

纯电动汽车磷酸铁锂电池组的建模及优化

宋绍剑, 林庆芳, 林小峰

(广西大学 电气工程学院, 南宁 530004)

摘要: 鉴于传统神经网络和支持向量机机理复杂、计算量大的缺陷, 很难实时跟踪磷酸铁锂电池组复杂快速的内部反应, 影响电池荷电状态的估算精度, 提出应用一种简单、有效的极限学习机对一额定容量为 100 Ah、额定电压为 72 V 的纯电动汽车磷酸铁锂电池组建模, 并分别与 BP 神经网络、RBF 神经网络、支持向量机进行对比; 随后, 以学习时间和泛化性能为优化目标, 应用粒子群方法寻找最佳隐层节点个数; 结果表明, 基于极限学习机的磷酸铁锂电池组模型的学习时间、泛化性能优于 BP 神经网络、RBF 神经网络、支持向量机; 隐层节点优化后, 模型的学习时间和泛化性能达到最优。

关键词: 传统神经网络; 支持向量机; 磷酸铁锂电池组; 荷电状态; 极限学习机; 粒子群优化

Modeling and Optimization of Pure Electric Vehicle's LiFePO₄ Battery Pack

Song Shaojian, Lin Qingfang, Lin Xiaofeng

(School of Electrical Engineering, Guangxi University, Nanning 530004, China)

Abstract: The traditional neural networks and support vector machine have the weakness of complex mechanism and large amount of computation. It is difficult to track the complex and fast inner reaction of LiFePO₄ battery pack in real time, affecting the estimation accuracy of the battery state of charge. A simple and effective extreme learning machine is proposed for the modeling of pure electric vehicle's LiFePO₄ battery pack, whose rated capacity is 100 Ah and nominal voltage is 72 V, then compared with the back-propagation neural networks-based, radical basis function neural networks-based and support vector machines-based. Subsequently, taking the learning time and generalization performance as the optimization goal and using the particle swarm to find the optimal hidden node. The results show that the model of LiFePO₄ battery pack based on extreme learning machine has shorter learning time and higher generalization performance compared with the model based on BP neural networks, RBF neural networks and support vector machines. After optimization of hidden nodes, learning time and generalization performance of the model is optimal.

Keywords: traditional neural networks; support vector machine; LiFePO₄ battery pack; state of charge; extreme learning machine; particle swarm optimization

0 引言

近年来, 磷酸铁锂电池因其具有寿命长、比能量高、无环境污染、安全性好等一系列优点, 被广泛用来做新能源汽车的车载能源。然而, 磷酸铁锂电池组因其复杂的内部反应及在运行过程中所表现出来的非线性和时变性等特征, 严重影响电池荷电状态 (SOC) 的估算精度, 在某种程度上阻碍了新能源汽车的快速发展。因此, 对磷酸铁锂电池建模对于电池全面的分析和研究是非常必要的。

文献 [1] 给出了目前几种常见的磷酸铁锂电池等效电路模型。然而, 仅靠等效电路很难描述电池状态的非线性; 而传统神经网络和支持向量机 (SVM) 也存在以下不足: 1) 传统神经网络需要大量的计算。2) 由于 SVM 是借助二次规划来求解支持向量, 因此 SVM 算法对大规模训练样本难以实施。

针对传统神经网络和 SVM 的不足, 2006 年新加坡南洋理

工大学黄广斌教授提出了一种简单易用、有效的单隐层前馈神经网络 (SLFNs) 学习算法: 极限学习机 (ELM)^[2-3]。ELM 无需调整模型参数, 其输入权值和隐层偏置是随机选定的, 因此只需计算输出权值, 训练过程快速且性能较佳^[4-5]。ELM 的这些特性使其在内存、处理速度有限的汽车系统中的应用成为可能。

为此, 本文提出应用 ELM 对一微型纯电动汽车的能量源、额定容量为 100 Ah、额定电压为 72 V 的磷酸铁锂电池组进行建模, 并与 BPNN、RBFNN、SVM 进行比较; 最后以学习时间和泛化性能为优化目标, 应用粒子群算法寻找最佳隐层节点个数。

1 极限学习机

1.1 SLFNs 的逼近问题

对于任意 N 个不同的样本 (x_i, t_i) , 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in \mathbf{R}^n, t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbf{R}^m$ 。则具有 \tilde{N} 个隐层节点、激励函数为 $g(x)$ 的标准 SLFNs 的数学模型为:

$$\sum_{i=1}^{\tilde{N}} \beta_j g_i(x_j) = \sum_{i=1}^{\tilde{N}} \beta_j g_i(w_i \cdot x_j + b_i) = o_j, j = 1, \dots, N$$

收稿日期: 2014-09-11; 修回日期: 2014-10-13。

基金项目: 国家自然科学基金项目 (61364007); 国家自然科学基金重点项目 (610034002)。

作者简介: 宋绍剑 (1970-), 男, 广西象州人, 教授, 硕士生导师, 主要从事新能源转换与控制、复杂系统建模与优化方向的研究。

式中, $w_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{im}]^T$, 是连接第 i 个隐层节点和输入节点的权值向量; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$, 是连接第 i 个隐层节点和输出节点的权值向量; b_i 为第 i 个隐层节点的阈值; $w_i \cdot x_j$ 表示 w_i 和 x_j 的内积, 输出节点设为线性。

这样具有 \tilde{N} 个隐层节点、激励函数为 $g(x)$ 的标准 SLFNs 就能够以零误差逼近这 N 个样本, 也就意味着 $\sum_{j=1}^{\tilde{N}} \|o_j - t_j\| = 0$, 即, 存在 β_i, w_i, b_i 使得

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = t_j, j = 1, \dots, N \quad (2)$$

式 (2) 中的 N 个等式可简写如下:

$$H\beta = T \quad (3)$$

其中:

$$H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}} \quad (4)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}, T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (5)$$

与文献 [6-7] 中的命名相同, H 称为神经网络的隐层输出矩阵。

1.2 基于梯度的 SLFNs 学习方法

由文献 [6-8] 可知, 如果隐层节点数等于训练样本数, $\tilde{N} = N$, 则矩阵 H 是方阵且可逆, 并且 SLFNs 可以以零误差逼近这些训练样本。然而, 在大多数情况下, 隐层节点数要远小于训练样本数, $\tilde{N}N$, 此时, 矩阵 H 为非方阵, 而且可能找不到使 $H\beta = T$ 的 $w_i, b_i, \beta_i (i = 1, \dots, \tilde{N})$ 。因此就可能需要寻找特定的 $\hat{w}_i, \hat{b}_i, \hat{\beta}_i (i = 1, \dots, \tilde{N})$ 来替代, 以使

$$\|H(\hat{w}_1, \dots, \hat{w}_{\tilde{N}}, \hat{b}_1, \dots, \hat{b}_{\tilde{N}})\hat{\beta} - T\| = \min_{w_i, b_i, \beta} \|H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}})\beta - T\| \quad (6)$$

上式等价于代价函数最小化

$$E = \sum_{i=1}^N \left(\sum_{j=1}^{\tilde{N}} \beta_j g(w_i \cdot x_j + b_j) - t_j \right)^2 \quad (7)$$

式中, H 矩阵未知、是一个基于梯度的学习算法, 主要是用于寻找 $H\beta - T$ 的最小值。在最小化的过程中采用基于梯度的算法, 向量 W (权值 w_i, β_i 和偏置 b_i 的参数集) 通过下式进行迭代调整:

$$W_k = W_{k-1} - \eta \frac{\partial E(W)}{\partial W} \quad (8)$$

式中, η 为学习率。BP 学习算法是最常用的前馈神经网络学习算法, 梯度可以在输出反向传播到输入的过程中高效地计算出来。然而 BP 学习算法也存在以下几个问题:

- 1) 当学习率 η 过小时, 该学习算法收敛的非常慢; 而当 η 过大时, 该算法就会变得不稳定, 甚至发散。
- 2) 另一个影响 BP 学习算法性能的是存在局部极小值^[9]。
- 3) 采用 BP 算法的神经网络会存在训练过度的问题, 并使

得神经网络的泛化性能差。

4) 在大多数应用中, 基于梯度的学习方法都非常的耗时。

1.3 SLFN 的最小范数最小二乘解

为了解决以上存在的问题, Huang 基于以下定理提出了一种高效的前馈神经网络学习算法。

定理 1^[3]: 给定一个具有 N 个隐层节点、激励函数为 $g: R \rightarrow R$ (在任何区间内无穷可微) 的标准 SLFN, 对于任意 N 个不同的样本 (x_i, t_i) (其中 $x_i \in R^n, t_i \in R^m$), 随机选取 $w_i \in R^n, b_i \in R$, 则由连续概率分布可知, SLFN 的隐层输出矩阵 H 可逆且 $\|H\beta - T\| = 0$ 的概率为 1。

定理 2^[3]: 给定任意小的正数 $\epsilon > 0$ 和在任何区间内无穷可微的激励函数 $g: R \rightarrow R$, 则存在 $\tilde{N} \leq N$, 使得对于任意 N 个不同的样本 (x_i, t_i) (其中 $x_i \in R^n, t_i \in R^m$), 随机选取 $w_i \in R^n, b_i \in R$, 由连续概率分布可得, $\|H_{N \times \tilde{N}} \beta_{\tilde{N} \times m} - T_{N \times m}\| < \epsilon$ 的概率为 1。

由定理 1 和定理 2 可知, 与需要对输入权值和隐层偏置进行调整的传统函数逼近理论不同的是, 只要激励函数是无穷可微的, 输入权值和隐层偏置可以随机给定。实际上, SLFNs 的输入权值 w_i 和隐层偏置 b_i 无需调整, 隐层输出矩阵 H 在这些参数值随机给定之后就可以唯一确定。

输入权值 w_i 和隐层偏置 b_i 确定之后, 根据式 (6) 可知, 训练 SLFN 就等价于寻找线性系统 $H\beta = T$ 的最小二乘解 $\hat{\beta}$:

$$\|H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}})\hat{\beta} - T\| = \min_{\beta} \|H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}})\beta - T\| \quad (9)$$

若隐层节点数 \tilde{N} 等于训练样本数 N , 则当随机给定输入权值 w_i 和隐层偏置 b_i 时, 矩阵 H 是方阵且可逆, SLFN 能够以零误差逼近这些训练样本。然而, 在大多数情况下, 隐层节点数 \tilde{N} 要远小于训练样本数 N , 此时, 矩阵 H 为非方阵, 而且可能找不到使 $H\beta = T$ 的 $w_i, b_i, \beta_i (i = 1, \dots, \tilde{N})$ 。而由 Moore-Penrose 广义逆^[3]的定义可知。上述线性系统的最小范数最小二乘解是

$$\hat{\beta} = H^+ T \quad (10)$$

式中, H^+ 为矩阵 H 的 Moore-Penrose 广义逆。

1.4 ELM 算法

因此, 一种简单的 SLFN 学习算法——ELM 算法就可以概括如下:

给定训练集 = $\{(x_i, t_i) | x_i \in R^n, t_i \in R^m, i = 1, \dots, N\}$ 、激励函数 $g(x)$, 隐层节点数 \tilde{N} 。

Step1: 随机给定输入权值 w_i 和隐层偏置 $b_i, i = 1, \dots, \tilde{N}$ 。

Step 2: 计算隐层输出矩阵 $H = g(w, b, x)$ 。

Step 3: 计算输出权值 $\beta: \beta = H^+ \cdot T$ 。

2 ELM 的建模

为了得到磷酸铁锂电池的模型, 以往的方法都是通过一些简化方程来代替复杂的非线性映射。而基于神经网络的模型却无需知道电池的内部结构, 这使电池的建模变得更简单。

磷酸铁锂电池的 SOC 与电池的电流、电压、温度有相当强的非线性关系^[10]。如电流在 SOC 的估算过程中变化很快。因此, 数据采集周期必须足够短, 以免因电流的快速变化而影响模型的精度。此外, 充满电的电池组有较长的工作周期, 如

几个小时。综上, 所采集的磷酸铁锂电池组的数据比较大, 对应的训练数据量也很大。应用传统的神经网络或 SVM 来训练这么大的数据。需要的时间很长, 甚至对 SVM 来说, 还可能无法运行。因此有必要寻找更快的学习算法。而由 1.1 节可知。ELM 不同于传统的神经网络, 它的特点是无迭代学习训练, 这使得学习过程非常快。

磷酸铁锂电池的 SOC 与电池的电流、电压、温度有关^[10], 因此, 本文以磷酸铁锂电池的电流、温度、SOC 作为模型的输入, 以电压作为模型的输出。即

$$p(k) = [I(k), T(k), SOC(k)]^T \quad (13)$$

式中 k 表示采集到的第 k 组数据。令 $p(k) = x_i, V(k) = t_i$, 则训练集就为: $\{(x_i, t_i) \mid x_i \in \mathbf{R}^n, t_i \in \mathbf{R}^m, i=1, \dots, N\}$ ($n=3, m=1$)。具体的训练步骤如下所示。

Step1: 导入所采集到的数据, 并随机化。

Step2: 对随机化后的数据进行归一化, 并选取对应的训练集和测试集。

Step3: 给定 ELM 的输入, 即训练集、测试集、激励函数类型、隐层节点数。

Step4: 利用 ELM 学习算法对数据进行训练, 并得出学习时间、训练精度、测试时间、测试精度等值。

Step5: 对训练输出值和预测输出值进行反归一化。

3 仿真结果及分析

根据如图 1 所示的电流值对一额定容量为 100 Ah、额定电压为 72 V 的纯电动汽车能量源磷酸铁锂电池组进行充放电实验 (电流为正值表示充电, 电流为负值表示放电), 在此过程中磷酸铁锂电池组的端电压变化如图 1 所示。由图 1 可知, 在磷酸铁锂电池组充放电过程中, 电压表现出很强的非线性, 这使得磷酸铁锂电池组的建模过程更加复杂。




图 1 磷酸铁锂电池组的充放电电流及电压变化

在整个充放电过程中, 总共采集到了 9 715 组数据 (上位机通过 CAN 总线每 0.4 s 读取一次电池管理系统的数)。随机选取其中的 6 000 组数据作为 ELM 的训练集, 剩余的 3 715 组作为测试集, 在 Dual-Core (2.60 GHz) /Windows xp/MATLAB/R2010a 环境下, 以 Sigmoidal 函数作为激励函数, 当隐层节点为 40 (训练 50 次后求平均值) 时, ELM 学习算法的训练精度 (或 RMSE) 及测试精度, 结果列于表 1。

为了验证基于 ELM 的磷酸铁锂电池组模型的性能, 本文将基于 ELM 的磷酸铁锂电池组模型与基于 BPNN、RBFNN、SVM 的模型进行比较。

同样从 9 715 组数据中随机选取 6 000 组作为训练集, 3 715 组作为测试集, 在相同的运行环境下, 当隐层节点为 40

(训练 50 次后求平均值) 时, BPNN (单隐层, 迭代次数取 40, 学习率取 0.1, 均方误差目标取 0.001)、RBFNN (迭代次数取 40, 扩展速度取 1, 均方误差目标取 0.001)、SVM 算法的训练精度及测试精度, 结果列于表 1。四种学习算法前 20 个样本的拟合效果和泛化性能如图 2~3 所示。

由表 1 可知: 1) ELM 的学习时间 (0.1406 s) 比 BPNN (16.1094 s) 快 114.6 倍、比 RBFNN (87.5156s) 快 622.4 倍, 比 SVM (2704.9 s) 快 19238.3 倍; ELM 的测试时间 (0.0313 s) 也要比 BPNN (0.1250 s)、RBFNN (0.0625 s)、SVM (1.7344 s) 短; 2) ELM、BPNN、SVM 的训练精度 (拟合效果) 一样大, 要优于 RBFNN, 如图 2 所示; 3) ELM 的测试精度 (泛化性能) 优于 BPNN、SVM, 尤其优于 RBFNN, 如图 3 所示。

表 1 不同算法的性能比较

算法	训练		测试		Nodes/ SVs
	t/s	RMSE	t/s	RMSE	
ELM	0.1406	0.0414	0.0313	0.0498	40
BPNN	16.1094	0.0853	0.1250	0.0905	40
RBFNN	87.5156	0.0738	0.0625	0.0825	40
SVM	2704.9	0.0395	1.7344	0.0502	3192.5




图 2 不同算法的拟合效果




图 3 不同算法的泛化性能

由此可知, 基于 ELM 的磷酸铁锂电池组模型的拟合效果、泛化性能、学习时间及预测时间等性能更佳。

众所周知, 纯电动汽车中的整车控制器是一个嵌入式系统, 与 PC 中的 CPU 相比, 其内存有限、处理能力较低。因

此,若要用神经网络算法对纯电动汽车中的磷酸铁锂电池组建模,则该神经网络应该是一种计算简单、运算量小、学习时间短的算法。然而,传统神经网络和 SVM 不仅计算复杂、运算量大;ELM 作为一种简单、高效的前馈神经网络,其学习时间很短(低于采集周期),因此,把 ELM 应用于纯电动汽车中磷酸铁锂电池组的建模是可能的。

4 粒子群优化

通过上节分析可知,若要把 ELM 应用于纯电动汽车磷酸铁锂电池组的建模,则应在追求高测试精度的同时,追求高学习速率。因此应该寻找一个隐层节点数,使它对应的学习时间最短、泛化性能最佳。然而,通过对不同隐层节点数的学习训练发现,虽然 ELM 的测试精度在一定范围内随隐层节点数的递增而有所提高(如图 4 所示),但随着隐层节点数的递增,也会使 ELM 的学习时间变长(如图 4 所示)。即,高测试精度和高学习速率无法同时满足。




图 4 不同隐层节点数对应的测试精度及学习时间

为此,本节以学习时间和测试精度为优化目标,通过分配不同的权重,用粒子群优化算法(PSO)寻找最优隐层节点数,使得该隐层节点数对应的值最小,即,该隐层节点数的测试精度和学习时间在带权重的情况下最优。具体步骤如下。

Step1: 设置 PSO 的运行参数。令速度更新参数 $c1 = c2 = 2$; 迭代次数 $maxgen = 100$; 种群规模 $sizepop = 20$; 种群和速度限制为: $pop_{max} = 100$, $pop_{min} = 1$; $V_{max} = 4$, $V_{min} = -4$ 。

Step2: 随机初始化粒子的位置和速度,根据适应度函数计算粒子适应度值。

Step3: 迭代寻优。根据如下公式更新粒子位置和速度,并且根据新粒子的适应度值更新个体极值和群体极值。

$$V_i^{k+1} = V_i^k + c_1(gbest_i^k - pop_i^k) + c_2(zbest_i - pop_i^k) \quad (14)$$

$$pop_i^{k+1} = pop_i^k + V_i^{k+1} \quad (15)$$

式中, k 为当前迭代次数, $i = 1, 2, \dots, sizepop$, $gbest$ 为个体最优, $zbest$ 为全局最优。

根据以上步骤进行粒子群优化,得到最优个体适应度值如图 5 所示。由图 5 可知,最终得到的最优个体适应度值为 0.028 8,对应的隐层节点数为 34。由图 4 可知,当隐层节点数为 34 时,对应的测试精度为 0.050 0,学习时间为 0.070 9 s。与隐层节点数为 40 的相比,其测试精度虽然变低了,但是学习速率提高了;再者,其测试精度和学习速率仍要优于传统神经网络和 SVM。因此,粒子群优化算法寻优得到的隐层节点数是最优的。




图 5 最优个体适应度值

5 结论

ELM 的学习时间很短,只需要几十毫秒就可以完成,是传统神经网络的成百上千倍、SVM 的上万倍,打破了传统神经网络和 SVM “学习时间短与训练精度高不能同时满足”的矛盾;隐层节点优化后,模型的学习时间和泛化性能达到最优。

参考文献:

- [1] Chen M, Gabriel A. Rincon-Mora. Accurate Electrical Battery Model Capable of Predicting Runtime and IV Performance [J]. Energy conversion, IEEE transactions on, 2006, 21 (2): 504-511.
- [2] Huang G B, Zhu Q Y, Siew C K. Extreme Learning Machine: a New Learning Scheme of Feed Forward Neural Networks [A]. Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on [C]. IEEE, 2004, 2: 985-990.
- [3] Huang G B, Zhu Q Y, Siew C K. Extreme Learning Machine: Theory and Applications [J]. Neurocomputing, 2006, 70 (1): 489-501.
- [4] Huang G B, Zhou H M, Ding X J, et al. Extreme Learning Machine for Regression and Multiclass Classification [J]. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on, 2012, 42 (2): 513-529.
- [5] Huang G B, Zhu Q Y, Siew C K. Real-time Learning Capability of Neural Networks [J]. Neural Networks, IEEE Transactions on, 2006, 17 (4): 863-878.
- [6] Huang G B, Babri H A. Upper Bounds on the Number of Hidden Neurons in Feedforward Networks with Arbitrary Bounded Nonlinear Activation Functions [J]. Neural Networks, IEEE Transactions on, 1998, 9 (1): 224-229.
- [7] Huang G B. Learning Capability and Storage Capacity of Two-hidden-layer Feedforward Networks [J]. Neural Networks, IEEE Transactions on, 2003, 14 (2): 274-281.
- [8] Tamura S, Tateishi M. Capabilities of a Four-layered Feed-forward Neural Network: Four Layers Versus Three [J]. Neural Networks, IEEE Transactions on, 1997, 8 (2): 251-255.
- [9] Haykin S. Neural Networks: a Comprehensive Foundation [M]. Prentice Hall PTR, 1994.
- [10] Gao L J, Liu S Y, Dougal R A. Dynamic Lithium-ion Battery Model for System Simulation [J]. Components and Packaging Technologies, IEEE Transactions on, 2002, 25 (3): 495-505.