

DOI:10.15923/j.cnki.cn22-1382/t.2017.5.11

基于人群搜索的极限学习机荷电状态估计

姜长泓, 王 闯

(长春工业大学 电气与电子工程学院, 吉林 长春 130012)

摘 要: 以电池组的电压、充放电电流作为输入变量, SOC 作为输出变量。在建模过程中, 用人群搜索算法来优化随机给定的极限学习机的输入权值矩阵和偏差。

关键词: 荷电状态; 极限学习机; 人群搜索算法; 预测

中图分类号: TM 911 **文献标志码:** A **文章编号:** 1674-1374(2017)05-0468-04

Extreme Learning Machine SOC estimation based on seeker optimization

JIANG Changhong, WANG Chuang

(School of Electrical & Electronic Engineering, Changchun University of Technology, Changchun 130012, China)

Abstract: With the battery voltage, charge and discharge current as input variables, and state of current (SOC) as output variables. Seeker optimization algorithm is used to modify the input weight-matrix and bias of the extreme learning machine, when a random model is established.

Key words: SOC; Extreme Learning Machine (ELM); seeker optimization algorithm; prediction.

0 引 言

电池的荷电状态(SOC)是电池的一个重要参数,反映了电池的使用情况。在电池的管理系统中,SOC的估算占有很重要的地位。准确的估算SOC可以提高电动车运行的可靠性和安全性。但是电动汽车在实际运行过程中,电流随工况不同而随之波动,电池组的温度也随之有升高的趋势,从而影响电池的性能。因此采取有效方法可靠的估计SOC尤为重要,这也是电池管理系统研究的重点之一。根据 Peukert 经验方程 $I^n t = k$

可知,当放电电流 I 为恒流时,放电电量 $Q = I^{1-n} k$,其中, k 为电池型号类别的常数、 t 为放电时间。而 SOC 与放电电量有关,可以看出 SOC 与电流具有一定的非线性关系。又根据 G. L. Plett 提出的电池简化模型可知,SOC 与电池电压具有一定的非线性关系。考虑到电池模型的非线性特性,文中采用神经网络来研究非线性特性。

文中采用人群搜索的极限学习机预测方法,结合了人群搜索算法收敛精度高、收敛迅速和极限学习机的学习速度快、误差小的优点^[1]。使得SOC的估算和预测速度有所提高,具有较高的预

收稿日期: 2017-08-25

作者简介: 姜长泓(1969—),男,汉族,吉林长春人,长春工业大学教授,博士,主要从事机械故障诊断与微弱光电检测及仪器方向研究,E-mail:jiangchanghong@ccut.edu.cn.

测和估算精度。

1 极限学习机(ELM)

极限学习机是一种新型的前馈神经网络^[2-3]学习算法。对于一个单隐层的神经网络,假设 n 个任意的样本 (X_i, Y_i) , $X_i = [X_{i1}, X_{i2}, \dots, X_{im}]^T \in \mathbf{R}^n$, $Y_i = [Y_{i1}, Y_{i2}, \dots, Y_{im}]^T \in \mathbf{R}^m$, 对一个具有 L 个隐含节点的神经网络而言,激励函数为 $g(x)$, 输出可以表示为:

$$f_L(X) = \sum_{i=1}^L \beta_i g(a_i \cdot X_i + b_i) \quad (1)$$

$$a_i \in \mathbf{R}^n, \beta_i \in \mathbf{R}^m$$

式中: a_i ——输入层到第 i 个隐含层节点的输入权值, $a_i = [a_{i1}, a_{i2}, \dots, a_{im}]^T$;

b_i ——第 i 个隐含层节点的偏差;

β_i ——第 i 个隐含层节点的输出权值, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$;

$g(x)$ ——可以选择为“Sigmoid”、“Sine”或“RBF”等。

如果这个具有 L 个隐含层的神经网络能以零误差逼近这 n 个样本,则存在 a_i, b_i, β_i 使得 $f_L(X) = Y_i, i = 1, 2, \dots, L$ 。当输入权值矩阵和偏差随机给定时,隐含层矩阵就会确定,从而可以计算得出输出权值矩阵。

2 人群搜索的极限学习机(SOA-ELM)

由于 ELM 随机给定输入权值矩阵和偏差,而隐含层输出权值矩阵是由输入权值矩阵和偏差计算得出。当输入权值矩阵和偏差都为零时,此时隐含层节点是无效的。因此在实际中需要大量隐含节点才能满足精度^[4]。SOAELM 结合了 SOA 和 ELM 的优点。由 SOA 优化选择 ELM 的输入权值矩阵和偏差,从而得到一个优化的网络。SOA 是一种群智能算法^[5],该算法种群的个体是由输入权值矩阵和隐含层偏差构成,粒子长度 $D = k \cdot (n + 1)$,其中 k 是隐含层节点数, n 为输入神经元数,用 D 表示 SOA 的搜索空间维数。

2.1 搜索步长的确定

SOA 模拟人智能搜索行为,建立目标函数与步长的关系^[6]。采用高斯隶属函数表示搜索步长模糊变量:

$$u(x) = \exp\left[-\frac{(x - \mu)^2}{2\delta^2}\right] \quad (2)$$

式中: x ——输入变量;

u ——高斯隶属度值;

μ, δ ——隶属函数参数。

当输入变量超出 $[\mu - 3\delta, \mu + 3\delta]$ 时,隶属度 $u(\mu - 3\delta) < 0.0111$, 故 $u_{\min} = 0.0111$ 。采用线性隶属度时,在最佳位置有最大隶属度 $u_{\max} = 1.0$,最差位置有最小隶属度。当隶属度在 $[u_{\min}, u_{\max}]$ 时,隶属度则有:

$$u_i = u_{\max} - \frac{s - I_i}{s - 1}(u_{\max} - u_{\min}) \quad (3)$$

$$i = 1, 2, \dots, s$$

$$u_{ij} = \text{rand}(u_i, 1) \quad (4)$$

$$j = 1, 2, \dots, D$$

式中: u_i ——目标函数 i 的隶属度;

u_{ij} —— j 维搜索空间目标函数 i 的隶属度值;

s ——种群的规模大小;

I_i ——种群规模按降序排列的编号。

根据下式可以算出步长:

$$\alpha_{ij} = \delta_{ij} \sqrt{-\ln(u_{ij})} \quad (5)$$

式中: α_{ij} —— j 维空间的搜索步长;

δ_{ij} ——高斯隶属函数参数。

其中:

$$\delta_{ij} = \frac{(t_{\max} - t)}{t_{\max}}(x_{\max} - x_{\min}) \quad (6)$$

式中: t ——进化代数;

x_{\max}, x_{\min} ——分别为同一子群中最大和最小函数值;

t_{\max} ——最大进化代数。

2.2 确定搜索方向

根据人群搜索的利己、利他和预动行为进行分析,分别得到第 i 个搜寻个体的利己方向 $d_{i,ego}$ 、利他方向 $d_{i,alt}$ 和预动方向 $d_{i,pro}$ 。

$$d_{i,ego}(t) = p_{i,best} - x_i(t) \quad (7)$$

$$d_{i,alt}(t) = g_{i,best} - x_i(t) \quad (8)$$

$$d_{i,pro}(t) = x_i(t_1) - x_i(t_2) \quad (9)$$

考虑到搜索种群个体的差异,采用 3 个方向加权平均确定搜索方向:

$$d_i(t) = \omega d_{i,pro} + \varphi_1 d_{i,ego} + \varphi_2 d_{i,alt} \quad (10)$$

式中: ω ——惯性权重;

φ_1, φ_2 ——分别为 $[0, 1]$ 内均匀分布的随机数;

$x_i(t_1), x_i(t_2)$ ——分别为 $\{x_i(t - 2), x_i(t - 1), x_i(t)\}$ 中最佳的位置;

$p_{i,best}$ ——第 i 个搜寻者到目前为止所经历的最佳位置;

$g_{i,best}$ ——第 i 个搜寻者所在邻域的集体最佳位置;

sign——符号函数;

$t_1, t_2 \in \{t, t-1, t-2\}$ 。

2.3 搜寻者个体位置更新

根据搜索方向和步长进行位置更新。

$$\Delta x_{ij}(t+1) = \alpha_{ij}(t) d_{ij}(t) \quad (11)$$

$$x_{ij}(t+1) = x_{ij}(t) + \Delta x_{ij}(t+1) \quad (12)$$

通过上述几步反复运用直到得到最优的输入权值矩阵和偏差,然后将它们代入公式计算出输出权值矩阵。

3 验证仿真和分析

文中将容量为 $100 \text{ A} \cdot \text{h}$ 的磷酸铁锂动力电池组作为研究对象。电池组共 24 块单体电池。先常温下以 0.4 C 恒流充电至 84 V , 然后恒压充电至电流降到 0.02 C 为止。分别采用 0.2 、 0.3 、 0.4 C 的恒流放电。为了防止过放,当某一块电池达到最低电压 2.8 V 时,则停止放电。然后静置一段时间。通过电池测试柜获取电池组的电压、充放电电流和电池真实 SOC 这 3 项数据。将所得数据进行整理随机分成训练集和测试集二类,

其中训练集 60 个样本,测试组 33 个样本。每个样本都是由电池组电压、充放电电流和相应 SOC 组成。设置种群规模为 30,最大迭代次数为 50,隐含层节点数都设为 10,其他参数设置相同。将所得数据分别用 ELM、PSOELM、SOAELM、BPNN 来训练和测试。4 种模型的性能比较见表 1。

表 1 4 种模型的性能比较

模型	均方误差 (MSE)	训练平均相对误差	测试平均相对误差
ELM	7.7067×10^{-5}	0.027 7	0.359 2
PSOELM	4.9517×10^{-5}	0.016 4	0.388 6
SOAELM	3.0540×10^{-5}	0.010 2	0.384 1
BPNN	3.5684×10^{-4}	0.170 0	0.418 7

从表 1 可以看出,SOAPLM 的均方误差比 ELM、PSOELM 和 BPNN 的均方误差都要小,说明该方法有较高的预测精度。而且训练平均误差和测试平均误差比其他 3 种方法都要低,故该方法具有较好的收敛精度。当电池组发生不平衡问题时,该方法也可以很好地预测 SOC。

用 SOAELM 来训练和测试,得到训练集和测试集的 SOC 拟合曲线如图 1 所示。

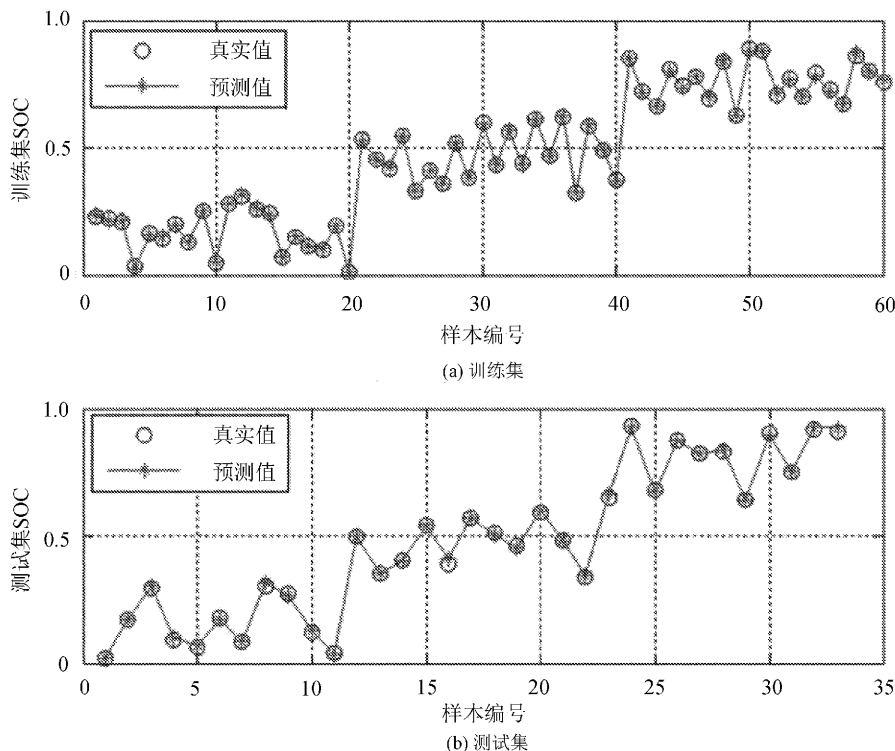


图 1 SOC 拟合曲线

通过图1可以很明显看出,该方法可以很好地预测SOC且具有较高的精度。训练集和测试集都能进行很好的拟合。

通过人群搜索的极限学习机方法可以得到SOC预测误差曲线,如图2所示。




图2 预测误差曲线

通过图2可以看出,对于每个测试样本,其预测误差都很小,最大预测误差低于1.2%,说明该方法具有很高的预测精度。证明了算法的有效性和优越性。

4 结语

采用一种新的SOC估算方法,即基于人群搜索的极限学习机的预测方法。在正确输入变量的情况下,只需要通过简单的训练,就能达到很好的预测效果。该算法采用智能算法,可以嵌入芯片中,对SOC进行实时预测,具有很好的实际意义。人群搜索的极限学习机是一种新的有效方法,在其他类似的预测中具有推广意义。

参考文献:

- [1] 王杰,毕浩洋.一种基于粒子群优化的极限学习机[J].郑州大学学报:理学版,2013(1):100-104.
- [2] Huang Guangbin, Zhu Qinyu, Siew Cheekheong. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [3] 陈盛双.基于极限学习机的XML文档分类[J].计算机工程, 2011, 19: 177-178, 182.
- [4] 李国进,董第永,陈双.磷酸铁锂电池的SOC预测[J].计算机仿真, 2015(3): 163-168.
- [5] 莫宏伟.自然计算研究进展[J].智能系统学报, 2011(6): 544-555.
- [6] 余胜威,曹中清.基于人群搜索算法的PID控制器参数优化[J].计算机仿真, 2014(9): 347-350, 373.