

# 基于 QPSO 优化 LSTM 的锂离子电池荷电状态估计<sup>\*</sup>

刘 锐<sup>1</sup> 朱培逸<sup>1,2</sup>

(1. 盐城工学院电气工程学院 盐城 224300; 2. 常熟理工学院电气工程学院 常熟 215500)

**摘要:** 锂离子电池荷电状态(SoC)是电池管理系统的关鍵参数之一,针对单一长短期记忆(LSTM)网络估计精度不高的问题,提出量子粒子群(QPSO)优化的长短期神经网络,引入量子粒子群算法对LSTM神经网络模型关鍵参数进行优化,进而提高网络对SoC的估计性能。此外,采用INR-18650电池数据集对所提出的模型进行测试,包含3种不同温度(0℃、25℃、45℃)和4种工况包括动态压力测试DST、联邦城市驾驶时间表FUDS、US06高速公路驾驶时间表和北京动态压力测试BJDST。最后,在各工况下分别验证模型性能,并与其他优化算法进行比较,验证结果表明,所提方法在各温度下均能提高模型的SoC估计结果,且不同温度4种工况下的均值绝对误差(MAE)均小于1%和均方根误差(RMSE)均小于1.1%,最大误差均在5%以内。

**关键词:** 荷电状态估;长短期记忆;量子粒子群优化算法;电池管理系统

中图分类号: TM912; TN98 文献标识码:A 国家标准学科分类代码: 480.40

## State of charge estimation of lithium-ion batteries based on QPSO optimized LSTM

Liu Rui<sup>1</sup> Zhu Peiyi<sup>1,2</sup>

(1. School of Electrical Engineering Yancheng Institute of Technology, Yancheng 224300, China;

2. School of Electrical Engineering Changshu Institute of Technology, Changshu 215500, China)

**Abstract:** The state of charge of lithium-ion battery is one of the key parameters of the battery management system, and in order to solve the problem of low estimation accuracy of a single LSTM network, this paper proposes a long-term and short-term neural network optimized by quantum particle swarm optimization, and introduces the quantum particle swarm optimization algorithm to optimize the key parameters of the LSTM neural network model, so as to improve the estimation performance of the network on SoC. In addition, the INR-18650 battery dataset was used to test the proposed model, which included three different temperatures (0℃, 25℃, 45℃) and four working conditions, including dynamic stress test DST, federal city driving timetable FUDS, US06 highway driving timetable and Beijing dynamic stress test BJDST. Finally, the performance of the model is verified under each working condition and compared with other optimization algorithms, and the verification results show that the proposed method can improve the SoC estimation results of the model at all temperatures, and the mean absolute error (MAE) and root mean square error (RMSE) are less than 1% and the root mean square error (RMSE) are all less than 1.1% under the four working conditions at different temperatures, and the maximum error is within 5%.

**Keywords:** state of charge estimation; long short-term memory; quantum particle swarm optimization algorithm; battery management system

## 0 引言

在现代电动汽车和能源存储系统中,锂离子电池作为

一种高效能源载体,其状态估计尤其是荷电状态(state of charge, SoC)的准确评估,对于电池管理系统(battery management system, BMS)的性能至关重要<sup>[1]</sup>。然而,由

收稿日期:2024-08-30

\*基金项目:国家自然科学基金(62106025)、江苏省自然科学基金(BK20241968)、江苏省产学研合作项目(BY20231393)资助

# 理论与方法

于电池在实际使用中会受到温度变化、充放电率波动等多种因素的影响,使得 SoC 的直接测量变得复杂且不准确,传统的方法难以满足实际应用的精度要求。

目前,锂电池 SoC 估计主要的方法有安时积分法、开路电压法等。安时积分法通过传感器所采集到的电池电流再对电流进行积分计算的到,但该方法对初值校准的准确度和对电流采集精度具有较高要求,且误差也会随着传感器采集到电流误差累积增加。开路电压法则是通过电池端电压与 SoC 一一对应非线性拟合的关系,但该方法获取端电压需要长时间静置,一般用于电池测试,不适合在线测量<sup>[2]</sup>。现有的 Kalman 滤波算法<sup>[3-4]</sup>计算量大,在 SoC 估算前需对电池进行等效电路建模<sup>[5]</sup>,模型精度往往会影响电池 SoC 估计的精度。在数据驱动的 SoC 估算中,将电池视为一个黑盒系统,并直接从大量样本数据中对非线性输入输出关系进行建模<sup>[6]</sup>。神经网络法具有较强的非线性映射能力,反向传播神经网络(back propagation neural network, BPNN)的方法<sup>[7]</sup>被用于电池 SoC 估计,但单一的网络结构简单,对于 SoC 估计效果并不显著。文献[8]利用遗传算法优化 BP 神经网络(GA-BP)应用于 SoC 的估计方法。然而由于 BP 网络的局限性对数据的时间序列特性并不敏感,而 SoC 估计往往需要考虑电池充放电过程的时间动态特性,循环神经网络(recurrent neural network, RNN)通过不同时刻的隐藏层之间链接权重,考虑电池的历史状态,但存在梯度消失和梯度爆炸的问题<sup>[9-10]</sup>。为了克服这一问题,长短期记忆(long short-term memory, LSTM)神经网络依赖于过去样本的输入且有效解决了 RNN 无法捕获长期依赖性的问题<sup>[11]</sup>。然而 LSTM 模型在处理复杂的电池动态行为时,可能会陷入局部最优和模型过拟合<sup>[12]</sup>,导致估计精度降低。针对上述问题,本文提出了一种基于量子粒子群(quantum particle swarm optimization, QPSO)优化的 LSTM 模型,利用 LSTM 深度处理提取电压电流与 SoC 之间的映射关系,通过 QPSO 优化算法搜索参数空间,自适应地更新 LSTM 网络参数。引入温度作为辅助,以增强模型对环境变化的适应性;通过实际电池数据集对模型进行训练和测试,验证模型的精确性和泛化性。

## 1 建模方法以及理论介绍

### 1.1 LSTM 神经网络

RNN 是一种用处理时序的神经网络,通过分析当前的输入特征和以前输入数据的时间依赖性来估计输出状态,但当序列较长时,就会出现梯度消失和梯度爆炸等问题,针对其存在的问题人们提出了 LSTM 神经网络是该网络的改进形式。在循环神经网络的隐含层中添加了记忆单元用来存储以往的信息,并且增添新的激活函数来削弱梯度消失率,通过输入门、遗忘门、和输出门来更新层与层之间的传递信息,使得模型具有较长时间的“记忆功能”,因此 LSTM 在处理长时间序列数据方面表现良好,

可以在不同的时间步长共享相同的参数<sup>[13]</sup>。

LSTM 的网络单元结构如图 1 所示,每个单元细胞内都包含 3 种类型的门,输入门  $i$ 、输出门  $o$ 、遗忘门  $\lambda$ 。通过激活函数  $\sigma(\cdot)$ 、输入门  $i$ 、输出门  $o$ 、遗忘门  $\lambda$ ,将输入的当前信息更新,有选择性的保存和遗忘从而获得所需要的信息。电池的电压、电流、实际 SoC 等数据均为一维时间序列数据<sup>[14]</sup>。本文将电压、电流、实际 SoC 输入到 LSTM 网络进行训练,其中输入向量为  $x_t = \{V_t, I_t, \text{SoC}_t\}$ , LSTM 网络的输出值为  $y_t = \text{SoC}_p$ 。

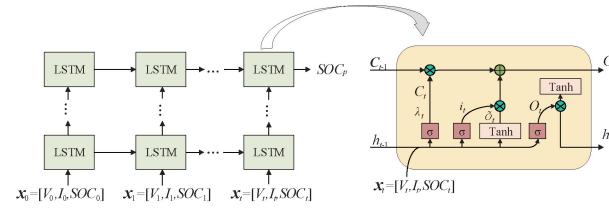


图 1 LSTM 隐含层网络单元结构

Fig. 1 LSTM hidden layer network unit structure

从图 1 可以得到,输入包括当前  $t$  时刻输入向量  $x_t$  与  $t-1$  时刻记忆状态  $C_{t-1}$  和  $t-1$  时刻的输出状态  $h_{t-1}$ 。 $x_t$  通过 sigmoid 激活函数  $\sigma$  变量控制在  $[0,1]$  之间,并计算得到  $i_t$ 、 $o_t$  和  $\lambda_t$ 。利用双曲正切激活函数 Tanh 更新作为  $t$  时刻的记忆状态,利用遗忘门决定遗忘当前哪些无关信息,主要公式如下:

$$\lambda_t = \sigma(\omega_\lambda(h_{t-1}, x_t) + b_\lambda) \quad (1)$$

$$i_t = \sigma(\omega_i(h_{t-1}, x_t) + b_i) \quad (2)$$

$$\tilde{C}_t = \text{Tanh}(\omega_c(h_{t-1}, x_t) + b_c) \quad (3)$$

$$C_t = \lambda_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t \quad (4)$$

$$o_t = \sigma(\omega_o(h_{t-1}, x_t) + b_o) \quad (5)$$

$$h_t = o_t \otimes \text{Tanh}(C_t) \quad (6)$$

式中:  $\omega_\lambda$ 、 $\omega_i$ 、 $\omega_o$  分别表示权重矩阵;  $b_\lambda$ 、 $b_i$ 、 $b_c$ 、 $b_o$  表示偏差向量;  $\tilde{C}_t$  表示当前输入的单元状态;  $\otimes$  表示元素乘。

### 1.2 量子粒子群优化算法

粒子群优化算法(particle swarm optimization, PSO)是一种仿生算法,源于对鸟类觅食行为的研究。粒子可以根据飞行中的状态将组的个体最优值和全局最优值与适应度值进行比较。在得到结果后,通过模拟粒子在搜索空间中的移动和信息交流,以求寻找最优解<sup>[15]</sup>。粒子群算法的缺点是粒子的可行解是一个有限收缩区域,粒子速度是固定的。一旦粒子运动轨迹固定,它就不能覆盖整个解空间,这导致解空间的局部最优。量子粒子群算法是受量子力学的启发,引入量子力学的不确定性理论,具有更强的随机性、自适应性和跳出局部最优解的能力<sup>[16]</sup>。其计算公式如下:

$$x_i = p_i \pm \alpha \cdot |m_{best} - x_i| \cdot \ln\left(\frac{1}{u}\right) \quad (7)$$

$$p_i = \varphi \cdot p^{best_i} + (1 - \varphi) \cdot g^{best} \quad i = 1, 2, \dots, M \quad (8)$$

$$m_{best} = \frac{1}{M} \sum_{i=1}^M p^{best_i} \quad (9)$$

式中:引入参数  $m_{best}$ 、 $P_{best}$ 、 $g_{best}$  分别表示历史最佳位置的平均值、单个粒子的最佳位置和全局最优粒子;  $x_i$  为第  $i$  个粒子的位置;  $p_i$  为更新后第  $i$  个粒子;  $p^{best_i}$  表示当前迭代中第  $i$  个粒子的最佳位置;  $u$  是均匀分布在  $(0,1)$  的值, 且取正取负的概率都是 0.5;  $\varphi = l/(l+r)$  表示  $P_{best}$  的更新矩阵,  $l$  表示学习因素,  $r$  表示平均分散数值;  $\alpha$  为收缩因子, 通常情况  $\alpha < 1.781$ 。

### 1.3 QPSO-LSTM 网络模型建立

LSTM 网络模型包含输入层、隐含层、输出层, 其中网络模型参数的选取对精度有较大的影响, 因此, 提出使用 QPSO 算法对 LSTM 网络的相关参数进行优化, 建立 QP-SO-LSTM 网络的 SoC 估计模型, 其结构如图 2 所示, 整个模型框架可分为两个部分, 一部分是 LSTM 模型的构建。

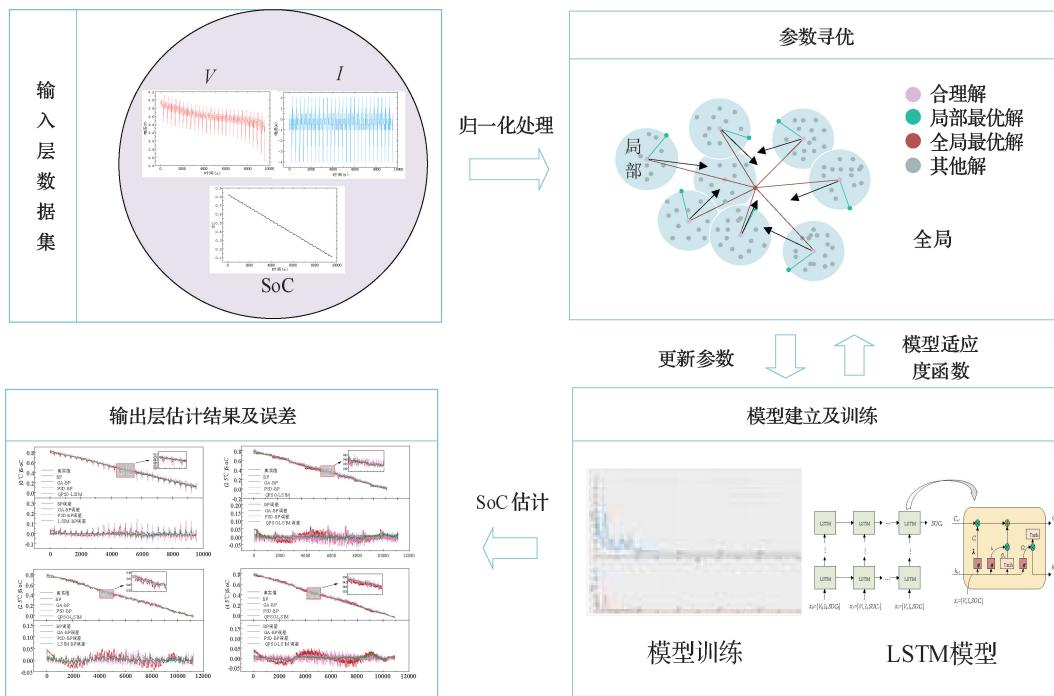


图 2 QPSO-LSTM 网络估计示意图

Fig. 2 Schematic diagram of QPSO-LSTM network estimation

使用 QPSO 优化算法对 LSTM 网络模型进行参数调整, 对网络的隐藏层节点数、网络训练次数和学习率进行寻优, 具体流程如图 3 所示。

### 1.4 模型预测性能评价指标

本文采用平均绝对误差 (MAE)、均方根误差 (RMSE) 和最大误差值 (Max error) 显示各模型的估计性能, 其计算方法如下:

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (11)$$

$$Maxerror = \max |\hat{y}_i - y_i| \quad (12)$$

式中:  $N$  表示样本数量;  $\hat{y}_i$  表示预测值;  $y_i$  表示真实值;  $\bar{y}_i$  表示样本均值; MAE 和 RMSE 误差指标的值越小, 表明模型的精度越高, 若较大, 说明估计结果的波动范围较大, 存在较大的偏差。

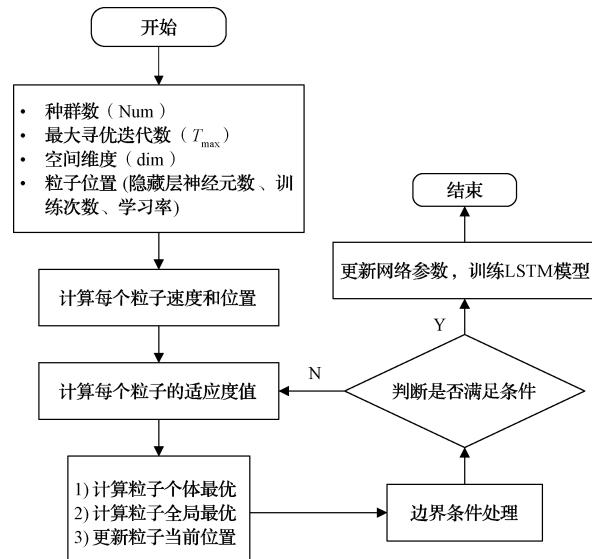


图 3 QPSO 优化 LSTM 模型流程

Fig. 3 Flow chart of QPSO optimization LSTM model

## 2 实验结果分析

## 2.1 实验数据采集与实验设计

本文选择马里兰大学 CALCE 电池数据集,该数据集涵盖了不同温度和工况下的电池性能数据,有效模拟了现实生活中电动汽车电池的负载状态。为深入研究锂电池在实际使用条件下的行为提供了丰富的信息,有助于提高模型的泛化能力和实际应用价值。其电池关键参数如表 1 所示。

表 1 INR 18650-20R 规格  
Table 1 INR 18650-20R specifications

电池(参数)	规格(值)
化学成分	LiNiMnCo/石墨
标称电压/V	3.7
容量额定值/mAh	2 000
重量/g	45
直径/mm	18.33±0.07
长度/mm	64.85±0.15
饱和/截止电压/V	4.2/2.5

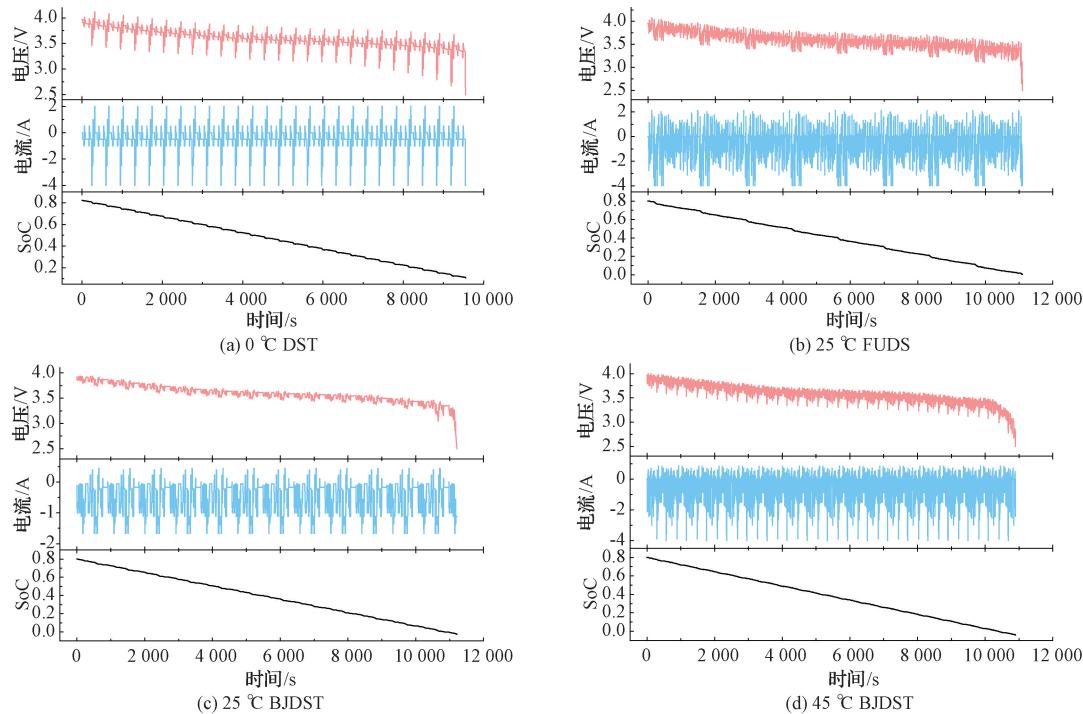


图 4 各温度不同工况的电压分布、电流分布和实际的 SoC 值

Fig. 4 Voltage distribution, current distribution, and actual SoC values for each temperature and operating condition

练集对网络模型进行训练,训练集样本总数为 94 650 个。使用 DST(28 656 个样本)、FUDS(33 294 个样本)、BJDST(33 294 个样本)、US06(32 700 个样本)4 种工况电压、电流、SoC 作为验证的数据集在线评估模型性能。将

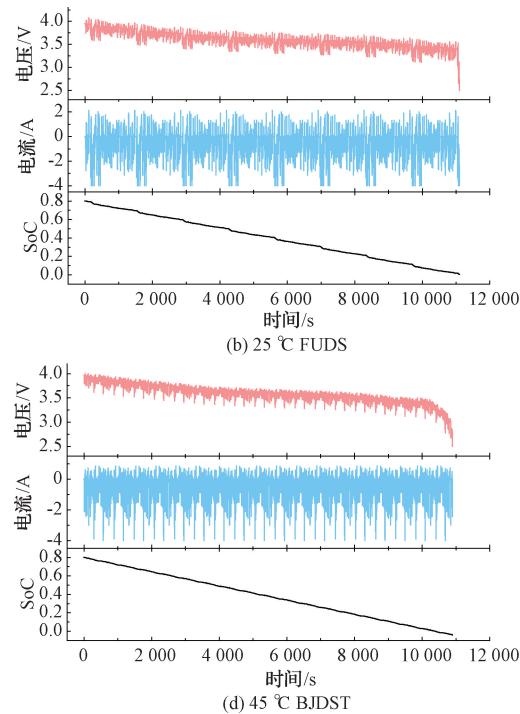
本文实验选择在 0 °C、25 °C 和 45 °C 这 3 种温度条件进行测试,以反映电池在低温、常温和高温环境中的实际运行情况。这一阶段包含 4 种具有代表性的工况数据,分别是动态压力测试(DST)、高速公路驾驶时间表测试(US06)、联邦城市驾驶计划(FUDS)以及北京动态压力测试(BJDST)。图 4 所示为不同温度部分工况数据集,图 4(a)表示 0 °C 的 DST 工况,图 4(b)、(c)分别表示 25 °C 的 FUDS、BJDST 工况,图 4(d)表示 45 °C 的 US06 工况在一个放电循环中的电流、电压以及实际的 SoC 值。

图 4 中正电流为放电过程,负电流为充电过程,实际的 SoC 值采用库伦计数法,该方法是通过电流在时间轴上的积分来获得,公式如下:

$$SoC = SoC_0 - \frac{1}{C} \int i dt \quad (13)$$

式中:  $SoC_0$  为初始的 SoC 值;  $i$  表示电池电流;  $C$  表示标称容量;  $t$  表示时间。

图 5 所示为在不同温度环境下,依次使用不同的工况数据进行模型训练,在离线阶段,低温(0 °C)测试环境中,依次使用 DST(28 656 个样本)、FUDS(33 294 个样本)、US06(32 700 个样本)3 种混合驾驶电压电流、SoC 作为训



QPSO-LSTM 算法与其他算法<sup>[9-10,12,15]</sup>(包含 BP、LSTM、GA-BP、PSO-BP、PSO-LSTM)的 SoC 估计值进行比较。

## 2.2 结果分析

一些网络超参数设置如表 2 所示,设置两个堆叠的

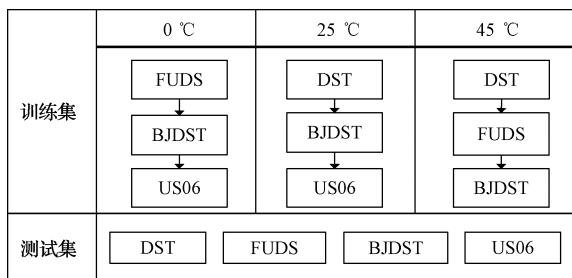
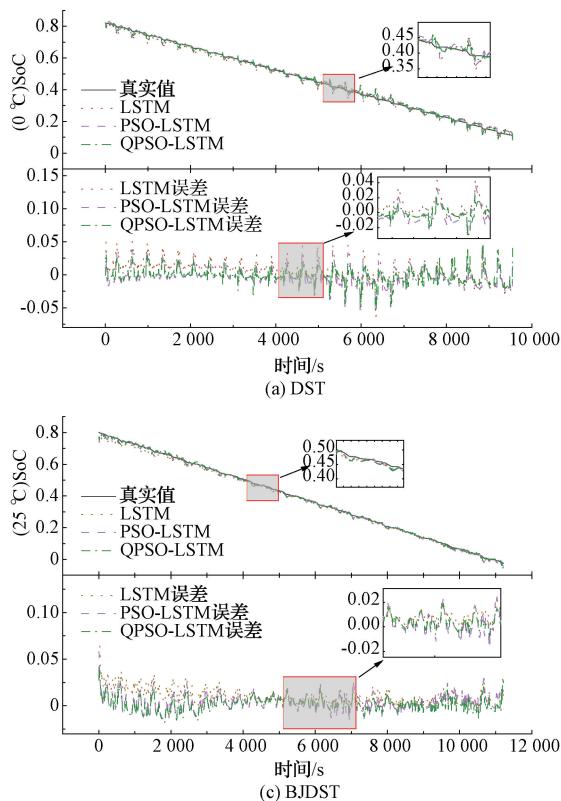


图 5 测试模型程序流程

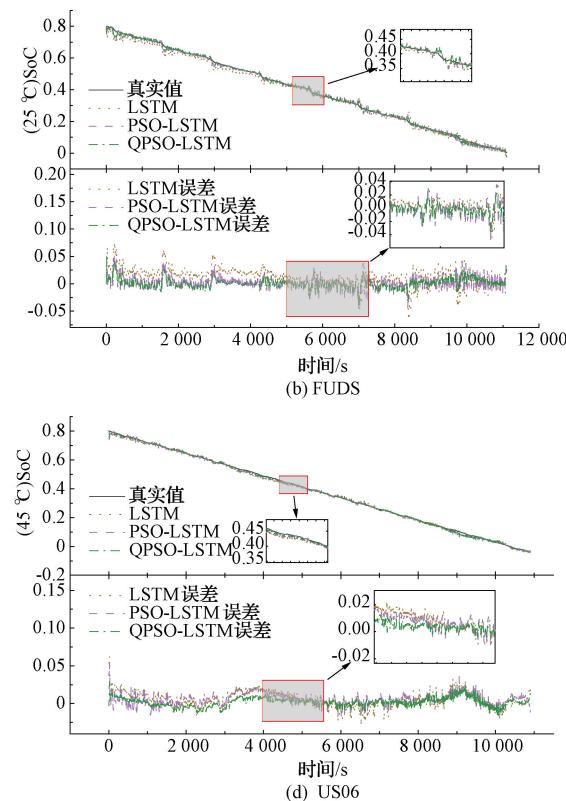
Fig. 5 Test model process

LSTM 神经节点数分别为  $(50, 50)$ , 构建一个全连接层进行 SoC 回归, 其他超参数, 如 LSTM 网络最大训练周期均设定为 500, 初始学习率均设定为 0.005, 采用 Adam 优化器更新学习率以实现更快收敛。PSO、QPSO 优化算法的种群数设置为 100, 最大寻优迭代次数设置为 100, 训练次数范围设为  $[1, 500]$ , 学习率范围设为  $[0.001, 0.01]$ 。根据经验, 加速常数  $c_1$  和  $c_2$  通常设定为 1.5, 惯性权重  $\omega$  设定为 0.8。恒流放电 20% 电量后, 对多个温度下的 SoC 进行估算。

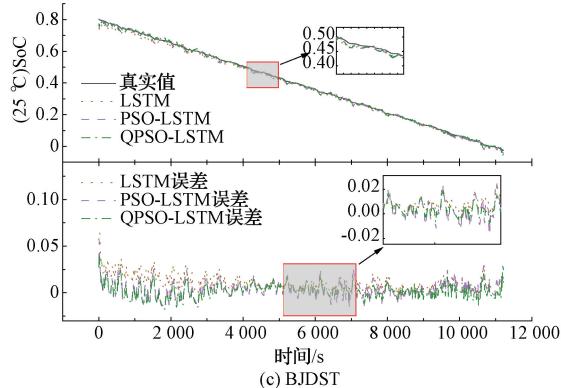
QPSO 优化 LSTM 模型神经元数、模型的训练次数以及学习率即在设定范围内寻优。图 6 所示为优化前后 LSTM 各个工况测试的 SoC 估计曲线以及误差。可以看



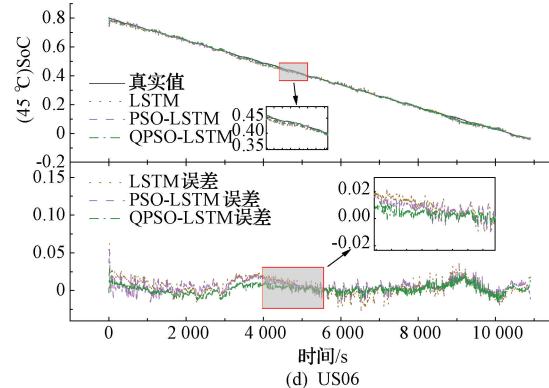
(a) DST



(b) FUDS



(c) BJDST



(d) US06

图 6 优化前后 LSTM 估计曲线以及误差

Fig. 6 LSTM estimation curves and errors before and after optimization

表 2 网络参数设置

Table 2 Network parameter settings

参数	LSTM	PSO-LSTM	QPSO-LSTM
隐藏层数	$(50, 50)$	1/50	1/50
学习率	0.005	0.001/0.01	0.001/0.01
训练次数	500	1/500	1/500
优化器	Adam	Adam	Adam

到, QPSO 优化后 LSTM 模型在各工况测试中 SoC 估计曲线变得更加稳定且平滑。优化前后各个工况测试的评价指标, 如表 3 所示, 优化前后评价对比在各工况测试中, 加入 QPSO 修正 LSTM 网络参数后算法在时序估计中表现出较好的精确性和模型泛化性, 在 DST 工况下验证的 MAE 为 0.78%, RMSE 为 1.09%, 最大估计误差为 4.41%, MAE 下降了 0.53%, RMSE 下降了 0.56%, 最大误差下降了 2.36%; FUDS 工况测试的 MAE 下降了 0.95%, RMSE 下降了 1.13%, 最大估计误差下降了 2.36%; BJDST 工况下测试的 MAE 下降了 0.51%, RMSE 下降了 0.6%, 最大误差下降了 2.52%; US06 工况下测试的 MAE 下降了 0.4%, RMSE 下降了 0.51%, 最大误差下降了 3.1%; QPSO-LSTM 网络在各个工况下验证的 MAE 均值下降了 0.6%, RMSE 均值下降了 0.7%, 最大误差均值下降了 2.57%; 这表明 QPSO 在优化过程

表 3 优化前后评价对比

Table 3 Comparison of evaluations before and after optimization

工况类型	LSTM			PSO-LSTM			QPSO-LSTM		
	MAE	RMSE	Max error	MAE	RMSE	Max error	MAE	RMSE	Max error
(0 °C) DST	1.31	1.65	6.77	1.01	1.3	5.12	<b>0.78</b>	<b>1.09</b>	<b>4.41</b>
(25 °C) FUDS	1.56	1.97	7.29	0.71	1.01	5.89	<b>0.61</b>	<b>0.84</b>	<b>4.93</b>
(25 °C) BJDST	1.08	1.34	6.4	0.66	0.87	5.4	<b>0.57</b>	<b>0.74</b>	<b>3.88</b>
(45 °C) US06	0.88	1.11	6.2	0.73	0.91	4.89	<b>0.48</b>	<b>0.6</b>	<b>3.1</b>
平均值	1.21	1.52	6.67	0.78	1.02	5.33	<b>0.61</b>	<b>0.82</b>	<b>4.1</b>

中找到了一个更好的模型复杂性和泛化性能之间的平衡, SoC 估计结果与真实值更接近, 有效的防止模型过拟合, 提高模型的收敛性和精确性。

为了进一步验证优化方案的泛化性, 图 7 所示为与各类算法对比, 25 °C 下 FUDS、BJDST 工况测试的结果如图 7(a)、(b) 所示, 可见, 加入 GA、PSO 优化 BP 模型参数后, 模型对于 SoC 收敛性以及泛化性明显提升, 相较于 BP 网络, FUDS 工况测试的 MAE 分别下降了 0.67%、0.56%,

RMSE 分别下降了 0.7%、0.55%; BJDST 工况下测试的 MAE 分别下降了 0.97%、0.89%, RMSE 分别下降了 1.07%、1.02%; 优化后的 BP 网络模型对于长时间序列估算仍然存在较大误差。加入 QPSO 算法的 LSTM 模型较于 GA-BP、PSO-BP 算法均有进一步所提升, 各工况测试 MAE 均值分别下降了 0.2%、0.32%; RMSE 均值分别下降了 0.29%、0.42%; Max error 均值分别下降了 3.44%、3.16%。

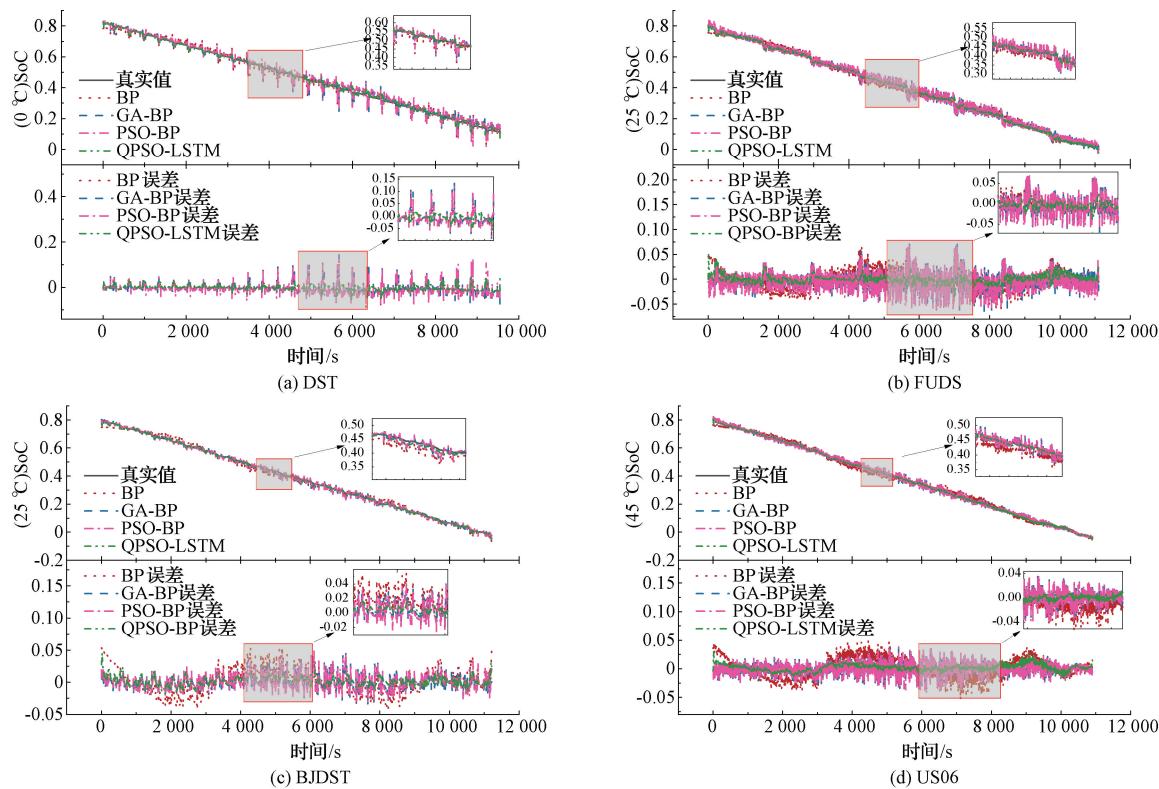


图 7 各类算法对比

Fig. 7 Comparison of various algorithms

图 8 所示为各算法之间差系数, QPSO-LSTM 较于其他算法均有所提升, 各工况测试 MAE 均小

于 1%, RMSE 均小于 1.1%, 最大误差均在 5% 以内。

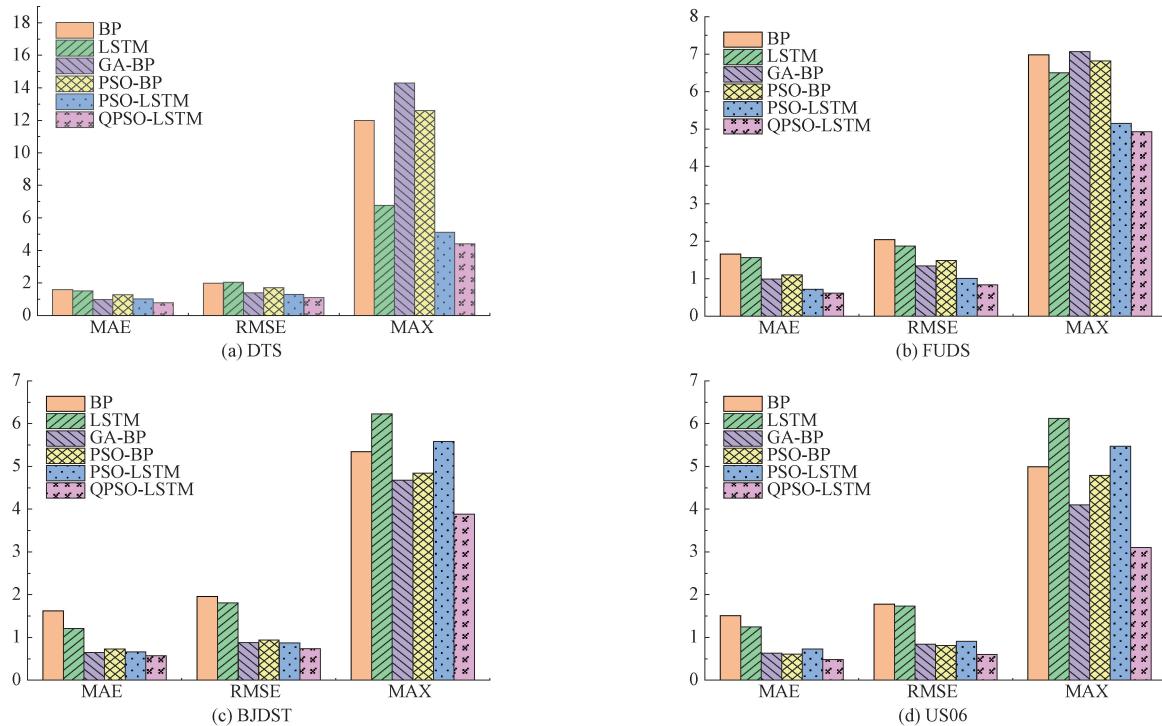


图 8 各算法之间误差系数  
Fig. 8 Error coefficients between algorithms

### 3 结论

本文采用 QPSO 对 LSTM 模型参数进行优化, 以提高锂电池 SoC 的估计精度。通过全局搜索, QPSO 优化 LSTM 模型克服局部最优和数据复杂性问题, 显著提升 SoC 估计的准确性。基于马里兰大学先进寿命中心提供的 INR-18650-20R 电池数据集, 在不同温度条件下测试了 3 种 LSTM 训练方法, 并利用 QPSO 优化网络参数。结果表明, 优化后的 QPSO-LSTM 模型在 SoC 估计的精确性和泛化性上均有显著提升, 其绝对误差均在 1% 以内, 均方根误差均在 1.1% 以内, 最大误差均在 5% 以内。QPSO-LSTM 模型对于训练数据的质量和数量有较高要求, 对比传统的 LSTM 模型涉及的参数增多, 这些参数的选择和优化需要大量的实验和专业知识。虽然 QPSO-LSTM 模型在实验中表现出色, 但在实时应用中, 其估计速度和响应时间需要进一步优化。

### 参 考 文 献

- [1] XU X, LIN Y Z, WANG F, et al. A hybrid observer for SoC estimation of lithium-ion battery based on a coupled electrochemical-thermal model [J]. International Journal Of Green Energy, 2019, 16(15): 1527-1538.
- [2] 林加顺, 周娟, 吴乃豪, 等. 一种高精度磷酸铁锂电池 OCV-SoC 曲线获取方法 [J]. 电源学报, 2023: 1-13.
- [3] LIN J SH, ZHOU J, WU N H, et al. A high precision OCV-SoC curve acquisition method for LiFeO<sub>4</sub> battery[J]. Journal of Power Supply, 2023; 1-13.
- [4] 郝世宇, 殷会飞, 杨茹, 等. 基于 AEKF 的锂离子动力电池荷电状态估计 [J]. 国外电子测量技术, 2021, 40(9): 49-53.
- [5] HAO SH Y, YIN H F, YANG R, et al. State of charge estimation of lithium-ion power battery based on AEKF [J]. Foreign Electronic Measurement Technology, 2021, 40(9): 49-53.
- [6] CHEMALI E, KOLLMAYER P J, PREINDL M, et al. State-of-Charge estimation of Li-ion batteries using deep neural networks: A machine learning approach[J]. Journal of Power Sources, 2018, 400: 242-255.
- [7] LI Y W, WANG C, GONG J F. A multi-model probability SoC fusion estimation approach using an improved adaptive unscented Kalman filter technique [J]. ENERGY, 2017, 141: 1402-1415.
- [8] SHI Q, JIANG Z X, WANG Z, et al. State of charge estimation by joint approach with model-based and data-driven algorithm for lithium-ion battery [J]. IEEE Transactions on Instrumentation and Measurement, 2022, DOI:10.1109/TIM.2022.3199253.

- [7] 苏振浩,李晓杰,秦晋,等. 基于BP人工神经网络的动力电池SoC估算方法[J]. 储能科学与技术,2019,8(5):868-873.
- SU ZH H, LI X J, QIN J, et al. SoC estimation method of power battery based on BP artificial neural network [J]. Energy Storage Science and Technology, 2019, 8(5):868-873.
- [8] 于仲安,卢健,王先敏. 基于GA-BP神经网络的锂离子电池SoC估计[J]. 电源技术,2020,44(3):337-340,421.
- YU ZH AN, LU J, WANG X M. SoC estimation of Li-ion battery based on GA-BP neural network [J]. Chinese Journal of Power Sources, 2020, 44(3):337-340, 421.
- [9] 徐帅,刘雨辰,周飞. 基于RNN的锂离子电池SoC估算研究进展[J]. 电源技术,2021,45(2):263-269.
- XU SH, LIU Y CH, ZHOU F. Research progress of SoC estimation of lithium-ion batteries based on RNN [J]. Chinese Journal of Power Sources, 2021, 45(2):263-269.
- [10] 刘建华,陈治铭,陈可纬,等. 基于深度学习的SoC预测模型比较研究[J]. 计算机与数字工程,2024,52(6):1668-1675.
- LIU J H, CHEN ZH M, CHEN K W, et al. Comparative research on SoC prediction models based on deep learning [J]. Computer & Digital Engineering, 2024, 52(6):1668-1675.
- [11] XU SH, LIU Y CH, ZHOU F. Research progress of SoC estimation of lithium-ion batteries based on RNN [J]. Chinese Journal of Power Sources, 2021, 45(2):263-269.
- [12] 明彤彤,王凯,田冬冬,等. 基于LSTM神经网络的锂离子电池荷电状态估算[J]. 广东电力,2020,33(3):26-33.
- MING T T, WANG K, TIAN D D, et al. Estimation in state of charge of lithium battery based on LSTM neural network [J]. Computer Engineering and Applications, 2020, 33(3):26-33.
- [13] 毛远宏,孙琛琛,徐鲁豫,等. 基于深度学习的时间序列预测方法综述[J]. 微电子学与计算机,2023,40(4):8-17.
- MAO Y H, SUN CH CH, XU L Y, et al. A survey of time series forecasting methods based on deep learning [J]. Microelectronics & Computer, 2023, 40(4):8-17.
- [14] ALMAITA E, ALSHKOOR S, ABDELSALAM E, et al. State of charge estimation for a group of lithium-ion batteries using long short-term memory neural network [J]. Journal of Energy Storage, 2022, DOI: 10.1016/j.est.2022.104761.
- [15] 黄海宏,汪宇航,王海欣. 基于粒子群优化粒子滤波算法的SoC估算研究[J]. 电子测量与仪器学报,2022,36(2):245-253.
- HUANG H H, WANG Y H, WANG H X. Research on SoC estimation based on particle swarm algorithm and particle filter algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 245-253.
- [16] 杨立新,张孝远. 基于QPSO优化CNN-Bi-LSTM网络的锂电池健康状态估计[J]. 昆明理工大学学报(自然科学版),2023,48(5):130-139.
- YANG L X, ZHANG Y X. Estimation of SOH of lithium batteries based on QPSO-CNN-Bi-LSTM network [J]. Journal of Kunming University of Science and Technology (Natural Science), 2023, 48(5): 130-139.

## 作者简介

刘锐,硕士研究生,主要研究方向为锂电池管理系统。  
E-mail:963266355@qq.com

朱培逸(通信作者),教授,主要研究方向为智能检测及信息处理。  
E-mail:zhupy@cslg.edu.cn