

基于ESN的锂电池SOC评估方法与仿真研究*

杜广波¹, 蔡茂², 张鑫², 范兴明², 程江华¹

(1. 中国联合工程有限公司, 浙江 杭州 310052; 2. 桂林电子科技大学 电气工程及其自动化系, 广西 桂林 541004)

摘要: 以新能源车载锂电池为研究对象, 建立基于回声状态网络(ESN)预测锂电池的荷电状态(SOC)评估模型。采用交叉验证方法优选回声状态网络参数, 以此解决网络模型的参数选择困难。通过带遗忘因子的递归最小二乘法训练建立的回声状态网络模型, 实时更新输出权值矩阵以此提高网络的适应性和精度。通过模型仿真分析验证了预测算法的可行性, 进一步对比分析了所建立的ESN预测模型与BP神经网络算法、径向基(RBF)网络算法在UDDS、US06和NYCC工况条件下的锂电池SOC评估预测效果, 结果表明所建立的回声状态网络模型方法用于锂电池SOC评估预测的性能和效果优于BP算法和RBF算法, 具有较好的应用前景, 可以为锂电池SOC长期长效预测评估提供参考。

关键词: 锂电池; 荷电状态; 回声状态网络; 参数优化选择; 交叉验证

中图分类号: TP305

文献标志码: A

DOI: 10.16157/j.issn.0258-7998.223057

中文引用格式: 杜广波, 蔡茂, 张鑫, 等. 基于ESN的锂电池SOC评估方法与仿真研究[J]. 电子技术应用, 2023, 49(1): 45-51.

英文引用格式: Du Guangbo, Cai Mao, Zhang Xin, et al. Research on SOC evaluation method and simulation of lithium battery based on echo state network[J]. Application of Electronic Technique, 2023, 49(1): 45-51.

Research on SOC evaluation method and simulation of lithium battery based on echo state network

Du Guangbo¹, Cai Mao², Zhang Xin², Fan Xingming², Cheng Jianghua¹

(1. China United Engineering Corporation Limited, Hangzhou 310052, China;

2. Dep. of Electrical Engineering & Automation, Guilin University of Electronic and Technology, Guilin 541004, China)

Abstract: Taking lithium battery of new energy vehicles as the research object, an echo state network (ESN) model is established to predict the state of charge (SOC) of the vehicle's lithium battery. The cross-validation method is used to optimize the parameters of the ESN to solve difficulty to select parameters of the model. The echo state network is trained by recursive least squares method with forgetting factors to calculate the output weight matrix so as to improve the adaptability and accuracy of the network. The feasibility of the prediction algorithm is further analyzed and verified by the model simulation. The research further analyzes and compares the predicted SOC of the established ESN model, the BP neural network algorithm and radial basis function (RBF) network algorithm under UDDS, US06 and NYCC. The research results show that the established echo state network model is superior to the BP algorithm and RBF algorithm in estimating the performance and effect of lithium-ion battery SOC evaluation. Using ESN model to predict SOC has a good application prospect and can provide a reference for long-term and effective SOC prediction of the lithium battery.

Key words: lithium battery; state of charge; echo state network; parameters optimization and selection; cross validation

0 引言

新能源电动汽车锂电池因具有无污染、续航能力强以及可多次循环使用等优点被广泛应用, 锂电池荷电状态SOC的预测研究是新能源汽车领域的关键技术。

SOC反映了锂电池的剩余可用电量^[1-2], 准确预测SOC对于研究新能源汽车的续航里程、锂电池合理充放电以及电池健康管理等可提供可靠依据^[3]。

锂电池内部化学反应复杂, SOC的变化受温度、电池循环使用次数、充放电倍率和老化等多种因素影响, 致使SOC预测困难^[4]。常用预测SOC的方法主要有: 安

* 基金项目: 国家自然科学基金(61741126); 广西自然科学基金(2022GXNSFAA035533)

时积分法、开路电压法、内阻法和电池模型法。由于这些方法存在误差累积较多^[5-6]、应用状态受限^[7-8]、无法直接检测实际SOC^[9]、参数辨识困难^[10-13]等不足,其应用场合受到一定限制。

采用交叉验证法对回声状态网络(ESN)的储备池规模 N 、谱半径SR、输入缩放IS和输入位移IF进行寻优,并采用带遗忘因子的递归最小二乘法实时调整网络输出权值矩阵。为验证ESN算法的可行性和优越性,将ESN算法在UDDS工况下与BP算法和RBF算法以不同的训练集和测试集进行仿真对比,进而将以上3种算法在UDDS、US06和NYCC工况下进行对比分析。

1 ESN建模分析

1.1 原理分析

研究表明,回声状态网络具有储备池神经元丰富、网络计算量少、神经元连接具有稀疏性、可通过少量输入随机产生复杂多样的网络状态空间等特点。

如图1所示,回声状态网络模型包含 K 个输入单元, L 个输出单元,储备池规模为 N ,网络输入权值矩阵 $W_{in(N \times K)}$,储备池内部权值矩阵 $W_{(N \times N)}$,反馈权值矩阵 $W_{back(N \times L)}$ 。




图1 回声状态网络结构图

储备池内部更新状态如式(1)、(2)所示:

$$x_{(n+1)} = f(W \times x_{(n)}) + W_{in} \times u_{(n+1)} + W_{back} \times y_{(n)} \quad (1)$$

$$y_{(n+1)} = f_{out}(x_{(n+1)}, u_{(n+1)}, y_{(n)}) \quad (2)$$

式中, $u_{(n)}$ 为网络输入向量, $n=1,2,\dots,M$; $x_{(n)}$ 为储备池内部 n 时刻的输入信号, $n=1,2,\dots,N$; $y_{(n)}$ 为网络输出, $n=1,2,\dots,M$; $f(*)$ 为储备池内部神经元的S型激活函数, f_{out} 为输出节点的线性激活函数。

1.2 ESN参数寻优

基于以上分析,回声状态网络的研究和实施中仍存在多元参数优化选择的困难,包括储备池神经元规模 N 、谱半径SR、输入缩放IS、输入位移IF和稀疏度SD,且参数之间相互独立互不影响。 N 反映了储备池规模的大小,一定范围内 N 增加,网络的非线性处理能力越强, N 过大将导致网络灾难和计算复杂等问题;谱半径SR为储备池内部权值矩阵的最大特征值,当 $0 < SR < 1$ 时可确保网络具有回声状态特性;IS和IF为输入信号传递至储备池前需进行一定的缩放和移动;SD反映了储备池

神经元的互相连接情况,一般取2%~10%,当SD=100%时,回声状态网络即为传统递归神经网络,储备池为传统神经网络的隐层结构。假定 N 、IS、IF和SR按表1所设定的范围和步长进行变化,则 N 需要变化的次数为24次,IS、IF和SR变化的次数为20次,若采用穷举法寻优,则需要做的计算次数为 $24 \times 20 \times 20 \times 20 = 192\,000$ 次,计算复杂,给网络参数寻优带来了困难。

表1 参数设置和步长

参数	取值范围	步长
N	[30,150]	5
SR	[0,1]	0.05
IS	[0,1]	0.05
IF	[0,1]	0.05

针对ESN参数寻优困难,采用一种基于 K 折交叉验证的方法来优选网络相关参数,具体实施如下:将采集到的电池相关数据分为 K 组,其中一组作为测试集,其他的作为训练集,同时寻优参数以一定的步长变化,经过 K 次训练和测试,当网络训练和测试结束后,与训练和测试误差之和最小对应的参数则可认为是最优参数。研究数据来源于美国高级汽车仿真软件Advisor,该软件通过大量人工实验获取电动汽车在美国城市道路复杂时变工况UDDS下车载锂电池实际放电的实时电流、电压、电池组外表温度以及实际SOC值,共1598组数据,并分为4个数据子集,交叉验证中取 $K=4$,如图2所示进行4回合的训练和测试。理论上随着 K 值的增加,所选取的网络参数更优,但同时也会带来网络计算灾难等问题,因此 K 值的选取需结合网络的复杂度以及实施难易程度来选取。

1	训练集	训练集	训练集	测试集
2	训练集	训练集	测试集	训练集
3	训练集	测试集	训练集	训练集
4	测试集	训练集	训练集	训练集

图2 训练集和测试集

在第一回合中,前3个数据子集用以训练模型,另外一个作为测试集;在第二回合中,则将第1、2、4个数据子集作为训练集,依此类推,经过4次训练,4次测试后得到测试误差 $error_{test}$ 和4次训练误差 $error_{train}$,求得 $Error = (error_{test} + error_{train}) / 2$,取误差平均值 $\min(Error)$ 作为最优解。首先随机产生输入缩放和输入位移的值,IS =

[0.5;0.5;0.5], IF=[0.1;0.1;0.1],同时 N 和 SR 分别以如表 1 所示的步长变化,得到最优解如表 2 所示。得到最优训练误差 0.037 52,测试误差 0.022 76,与之对应的 $N=75$, SR=0.4 可认为是最优参数。同理固定 $N=75$, SR=0.4,再次进行参数寻优得到 IS=[0.25;0.25;0.25], IF=[0.55;0.55;0.55]。经上述计算,4 折交叉验证计算次数为 $24 \times 20 \times 4 + 20 \times 20 \times 4 = 3\ 520$ 次,相比穷举法计算 192 000 次,4 折交叉验证的寻优计算效率提高了接近 55 倍。因此 ESN 参数寻优最终取值分别为 $N=75$, SR=0.4, IS=[0.25;0.25;0.25], IF=[0.55;0.55;0.55],4 折交叉验证流程图如图 3 所示。稀疏度 SD 反映了储备池神经元内部连接情况,通过试验法取得 SD=8%。

表 2 参数选取

初始值	最优参数	error _{train}	error _{test}
IS=[0.5;0.5;0.5]	$N=75$	0.037 52	0.022 76
IF=[0.1;0.1;0.1]	SR=0.4		
$N=75$	IS=[0.25;0.25;0.25]	0.015 87	0.035 18
SR=0.4	IF=[0.55;0.55;0.55]		

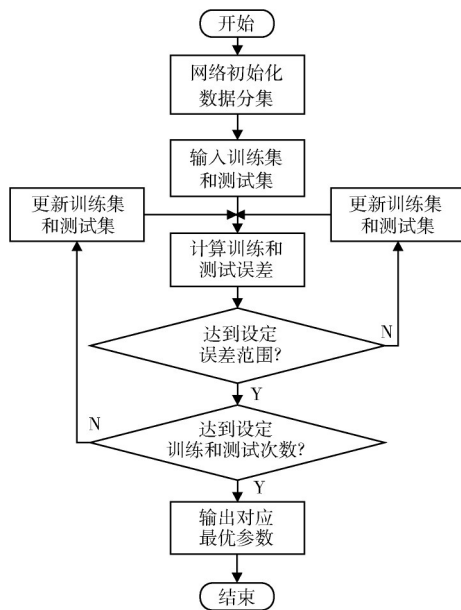


图 3 4 折交叉验证流程图

2 ESN 训练和预测过程分析

车载锂电池 SOC 与锂电池的实时电流、电压存在非线性时变的关系,且电池组外表温度会影响电池活性,因此 ESN 输入设定为锂电池实时电流、电压、和电池组外表温度, SOC 值作为网络输出,网络输出与输入的函数关系可表述为:

$$\text{SOC}_t = f(I_t, V_t, T_t) \quad (3)$$

因此,ESN 输入节点确定为 $K=3$,储备池神经元 $N=75$,输出节点 $L=1$ 。参数设置为:稀疏度 SD=8%,储备池

谱半径 SR=0.4,输入缩放 IS=[0.25;0.25;0.25],输入位移 IF=[0.55;0.55;0.55]。采用带遗忘因子 λ 的递归最小二乘法(RLS)进行网络训练,设所求输出权值矩阵为 \mathbf{W}_{out} ,网络教师监督信号设为 $\mathbf{Y}_{(n)}$ 。为使得网络输出和教师监督信号 $\mathbf{Y}_{(n)}$ 之间保证误差最小化,则有求解最优的条件约束:

$$\min \frac{1}{M-m+1} \left[\sum_{n=m}^M \mathbf{Y}_{(n)} - \sum_{i=1}^K \mathbf{W}_{\text{out}i} \times \mathbf{x}_{i(n)} \right]^2 \quad (4)$$

由式(4)可得网络误差:

$$\mathbf{E}_{(k)} = \mathbf{Y}_{(n)} - \sum_{i=1}^K \mathbf{W}_{\text{out}i} \times \mathbf{x}_{i(n)} \quad (5)$$

引入 RLS 的遗忘因子 λ ,则有 $J_{(n)}$ 满足:

$$J_{(n)} = \frac{1}{2} \sum_{k=1}^n \lambda^{n-k} E_{(k)}^2 \quad (0 < \lambda < 1) \quad (6)$$

RLS 算法遗忘因子 λ 的引入会使得 RLS 对所求输出权值矩阵做出快速反应,使得网络加快了寻求使得 $J_{(n)}$ 最小的权值矩阵 \mathbf{W}_{out} ,则可通过求偏导计算出满足式(4)的输入权值矩阵:

$$\frac{\partial J_{(n)}}{\partial \mathbf{W}_{\text{out}}} = 0 \quad (7)$$

为避免网络训练陷入局部最优,当满足式(7)时,设定误差阈值。若训练误差小于误差阈值时,输出权值矩阵,因此误差函数 $J_{(n)}$ 取得极值时,达到了设定的误差阈值,可近似认为所得对应的 \mathbf{W}_{out} 是满足网络最优条件的输出权值矩阵,由带遗忘因子的 RLS 算法可得 ESN 输出权值矩阵的更新方程如下:

$$\mathbf{W}_{\text{out}}^{k+1} = \mathbf{W}_{\text{out}}^k + \mathbf{Q}^k \mathbf{E}_{(k)} \quad (8)$$

其中, \mathbf{Q}^k 为权值增益矩阵,权值矩阵 \mathbf{W}_{out} 调整流程图如图 4 所示。




图 4 输出权值更新流程图

基于以上 ESN 学习算法的分析,ESN 预测 SOC 实施步骤如下:

- (1)确定网络输入和输出节点;
- (2)网络初始化,随机设定输入权值矩阵,储备池内部权值矩阵,矩阵元素取值在[-1,1]之间随机产生,并保持不变;
- (3)将初始采集数据分为 4 份进行训练和测试,交叉验证确定最优参数 N 、SR、IS、IF,试验法确定 SD;
- (4)采用带遗忘因子的递归最小二乘法进行网络学习,实时更新输出权值矩阵;

(5)判断网络学习是否达到终止条件(达到设定误差 Error 或步数),如果没达到,返回步骤(4),继续加载训练集和测试集进行学习,直到满足条件终止;

(6)将训练好的回声状态网络输入采集的最新数据进行预测,输出预测 SOC 值。

3 模型验证与仿真分析

回声状态网络经 4 折交叉验证参数寻优和网络模型建立完成后,以美国高级汽车仿真软件 Advisor 在 Matlab 环境下采集到 UDDS、US06 和 NYCC 3 个工况下的电流、电压和温度作为网络输入,采集的 SOC 为神经

络教师监督信号,工况数据分别为 1 598 组、389 组和 1 795 组。为验证交叉验证选取网络参数的可靠性以及回声状态网络模型的可行性和优越性,根据 Kolmogorov 定理^[14-15]建立经典 3 层前向 BP 神经网络模型和 RBF 神经网络模型用于电池 SOC 的预测。将 ESN 算法与 BP 算法和 RBF 算法在多工况不同训练集和测试集下进行对比分析。为比较 ESN、BP 算法和 RBF 算法的性能,分别使用 479 组、639 组和 700 组 UDDS 工况数据进行训练,得到的预测曲线每间隔 63 s 作图,如图 5~图 7 所示,仿真结果如表 3 所示。

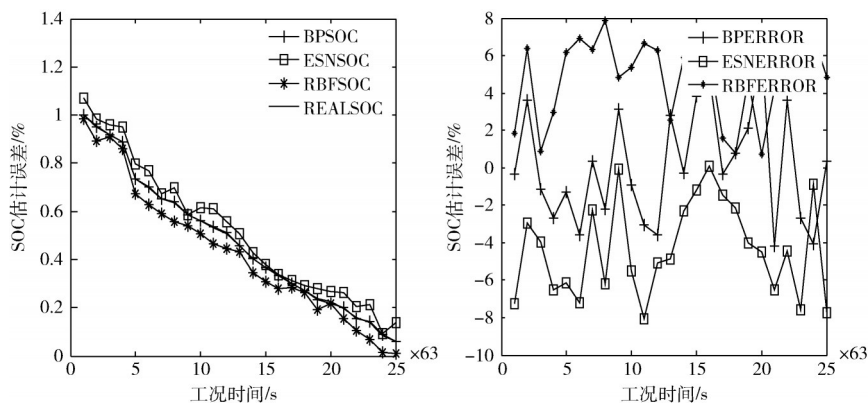


图 5 479 组数据训练的 SOC 预测结果和误差

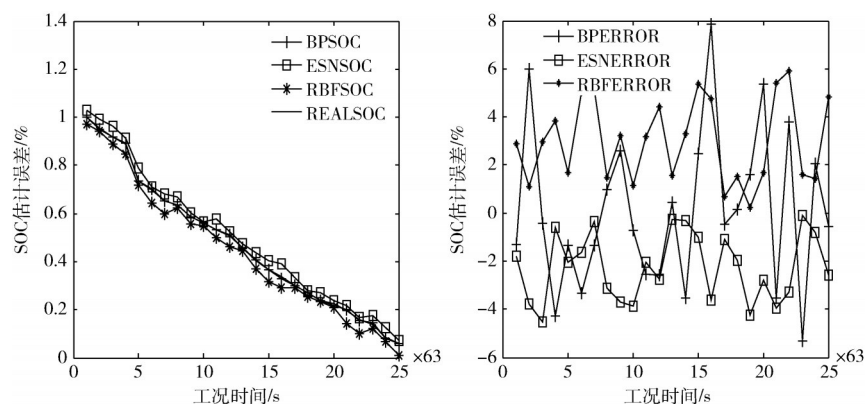


图 6 639 组数据训练的 SOC 预测结果和误差




图 7 700 组数据训练的 SOC 预测结果和误差

表3 ESN、BP和RBF算法预测性能对比

算法	训练/测试	Max error	NRMSE	时间/s
ESN		0.078 6	0.043 3	1.259 4
BP	479/1 119	0.061 7	0.042	1.789 5
RBF		0.080 0	0.054 6	1.671 5
ESN		0.059 0	0.032 5	1.354 8
BP	639/959	0.079 8	0.051 2	1.593 3
RBF		0.059 9	0.061 9	1.548 6
ESN		0.048 2	0.031 3	0.794 7
BP	700/898	0.076 3	0.087 4	1.854 2
RBF		0.046 9	0.039 5	1.468 5

如图5~图7和表3所示,当使用479组数据进行训练时,ESN算法和RBF算法预测精度约控制在8%以内,且误差波动幅度大;BP算法误差约控制在6%以内,误差波动较为明显;3种算法预测精度偏低,主要原因在于网络学习数据不充分导致网络泛化能力不强。对比3种算法的预测时间可以发现ESN的预测时间最短,为1.259 4 s;如图6所示,当训练数据为639组时,ESN算法的精度在6%以内,BP算法精度在8%以内,RBF算法误差在5%以内,随着训练数据的增加,ESN算法和RBF算法在误差上相比479组训练集的结果有一定的改善,但随着训练数据的增加,网络预测时间也有一定的增加;如图7所示,当训练数据为700组时,ESN网络预测最大误差Max error为0.048 2,标准均方根误差NRMSE为0.031 3,相比前两次训练预测的结果,算法在预测精度上有提升。在预测时间上,ESN算法和RBF算法分别为0.794 7 s和1.468 5 s,相比训练数据集为479组和639组得到的预测结果,ESN算法预测时间和RBF算法预测时间随着网络训练数据的增加在预测速度上无明显的改进。BP算法在预测精度上和预测时间无明显的改善,且BP网络误差呈现出波动幅度过大,多个时间点出现较大的预测偏差,最大误差达到0.076 3。因此BP算法在预测精度

和预测效率上相对于ESN算法和RBF算法而言较低。综合以上分析,在UDDS工况下,ESN算法性能优于BP算法,ESN在网络预测精度上优势明显,预测效率高。

为进一步分析所建立回声状态网络模型用来预测SOC的特性优势,将回声状态网络模型ESN、BP算法和径向基RBF网络算法分别在UDDS、US06和NYCC 3种工况下进行预测,得到的结果分别间隔63 s、15 s和60 s取值作图,则SOC的预测结果和误差如图8~图10所示。3种工况预测性能对比如表4所示。

图8中,在UDDS工况下数据为1 598组时,ESN算法预测SOC的最大误差不超过2%,相比BP算法和RBF算法,精度更高;图9中US06工况下,工况数据为389组时,可以看出ESN算法预测SOC的误差波动幅度变化平缓,最大误差控制在4%以内;图10中,ESN网络在NYCC工况下预测误差不超过3%。因此在不同工况下,从精度上考虑,ESN算法优于BP算法和RBF算法。

在计算效率上,由表4分析可知ESN算法在UDDS、US06和NYCC工况下,ESN算法预测时间分别为0.691 9 s、0.354 6 s和1.233 5 s,预测时间比BP算法和RBF算法短,这主要是由于ESN模型计算量小,只需计算输出权值矩阵,其他矩阵在网络初始化后固定不变。

在网络泛化能力上,ESN在3种不同工况下,SOC预测误差波动较稳定,预测精度较高,且在不同的训练数据下也呈现出相对稳定的预测精度。BP算法在不同工况下预测SOC,初始数据样本越少,网络预测误差波动越大,在US06工况下,网络最大误差达到0.117 2。因此,BP算法存在预测性能差、泛化能力弱以及对样本数据依赖性强等缺陷。RBF算法在3种工况下预测时间最长,预测SOC精度相比ESN算法低,网络预测SOC值和实际SOC值之间的误差在多个时间点出现比较高的误差,在不同工况下预测SOC,RBF算法呈现出的较弱的泛化能力,因此ESN算法性能优于RBF算法。




图8 UDDS工况的SOC预测结果和误差

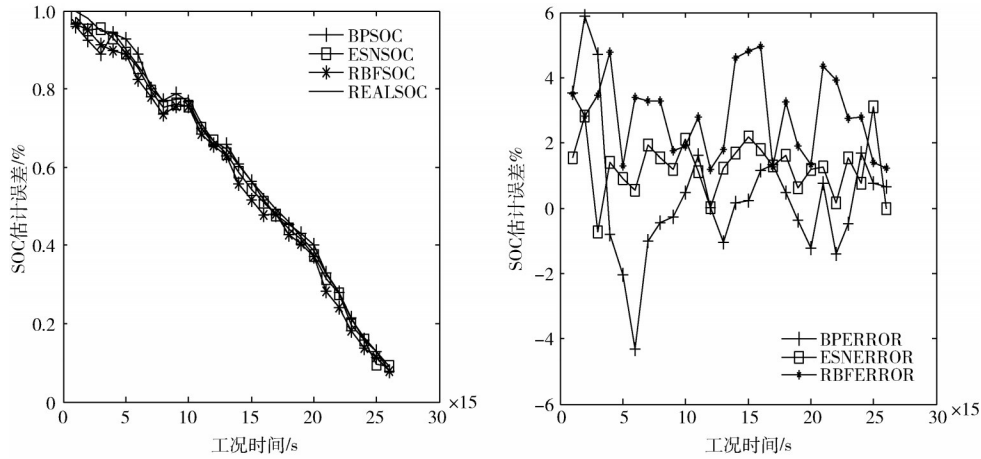


图9 US06工况的SOC预测结果和误差

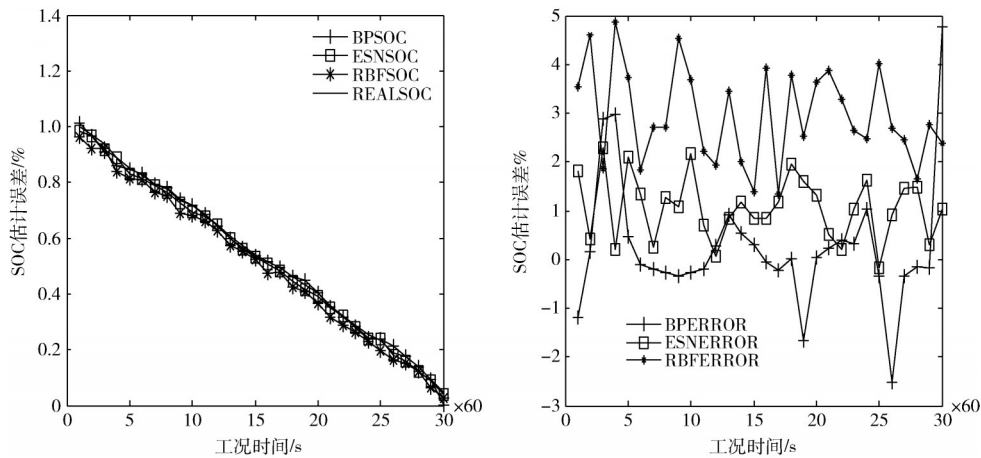


图10 NYCC工况的SOC预测结果和误差

表4 3种工况预测性能对比

工况	算法	Max error	NRMSE	时间/s
UDDS	ESN	0.001 8	0.005 1	0.691 9
	BP	0.049 3	0.067 1	1.154 2
	RBF	0.049 9	0.007 9	1.768 5
US06	ESN	0.031 0	0.012 9	0.354 6
	BP	0.117 2	0.023 0	0.422 9
	RBF	0.049 9	0.032 0	0.476 9
NYCC	ESN	0.029 4	0.013 0	1.233 5
	BP	0.081 1	0.019 7	2.168 1
	RBF	0.067 3	0.004 6	2.825 4

4 结论

研究表明,所建立的回声状态网络模型预测锂离子电池SOC在效率和预测精度上优于BP算法和RBF算法,为研究电池SOC的预测领域提供了一种可行的方法。

回声状态网络(ESN)预测电池SOC具有预测精度高、计算量小、网络预测速度快等优点,克服了传统神经网络隐层节点难以确定和计算量大等缺陷,得到了良好

的仿真预测效果,验证了该模型的可行性,具有良好的应用前景。随着历史数据的积累和仿真手段的创新,预测电池SOC的精度将不断提高,也会有越来越多的模型创建出来,将作为后续研究的努力方向。

参考文献

- [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, 22(8): 155-160.
- [2] CHAN C C. The state of the art of electric and hybrid vehicles[J]. Proceedings of the IEEE, 2002, 90(2):247-275.
- [3] 王琪,孙玉坤,倪福银,等. 一种混合动力电动汽车电池荷电状态预测的新方法[J]. 电工技术学报, 2016, 31(9): 189-196.
- [4] GAO L, LIU S, DOUGAI R. Dynamic lithium-ion battery model for system simulation[J]. IEEE Transactions on Components & Packaging Technologies, 2002, 25(3): 495-505.
- [5] 于海芳,逯仁贵,朱春波,等. 基于安时法的镍氢电池SOC估计误差校正[J]. 电工技术学报, 2012, 27(6): 12-18.
- [6] 邓晔,胡越黎,滕华强. 锂电池开路电压的预估及SOC估

- 算[J]. 仪表技术,2015(2):21-24.
- [7] 裴锋,黄向东,罗玉涛,等. 电动汽车动力电池变流放电特性与荷电状态实时估计[J]. 中国电机工程学报,2005(9):164-168.
- [8] 朱小平,张涛. 基于自适应理论的锂离子电池SOC估计[J]. 电气技术,2013(7):47-50.
- [9] CHIANG Y H, SEAN W Y, KE J C. Online estimation of internal resistance and open-circuit voltage of lithium-ion batteries in electric vehicles[J]. Journal of Power Sources, 2011, 196(8):3921-3932.
- [10] 孙朝晖,成晓潇,陈冬冬,等. 计及非线性容量效应的锂离子电池混合等效电路模型[J]. 电工技术学报,2016,31(15):156-162.
- [11] 赵天意,彭喜元,彭宇,等. 改进卡尔曼滤波的融合型锂离子电池SOC估计方法[J]. 仪器仪表学报,2016,37(7):1441-1448.
- [12] 刘树林,崔纳新,李岩,等. 基于分数阶理论的车用锂离子电池建模及荷电状态估计[J]. 电工技术学报,2017,32(4):189-195.
- [13] 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.
- [14] 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.
- [15] 封进. BP神经网络预估锂离子电池SOC训练数据选择[J]. 电源技术,2016,40(2):283-286.
- (收稿日期:2022-06-04)

作者简介:

杜广波(1976-),通信作者,男,硕士,高级工程师,主要研究方向:智能化电器、电力工程设计,E-mail:dugb@china-cuc.com。

蔡茂(1993-),男,硕士,主要研究方向:智能化电器。

张鑫(1976-),女,硕士,讲师,主要研究方向:智能化电器。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所