

文章编号:1674-2869(2015)10-0051-06

电动汽车电池荷电状态估算

王华杰, 郑来芳

太原工业学院电子工程系, 山西 太原 030008

摘要:为了精确估计电动汽车电池的荷电状态(SOC),将模糊神经网络和最小二乘支持向量机分别用来估计电池的 SOC,然后将两种方法相结合,交替地使用来预测电池 SOC. 在美国能源部纯电动汽车试验计划提供的混合工况 UDDS-NYCC-US06_HWY 驾驶循环实验中提取电池模型参数的充电/放电测试周期,用电池电流,电池电压和电池温度为独立变量,试验进行了 80 Ah 镍氢电池与动力测试周期来预测电池 SOC. 结果表明,此方法不仅可以准确的估算 SOC,而且能减少计算量.

关键词:电动汽车;模糊神经网络;最小二乘支持向量机;电池荷电状态

中图分类号:TM912

文献标识码:A

doi:10. 3969/j. issn. 1674-2869. 2015. 10. 010

0 引言

为了充分利用电池里的能量,同时防止不必要的浪费,电池荷电状态是电池的一个重要参数,反映了电池能量.

一个准确的 SOC 指示是非常重要的,方便用户使用. 设计一个精确的 SOC 指示系统的关键问题是电池和用户行为的不可预见性. 电池充放电过程是一个复杂的动态非线性系统,创建一个可以确切描述电池充放电系统的数学模型很困难. 所以准确估算电池 SOC 有相当大的难度^[1-3].

近年来,支持向量机^[4-7](SVM)技术被广泛用在各种领域. 在建立较好网络模型的前提下,神经网络法依靠大量的样本数据进行训练可以得到较好的预测精度,但神经网络可能有局部极小的问题,而支持向量机的学习算法具有全局最优解.

在本文中,模糊神经网络和最小二乘支持向量机用于估计电池的 SOC,将两种方法相结合,研究他们是否能更有效地估计电池的 SOC. 仿真是基于电动汽车仿真软件 ADVISOR,结果表明,新方法能给出更精确的估计并减少计算.

1 模糊神经网络原理

神经网络是近似和简化人类大脑的结构与工作模式. 这种结构和工作模式可产生一定的功能特征,类似于人脑的行为. 本文以自适应神经模糊

推理系统为建模基础.

假设模糊逻辑系统中有两个输入 x 和 y , 一个输出 z , 那么在一阶 Sugeno 模糊模型具有两条“if-then”模糊规则:

Rule 1: if x 是 A_1 and y 是 B_1 then

$$z_1 = p_1 x + q_1 y + r_1$$

Rule 2: if x 是 A_2 and y 是 B_2 then $z_2 = p_2 x +$

$$q_2 y + r_2$$




图 1 ANFIS 的结构

Fig.1 The structure of ANFIS

在第一层中,每一个节点函数的自适应节点的功能如下: $O_{1,i} = \mu A_i(x)$, $i=1, 2$.

采用钟型函数作为隶属度函数:

$$\mu_A(x) = \frac{1}{1 + \left[\left| \frac{x - c_i}{a_i} \right| \right]} \quad (1)$$

式(1)中, $\{a_i, b_i, c_i\}$ 是参数的集合.

在第二层中,节点的输出跟输入的关系用式(2)表示:

收稿日期:2015-08-25

基金项目:国家自然科学基金资助项目(61072121)

作者简介:王华杰(1988-),女,山西太原人,助教,硕士. 研究方向:嵌入式系统及应用.

$$O_{2,i} = \omega A_i(x) \mu B_i(y), \quad i=1,2 \quad (2)$$

在第三层中,节点 i 是一个比率,节点的输出跟输入的关系用式(3)表示:

$$O_{3,i} = \frac{\omega_i}{\omega_1 + \omega_2}, \quad i=1,2 \quad (3)$$

在第四层中,每一个节点 i 都是一个自适应节点.

$$O_{4,i} = \omega_i f_i = \omega(p_i x + q_i y + r_i) \quad (4)$$

式(4)中, $\{p_i, q_i, r_i\}$ 是参数的集合.

在第五层中,单点是被标记为一个固定节点 Σ ,把所有传送信号的总和作为输出.

在 ANFIS 中,利用神经网络法计算采样数据得到所需的参数,完成自适应建模过程.

2 基于模糊神经网络电池 SOC 预测模型

电池的放电性质是由多种因素的影响,可以得到如下的数据:充电电压,放电电流,电池的內部温度. SOC 估计就是根据蓄电池的充电电压、放电电流和电池的內部温度的数值得到电池 SOC 数值. 使用神经网络设计估计器的目的是为了逼近函数:

$$SOC = f(V, I, T) \quad (5)$$

在实际应用中,采用测量那些容易测量的因素,即监测电池的 SOC,结合放电电流,电池温度的变化,电池电压变化.这种分析 SOC 方法被称作电化学方法. 电池的电压是一个参数,它是最简单的测量,但它是反映多电池信息的参数.

为了避免由不同的电池采样值的影响,首先归一化输入数据,然后定义输入、输出变量,构造了一个一阶 Sugeno 模糊模型,最后使用隶属函数为每个输入进行了训练.




图 2 一阶 Sugeno 模糊系统的 SOC 模型

Fig.2 SOC model of the first-order Sugeno fuzzy system

模糊神经网络的训练过程如下:

(1) 初始化模糊神经网络隶属度函数参数和

系数,将所得到的数据归一化到 $[-1, 1]$, 用作训练样本.

(2) 设置初始权重为均匀分布的小的随机值,并设置神经元的数目,学习速率.

(3) 用训练样本训练模糊神经网络和迭代法调整权重,然后计算得出输出.

3 模糊神经网络仿真

使用 ADVISOR 仿真软件获得所需的训练和测试数据集. ADVISOR 是美国能源实验室(Natural Renewable Energy Library)开发的高级车辆仿真软件(Advanced Vehicle Simulator). 使用该软件可以搭建一个电动汽车实验平台,利用标准测试路程的模拟行驶程序,获取电动车在行驶过程中的各项参数.

动态 SOC 测试是 80Ah/96V Ni-MH 电池组采用混合工况 UDDS-NYCC-US06_HWY 混合驱动循环实验进行的. 采用混合工况试验数据进行研究是让预测结果能够充分表现出电池在实际使用时的动态特性,而且也能说明此方法较好的鲁棒性和实用性. 基于电动汽车仿真软件 ADVISOR,将此循环运行 2 个周期,虚拟的电动车一共运行了 4 675 s,全程 29.73 m,运行过程中最大速度为 80.3 mph,平均速度为 22.89 mph. 收集的数据有速度、电流、电压、温度,如图 3、4、5、6 所示. 蓄电池 SOC 是通过“库仑折算”的方法获得的,如图 7 所示.

预测误差图如图 8 所示. 由图 8 可以看出,虽然最大预测误差大于 0.1,但总体来说,结果大体让人满意.




图 3 仿真平台下纯电动汽车车速变化曲线

Fig.3 Curve of the pure electric vehicle's speed under the simulation platform




图 4 仿真平台下蓄电池输出电流变化曲线

Fig.4 Curve of the battery's output current change under the simulation platform




图 5 仿真平台下温度变化曲线

Fig.5 Curve of the variation of temperature under simulation platform




图 6 仿真平台下蓄电池电压变化曲线

Fig.6 Curve of the variation of battery voltage under simulation platform




图 7 仿真平台下蓄电池 SOC 变化曲线

Fig.7 Curve of battery's SOC change under simulation platform




图 8 基于模糊神经网络方法的预测误差图

Fig.8 Error prediction based on fuzzy neural network method

4 LS-SVM 原理

SVM 是一种基于经验风险最小化和统计学习理论的计算学习理论,利用内核函数,可以使低维空间非线性输入映射到高维空间,能够使这些低维特征变量成为线性可分的变量。

最小二乘支持向量机可以改变复合二次规划问题转化为求解线性方程组,并且可以通过使用迭代的方式来解决,大大减少了计算量,提高了求解速度。设训练样本集 T 由 N 个样本点组成:

$$T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\} \quad (6)$$

其中, $x_i \in \mathbf{R}^n$ 是输入向量, $y_i \in \mathbf{R}$ 是对应于 x_i 的输出。令 $a = \frac{1}{\gamma}$, 则优化问题是一个最小二乘支持向量机:

$$\min_{w, b, e} J(w, b, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{k=1}^N e_k^2 \quad (7)$$

约束条件:

$$y_k = w^T \varphi(x_k) + b + e_k, k = 1, \dots, N \quad (8)$$

其中, w 是权重向量, γ 是恒定可调参数, e_k 是相应的误差变量, $\varphi(\cdot)$ 是具有非线性映射功能的函数, 使输入样本从低维空间到高维特征空间, b 是一个偏差。

相应的优化问题(6)、(7)两式,可以定义一个拉格朗日函数为:

$$L(w, b, e, \alpha) = J(w, b, e) - \sum_{k=1}^N \alpha_k \{w^T \varphi(x_k) + b + e_k - y_k\} \quad (9)$$

其中, $\alpha_k \in \mathbf{R}$ 是拉格朗日乘子,用来做二次逼近。下面对等式(8)进行优化:

$$\frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_{k=1}^N \alpha_k \varphi(x_k) \quad (10)$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_{k=1}^N \alpha_k = 0 \quad (11)$$

$$\frac{\partial L}{\partial b}=0 \rightarrow \partial_k=\gamma e_k, k=1, \cdots, N \quad (12)$$

$$\frac{\partial L}{\partial \alpha_k}=0 \rightarrow \mathbf{w}^T \varphi(x_k)+b+e_k-y_k=0, k=1, \cdots, N \quad (13)$$

可以表示为下列矩阵的形式:

$$\begin{pmatrix} 0 & 1^T \\ 1 & \Omega+\gamma^{-1}I \end{pmatrix} \begin{pmatrix} b \\ \alpha \end{pmatrix} = \begin{pmatrix} 0 \\ Y \end{pmatrix} \quad (14)$$

其中 $\Omega_{ij}=\varphi(x_i)^T \varphi(x_j)=K(x_i, x_j)$, $Y=(y_1, \cdots, y_N)^T$, $1=(1, \cdots, 1)^T$, $\alpha=(\alpha_1, \cdots, \alpha_N)^T$

解方程(13)得到 α 和 b 后,对于新的输入向量 x ,其输出值 $y(x)$ 可以根据下式进行计算:

$$y(x)=\sum_{k=1}^N \alpha_k K(x, x_k)+b \quad (15)$$

其中, $K(x, x_k)$ 是核函数.核函数从低维空间中选取特征向量,使低维空间的数据通过映射后在高维空间变得线性可分.可以看出,核函数在处理非线性问题时起到非常重要的作用.核函数之所以是最小二乘支持向量机的重要因素,是因为选择不同类型的核函数能直接决定最小二乘支持向量机的性能.目前,多项式核函数、Mercer 核函数、RBF 核函数等使用的比较普遍.目前,支持向量机的内核类型常选用的 RBF 神经.要使用支持向量机解决回归问题的数据是不是线性可分的,内核必须选择.在本文中,径向基函数被选为核函数:

$$K(x_i, x_j)=\exp\left(\frac{-|x_i-x_j|^2}{2\sigma^2}\right) \quad (16)$$

5 基于 LS-SVM 电池 SOC 预测模型

在电池充放电过程中,电池荷电状态(SOC)与电池的电压、电流、温度等因素密切相关,那么用电池温度、电压、电流作为输入,电池 SOC 作为模型的输出.建立如下的数学方程:

$$SOC=f[(V, I, T), \alpha_k, b] \quad k=1, \cdots, N \quad (17)$$

最小二乘支持向量机依赖于超参数(C, ν, γ),惩罚参数 C ,超参数 ν 定义该类型的 SVM 回归.当 RBF 核被选作为核函数时, γ 就表示为内核参数.对于核函数来说,内核参数是非常重要的,因此在升高学习和泛化能力方面起着决定性作用,增强预测模型性能就必须准确选择内核参数.

超参数的选择,是通过每个组合都使用八倍交叉验证,然后选用最佳的交叉验证精度的参数.根据式(10)来求出 α 和 b 的值,然后把模型参数引入到 LS-SVM 预测模型中,那么输入测试样本后,就可以得到预测电池 SOC.将预测值与 SOC 的实

验数据进行对比,以验证基于 LS-SVM 算法电池 SOC 预测模型的性能.

6 LS-SVM 仿真

基于 LS-SVM 电池 SOC 的预测模型预测过程的具体步骤如下:

(1)选择样本数据,进行数据处理,生成训练样本集和预测样本集;

(2)建立一个核函数 $K(x_i, x_j)$ 和参数 C, γ ,并选择核函数的类型和惩罚系数;每个参数组合经过八倍交叉验证,得到最佳的参数.本文得到的参数为: $C=0.707\ 107$ 、 $\gamma=2.828\ 43$ 、均方误差 $MSE=2.866\ 42e-005$.

(3)通过训练样本建立目标函数,并通过求解二次规划问题找到最佳的超平面,得到拉格朗日乘子 α 和 b ;

(4)建立与所获得的参数的预测模型,并预测未来的预测值与测试样本集.

预测误差如图 9 所示,LS-SVM 预测的电池 SOC 的结果与试验结果相符合,它的最大预测误差小于 0.5%,并且相关系数 $R=99.99\ 09\%$,运行了 599.933 132 s.




图 9 基于 LS-SVM 方法的预测误差图

Fig.9 Error prediction based on LS-SVM method

7 基于模糊神经网络和 LS-SVM 电池 SOC 预测

这里提出将模糊神经网络和 LS-SVM 相结合的 SOC 估算方法,预测步骤大致如下:首先,LS-SVM 来估计 SOC 和规范初始误差;然后它被模糊神经网络取代时预测 SOC 接近实际值.经过一段时间,LS-SVM 用来取代模糊神经网络,校正累积的偏移量,然后再次切换到模糊神经网络,依此类

推. 将两者合并交替使用方法的预测误差如图 10 所示. 可以看到, 预测数据与实验数据的变化是相同的. 均方误差 $MSE=2.798\ 04e-005$, 相关系数 $R=99.991\ 2\%$, 运行了 488.245 310 s.

不过发现当 SOC 较大和较小的时段, 预测误差相对大一些. 引起这种情况大致有以下几个原因: (1) 在 SOC 较大和较小的时段, 有大电流的充放电, 引起较大误差的产生; (2) 汽车运行过程中不停的充放电, 温度会不断的升高, 电池模型也会发生相应改变, 那么所建立的函数关系也不能完全适用了. 鉴于这种情况, 要想得到满意的试验结果, 就要设法保证电池的内部温度相对稳定. 这样电池模型就不用考虑电池内部温度的变化, 只需要考虑外界环境温度就可以了.




图 10 基于新方法的预测误差图

Fig.10 Error prediction based on the new method

实验结果表明, 该 LS-SVM 预测的电池 SOC 的结果与试验结果相符合, 它的最大预测误差小于 0.5%, 而模糊神经网络的最大预测误差大于 0.1, 但总体来说, 结果大体让人满意, 基于新方法的最大预测误差小于 0.3%. 由此也可以看出, 基于合并的方法具有更高的精度, 更好的实用性.

8 结 语

对于在电动汽车动力电池的最优控制问题, 准确地估计电池的充电状态(SOC)的状态是不可忽略的部分. 本文分别建立了基于模糊神经网络算法和 LS-SVM 算法的电池 SOC 预测模型, 并将其交替应用到了 NI-MH 电池组 SOC 动态预测. 仿真是基于电动汽车仿真软件 ADVISOR, 验证结果

表明, 此估计方法是可行的, 并具有较高的精度. 此预测方法不需要知道电池内部复杂的物理化学变化, 反映了它良好的适应性, 不仅可以准确的估算 SOC, 而且能减少计算量, 所以它可以成为一个实用的电池 SOC 估计方法.

参考文献:

- [1] WANG Geng bo. The development of batteries in electric vehicles [J]. Hu bei Automotive Industries Institute, 1996, 32(12): 83-86.
- [2] MA you-liang, CHEN quan-shi, QI zhan-ning. A research on the SOC Definition and measurement method of batteries used in EVS [J]. J Tsinghua Univ (Sci&Tech), 2001, 41(11): 95-97.
- [3] 邵海岳, 钟志华, 何莉萍, 等. 电动汽车动力电池模型及 SOC 预测方法[J]. 电源技术, 2004, 28(10): 637-640.
SHAO Haiyue, ZHONG Zhihua, HE Liping, et al. The model of Electric vehicle battery and the method of SOC's estimation[J]. Power Technology, 2004, 28(10): 637-640. (in Chinese)
- [4] 裴晟, 陈全世, 林成涛. 基于支持向量回归电池 SOC 估计方法研究[J]. 电源技术, 2007, 31(3): 243-252.
PEI Sheng, CHENG Shiquan, LIN Chengtao. Study on estimating method for battery state of charge based on support vector regression[J]. Power Technology, 2007, 31(3): 243-252. (in Chinese)
- [5] 郭桂芳, 曹秉刚. 电动车用 Ni/MH 电池组剩余容量的非线性自回归滑动平均预测 [J]. 控制理论与应用, 2011, 28(4): 591-595. (in Chinese)
GUO Gui-fang, CAO Binggang. NARMAX method for estimating the residual capacity of Ni/MH battery pack for electric vehicle[J]. Control Theory & Applications, 2011, 28(4): 591-595. (in Chinese)
- [6] SUYKENS J A K. De Brabanter JaLukas Let alWeighted least squares support vector machines robustness and sparse approximation [J]. Neurocomputing, 2002, 48(1-4): 85-105.
- [7] 阎威武, 绍惠鹤. 支持向量机和最小二乘支持向量机的比较及应用[J]. 控制与决策, 2003, 18(3): 18-20.
YAN Wei-wu, SHAO Hui-he. Application of support vector machines and least squares support vector machines to heart disease diagnoses[J]. Control and Decision, 2003, 18(3): 18-20. (in Chinese)

Evaluating charge state of electric vehicle battery

WANG Hua-jie, ZHENG Lai-fang

Electronic of Engineering, Taiyuan Institute of Technology, Taiyuan 030008, China

Abstract: To exactly evaluate the state of the charge (*SOC*) of the electric vehicle's battery, the fuzzy neural network and least squares support vector machines were used separately at first and then the two methods were combined and employed alternately to predict the battery *SOC*. The battery model parameters of charging/discharging testing period were drawn from UDDS-NYCC-US06_HWY driving cyclic experiment, which was provided by the U.S. department of energy's electrical vehicle. Using the data of battery current, voltage and temperature as the independent variables, test on an 80 Ah Ni-MH battery and the cycle of the battery's power was conducted to predict the battery's *SOC*. Results showed that the method not only can accurately estimate the *SOC* but also can reduce the amount of calculation.

Keywords: electric vehicle; fuzzy neural network; least square support vector machine; state of charge;

本文编辑:陈小平