

doi:10.3969/j.issn.1673-9833.2022.04.004

基于 IPSO-GRU 的锂离子电池剩余使用寿命预测

王 钊¹, 雷 敏², 梁娇娇², 朱登伟³, 汤迪虎¹

(1. 湖南工业大学 电气与信息工程学院, 湖南 株洲 412007; 2. 湖南工业大学 轨道交通学院, 湖南 株洲 412007;
3. 湖南立方新能源科技有限责任公司, 湖南 株洲 412007)

摘要: 为了提高预测锂离子电池剩余使用寿命 (RUL) 的精度, 提出了一种基于改进型粒子群算法 (IPSO) 与门控循环单元 (GRU) 神经网络的锂离子电池 RUL 预测模型。首先, 通过改变 PSO 算法的惯性权重和学习因子的更新规则, 提高其寻优能力; 然后, 通过 IPSO 算法优化 GRU 神经网络的参数选择, 搭建 IPSO-GRU 模型。最后, 利用美国国家航空航天局 (NASA) 公开的锂离子电池实验数据进行试验, 验证 IPSO-GRU 模型的准确性。实验结果表明, 相比于直接采用单一 GRU 模型, 所提 IPSO-GRU 模型降低了容量预测误差, 有效提高了锂离子电池 RUL 预测精度。

关键词: 锂离子电池; 剩余使用寿命; 改进粒子群; 门控循环单元

中图分类号: TM912.9

文献标志码: A

文章编号: 1673-9833(2022)04-0023-08

引文格式: 王 钊, 雷 敏, 梁娇娇, 等. 基于 IPSO-GRU 的锂离子电池剩余使用寿命预测 [J]. 湖南工业大学学报, 2022, 36(4): 23-30.

An IPSO-GRU-Based Prediction of Remaining Useful Life of Lithium-Ion Batteries

WANG Po¹, LEI Min², LIANG Jiaojiao², ZHU Dengwei³, TANG Dihu¹

(1. College of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China;
2. College of Railway Transportation, Hunan University of Technology, Zhuzhou Hunan 412007, China;
3. Hunan Li-Fun Technology Corporation Limited, Zhuzhou Hunan 412007, China)

Abstract: In view of an improvement of the accuracy of remaining useful life (RUL) prediction of lithium-ion batteries, a prediction model of lithium-ion batteries has thus been proposed based on the improved particle swarm optimization (IPSO) as well as gated recurrent unit (GRU) neural network. Firstly, the optimization ability of PSO algorithm is improved by changing the inertia weight and the update rules of learning factors. Next, the parameter selection of GRU neural network is optimized by IPSO algorithm, with an IPSO-GRU model built. Finally, the accuracy of IPSO-GRU model is to be verified by using the experimental data of lithium-ion battery published by NASA. The experimental results show that compared with the single GRU model, the proposed IPSO-GRU model helps to reduce the capacity prediction error and effectively improves the RUL prediction accuracy of lithium-ion batteries.

Keywords: lithium-ion battery; remaining useful life; improved particle swarm optimization; gated recurrent unit

收稿日期: 2021-12-06

基金项目: 湖南省省市联合基金资助项目 (2020JJ6071)

作者简介: 王 钊 (1998-), 男, 湖南娄底人, 湖南工业大学硕士生, 主要研究方向为电力网络自动化技术及应用,
E-mail: wangpo5129@hotmail.com

通信作者: 雷 敏 (1973-), 女, 湖南株洲人, 湖南工业大学副教授, 博士, 硕士生导师, 主要研究方向为复杂网络理论及其在电网稳定性分析中的应用, E-mail: leimin0606@hotmail.com

1 研究背景

随着国家智能电网战略的提出,分布式储能技术获得了广泛应用。由于锂离子电池与其它类型的储能电池相比具有更优异的性能,如电池能量密度系数高、质量轻、充放电速度快等,锂离子电池占据了大部分储能电池市场份额,不仅被广泛应用于手机、电脑和蓝牙耳机等电子设备,还经常被作为电动汽车和航空航天等大型电气系统的动力来源^[1-3]。但是随着锂离子电池循环充放电的进行,其内部会发生一系列物理化学变化,具体表现为电池容量逐渐减少和放电电压逐渐降低^[4]。当锂离子电池寿命衰减过低时可能会导致用电中的电气设备损坏,轻微故障会使机器无法继续使用,而严重故障则会危及人身安全。因此,精确的电池剩余使用寿命(remaining useful life, RUL)预测,能及时提醒管理者更换失效电池,避免事故的发生。目前,锂离子电池 RUL 的预测研究主要包括基于物理模型和基于数据驱动的方法^[5]。

1) 基于物理模型的方法。其基本原理是通过数学公式来推知锂离子电池的容量退化规律,从而预测电池的 RUL。在这些数学公式中,粒子滤波(particle filter, PF)算法及其改进算法应用最广泛。王帅等^[6]利用粒子滤波算法的状态跟踪能力来实现电池经验模型参数的灵活设置,提高了 RUL 预测实验结果的准确性;Zhang X. 等^[7]通过引入马尔可夫链蒙特卡罗方法,很好地解决了无迹粒子滤波算法样本贫化问题,最终的试验结果表明,其所提出方法提高了电池 RUL 预测精度。尽管近年来基于物理模型的方法取得了一定的进展,但 RUL 预测的准确度取决于模型设置的参数,易受外界动态因素的影响,因此仍然存在一定的局限性。

2) 基于数据驱动的方法。该方法不需要关注电池的內部物理化学反应及模型参数,它是从锂离子电池的历史寿命循环数据中提取必要的信息来评估电池的容量衰减规律,从而实现 RUL 预测。其中,人工智能和机器学习算法受到越来越多的国内外学者的关注。高斯过程回归(Gaussian process regression, GPR)和支持向量回归(support vector regression, SVR)是基于数据驱动的一种常用的建立电池退化模型方法。刘健等^[8]提出了一种多核核函数的 GPR 模型,并通过粒子群算法(particle swarm optimization, PSO)来优化 GPR 模型参数,将提取到的等压差充电时间作为特征参数来实现容量退化轨迹的预测。徐佳宁等^[9]利用改进蚁狮算法(improved ant lion optimization, IALO)来优化 SVR,并对从充

电过程中提取到的间接健康因子采取相关性分析法,分析其与容量之间的相关性,结果提高了锂离子电池 RUL 的预测精度。除了 GPR 和 SVR,其它的数据驱动算法如人工神经网络(artificial neural networks, ANN)^[10]和相关向量机(relevance vector machine, RVM)^[11]等也被广泛地应用于电池 RUL 预测研究。但是这些数据驱动的方法仍需要大量的有效数据来训练网络模型,因此,如何有效地从电池历史寿命数据中提取出有效高频信号仍然是一项具有挑战性的工作。

当采用数据驱动的方法进行训练时,模型预测精度主要取决于算法的学习能力。与经典 BP 神经网络相比,循环神经网络(recurrent neural network, RNN)由于能通过内部状态变量来描述信号内部的隐含特征,因此具有更优越的数据处理能力。但 RNN 历史信息存储空间十分有限,在长期进行高精度的预测时效果较差。门控循环单元(gated recurrent unit, GRU)神经网络是 RNN 的一种改进,其克服了传统 RNN 不能长期预测的问题,被逐步应用于语言建模和图像识别领域。鉴于电池老化是一个长期的过程,GRU 神经网络是电池容量退化趋势预测的可行解决方案。

受此启发,本研究应用 GRU 神经网络来实现锂离子电池的 RUL 预测。为了提高预测的精度,采用改进的粒子群算法(improved particle swarm optimization, IPSO)来优化 GRU 神经网络参数的选择,搭建基于 IPSO-GRU 的锂离子电池 RUL 预测模型。最后,基于美国国家航空航天局电池数据集,对多块锂离子电池应用本研究提 IPSO-GRU 算法进行实验验证,以证明所提出方法的有效性。

2 IPSO-GRU 模型建立

2.1 GRU 神经网络

锂离子电池 RUL 预测过程实际是对电池历史放电数据时间序列的分析,时间序列越长,分析的电池历史放电数据越多,预测精度越高。传统 RNN 不能很好地处理距离长时间的数据特征信息,长短期记忆(long short term memory, LSTM)神经网络作为 RNN 的一种改进算法,通过在神经元中引入 3 个“门”解决了 RNN 的长期依赖问题^[12]。GRU 则由 LSTM 变异而来,它将 LSTM 的 3 个门结构变为 2 个,即重置门和更新门,门结构数量的减少使 GRU 所需训练样本数据大为减少,收敛速度进一步加快,很好地克服了 LSTM 存在的过拟合问题,很大程度上改善了网络的学习效果。GRU 的网络结构如图 1 所示。

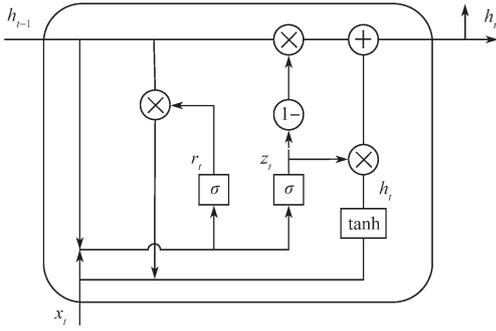


图1 GRU神经网络结构图

Fig. 1 GRU neural network structure diagram

由图1可得各分量函数的表达式为

$$\begin{cases} r_t = \sigma(W_r h_{t-1} + W_r x_t + b_r), \\ z_t = \sigma(W_z h_{t-1} + W_z x_t + b_z), \\ \tilde{h}_t = \tanh(W_h x_t + W_h (r_t \otimes h_{t-1}) + b_h), \\ h_t = z_t \otimes \tilde{h}_t + (1 - z_t) \otimes h_{t-1}. \end{cases} \quad (1)$$

式中： t 为当前时刻； $t-1$ 为前一时刻； r_t 和 z_t 分别为重置门和更新门； x_t 和 h_t 分别为电池当前的输入容量值和输出容量值； h_{t-1} 为前一单元节点传递来的隐藏层状态信息； \tilde{h}_t 为待更新单元； W_r 和 b_r 、 W_z 和 b_z 、 W_h 和 b_h 分别为计算重置门输出、更新门输出、过程量所需的权重矩阵和偏置参数； \otimes 为元素相乘； σ 和 \tanh 分别为sigmoid函数和双曲正切函数。

2.2 PSO算法及其改进

基于GRU神经网络的预测模型包含一个隐藏网络，隐藏网络中的神经元数量难以直接确定，其迭代次数直接影响着预测效果，如果迭代次数不能满足要求会导致预测结果拟合程度不够，而迭代次数过多又会导致预测结果过拟合^[13]。传统GRU神经网络参数一般都根据经验手动设置，这导致最终估计结果的随机性较大。PSO算法可以在设置的空间范围内找到自己的最优解和全局优化解。因此，本文采用PSO算法对GRU神经网络的参数进行自动寻优，以提高实验预测精度。

PSO算法的核心思想是：先在其搜索空间中初始化一组随机解，然后一步步迭代，找到需要的最优解。GRU神经网络模型的两个参数作为粒子在二维空间的寻优变量，通过不断更新粒子的速度和位置来计算目标函数的自适应值，从而实现全局最优，获得更好的模型参数。PSO算法的速度和位置公式如下：

$$v_i^{n+1} = \omega v_i^n + c_1 r_1 (P_{besti}^n - x_i^n) + c_2 r_2 (G_{best}^n - x_i^n), \quad (2)$$

$$x_i^{n+1} = x_i^n + v_i^{n+1}. \quad (3)$$

式(2)(3)中： v_i^{n+1} 和 x_i^{n+1} 分别为第 i 个粒子在 $n+1$ 次迭代中的速度和位置； ω 为惯性权重； c_1 和 c_2

为学习因子； r_1 和 r_2 为区间 $[0, 1]$ 中随机确定的数值； P_{besti}^n 为第 i 个粒子在 n 次迭代时个体极值（个体最优解）； G_{best}^n 为整个群体在 n 次迭代时的全局极值（群体最优解）。

如果直接将传统PSO算法应用到锂离子电池RUL预测模型中，很容易陷入局部最优，造成算法在寻优操作过程中陷入停滞，不能进一步提高锂离子电池RUL的预测精度。因此本文针对传统PSO算法进行了如下两个方面的改进。

1) 改进惯性权重。PSO算法的收敛性取决于惯性权重，当惯性权重较大时，PSO全局搜索寻优能力较强，而局部搜索寻优能力较弱；惯性权重较小时，其局部搜索寻优能力较强，而全局搜索寻优能力较弱。考虑到GRU神经网络参数范围很大，PSO如果采用其经典线性递减策略，则在迭代过程中容易陷入局部极值，不能找到最优解。为了解决这一问题，本研究针对PSO惯性权重采用了线性微分递减策略，公式为

$$\frac{d\omega}{dt} = -\frac{2(\omega_{max} - \omega_{min})}{t_{max}^2} \times t, \quad (4)$$

式中： t 为迭代时刻； ω 为惯性权重，且

$$\omega = \omega_{max} - \frac{\omega_{max} - \omega_{min}}{t_{max}^2} \times t^2. \quad (5)$$

在算法迭代的早期阶段，线性微分递减策略使 ω 下降趋势缓慢，此时PSO全局搜索能力较强，在较大范围内能够得到合适的解；在算法迭代后期，线性微分递减策略使 ω 的下降趋势加快，这使得当PSO在早期阶段找到合适的解后，能进一步加快算法的收敛速度。

2) 改进学习因子。从公式(2)可以看出， c_1 反映了粒子接近其局部历史最佳位置的趋势度， c_2 反映了粒子接近其全局历史最佳位置的趋势度。通常 $c_1=c_2=2$ ，为了使其前期迭代过程中全局搜索能力强、后期迭代过程中局部寻优能力强，应使 c_1 随算法的进行而减小， c_2 随算法的进行而增加。本文采用如下公式对其进行改进：

$$c_1(t) = c_{max} - \frac{t(c_{max} - c_{min})}{t_{max}}, \quad (6)$$

$$c_2(t) = c_{min} + \frac{t(c_{max} - c_{min})}{t_{max}}. \quad (7)$$

式(6)(7)中： c_{max} 和 c_{min} 分别为 c 的最大值和最小值。

通过对PSO算法的惯性权重和学习因子两个方面进行改进，实现其在迭代初期能有较大的搜索范围，在迭代后期能快速收敛到最优解，从而进一步优化GRU神经网络的参数选择。

2.3 IPSO-GRU 模型

GRU 方法的预测精度主要取决于其参数的确定, 为了实现自动寻优, 需要采用优化算法来优化 GRU。粒子群算法相比于其它优化算法, 它所需参数更少, 更容易实现^[14]。在 Matlab 2019b 的环境下, 通过改进的粒子群算法对 GRU 网络的参数选取进行优化, 形成 IPSO-GRU 模型, 该模型首先按照每个参数的取值范围对粒子位置信号进行随机初始化, 然后使用与粒子位置对应的参数构建 GRU 神经网络模型, 并使用样本数据对模型进行训练。本文将模型的均方误差作为粒子适应值, 适应度函数为

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (8)$$

式中: n 为测试数据个数; y_i 为第 i 个测试数据的真实值; \hat{y}_i 为第 i 个测试数据的预测值。

通过比较每个粒子的适应度值, 可以得到 P_{best} 和 G_{best} 。为达到最小均方误差的优化目标, 将方程(2)用于更新粒子速度, 方程(3)用于更新粒子位置。利用最优粒子位置信息优化 GRU 神经网络模型, 完成 IPSO-GRU 模型, 模型流程如图 2 所示。

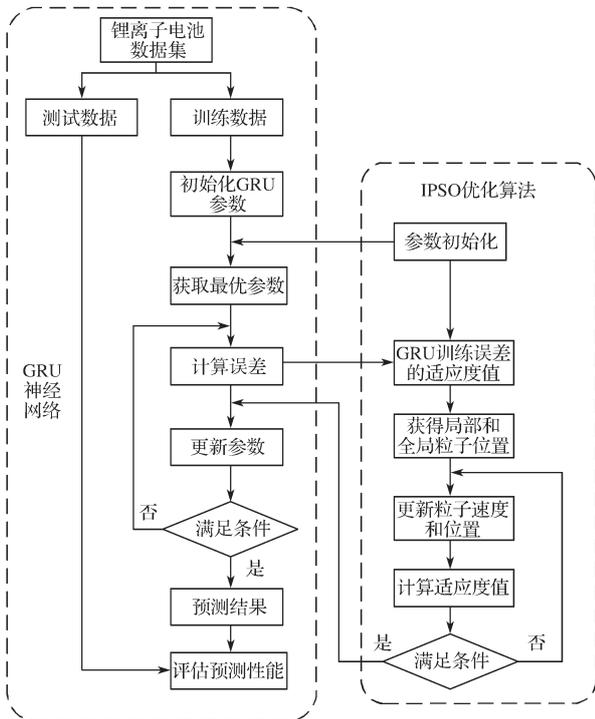


图 2 IPSO-GRU 模型流程图
Fig. 2 IPSO-GRU model flowchart

模型预测的主要步骤如下:

步骤 1 数据预处理, 将原始数据划分为两部分, 分别为实验训练样本数据和测试数据;

步骤 2 初始化 PSO 算法参数, 包含建立迭代次数、种群规模、学习因子及其粒子位置和速度值区间;

步骤 3 确定方程(8)为适应度函数, 通过初始化粒子信息对应的参数优化 GRU 神经网络模型, 通过模型训练计算得到适应值;

步骤 4 比较各粒子适应度函数, 分别记录个体极值和全局极值;

步骤 5 根据式(5)更新惯性权重, 然后分别用公式(2)和(3)不断更新粒子的速度和位置;

步骤 6 在满足 IPSO 算法的最大迭代次数后, 取参数的最优值进行训练和预测, 以优化 GRU 神经网络模型。如不满足条件, 则转到步骤 4 继续迭代;

步骤 7 利用 IPSO 优化后的 GRU 神经网络模型对锂离子电池 RUL 预测。

3 锂离子电池 RUL 预测

3.1 实验数据

本文原始数据采用美国航空航天局(National Aeronautics and Space Administration, NASA)卓越故障预测中心公布的电池实验数据集, 本实验采用 18650 型锂离子电池, 额定容量为 2 A·h, 额定电压为 3.6 V, 充电截止电压为 4.2 V。实验选择一组 4 个锂离子电池(B5、B6、B7 和 B18)进行测试, 每个电池数据集在 24℃ 下具有 3 种相同的操作步骤: 充电、放电和阻抗测量。充电过程在恒流(constant current, CC)模式和恒压(constant voltage, CV)模式下完成, 其中 CC 模式是在 1.5 A 电流下充电直到电池电压达到 4.2 V, 再继续 CV 模式直至充电电流下降至 20 mA。最后以 2 A 的 CC 进行放电, 直至电池 B5、B6、B7 和 B18 的电压下降至各自的截止电压 2.7, 2.5, 2.2, 2.5 V 时停止。

图 3 是 4 块锂离子电池在整个生命周期中的容量变化趋势, 由于该组电池一致性不是很好, 所以其放电截止电压不同。

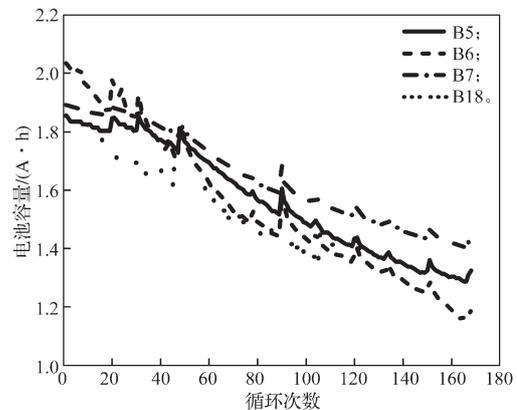


图 3 NASA 数据集的 B5、B6、B7、B18 电池容量退化曲线
Fig. 3 Capacity degradation curves of B5, B6, B7 and B18 batteries in NASA data-sets

从图3中可以看出, 锂离子电池放电容量随着充放电循环次数的增多而减少, 这是由于电池寿命衰退所致。一般认定当电池的放电容量降低至出厂时额定容量的70%时, 即从2.00 A·h降到1.40 A·h时, 锂离子电池寿命到达故障阈值点。电池B5、B6、B7和B18循环次数分别为168, 168, 168, 132, 从图中可以看出, 其中B7电池容量退化没有达到失效阈值1.40 A·h, 因此本研究按文献[15]中的处理方法, 将本文所有测试电池的失效阈值定为1.44 A·h。

3.2 评价指标

为了评价本研究所提IPSO-GRU方法对锂离子电池RUL预测的性能, 选取平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)作为评价标准。

1) 容量值预测误差(Error)。其表达式为

$$Error = |\hat{y} - y| \quad (9)$$

2) 平均绝对误差(MAE)。其表达式为

$$MAE = \frac{1}{n} \sum_i^n |\hat{y}_i - y_i| \quad (10)$$

3) 均方根误差(RMSE)。其表达式为

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

式(9)~(11)中: n 为锂离子电池总循环次数; \hat{y} 为第 i 次循环的预测容量; y 为第 i 次循环时的实际容量。

3.3 实验结果与分析

NASA的原始数据集包含许多参数, 如容量、电压和电流等。电压和电流变化只能间接反映电池的健康状况, 而电池容量变化能直接反映电池在循环充放电过程中的寿命衰退程度, 因此本研究选取容量作为直接健康因子。

为了验证所提IPSO-GRU方法的有效性, 将每节锂离子电池选取两个不同的循环次数点作为剩余使用寿命预测实验的起始点, 分别选为电池总循环次数的第40%和第50%, 即B5、B6、B7电池的第68次循环和第84次循环, B18电池的第53次循环和第66次循环。

当取前40%的数据作为训练数据时, 后60%的数据则用来验证方法效果; 当取前50%的数据作为训练数据时, 后50%的数据则用来验证方法的效果。最后将预测结果与传统GRU方法得出的结果进行分析和比较。样本数据为总循环前40%时, 实验预测结果如图4所示; 样本数据为总循环前50%时, 实验预测结果如图5所示。

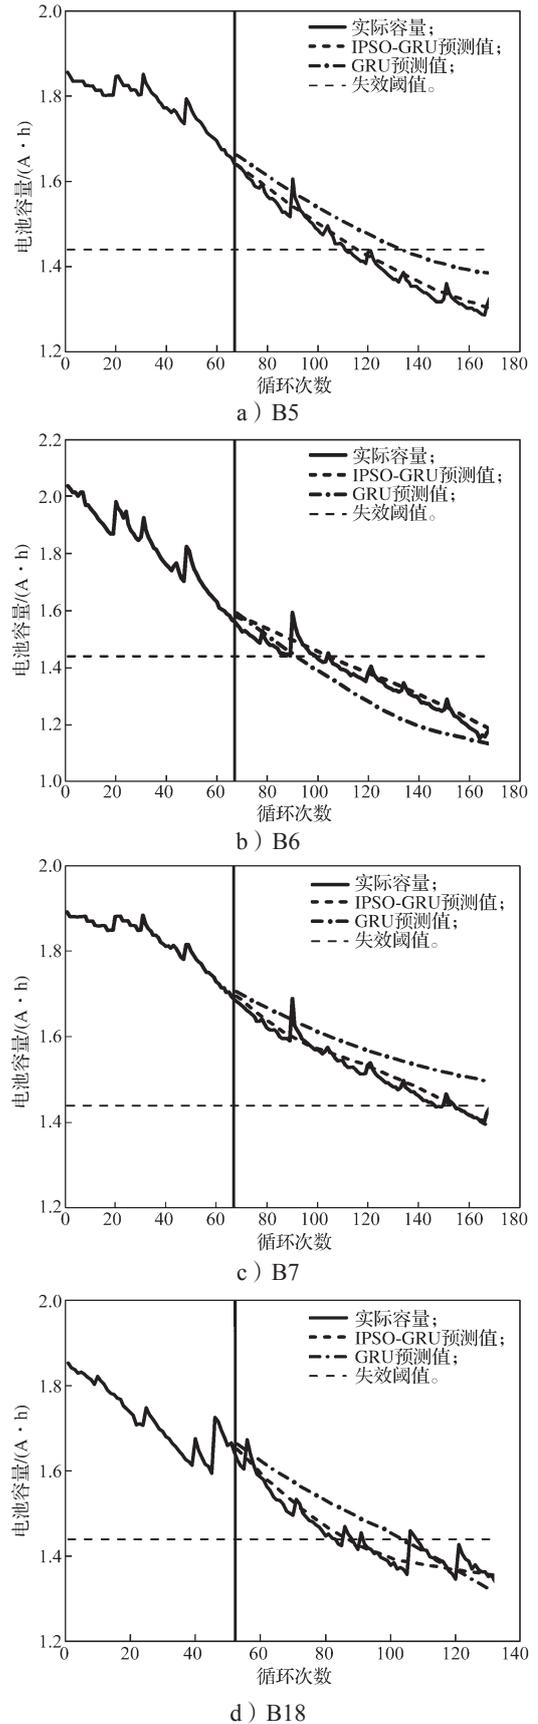


图4 样本数据为总循环前40%时的实验预测结果
Fig. 4 Experimental prediction results obtained with the sample data at the first 40% of the total cycle

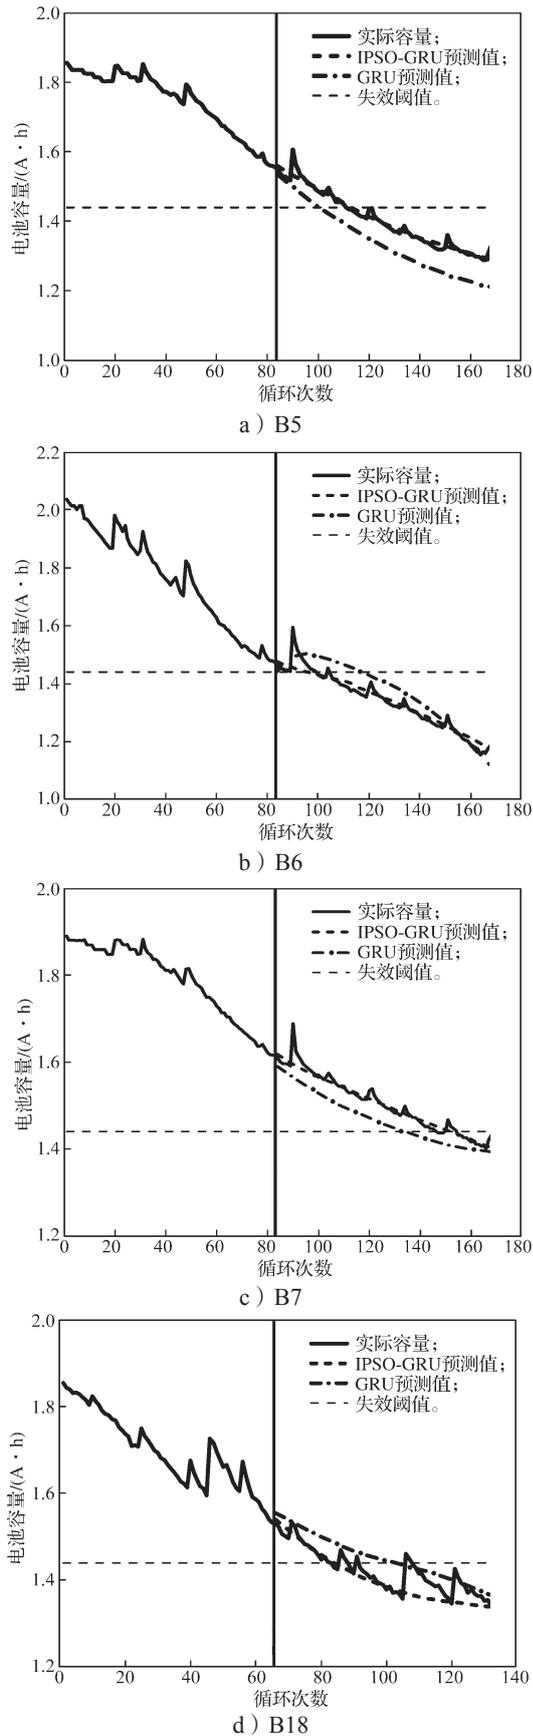


图5 样本数据为总循环前50%时的实验预测结果
Fig. 5 Experimental prediction results obtained with the sample data at the first 50% of the total cycle

IPSO-GRU方法和GRU方法的预测结果统计如表1所示。锂离子电池的剩余使用寿命RUL,定义为电池放电容量衰退至额定容量的70%时的充放电循环次数与当前充放电循环次数之差。电池的实际RUL与预测RUL的误差如下:

$$E_r = |P_{RUL} - T_{RUL}|, \quad (12)$$

$$PE_r = \frac{|P_{RUL} - T_{RUL}|}{R_{RUL}} \times 100\% \circ \quad (13)$$

式(12)(13)中: P_{RUL} 为RUL预测值; T_{RUL} 为RUL真实值; E_r 为 P_{RUL} 与 T_{RUL} 之间的绝对误差; PE_r 为 P_{RUL} 与 T_{RUL} 之间的相对误差。

表1 IPSO-GRU与GRU方法的RUL预测结果

Table 1 RUL prediction results of IPSO and GRU

电池序号	开始时刻	RUL	IPSO-GRU			GRU		
			P_{RUL}	E_r	$PE_r/\%$	P_{RUL}	E_r	$PE_r/\%$
B5	68	43	48	5	11.6	66	23	53.5
	84	27	29	2	7.4	37	10	37.0
B6	68	31	36	5	16.1	23	8	25.8
	84	15	11	4	26.7	33	18	120.0
B7	68	78	85	7	9.0	—	—	—
	84	62	67	5	8.1	49	13	21.0
B18	53	30	34	4	13.3	51	21	70.0
	66	17	19	2	11.8	37	20	118.0

分析图4、图5和表1可得:对所有测试电池在不同预测起点,应用本文所提IPSO-GRU方法进行RUL预测,其预测曲线能更好地与实际容量曲线相吻合,并且得到比GRU预测结果更小的 E_r 和 PE_r 值。例如,对于B5电池,当选取预测起点为第68次充放电循环时,IPSO-GRU得出的RUL预测结果 E_r 和 PE_r 分别为5和11.6%,而在同样条件下GRU方法得出的 E_r 和 PE_r 分别为23和53.5%,很明显,IPSO-GRU预测误差要小于GRU预测误差的25%。在所有电池预测中,GRU方法预测误差最高达到了120%,而IPSO-GRU方法最高预测误差仅为26.7%,这证明IPSO-GRU方法预测精度更高。

表2为IPSO-GRU与GRU的预测结果比较。

表2 IPSO-GRU与GRU的预测结果比较

Table 2 Comparison of prediction results between IPSO-GRU and GRU

电池序号	开始时刻	IPSO-GRU		GRU	
		MAE	RMSE	MAE	RMSE
B5	68	0.015 8	0.017 9	0.061 6	0.064 9
	84	0.009 8	0.014 3	0.063 3	0.066 6
B6	68	0.027 5	0.032 4	0.063 2	0.069 9
	84	0.017 6	0.026 1	0.042 8	0.049 6
B7	68	0.013 6	0.017 5	0.055 7	0.059 1
	84	0.009 0	0.014 7	0.037 6	0.041 0
B18	53	0.019 5	0.024 4	0.047 8	0.053 9
	66	0.021 9	0.030 7	0.033 3	0.038 5

从表 2 中给出的平均绝对误差 MAE 和均方根误差 RMSE 这两个评价指标数据看, 当取相同的预测起点时, IPSO-GRU 方法的 MAE 和 RMSE 值均小于 GRU 方法的得值。以 B7 号电池为例, 当取第 68 次循环为预测起点时, GRU 方法 MAE 值为 0.055 7, 而 IPSO-GRU 方法的 MAE 值小于其 25%; GRU 方法的 RMSE 值为 0.059 1, 约为 IPSO-GRU 方法的 RMSE 值的 3.4 倍。

预测误差越小, 说明使用方法的预测精度越高。通过分析上述实验结果可以得知, 使用本文所提出的 IPSO-GRU 方法来预测锂离子电池的 RUL, 有着更高的预测精度。

4 结论

准确预测锂离子电池^[16-17]的 RUL 能够提高储能系统的安全性和可靠性。本文提出一种基于 IPSO-GRU 方法预测锂离子电池的 RUL, 有效解决了 GRU 方法中参数选择的难题。采用 NASA 公开的电池充放电循环数据集, 验证了所提 RUL 预测方法的有效性, 可得出如下结论:

1) 从 NASA 原始电池数据集中提取电池容量作为电池寿命健康因子, 具有易采集和便于计算的特点。使用 Matlab 2019b 曲线拟合工具, 按照电池循环次数拟合而成的容量退化曲线符合时间序列, 并且具有明显的非线性特性, 契合 GRU 方法所适合解决问题的特征。

2) 传统 GRU 方法一般都是根据经验来手动设置最优神经元个数和最优迭代次数, 因此预测结果的随机性较大。利用 PSO 算法可以优化 GRU 神经网络参数选择, 但是 PSO 算法迭代后期容易陷入局部最优, 导致优化效果不理想。而改进后的方法通过采用线性微分递减策略改进了粒子的惯性权重, 并且在改进学习因子后有效解决了 PSO 算法局部最优问题, 增加了粒子的搜索空间。

3) 从实验预测结果来看, GRU 方法预测的平均相对误差达到了 63.6%; 而 IPSO-GRU 方法预测的平均相对误差仅为 13.0%, 不到 GRU 方法的相对误差的 25%。从评价指标来看, GRU 方法的 MAE 和 RMSE 值分别达到了 6.33% 和 6.99%, 而 IPSO-GRU 方法的 MAE 和 RMSE 值在 2.75% 和 3.24% 以内。很明显, 采用本文 IPSO-GRU 方法来预测锂离子电池 RUL, 能够有效提高预测精度。

考虑到锂离子电池实际运行环境的复杂性, 未来的工作将致力于锂离子电池在动态工作条件以及在

低温性能下的 RUL 预测研究。

参考文献:

- [1] 雷 敏, 杨万里, 李 丹, 等. 分布式电源并网对配电网的影响 [J]. 湖南工业大学学报, 2014, 28(5): 68-73.
LEI Min, YANG Wanli, LI Dan, et al. Effect of Distributed Generation Grid-Connection on Distribution System[J]. Journal of Hunan University of Technology, 2014, 28(5): 68-73.
- [2] 雷 敏, 徐 波, 华一飞, 等. 基于 SHEKF-GPM 融合的锂电池 SOC 估算 [J]. 湖南工业大学学报, 2020, 34(6): 10-15.
LEI Min, XU Bo, HUA Yifei, et al. State of Charge Estimation of Lithium Battery Based on SHEKF-GPM Fusion[J]. Journal of Hunan University of Technology, 2020, 34(6): 10-15.
- [3] GUO B Q, NIU M, LAI X K, et al. Application Research on Large-Scale Battery Energy Storage System Under Global Energy Interconnection Framework[J]. Global Energy Interconnection, 2018, 1(1): 79-86.
- [4] 雷 敏, 华一飞, 赵洪山, 等. 计及电池寿命的电动汽车参与电网调峰策略 [J]. 现代电力, 2020, 37(5): 510-517.
LEI Min, HUA Yifei, ZHAO Hongshan, et al. Strategy of Electric Vehicles Participating Peak Load Regulation of Power Grid Considering Battery Life[J]. Modern Electric Power, 2020, 37(5): 510-517.
- [5] 肖 迁, 焦志鹏, 穆云飞, 等. 基于 LightGBM 的电动汽车行驶工况下电池剩余使用寿命预测 [J]. 电工技术学报, 2021, 36(24): 5176-5185.
XIAO Qian, JIAO Zhipeng, MU Yunfei, et al. Light GBM Based Remaining Useful Life Prediction of Electric Vehicle Lithium-Ion Battery Under Driving Conditions[J]. Transactions of China Electrotechnical Society, 2021, 36(24): 5176-5185.
- [6] 王 帅, 韩 伟, 陈黎飞, 等. 基于粒子滤波的锂离子电池剩余寿命预测 [J]. 电源技术, 2020, 44(3): 346-351.
WANG Shuai, HAN Wei, CHEN Lifei, et al. Prediction of Lithium Ion Batteries Remaining Useful Life Based on Particle Filtering Method[J]. Chinese Journal of Power Sources, 2020, 44(3): 346-351.
- [7] ZHANG X, MIAO Q, LIU Z W. Remaining Useful Life Prediction of Lithium-Ion Battery Using an Improved UPF Method Based on MCMC[J]. Microelectronics Reliability, 2017, 75: 288-295.
- [8] 刘 健, 陈自强, 黄德扬, 等. 基于等压差充电时间的锂离子电池寿命预测 [J]. 上海交通大学学报,

- 2019, 53(9): 1058-1065.
- LIU Jian, CHEN Ziqiang, HUANG Deyang, et al. Remaining Useful Life Prediction for Lithium-Ion Batteries Based on Time Interval of Equal Charging Voltage Difference[J]. Journal of Shanghai Jiaotong University, 2019, 53(9): 1058-1065.
- [9] 徐佳宁, 倪裕隆, 朱春波. 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.
- XU Jianing, NI Yulong, ZHU Chunbo. Remaining Useful Life Prediction for Lithium-Ion Batteries Based on Improved Support Vector Regression[J]. Transactions of China Electrotechnical Society, 2021, 36(17): 3693-3704.
- [10] HARIHARAN K S, KUMAR V S. A Nonlinear Equivalent Circuit Model for Lithium Ion Cells[J]. Journal of Power Sources, 2013, 222: 210-217.
- [11] PATIL M A, TAGADE P, HARIHARAN K S, et al. A Novel Multistage Support Vector Machine Based Approach for Li Ion Battery Remaining Useful Life Estimation[J]. Applied Energy, 2015, 159: 285-297.
- [12] LIU F G, ZHENG J Z, ZHENG L L, et al. Combining Attention-Based Bidirectional Gated Recurrent Neural Network and Two-Dimensional Convolutional Neural Network for Document-Level Sentiment Classification[J]. Neurocomputing, 2020, 371: 39-50.
- [13] XU C Y, SHEN J Z, DU X, et al. An Intrusion Detection System Using a Deep Neural Network with Gated Recurrent Units[J]. IEEE Access, 2018, 6: 48697-48707.
- [14] 雷敏, 杨万里, 彭晓波, 等. 基于改进简化粒子群算法的含 DG 的配电网无功优化[J]. 华北电力大学学报(自然科学版), 2015, 42(1): 39-44.
- LEI Min, YANG Wanli, PENG Xiaobo, et al. Reactive Power Optimization of the Distribution Network with Distributed Generation Based on Improved Simple PSO Algorithm[J]. Journal of North China Electric Power University (Natural Science Edition), 2015, 42(1): 39-44.
- [15] 王瀛洲, 倪裕隆, 郑宇清, 等. 基于 ALO-SVR 的锂离子电池剩余使用寿命预测[J]. 中国电机工程学报, 2021, 41(4): 1445-1457, 1550.
- WANG Yingzhou, NI Yulong, ZHENG Yuqing, et al. Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Support Vector Regression Optimized and Ant Lion Optimizations[J]. Proceedings of the CSEE, 2021, 41(4): 1445-1457, 1550.
- [16] 卢婷, 杨文强. 锂离子电池全生命周期内评估参数及评估方法综述[J]. 储能科学与技术, 2020, 9(3): 657-669.
- LU Ting, YANG Wenqiang. Review of Evaluation Parameters and Methods of Lithium Batteries Throughout Its Life Cycle[J]. Energy Storage Science and Technology, 2020, 9(3): 657-669.
- [17] 于海芳, 陈文帅. 锂离子动力电池寿命预测技术综述[J]. 电源技术, 2018, 42(2): 304-307.
- YU Haifang, CHEN Wenshuai. Summary of Life Prediction Technology for Lithium-Ion Power Batteries[J]. Chinese Journal of Power Sources, 2018, 42(2): 304-307.

(责任编辑: 申剑)