×10^{-5}	1.23×10^{-2}
	IBWO	4.93×10^{-134}	0	4.44×10^{-16}
标准差	BWO	1.09×10^{-134}	0	0
	PSO	5.97×10^{-5}	2.71×10^{-1}	1.99×10^{-1}
	WOA	2.05×10^{-27}	2.71×10^{-5}	2.04×10^{-1}
	IBWO	0	0	0

为保证公平性 4 种算法的共有参数和约束条件保持一致,其中种群规模设置为 50,最大迭代次数设置为 300。同时,对每个测试函数重复运行 30 次,从结果的平均值、标准差和最佳值 3 个方面进行评估。其中,算法的平均值越小则表明其全局搜索效率更高,标准差反映了算法在多次实验中的鲁棒性,而最佳值则代表算法在单次运行中的极限性能。

由表 1 可知,IBWO 算法总体性能表现较为突出。其

中 F_1 的测试结果表明 IBWO 算法的平均值最接近测试函数的最优解; F_2 的测试结果中,只有 IBWO 算法和 BWO 算法达到了最优值; F_3 的结果表明 IBWO 算法在处理复杂模型时具有较强的性能,并且有跳出局部最优的能力。相对于 BWO 算法、WOA 算法和 PSO 算法,IBWO 算法具有更好的局部最优逃逸能力和全局搜索能力。

取测试结果中与平均值相近的一次绘制上述 4 种优化算法基于标准测试函数的收敛曲线如图 5 所示。




图 5 不同优化算法基于标准测试函数的收敛曲线

Fig. 5 Convergence curves of different optimization algorithms based on standard test functions

由图 5 可知, F_1 和 F_2 的测试结果中 4 种优化算法均未收敛,但 IBWO 在迭代初期迅速接近最优解,表明 IBWO 有更迅速的寻优能力; F_3 的结果表明,IBWO 在 231 次迭代时达到收敛,收敛最快且精度最高。

因此本文选择性能较优的 IBWO 算法对 BiTCN-BiGRU 进行优化,从而减少人工调参带来的偏差。

2.3 基于 IBWO-BiTCN-BiGRU 的 SOC 估计流程

引入 IBWO 算法对 BiTCN-BiGRU 模型的残差连接层数、膨胀系数和网络单元数等超参数进行优化,BiTCN-BiGRU 超参数搜索区间如表 2 所示。

表 2 BiTCN-BiGRU 超参数搜索区间

Table 2 Hyperparameter search range for BiTCN-BiGRU

超参数	寻优范围
批量大小	[20,500]
初始学习率	[0.001,0.1]
优化器	SGD,Adam
残差连接层数	2+2,4+4
膨胀系数	1,2,4,8
BiTCN 单元数	2,4,8
BiGRU 单元数	16,32,64
全连接层	激活函数:Sigmoid、ReLU

基于 IBWO 优化 BiTCN-BiGRU 的 SOC 估计方法流程如图 6 所示。

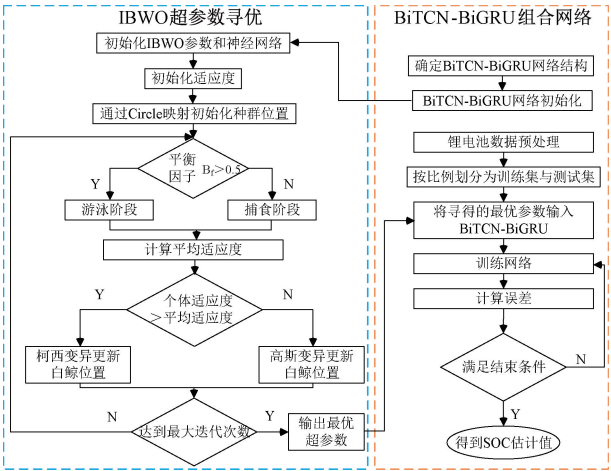


图 6 IBWO 优化 BiTCN-BiGRU 的 SOC 估计方法流程

Fig. 6 The process flow of SOC estimation method based on IBWO-optimized BiTCN-BiGRU

主要步骤如下:

步骤 1) 锂电池数据预处理,随机将其划分为训练样本集和测试样本集,并进行数据归一化;

步骤 2) 设置 IBWO 算法的种群规模、搜索维度、最大迭代次数和 BiTCN-BiGRU 的超参数寻优范围,结合改进的初始化策略使白鲸种群达到均匀分布;

步骤 3) 以准确率为适应度,计算当前超参数下每只白鲸的适应度最优值以记录位置;

步骤 4) 全局探索阶段和局部开发阶段。当 $B_f > 0.5$,

进入全局探索阶段,使用式(2)更新白鲸位置;否则进入局部开发阶段,使用式(4)更新白鲸位置;

步骤 5)计算更新后的白鲸位置的适应度值。若更新后的适应度值更佳,则更新白鲸个体的最优适应度,否则使用式(12)、(13)继续训练;

步骤 6)判断是否满足终止条件。若满足,则保留最优超参数,并将其赋予 BiTCN-BiGRU,否则返回步骤 5);

步骤 7)使用经由 IBWO 寻优所得最优超参数建立 BiTCN-BiGRU 组合网络 SOC 估计模型,并利用测试数据集进行验证实验,最后评估实验结果。

3 改进后的模型验证与分析

3.1 数据集和数据处理

为验证本文所提出的 IBWO-BiTCN-BiGRU 模型的可行性,选用麦克马斯特大学汽车研究与技术研究所(McMaster University McMaster Institute for Automotive Research and Technology)的开源电池测试数据集作为研究目标^[18]。该数据集在多个不同工况下对 LG18650HG2 型号电池进行了充放电测试实验。每个电池测试工况数据集都包含时间、电流、电压、温度和容量等测试数据。LG18650HG2 型号电池的各个参数如表 3 所示。

表 3 LG 18650HG2 的主要参数

Table 3 Main parameters of LG 18650HG2

电池参数	值
额定容量/电压	3.0 Ah / 3.6 V
充电和放电截止电压	4.2 V / 2.5 V
充电截止电流	50 mA
最大可持续放电电流	20 A
标准充电电流	1.5 A
能量密度	240 Wh/Kg

本文选取在 0℃、25℃和 40℃ 3 种温度下美国联邦环保署(USEPA)标准化城市循环(Urban Dynamometer Driving Schedule, UD DS)的电动汽车模拟工况测试数据进行模型验证。图 7(a)~(d)分别为 UD DS 动态测试工况的测试数据中的电压、电流、容量、温度曲线,由图 7 可知电池在放电过程中容量与电流、电压和温度 3 个测量信号之间呈现高度的非线性关系,且 25℃和 40℃温度下的放电容量明显大于 0℃温度下的放电容量。这说明随着温度的下降,电池内部的化学反应变得缓慢,实际放出的容量值逐渐减少。同时工况数据集中的电流、电压和温度 3 个测量信号波动幅度较大,因此需要对数据进行归一化处理以缩小输入数据的数值范围从而降低计算复杂度,提高数值稳定性。

本文采用 mapminmax 函数将 3 个特征数据归一到

[0,1]之间,其数学公式为:

$$x_{normal} = (x_{signal} - x_{min}) / (x_{max} - x_{min})$$

(17)

式中: x_{min} 和 x_{max} 为特征向量中的最小值和最大值, x_{signal} 为数据中的真实测量数据, x_{normal} 为归一化之后的数据。选取电池电流、电压及温度作为输入, SOC 作为输出。其中 SOC 理论参考值是通过安时积分法得到的,其计算过程如下:

$$SOC(t) = SOC(t_0) - \int_{t_0}^t \eta I_t / C d\tau$$


(18)

式中: $SOC(t_0)$ 为初始 SOC 值,数据集中的充电工况 $SOC(t_0)$ 为 0,放电工况 $SOC(t_0)$ 为 1, $SOC(t)$ 为当前 t 时刻时的 SOC 值, η 库伦倍率为 1, I_t 为 t 时刻流过电池的电流, C 为各个工况电池的容量值。


将 UD DS 动态测试工况数据划分为训练集和测试集,将其中 90%作为训练集,余下 10%作为测试集。0℃、25℃和 40℃分别有 14 043、15 965、15 895 组数据。

3.2 IBWO-BiTCN-BiGRU 模型实验验证分析

为了比较不同模型之间的性能差别,本文采用平均绝对误差 (E_{MAE}) 和均方根误差 (E_{RMSE}) 作为估计模型的评价



(a) 电压曲线
(a) Voltage curve



(b) 电流曲线
(b) Current curve

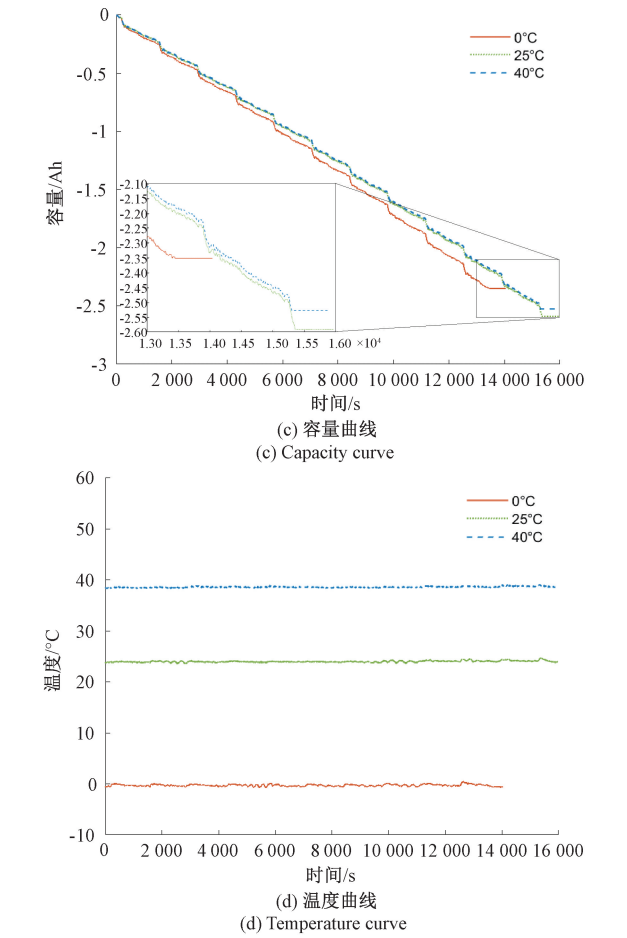


图 7 UDDS 动态测试工况数据曲线

Fig. 7 UDDS dynamic test cycle data curve

价指标,其计算公式为:

$$E_{MAE} = \frac{1}{n} \sum_{t=1}^n |T_t - O_t| \tag{19}$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (T_t - O_t)^2} \tag{20}$$

式中: n 为样本数; T_t 为真实值; O_t 为估计值。

1)实验环境配置

本文在 MATLAB2023 环境下进行实验,所用工具和函数均来自 MATLAB 深度学习工具箱及相关扩展包,具体实验配置如表 4 所示。

表 4 实验环境配置

参数	配置
CPU	Intel i5-8400
GPU	GeForce GTX1060
系统环境	Windows10
加速环境	CUDA9.2

2)模型参数设置

本次实验在 MATLAB 软件中搭建 GRU、BiTCN-BiGRU 和 BWO-BiTCN-BiGRU 3 种模型与 IBWO-BiTCN-BiGRU 模型进行对比。其中本文提出的 IBWO-BiTCN-BiGRU 模型进行超参数寻优后设置最优参数如表 5 所示。

表 5 BiTCN-BiGRU 最优组合参数

Table 5 Optimal combination parameters for BiTCN-BiGRU

超参数	值
批量大小	256
初始学习率	0.003
优化器	Adam
残差连接层数	4+4
膨胀系数	2
BiTCN 单元数	2
BiGRU 单元数	64
全连接层	激活函数:Sigmoid

3)25℃ UDDS 工况下模型估计性能分析

为测试模型的 SOC 估计性能,基于 25℃ 下 UDDS 工况数据对各模型进行对比验证,估计曲线如图 8 所示。

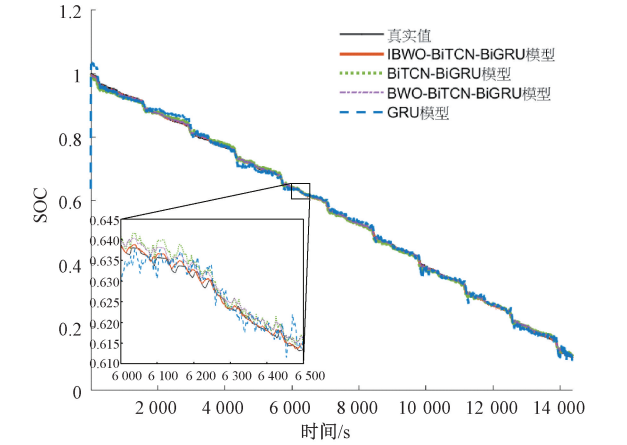


图 8 25℃ UDDS 工况估计曲线

Fig. 8 Estimation curves under 25°C UDDS conditions

由图 8 可知,基于 GRU 模型的 SOC 估计结果相较于另外 3 种组合模型波动较为明显,各模型的误差评价指标如表 6 所示。

表 6 各模型的误差评价指标

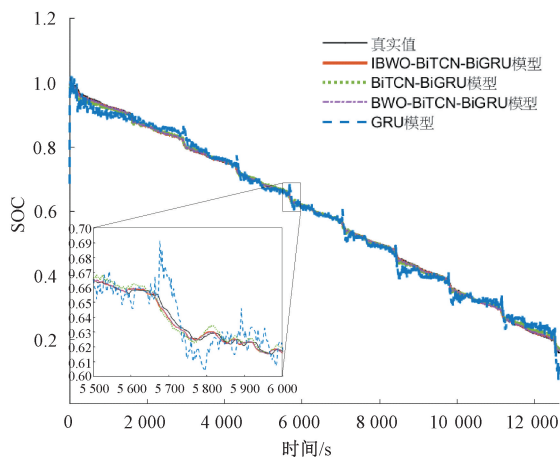
模型	$E_{MAE} \%$	$E_{RMSE} \%$
GRU	1.630	1.316
BiTCN-BiGRU	0.986	0.913
BWO-BiTCN-BiGRU	0.673	0.598
IBWO-BiTCN-BiGRU	0.428	0.380

由表 6 可知,IBWO-BiTcn-BiGRU 模型估计的 E_{MAE} 与 E_{RMSE} 最低,其中 E_{MAE} 相较于 GRU 模型和 BiTCN-BiGRU 模型分别降低了 73.74% 和 56.59%, E_{RMSE} 分别降低了 71.12% 和 58.37%。

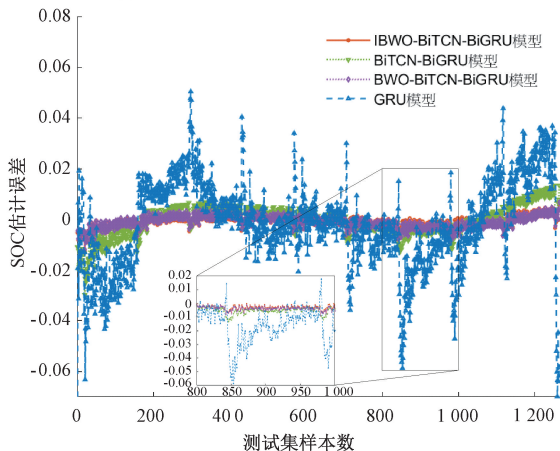
4) 不同温度 UDDS 工况下模型估计性能分析

将 0℃ 和 40℃ 下的 UDDS 工况数据对各估计模型进行对比分析。0℃ 和 40℃ 环境温度下各模型的估计曲线与估计误差曲线分别如图 9(a)、(b) 和图 10(a)、(b) 所示。

由图 9 和 10 可知,在不同温度下基于 BWO 与 BiTCN-BiGRU 组合模型的 SOC 估计模型在估计精度和稳定性上均优于 GRU 模型和 BiTCN-BiGRU 模型,但 BWO 算法存在陷入局部极值的问题,难以在 SOC 估计过程中实现全局优化,改进后的 IBWO-BiTcn-BiGRU 模型估计精度和稳定性都进一步得到提升。



(a) 0℃ UDDS 工况估计曲线
(a) Estimation curves under 0℃ UDDS conditions




(b) 0℃ UDDS 工况估计误差曲线
(b) Estimation error curves under 0℃ UDDS conditions

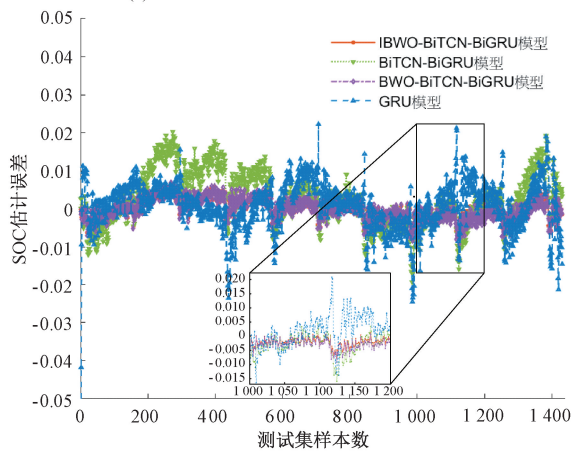
图 9 0℃ 下 UDDS 工况估计结果

Fig. 9 Estimation results under 0℃ UDDS conditions

综上,本文使用改进的 IBWO 对 BiTCN-BiGRU 模型进行超参数寻优后,SOC 估计模型的精度和稳定性有明显提升。



(a) 40℃ UDDS 工况估计结果
(a) Estimation curves under 40℃ UDDS conditions



(b) 40℃ UDDS 工况估计误差曲线
(b) Estimation error curves under 40℃ UDDS conditions

图 10 40℃ 下 UDDS 工况估计结果

Fig. 10 Estimation results under 40℃ UDDS conditions

4 结 论

针对锂电池 SOC 估计对模型估计精度高的要求,本文提出基于 IBWO-BiTcn-BiGRU 模型的 SOC 估计模型。基于 UDDS 工况数据对比 4 种 SOC 估计模型,得出以下结论:

本文提出的 IBWO 算法,能有效解决传统 BWO 对复杂模型寻优时存在陷入局部最优且收敛速度慢的问题,提高算法的寻优性能。同时通过实验验证了利用 IBWO 优化 BiTCN-BiGRU 模型使锂电池 SOC 估计精度有效提升,在 UDDS 工况下,IBWO-BiTcn-BiGRU 模型的 SOC 估计性能明显优于 GRU 模型、BiTCN-BiGRU 模型和 BWO-BiTcn-BiGRU 模型。且在不同温度条件下 IBWO-BiTcn-BiGRU 模型同样展现出优异的估计精度,证明了其在锂电池 SOC 估计中的适用性。

参考文献

[1] 和承英. 动力锂电池在电动汽车中的应用分析[J]. 汽

- 车知识,2024,24(11):17-19.
- HE CH Y. Analysis of the application of power lithium batteries in electric vehicles[J]. Automotive Knowledge,2024,24(11):17-19.
- [2] 崔相东,黄彦淇,郭小玫. 锂电池剩余电量估算方法及应用研究综述[J]. 电子测量技术,2024,47(20):41-59.
- CUI X D, HUANG Y Q, WU X M. Overview of state-of-charge estimation methods and application for Lithium-ion batteries [J]. Electronic Measurement Technology,2024,47(20):41-59.
- [3] PRATIMA D. Maximum power tracking based open circuit voltage method for PV system[J]. Energy Procedia, 2016,90:2-13.
- [4] ZHANG X, HOU J W, WANG Z K, et al. Study of SOC estimation by the ampere-hour integral method with capacity correction based on LSTM [J]. Batteries,2022,8(10):170.
- [5] 海涛,范攀龙,王钧. 基于联合 EKF-UKF 算法的锂电池 SOC 预估研究[J]. 电源技术,2023,47(11):1424-1428.
- HAI T, FAN P L, WANG J. SOC estimation of lithium battery based on joint EKF-UKF algorithm[J]. Chinese Journal of Power Sources,2023,47(11):1424-1428.
- [6] CUI D W. Vehicle state and parameter estimation based on double cubature Kalman filter algorithm[J]. Journal of Vibroengineering,2022,24(5):936-951.
- [7] 张心成,李翔晟,李藏龙,等. 基于改进 GRU 模型算法的锂电池 SOC 估计[J]. 电子测量技术,2023,46(11):57-65.
- ZHANG X CH, LI X SH, LI C L, et al. SOC estimation of lithium battery based on improved gated recurrent unit model algorithm [J]. Electronic Measurement Technology,2023,46(11):57-65.
- [8] 周丹,祝乔,冯雄,等. 基于 BiGRU 和 PF 的锂电池 SOC 估计[J]. 电工技术,2022(18):80-82.
- ZHOU D, ZHU Q, FENG X, et al. Estimation of lithium battery SOC based on BiGRU and PF [J]. Electric Engineering,2022(18):80-82.
- [9] 王升晖,田庆,刘力豪,等. 融合注意力机制的 CNN-GRU 动车组蓄电池 SOC 估算方法[J]. 控制与信息技术,2023(5):83-90.
- WANG SH H, TIAN Q, LIU L H, et al. CNN-GRU battery SOC estimation method fused with attention mechanism for electric multiple units[J]. Control and Information Technology,2023(5):83-90.
- [10] 刘少卿,李帅,苗建国,等. 基于 TCN-BiGRU 的锂离子电池健康状态评估[J]. 电子测量技术,2023,46(23):68-76.
- LIU SH Q, LI SH, MIAO J G, et al. Lithium-ion battery state of health estimation based on TCN-BiGRU [J]. Electronic Measurement Technology, 2023,46(23):68-76.
- [11] 卞玉露. 面向文本情感分析的 BiTCN-SA 模型的研究[J]. 佳木斯大学学报(自然科学版),2022,40(6):38-42,67.
- BIAN Y L. Research on BiTCN-SA model for text emotion analysis [J]. Journal of Jiamusi University (Natural Science Edition),2022,40(6):38-42,67.
- [12] 刘齐,吴松荣,邓鸿彬,等. 基于 ASSA-RBF 联合算法的三元锂离子电池 SOC 估计[J]. 电子测量技术,2024,47(1):71-78.
- LIU Q, WU S R, DENG H L, et al. SOC estimation of ternary lithium-ion battery based on ASSA-RBF joint algorithm[J]. Electronic Measurement Technology,2024,47(1):71-78.
- [13] 李思聪,王坚,宋亚飞,等. 基于 BiTCN-DLP 的恶意代码分类方法[J]. 信息安全,2023,23(11):104-117.
- LI S C, WANG J, SONG Y F, et al. Malicious code classification method based on BiTCN-DLP [J]. Netinfo Security,2023,23(11):104-117.
- [14] 朱元富,贺文武,李建兴,等. 基于 Bi-LSTM/Bi-GRU 循环神经网络的锂电池 SOC 估计[J]. 储能科学与技术,2021,10(3):1163-1176.
- ZHU Y F, HE W W, LI J X, et al. SOC estimation for Li-ion batteries based on Bi-LSTM and Bi-GRU [J]. Energy Storage Science and Technology, 2021,10(3):1163-1176.
- [15] ZHONG CH, LI G, MENG Z. Beluga whale optimization: A novel nature-inspired metaheuristic algorithm[J]. Knowledge-Based Systems,2022,251, DOI:10.1016/j.knosys.2022.109215.
- [16] FERAHTIA S, REZK H, ABDELKAREEM M A, et al. Optimal techno-economic energy management strategy for building's microgrids based bald eagle search optimization algorithm [J]. Applied Energy, 2022,306:118069.
- [17] 郭雨鑫,刘升,高文欣,等. 多策略改进哈里斯鹰优化算法[J]. 微电子学与计算机,2021,38(7):18-24.
- GUO Y X, LIU SH, GAO W X, et al. Improved harris Hawks optimization algorithm with multiple strategies [J]. Microelectronics&Computer, 2021,38(7):18-24.
- [18] VIDAL C, KOLLMEYER P J, NAGUIB M, et al. Robust xEV battery state-of-charge estimator design using a feedforward deep neural network [J]. SAE International Journal of Advances and Current Practices in Mobility,2020,2(5):2872-2880.

作者简介

柳博,硕士研究生,主要研究方向为锂电池荷电状态估计、深度学习等。

E-mail:691637020@qq.com

吴松荣(通信作者),博士,副教授,主要研究方向为电力电子技术、机车/动车组牵引传动等。

E-mail:srwu88@163.com