

DOI:10.3969/j.issn.1001-4551.2015.01.024

基于神经网络模型的动力电池 SOC 估计研究

蔡 信, 李 波, 汪 宏 华, 聂 亮

(国网浙江省电力公司 电动汽车服务分公司,浙江 杭州 310007)

摘要:针对电动汽车动力电池荷电状态(SOC)的估计问题,对动力电池的荷电状态估计方法进行了研究。对电池荷电状态的影响因素进行了归纳,提出了基于反向传播神经网络(BP 神经网络)的动力电池荷电状态估计方法。利用汽车仿真软件 ADVISOR 对电动汽车行驶典型的汽车测试工况进行了模拟,得到了电动汽车动力电池荷电状态与电池的充放电电流、温度之间的关系。对得到的训练样本数据进行了归一化处理,经过训练,得到基于 BP 神经网络的动力电池荷电状态估计模型。同样,利用 ADVISOR 软件得到的测试数据,对得到的神经网络模型进行了测试。研究结果表明,该模型的估计值和输出值之间的误差最大值为 4% 左右,模型的精度符合动力电池荷电状态估计的使用要求。

关键词:电动汽车;电池荷电状态;神经网络

中图分类号:TM911;TP24

文献标志码:A

文章编号:1001-4551(2015)01-0128-05

Estimation of state-of-charge for electric vehicle power battery with neural network method

CAI Xin, LI Bo, WANG Hong-hua, NIE Liang

(State Grid Zhejiang Electric Vehicle Company, Hangzhou, 310007, China)

Abstract: Aiming at estimating state-of-charge of electric vehicle batteries precisely, study on modeling state-of-charge(SOC) was investigated. After analyzing effect factors of SOC, a model of SOC on BP neural network was established. Electric vehicle simulation software ADVISOR was used to simulate an electric vehicle on typical driving cycles. The relationship between current, temperature and SOC was derived through simulation. After normalization of the training data and training the neural network, a SOC estimation model based on BP neural network was derived. The model was tested by testing data obtained by ADVISOR. The results indicate that the maximum error between the model estimation and actual values is 4%, which can satisfy the requirements of actual use of SOC.

Key words: electric vehicle; state-of-charge(SOC); neural network

0 引言

动力电池的电能容量大小使用荷电状态(SOC)进行定量表示^[1]。预测电池 SOC 是动力电池管理系统的主要功能之一。该功能根据电池 SOC 来估计续航里程,防止车辆在行驶过程中抛锚或是因电池过度放电造成电池本身的损害甚至是危险的发生^[2]。因此,如何准确预测电池的 SOC 成为电动汽车电池管理系

统的重点问题之一。

常用的电池 SOC 估计方法可以分为以下几类:

- ①基于安时积分法的电池 SOC 估计^[3]。在提供动力电池初始荷电状态(SOC)的情况下,根据放电的总电量,计算出当前的电池荷电状态。由于电流检测和电池容量统计中存在的误差,会导致荷电状态的估计不准确。
- ②基于开路电压法的电池 SOC 估计^[4]。动力电池的开路电压与动力电池的 SOC 之间有某种对应

关系,通过测量电池的开路电压,来预测电池的SOC。
③基于电池内阻的电池SOC估计。动力电池的内阻随着电池的使用程度加深而增大电池的内阻随着电池的老化而增大,通过测量动力电池的内阻可以估计出电池的SOC。但是该种方法需要电池内阻测量装置。该种装置价格高,体积大。
④基于卡尔曼滤波算法的电池SOC估计方法^[5]。该方法将电池看做一个动态系统,SOC作为电池内部的一个状态变量。卡尔曼滤波器作为递推算法,对初值的选择十分敏感,错误的初值会导致估计的不断恶化。

针对以上在预测电池SOC中出现的问题。神经网络提供了有效的解决方法^[6],神经网络只要能够合理地选择输入和输出参数,输入和输出之间的关系可以通过神经网络的训练得到。

本研究采用使用比较广泛的BP神经网络,通过在电动汽车仿真软件ADVISOR上搭建的电动汽车仿真平台,采集电池的电流和温度作为BP神经网络的输入,电池SOC作为神经网络的输出,对BP神经网络模型进行训练。

1 神经网络和电池SOC简介

1.1 BP神经网络简介

神经网络由大量简单的单元构成的非线性系统,具有非线性映射能力,不需要精确的数学模型,擅长从输入输出数据中学习有用知识^[7]。神经元是神经网络基本单元。神经元模型如图1所示。由连接权、加法器和非线性激活函数这3种元素组成。

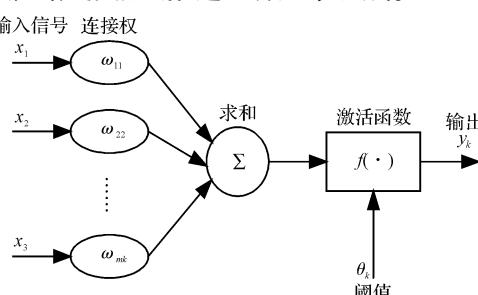


图1 人工神经元模型图

1986年,Rumelhart及其研究小组在Nature杂志上发表误差反向传播(error back-propagation)算法^[8],并将该算法用于神经网络的研究,使之成为迄今为止最著名的多层神经网络学习算法——BP算法^[9]。由该算法训练的网络,称为BP神经网络。

BP神经网络是一种正向的、各层相互连接的网络。输入信号首先经过输入层传递给各隐含层节

点,经过激发函数,将隐含层节点的输出传递到输出节点,最后再经过激发函数后才给出输出结果,若输出层的输出和期望输出之间的误差达不到要求,则转入反方向传播,将误差信号沿原来的连接通路返回,通过修正神经网络各层的权值,使过程的输出和神经网络的输出之间的误差信号达到期望值为止^[10]。

1.2 电池SOC的定义

动力电池的剩余电量,是指电池在当前时刻,达到放电截止电压前可以使用的电量。目前,国内外普遍采用荷电状态来表征电池的剩余容量^[11]。电池的荷电状态(SOC)是电池的剩余电量与电池的额定电量的比值:

$$SOC = \frac{Q_{\text{remain}}}{Q_{\text{rated}}} \times 100\% \quad (1)$$

式中: Q_{remain} —电池的剩余电量, Q_{rated} —电池的额定电量。

1.3 影响电池SOC的因素

动力电池是一个非线性系统,其中电池的荷电状态受到很多种因素的影响,主要包括电池的充/放电倍率、自放电、环境温度以及电池的工作状态等因素。

(1)电池的充/放电倍率

电池的放电电流的大小,会影响电池的容量。在其他条件相同的情况下,电池的放电容量会随着放电倍率的增加而降低^[12]。

(2)自放电

自放电又称荷电保持能力,指在一定的条件下,当电池处于开路状态时,电池对电量的储存能力。电池在自放电的作用下,SOC值会随着存储时间的增加而减小。

(3)温度

首先,锂离子电池正常工作的温度有一定的要求。动力电池的使用环境温度发生变化时,电池的可用容量也会随之发生变化。在温度较低时,电池活性较低,电池可用容量降低;当温度升高时,电池活性增强,可用容量也随之增多。因此,在预估电池的荷电状态时,需要考虑到电池的温度的影响。

2 神经网络SOC估计器设计

2.1 实验数据的获取

本研究的实验数据是在ADVISOR 2002汽车仿真软件上仿真得到的。ADVISOR(Advanced Vehicle Sim-

ulator, 高级车辆仿真器)是由美国可再生能源实验室, 在 Matlab/Simulink 软件环境下开发的高级车辆仿真软件^[13]。该软件的界面友好、源代码完全开放, 目前已经在世界范围内广泛使用。

ADVISOR 采用了前向、后向相结合的混合仿真方法。后向仿真方法是在假设车辆能满足道路循环的请求行驶轨迹(包括汽车行驶速度、道路坡度和汽车动态质量)的前提下, 计算汽车中各个部件性能的仿真方法, 前向仿真时根据驾驶员行为调节部件, 使得车辆各部件跟随路面循环工况^[14]。

本研究在 ADVISOR 软件搭建了某国产电动汽车的仿真平台。整车的主要技术参数如表 1 所示^[15-16]。模拟行驶程序使用的测试路程是 ECE 工况、UDDS 工

况和 HWFET 工况混合行驶工况, 其速度与时间关系曲线如图 2 所示。

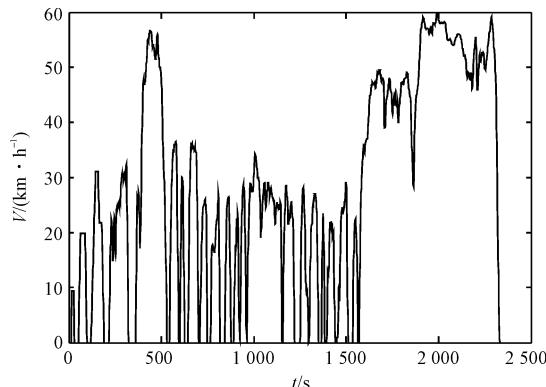


图 2 混合行驶工况

表 1 电动汽车整车技术参数

参数名称	参数值	参数名称	参数值
外形尺寸/mm	4 500 × 1 705 × 1 495	滚动半径/mm	298
轴距/mm	2 605	轮胎滚动阻力系数	0.01
轮距(前/后)/mm	1 470/1 460	迎风面积/m ²	2.3
整备质量/kg	1 490	风阻系数 Cd	0.3
满载质量/kg	1 895	传动系机械效率	0.9
前、后轮胎规格	195/60R15(0.308)		

ECE 工况、UDDS 工况和 HWFET 工况均被广泛应用于电动汽车性能测试。其中 ECE 工况为欧洲经济委员会汽车法规规定的汽车测试循环工况。ECE 工况是用来测试车辆在城市低速道路下车辆的循环工况。其循环时间为 195 s, 车辆行驶的路程为 0.99 km, 最高车速为 50 km/h。UDDS 工况是美国环境保护署制订的城市道路循环工况, 用来测试车辆在城市道路上行驶的各种性能的循环工况。其循环时间为 1 367 s, 行驶路程为 11.99 km, 最高车速为 91.25 km/h。HWFET 工况为美国环境保护署制订的汽车在高速公路上的循环工况, 用来测试汽车在高速道路上车辆行驶的循环工况, 其循环时间为 767 s, 行驶路程为 1.51 km, 最高车速为 96.4 km/h。在搭建的仿真平台上, 本研究进行了仿真, 其中电动汽车使用的电池为锂电池。虚拟电动汽车共行驶了 2 329 s, 行驶的距离为 14.49 km。对电动汽车的电池的充放电电流、电池温度和电池的 SOC 进行采集, 得到结果如图 3 ~ 5 所示。

2.2 数据预处理

根据前文的分析, 本研究的神经网络模型训练数据选择如下:

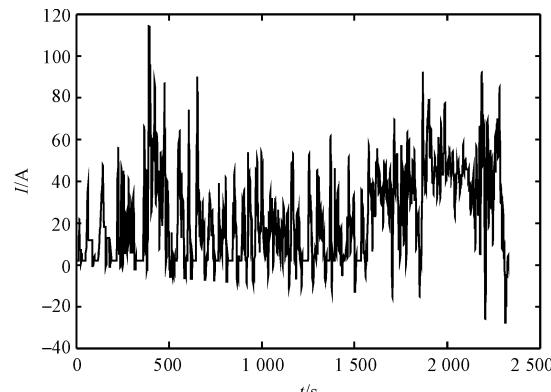


图 3 电池电流曲线图

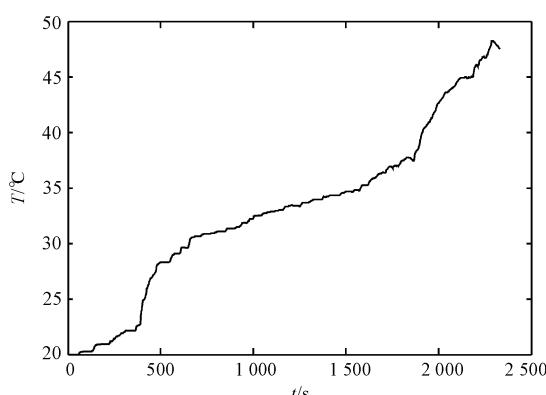


图 4 电池的温度曲线图

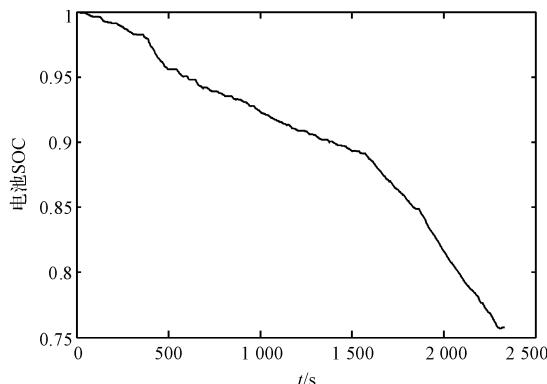


图 5 电池 SOC 图

本研究选择动力电池的充放电电流和电池的温度作为动力电池神经网络的输入,电池的 SOC 作为神经网络的输出。在对神经网络训练之前,对训练数据进行归一化操作。归一化操作可以避免各个因子之间的量级差异,加快 BP 神经网络训练的收敛,减少计算难度。对数据进行如下操作:

$$x_i^* = \frac{x_i^* - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

式中: x_i^* —经过归一化处理后的数据, x_i^* —原始数据, x_{\min} —原始样本数据中的最小值, x_{\max} —原始样本数据中的最大值。

2.3 动力电池 SOC 神经网络的训练

SOC 估计是根据动力电池的电流、温度的数值得到电池的 SOC 数值。使用神经网络设计估计器的目的是为了能够逼近函数:

$$\text{SOC} = f(I, T) \quad (3)$$

本研究使用了 BP 神经网络模型来逼近动力电池的电流、温度和 SOC 之间的关系,其中 BP 神经网络的隐含层选择 tansig 函数。学习算法使用基于数值最优化理论的 Levenberg-Marquardt 算法作为神经网络的学习算法。

3 实验验证及结果分析

为了验证模型的有效性,本研究采用了另外 3 种工况混合的行驶工况的实验数据作为测试样本数据来验证本研究得到的神经网络模型。

这 3 种工况分别是:普锐斯工况(Prius 工况,该种工况用来测试丰田普锐斯混合动力汽车的行驶工况),CYC_Nuremberg_R36 工况(该种工况用来测试德国纽伦堡市 36 路公共汽车线路工况)和 CYC_US06 工况(该种工况用来考察测试车辆在高速情况下的行驶

状况)。以上 3 种工况基本上能够模拟出汽车在城市中行驶的加速、减速、低速和高速行驶的各种工况,测试混合工况如图 6 所示。

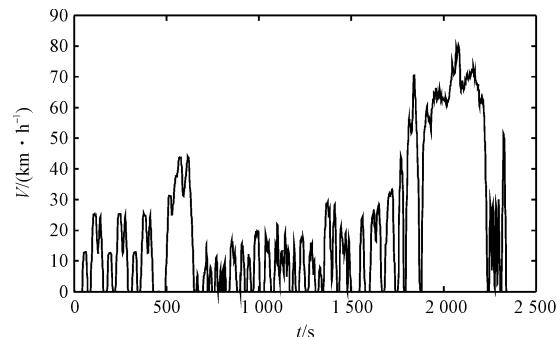


图 6 测试混合工况

本研究对得到的测试数据同样进行归一化处理。模型的输入为电池的电流和温度,模型的输出为 SOC 值。最后,得到的电池 SOC 的实际值和经过神经网络得到的 SOC 估计值如图 7 所示。

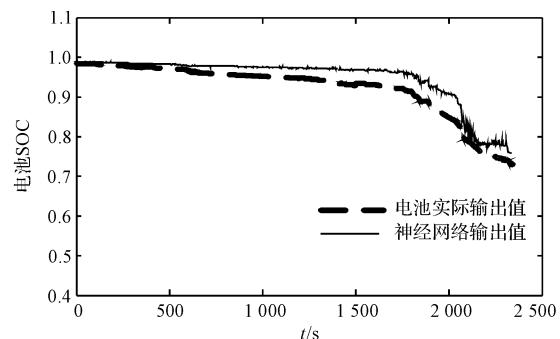


图 7 电池 SOC 输出图

通过求神经网络模型的输出值和真实值之间的误差值,来评价本研究的神经网络模型的精度。其计算公式如下式所示:

$$\text{error} = \left| \frac{D_e - D_t}{D_t} \right| \times 100\% \quad (4)$$

式中: D_e —神经网络估计器的估计值, D_t —电池 SOC 的实际值。

得到的神经网模型的估计值与动力电池 SOC 的真实值之间的误差如图 8 所示。通过图 8 可以看出,神经网络估计器的估计值与电池 SOC 的真实值之间绝对误差的最大值为 4% 左右,符合动力电池对 SOC 预测的精度要求。

4 结束语

本研究利用反向传播神经网络模型(BP 神经网络)对动力电池的荷电状态(SOC)进行估计,研究了

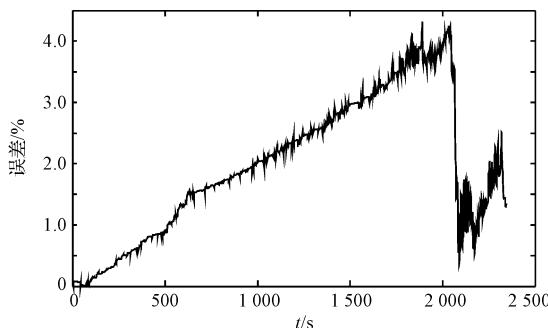


图 8 电池实际值和神经网络预测值误差

动力电池的充放电电流、电池温度和电池 SOC 之间的关系。

本研究采用了目前使用广泛的 ADVISOR 仿真软件,通过搭建仿真平台,将 ECE、UDDS 和 HWFET 3 种典型工况混合仿真,采集得到电池的电流、温度和 SOC 等参数。BP 神经网络的输入是通过 ADVISOR 仿真平台采集得到的电流值和温度值,输出是通过仿真平台得到的动力电池的荷电状态(SOC)。最后得到的神经网络模型的输出估计值与真实值之间的误差的最大值为 4%,符合电池 SOC 估计精度的要求。

参考文献(References) :

- [1] 雷 肖,陈清泉,刘开培,等.电动车蓄电池荷电状态估计的神经网络方法[J].电工技术学报,2007(8):155-160.
- [2] PILLER S, PERRIN M, JOSSEN A. Methods for state-of-charge determination and their applications[J]. *Journal of Power Sources*, 2001, 96(1):113-120.
- [3] CHO S, JEONG H, HAN C, et al. State-of-charge estimation for lithium-ion batteries under various operating conditions using an equivalent circuit model[J]. *Computers & Chemical Engineering*, 2012, 41(6):1-9.

- [4] 徐欣歌,杨 松,李艳芳,等.一种基于预测开路电压的 SOC 估算方法[J].电子设计工程,2011, 19(14):127-129.
- [5] PLETT G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs[J]. *Journal of Power Sources*, 2004, 134(2):277-292.
- [6] SHEN W X, CHAN C C, LO E W C, et al. Adaptive neuro-fuzzy modeling of battery residual capacity for electric vehicles[J]. *IEEE Transactions on Industrial Electronics*, 2002, 49(3):677-684.
- [7] 张良均,曹 晶,蒋世忠.神经网络实用教程[M].北京:机械工业出版社,2008.
- [8] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors [J]. *Nature*, 1986, 323(6088):533-536.
- [9] 周开利,康耀红.神经网络模型及其 MATLAB 仿真程序设计[M].北京:清华大学出版社,2005.
- [10] 左燕霞,徐振辞,聂建中,等.基于 BP 神经网络模型的用水量预测研究[J].灌溉排水学报,2007(S1):97-98.
- [11] 孔 庆,王 冬,张治国.电动汽车动力电池 SOC 估计研究综述[J].电气时代,2012(10):30-32.
- [12] 徐 杰.基于卡尔曼滤波的动力电池组 SOC 精确估计[D].杭州:杭州电子科技大学电子信息学院,2009.
- [13] 曾小华,宫维钧. ADVISOR 2002 电动汽车仿真与再开发应用[M].北京:机械工业出版社,2014.
- [14] 高 燕.串联式混合动力城市客车参数匹配与控制策略研究[D].济南:山东理工大学交通与车辆工程学院,2007.
- [15] 楼海星,姚 维.超级电容在电动汽车电池能量回馈中的应用[J].轻工机械,2013, 31(6):54-58.
- [16] 汤峰桃.电动车锂离子电池组 SOC 预估及一致性研究[D].重庆:重庆大学机械工程学院,2011.

[编辑:张 豪]

本文引用格式:

蔡 信,李 波,汪宏华,等.基于神经网络模型的动力电池 SOC 估计研究[J].机电工程,2015,32(1):128 - 132.

CAI Xin, LI Bo, WANG Hong-hua, et al. Estimation of state-of-charge for electric vehicle power battery with neural network method[J]. *Journal of Mechanical & Electrical Engineering*, 2015, 32(1):128 - 132.