

文章编号:1671-8879(2009)05-0112-04

电动汽车新型动力电池建模分析

张接信¹,程 博¹,周雁麓¹,王军平²

(1. 长安大学 工程机械学院,陕西 西安 710064; 2. 西安交通大学 机械工程学院,陕西 西安 710049)

摘 要:针对传统的神经网络电池建模方法的缺陷,利用计算智能算法训练的 RBF 网络实现镍氢动力电池组建模;采用免疫聚类的方法,通过对样本径向基进行成分提取,并与自适应并行免疫进化策略(PIES)相结合,形成一种更有效的 RBF 网络构造策略,并对理论分析进行放电验证。研究表明:利用计算智能算法训练的 RBF 网络实现镍氢动力电池组建模,有效地减少了训练时间;同时能够减少 RBF 网络的隐节点数目,并有效地确定中心宽度;该建模方法比传统网络镍氢电池建模方法精度有所提高,最大电压误差在 0.3 V 以内。

关键词:汽车工程;电动汽车;电池建模;免疫聚类;RBF 网络

中图分类号:U469.72

文献标志码:A

New battery modeling analysis for electric vehicle

ZHANG Jie-xin¹, CHENG Bo¹, ZHOU Yan-lu¹, WANG Jun-ping²

(1. School of Engineering Machinery, Chang'an University, Xi'an 710064, Shaanxi, China;

2. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, Shaanxi, China)

Abstract: In order to solve the problems of traditional neural network battery modeling method, the computational intelligence algorithm is used to train RBF networks and to realize the nickel-hydrogen batteries modeling, the immune clustering algorithm is adopted to extract the radial basis function. Combined with adaptive parallel immune evolutionary strategy(PIES), a more effective strategy of constructing RBF network is formed. This method is verified by the battery discharge experiment. The results show that the method proposed in this paper can reduce training time and the number of hidden nodes, and it can more effectively determine the center width of hide layer. The modeling is more accurate than the traditional methods, the most voltage error of this modeling is less than 0.3 V. 7 figs, 9 refs.

Key words: automobile engineering; electric vehicle; battery modeling; immune clustering; RBF network

0 引 言

在电动汽车新型电池研发中,电池建模精度对整车动力性、燃料经济性和安全性都有重大影响。由于电流、功率、充电状态(SOC, state of charge)和

温度等因素对电池特性呈非线性影响,使得建立准确的电池模型成为电动汽车系统仿真的难点之一。电动汽车常用电池性能模型可分为简化的电化学模型、等效电路模型、神经网络模型、部分放电模型和特定因素模型等。简化的电化学模型常见的有

收稿日期:2008-10-13

基金项目:陕西省重大科技专项项目(2006kz02-G7)

作者简介:张接信(1959-),男,陕西礼泉人,副教授,E-mail:cazjx@yahoo.com.cn。

Peukert 方程、Shepherd 模型^[1]和 Unneweher 模型^[2];等效电路模型主要包括基本电路模型^[3]、线性电路模型^[4]和非线性电路模型^[5];特定因素模型主要有温度模型、SOC 模型、循环寿命模型^[6]和容量衰减模型。利用 BP 神经网络进行电池建模^[7]其收敛性不易保证,而局部激励函数的 RBF(radial basis function)网络,具有良好的泛化能力,学习速度较快,其隐层节点的数目也在训练过程中确定,并且其收敛性也较 BP 网络易于保证,因此可以得到最优解。为此,本文提出采用免疫聚类的方法,通过对样本径基进行成分提取,利用 PIES(parallel immune evolutionary strategy)^[8]设计了改进的 RBF 网络的训练步骤,在镍氢电池恒流放电和变功率放电工况下,检验改进的 RBF 网络在镍氢电池建模方面的精度。

1 隐节点数和聚类中心的确定算法

目前,选择设计 RBF 网络的最常用算法是聚类方法和正交最小二乘算法(OLS 算法)。OLS 算法能自动设计满足精度要求的网络结构,但学习精度无法确定,无法保证所选取的径向基能够反映训练样本的全部信息,当输入数据量较大时,容易出现病态矩阵,往往不能设计出最小结构的 RBF 网;聚类方法的隐节点数据中心通过对样本输入聚类产生,不存在设定学习精度的问题,但对确定隐节点数(即聚类数)却没有好的方法,一般需要预先指定聚类的数量,而由于径向基数目是经验值,径向基向量的求取极易陷入局部最小。

本文采用文献[9]提出的一种人工免疫数据聚类方法确定 RBF 网络的中心。假定训练数据中包含 N 个输入矢量,每个输入矢量的维数为 p ,构成矢量集合 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ 。算法的目的就是寻求包含 m 个矢量的集合 $\mathbf{Z} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_m\}$ 构成 RBF 网络的中心集合。

在该算法中, \mathbf{X} 中的每个输入量 \mathbf{x}_i 相当于一个抗原(A_g),而 \mathbf{Z} 中的中心量 \mathbf{z}_j 则相应于一个抗体(A_b)。矢量之间的匹配度(亲和度)用欧氏距离来表示。距离越小,则矢量之间的匹配度越高;当矢量间的距离小于特定阈值时,则意味着发生了“识别”事件。确定 RBF 网络中心的免疫聚类方法的迭代步骤如下。

Begin

随机初始化中心集合 \mathbf{Z}

while (Conditions = True)

for $i = 1$ to N

计算 \mathbf{x}_i 与所有中心矢量的差异度 D_i

$$D_i = \{d_{ij} \mid d_{ij} = \|\mathbf{x}_i - \mathbf{z}_j\|, j = 1, 2, \dots, m\} \quad (1)$$

选择 n 个与 \mathbf{x}_i 差异度最小的中心矢量 \mathbf{Z}_p

$$\mathbf{Z}_p = \{\mathbf{z}_k \mid d_{ik}^{\min} = \text{statistics}(d_{ij} \mid j = 1, 2, \dots, m), k = 1, 2, \dots, n\} \quad (2)$$

对 \mathbf{Z}_p 变异并确定其差异度矩阵

$$\mathbf{Z}_p = \text{mutation}(\mathbf{Z}_p), \mathbf{D}_p = \{d_{ik} \mid \mathbf{z}_k \in \mathbf{Z}_p\} \quad (3)$$

选择 \mathbf{Z}_p 中 $\alpha\%$ 个与 \mathbf{x}_i 差异度最小的矢量加以保留

$$\mathbf{Z}_p = \{\mathbf{z}_k \mid d_{ik}^{\min} = \text{statistics}(d_{ij} \mid j = 1, 2, \dots, n), k = 1, 2, \dots, \text{int}(n\alpha\%), d_{ik}^{\min} < \sigma_d\} \quad (4)$$

克隆抑制操作

$$\mathbf{S}_p = \{s_{kl} \mid s_{kl} = \|\mathbf{z}_k - \mathbf{z}_l\|, \mathbf{z}_k, \mathbf{z}_l \in \mathbf{Z}_p\} \quad (5)$$

$$\mathbf{Z}_p = \mathbf{Z}_p - \{\mathbf{z}_k \mid s_{kl} < \sigma_s, \mathbf{z}_k, \mathbf{z}_l \in \mathbf{Z}_p\} \quad (6)$$

更新中心矢量集合

$$\mathbf{Z} = [\mathbf{Z}, \mathbf{Z}_p], m = \text{size}(\mathbf{Z}) \quad (7)$$

end

免疫网络抑制操作

$$\mathbf{S} = \{s_{kl} \mid s_{kl} = \|\mathbf{z}_k - \mathbf{z}_l\|, \mathbf{z}_k, \mathbf{z}_l \in \mathbf{Z}\} \quad (8)$$

$$\mathbf{Z} = \mathbf{Z} - \{\mathbf{z}_k \mid s_{kl} < \sigma_s, \mathbf{z}_k, \mathbf{z}_l \in \mathbf{Z}, k = 1, 2, \dots, \text{int}(m\gamma\%)\} \quad (9)$$

End

在上述步骤中:int 为取整函数; σ_d 为自然死亡率阈值; d_{ij} 为 $\mathbf{x}_i - \mathbf{z}_j$ 的匹配度(即输入矢量和中心矢量的“差异度”); s_{ij} 为 $\mathbf{z}_i - \mathbf{z}_j$ 的匹配度(即中心矢量之间的“类似度”); \mathbf{S} 为元素 s_{ij} 的类似度矩阵; \mathbf{Z}_k 为中心矢量集合; $\mathbf{z}_k, \mathbf{z}_l$ 均为中心矢量; d_{ik} 为 i, k 之间的欧式距离; d_{ik}^{\min} 为 i, k 之间最小的欧式距离; \mathbf{D}_p 为 i, k 之间的欧式距离集合; s_{kl} 为 k, l 之间的欧式距离。

采用的终止条件是固定的迭代次数 M_c 。算法中的参数 $\sigma_s, \sigma_d, n, \alpha, \gamma$ 和 M_c 可以根据经验设定。抑制阈值 σ_s 控制着中心的特异性和聚类排列方式,它直接影响集合 \mathbf{Z} 中的中心矢量的数量 m 。

\mathbf{Z}_p 中的矢量 \mathbf{z}_j 相应于 \mathbf{x}_i 的变异可以表示为

$$\mathbf{z}_j = \mathbf{z}_j - \beta(\mathbf{z}_j - \mathbf{x}_i), \mathbf{z}_j \in \mathbf{Z}_p \quad (10)$$

式中:学习速率 β 根据 $\mathbf{x}_i - \mathbf{z}_j$ 的匹配度设定,匹配度越高, β 越小。

2 基于 PIES 的 RBF 网络预测模型

2.1 自适应并行免疫进化策略

在 PIES 中,以抗体种群的平均亲和度为界,将

种群分为 2 个子群,相应的提出精英克隆算子(ECO, elitist clonal operator)和采用超变异算子(SMO, super mutation operator)。利用 ECO 的自适应变异操作可提高局部搜索能力,并通过 SMO 加强种群变异能力,维持种群的多样性,这样就通过功能互补的 2 个算子协作,实现了种群并行进化。

2.2 改进的 RBF 网络的训练步骤设计

(1)利用人工免疫聚类确定 RBF 网络中心 z_j ($j=1,2,\dots,m$)的数量和初始位置,对核函数的标准差 σ_j , $j=1,2,\dots,m$ 以及每个输出节点 i 的权值矢量 w_i 采用随机初始化,从而产生初始种群 P_1 。 P_1 中的每个个体对应一种网络结构,其中心相同而标准差和权值矢量彼此不同。

(2)计算当前种群 P_k 中所有抗体的适应度函数,如当前群体 P_k 中的最佳个体满足要求或达到最大进化代数,则网络的训练停止;否则继续。

(3)在 PIES 算法中,根据抗体亲和度相对于种群平均亲和度的高低,采用对应的 ECO 或 SMO 操作。在群体变异操作中,为避免随机变异破坏人工免疫聚类的结果,中心对应编码位的变异幅度和概率小于其他编码位的变异幅度和概率。

(4)2 个变异算子 ECO 和 SMO 操作完成后,合并种群,计算群体的适应度函数;由随机生成的抗体代替当前种群中适应度较差的部分抗体,然后采用轮盘赌的选择机制,从种群中选择个体,产生新一代群体 P_{k+1} ;返回步骤(2)。

算法的选择机制采用轮盘赌的方式,即使是群体中最差的个体也有生存的可能,避免过早收敛。

$$P(i) = F(i) / \sum_i^N F(i) \quad (11)$$

式中: $P(i)$ 为第 i 个体在下一代中复制自身的概率; $F(i)$ 为每个抗体的适应度, $F(i) = 1/E$, E 为网络的误差目标函数。

$$E_i = \sum_{i=1}^M \sum_{t=1}^O (Y_i(t) - \hat{Y}_i(t))^2 \quad (12)$$

式中: $Y_i(t)$ 、 $\hat{Y}_i(t)$ 分别为训练数据 t 在第 i 输出节点的实际输出和期望输出; O 、 M 分别为输出节点数和输入数据的数目。

3 镍氢电池放电试验

3.1 恒流放电试验

恒流放电试验中,分别采用 5、10、15、20、 \dots 、80、85、90 A 的放电方式,图 1 为电池组 30~80 A 放电时的电压变化情况。




图1 电池组的恒流放电电压变化曲线

3.2 变功率放电试验

变功率放电是基于汽车工业标准联邦城市行驶工况 FUDS(federal urban driving schedule)来测试的。FUDS 是基于实际行驶数据的历时达到 1 372 s 的时间-车速表。从电池满荷电状态开始,电池按照 FUDS 功率行驶工况进行放电,试验要首尾相连无间断的循环进行,直至试验计划中所规定的放电终止点。测试前,在荷电状态为 0 的情况下,对电压为 96 V 的镍氢电池组充电,充满电为 54.96 Ah 的电量。放电时,采用 0.25 倍的 FUDS 功率变化,继续不停歇的放电,总共完成 8 个循环。图 2 为电池的变功率放电电压变化曲线。




图2 电池的变功率放电电压的变化曲线

4 仿真结果

4.1 恒流放电测试结果与分析

以 30、40、50、60、70、80 A 恒流放电数据作为样本,预测 45、55、65 A 的电压变化情况,并与原始数据做比较,计算二者之间的误差。

将训练集的数据输入网络训练,采用改进算法训练网络径向基函数隐层,取误差指数 SSE(sum squared error)为 1.8×10^{-4} ,经过训练网络达到了所需精度要求,隐含层共产生 23 个神经元。

下页图 3 为 55 A 恒流放电下 5 号电池的电压预测曲线;下页图 4 为电压误差曲线。由图 4 可以看出,最大绝对误差为 0.03 V,相对误差为 2.5%。

4.2 变功率放电测试结果与分析

镍氢电池组共完成了 8 个循环的 FUDS 放电




图 3 55 A 恒流放电下 5 号电池的电压




图 4 55 A 恒流放电下 5 号电池的电压误差

测试。以第 1、3、5、7、8 个循环作为训练样本,预测第 2、4 或第 6 个循环的电压以及功率变化情况。

训练样本中,输入变量为电流、温度和充电状态,输出变量为电压和功率。图 5 为第 4 个循环的实际电压变化情况;图 6 为预测电压变化情况;图 7 为电压的误差变化情况。从图 7 可以看出,最大电压预测误差在 0.3 V 以内。




图 7 第 4 个循环的电压预测误差

算法来训练 RBF 网络,有效地减少了训练时间。

(2)利用免疫聚类的方法能够减少 RBF 网络的隐节点数目,并有效地确定中心宽度。

(3)提出了训练 RBF 网络的训练步骤。

(4)本文建模方法比传统的网络镍氢电池建模方法精度有所提高。

参考文献:

References:

- [1] Moore S, Eshani M. An empirically based electron source horizon lead-acid battery model[J]. Society of Automotive Engineers, SAE Transactions, 1996, 105 (66): 421-424.
- [2] Unnewehr L E, Nasar S A. Electric vehicle technology[M]. New York: John Wiley & Sons, Inc, 1982.
- [3] Salameh Z M, Casacca M A, Lynch W A. A mathematical model for lead-acid batteries[J]. IEEE Transactions on Energy Conversion, 1992, 7(1): 93-98.
- [4] Appelbaum J, Weiss R. Estimation of battery charge in photovoltaic systems[C]//IEEE. Conference Record of the 16th IEEE Photovoltaic Specialists Conference. New York: IEEE, 1982: 513-518.
- [5] DOE/ID—10597, PNGV battery test manual[S].
- [6] Donald A T. Reducing battery costs for electric vehicles through optimal depth-of-discharge [C]// Andrews L. EVC Symposium VI Proceedings. Washington: Electric Vehicle Council, 1981: 467-474.
- [7] US Department of Energy. USABC electric vehicle battery test procedure manual[M]. Washington: US Department of Energy, 1996.
- [8] Cheng B, Guo Z Y. Adaptive parallel immune evolutionary strategy[C]// IEEE. 2006 International Conference on Computational Intelligence and Security. Piscataway: IEEE, 2006: 304-307.
- [9] De C L N, Von Z F J. An Immunological Approach to Initialize Centers of Radial Basis Function Neural Networks[C]// Alves da S A P, Pedreira C E. Proceedings of Fifth Brazilian Conference on Neural Networks. Rio de Janeiro: CRL Publishing, 2001: 177-178.




图 5 第 4 个循环的实际电压变化曲线




图 6 第 4 个循环的预测电压变化曲线

5 结 语

(1)在 RBF 网络基本框架的基础上,采用 PIES