

基于置信规则库的锂电池 SOC 估计

吕延卓¹, 肖明清², 唐希浪¹, 李剑峰¹, 刘 强¹, 王联科²

(1. 空军工程大学研究生院, 西安, 710051; 2. 空军工程大学航空工程学院, 西安, 710038)

摘要 电池荷电状态(SOC)的准确估计在电池广泛应用的背景下日益重要,但是构建精确的物理模型十分困难,使用纯粹的数据驱动方法又容易因为电池个体差异性出现过拟合问题。针对这些问题,提出基于置信规则库(BRB)的方法对锂电池 SOC 的进行估计。该方法既允许专家通过经验知识克服数据驱动方法的过拟合问题,又能通过参数训练克服专家知识的不准确性。以某型磷酸铁锂(LiFePO₄)电池为例,对提出的方法进行了验证,并将其与神经网络进行了对比。结果表明,该方法估计 SOC 具有较高的精度,估计误差不超过 10%,且可以克服传统神经网络方法存在的过拟合问题。

关键词 锂电池;电池荷电状态估计;置信规则库

DOI 10.3969/j.issn.1009-3516.2019.04.006

中图分类号 TM912 **文献标志码** A **文章编号** 1009-3516(2019)04-0039-07

SOC Estimation of Lithium Battery Based on Belief Rule Base

LYU Yanzhuo¹, XIAO Mingqing², TANG Xilang¹, LI Jianfeng¹, LIU Qiang¹, WANG Lianke²

(1. Graduate School, Air Force Engineering University, Xi'an 710051, China;

2. Aeronautics Engineering College, Air Force Engineering University, Xi'an 710038, China)

Abstract: The accurate estimation of the state of charge (SOC) of a battery is increasingly important in the context of the wide application of batteries. However, it is difficult to build accurate physical models, and the use of pure data-driven methods is prone to overfitting problems due to individual differences of batteries. To solve these problems, propose a method based on belief rule base (BRB) to estimate SOC of lithium battery. This method allows experts to overcome the overfitting problem of data-driven methods through empirical knowledge and the inaccuracy of expert knowledge through parameter training. A lithium iron phosphate (LiFePO₄) battery is taken as an example to verify the proposed method, and the results are compared with those of the neural network. The results show that this method has high accuracy in SOC estimation, the estimated error is not more than 10%, and can overcome the overfitting problem of traditional neural network methods.

Key words: Lithium battery; SOC estimation; belief rule base

锂电池具有使用寿命长、安全性能好、比能量和比功率较高等优点,在对储能电池的电性能、可靠性、安全性要求较高的航空航天^[1]、特种加工^[2-3]、军事装备^[4]等领域有较为广泛的运用。

收稿日期: 2019-04-05

作者简介: 吕延卓(1994—),男,黑龙江佳木斯人,硕士生,主要从事航空武器装备故障诊断研究。E-mail:2636778922@qq.com

引用格式: 吕延卓, 肖明清, 唐希浪, 等. 基于置信规则库的锂电池 SOC 估计[J]. 空军工程大学学报(自然科学版), 2019, 20(4): 39-45.
LYU Yanzhuo, XIAO Mingqing, TANG Xilang, et al. SOC Estimation of Lithium Battery Based on Belief Rule Base[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(4): 39-45.

电池荷电状态(State of Charge, SOC)的准确估计能够在电池的使用过程中为操作人员提供可信的电池续航参考^[5]、避免过充或过放对电池造成损害^[6],对维持电池的良好性能、延长电池使用寿命、保证所在系统的良好健康状态具有重要意义^[7]。

电池 SOC 无法直接测量,只能根据电池特性,测量充放电过程中的电池端电压、电流、温度等数据,结合相应算法,计算得到 SOC 的估计值^[8]。目前, SOC 估计的主要方法包括:安时计量法^[9]、开路电压法^[10]、内阻法^[11]、卡尔曼滤波法^[12-13]、神经网络法^[14]等。其中,安时计量法原理简单、操作方便,但其精度受电流测量精度及 SOC 初始值影响较大,且存在累计误差;开路电压法简便易行,但对“SOC-开路电压”关系的测量准确度要求较高,且需要较长的电池静止时间,不适合用于实时 SOC 估计;内阻法在估计 SOC 极值时精度较高,但电池交流阻抗受电池温度、静置时间等因素影响较大,与 SOC 关系不稳定;卡尔曼滤波法误差纠正能力较为出色,但对电池模型的准确性及系统处理速度的要求较高。

值得关注的是,神经网络算法具有非线性、自学习等特点,广泛应用于各个领域^[15-18],可以避免复杂的建模过程。但是在电池 SOC 估计领域的应用中,神经网络将电池看做黑箱,网络的训练对电池历史数据的数量和质量依赖性较强。同时,在既有的工艺水平下,锂电池在制造中不可避免地存在不一致^[19]的问题。在经某一电池的实验数据训练后,神经网络往往会因为自身存在的过拟合问题而出现对训练数据的拟合效果较好而对同型号不同个体的电池的 SOC 估计效果较差的问题。此外,在采集训练数据的过程中难免存在测量误差,导致训练数据中夹杂噪声,这将进一步加剧神经网络算法的过拟合问题,对电池 SOC 的估计造成较大偏差甚至是明显的错误。

针对上述问题,本文提出利用基于证据推理的置信规则库(Belief Rule Base, BRB)推理方法^[20]进行锂电池 SOC 估计。该方法能够综合利用主、客观信息且可调参数物理意义明确^[21],是专家知识及数据驱动方法的结合。置信规则库能够通过参数优化减少专家知识中存在的主观偏差的影响,同时它在专家知识的基础上进行数据训练,是对其中专家设定的参数进行调整而非直接生成。另外,其约束条件的设定及推理过程的设计能够将结果约束在合乎专家对事物的认知的合理范围内。因此该方法能够在保证精度的同时避免过拟合问题,适用于锂电池 SOC 估计问题。

本文首先简单介绍了 BRB 的相关知识,然后以

LiFePO₄ 电池为例进行放电特性分析,在此基础上选取置信规则库的输入输出并根据专家知识构建置信规则库。然后,选取同型号的 2 个 LiFePO₄ 电池分别进行放电实验,采集到的 2 组数据分别作为训练数据和测试数据。利用训练数据分别对置信规则库参数进行优化、对神经网络进行训练,最后利用测试数据对 2 种方法的效果进行验证。

1 基于证据推理的置信规则库推理方法

1.1 置信规则库结构

置信规则库规则的一般表达形式为:

$$R_k: \text{If } x_1 \text{ is } A_1^k \wedge x_2 \text{ is } A_2^k \wedge \dots \wedge x_m \text{ is } A_m^k$$

$$\text{Then } \{(D_1, \beta_{1,k}), \dots, (D_N, \beta_{N,k})\}$$

With a rule weight θ_k and attribute

weight $\delta_{1,k}, \delta_{2,k}, \dots, \delta_{M,k}$

$x_i (i=1, 2, \dots, M)$ 为第 k 条规则 R_k 中第 i 个前项属性; $A_i^k (i=1, 2, \dots, M; k=1, 2, \dots, L)$ 表示第 $k (k=1, 2, \dots, L)$ 条规则中第 i 个前提属性的参考值; M 表示第 k 条规则中的前项属性数目; L 是置信规则库中置信规则的数量; $A_i^k \in A_i, A_i = \{A_{i,j}, j=1, 2, \dots, J_i\}$ 表示第 i 个前提属性的 J_i 个参考值组成的集合; $\theta_k (k=1, 2, \dots, L)$ 表示第 k 条规则的权重,反映第 k 条规则相对于规则库中其他规则的重要度; $\delta_i (i=1, 2, \dots, M)$ 表示第 i 个前提属性的权重,反映了第 i 个前提属性相对于其他前提属性的重要度。 $\beta_{j,k} (j=1, 2, \dots, N; k=1, 2, \dots, L)$ 表示第 k 条规则中对第 j 个输出结果 D_j 的置信度。

1.2 置信规则库推理

进行置信规则库的推理首先需要计算激活权重,然后在此基础上使用证据推理算法集成激活的规则。

激活权重 ω_k 指的是根据匹配度、规则权重及属性权重计算出的规则对输入的参考程度。激活权重计算方法为:

$$\omega_k = \theta_k \prod_{i=1}^M (\alpha_i^k)^{\bar{\delta}_i} / \sum_{k=1}^L \theta_k \prod_{i=1}^M (\alpha_i^k)^{\bar{\delta}_i} \quad (1)$$

式中: $\bar{\delta}_i$ 为相对属性权重,计算方法如下:

$$\bar{\delta}_i = \delta_i / \max_{i=1, 2, \dots, M} \{\delta_i\} \quad (2)$$

式中: α_i^k 是第 k 条规则中第 i 个输入 x_i 与参考值 A_i^k 的匹配度。在得到 ω_k 后,可利用证据推理算法对被激活的规则进行融合,得到最终的置信规则库系统输出为:

$$O(X) = \{(D_j, \beta_j); j=1, 2, \dots, N\} \quad (3)$$

式中: β_j 为后项 D_j 的置信度,表达式为^[20]:

$$\beta_j = \frac{u \left[\frac{\prod_{k=1}^L (\omega_k \beta_{j,k} + 1 - \omega_k \sum_{i=1}^N \beta_{i,k})}{\prod_{k=1}^L (1 - \omega_k \sum_{i=1}^N \beta_{i,k})} \right]}{1 - u \left[\prod_{k=1}^L (1 - \omega_k) \right]} \quad (4)$$

式中: u 为效用值, 表达式为:

$$u = \left[\frac{\sum_{j=1}^N \prod_{k=1}^L (\omega_k \beta_{j,k} + 1 - \omega_k \sum_{i=1}^N \beta_{i,k})}{(N-1) \prod_{k=1}^L (1 - \omega_k \sum_{i=1}^N \beta_{i,k})} \right]^{-1} \quad (5)$$

1.3 置信规则库优化学习模型

置信规则库中的前提属性权重、规则权重、结果置信度这 3 类参数均由系统专家根据经验设定, 具有一定的主观性。为了选取置信规则库的最优参数, Yang 提出了对置信规则库参数优化的基本思想^[20]。置信规则库优化学习模型具体结构见图 1 (优化的约束条件包括: $0 \leq \theta_k \leq 1, 0 \leq \delta_k \leq 1, 0 \leq \beta_{j,k} \leq 1, \sum_{j=1}^N \beta_{j,k} = 1$)。




图 1 置信规则库优化学习模型

此外, Chen^[21] 等人研究发现, 将前项属性及后项属性的参考值纳入优化范围可获得性能更好的置信规则库, 因此, 本文将 $A_{i,j}, D_j$ 同样作为待优化参数, 添加到上述优化学习模型中。

Matlab 中的 fmincon 函数多用于求解有约束的非线性多元函数最小值, 本文利用该函数对初始置信规则库的参数进行优化。

选取实际值与系统估计输出的均方差为目标函数, 即:

$$\zeta = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (6)$$

2 基于置信规则库的 SOC 估计

本文以锂电池 SOC 估计为目标, 故选取电池 SOC 为置信规则库输出。

观察实际应用中锂电池的放电特性, 对置信规则库方法估计锂电池 SOC 所需的输入进行分析。

锂电池的放电特性曲线见图 2, 可见锂电池在恒流放电过程中初末段电压下降较为迅速, 中段放

电电压虽较为平稳, 但仍有一定的下降趋势。另一方面, 随着放电倍率的提高, 电池的放电容量和放电电压平台均有所下降。可知电流、电压与电池 SOC 变化趋势有较为明显的对应关系, 故选取电流、电压为置信规则库输入。




图 2 锂电池放电特性曲线示意图

专家知识的表达往往是以语义的形式表示的, 是模糊的、定性的, 如“电流和电压都很大, 那么 SOC 也很可能为大”。但我们能够直接获得的是测量仪器测得的电池的电流、电压这样的数值信息, 如果想利用专家知识, 则需进行数值到语义值的转换, 转换的过程是在匹配度的计算中完成的, 于是就需要通过设定语义值的参考值来架起数值到语义之间的桥梁。

在完成语义值和参考值的设定后, 可以进行式 (1) 中所涉及的匹配度 α_i^k 的计算, 具体计算方法如下:

当 $x_i \leq A_{i,1}$ 或 $x_i \geq A_{i,J_i}$ 时, x_i 对于 $A_{i,1}$ 或 A_{i,J_i} 的匹配度为 1, 对其他参考值的匹配度均为 0; 当 $A_{i,q} \leq x_i \leq A_{i,q+1}$ 时, x_i 对 $A_{i,q}$ 和 $A_{i,q+1}$ ($q=1, 2, \dots, J_i-1$) 的匹配度计算方法如式 (7)、(8) 所示, 对其他参考值的匹配度为 0。

$$\alpha_{i,q} = (A_{i,q+1} - x_i) / (A_{i,q+1} - A_{i,q}) \quad (7)$$

$$\alpha_{i,q+1} = (x_i - A_{i,q}) / (A_{i,q+1} - A_{i,q}) \quad (8)$$

例如, 若测得某一时刻锂电池放电电流为 20 A, 电流语义值设定为小 S (Small)、中 M (Medium)、大 L (Large), 对应的参考值分别为 4 A, 12 A, 40 A, 则该输入对 S、M、L 的匹配度分别为 $\{0, (40-20)/(40-12)=0.7143, (20-12)/(40-12)=0.2857\}$

在计算出匹配度之后, 再经过第 1.2 节中介绍的证据推理过程, 可得出后项置信度 β 。因为最终需要输出的是 SOC 估计值, 所以对于后项属性, 同样需要对其语义值对应的参考值 D_j 进行定义, 从而利用式 (9) 计算获得最终定量的 SOC 估计值输出。

$$\text{SOC} = \sum_{j=1}^N (D_j \beta_j) \quad (9)$$

例如, 后项属性同样选取 S、M、L 作为语义值,

对应参考值分别设定为 0, 55, 100, 在后项置信度分别为 0.07, 0.78, 0.15 时, 可得最终的 SOC 估计值为 $0 \times 0.07 + 55 \times 0.78 + 100 \times 0.15 = 57.9$ 。

简而言之, 根据专家对锂电池外部特性参数与 SOC 之间的非线性复杂关系的认识, 结合对电池数据的分析给出规则的前项及后项参考值及属性权重、规则权重、后项置信度这一系列参数, 即可建立初始置信规则库。最终形成置信规则库中的规则形如: “if {I is S, U is M}, then SOC is {(S, 0.96), (M, 0.04), (L, 0)}”, 代表在电流较小而电压处在中等水平时, SOC 大概率为小值。

3 实际案例

3.1 数据获取

以中航锂电公司生产的 SE40AHA 型号 LiFePO_4 电池为测试对象, 该电池标称容量 40 Ah, 标称电压 3.2 V, 充电截止电压 3.6 V, 放电截止电压 2 V。

测试过程中, 保持环境温度为 20 °C, 同时为减少电池容量衰减, 在 0.1 C、0.3 C、1 C 的放电倍率下对 2 个同型号电池分别进行数据收集, 部分数据展示见表 1。

表 1 部分实验数据

训练样本			测试样本		
电流/A	电压/V	SOC/%	电流/A	电压/V	SOC/%
40	3.417	99.656	40	3.474	99.317
40	3.160	66.335	40	3.147	59.956
40	3.141	55.944	40	3.115	38.013
40	3.109	33.014	40	3.093	27.255
40	2.984	7.507	40	2.904	5.313
12	3.548	99.919	12	3.269	97.673
12	3.224	65.789	12	3.221	63.889
12	3.154	25.364	12	3.106	14.056
12	3.128	18.183	12	3.061	7.395
4	3.269	71.366	4	3.269	77.302
4	3.218	33.082	4	3.234	49.843
4	3.189	26.143	4	3.183	22.304
4	3.157	14.657	4	3.161	16.511

3.2 置信规则库的建立

根据 LiFePO_4 的电池特性、测试数据及专家经验等信息, 进行语义值及其对应参考值的设定。

需要注意的是, 前项属性参考值的个数决定了置信规则库包含的规则数目, 同时与后项属性参考值的个数共同影响待优化参数的个数。参考值个数过多, 则生成的规则和待优化参数过多, 后续证据推理及参数优化部分计算量将十分庞大; 反之, 则不足

以描述输入和输出之间复杂的非线性关系^[22]。

针对锂电池 SOC 估计问题, 前项属性 I、U 及后项 SOC 均选取 3 个参考值, 语义值描述分别为: 小 S(Small)、中 M(Medium)、大 L(Large)。在此基础上, 根据具体型号的锂电池充电截止电压、放电截止电压、标准放电电流等电池参数、采集到的电池数据等信息及专家经验等信息, 对各语义值和参考值进行设定, 见表 2。

表 2 前后项的语义值和参考值

电池参数	S	M	L
电流/A	4	12	40
电压/V	2	2.8	3.6
SOC/%	0	50	100

在此基础上, 根据专家对其外部特性参数与 SOC 之间的非线性复杂关系的认识, 结合对电池数据的分析, 建立初始置信规则库表 3。

表 3 初始置信规则库

No.	A_1^k	A_2^k	SOC 置信结构
1	S	S	{(S, 1.00), (M, 0.00), (L, 0.00)}
2	S	M	{(S, 0.96), (M, 0.04), (L, 0.00)}
3	S	L	{(S, 0.00), (M, 0.01), (L, 0.99)}
4	M	S	{(S, 0.99), (M, 0.01), (L, 0.00)}
5	M	M	{(S, 0.95), (M, 0.05), (L, 0.00)}
6	M	L	{(S, 0.00), (M, 0.00), (L, 1.00)}
7	L	S	{(S, 0.98), (M, 0.02), (L, 0.00)}
8	L	M	{(S, 0.93), (M, 0.07), (L, 0.00)}
9	L	L	{(S, 0.00), (M, 0.00), (L, 1.00)}

其中, 属性权重 δ_1, δ_2 均取值为 1。为减少初始置信规则库中包含的主观偏差, 下面将对初始置信规则库进行优化。

3.3 置信规则库优化

利用 1.3 中提到的优化方法对初始置信规则库进行优化。形成优化后的置信规则库表 4, 优化后的前、后项属性参考值见表 5, 其中优化后的属性权重取值为 $\delta_1 = 0.544 1, \delta_2 = 0.545 3$ 。

表 4 优化后的置信规则库

No.	A_1^k	A_2^k	SOC 置信结构
1	S	S	{(S, 0.987 3), (M, 0.012 7), (L, 0.000 0)}
2	S	M	{(S, 0.635 5), (M, 0.352 0), (L, 0.012 5)}
3	S	L	{(S, 0.000 0), (M, 0.000 6), (L, 0.999 4)}
4	M	S	{(S, 0.990 0), (M, 0.010 0), (L, 0.000 0)}
5	M	M	{(S, 0.343 8), (M, 0.656 2), (L, 0.000 0)}
6	M	L	{(S, 0.000 0), (M, 0.000 0), (L, 1.000 0)}
7	L	S	{(S, 0.998 8), (M, 0.001 2), (L, 0.000 0)}
8	L	M	{(S, 0.000 0), (M, 0.000 9), (L, 0.999 1)}
9	L	L	{(S, 0.004 8), (M, 0.986 8), (L, 0.008 4)}

优化后的规则权重从规则 1 到规则 9 分别为:

0.652 9,0.412 0,0.459 7,0.174 6,0.123 2,0.183 9,
0.362 6,0.032 7,0.922 2。

表 5 优化后的前后项参考值

电池参数	S	M	L
电流/A	4.000	12.000	40.000
电压/V	2.000	3.2230	3.600
SOC/%	0.000 0	95.998 9	100.000 0

3.4 BP 神经网络 SOC 预测模型建立

建立 3 层 BP 神经网络,其中输入层包含 2 个节点,分别为电池的电流和电压。输出层节点数为 1,为电池 SOC 估计值。隐含层采用 logsig 函数,隐含层节点个数取决于系统精度和过拟合问题两方面的考虑,节点数目过少,模型容错性会较差;节点数目过多,会增加网络训练时间,降低泛化能力^[23]。经试验,最终取节点数为 12。设置最大迭代次数 1 000,训练目标误差 0.001,利用训练数据对网络进行训练。在算法实现的过程中,设置提前停止(Early Stopping),在训练过程中,记录到目前为止的最佳精度,当连续 10 次迭代没出现新的最佳精度时,则可以认为精度不再提高了,此时便停止迭代。如此可避免因无用迭代次数过多而产生的过拟合问题。

3.5 估计结果

首先,对比初始置信规则库与参数优化后的置信规则库的估计结果见图 3。




图 3 置信规则库优化前后效果对比

可见,初始置信规则库的输出与训练数据有很大的偏差,均方误差(Mean Squared Error, MSE)为 0.275 5,经过 fmincon 的参数训练后,置信规则库输出与真实值更加接近,MSE 为 $7.616 9 \times 10^{-4}$ 。

分别利用训练数据和测试数据对置信规则库及神经网络算法的电池 SOC 估计效果进行验证和对比。2 种方法对训练数据的估计结果和估计误差见图 4、图 5。从图 4 中可以看出,2 种方法的估计值都在真实值附近分布。从图 5 中所展示的估计误差来看,神经网络算法对训练数据的估计效果较好,经计算,其 MSE 为 $2.481 4 \times 10^{-4}$ 略优于置信规则库的 $7.616 9 \times 10^{-4}$ 。

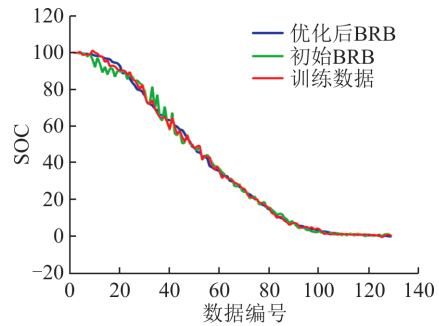


图 4 训练数据估计效果对比




图 5 训练数据估计误差

2 种方法对测试数据的估计结果和估计误差见图 6、图 7。从图 6 中可以看出,置信规则库方法的 SOC 估计值仍在真实值附近。经计算,神经网络算法的 MSE 为 $1.799 3 \times 10^{-3}$,置信规则库输出的 MSE 为 $6.567 6 \times 10^{-4}$,可见置信规则库的精度要优于神经网络。且从图 7 中可以更加明显地观察到,神经网络方法的部分估计值已经出现了明显偏差,甚至产生了负值,可以认为是错误的结果。




图 6 测试数据估计效果对比

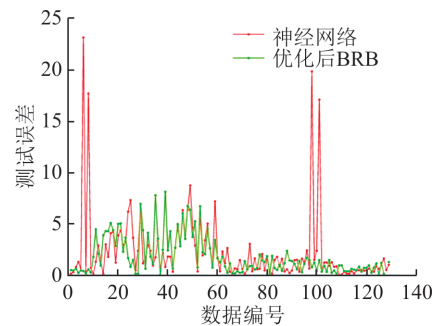


图 7 测试数据估计误差

由于置信规则库参数及神经网络的训练结果具有随机性,本文利用前述数据进行了50次的训练及测试,记录了两者的测试数据的MSE,对比见图8。




图8 测试数据MSE对比

从图8可以看出,神经网络的测试效果普遍较差且部分实验中估计值出现了严重偏差;置信规则库的效果较好且较为稳定。

4 结论

本文提出了基于置信规则库的锂电池SOC估计的方法。通过磷酸铁锂电池的案例研究来验证BRB的性能,同时与神经网络算法进行对比,实验结果显示:

1)BRB能够通过历史数据的训练进行参数优化,优化后的置信规则库相较于初始置信规则库的估计效果有明显提升。

2)将参数优化后的置信规则库与神经网络算法对训练数据和测试数据的估计效果进行对比,结果显示,传统神经网络算法对训练数据的拟合效果较好,然而对测试数据的估计效果偏差较大,且部分估计值出现了明显的错误。

3)置信规则库方法虽然对训练数据的估计效果不如神经网络算法,但其对测试数据的估计效果较神经网络算法有明显的优势,总体表现较为稳定。

4)置信规则库方法估计SOC具有较高的精度,且可以克服传统神经网络方法因电池个体差异性而存在的过拟合问题。

参考文献(References):

[1] 王东,李国欣,潘延林. 锂离子电池技术在航天领域的应用[J]. 上海航天,2000,17(1):54-58,62.
WANG D,LI G X,PAN Y L. The Technology of Lithium-ion Batteries for Spacecraft Application [J]. Shanghai Aerospace,2000,17(1):54-58,62. (in Chinese)

[2] 姜兴刚,朱咸斌,张德远. 超声振动加工电源的研究进展[J]. 陕西师范大学学报(自然科学版),2018,46

(3):13-20.
JIANG X G,ZHU X B,ZHANG D Y. Progress of Ultrasonic Machining Power Supply [J]. Journal of Shaanxi Normal University (Natural Science Edition),2018,46(3):13-20. (in Chinese)

[3] 孙继欣,张宇,朱永伟. 压电器件的精密超声复合电解加工技术[J]. 陕西师范大学学报(自然科学版),2018,46(5):32-38.
SUN J X,ZHANG Y,ZHU Y W. Design of Precision Ultrasonic Compound Electric Machining for Piezoelectric Components[J]. Journal of Shaanxi Normal University(Natural Science Edition),2018,46(5):32-38. (in Chinese)

[4] 吴铭. 军用电子设备用高比能锂原电池研究[D]. 长沙:中南大学,2014.
WU M. Research on Lithium Primary Batteries with High Specific Energy of Military Electronic Equipment [D]. Changsha: Central South University,2014. (in Chinese)

[5] 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.
FENG J. Training Data Selection of BP Neural Network for State-of-Charge Estimation of Li-Ion Battery [J]. Chinese Journal of Power Sources,2016,40(2):283-286. (in Chinese)

[6] 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 A D,ZHANG W X,ZHAO H,et al. Research on Estimation for SOC of LiFePO₄ Li-Ion Battery Based on Neural Network [J]. Journal of Electronic Measurement and Instrumentation,2011,25(5):433-437. (in Chinese)

[7] 冯勇. 电动汽车电池管理系统研究[D]. 长沙:湖南大学,2010.
FENG Y. Research on Electric Vehicle Battery Management System [D]. Changsha: Hunan University,2010. (in Chinese)

[8] 雷津,邓磊,李小谦,等. 基于EKF的船舶动力锂电池剩余容量估算[J]. 电子测量技术,2016,39(12):85-88.
LEI J,DENG L,LI X Q,et al. Accurate SOC Estimation of The Power Li-Ion Battery Based on EKF [J]. Electronic Measurement Technology,2016,39(12):85-88. (in Chinese)

[9] 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.
YU H F,LU R G,ZHU C B,et al. State of Charge Estimation Calibration for Ni-MH Battery Based on Ampere-Hour Method[J]. Transactions of China Elec-

- tro Technical Society, 2012, 27(6): 12-18. (in Chinese)
- [10] WU G L, ZHOU Y Z, YU D R. Unsteady Open Circuit Voltage Method for State of Charge Estimation of Electric Vehicle Batteries [J]. Electric Machine-s & Control, 2013, 17(4): 110-115.
- [11] SATO S, KAWAMURA A. A New Estimation Method of State of Charge Using Terminal Voltage and Internal Resistance for Lead Acid Battery[C]//Proceedings of the Power Conversion Conference-Osaka 2002 (Cat. no. 02TH8579). Osaka, Japan: PCC, 2002: 565-570.
- [12] HU C, YOUN B D, CHUNG J. A Multiscale Framework with Extended Kalman Filter for Lithium-ion Battery SOC and Capacity Estimation [J]. Applied Energy, 2012, 92: 694-704.
- [13] 全云旭, 吴保卫. 具有分布时滞的不确定中立系统鲁棒 H^∞ 降维滤波器的设计[J]. 陕西师范大学学报(自然科学版), 2014, 42(2): 1-6.
- TONG Y X, WU B W. A Design of Robust H^∞ Reduced-Order Filter for Uncertain Neutral Systems with Distributed Delay[J]. Journal of Shaanxi Normal University (Natural Science Edition), 2014, 42(2): 1-6. (in Chinese)
- [14] GUAN K, WEI Z Q, YIN B. SOC Prediction Method of a New Lithium Battery Based on GA-BP Neural Network[C]//GUAN K, WEI Z Q, YIN B. eds. Proceedings of the 4th International Conference on Computer Engineering and Networks. Cham: Springer International Publishing, 2015: 141-153.
- [15] 邢志伟. 带有时滞和脉冲的 Markovian 跳变神经网络的同步[J]. 纺织高校基础科学学报, 2019, 32(1): 57-62.
- XING Z W. Synchronization of Markovian jump Neural Networks with Time-Varying Delay and Impulses[J]. Basic Sciences Journal of Textile Universities, 2019, 32(1): 57-62. (in Chinese)
- [16] 宋乐, 谷林, 东虎, 等. 优化的 BP 网络在面部特征点的深度估计[J]. 西安工程大学学报, 2017, 31(4): 551-555.
- SONG L, GU L, DONG H, et al. Depth Estimation of Facial Feature Points Based on Optimized BP Neural Network[J]. Journal of Xi'an Polytechnic University, 2017, 31(4): 551-555. (in Chinese)
- [17] 姚青岐, 马训鸣, 洪奔奔, 等. 基于神经网络 PID 控制的电液开口机构系统仿真[J]. 西安工程大学学报, 2018, 32(4): 468-473.
- YAO Q Q, MA X M, HONG B B, et al. Electro-Hydraulic Opening Mechanism Simulation Based on Neural Network PID Control[J]. Journal of Xi'an Polytechnic University, 2018, 32(4): 468-473.
- [18] 李璐, 温宗周, 张阳阳, 等. 基于 RBF 神经网络滑坡灾害发生概率预报方法[J]. 西安工程大学学报, 2017, 31(4): 521-526.
- LI L, WEN Z Z, ZHANG Y Y, et al. Probability Prediction Method of Landslide Disaster Based on RBF Neural Network[J]. Journal of Xi'an Polytechnic University, 2017, 31(4): 521-526. (in Chinese)
- [19] 张树梅. 基于磷酸铁锂单体电池荷电状态的均衡算法研究 [D]. 上海: 上海交通大学, 2015.
- ZHANG S M. Research on Equalization Algorithm Based on LiFePO_4 Cell State of Charge [D]. Shanghai: Shanghai Jiaotong University, 2015. (in Chinese)
- [20] YANG J B, LIU J, JIN W, et al. Belief Rule Base Inference Methodology Using the Evidential Reasoning Approach- RIMER [J]. IEEE Transactions on Systems Man & Cybernetics Part A Systems & Humans, 2006, 36(2): 266-285.
- [21] XU D L, LIU J, YANG J B, et al. Inference and Learning Methodology of Belief-Rule-Based Expert System for Pipeline Leak Detection [J]. Expert Systems with Applications, 2007, 32(1): 103-113.
- [22] 徐晓滨, 汪艳辉, 文成林, 等. 基于置信规则库推理的轨道高低不平顺检测方法[J]. 铁道学报, 2014, 36(12): 70-78.
- XU X B, WANG Y H, WEN C L, et al. Track Vertical Irregularity Detection Based on Inference of Belief Rule Base [J]. Journal of Railway, 2014, 36(12): 70-78. (in Chinese)
- [23] 黄耀波, 唐海定, 章欢, 等. 基于遗传神经网络的电动汽车锂电池 SOC 预测[J]. 机电工程, 2013, 30(10): 1255-1258.
- HUANG Y B, TANG H D, ZHANG H, et al. Prediction of Lithium-Ion Battery SOC in EV Based on Genetic Neural Network [J]. Journal of Mechanical & Electrical Engineering, 2013, 30(10): 1255-1258. (in Chinese)

(编辑: 姚树峰)