



引用格式:王震,陆金桂.改进的 ACO-BP 神经网络在锂离子电池 SOC 估算中的应用[J].轻工学报,2019,34(4):81-86.

中图分类号:TM912 文献标识码:A

DOI:10.3969/j.issn.2096-1553.2019.04.012

文章编号:2096-1553(2019)04-0081-06

改进的 ACO-BP 神经网络 在锂离子电池 SOC 估算中的应用

Application of improved ACO-BP neural network in estimation of SOC of lithium ion battery

王震,陆金桂

WANG Zhen, LU Jingui

南京工业大学 机械与动力工程学院,江苏 南京 211816

School of Mechanical and Dynamic Engineering, Nanjing Tech University, Nanjing 211816, China

关键词:
电池 SOC; 蚁群优化;
神经网络; 估算模型

Key words:
SOC of battery;
ant colony optimization;
neural network;
estimation model

摘要:针对单一 BP 神经网络模型估算锂离子电池 SOC 易陷入局部最优的问题,引入蚁群算法 ACO,并与 BP 神经网络模型相结合,提出了改进的 ACO-BP 神经网络以估算电池 SOC.采用惯性修正算法,在校正权阈值时加入惯性量,以改进 BP 神经网络;利用改进的全局信息素更新规则来改进 ACO 算法,以解决其易早熟收敛的问题.将改进的 ACO-BP 神经网络应用于 18650 锂离子动力电池 SOC 估算,结果表明,改进的 ACO-BP 神经网络估算 SOC 的相对误差能控制在 $\pm 1.957\%$ 以内,MAPE 为 0.897%,精度和稳定性明显优于单一 BP 神经网络和 ACO-BP 神经网络.

收稿日期:2019-02-07

作者简介:王震(1992—),男,江苏省无锡市人,南京工业大学硕士研究生,主要研究方向为神经网络和智能优化算法.

通信作者:陆金桂(1966—),男,江苏省靖江市人,南京工业大学教授、博士生导师,主要研究方向为智能优化及智能 CAD.

Abstract: Aiming at the problem that SOC of lithium ion batteries is easy to fall into local optimum by single BP neural network, ant colony algorithm was introduced and combined with BP neural network model, and an improved ACO-BP neural network was proposed to estimate battery SOC. Inertia correction algorithm was used to add inertia amount when correcting the weight threshold to improve BP neural network. ACO algorithm was improved using the improved global pheromone updating rules to solve the problem of premature convergence. The improved ACO-BP neural network was applied to estimate SOC of 18650 lithium ion power battery. The results showed that the relative error of the improved ACO-BP neural network in estimating SOC could be controlled within $\pm 1.957\%$ and the *MAPE* was 0.897% . The accuracy and stability of the improved ACO-BP neural network were obviously better than those of single BP neural network and ACO-BP neural network.

0 引言

动力电池 SOC(state of charge)的估算是动力电池管理系统的核心。精确地估计动力电池 SOC,一方面可以合理地分配能量,提高动力电池的续航时间,另一方面可以避免动力电池的过充和过放,安全保护动力电池,延长动力电池的使用寿命。如何精确地估算动力电池的 SOC 是业界当今研究的热点和难点。

目前国内外用于估算动力电池 SOC 的方法主要有安时积分法^[1]、开路电压法^[2]、扩展卡尔曼滤波法^[3]、BP 神经网络法^[4]等。安时积分法虽然简单稳定,但是无法避免累计误差;开路电压法不能满足在线动态估算电池 SOC 的要求;扩展卡尔曼滤波法具有一阶泰勒精度^[5],但个别特征参数不稳定。BP 神经网络具有较强的自学习和非线性拟合能力,而 SOC 与测量所得的电压、电流、温度等值之间是强烈的非线性关系,所以 BP 神经网络能够较好地估算动力电池的 SOC。张传伟等^[6]提出了 BP 神经网络估算 SOC 的模型;黄妙华等^[7]改进了 BP 神经网络的 SOC 估算,利用较优的训练函数和传递函数提高了 BP 神经网络估算 SOC 的普适性。但单纯的 BP 神经网络法易陷入局部最优、收敛速度慢的情况。王鸽等^[8]将蚁群算法(ACO)与 BP 神经网络结合,加快了网络的收敛速度,在一定程度上避免了单纯 BP 算法易出现局部极小值的问题,但是标准 ACO 算法仍存在易陷入

局部最优的问题。

鉴于此,本文拟采用改进 ACO 算法优化改进后的 BP 神经网络,构建改进的 ACO-BP 神经网络,将其运用于锂离子电池的 SOC 估算,以期提高动力电池 SOC 的估算精度。

1 改进 ACO-BP 神经网络的构建

1.1 BP 神经网络的改进

BP 神经网络在训练过程中信号前向传播,误差逆向传播^[9],是通过模仿人类大脑神经网络构造、具有自适应和非线性拟合等能力的人工神经网络,其实质是通过不断修正神经网络各隐含层的各个权值和阈值,使误差达到设置的范围。估算 SOC 的 BP 神经网络由 3 层网络结构构成,即输入层、隐含层和输出层。

为了提高 BP 神经网络估算的实时性和准确性,本文采用惯性校正算法来改进 BP 神经网络,即在校正权阈值时,在本次误差计算得到的校正量的基础上,以一定的惯性系数加上前一次权阈值的校正量,作为此次的校正量。其计算公式为

$$\Delta W(n) = W + \alpha \Delta W(n-1) \quad (1)$$

其中, $\Delta W(n)$ 为本次最终校正量; W 为误差计算得到的校正量; $\alpha \Delta W(n-1)$ 为惯性量, α 是取值为(0,1)的惯性系数, $\Delta W(n-1)$ 为前一次权阈值最终校正量。

相较于标准 BP 神经网络,经改进的 BP 神经网络其学习收敛速度和精度有较大的

提高^[10].

1.2 ACO 算法的改进

ACO 算法是一种仿生智能随机搜索算法. 蚂蚁的觅食行为是一种强化正确行为的正反馈,而优先选择信息素浓度较高的路径则是该正反馈的前提,所有待优化问题的解空间对应整个蚂蚁群体的所有路径,较优蚂蚁(即行进路径较短的蚂蚁)释放较多的信息素,一段时间以后,该路径上累积了较高浓度的信息素,在正反馈的作用下选择此条路径的蚂蚁数量相应增多,如此循环,最终在最佳路径上集中了数量最多的蚂蚁^[11],此时该最短路径即为最优解. 由于蚁群系统是通过信息素的累积将搜索行为集中到最优解附近来寻优的,当局部最优解附近已经有较高浓度信息素时,绝大多数蚂蚁会选择局部最优解的路径,在正反馈的作用下易造成早熟收敛的行为,导致最终得到的是局部最优解而不是全局最优解.

本文拟通过改进 ACO 算法的全局信息素更新规则来避免蚁群陷入局部最优解,改进的全局信息素更新规则是:通过增强蚁群目前最优解的信息素,削弱之前局部最优解信息素的方法,可以避免蚁群算法陷入局部最优解的问题,即为

$$\tau_{ij}(t+n) = (1-\rho) \times \tau_{ij}(t) + \Delta\tau_{ij} \quad (2)$$

$$\Delta\tau_{ij} = Q_k \times \frac{L_b - L_k}{L_b} \quad (3)$$

其中, $0 \ll \rho < 1$; $\Delta\tau_{ij}$ 为信息素增量, $\Delta\tau_{ij}(0) = 0$; Q_k 为在本次循环中蚂蚁 k 释放的信息素总量; L_b 为本次循环之前的最优解; L_k 为本次循环的最优解. 若 $L_b > L_k$, 则先执行公式(2)再将 L_b 的值变更为当前 L_k 的值,若 $L_b < L_k$, 则执行公式(2), L_b 值不变.

1.3 ACO-BP 神经网络的改进

设 BP 神经网络有 K 个权值,根据权值的取值范围将每个参数 $K_i (1 \leq i \leq K)$ 的定义域平

均划分成 L 个区间,即每个区间的长度被 L 等分,从而形成一个 $K \times L$ 大小的集合 A . 将区间的临界值或选择区间中的随机值作为候选值. 蚂蚁在集合 A 中遍历. 计算蚂蚁经过的路径,分别选出最优和最差的蚂蚁,然后更新调节信息素,循环以上步骤直到达到最大循环次数,找出使得权值最合适的节点所在. 所得到的解即是较优解. 将此较优解作为 BP 神经网络算法权值的初始值. 训练 BP 神经网络,对误差进行反馈调节,调整权值,得到最优解. 算法流程图如图 1 所示,具体步骤如下.

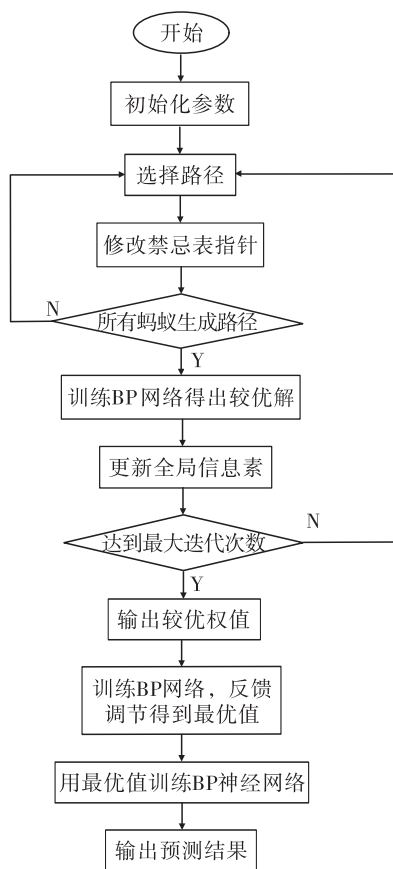


图 1 ACO-BP 算法流程图

Fig. 1 Flow chart of ACO-BP algorithm

步骤 1 参数初始化:将每个权值和阈值的定义域等分,设置有 m 个蚂蚁,信息挥发系数 ρ ,信息素残留系数 λ ,信息素强度 Q ,最大迭代次数 N_{max} ,BP 神经网络全局误差 E ,最大学

习次数 N .

步骤 2 权值选择: m 只蚂蚁根据状态转移概率函数选择路径, 蚁群迭代一次则完成一次解的构造, 状态转移概率函数为

$$p_{ij}^k(t) = f(x) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha \times [\eta_{ij}(t)]^\beta}{\sum_{s \in allowed} [\tau_{is}(t)]^\alpha \times [\eta_{is}(t)]^\beta} & \text{若 } j \in allowed \\ 0 & \text{否则} \end{cases} \quad (4)$$

其中, $allowed = \{0, 1, \dots, L - 1\}$, 表示蚂蚁 k 下一步允许选择的元素; $\tau_{ij}(t)$ 表示 t 时刻路径 (i, j) 上的信息量; $\eta_{ij}(t)$ 为启发度函数, 表示蚂蚁 k 从元素 i 转移到元素 j 的期望程度.

步骤 3 若 $k < m$, 则重复步骤 2, 否则执行步骤 4.

步骤 4 将蚁群迭代得到的解作为 BP 神经网络的初始权值对网络进行训练, 将 BP 神经网络的输出均方差最小值作为蚁群算法较优解.

步骤 5 一个循环结束后, 根据公式②③对残留信息进行全局更新, 并重置信息表.

步骤 6 若达到最大循环次数则输出较优权值, 否则跳转至步骤 2 重复以上步骤.

步骤 7 将蚁群迭代得到的较优解作为 BP 神经网络的初始权值进行训练, 根据输出值与实际值的误差进行反馈调节, 得到最优权值.

2 改进后的 ACO-BP 神经网络在电池 SOC 估算中的应用

2.1 输入层建模

神经网络输入参数的选择一般按照输入参数和输出参数相关性大、输入参数较易测量或提取、各输入参数之间相关性越小越好的原则进行. 影响电池 SOC 的因素很复杂, 其中电池的端电压、充放电电流和工况温度与 SOC 有极大的关系且较容易测得, 故将其作为输入. 因为有 3 个输入量, 所以输入层节点数为 3.

2.2 隐含层建模

多隐含层训练的复杂度高, 训练所需的时

间长, 虽然估算精度高, 泛化能力强, 但是会增大过拟合的可能性. 本文选用单隐含层的神经网络实现电池 SOC 的估算.

隐含层节点数根据经验公式大致确定为

$$N = \sqrt{(m + n)} + a \quad (5)$$

$$N = \log_2 m \quad (6)$$

$$N = \sqrt{mn} \quad (7)$$

其中, N 为隐含层节点数, m 为输入层节点数, n 为输出层节点数, a 为区间 $[0, 10]$ 之间的常数.

将每一个可能的隐含层节点数代入 BP 神经网络进行训练, 选取最小误差值的隐含层节点数为 5.

2.3 输出层建模

电池 SOC 的估计值是输出层的唯一项, 所以输出层节点数为 1.

2.4 确定学习速率

学习速率过大, 网络训练时间缩短, 牺牲了 BP 神经网络训练的收敛性, 如果预期提高估算精度, 则需降低学习速率, 但是易造成网络收敛速度慢, 训练时间过长^[12]. 通过不断调整 BP 神经网络训练中的学习速率, 选取最适合本模型的学习速率为 0.01.

2.5 数据归一化处理

由于电压、电流和温度不是同一个量纲, 本文将训练样本和估算样本数据通过最大最小法进行归一化处理, 将样本数据归一化为无量纲数据^[13]. 数据归一化函数形式为

$$x_k = \frac{x_k - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

其中, x_{\max} , x_{\min} 分别为序列中的最大数和最小数.

3 仿真结果与分析

本文测试对象为额定电压 3.7 V, 容量为 2.9 Ah 的 18650 动力电池单体. 分别测得该电

池在 0.5 C, 1 C, 1.5 C 的放电率下恒流放电的电压、电流和温度数据. 随机取 100 组数据作为训练样本, 15 组数据作为测试样本. 为了验证本文改进后的 ACO-BP 神经网络估算电池 SOC 的准确性, 将其与单一 BP 神经网络、ACO-BP 神经网络估算结果进行对比. 通过仿真实验, 三者的估算效果、估算数据与样本数据误差分别如图 2, 图 3 和表 1 所示.

由图 2 可以看出, 改进后的 ACO-BP 神经网络估算 SOC 的结果明显比单一 BP 神经网络和 ACO-BP 神经网络的估算结果更逼近样本数




图 2 SOC 估算效果图

Fig. 2 SOC estimation effect diagram




图 3 SOC 估算样本相对误差图

Fig. 3 SOC estimation sample relative error diagram

据值. 由图 3 和表 1 可以看出, 改进后的 ACO-BP 神经网络训练结果的相对误差在 $\pm 1.957\%$ 以内, ACO 输出层 BP 神经网络训练结果的相对误差在 $\pm 2.597\%$ 以内, 单一 BP 神经网络训练结果的相对误差在 $\pm 4.978\%$ 以内. 改进后的 ACO-BP 神经网络的相对误差范围明显小于标准 ACO-BP 和单一 BP 神经网络, 表明改进后的 ACO-BP 神经网络估算电池 SOC 具有较高的精度和较高的稳定性.

为了更加直观地评价 ACO-BP 神经网络的估算能力, 本文采用平均绝对值百分比误差 (MAPE) 进行分析, 其计算公式为

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_{f,i} - P_{a,i}}{P_{a,i}} \right| \times 100\%$$

其中, N 为估算样本总数; $P_{f,i}$ 为第 i 个样本 SOC 估算值; $P_{a,i}$ 为第 i 个样本的样本值. 由表 1 数据计算可得, 改进后的 ACO-BP 神经网络、ACO-BP 神经网络和 BP 神经网络的 MAPE 分别为 0.897%, 1.871%, 3.124%, 改进后的 ACO-BP 神经网络的估算精度明显优于单一 BP 神经网络和标准 ACO-BP 神经网络, 证明了改进后的 ACO-BP 神经网络估算动力电池 SOC 的可行性.

4 结语

本文利用惯性校正算法优化 BP 神经网络, 利用改进的全局信息素更新规则改进 ACO 算法, 利用改进的 ACO 算法优秀的整体寻优能力, 优化 BP 神经网络的初始权值, 在一定程度上弥补了 BP 神经网络容易陷入局部最优的缺点. 将改进后的 ACO-BP 神经网络模型用于动力电池 SOC 估算, 使得估算误差明显减小. 与单一 BP 神经网络、标准 ACO-BP 神经网络估算结果对比发现, 其在逼近能力方面明显更优, 精度更高, 故本模型有较好的准确性和合理性. 深入研究影响电池 SOC 的因素, 如循环次数、充

表1 SOC 估算结果分析表

Table 1 Analyze the results of SOC estimation

%

样本编号	样本值	BP 神经网络		ACO-BP 神经网络		改进后的 ACO-BP 神经网络	
		估算值	相对误差	估算值	相对误差	估算值	相对误差
1	95.0	98.7	3.895	96.8	1.895	95.6	0.632
2	44.3	45.2	2.031	43.2	-2.483	43.5	-1.806
3	20.6	19.7	-4.369	20.2	-1.942	20.8	0.971
4	89.5	93.1	4.022	89.9	0.447	89.3	-0.223
5	53.2	51.4	-3.383	54.5	2.444	54.1	1.692
6	62.5	61.1	-2.240	61.3	-1.920	62.9	0.640
7	92.0	90.9	-1.196	93.3	1.413	90.2	-1.957
8	38.9	40.7	4.627	38.4	-1.285	39.4	1.285
9	78.7	76.4	2.922	80.5	2.287	78.2	-0.635
10	49.7	49.1	-1.207	48.9	-1.610	50.2	1.006
11	26.3	27.0	2.662	26.9	2.281	26.2	-0.380
12	96.2	91.7	-4.678	98.5	2.391	96.8	0.624
13	23.6	23.1	-2.119	23.8	0.847	23.7	0.424
14	46.2	48.5	4.978	45.0	-2.597	46.6	0.866
15	63.1	64.7	2.536	61.7	-2.219	63.3	0.317

电倍率和内阻等,以进一步提高电池 SOC 的估算精度,将是下一步的工作重点.

参考文献:

- [1] 欧阳剑,李迪,柳俊城.电动汽车用动力电池荷电状态估算方法研究综述[J].机电工程技术,2016,45(1):52.
- [2] 李争,智若东,孙宏旺,等.基于开路电压预测的SOC估算方法[J].河北工业科技,2017,34(1):36.
- [3] 王宇航,王顺利,潘小琴,等.基于扩展卡尔曼的锂离子电池SOC估算研究[J].自动化与仪表,2018,33(8):76.
- [4] 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.
- [5] 欧阳剑.电动汽车用锂离子动力电池SOC估算和SOF评估的研究[D].广州:华南理工大学,2016.
- [6] 张传伟,李林阳,赵东刚.基于BP神经网络法估算动力电池SOC[J].电源技术,2017,41(9):1356.
- [7] 黄妙华,严永刚,朱立明.改进BP神经网络的磷酸铁锂电池SOC估算[J].武汉理工大学学报(信息与管理工程版),2014(6):790.
- [8] 王鸽,蒲蓬勃.ACO-BP在神经网络训练中的研究与应用[J].计算机仿真,2009,26(12):136.
- [9] 赵钢,孙豪赛,罗淑贞.基于BP神经网络的动力电池SOC估算[J].电源技术,2016,40(4):818.
- [10] 李东玉,王睿,冯宜民.基于BP神经网络的阀控铅酸盐蓄电池劣化程度预测[J].郑州轻工业学院学报(自然科学版),2012,27(4):12.
- [11] 孙启豪,蔡爱华.航空搜潜布阵航路优化研究[J].电光与控制,2017(4):39.
- [12] 霍健.大跨径连续梁桥悬臂施工线形控制[D].哈尔滨:东北林业大学,2013.
- [13] 周美兰,王吉昌,李艳萍.优化的BP神经网络在预测电动汽车SOC上的应用[J].黑龙江大学自然科学学报,2015,32(1):129.