

# 基于最优权阈值 ELM 算法的锂离子电池 RUL 预测

刘 柱<sup>1</sup>, 姜媛媛<sup>1,2</sup>, 罗 慧<sup>3</sup>, 周利华<sup>1</sup>

(1. 安徽理工大学电气信息与工程学院, 淮南 232001; 2. 南京航空航天大学自动化学院, 南京 210016;  
3. 南京农业大学工学院, 南京 210031)

**摘要:** 针对锂离子电池剩余使用寿命 RUL(remaining useful life) 预测结果不准确及极限学习机 ELM(extreme learning machine) 权阈值随机选取等问题, 提出利用 ELM 模型间接预测锂离子电池 RUL 的方法, 并利用遗传蚂蚁算法 GAAA(genetic algorithm ant algorithm) 选取 ELM 的最优权值与阈值, 建立基于等压降放电时间间接寿命特征参数的最优 GAAA-ELM 锂离子电池 RUL 预测模型。基于 NASA 锂离子电池数据集预测和评估锂离子电池的 RUL, 并与 BP 模型预测方法、ELM 模型预测方法和 GA-ELM 模型预测方法相比较, 结果表明该方法能够更准确有效地实现锂离子电池 RUL 预测。

**关键词:** 极限学习机(ELM); 锂离子电池; 遗传蚂蚁算法(GAAA)

## Prediction of Lithium-ion Battery RUL Based on Optimal Weight and Threshold Using ELM Algorithm

LIU Zhu<sup>1</sup>, JIANG Yuanyuan<sup>1,2</sup>, LUO Hui<sup>3</sup>, ZHOU Lihua<sup>1</sup>

(1. School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China;  
2. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;  
3. College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

**Abstract:** Since the predictions of lithium-ion battery remaining useful life(RUL) are inaccurate and the selection of weights and thresholds for an extreme learning machine(ELM) is random, an indirect prediction method for lithium-ion battery RUL is proposed based on ELM model. Moreover, the optimal weight and threshold of ELM are selected using genetic algorithm-ant algorithm(GAAA), and the prediction model for lithium-ion battery RUL using GAAA-ELM is established based on the time interval to equal discharging voltage which is a kind of indirect life feature character. Finally, the lithium-ion battery RUL is predicted and assessed based on NASA data sets of lithium-ion battery, which is further compared with that obtained using BP, ELM, and GA-ELM prediction model methods, showing that the proposed method can accurately and effectively predict the lithium-ion battery RUL.

**Keywords:** extreme learning machine(ELM); lithium-ion battery; genetic algorithm-ant algorithm(GAAA)

收稿日期: 2016-04-29; 修回日期: 2018-03-30

基金项目: 国家自然科学基金资助项目(51604011); 安徽省自然科学基金资助项目(1708085QF135); 安徽省高校自然科学基金资助项目(KJ2017A077); 安徽省高校优秀青年骨干人才国外访学研修资助项目(gxfx2017025)

Project Supported by National Natural Science Foundation of China(51604011); Natural Science Foundation of Anhui Province(1708085QF135); University Natural Science Foundation of Anhui Province(KJ2017A077); Study Abroad for Young Scholar of Anhui Province(gxfx2017025)

锂离子电池是一种具有比能量大、自放电率低、安全性能好、循环寿命长等优点的绿色充电电池, 因而被广泛用于消费数码类、动力安防类、医疗保健类和航空航天等领域<sup>[1-4]</sup>。锂离子电池良好的工作状态既可以保证仪器设备的正常使用, 也可以避免严重的故障事故。锂离子电池剩余寿命 RUL(remaining useful life) 的预测作为农业技术领域的关键技术之一, 目前已经成为国内外的研究热点。

目前国内外主流的锂离子电池 RUL 预测方法是基于数据驱动的方法,其利用锂离子电池寿命特征参数,借助算法模型,如贝叶斯推理概率<sup>[5]</sup>、支持向量机<sup>[6]</sup>、高斯过程回归<sup>[7]</sup>、回声状态网络<sup>[8]</sup>、极限学习机<sup>[17]</sup>等,进行分析与预测,以得到电池寿命参数趋势和退化程度等信息。极限学习机 ELM(extreme learning machine)具有训练速度快、预测精度高和参数设置简单等优点,被广泛用于电力价格预测<sup>[9]</sup>、风力发电预测<sup>[10]</sup>、工业指标参数预测<sup>[11]</sup>等方面。ELM 用于预测时,由于其输入层与隐含层间的权值以及隐含层阈值的随机选取,导致每次的训练结果不同,并存在细微偏差,进而影响模型的预测精度,因此可寻求最优的 ELM 权阈值以获取最好的预测效果。文献[12]基于遗传算法 GA(genetic algorithm)优化 ELM 的权阈值,但 GA 寻优过程中容易陷入局部最优,致使预测精度也呈现局部最好而非全局最好。蚁群算法 ACO(ant colony optimization)是一种具有正反馈机制的模拟进化算法,能够较大概率地发现最优解且搜索过程不易陷入局部最优,但蚁群算法需要较长的搜索时间,不适用于在线搜索。

为此,本文充分利用遗传算法的快速性、随机性、收敛性与蚂蚁算法的并行性、正反馈性、求解精度高特点,融合 GA 和 ACO 两种算法,构造基于遗传蚂蚁算法 GAAA(genetic algorithm ant algorithm)的最优权阈值 ELM 锂离子电池性能预测模型,基于间接参数(等压放电时间)和直接参数(实际容量)的两种预测方法,最终实现锂离子电池剩余寿命的快速准确预测。

## 1 最优权阈值 ELM 预测方法

### 1.1 极限学习机

极限学习机 ELM 是 Huang 等<sup>[13]</sup>提出的单隐层前馈神经网络 SLFN(singlehidden layer feedforward neutral network),其机理简单描述如下。

首先给出  $m$  个输入变量,  $M$  个隐含神经元,  $n$  个输出隐含层神经元。ELM 的数学表达式为

$$\mathbf{v}_k = \boldsymbol{\omega}^T g(\mathbf{W}_m \mathbf{u}_k + \mathbf{b}) \quad k=1, 2, \dots, N \quad (1)$$

式中:  $g$  为激活函数,取 Sigmoid 函数;  $\mathbf{W}_m$  为输入权值;  $\boldsymbol{\omega}$  为输出权值;  $\mathbf{b}$  为隐含层偏差值;  $N$  为样本总数;  $\mathbf{u}_k$  为  $m$  维输入变量;  $\mathbf{v}_k$  为输出变量。

设有  $N$  个样本对为  $(\mathbf{u}_i, I_i), 1 \leq i \leq N$ 。训练时,输入权值  $\mathbf{W}_m$  和偏差值  $\mathbf{b}$  随机初始化并保持不变,只要确定隐含层神经元个数及隐含层激活函数,即可计算出输出权值  $\boldsymbol{\omega}$ ,具体算法为

$$\boldsymbol{\omega} = \mathbf{H}^+ \mathbf{I} \quad (2)$$

式中:  $\mathbf{H}^+$  为隐含层输入矩阵  $\mathbf{H}$  的摩尔-彭洛斯(Moore-Penrose)广义逆矩阵<sup>[14]</sup>;  $\mathbf{I}$  为期望输出矩阵,  $\mathbf{I} = (I_1, I_2, \dots, I_N)^T$ 。将  $\mathbf{H}$  展开为

$$\mathbf{H} = \begin{bmatrix} g(\mathbf{W}_m \mathbf{u}_1 + \mathbf{b}_1) & \cdots & g(\mathbf{W}_m \mathbf{u}_1 + \mathbf{b}_n) \\ \vdots & & \vdots \\ g(\mathbf{W}_m \mathbf{u}_N + \mathbf{b}_1) & \cdots & g(\mathbf{W}_m \mathbf{u}_N + \mathbf{b}_n) \end{bmatrix}_{N \times n} \quad (3)$$

相比于传统的梯度下降理论算法,极限学习机学习速度更快,具有更好的泛化性能,应用于锂离子电池 RUL 预测能够极大地提高预测的速度与准确性,尤其在输入权值  $\mathbf{W}_m$  和隐含层偏差值  $\mathbf{b}$  最优时预测精度最佳。

### 1.2 基于 GAAA 的最优权阈值 ELM 预测

GA 是以生物进化方式编制的全局搜索算法<sup>[15]</sup>,其只需进行选择、杂交、变异 3 种遗传运算就可寻出最优解,具有快速性、随机性和收敛性等优点。ACO 是一种基于种群寻优的启发式搜索算法<sup>[16]</sup>,通过对不同种群间的信息素识别选择合适的搜寻路径,具有并行性、正反馈性、求精解效率高等优点。GAAA 采用 GA 初步寻优,生成初始信息素分布,再利用 ACO 深度寻优,使两种算法优劣互补,在求解效率上优于 GA,在时间效率上优于 ACO。

ELM 具有良好的训练速度和泛化性能,由于 ELM 固有的权阈值随机性会影响其泛化性能和预测精度,故采用 GAAA 优化 ELM 的权值与阈值。其实现流程如图 1 所示。

具体实现步骤可分为以下 4 个阶段。

(1)数据预处理。先将数据集划分为训练样本与测试样本,再将训练样本划分为训练样本输入与训练样本输出,对训练样本输入编码,产生初始种群。

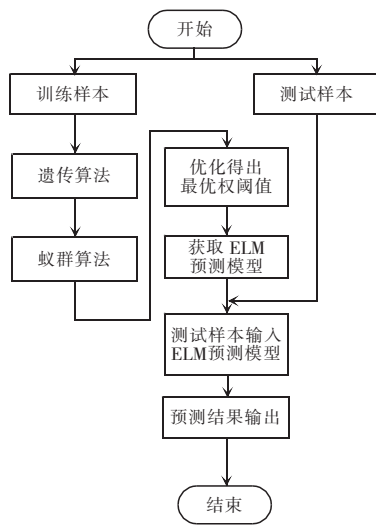


图 1 GAAA 融合算法对 ELM 寻优流程

Fig.1 Flow chart of ELM optimization using GAAA fusion algorithm

(2)遗传算法。定义适应度函数,生成初始种群,对于得到的群体进行选择、复制、交叉、变异操作,生成下一代种群,辨别算法终止条件;算法终止后,得到权阈值的初始信息素分布,进入蚁群算法。

遗传算法中,以 ELM 训练集预测平均误差作为其适应度函数,即

$$\Phi(X) = \frac{\sum_{i=1}^{N_T} |\hat{X}_i - X_i|}{N_T} \quad (4)$$

式中: $\hat{X}_i$ 为训练样本输出值; $X_i$ 为训练样本真实值; $N_T$ 为训练样本个数。遗传算法的终止条件为:达到最大迭代次数  $G_{GA-max}$  或者连续  $d$  代进化率  $\Delta_{GA}$  小于最小进化率  $\Delta_{GA-min}$ 。

(3)蚁群算法。适应度函数的选择与遗传算法相同,设置初始信息素  $\lambda$  和蚂蚁数量  $N_0$ ,辨别算法是否终止。若满足,则算法终止;若不满足,则信息素挥发,继续寻优。算法终止后,得出最优权值与阈值,用于 ELM 预测。

蚁群算法中,适应度函数的选取与遗传算法相同;初始信息素  $\lambda_0$  设置由 GA 优化解得出;经过  $s$  个时间段,蚂蚁完成 1 次循环,信息素的更新方程为

$$\lambda_{ij}(t+s) = (1-\rho)\lambda_{ij}(t) + \sum_{k=1}^s \Delta\lambda_{ij}^k \quad (5)$$

式中: $\sum_{k=1}^s \Delta\lambda_{ij}^k$ 为第  $k$  只蚂蚁在路径  $(i,j)$  上的信息素增量; $s$  为经历时间段; $\rho$  为信息素衰减系数。蚁群算法的终止条件为:达到最大迭代次数  $G_{ACO-max}$  或者连续  $f$  代改进率  $\Delta_{ACO}$  小于最小改进率  $\Delta_{ACO-min}$ 。

(4)ELM 预测。由步骤(3)获取 ELM 预测模型,将测试样本输入 ELM 预测模型,得出结果。

## 2 实验结果与分析

### 2.1 实验数据的获取

本文对 NASA PCoE 研究中心测试的锂离子电池数据集进行 RUL 预测。采用型号为 18650、容量为 2 A·h 的市售锂离子电池,实验分为多组进行,测试温度为 25 °C。测试方式为:先以 1.5 A 恒流充电,电压达到 4.2 V 后,再以 2.0 A 恒流放电至 2.5 V;如此循环进行,测量监测数据。本文以第 3 组 5 号电池实验数据作为 ELM 预测模型验证实例,以锂离子电池额定容量的 70%作为失效阈值<sup>[7]</sup>,失效阈值为 1.38 Ah。

### 2.2 间接寿命特征参数

锂离子电池寿命特征参数分为直接参数(实际容量)与间接参数(电压、电流、阻抗等)。实际应用中,常用传感器难以检测锂离子电池内部机理状态,直接参数的获取一般通过安时法估算得出,对于有限数据,采用直接预测方法会因为缺少历史数据导致预测建模模型不准确。因此,本文离线监测采用直接预测方法,而在线监测采用间接预测方法。本文选用等压降放电时间作为锂离子电池间接寿命特征参数,即温度恒定时,锂离子电池从一高电位恒流放电到一低电位所用的时间即为等压降放电时间,数学表达式为

$$t_{i(HL)} = |t_{V_H} - t_{V_L}| \quad i=1,2,\dots \quad (6)$$

式中: $t_{i(HL)}$ 为第  $i$  个循环寿命周期下等压降放电时间差; $t_{V_H}$ 为高电压时所对应的时间; $t_{V_L}$ 为低电压时所对应的时间。

等压降放电时间与实际容量如图 2 所示。通过一阶偏相关系数法<sup>[7]</sup>确定等压降放电时间序列与

实际容量序列之间的相关性,基于 NASA 的锂离子电池数据得出相关系数为 0.784 4,为强相关性,表明间接寿命特征参数可以表征锂离子电池的健康状况,能够用于锂离子电池 RUL 预测。因此,基于锂离子电池特征参数时间序列,构建最优权阈值 ELM 预测模型,预测出锂离子电池未来时刻的特征参数,以评估其 RUL。




图 2 等压降放电时间与实际容量

Fig.2 Time interval to equal discharging voltage and the actual capacity

### 2.3 等压降放电时间预测实际容量的 GAAA-ELM 模型

选取放电阶段为  $t_{V_H}$  (对应高电压为 3.8 V) 至  $t_{V_L}$  (对应低电压为 3.5 V),以等压降放电时间  $T_i$  作为模型输入,实际容量  $Q_i$  作为模型输出。其中,B5 中共有 168 组等压降放电时间和实际容量数据,取前 100 组作为训练集,后 68 组作为测试集,运行 GAAA 优化 ELM 神经网络模型。根据实测,相关参数设置如表 1 所示,模型预测结果如图 3 所示。

由图 3 可知,此时预测实际容量失效阈值  $Q_f$  所对应的等压降时间失效阈值  $T_f$  即为间接寿命特征参数的预测失效阈值。

### 2.4 等压降放电时间的 GAAA-ELM 预测模型

构建等压降放电时间预测的 GAAA-ELM 神经网络模型,以 B5 中 168 组等压降放电时间的前 100 组作为训练集,后 68 组作为测试集,参数设置与等压降放电时间与实际容量的关系模型相同,实现  $\{c, \hat{t}_c\}_{c=101}^{c=168}$  的等压降放电时间迭代预测,等压降放电时间失效阈值  $T_f$  已由图 3 结果求出,预测结果如图 4 所示。

表 1 GAAA 优化 ELM 神经网络参数设置

Tab.1 Parameter setting of ELM neural network using GAAA optimization

| GAAA-ELM 参数                          | 设置     | GAAA-ELM 参数           | 设置    |
|--------------------------------------|--------|-----------------------|-------|
| ELM 隐含层节点数 $M_H$                     | 60     | GA 串长 $l$             | 20    |
| GA 初始种群 $n_c$                        | 30     | GA 交叉概率 $p_c$         | 0.8   |
| GA 编码方式                              | 二进制编码  | GA 变异概率 $p_m$         | 0.01  |
| GA 选择操作                              | 最优保存策略 | $G_{GA-max}$          | 50    |
| GA 交叉算子                              | 一点交叉   | $\Delta_{GA-min}/\%$  | 0.5   |
| GA 变异算子                              | 离散变异   | $d$                   | 3     |
| GA 适应度函数                             | 均相对误差  | 最小平                   | 最小平   |
| $G_{ACO-max}$                        | 100    | ACO 适应度函数             | 均相对误差 |
| $f$                                  | 3      | $\Delta_{ACO-min}/\%$ | 0.5   |
| $\sum_{k=1}^s \Delta \lambda_{ij}^k$ | [0,1]  | $N_0$                 | 30    |
|                                      |        | $\rho$                | 0.2   |




图 3 真实实际容量与 GAAA-ELM 模型预测的容量  
Fig.3 The true actual capacity and the capacity predicted using GAAA-ELM model

由图 4 可知,从模型预测的等压降放电时间失效阈值  $\hat{T}_f$  代入图 3 中,可得出预测实际容量  $\hat{Q}_c$ ,即为预测实际容量失效阈值。

### 2.5 等压降放电时间预测锂离子电池 RUL 实验结果分析

利用等压降放电时间作为寿命特征参数,将本文提出的 GAAA-ELM 预测模型与传统 BP(back propagation)神经网络(BP 神经网络采用与 ELM 神经网络




图4 基于GAAA-ELM预测模型的等压降放电时间预测结果

Fig.4 Prediction result of the time interval to equal discharging voltage based on GAAA-ELM prediction model

络相同的节点数与激活函数)、ELM及GA-ELM预测模型相比较,结果如表2所示。

表2中, $RUL_{error}$ 为锂离子电池剩余寿命预测误差,MAPE为预测结果平均相对误差,时间为预测所花费时间,则有

$$RUL_{error} = RUL_{pr} - RUL_{tr} \quad (7)$$

式中: $RUL_{pr}$ 为剩余寿命预测值; $RUL_{tr}$ 为剩余寿命真实值。

$$MAPE = \frac{1}{N_1} \sum_{i=1}^{N_1} \left| \frac{RUL_{tri} - RUL_{pri}}{RUL_{tri}} \right| \times 100\% \quad (8)$$

式中, $N_1$ 为测试次数。

表2 基于等压降放电时间的4种锂离子电池RUL预测模型性能对比

Tab.2 Performance comparison among four kinds of lithium-ion battery RUL prediction models based on pressure drop discharge time

| 预测模型     | $RUL_{error}$ | MAPE/% | 时间/s   |
|----------|---------------|--------|--------|
| BP       | -5.2          | 7.50   | 5.254  |
| ELM      | -3.9          | 5.75   | 2.475  |
| GA-ELM   | -3.2          | 4.65   | 10.746 |
| GAAA-ELM | -2.5          | 4.25   | 6.546  |

由表2可知:ELM预测方法在预测时间和精度上面都明显优于传统BP方法,训练效率得到了提升;GAAA-ELM预测方法在时间和精度上都优于GA-ELM预测方法,并且相对于ELM预测方法具有更好的预测精度,具有良好的实用价值。

## 2.6 实际容量预测锂电池RUL实验结果分析

利用容量作为寿命特征参数,将本文提出的

GAAA-ELM预测模型与传统BP神经网络、ELM及GA-ELM预测模型相比较,4种预测模型参数设置与利用等压降放电时间参数设置相同,结果如表3所示。

表3 基于实际容量值的4种锂离子电池RUL预测模型性能对比

Tab.3 Performance comparison among four kinds of lithium-ion battery RUL prediction models based on real capacity

| 预测模型     | $RUL_{error}$ | MAPE/% | 时间/s  |
|----------|---------------|--------|-------|
| BP       | -4.7          | 6.80   | 2.424 |
| ELM      | -4.1          | 5.25   | 1.732 |
| GA-ELM   | -2.8          | 4.25   | 5.362 |
| GAAA-ELM | -2.1          | 3.80   | 3.225 |

由表3可知,ELM的学习速度比BP神经网络快的多,而ELM参数设置比BP神经网络更少。优化后的ELM神经网络具有更高的训练精度,符合锂离子电池RUL的实际预测。

## 3 结语

本文通过对等压降放电时间与实际容量进行锂离子电池RUL预测,给出了基于GAAA优化ELM最优权阈值的方法体系。采用NASA公开的锂离子电池数据集测试验证了GAAA-ELM方法具有良好的RUL预测能力,符合数据测量方便、算法简单、处理速度快、结果准确等优点;并与传统的BP方法、ELM预测方法和GA-ELM预测方法相比较,其结果表明本文所提出的GAAA-ELM预测方法具有更好的实用性与更高的预测精度。

## 参考文献:

- [1] 吕航,刘承志,沈金锁,等.磷酸铁锂电池组的均衡控制策略优化研究[J].电源学报,2015,13(3):107-112.  
Lü Hang, Liu Chengzhi, Sheng Jinsuo, et al. Research on optimized balancing control system for  $LiFePO_4$  battery stacks[J]. Journal of Power Supply, 2015, 13(3): 107-122 (in Chinese).
- [2] 周佳男,陈敏,李海津,等.超级UPS中锂电池功率变换

- 单元设计[J]. 电源学报, 2015, 13(3): 21-27.
- Zhou Jianan, Chen Min, Li Haijin, et al. Design of li-ion battery power conversion system applied in super UPS[J]. Journal of Power Supply, 2015, 13(3): 21-27(in Chinese).
- [3] 邓磊, 王立欣, 葛腾飞, 等. 基于改进 PNGV 模型的动力锂电池快速充电优化[J]. 电源学报, 2014, 12(4): 10-14.
- Deng Lei, Wang Lixin, Ge Tengfei, et al. Multi-objective optimization of power li-ion battery quick charging based on improved PNGV model[J]. Journal of Power Supply, 2014, 12(4): 10-14(in Chinese).
- [4] 雷治国, 张承宁, 李军求. 电动车辆用锂离子电池热特性研究[J]. 电源学报, 2014, 12(4): 83-87.
- Lei Zhiguo, Zhang Chengning, Li Junqiu, et al. Research on thermal characteristics of EVs lithium-ion battery [J]. Journal of Power Supply, 2014, 12(4): 83-87(in Chinese).
- [5] Yu Jianbo. State-of-health monitoring and prediction of lithium-ion battery using probabilistic indication and state-space model[J]. IEEE Transactions on Instrumentation and Measurement, 2015, 64(11): 2937-2949.
- [6] Alvarez Anton J C, Garcia Nieto P J, Blanco Viejo C, et al. Support vector machines used to estimate the battery state of charge[J]. IEEE Transactions on Power Electronics, 2013, 28(12): 5919-5926.
- [7] 庞景月, 马云彤, 刘大同, 等. 锂离子电池剩余寿命间接预测方法[J]. 中国科技论文, 2014, 9(1): 28-36.
- Pang Jingyue, Ma Yuntong, Liu Datong, et al. Indirect remaining useful life prognostics for lithium-ion battery [J]. China Sciencepaper, 2014, 9(1): 28-36(in Chinese).
- [8] Liu Datong, Xie Wei, Liao Haitao, et al. An integrated probabilistic approach to lithium-ion battery remaining useful life estimation[J]. IEEE Transactions on Instrumentation and Measurement, 2015, 64(3): 660-670.
- [9] Chen Xia, Dong Zhaoyang, Meng Ke, et al. Electricity price forecasting with extreme learning machine and bootstrapping[J]. IEEE Transactions on Power Systems, 2012, 27(4): 2055-2062.
- [10] Wan Can, Xu Zhao, Pinson P, et al. Probabilistic forecasting of wind power generation using extreme learning machine[J]. IEEE Transactions on Power Systems, 2014, 29(3): 1033-1044.
- [11] Ning Kefeng, Liu Min, Dong Mingyu, et al. Two efficient twin ELM methods with prediction interval[J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26(9): 2058-2071.
- [12] 谢国民, 丁会巧, 付华, 等. 基于 FRS 与 GA-ELM 的煤与瓦斯突出预测研究[J]. 传感技术学报, 2015(11): 1670-1675.
- Xie Guoming, Ding Huiqiao, Fu Hua, et al. Based on the FRS with GA-ELM coal and Gas outburst prediction research[J]. Chinese Journal of Sensors and Actuators, 2015(11): 1670-1675(in Chinese).
- [13] Lan Y, Soh Y C, Huang Guangbin. Ensemble of online sequential extreme learning machine[J]. Neurocomputing, 2009, 72: 3391-3395.
- [14] Zhao Jianwei, Wang Zhihui, Park D S. Online sequential extreme learning machine with forgetting mechanism[J]. Neurocomputing, 2012, 87(11): 79-89.
- [15] Goldberg D E. Genetic algorithms in search, optimization and machine learning[M]. New Jersey: Addison Wesley Publishing Company, 1989.
- [16] Dorigo M, Maniezzo V, Colomi A. The ant system: optimization by a colony of cooperating agents[J]. IEEE Transactions on Systems, Man and Cybernetics-Part B, 1996, 26(1): 29-41.
- [17] 姜媛媛, 刘柱, 罗慧, 等. 锂电池剩余寿命的 ELM 间接预测方法[J]. 电子测量与仪器学报, 2016, 30(2): 179-185.
- Jiang Yuanyuan, Liu Zhu, Luo Hui, et al. ELM indirect method of prediction of the remaining life of lithium batteries[J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(2): 179-185(in Chinese).



刘柱

## 作者简介:

刘柱(1993-)男,硕士研究生,研究方向:系统测试与健康管埋,E-mail: liuzhu1105010118@163.com。

姜媛媛(1982-),女,通信作者,博士研究生,教授,硕士生导师,研究方向:电子系统的故障预测与健康管埋,E-mail: jyyll672@163.com。

罗慧(1982-)女,博士,讲师,研究方向:电子设备故障检测和信号处理,E-mail: lh821005@126.com。

周利华(1991-),女,硕士研究生,研究方向:系统故障预测与管埋,E-mail: 1107205745@qq.com。