

基于 PSO-ELM 的储能锂电池荷电状态估算

缪家森^{1,3}, 成丽珉³, 吕宏水^{1,2}

(1. 南瑞集团(国网电力科学研究院)有限公司, 江苏 南京 211106;

2. 国电南瑞科技股份有限公司, 江苏 南京 211106;

3. 南京师范大学南瑞电气与自动化学院, 江苏 南京 210042)

摘要:对锂离子电池荷电状态(SOC)进行准确估算是保证电池管理系统安全稳定运行的关键。常用的安时积分法存在累积误差,卡尔曼滤波算法需要建立精确的电池模型,神经网络不依赖具体的锂电池模型,能够反映锂电池的非线性关系,因而受到广泛关注,然而传统神经网络估算SOC训练时间长、精度低。针对以往电池SOC估算精度低等问题,文中提出粒子群(PSO)优化极限学习机(ELM)神经网络的方法。以电池电压、电流和温度作为PSO-ELM模型的输入向量,以SOC作为输出向量。将实验获得的数据导入模型进行训练和测试,采用PSO对ELM随机给定的输入权值和隐含层阈值进行寻优。仿真结果表明,与BP神经网络的预测结果相比,文中估算SOC的方法具有更高的精度。

关键词:储能电池;荷电状态估算;粒子群优化算法;极限学习机

中图分类号:TM727;TP183

文献标志码:A

文章编号:2096-3203(2020)01-0165-05

0 引言

近年来,环境保护、节能减排得到了社会各界的重视,各国对风能、太阳能等绿色能源的投入力度加大,使得新能源发电在电力系统中的渗透率不断提高^[1-3]。然而新能源发电的功率输出存在随机性、波动性^[4],分布式储能单元的引入使得新能源发电对电网稳定性的影响问题得到了解决^[5]。在各种储能方式中,以磷酸铁锂电池为主的储能系统最具发展前景^[6]。为了提高电池使用寿命、保证储能系统的安全运行,需要对储能系统配备电池管理系统(battery management system, BMS)。

对电池荷电状态(state of charge, SOC)进行估算是BMS的关键技术之一^[7]。SOC表示电池剩余容量与电池实际总容量的比值^[8],受电池的温度、充放电倍率、自放电率、电池老化等多种因素的影响。SOC估算方法有开路电压法(open circuit voltage, OCV)、安时积分法、内阻法、卡尔曼滤波法等,近年来又出现了神经网络法、支持向量机法^[9-11]。

神经网络法估算SOC不依赖具体的电池模型,具有较强的非线性,能够模拟电池的动态特性^[12]。但是对于小样本数据,神经网络泛化能力差,只能获得次优解。与传统神经网络法相比,极限学习机

(extreme learning machine, ELM)具有结构简单、学习时间短、参数易整定、不易陷入局部最优等优点^[13-14]。由于ELM初始化参数生成方式的随机性导致模型隐含层神经元冗余、对未知输入参数识别能力差,进而造成预测值与真实值偏差较大^[15-16]。

基于以上问题,文中建立基于粒子群(particle swarm optimization, PSO)优化ELM的SOC估算模型,利用PSO对ELM的输入层权值和隐含层阈值进行迭代寻优,通过改善ELM随机参数的产生过程提高SOC估算精度。

1 ELM网络结构模型

ELM是由南洋理工大学的黄广斌教授等人于2004年提出的一种单隐层前馈神经网络算法模型,其网络结构如图1所示。ELM网络由输入层、隐含层和输出层构成,各层之间的连接方式为全连接。 n, k 和 m 分别为输入层、隐含层以及输出层神经元的个数。




图1 ELM网络结构

Fig.1 Structure of ELM network

收稿日期:2019-07-21;修回日期:2019-09-05

基金项目:国家重点研发计划资助项目“面向新型城镇的能源互联网关键技术及应用”(2018YFB0905000)

假设有 N 个不同的样本数据集:

$$E = \{(\mathbf{x}_p, \mathbf{y}_p) \mid p = 1, 2, \dots, N, \mathbf{x}_p \in \mathbf{R}^n, \mathbf{y}_p \in \mathbf{R}^m\} \quad (1)$$

式中: $\mathbf{x}_p \in \mathbf{R}^n$, 为 n 维输入向量; $\mathbf{y}_p \in \mathbf{R}^m$, 为对应的输出目标向量。若 ELM 隐含层的神经元数目为 k , 那么当输入样本为 \mathbf{x}_p 时, ELM 对应的实际输出可表示为:

$$\mathbf{Y} = \sum_{i=1}^k \beta_i g(\omega_i \cdot \mathbf{x}_i + b_i) \quad i = 1, 2, \dots, N \quad (2)$$

式中: $\omega_i = (\omega_{i1}, \omega_{i2}, \dots, \omega_{in})$ 为第 i 个隐含层神经元与输入层对应单元的连接权值; b_i 为第 i 个隐含层神经元阈值; $g(\cdot)$ 为激活函数; $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{im})^T$, 为第 i 个隐含层神经元对应于输出层单元的连接权值。

训练 ELM 网络旨在求解隐含层神经元对应于输出层单元的连接权值。当激活函数 $g(x)$ 无限可微时, ELM 的输出可表示为:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{Y}' \quad (3)$$

式中: $\mathbf{Y}' = (y_1, y_2, \dots, y_N)$, 为一个由 N 个方程构成的线性方程组; $\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_k)^T$, 为输出权值矩阵; \mathbf{H} 为隐含层的输出矩阵, 用式(4)表示。

$$\mathbf{H} = \begin{pmatrix} g(\omega_1 \cdot \mathbf{x}_1 + b_1) & \cdots & g(\omega_k \cdot \mathbf{x}_1 + b_k) \\ \vdots & & \vdots \\ g(\omega_1 \cdot \mathbf{x}_N + b_1) & \cdots & g(\omega_k \cdot \mathbf{x}_N + b_k) \end{pmatrix} \quad (4)$$

一般情况下, 为了提高 ELM 的泛化能力, 隐含层矩阵 \mathbf{H} 中神经元的个数要远小于训练的样本个数, 即隐含层矩阵 \mathbf{H} 不是方阵, 从而使得误差可以趋近于一个极小值, 但不会出现零误差的情况。因此, 利用 \mathbf{H} 的广义逆矩阵 \mathbf{H}^+ 来求解 $\mathbf{H}\boldsymbol{\beta} = \mathbf{Y}'$ 的最小二乘解可以表示为:

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{Y}' \quad (5)$$

由于 ELM 隐含层的输入权值以及隐含层神经元的阈值具有随机产生的特点, 只需要设置隐含层神经元的个数, 便可以利用 ELM 算法获取较好的输出结果。

2 PSO-ELM 估算模型的建立

由于 ELM 初始化参数生成方式的随机性导致模型不可避免地产生了隐含层神经元冗余、对未知输入参数识别能力差等问题, 从而降低了预测精度。因此本节利用 PSO 算法对 ELM 的输入权值和隐含层神经元的阈值进行寻优, 建立 PSO-ELM 模型以提高 SOC 估算精度。

PSO 算法起源于对鸟群、鱼群捕食行为的研究, 其本质是基于粒子群中的个体对信息的共享特

性来获得问题的最优解^[17]。

假设在一个 D 维空间中, 每个粒子 s 可表示为 $\mathbf{X}_s = (x_{s1}, x_{s2}, \dots, x_{sD})$, 将 \mathbf{X}_s 通过迭代可以找到最优解。在每次迭代中, 其第 d 维 ($1 \leq d \leq D$) 空间根据式(6)、式(7)变化。个体极值为 $\mathbf{P}_s = (p_{s1}, p_{s2}, \dots, p_{sD})$, 群体极值为 $\mathbf{P}_g = (p_{g1}, p_{g2}, \dots, p_{gD})$, 个体的速度为 $\mathbf{V}_s = (v_{s1}, v_{s2}, \dots, v_{sD})$ 。

$$v_{sd}^{t+1} = \omega_0 v_{sd}^t + r_1 c_1 (P_{sd}^t - x_{sd}^t) + r_2 c_2 (P_{gd}^t - x_{sd}^t) \quad (6)$$

$$x_{sd}^{t+1} = x_{sd}^t + v_{sd}^{t+1} \quad (7)$$

式中: ω_0 为惯性权重; v_{sd}^t 为第 s 个粒子迭代 t 次时的速度; x_{sd}^t 为第 s 个粒子迭代 t 次时的位置; c_1, c_2 为学习因子; r_1, r_2 为区间 $[0, 1]$ 内的随机数。粒子的位置和速度限制在 $[-X_{\max}, X_{\max}]$ 、 $[-V_{\max}, V_{\max}]$ 以防止粒子的盲目搜索。

式(6)右边分别为个体先前的速度, 它维持算法拓展搜索空间的能力; 自身寻优部分, 表示个体自身的进化, 以防止算法陷入局部最优; 种群寻优部分, 表示个体间的信息共享。PSO 算法既避免陷入局部最优解, 又减少了计算量, 加快了收敛速度。

文中 SOC 估算流程如图 2 所示。

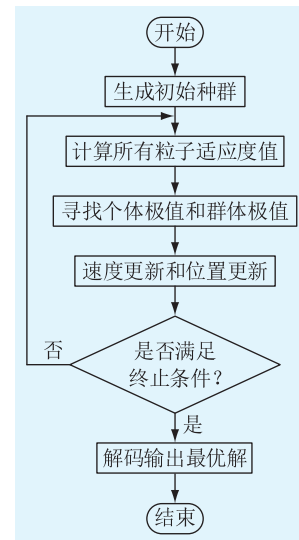


图 2 基于 PSO-ELM 的 SOC 估算流程

Fig.2 Flow chart of SOC estimation based on PSO-ELM

具体步骤如下:

(1) 将 ELM 网络的输入权值和隐含层神经元的阈值编码为粒子, 生成初始种群并初始化;

(2) 计算所有粒子的适应度值, 选用网络的均方误差 (mean squared error, MSE) 作为目标函数计算 PSO 的适应度值, 其表达式为:

$$S_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (T(i) - Y(i))^2 \quad (8)$$

式中： N 为样本总数； T 为每个粒子对应的预测输出； Y 为样本的实际输出。

(3) 根据初始粒子的适应度值寻找初始个体极值和群体极值；

(4) 迭代优化,更新粒子的位置和速度,得到新粒子；

(5) 判断是否满足终止条件($S_{MSE} \leq 0.0001$ 或达到最大迭代次数)。如果满足则退出并返回最优个体;否则跳转至第(2)步继续执行；

(6) 迭代优化结束,解码输出最优解。

文中采用图 3 所示模型对 SOC 进行估算,模型的输入量为电压、电流、温度,输出量为 SOC。网络的隐含层激活函数选用 S 型的对数函数 Sigmoid,其表达式为:

$$g(x) = \frac{1}{1 + e^{-x}} \quad (9)$$




图 3 PSO-ELM 神经网络预测模型结构

Fig.3 Structure of PSO-ELM neural network prediction model

为了使输入量起到较强的作用,在选用 Sigmoid 函数时必须对网络的输入量进行归一化处理。进行归一化处理能使所有分量都在 $[-1, 1]$ 区间内变化,可以加快网络学习速度,有效避免网络无法收敛的情况。文中采用 Premnmx 函数对模型输入数据进行归一化和输出数据反归一化处理。

数据处理完毕后,就可以对建立的 PSO-ELM 模型进行训练。综合考虑隐含层节点数和迭代次数对 PSO-ELM 的影响,最终模型的隐层节点数目设置为 30,迭代次数设置为 100。

3 仿真实验

3.1 实验数据的采集

受锂电池充放电滞回特性的影响,在对锂电池进行试验获取神经网络的训练样本时需要进行充电与放电实验。

首先,在室温 $20\text{ }^{\circ}\text{C}$ 的条件下,将磷酸铁锂电池充至满电状态,恒温静置 60 min,然后以 6 A 恒流放电至截止电压,充电过程与此相反。电池充放电测试仪每 1 s 采样一次原始数据,上位机通过 CAN 总线每 1 s 读取一次电池电压、电流数据,SOC 可以通过安时积分法计算获得。 $20\text{ }^{\circ}\text{C}$ 下电池 6 A 恒流充

放电所得的部分数据如表 1 所示。接着改变环境温度,在 $-5\text{ }^{\circ}\text{C}$, $5\text{ }^{\circ}\text{C}$, $15\text{ }^{\circ}\text{C}$, $25\text{ }^{\circ}\text{C}$, $35\text{ }^{\circ}\text{C}$, $45\text{ }^{\circ}\text{C}$ 下进行相同的充放电测试实验。不同环境温度下电池 SOC-OCV 曲线如图 4 所示。

表 1 电池充放电实验数据

Table 1 Battery charge and discharge experimental data

充电电流/mA	电压/V	荷电状态/%	放电电流/mA	电压/V	荷电状态/%
5 997	2.700	0	-5 997	3.343	100
5 997	3.160	10	-5 997	3.29	90
5 997	3.280	20	-5 997	3.28	80
5 997	3.340	30	-5 997	3.27	70
5 996	3.350	40	-5 997	3.25	60
5 997	3.356	50	-5 996	3.246	50
5 997	3.368	60	-5 996	3.236	40
5 996	3.390	70	-5 997	3.22	30
5 997	3.394	80	-5 997	3.18	20
5 997	3.410	90	-5 997	3.12	10
2 315	3.620	100	-5 997	2.5	0




图 4 电池不同温度 SOC-OCV 曲线

Fig.4 Battery SOC-OCV curves under different temperatures

测试完毕后,在以上 6 组不同温度的实验结果中按时序各取出 400 组样本数据,将获得的 2 400 组数据分为奇偶 2 组,其中奇数组数据作为网络的训练样本,对 PSO-ELM 网络进行训练。按时序随机选取 $20\text{ }^{\circ}\text{C}$ 下对电池恒流放电的 60 组实验数据作为网络的测试样本,用来检验该网络的估算精度和泛化性能。

3.2 仿真结果

对建立的 PSO-ELM 模型进行训练得到的适应度曲线如图 5 所示,经过 52 次迭代,PSO-ELM 模型的训练误差达到了期望目标。

采用相同的训练样本对 BP 神经网络进行训练,训练函数为 trainlm 函数,训练次数设为 50 次,




图5 算法最优适应度曲线

Fig.5 Optimal fitness curves

训练目标设为 0.000 1,当训练到第 12 次时,误差达到了目标值以下。

采用样本数据对模型训练之后,选取网络的测试样本对所训练的 PSO-ELM 模型进行检验。将 BP 神经网络的预测结果与文中建立的模型进行对比实验,实验结果如图 6 所示。

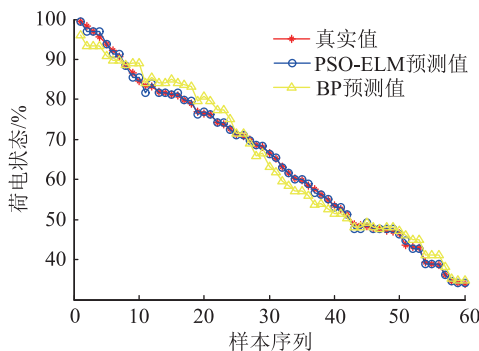


图6 SOC估算结果对比

Fig.6 Comparison of SOC estimation result

由图 6 可知,训练以后的 PSO-ELM 神经网络与 BP 神经网络都表现出良好的跟随性,在部分样本点上,两者的预测结果很接近。但是从整体上看,文中建立的模型具有更高的估算精度,能准确预测 SOC 的变化趋势。

2 种方法预测误差曲线如图 7 所示,可以看出 PSO-ELM 模型误差在 2%以内,BP 神经网络模型的误差在 5%以内,验证了文中建立的 SOC 估算模型能够有效降低估算误差。

图 8 反映的是 PSO-ELM 模型 SOC 估算结果的相对误差和绝对误差,可以得出 PSO-ELM 估算模型的绝对误差波动较小,其最大值为 0.019 4,相对误差最大值为 0.024 8。

对 BP 神经网络、ELM、PSO-ELM 3 种模型的性能进行比较的结果如表 2 所示。

从表 2 中可以看出 BP 神经网络训练时间最长,ELM、PSO-ELM 模型训练时间接近且明显低于

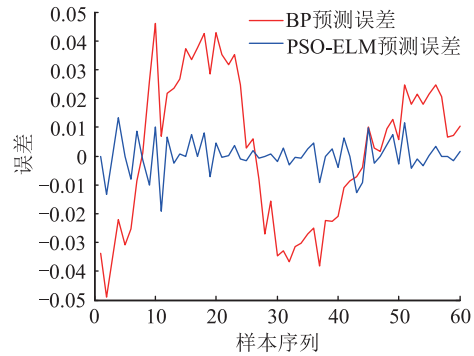


图7 SOC估算误差曲线

Fig.7 Error curves for SOC estimation




图8 模型误差曲线

Fig.8 Error curves for PSO-ELM model

表 2 模型性能比较

Table 2 Model performance comparison

模型	训练时间/s	均方根误差	最大相对误差/%
BP	5.932	0.044 8	4.91
ELM	0.023	0.017 8	4.62
PSO-ELM	0.913	0.006 0	1.83

BP 神经网络的训练时间。经过 PSO 优化后的 ELM 神经网络,即文中建立的 PSO-ELM 模型能使误差明显降低,整体性能在 3 种模型中是最好的。

实际储能 BMS 分为从控、主控、总控三层架构。从控对锂电池电压、电流、温度等不同种类数据进行实时采集与分析,通过 CAN 总线与主控进行通讯。同时,从控以主控下发的 SOC 估算值作为锂电池组均衡依据,完成制定的均衡策略,以改善电池组的不一致性。准确的 SOC 估算是提高储能系统的安全性和使用寿命的关键。文中方法在减小 SOC 估算误差上取得了明显的效果,满足 BMS 技术规范对 SOC 估算误差的要求。

4 结语

针对储能锂电池具有较强的非线性这一特点,文中采用神经网络法对 SOC 估算,提出 PSO-ELM 神经网络估算 SOC 的方法。在分析 SOC 影响因素

基础上,以电压、电流和温度作为网络输入,利用 PSO 对 ELM 的输入权值和隐含层神经元阈值进行迭代寻优。最后将 PSO-ELM 网络的测试结果与 BP 神经网络进行对比。通过仿真实验,得到以下结论:

(1) 在参数寻优过程中 PSO 算法能快速收敛,在同等条件下,文中提出的方法对锂电池 SOC 的估算值更准确;

(2) 在实际应用中,可由计算机将建立的 PSO-ELM 模型在离线状态下计算出电池组 SOC 值,将结果存到可编程处理器的 Flash 中,由 BMS 在线调用、定期校正安时积分法的 SOC 估算值,为 BMS 安全稳定运行提供保证。


参考文献:

- [1] 白建华,辛颂旭,刘俊,等. 中国实现高比例可再生能源发展路径研究[J]. 中国电机工程学报,2015,35(14):3699-3705.
BAI Jianhua, XIN Songxu, LIU Jun, et al. Roadmap of realizing the high penetration renewable energy in China[J]. Proceedings of the CSEE, 2015, 35(14): 3699-3705.
- [2] 王成山,王守相. 分布式发电供电系统若干问题研究[J]. 电力系统自动化,2008,32(20):1-4.
WANG Chengshan, WANG Shouxiang. Study on some key problems related to distributed generation systems[J]. Automation of Electric Power Systems, 2008, 32(20): 1-4.
- [3] 张翼. 电力储能技术发展和应用[J]. 江苏电机工程,2012,31(4):81-84.
ZHANG Yi. The development and application of energy storage technology[J]. Jiangsu Electrical Engineering, 2012, 31(4): 81-84.
- [4] GE F, XIE T, XU H H, et al. An uncertainty reduction strategy to schedule and operate microgrids with renewable energy sources[C]//Asia-Pacific Power and Energy Engineering Conference, Xi'an, 2016.
- [5] 李蓓,郭剑波. 平抑风电功率的电池储能系统控制策略[J]. 电网技术,2012,36(8):38-43.
LI Bei, GUO Jianbo. A control strategy for battery energy storage system to level wind power output[J]. Power System Technology, 2012, 36(8): 38-43.
- [6] 丁明,陈忠,苏建徽,等. 可再生能源发电中的电池储能系统综述[J]. 电力系统自动化,2013,37(1):19-25.
DING Ming, CHEN Zhong, SU Jianhui, et al. An overview of battery energy storage system for renewable energy generation[J]. Automation of Electric Power Systems, 2013, 37(1): 19-25.
- [7] HANNAN M A, LIPU M S H, HUSSAIN, et al. A review of lithium ion battery state of charge estimation and management system in electric vehicle application; challenges and recommendations[J]. Renewable and Sustainable Energy Reviews, 2017, 78:834-854.
- [8] WANG P J, LI K P, ZHANG H. PMGA and its application in area and power optimization for ternary FPRM circuit[J].

Journal of Semiconductors, 2016, 37(1):7-15.

- [9] YAN Q Y, WANG Y N. Predicting for power battery SOC based on neural network[C]//2017 36th Chinese Control Conference (CCC), 2017.
- [10] 杨孝敬,钟宁. 基于神经网络的动力电池 SOC 研究[J]. 电源技术,2016,40(12):2415-2416,2438.
YANG Xiaojing, ZHONG Ning. Research on power battery SOC based on neural network[J]. Power Technology, 2016, 40(12):2415-2416,2438.
- [11] 方志强,王晓辉,夏通. 基于长短期记忆网络的售电量预测模型研究[J]. 电力工程技术,2018,37(3):78-83.
FANG Zhiqiang, WANG Xiaohui, XIA Tong. Electricity sales forecasting based on long-short term memory networks[J]. Electric Power Engineering Technology, 2018, 37(3): 78-83.
- [12] DONG C, WANG G. Estimation of power battery SOC based on improved BP neural network[C]//IEEE International Conference on Mechatronics and Automation, 2014.
- [13] HUANG B, ZHU Q Y. Extreme learning machine theory and applications[J]. Neuro computing, 2006, 70(1):489-501.
- [14] 赵旭阳. 基于极限学习机的人脸识别[J]. 电子技术与软件工程,2018(6):108.
ZHAO Xuyang. Face recognition based on extreme learning machine[J]. Electronic Technology and Software Engineering, 2018(6):108.
- [15] 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,2013,45(1):100-104.
WANG Jie, BI Haoyang. An extreme learning machine based on particle swarm optimization[J]. Journal of Zhengzhou University, 2013, 45(1): 100-104.
- [16] 赵钢,朱芳欣,窦汝振. 基于 PSO-BP 的电动汽车锂离子电池 SOC 估算[J]. 电源技术,2018,42(9):1318-1320.
ZHAO Gang, ZHU Fangxin, DOU Ruzhen. SOC estimation of lithium battery for electric vehicle based on PSO-BP neural network[J]. Power Technology, 2018, 42(9): 1318-1320.
- [17] 张任,胥芳,陈教料,等. 基于 PSO-RBF 神经网络的锂离子电池健康状态预测[J]. 中国机械工程,2016,27(21):2975-2981.
ZHANG Ren, XU Fang, CHEN Jiaoliao, et al. Prediction of health status of lithium ion battery based on PSO-RBF neural network[J]. China Mechanical Engineering, 2016, 27(21): 2975-2981.

作者简介:



缪家森

缪家森(1993),男,硕士在读,研究方向为储能电池管理系统(E-mail:605836211@qq.com);

成丽珉(1994),女,硕士在读,研究方向为电力系统负荷预测、电力需求响应、电力市场;

吕宏水(1969),男,硕士,高级工程师,从事风力发电、太阳能发电等专业领域的科研开发相关工作。

(下转第 199 页)

Comprehensive charging demand of multi-type electric vehicles based on traffic information

LI Linwei, NING Guangtao, YU Yue, CHEN Mingfan, CHEN Yida, HE Lipeng
(Hainan Power Grid Co., Ltd., Haikou 570203, China)

Abstract: In order to prevent the impact of electric vehicles' charging uncertainty on the distribution network, a joint modeling method for charging demand considering large-scale and multi-type electric vehicle access is proposed based on dynamic traffic information. This paper starts from the characteristics of electric vehicles as forms of transportation, combining the driving characteristics of different types of electric vehicles with traffic information, and establishes the corresponding operation spatio-temporal model. Considering the two modes of fast charging and slow charging, this paper studies the charging behavior of various electric vehicles, in order to construct corresponding charging demand models. Combined with the user's daily mileage, the basic operation cycle is proposed, and the Monte Carlo simulation method is used to calculate the distribution of the comprehensive charging demand of multiple types of electric vehicles under different working days. The simulation results verify the feasibility of the modeling method and show that the access of multiple types of electric vehicles will bring multiple peaks of power demand to the distribution network as a whole.

Keywords: traffic information; electric vehicle; charging demand; Monte Carlo simulation method

(编辑 陈静)

(上接第 169 页)

Estimation of state of charge of energy storage lithium battery based on PSO-ELM

MIAO Jiasen^{1,3}, CHENG Limin³, LYU Hongshui^{1,2}

(1. NARI Group(State Grid Electric Power Research Institute) Co., Ltd., Nanjing 211106, China;

2. NARI Technology Co., Ltd., Nanjing 211106, China;

3. NARI School of Electrical Engineering and Automation, Nanjing Normal University, Nanjing 210042, China)

Abstract: Accurate estimation of lithium ion battery state of charge (SOC) is the key to ensure safe and stable operation of battery management system. The commonly used ampere-hour integral method has cumulative errors. And the Kalman filter algorithm needs to establish an accurate battery model. The neural network method does not rely on a specific lithium battery model and can reflect the nonlinear relationship of lithium batteries, and thus has received extensive attention. However, traditional neural network has long training time and low precision when estimating SOC. For the low accuracy of SOC estimation in the past, the particle swarm optimization (PSO) of extreme learning machine (ELM) neural network method is proposed. In the PSO-ELM model, voltage, current and temperature are used as input vector and the value of SOC is used as output vector. The experimental data is imported into the model for training and testing, and the input weight matrix and hidden layer threshold of ELM are optimized by PSO. In addition, the simulation results show that compared with the prediction results of BP neural network, the method of estimating SOC in this paper has higher precision.

Keywords: energy storage battery; state of charge estimation; particle swarm optimization algorithm; extreme learning machine

(编辑 陈静)