

可充电锂电池剩余电量预测方法

陈思媛, 方正, 胡伟锋, 余杰, 王倩, 王涵博, 王禹昕

(厦门大学 航空航天学院, 福建 厦门, 361102)

摘要: 为了对锂离子电池剩余电量(SOC)进行准确测量,以 2 200 mA·h 的聚合物锂电池为研究对象,利用 Hyperion 平衡充放电设备采集 6 个不同放电电流下(0.7, 1.1, 1.7, 2.2, 2.7 和 3.3 A)的放电电压和放电倍率;采取误差反向传播(BP)和径向基函数(RBF) 2 个原理不同的神经网络算法进行 SOC 预测;把采集的样本数据分为训练组和测试组,采用不同的神经网络算法对训练组进行训练后,选择合适的参数构建神经网络,并用测试组数据进行测试;最终比较 2 种算法的预测效果和误差。研究结果表明:RBF 预测结果的相对误差比 BP 的低,且预测速度更快,RBF 较 BP 更适合于锂离子电池剩余电量的预测。

关键词: 锂离子电池;SOC 预测;BP;RBF

中图分类号: TP183

文献标志码: A

文章编号: 1672-7207(2018)09-2121-08

Method of predicting residual power of rechargeable lithium batteries

CHEN Siyuan, FANG Zheng, HU Weifeng, YU Jie, WANG Qian, WANG Hanbo, WANG Yuxin

(School of Aerospace Engineering, Xiamen University, Xiamen 361102, China)

Abstract: In order to accurately measure SOC (state of charge) of lithium ion batteries, the discharge voltage and discharge rate of 6 different discharge currents (0.7, 1.1, 1.7, 2.2, 2.7 and 3.3 A) were collected by using Hyperion balanced charge and discharge equipment with 2 200 mA·h polymer lithium battery as the research object. The neural network algorithm based on backpropagation (BP) and radial basis function (RBF) was used. Collected sample data was divided into training group and test group. After training the training group with different neural network algorithms, appropriate parameters were selected to construct the neural network and the test group data were tested. Finally, predicted results and errors of the two algorithms were compared. The results show that the average relative error of RBF prediction is lower than that of BP, and the prediction speed is faster, therefore, RBF is more suitable for the prediction of residual capacity of lithium-ion batteries than BP.

Key words: lithium ion battery; SOC prediction; BP; RBF

近年来,随着智能机、平板电脑等便携设备以及电动汽车的兴起,锂离子电池发挥的功效越来越大。要使锂离子电池的功效得到充分发挥,需要依靠性能完备、可靠性高的电池管理系统(BMS)来监控锂离子电池的状态^[1]。电池剩余电量(state of charge, SOC)作

为 BMS 研究的核心内容之一,对其进行准确预测是实现包括充放电、获取电池相关参数、实时安全监测等功能的关键所在。SOC 是通过电池的外部特性如电压、电流、温度、内阻等参数来估算的。由于受到很多不确定因素(如极化效应、电池老化、外部温度等)

收稿日期: 2017-09-16; 修回日期: 2017-10-28

基金项目(Foundation item): 国家自然科学基金资助项目(61571381) (Project(61571381) supported by the National Natural Science Foundation of China)

通信作者: 方正, 博士, 教授, 从事电池管理系统研究; E-mail: fangzheng@xmu.edu.cn

的影响, 电池的相关参数会随电池工作状态变化而变化^[2]。电池的非线性特性也给在线预测 SOC 带来极大困难, 因此, 需要对测量手段和预测方法等进行深入研究。针对 SOC 的预测方法, 一般从建立电路等效模型开始研究, 然后进行相关参数优化, 并利用相应算法(常用的有卡尔曼滤波法及由卡尔曼滤波法延伸而来的其他类型的卡尔曼滤波法)实现 SOC 的准确估计^[3]。不少研究者则从神经网络优化的角度着手, 提出关于初始权值、阈值以及隐含层的神经元个数的优化方案^[4]。同时, 对于传统的预测方法(如开路电压法与安时积分法), 优化参数增加其普适性以及提高其预测精度也成许多研究者新的研究方向^[5]。本文作者以 2 200 mA·h 的聚合物锂电池为研究对象, 采集不同放电电流下的放电电压和放电倍率; 选择误差反向传播(backpropagation, BP)、径向基函数(radial basis function, RBF)神经网络算法进行 SOC 预测; 观察预测图形以及统计相关误差指标, 并分析 BP 和 RBF 预测 SOC 的有效性。

1 SOC 预测方法概述

1.1 SOC 定义

电池剩余电量(SOC, 变量用 S 表示)是指在特定放电倍率条件下, 某时刻电池的剩余容量与额定容量的比值^[6]。下面从能量和电量 2 种角度来定义电池剩余电量。

1) 能量角度。

$$S = \left(\frac{Q_r}{Q_0} \right) \times 100\% \quad (1)$$

式中: Q_r 为该时刻电池所剩的电量; Q_0 为电池初始容量。

2) 电量角度。

$$S = \frac{W_{\text{Remember}}}{W_{\text{Initial}}} \times 100\%$$

$$S = \left(\frac{Q_r}{Q_0} \right) \times 100\% \quad (2)$$

式中: W_{Remember} 为该时刻电池所剩的电能; W_{Initial} 为电池初始电能。

与 SOC 相对的是放电深度(depth of discharge, DOD, 变量用 D 表示), 衡量的是该时刻累计放电量与其额定电池容量的比值^[7]。电池剩余电量 S 与放电深度 D 的关系如下:

$$S = 1 - D \quad (3)$$

1.2 常用 SOC 预测方法

常用的 SOC 预测方法有安时积分法、开路电压法、内阻法、卡尔曼滤波法、模糊推理和神经网络法等^[8]。为便于后续分析, 下面对本文所采用的模糊推理和神经网络的 SOC 预测方法进行介绍。

模糊推理和神经网络具有较强的非线性处理能力, 对于电池这一复杂的非线性系统适用性较高。模糊推理和神经网络可以把影响 SOC 的各种相关因素(放电电压、电池温度、放电电流等)作为输入, SOC 作为输出。由于其是基于所测的样本数据进行训练、测试、预测, 故对样本数据的精确度要求较高。

不同于卡尔曼滤波法, 模糊推理和神经网络法无需建立精确的电池等效电路模型, 因此, 硬件不需要有极高的精度。不同网络的结构训练方法不同, 所能达到的精度和效率也存在较大差别。在实际应用中, 选择合适的网络往往要综合考虑各方面的因素^[9]。

1.3 人工神经网络

人工神经网络(artificial neural network, ANN)是基于生物神经网络结构和功能的计算模型。ANN 参考生物神经构成, 构建类似于轴突的人造神经元的简单单元。当输入信号足够强时, 神经元被激活并且信号传播到与其相连的其他神经元, 通过各神经元间的相互传导, 最终得到输出信号。

基本的神经网络包含输入、输出、神经元。其中神经元接收输入, 以某种方式进行组合, 对结果执行非线性运算, 然后输出最终结果。图 1 所示为人造神经网络的基本结构。

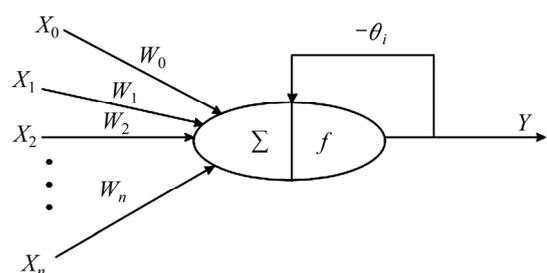


图 1 人造神经网络基本结构

Fig. 1 Basic structure of artificial neural network

多输入和单输出的结构关系可表示为

$$Z_i = \sum_{i=0}^n (W_i \times X_i - \theta_i) \quad (4)$$

$$Y = f(Z_i) \quad (5)$$

式中: $X_i(i=0, 1, \dots, n)$ 为输入; $W_i(i=0, 1, \dots, n)$ 为输入与神经元间的加权因子, 也称连接权值; θ_i 为神经元 i 的偏置, $f(\cdot)$ 为激活函数。

神经网络的实现过程如下: 首先是将输入中的每

一个乘以各自的加权因子 W_i , 然后将这些修改的输入反馈到求和函数中, 将求和函数的输出发送到传递函数中。最后通过传递函数一些特定的算法处理得到输出。传递函数还可以通过阈值缩放输出或控制其值。

随着人工智能的发展, 神经网络算法也不断得到完善。目前已经有约 40 种神经网络算法, 其中以 BP 和 RBF 这 2 种最为常见^[10]。下面, 本文作者将采用 BP 和 RBF 这 2 种算法实现 SOC 的预测并进行比较。

BP 神经网络是训练人造神经网络的常用方法, 并与诸如梯度下降的优化方法结合使用^[11]。该算法包含神经元传播信号和权值更新这 2 个阶段。BP 神经网络基本结构如图 2 所示。输入向量通过输入层输入网络时, 逐渐通过内部网络间的神经元传播, 直到到达输出层; 然后, 使用损耗函数将网络的输出与期望的输出进行比较, 计算输出层中每个神经元的误差; 最后, 把这个误差从输出开始向后传播误差, 直到每个神经元具有大致代表其对原始输出贡献度的相关联的误差为止。

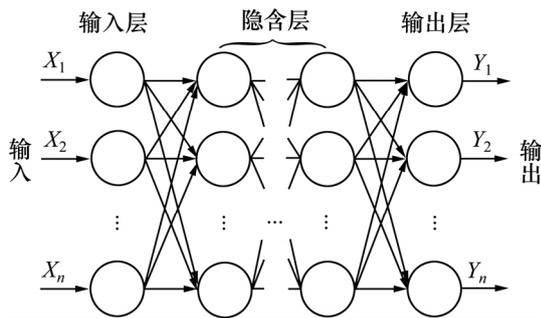


图 2 BP 神经网络基本结构
Fig. 2 Basic structure of BP neural network

BP 神经网络算法流程如图 3 所示。其中, 确认检查数 $N_{\max\text{fail}}$ 指在利用训练集进行训练的过程中, 若确认样本连续 $N_{\max\text{fail}}$ 次迭代不再下降, 则自动终止训练。设置 $N_{\max\text{fail}}$ 可以有效防止神经网络发生过拟合^[12]。 N_{fail} 为累计迭代没有下降的次数, k 为当前学习批次下正在训练的样本, t 为当前学习的批数。

RBF 网络是一种使用径向基函数作为激活函数的人工神经网络^[13]。径向基函数网络通常具有 3 层, 即输入层、具有非线性 RBF 激活功能的隐含层和线性输出层。网络的输出是输入和神经元参数的径向基函数的线性组合^[14]。RBF 神经网络结构如图 4 所示。

网络输出可以表示为

$$\varphi(x) = \sum_{i=1}^N a_i \rho(\|x - c_i\|) \quad (6)$$

式中: N 为隐含层神经元的数量; c_i 为神经元的 i 中心向量; a_i 为第 i 个神经元在线性输出神经元中的权重。

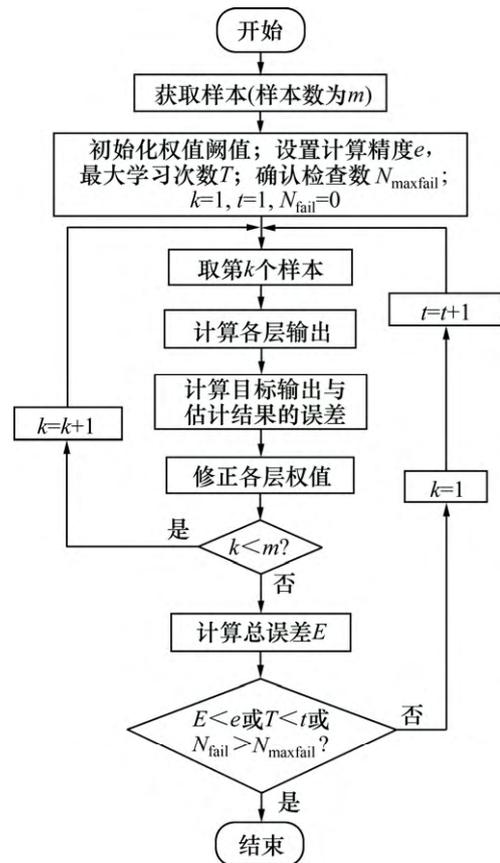


图 3 BP 神经网络算法流程
Fig. 3 Flow chart of BP neural network algorithm

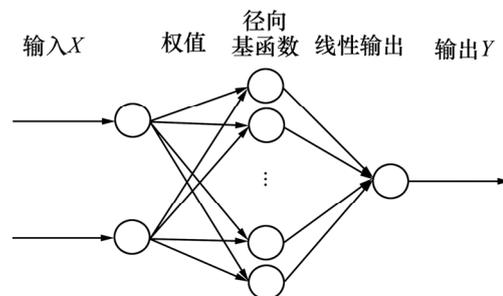


图 4 RBF 神经网络结构
Fig. 4 Structure of RBF neural network

在基本形式中, 所有输入都连接到每个隐含的神经元。径向基函数通常被认为是高斯函数。

$$\rho(\|x - c_i\|) = \exp[-\beta\|x - c_i\|^2] \quad (7)$$

对该函数求极限得

$$\lim_{\|x\| \rightarrow \infty} \rho(\|x - c_i\|) = 0 \quad (8)$$

由式(8)可知: 1 个神经元的变化参数对远离该神经元中心的输入值影响很小。具有足够隐含神经元的 RBF 网络能以任意精度逼近闭合有界集合上的任何连续函数^[15]。

RBF 神经网络算法流程如图 5 所示(其中 e_{RMSE} 为预测值和真实值的均方根误差)。

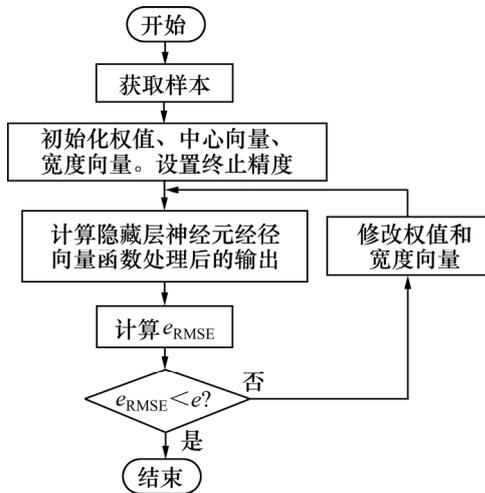


图 5 RBF 神经网络算法流程

Fig. 5 Flow chart of RBF neural network algorithm

2 实验过程及数据分析

聚合物锂电池的额定容量为 2 200 mA·h, 最大自放电倍率为 25C, 充放电截止电压分别为 4.2 和 3.6 V。

以 Hyperion NET & DUO3 系列平衡锂电池充放电设备为实验平台, 并用 Hyperion control & date suite 软件对锂电池充放电过程进行监测、观察。可通过上位机对相关参数(放电电流、放电截止电压、充放电循环次数、端口选择等)进行设定。该平衡充放电设备对锂离子电池的充放电倍率在 1C~5C 之间。在实际测量过程中, 当放电倍率为 2C 时, 放电电流即达到 4.4 A, 满足实验设定的电流范围, 因此, 把所研究的聚合物锂电池放电倍率设在 2C 之内。分别在放电电流为 0.7, 1.1, 1.7, 2.2, 2.7 和 3.3 A 下各采集 3 组放电电压和放电倍率。

2.1 BP 神经网络预测 SOC

理论上 BP 神经网络可以完成从 p 维向量到 q 维向量的映射。通过前面的分析可知: 环境温度、电池内阻、放电倍率等因素均会对 SOC 预测产生影响; 相关影响因素越多, SOC 预测精度就越高。但实验中能够完整实现可控制的参数仅有放电倍率; 又因为是恒流放电, 故采取放电电压和放电倍率为输入向量, 选择 SOC 作为预测输出变量^[16]。

为了增强网络的自适性, 选取 0.7, 1.7 和 2.7 A 放电电流下测得的放电电压和放电倍率为训练样本, 1.1, 2.2 和 3.3 A 放电电流下的放电电压和放电倍率作为测试样本, 来验证 BP 神经网络预测 SOC 的精度。

已知输入层和输出层各 1 层, 主要确定隐含层的

层数。隐含层层数越多, 在提高计算精度的同时, 相应的计算量也增大, 同时, 过拟合出现的可能性也较大^[17]。鉴于输入、输出变量数较少, 优先选择 1 层隐含层。激活函数选择具有实现任意的判决分类问题的 S 型函数即 tansig 函数。神经节点的经验公式为

$$h = \sqrt{p+q} + a \quad (9)$$

$$h = \log_2 p \quad (10)$$

$$h = 2p+1 \quad (11)$$

式中: h 为隐藏层节点数; q 为输出层节点数; p 为输入层节点数; a 为 1~10 之间的常数。经分析可知输入层 p 的神经元数为 2, 输出层神经元数 q 为 1, 由此计算得隐含层的神经元数 m 为 1~12 个。

用 1.1 A 放电电流下的放电电压和放电倍率作为测试对象验证当隐含层神经元数为 1~12 个情况下的 SOC 预测误差, 在每种情况下各测试 5 次, 然后选取最好的结果进行统计, 结果如表 1 所示。

由表 1 可知: 在隐含层神经元数分别为 1, 7, 8, 10, 11 和 12 个的情况下, SOC 最大误差均超过 0.05, 说明某些值存在较大的预测误差。在隐含层神经元数分别为 2, 3, 4, 5, 6 和 9 个的情况下, 5, 6 和 9 个神经元情况下的 SOC 平均相对误差较小。与神经元数分别为 5 和 6 个的情况相比, 不管是平均相对误差还是最大误差以及误差的标准差, 神经元数为 6 个的都比神经元数为 5 个的低, 故优先选择神经元数为 6 个的情况。由于神经元数为 6 个的训练次数比神经元数为 9 个的小且各项误差很接近, 经综合考虑, 选择隐含层神经元个数为 6。基于前面的分析, 构建 BP 神经网络如图 6 所示(其中 U 为放电电压; C 为放电倍率)。

利用构建的神经网络, 分别对放电电流为 1.1, 2.2 和 3.3 A 下的放电电量进行预测。利用 MATLAB 构建 BP 网络来实现预测, 并计算相关误差^[18]。不同放电电流下的放电电压与 DOD 的关系及预测误差分布图如图 7 所示。

对 1.1, 2.2 和 3.3 A 放电电流下的误差、训练次数进行统计, 结果如表 2 所示。

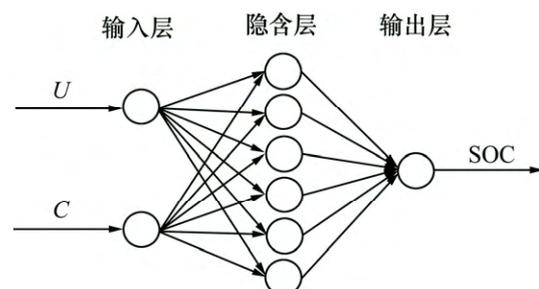


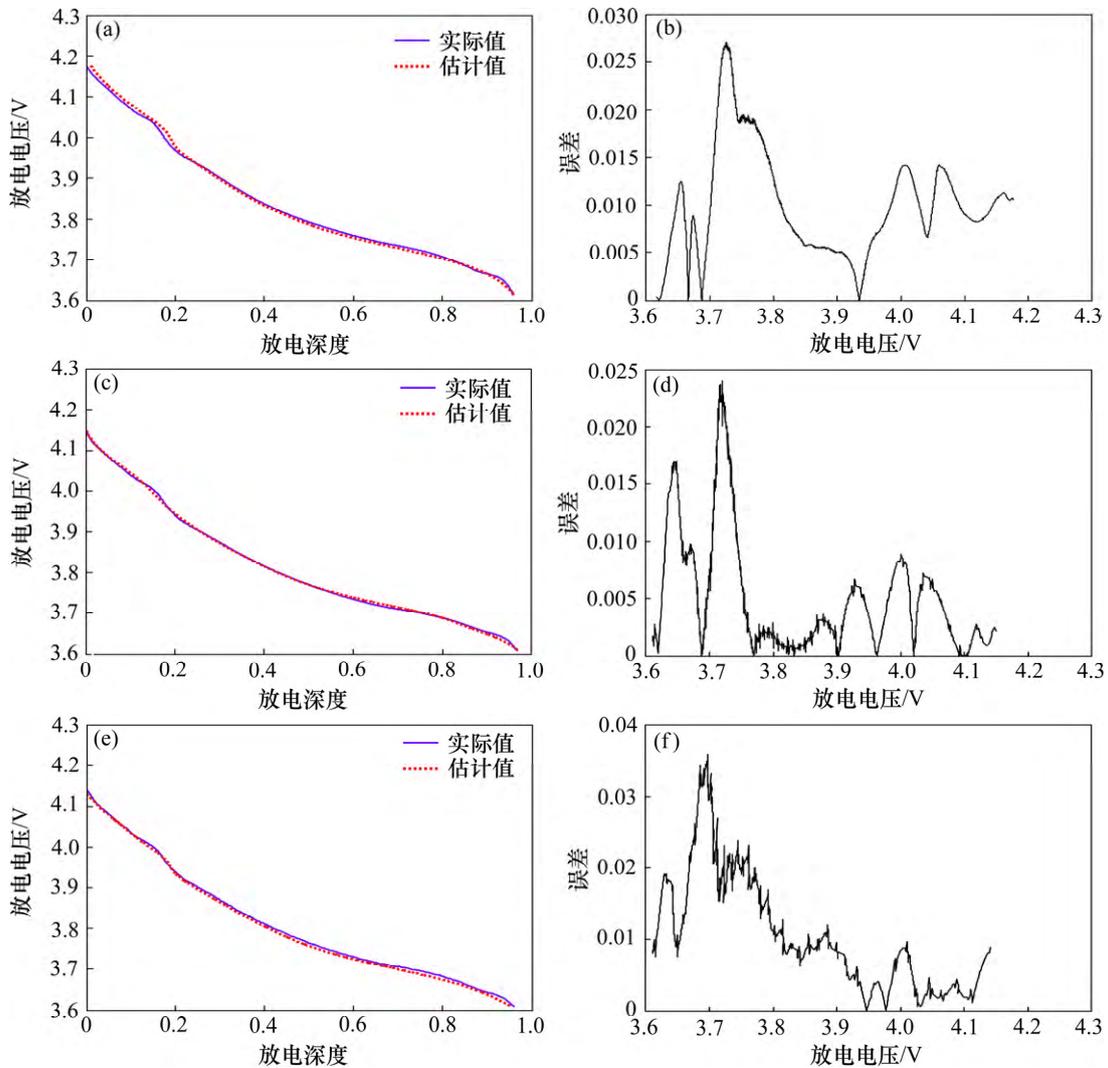
图 6 构建的 BP 神经网络

Fig. 6 Constructed BP neural network

表 1 BP 神经网络在不同隐含层神经元数量下的 SOC 预测误差对比

Table 1 Comparison of SOC prediction errors of BP neural network with different hidden neurons

神经元数/个	训练数/次	平均相对误差	最大误差	最小误差	平均误差	误差的标准差
1	17	0.214 3	0.101 5	0	0.018 5	0.014 5
2	135	0.044 0	0.029 3	0	0.011 6	0.005 9
3	174	0.096 1	0.040 8	0	0.005 5	0.004 6
4	194	0.076 4	0.032 1	0	0.017 1	0.007 7
5	161	0.066 8	0.025 5	0	0.014 7	0.007 5
6	117	0.051 5	0.021 4	0	0.011 1	0.004 1
7	125	0.166 5	0.071 5	0	0.022 5	0.016 7
8	243	0.435 1	0.319 3	0.000 2	0.147 8	0.096 7
9	734	0.047 4	0.031 2	0	0.009 7	0.006 8
10	236	0.294 3	0.158 1	0.000 1	0.069 3	0.052 2
11	499	0.454 1	0.589 4	0	0.229 7	0.195 5
12	222	1.365 8	0.224 5	0.000 4	0.043 7	0.045 0



(a) 1.1 A 放电电流下放电电压与放电深度的关系 ; (b) 1.1 A 放电电流下 SOC 预测误差分布 ;
 (c) 2.2 A 放电电流下放电电压与放电深度的关系 ; (d) 2.2 A 放电电流下 SOC 预测误差分布 ;
 (e) 3.3 A 放电电流下放电电压与放电深度的关系 ; (f) 3.3 A 放电电流下 SOC 预测误差分布。

图 7 不同放电电流下放电电压与放电深度(DOD)关系及 SOC 预测误差分布

Fig. 7 Relationship between discharge voltage and DOD and SOC prediction error distribution at different discharge current

表 2 不同放电电流下 SOC 预测误差

放电电流/A	训练次数	平均相对误差	最大误差	最小误差	平均误差	误差标准差
1.1	187	0.054 8	0.025 6	0	0.014 8	0.008 2
2.2	182	0.022 8	0.024 0	0	0.006 5	0.006 2
3.3	120	0.048 9	0.035 9	0	0.014 2	0.008 9

从表 2 可知:当隐含层神经元个数为 6 时,在 1.1, 2.2 和 3.3 A 放电电流下,三者的训练次数均不超过 200 次,且 SOC 预测值与真实值的平均相对误差均小于 0.1。总体来看,利用 BP 神经网络预测 SOC 能将误差控制在 5% 以内,属于可接受的范围^[19]。

2.2 RBF 神经网络预测 SOC

选用 MATLAB 中的 newrb 函数来构建严格径向基网络,即隐含层神经元个数与输入样本数一致,在本文中限于计算机存储,选取 3 000 个样本^[20]。对于

扩展速度因子 S_p 的选择,对不同的 S_p 进行试验,发现当 S_p 越大时,预测的曲线越光滑,但同时误差也越大^[21]。采用分区间搜索法确定了较优的 S_p 为 0.788。

构建的 RBF 神经网络如图 8 所示。

2.3 网络预测

利用 RBF 神经网络对 1.1, 2.2 和 3.3 A 的放电电流下的 DOD 进行预测^[22],得到不同放电电流下的放电电压与 DOD 关系及预测误差分布,如图 9 所示。

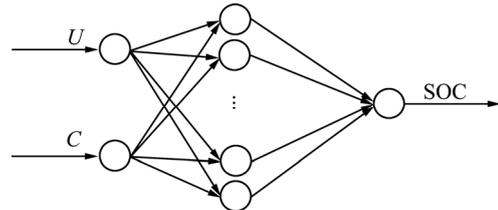
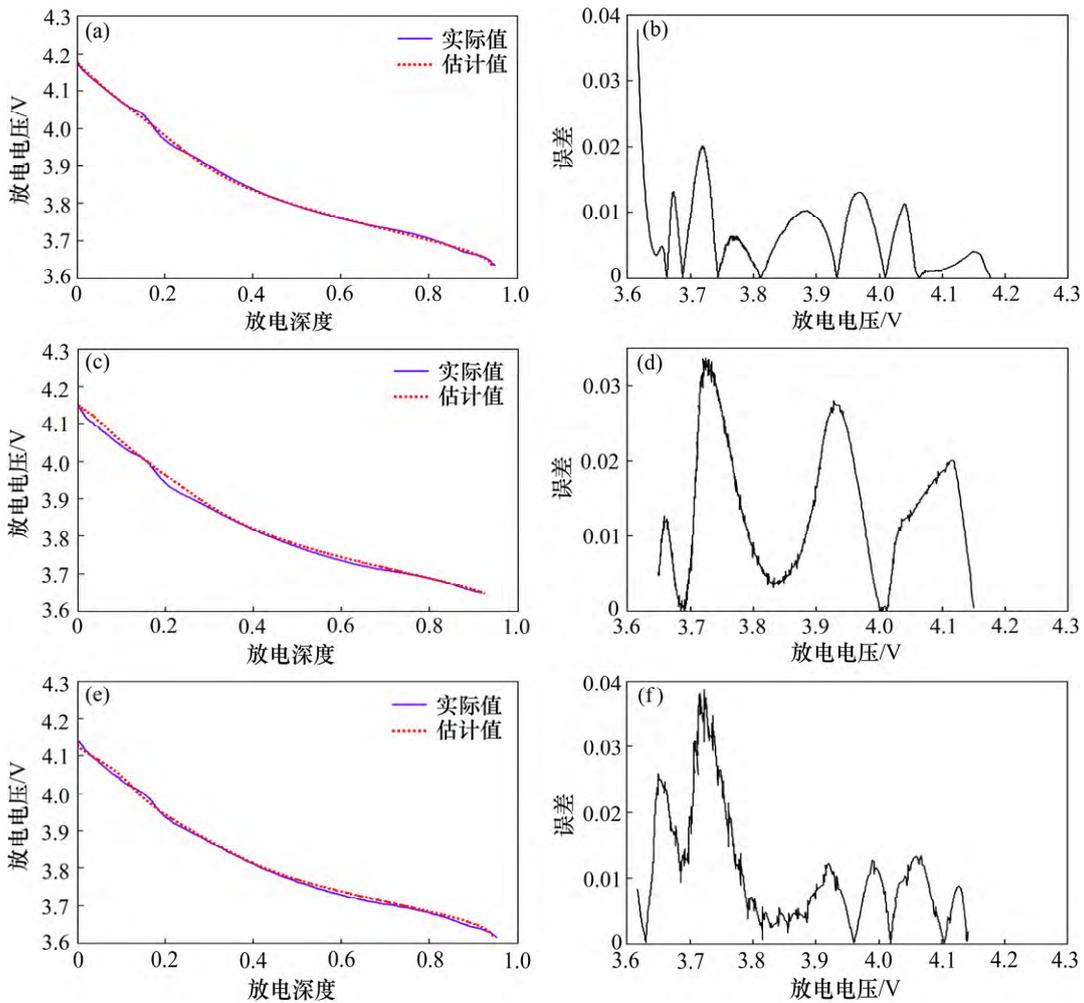


图 8 构建的 RBF 神经网络

Fig. 8 Constructed RBF neural network



(a) 1.1 A 放电电流下放电电压与放电深度的关系; (b) 1.1 A 放电电流下 SOC 预测误差分布;
 (c) 2.2 A 放电电流下放电电压与放电深度的关系; (d) 2.2 A 放电电流下 SOC 预测误差分布;
 (e) 3.3 A 放电电流下放电电压与放电深度的关系; (f) 3.3 A 放电电流下 SOC 预测误差分布。

图 9 不同放电电流下放电电压与放电深度(DOD)关系及 SOC 预测误差分布

Fig. 9 Relationships between discharge voltage and DOD and SOC prediction error distribution under different discharge currents

在 1.1、2.2 和 3.3 A 放电电流下 RBF 神经网络 SOC 预测误差如表 3 所示。

表 3 RBF 神经网络 SOC 预测误差

Table 3 SOC prediction errors of RBF neural network

放电 电流/A	平均 相对误差	最大 误差	最小 误差	平均 误差	误差 标准差
1.1	0.026 9	0.020 2	0	0.006 6	0.005 0
2.2	0.090 6	0.033 7	0	0.014 2	0.009 7
3.3	0.059 6	0.038 7	0	0.014 1	0.010 1

由图 9 和表 3 可知: RBF 神经网络对放电深度 DOD 和电池剩余电量 SOC 进行预测得到的预测值与真实值间的最大误差、平均误差都控制在 0.05 以内,且平均相对误差在 0.10 以内。总体来说,用 RBF 神经网络算法对 DOD 进行预测可以取得良好的效果。

3 结论

1) BP 和 RBF 算法都能实现 SOC 的准确预测。

2) BP 神经网络初始权值和阈值的确定极为困难,且对神经网络的预测效果及其适用性都会产生较大影响,且难以确定最优值;而 RBF 则在局部寻优过程中克服了 BP 陷入局部极小值的特点,且预测效果与 BP 的预测效果相当,运行速度更快。经综合考虑,RBF 较 BP 更适合于锂离子 SOC 预测。

参考文献:

- [1] 汪世国. 电动汽车电池管理系统(BMS)现状分析[J]. 汽车实用技术, 2014(2): 65-67.
WANG Shiguo. Status analysis of battery management system (BMS) for electric vehicles[J]. Automobile Practical Technology, 2014(2): 65-67.
- [2] 潘佰韬. 锂离子电池管理系统的设计与 SOC 估算研究[D]. 天津: 河北工业大学车辆工程系, 2015: 12
PAN Baitao. Design and SOC estimation of Li ion battery management system[D]. Tianjin: Department of vehicle engineering, Hebei University of Technology, 2015: 12
- [3] AUNG H, LOW K S, SHU T G. State-of-charge estimation of lithium-ion battery using square root spherical unscented Kalman filter (Sqrt-UKFST) in nanosatellite[J]. IEEE Transactions on Power Electronics, 2015, 30(9): 4774-4783.
- [4] 尹安东, 张万兴, 赵韩, 等. 基于神经网络的磷酸铁锂电池 SOC 预测研究[J]. 电子测量与仪器学报, 2011, 25(5): 433-437.
YIN Andong, ZHANG Wanxing, ZHAO Han, et al. Study on SOC prediction of lithium iron phosphate battery based on neural networks[J]. Journal of Electronic Measurement and Instrumentation, 2011, 25(5): 433-437.
- [5] 范兴明, 曾求勇, 张鑫. 基于改进安时积分法的电动汽车电池 SOC 估计与仿真研究[J]. 电气应用, 2015, 34(8): 111-115.
FAN Xingming, ZENG Qiuyong, ZHANG Xin. Improved ah integral method of electric vehicle battery SOC estimation and Simulation of electrical[J]. Electrotechnical Application, 2015, 34(8): 111-115.
- [6] 季迎旭, 杜海江, 孙航. 蓄电池 SOC 估算方法综述[J]. 电测与仪表, 2014, 51(4): 18-22.
JI Yingxu, DU Haijiang, SUN Hang. Summarization of battery SOC estimation methods[J]. Electrical Measurement and Instrumentation, 2014, 51(4): 18-22.
- [7] 孟仙雅, 刘立炳, 惠怀兵, 等. 放电深度对电池使用寿命的影响[J]. 汽车科技, 2016(3): 47-51.
MENG Xianya, LIU Libing, HUI Huaibing, et al. Influence of discharge depth on battery life[J]. Automotive Science and Technology, 2016(3): 47-51.
- [8] 邓涛, 孙欢. 锂离子电池新型 SOC 安时积分实时估算方法[J]. 重庆理工大学学报(自然科学), 2015, 29(1): 101-106.
DENG Tao, SUN Huan. A new real-time SOC time integration estimation method for Li ion battery[J]. Journal of Chongqing University of Technology (Natural Science), 2015, 29(1): 101-106.
- [9] 余少波, 严隽永. 神经网络应用[J]. 海军工程大学学报, 1990(2): 61-65.
YU Shaobo, YAN Juanyong. Neural network application[J]. Journal of Naval University of Engineering, 1990(2): 61-65.
- [10] 刘永, 张立毅. BP 和 RBF 神经网络的实现及其性能比较[J]. 电子测量技术, 2007, 30(4): 77-80.
LIU Yong, ZHANG Liyi. Implementation and performance comparison of BP and RBF neural networks[J]. Electronic Measurement Technology, 2007, 30(4): 77-80.
- [11] KARAYIANNIS NICOLAOS B. Reformulated radial basis neural networks trained by gradient descent[J]. IEEE Transactions on Neural Networks, 1999, 10(3): 10-27.
- [12] 李俭川, 秦国军, 温熙森, 等. 神经网络学习算法的过拟合问题及解决方法[J]. 振动、测试与诊断, 2002, 22(4): 260-264.
LI Jianchuan, QIN Guojun, WEN Xisen, et al. Over fitting problem of neural network learning algorithm and its solution[J]. Vibration, Testing and Diagnosis, 2002, 22(4): 260-264.
- [13] 周俊武, 孙传尧, 王福利. 径向基函数(RBF)网络的研究及实现[J]. 矿冶, 2001, 10(4): 71-75.
ZHOU Junwu, SUN Chuanyao, WANG Fuli. Research and implementation of radial basis function (RBF) network[J]. Mine and Metallurgy, 2001, 10(4): 71-75.

- [14] 颜七笙, 游泳, 杨志辉. BP 网络结构设计与算法探讨[J]. 科技广场, 2005(3): 36–38.
YAN Qisheng, You Yong, YANG Zhihui. BP network structure design and algorithm discussion[J]. Science and Technology Plaza, 2005(3): 36–38.
- [15] PRIMADUSI U, CAHYADI A I, WAHYUNGGORO O. The comparison of RBF NN and BPNN for SOC estimation of LiFePO₄ battery[C]// AIP Conference Proceedings 1755. Yogyakarta, INDONESIA: AIP Publishing, 2016: 090010-1–090010-7.
- [16] GUO Yifeng, ZHAO Zeshuang, HUANG Limin. SoC estimation of Lithium battery based on improved BP neural network[J]. Energy Procedia, 2017, 105: 4153–4158.
- [17] 陈强, 王洪佩. 基于 BP 神经网络的 SOC 估算策略研究[J]. 汽车与安全, 2011(8): 58–60.
CHEN Jiang, WANG Hongpei. Research on SOC estimation strategy based on BP neural network[J]. Automotive and Safety, 2011(8): 58–60.
- [18] 郭利辉, 周雅. 基于 MATLAB 神经网络工具箱的 BP 网络设计[J]. 信息技术与信息化, 2009(3): 20–22.
GUO Lihui, ZHOU ya. Design of BP network based on MATLAB neural network toolbox[J]. Information Technology and Informatization, 2009(3): 20–22.
- [19] HUANG Sirun, MA Yenhui, HENG Shiyun, et al. The SOC estimation of LCO battery based on BP neural network[M]// Energy, Transportation and Global Warming. New York, USA: Springer International Publishing, 2016: 543–552.
- [20] 高宁, 张建中. MATLAB 在 RBF 神经网络模型中的应用[J]. 农业网络信息, 2009(2): 111–112, 117.
GAO Ning, ZHANG Jianzhong. Application of MATLAB in RBF neural network model[J]. Agricultural Network Information, 2009(2): 111–112, 117.
- [21] SHARMA V. Analysis of spread spectrum in MATLAB[J]. International Journal of Scientific and Engineering Research, 2014, 5: 1899–1902.
- [22] 史艳霞, 乔佳. 基于 RBF 网络的锂电池 SOC 估算研究[J]. 自动化与仪表, 2015, 30(9): 89–92.
SHI Yanxia, QIAO Jia. Research on SOC estimation of lithium battery based on RBF network[J]. Automation and Instrumentation, 2015, 30(9): 89–92.

(编辑 伍锦花)