

DOI: 10.13382/j.jemi.B1902651

利用 QPSO 改进相关向量机的电池寿命预测^{*}

何 畏 罗 潇 曾 珍 黄飞扬 徐 杨
(西南石油大学 机电工程学院 成都 610500)

摘 要:锂离子电池作为系统供能的关键部分,其寿命终结往往导致用电设备的性能下降或故障,甚至整个系统的崩溃。因此,研究电池剩余使用寿命(RUL),提前预知失效时间,显得日趋重要。针对锂离子电池寿命预测过程中训练时间较长、参数确定困难、输出结果不稳定等问题,提出了利用泛化能力更好,更稀疏,测试时间更短,更适用于在线检测的相关向量机(RVM)进行预测,并通过量子粒子群对相关向量机进行了优化,保证了预测输出结果的稳定性。分析结果表明,量子粒子群算法改进后的相关向量机对锂电池失效时间的预测准确度高达 99%,电池寿命预测的绝对误差平均值 2%,均方根误差 3%,验证了该改进算法的可行性和优越性。

关键词: 锂离子电池;剩余使用寿命预测;稳定性;相关向量机;量子粒子群

中图分类号: TP206.3;TN86 **文献标识码:** A **国家标准学科分类代码:** 120.30

Battery life prediction based on QPSO improved relevant vector machine

He Wei Luo Xiao Zeng Zhen Huang Feiyang Xu Yang
(School of Mechanical and Electrical Engineering, Southwest Petroleum University, Chengdu 610500, China)

Abstract: As a key part of system energy supply, the end of life of lithium-ion battery often leads to the degradation or failure of the electrical equipment, or even the collapse of the whole system. Therefore, it is increasingly important to study the remaining useful life (RUL) of the battery and predict the failure time in advance. Aiming at the problems of long training time, difficult parameter determination and unstable output results during the life prediction process of lithium-ion batteries, this paper puts forward the Relevance Vector Machine (RVM) which is more suitable for on-line detection and has better generalization ability, sparser parameter and shorter test time, and optimizes relevance vector machine (RVM) through quantum particle swarm optimization (QPSO) to ensure the stability of predicted output results. The results show that the prediction accuracy of the improved relevance vector machine (QPSO-RVM) is up to 99%, the mean absolute error of battery life prediction is about 2% and the root mean square error is about 3%, which verifies the improved algorithm feasibility and superiority.

Keywords: lithium-ion battery; remaining useful life; stability; relevance vector machine; quantum particle swarm optimization

0 引 言

伴随着智能时代的来临,锂离子电池以其容量大、体积小、重量轻、寿命长、续航时间长和安全性好的特点被广泛使用,已经成为当前电池业的支柱。同时,锂离子电池凭借其独特优势促进了新能源行业的发展,对于优化能源的利用效率、缓解现今世界能源危机和保护环境都

具有重要战略意义^[1]。

随着锂离子电池的广泛使用,预测锂离子电池的剩余使用寿命(remaining useful life, RUL)显得更为重要^[2-3],及时准确的 RUL 预测可以在闲时提前更换即将失效的电池,提高锂离子电池的使用效率,同时也进一步提高了锂离子电池在使用过程中的安全性。

对电池的剩余使用寿命预测主要方法分为 3 类,基于电池模型的预测、基于数据驱动的间接预测和基于统

计分布的预测^[4]。其中基于数据驱动预测方法是锂电池寿命预测的主要方法。数据驱动的预测方法主要是通过机器学习的方法利用数据训练样本对模型的特征参数进行训练,得到预测精度较高的模型,常用的数据驱动方法有支持向量机(support vector machine, SVM),神经网络,相关向量机(relevance vector machine, RVM),滤波法^[5-6]等。文献[7]提出了一种结合核主元分析法(KPCA)特征提取与自适应神经网络模糊推理系统(ANFIS)的锂电池剩余寿命预测方法,结果表明剩余寿命预测精度得到一定的提高。文献[8]提出利用混合粒子群优化算法对极限学习机预测模型优化的方法,增加了锂离子电池剩余寿命预测结果的准确性。然而神经网络相关算法存在训练时间长,需要确定的参数较多,且容易陷入局部极值的问题,应用在实际工程设备上有一定的困难,对设备运算能力要求较高,不利于设备间差异化在线训练快速训练和预测。SVM 算法的运用克服了神经网络算法的一部分缺点,利用 SVM 算法在选取合适的核函数进行预测锂电池寿命取得了一定的效果^[9-11],但是 SVM 也存在一定的不足,在模型训练中支持向量机算法的支持向量数量与训练样本数量的增长线性正相关,会导致预测模型的复杂化,同时 SVM 算法对核函数的选取依赖性较强。

相关向量机算法是在 Bayesian 框架的基础上构建的模型,与 SVM 相比,其核函数不需要遵循 Mercer 定理,且输出结果具有不确定性,可以自动调节超参数,泛化能力较好,RVM 更加稀疏,从而测试时间更短,更适用于在线检测。但是直接运用 RVM 算法会由于算法本身更加稀疏,且容量数据存在动态波动导致预测结果的稳定性较差。针对这个缺点,构建了一种利用量子粒子群(QPSO)优化相关向量机算法,在保证 RVM 算法的快速性和稀疏性的前提下,使输出结果更加稳定。

1 RVM 模型描述

RVM 是 Tipping 于 2000 年在贝叶斯框架的基础上提出的一种稀疏概率模型,是一种新的监督学习方法^[12]。

RVM 在 Bayesian 框架下进行训练,在先验参数的结构下,基于主动相关决策理论来剔除不相关的点,由此获得稀疏化的模型。通过样本数据的迭代,大部分参数的后验分布趋于 0,进而与预测值无关,剩下非零参数对应的点被称为相关向量(relevance vectors),这些向量体现着数据最核心的特征。相比于支持向量机,相关向量机的核函数不仅无须满足 Mercer 条件,其计算量也大大减少。其预测模型^[13]:

$$y(x; \omega) = \sum_{i=1}^n \omega_i K(x, x_i) + \omega_0 \quad (1)$$

式中: x 代表输入量; $K(x, x_i)$ 表示核函数; ω_n 代表模型权值; N 为样本数。

假定样本都是独立分布, ε_i 表示均值为 0, 方差为 σ^2 的高斯噪声, 则有:

$$t_i = y(x_i, \omega) + \varepsilon_i \quad (2)$$

其中, t_i 服从均值为 $y(x_i, \omega)$, 方差为 σ^2 的高斯分布, $y(\cdot)$ 为非线性函数, 则有:

$$p(t_i | x) = N(t_i | y(x_i), \sigma^2) \quad (3)$$

由于 t_i 是独立分布的, 它的似然函数可以写成:

$$p(\mathbf{t} | \omega, \sigma^2) = (2\pi\sigma^2)^{-N/2} \times \exp\left\{-\frac{1}{2\sigma^2} \|\mathbf{t} - \Phi\omega\|^2\right\} \quad (4)$$

式中: $\mathbf{t}$ 为受高斯分布噪声干扰的模型; ω 为模型权重。

$$\mathbf{t} = (t_1 \cdots t_N)^T$$

$$\omega = (\omega_0 \cdots \omega_n)$$

$$\Phi = [\phi(x_1), \phi(x_2), \cdots, \phi(x_N)]^T$$

$$\phi(x_i) = [1, K(x_i, x_1), K(x_i, x_2), \cdots, K(x_i, x_N)]$$

把超参数引入每一个权值中。RVM 对超参数的约束是通过每个权值定义高斯先验概率分布的方式:

$$p(\omega/\alpha) = \prod_0^N N(\omega_i | 0, \alpha_i^{-1}) = \prod_0^N \frac{\alpha_i}{\sqrt{2\pi}} \exp\left(-\frac{\omega_i^2 \alpha_i}{2}\right) \quad (5)$$

式中: $\alpha = \{\alpha_0, \alpha_1, \cdots, \alpha_N\}$ 是 $N+1$ 个超参数。

SVM 中每个未知参数都有后验公式:

$$p(\omega, \alpha, \sigma^2/t) = \frac{p(\mathbf{t}/\omega, \alpha, \sigma^2)p(\omega, \alpha, \sigma^2)}{p(\mathbf{t})} \quad (6)$$

将新的特征值 x' 输入后, 得到对应的预测值为:

$$p(\mathbf{t}' | \mathbf{t}) = \int p(\mathbf{t}' | \omega, \sigma^2) p(\omega | \alpha, \sigma^2) d\omega d\alpha d\sigma^2 \quad (7)$$

由于 $p(\omega, \alpha, \sigma^2/t) = p(\omega/\alpha, \sigma^2, t)p(\alpha, \sigma^2/t)$, 所以:

$$p(\omega/\alpha, \sigma^2, t) = \frac{p(\mathbf{t}/\omega, \sigma^2)p(\omega/\alpha)}{p(\mathbf{t}/\alpha, \sigma^2)} = (2\pi)^{\frac{N+1}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(\omega-\mu)^T \Sigma^{-1}(\omega-\mu)\right\} \quad (8)$$

式中: $\Sigma = \sigma^2 \mathbf{I} + \Phi \mathbf{A}^{-1} \Phi^T$ 为权重的协方差, $\mathbf{A} = \text{diag}(\alpha_0, \alpha_1, \cdots, \alpha_n)$, 均值 $\mu = \Sigma \Phi^T \mathbf{B} \mathbf{t} (\mathbf{B} = \sigma^2 \mathbf{I})$ 。

用 delta 函数最可能取到的值 α_{MP} 和 σ_{MP}^2 , 对产参数后验 $p(\alpha, \sigma^2/t)$ 进行逼近, 进而求出 $p(\alpha, \sigma^2/t)$ 的最大值。

由于 $p(\alpha, \sigma^2/t) \propto p(\mathbf{t}/\alpha, \sigma^2)p(\alpha)p(\sigma^2)$, 求出 $p(\alpha, \sigma^2/t)$ 的最大值即可。

根据:

$$p(t/\alpha, \sigma^2) = \int p(t/\omega, \sigma^2) p(\omega/\alpha) d\omega \quad (9)$$

利用最大期望 (EM) 迭代法, 求出 α_{MP} 和 σ_{MP}^2 , 从而求出 $p(t/\alpha, \sigma^2)$ 的最大值。

设 $\mathbf{x}_*$ 是新的输入, 则预测均值为:

$$y_* = \boldsymbol{\mu}^T \boldsymbol{\varphi}(\mathbf{x}_*) \quad (10)$$

方差为:

$$\sigma_*^2 = \sigma_{MP}^2 + \boldsymbol{\varphi}(\mathbf{x}_*)^T \boldsymbol{\Sigma} \boldsymbol{\varphi}(\mathbf{x}_*) \quad (11)$$

2 QPSO 优化算法

QPSO 是在经典的粒子群算法 (PSO) 的基础上改良的一种算法^[14]。经典粒子群是由 Eberhart 和 Kennedy 提出的算法^[15], 是一种人类从鸟类觅食活动得到启发开发的一种算法, 模拟这种觅食活动来获得空间最优解。

在经典粒子群算法中, 随着时间的推移, 粒子的运动轨迹是既定的, 所以粒子的搜索空间减小, 并且搜索范围有限不能覆盖整个可行解空间, van den Bergh 等^[16-17]证明了经典粒子群算法不能够保证全局收敛。

由于经典粒子群存在缺点, Sun J 等^[18-19]提出了一种新的量子行为粒子群算法, 并进行了一系列的改进, 量子粒子群算法利用波函数表示粒子的状态, 并通过蒙特卡罗法求出粒子位置。在量子空间中, 粒子在整个可行解空间中进行搜寻, 因此量子粒子群算法具有很好的全局搜索能力。

在 QPSO 算法中, 粒子在势阱中心 δ 满足薛定谔方程。在量子空间中, 粒子的运动状态用波函数 $\psi(x, t)$ 来描述。在量子力学中, 粒子动力学方程为:

$$i\hbar \frac{\partial}{\partial t} \psi(x, t) = -\frac{\hbar^2}{2m} \nabla^2 \psi(x, t) + V(x) \psi(x, t) \quad (12)$$

式中: m 为粒子的质量; $\hbar$ 为普朗克常量; $V(x)$ 为粒子所在的势场。

假定粒子 p 只有一维, 在点 p 建立一维 δ 势阱, 则有:

$$V(x) = -\gamma \delta(x - p) = -\gamma \delta(y), y = x - p \quad (13)$$

将 (12) 式代入式 (13) 得到粒子在 δ 势阱中的定态薛定谔方程为:

$$\frac{d\psi}{dy^2} + \frac{2m}{\hbar^2} [E + \gamma \delta(y)] \psi = 0 \quad (14)$$

式中: E 为粒子的能量。

对式 (14) 求解可得:

$$\psi(y) = \frac{1}{\sqrt{L}} \exp(-|y|/L), (L = \hbar^2/m\gamma) \quad (15)$$

化简到最初的 QPSO 的进化方程为:

$$x = p \pm \frac{L}{2} \ln(1/u') \quad (16)$$

式中: u' 为 (0, 1) 区间均匀分布的随机数。

Sun 等^[20] 对式 (16) 进行了如下改动:

$$x_{ij}(t+1) = p_{ij}(t) \pm \alpha \times |g_{Best} - x_{ij}(t)| \times \ln[1/u_{ij}(t)] \quad (17)$$

式中: α 为收缩-扩张系数, 主要用来控制粒子进化的速度; $x_{ij}(t+1)$ 为 $t+1$ 时刻粒子所在的位置; $p_{ij}(t)$ 为粒子在 t 时刻出现点 p 位置; $u_{ij}(t)$ 为区间 (0, 1) 的均匀分布的随机数; $x_{i,jt}(t)$ 为 t 时刻粒子坐的位置; g_{Best} 为所有粒子个体最优值的平均值。

第 i 个粒子势阱的中心位置为:

$$p = \frac{r_1(t) \times p_i + r_2(t) \times p_g}{r_1(t) + r_2(t)} \quad (18)$$

g_{Best} 的表达式为:

$$g_{Best} = \frac{1}{n} \sum_{i=1}^n p_i(t) = \left[\frac{1}{n} \sum_{i=1}^n p_{i1}, \frac{1}{n} \sum_{i=1}^n p_{i2}(t), \dots, \frac{1}{n} \sum_{i=1}^n p_{id}(t) \right] \quad (19)$$

3 数据预处理

分析原数据可以看出, 原始数据中锂电池的容量并非严格的随着充放电次数的增加而减少, 在个别阶段有反弹现象出现, 如图 1 所示。




图 1 锂电池 B5 放电次数-容量原始数据

Fig. 1 Lithium battery B5 discharge number-capacity raw data

导致这种现象的原因可能是测量误差、信号干扰、容量突变、负载变化和其他尚不了解的原因。这种数据的突然改变影响锂电池寿命预测的准确度, 为了减少噪音的对预测结果的影响, 在预测前对原始数据进行合理的预处理, 对提高预测的准确性有着重要的意义。

本文采用小波降噪方法^[21], 对原始的锂电池容量数据进行降噪。小波降噪是一种实用的降噪方法, 降噪效

果好,易实现,“小波”即小的波形,“小”代表它具有衰减性,而“波”则代表它的波动性,其振幅正负相间的震荡形式,小波变换是根据时频局部化的要求而发展起来的,它对信号(函数)进行通过伸缩平移运算从而实现多尺度细化,达到高频处时间细分,低频处频率细分的效果,具有很好的自适应性和数学显微镜的性质,可以聚焦信号的细节,适合于非平稳、非线性信号的处理。

本文采用二次降噪的方法,其中第一次降噪采用 Sqrtwolog 方法生成阈值,其公式为:

$$Threshold_{\text{sqrtwolog}} = \sqrt{2\log n} \quad (20)$$

第1次降噪后,仍然存在少部分容量起伏,如图2所示。




图2 第1次降噪效果
Fig. 2 First noise reduction effect

第2次降噪采用 minimax 方法生成阈值,即通过极大值极小值生成阈值,其公式为:

$$Threshold_{\text{minimax}} = (c + d) \log n / \log 2 \quad (21)$$

式中: c 和 d 为调节参数, n 为数据 $H(x)$ 的大小。

第2次降噪后,整体曲线平稳,趋势与实验数据非常符合,如图3所示。

4 基于量子粒子群算法的相关向量机参数优化方法

4.1 算法优化思想

相关向量机的核函数无须满足 Mercer 条件,高斯径向基函数非线性处理能力强^[22],本文作为核函数使用:

$$K(x, x_u) = \exp\left(-\frac{\|x - x_u\|}{2d^2}\right) \quad (22)$$




图3 第2次降噪效果
Fig. 3 Second noise reduction effect

式中: d 为宽度因子。

在相关向量机回归预测中,其的核函数宽度直接影响预测的稀疏性和准确性。本文将 RVM 的核函数宽度因子 d 映射为 QPSO 算法的粒子位置进行搜索优化,利用 QPSO 算法找到 RVM 算法核函数宽度的最优取值,在下一阶段的预测过程中使用最优参数提高预测性能。

4.2 算法优化实现步骤

由于 RVM 的核函数宽度因子对预测的稀疏性和准确性有直接影响,为了提高性能,利用 QPSO 算法求解 RVM 算法的最优核函数宽度因子 d ,具体实现步骤如图4所示。

5 仿真实验及分析

5.1 锂电池充放电寿命实验

本文采用的锂电池循环充放电次数与实时容量数据是美国国家宇航局埃姆斯中心提供的真实实验数据。图5所示为美国国家宇航局埃姆斯中心搭建的锂离子电池实验测试台,实验采用的是额定容量2 Ah的市场正常售卖的18650锂电池,在环境温度为24℃的环境中,进行了70个星期的循环充放电寿命实验,实时采样记录了锂电池的电压、电流、阻抗值和温度。

充电过程:先以1.5 A恒流充电,直到电池电压达到4.2 V时,改为恒压充电,当电池电流下降到20 mA结束充电。

放电过程:以2.0 A恒流放电,当电池电压值下降到2.5 V时停止放电。

随着锂电池循环充放电次数的增加,电池的实际容量呈下降趋势,如图6所示。




图 4 优化流程
Fig. 4 Optimized flow chart




图 5 锂离子电池实验测试台
Fig. 5 Lithium ion battery test bench





图 6 NASA 电池数据的容量退化曲线
Fig. 6 Capacity degradation curve of NASA battery data

据惯例,电池容量低于额定容量的 70%~80%即为电池失效,此处我们认为当锂离子电池实际容量退化至


额定容量的 70%时,锂离子电池视为失效,故锂离子电池的实时容量曲线降低至额定容量的 70%时的点即为失效点。

5.2 利用 QPSO 改进相关向量机的电池寿命预测

根据实验得到的锂离子电池充放电次数和电池剩余容量数据来测试 QPSO 对相关向量机参数优化的实际效果。本文分别采用 RVM 和 QPSO-RVM 两种算法来对锂离子电池的寿命进行预测,并将预测结果与实际实验的数据进行对比,以评价算法的预测能力。为更好的验证模型预测能力,将编号为 5、6、18 的锂电池预处理之后的 3 组数据分别带入两种模型中,每组数据的前 80 个数据作为该组的训练组数据,其余数据作为该组的测试组数据,设置容量值为 1.4 Ah 为失效阈值,以编号为 5 的锂电池为例,RVM 和 QPSO-RVM 的预测效果对比如图 7 所示。



(a) RVM 预测结果
(a) RVM prediction results



(b) QPSO-RVM 预测结果
(b) QPSO-RVM prediction results

图 7 预测结果结果对比

Fig. 7 Comparison of prediction results

从图 7 可以看出,量子粒子群改进后的相关向量机预测曲线与失效阈值的交点和实际失效点非常接近,预测效果明显优于为改进的相关向量机。

在此引入电池失效绝对误差均值 (mean absolute error, MAE) 和均方根误差 (root mean square error, RMSE), 以评估预测的准确度。

$$MAE = \frac{1}{m} \sum_{i=1}^m | x(i) - y_{mu}(i) |$$

(23)

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (x(i) - y_{um}(i))^2}$$

(24)

式中: m 是测试集的长度; $x(i)$ 是第 i 次预测时的容量真实值, $y_{mu}(i)$ 是第 i 次预测的容量值, 编号为 5、6、18 的锂电池预测结果的平均绝对误差及均方根误差如表 1 所示。

表 1 算法优化前后误差对比

Table 1 Comparison of errors before and after optimizing algorithms

算法	B5		B6		B18	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
QPSO-RVM	0.014 1	0.017 6	0.026 9	0.034 0	0.031 4	0.040 6
RVM	0.019 1	0.022 7	0.042 8	0.058 0	0.041 3	0.052 3

由表 1 可以看出,相关向量机在量子粒子群算法的优化下,性能有了较大的改进,3 组电池的均方根误差平均值为 3%,3 组电池的绝对误差均值平均值为 2.4%,相比于相关向量机,量子粒子群优化后的均方根误差平均值降低了 1.4%,绝对误差均值平均值降低了 1%,在对编号 5 的锂电池寿命预测中,失效次数预测准确率最高,达到了 99.9%,由此可见,本文提出的改进相关向量机算法的预测数值与实际数据相比误差更小,能更为准确的预测出电池的失效点。

6 结 论

本文运用量子粒子群算法改进的相关向量机对锂离子电池的剩余使用寿命进行预测,并利用美国国家宇航局埃姆斯中心提供的锂离子电池充放电次数和电池剩余容量真实试验数据对改进算法的可靠性进行验证。利用量子粒子群选择最优的 RVM 核函数宽度因子改进了传统的相关向量机算法,将所述方法应用于 NASA 锂电池充放电实验数据集,并将结果与 RVM 的结果进行对比,可以看出,利用量子粒子群对相关向量机进行改进后,相关向量机预测性能有了较大的提高,为锂电池寿命预测在生产生活中实际运用打下了基础,提供了一个理论方向,也证明了本文所提方法是有效的并且有着更优越的

性能。特别是量子粒子群算法具有很好的全局搜索能力且相关向量机泛化能力更好,更稀疏,测试时间更短的特性,非常适合在锂电池实际应用中进行实时的模型训练和电池寿命预测,具有较好的应用前景。

参考文献

[1] 闫金定. 锂离子电池发展现状及其前景分析[J]. 航空学报,2014,35(10):2767-2775.
YAN J D. Development status and prospect analysis of lithium ion batteries [J]. Aeronautics, 2014,35(10):2767-2775.

[2] HE W,WILLIARD N,OSTERMAN M, et al. Prognostics of lithium-ion batteries using extended Kalman filtering[C]. Proceedings of IMAPS Advanced Technology Workshop on High Reliability Microelectronics for Military Applications, 2011: 17-19.

[3] XIAN W, LONG B, LI M, et al. Prognostics of lithium-ion batteries based on the Verhulst model, particle swarm optimization and particle filter[J]. IEEE Transactions on Instrumentation and Measurement (S0018-9456), 2014, 63(1): 2-17.

[4] 艾力,房红征,于功敬,等. 基于数据驱动的卫星锂离子电池寿命预测方法[J]. 计算机测量与控制,2015, 23(4): 1262-1265.
AI L, FANG H Z, YU G J, et al. Data-driven life prediction method for satellite lithium-ion batteries [J]. Computer Measurement and Control, 2015, 23(4): 1262-1265.

[5] 王笑天,杨志家,王英男,等. 双卡尔曼滤波算法在锂电池 SOC 估算中的应用[J]. 仪器仪表学报,2013, 34(8): 1732-1738.
WANG X T, YANG Z J, WANG Y N, et al. Application of double Kalman filter algorithm in SOC estimation of lithium battery [J]. Journal of Instrumentation, 2013, 34(8): 1732-1738.

[6] XING Y J, EDEN W M, KWOK-LEUNG M T, et al. An ensemble model for predicting the remaining useful performance of lithium-ion batteries[J]. Microelectronics Reliability, 2013, 53(6): 811-820.

[7] 王竹晴,庞晓琼,黄蕊,等. 基于 KPCA-ANFIS 的锂离子电池 RUL 预测[J]. 电子测量与仪器学报,2018, 32(10): 26-32.
WANG ZH Q, PANG X Q, HUANG R, et al. Rul prediction of lithium ion battery based on kpca-anfis [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(10): 26-32.

[8] 徐志远,肖奇. 基于脉冲远场涡流的管道缺陷外检测与定量评估[J]. 电子测量与仪器学报,2019, 33(2): 80-87.

- XU ZH Y, XIAO Q. External detection and quantitative evaluation of Pipeline Defects Based on pulsed far-field eddy current [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (2): 80-87.
- [9] WIDODO A, SHIM M C, CAESARENDRA W, et al. Intelligent prognostics for battery health monitoring based on sample entropy [J]. Expert Systems with Applications, 2011, 38(9): 11763-11769.
- [10] 解冰. 基于支持向量机的锂离子电池寿命预测方法研究[D]. 武汉: 华中科技大学, 2012.
- XIE B. Research on life prediction method of Li-ion battery based on support vector machine [D]. Wuhan: Huazhong University of science and technology, 2012.
- [11] 陈雄姿, 于劲松, 唐荻音, 等. 基于贝叶斯 LS-SVR 的锂电池剩余寿命概率性预测 [J]. 航空学报, 2013, 34(9): 2219-2229.
- CHEN X Z, YU J S, TANG D Y, et al. Probability prediction of residual life of lithium battery based on Bayesian LS-SVR [J]. Journal of Aviation, 2013, 34(9): 2219-2229.
- [12] 杨树仁, 沈洪远. 基于相关向量机的机器学习算法研究与应用 [J]. 计算技术与自动化, 2010, 29(1): 43-47.
- YANG SH R, SHEN H Y. Research and application of machine learning algorithms based on relevant vector machines [J]. Computing Technology and Automation, 2010, 29(1): 43-47.
- [13] 王立昆, 杨新峰. 一种基于 RVM 回归的分类方法 [J]. 电子科技, 2011, 24(5): 14-16.
- WANG L K, YANG X F. A classification method based on RVM regression [J]. Electronic Science and Technology, 2011, 24(5): 14-16.
- [14] 张兰. 量子粒子群算法及其应用 [D]. 西安: 西北大学, 2010.
- ZHANG L. Quantum particle swarm optimization and its application [D]. Xi'an: Northwest University, 2010.
- [15] WANG D, TAN D, LIU L. Particle swarm optimization algorithm: An overview [J]. Soft Computing, 2018, 22(2): 387-408.
- [16] VAN DEN BERGH F, ENGELBRECHT A P. A new locally convergent particle swarm optimizer [C]. IEEE international Conference on Systems, Man and Cybernetics, 2002(3): 96-101.
- [17] VAN DEN BERGH F. An analysis of particle swarm optimiser [D]. Pretoria: University of Pretoria, 2006.
- [18] SUN J, FANG W, PALADE V, et al. Quantum-behaved particle swarm optimization with Gaussian distributed local attractor point [J]. Applied Mathematics and Computation, 2011, 218(7): 3763-3775.
- [19] SUN J, WU X, PALADE V, et al. Convergence analysis and improvements of quantum-behaved particle swarm optimization [J]. Information Sciences, 2012, 193: 81-103.
- [20] SUN J, XU W, FENG B. A global search strategy of quantum-behaved particle swarm optimization [C]. Cybernetics and Intelligent Systems, 2004: 111-116.
- [21] 杨璐宇. 小波降噪在 MATLAB 与 ADSP 21160 中的实现 [J]. 计算机应用, 2015, 35(S1): 243-246, 272.
- YANG L Y. Implementation of wavelet denoising in MATLAB and ADSP 21160 [J]. Computer Application, 2015, 35(S1): 243-246, 272.
- [22] 杨柳, 张磊, 张少勋, 等. 单核和多核相关向量机的比较研究 [J]. 计算机工程, 2010, 36(12): 195-197.
- YANG L, ZHANG L, ZHANG SH X, et al. A comparative study of single-core and multi-core correlation vector machines [J]. Computer Engineering, 2010, 36(12): 195-197.

作者简介



何畏, 1982 年于重庆大学获得学士学位, 现为西南石油大学副教授, 高级工程师, 硕士生导师, 主要研究方向为新能源汽车装置与表面工程技术应用, 石油机械设计与制造。

E-mail: 370434073@qq.com

He Wei received his B. Sc. degree from Chongqing University in 1982. Now he is an associate professor, senior engineer and M. Sc. supervisor at Southwest Petroleum University. His main research interests include application of new energy vehicle device and surface engineering technology, and the design and manufacturing of petroleum machinery.



罗潇, 2017 年于西南石油大学获得学士学位, 现为西南石油大学硕士研究生, 主要研究方向机器学习和深度学习、新能源器件故障预测。

E-mail: luoxiao5566@126.com

Luo Xiao received his B. Sc. degree from Southwest Petroleum University in 1982. Now he is a M. Sc. candidate at Southwest Petroleum University. His main research interests include machine learning and deep learning, fault prediction of new energy devices.