

文章编号: 1000-5862(2015) 03-0221-09

基于遗传算法优化的 BP 神经网络的 PEMFC 动态特性仿真研究

简弃非 吴 昊

(华南理工大学机械与汽车工程学院 广东 广州 510640)

摘要: 针对一辆小型燃料电池电动车的 2 kW 质子交换膜燃料电池(PEMFC) 动力系统, 利用遗传算法优化的 BP 神经网络建立其电压输出特性模型. 将 PEMFC 部分实测数据作为遗传算法优化的 BP 神经网络的训练样本对其进行训练. 利用训练好的神经网络对电堆电压输出特性进行预测, 并与实验数据进行对比. 结果显示: 网络预测的输出电压与实测输出电压之间的最大相对误差均保持在 4% 之内.

关键词: 质子交换膜燃料电池; 遗传算法; BP 神经网络; 电压输出模型

中图分类号: TP 391. 92

文献标志码: A

DOI: 10. 16357/j. cnki. issn1000-5862. 2015. 03. 01

0 引言

环境和能源是当今世界发展所面临的两大重要课题^[1]. 由于传统汽车对环境的破坏和对石油资源的大量消耗, 故对各国政府和汽车制造商来说, 大力发展新能源汽车是刻不容缓的. 燃料电池是一种高效、环保的能源装置, 而其中的质子交换膜燃料电池(proton exchange membrane fuel cell, PEMFC) 因具有较高的效率(40% ~ 65%)、可靠性好、工作温度低(<100 ℃)、室温启动快、功率密度高(0. 8 W/cm²) 等特点^[2], 作为新能源被用于燃料电池汽车中是非常适合的. 建立一个好的 PEMFC 模型对更好地开发和应用系统 PEMFC 很有必要. 目前, PEMFC 模型主要分为机理模型^[3-4]和经验模型^[5] 2 种. 但无论是机理模型还是经验或半经验模型, 都是针对燃料电池本身建立的. 而在实际应用中, 燃料电池的响应不仅取决于燃料电池本身, 同时还与周围的附属设备的响应有关^[6]. 如果将燃料电池的所有附属设备系统都考虑进去将会导致非常复杂的模型. 因此, 本文利用遗传算法优化的 BP 神经网络来建立一辆小型燃料电池车的 2 kW 质子交换膜燃料电池堆的电压输出特性模型.

1 质子交换膜燃料电池系统

质子交换膜燃料电池是一个将化学能直接转化为电能电化学装置. 它利用氧化物(通常为 O₂ 或者空气) 将燃料(通常为 H₂) 直接、连续不断地转化为电能和热能^[7]. 在正常条件下, 一个质子交换膜燃料电池单体产生的电流密度大约 0. 5 A/cm², 其产生的电压为 0. 6 ~ 0. 9 V^[8]. 因此, 为了产生所需要的电压, 通常将许多的燃料电池单体通过双极板串联起来, 形成电堆. 本文所研究的燃料电池电堆的功率为 2 kW, 该电堆由 110 个质子交换膜燃料电池单体组成, 每一个电池单体的活性面积为 100 cm². 具体的电堆参数见表 1.

表 1 电堆详细参数

参数名称	数值
电池单体个数	110. 00
额定功率/kW	2. 00
额定电压/V	66. 00
额定电流/A	30. 00
质子膜厚度/mm	0. 05
膜活性面积/cm ²	100. 00
阳极气体通道宽度/mm	1. 00
阳极气体通道深度/mm	0. 40
阴极气体通道宽度/mm	2. 00
阴极气体通道深度/mm	1. 80

收稿日期: 2014-12-15

基金项目: 国家自然科学基金(50930005) 和广东省工程研究技术中心建设(2012B070800008) 资助项目.

作者简介: 简弃非(1963-) 男, 湖南邵阳人, 教授, 博士, 博士生导师, 主要从事动力机械、制冷工程及燃料电池等方向的研究.

2 基于遗传算法优化的 BP 神经网络

2.1 算法的流程

遗传算法优化的 BP 神经网络算法流程如图 1 所示,其主要分为 3 个部分:1) 确定 BP 神经网络的结构;2) 利用遗传算法对网络的初始权值和阈值进行优化;3) 利用优化后的 BP 神经网络对样本进行训练及预测. 其中网络结构的确定即要确定网络的输入变量数、隐含层数、隐含层神经元个数及输出变量数,当网络的拓扑结构确定后其权值和阈值个数就可以确定了,从而遗传算法所需优化参数的个数也确定了,因为遗传算法所优化的参数即为 BP 神经网络的初始权值和阈值. 通常神经网络的初始权值及阈值都是在 $[-0.5, 0.5]$ 区间范围内随机生成的^[9]或者依靠以往的经验 and 实验进行赋值,往往无法准确获得,而这一初始化的参数值却会对网络的训练产生很大影响,且对于相同的初始权值和阈值,网络的训练结果是不变的,通过引入遗传算法,就是为了优化出网络的最佳初始权值和阈值.

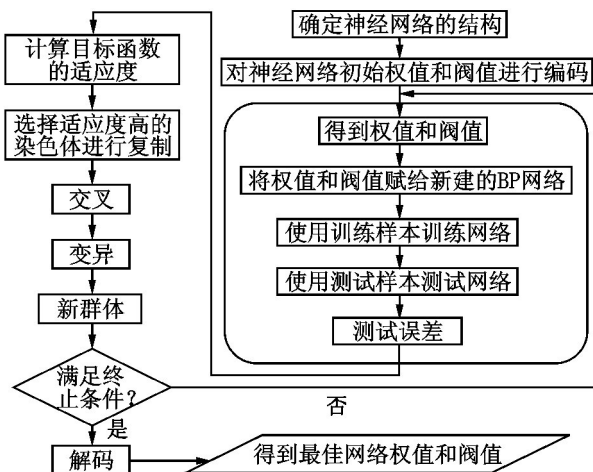


图 1 算法流程

2.2 神经网络算法的实现

根据已获得的实验数据,选取 2 kW 输出功率电堆的输出电流以及阳极气体通道的平均温度作为神经网络的输入变量,将电堆的输出电压作为神经网络的输出,则所要建立的神经网络有 2 个输入参数,1 个输出参数. 关于隐含层数的选取以及隐含层神经元个数的选取,并没有理论公式作指导. 根据文献[10]并结合多次测试,本文所建立的神经网络结构只包含 1 层隐含层,隐含层神经元个数为 16 个. 由本文所建立的 BP 神经网络的结构为 2-16-1,即输入层具有 2 个神经元,隐含层具有 16 个神经元,输出层仅有 1 个神经元,网络的权值和阈值数目

如表 2 所示.

表 2 权值与阈值的数目

类型	数目
隐含层与输入层间的连接权值	32
隐含层的阈值	16
输出层与隐含层间的连接权值	16
输出层的阈值	1

BP 神经网络算法的实质可分为 2 部分:1) 输入信息的正向传播;2) 计算误差的反向传递^[11],其中输入信息的正向传播是指输入信息依次从输入层、隐含层、最后到输出层这一逐层计算的过程,而每一层的神经元状态只会对下一层神经元的状态产生影响,同层神经元之间没有相互作用关系. 而误差的反向传递是指如果输出层没有得到给定的期望输出,则网络会计算输出层的误差变化值,然后将其沿原来的网络连接通路反向传递回来,并修改各层神经元之间的连接权值及阈值直到网络的输出达到期望目标. BP 神经网络神经元的模型可以用以下公式表示^[12]:

$$h_k = \sum_{i=1}^m W_{ik} p_i,$$

$$y_k = f(h_k + b_k) = f\left(\sum_{i=1}^m W_{ik} p_i + b_k\right),$$

式中 $p_i (i = 1, 2, \dots, m)$ 为网络的输入变量; W_{ik} 表示第 k 个神经元的突触权值; h_k 表示输入变量的线性组合器输出; b_k 表示第 k 个神经元的偏置(阈值); $f(\cdot)$ 表示 BP 神经网络的激活函数; y_k 表示神经元的输出. 对于网络的激活函数,本文将网络隐含层的传递函数设为 tansig 函数,而输出层的传递函数为 purelin 函数,2 者的表达式如下^[13]:

$$f_1(Wp + b) = \text{tansig}(Wp + b) = 2 / (1 + e^{-2(Wp + b)}) - 1,$$

$$f_2(Wp + b) = \text{purelin}(Wp + b) = Wp + b.$$

尽管 BP 网络是目前使用最为广泛的神经网络之一,但它仍存在着一些不足,如网络易陷于局部极小值、收敛速度慢等^[14],其中泛化能力差是其较为明显的一个不足之处. 由于本文的实验数据是燃料电池车辆在道路测试中获得,燃料电池堆的许多参数条件无法像实验平台那样得到精确的控制,并且采集的实验数据点非常多,这使得数据有一定的波动,为了防止神经网络在训练中出现所谓的“过适配”问题,从而提高 BP 网络的泛化能力,在此采用归一化均方误差函数(msereg)作为网络训练的误差性能函数,其表达式如下:

$$m_{\text{sereg}} = (1 - \beta) m_{\text{sw}} + \beta \cdot m_{\text{se}},$$

$$m_{\text{se}} = \frac{1}{S} \sum_{i=1}^S (T_i - Y_i)^2, \quad m_{\text{sw}} = \frac{1}{N} \sum_{j=1}^N w_j^2,$$

式中 m_{se} 为均方误差, T_i 为网络的期望值(目标值); Y_i 为网络的预测值; w_j 为各层之间的连接权值或阈值; β 为误差性能调整率. 在网络的训练过程中很难确定最佳的误差性能调整率, 过大可能出现“过适配”; 过小网络又不足以“适配”训练样本^[15]. 由此, 采用贝叶斯归一化法来实现最佳误差性能调整率的自动调整, 其网络训练的实现函数为 trainbr.

2.3 遗传算法的实现

基于遗传算法优化的 BP 神经网络, 其基本思想如前面所述, 针对 BP 神经网络的初始权值和阈值无法准确获得这一不足, 通过使用遗传算法来优化出其最佳的初始权值和阈值, 从而使得优化后的 BP 网络能够更好地对样本进行预测. 遗传算法的基本过程是随机产生 1 个适合于给定问题的初始群体, 通过设置遗传算法的目标函数使得每个群体中的个体都有 1 个适应度值, 通过个体的交叉、选择、变异等操作实现代际进化得到高适应度的个体, 从而产生下一代的群体, 这一过程将持续进行直到出现给定问题的解或近似解或达到最大遗传代数为止^[16]. 选择、交叉、变异是遗传算法中的 3 个非常重要的算子, 其中选择就是按照个体的适应度值的大小, 从种群中选出适应度较大的一些个体, 即适应度较高的个体繁殖下一代数目较多, 适应度较小的个体繁殖下一代数目较少, 甚至被淘汰, 从问题求解的角度来看就是选择与最优解相近的解, 一般选择(代沟)的概率取值为 0.85 ~ 0.95; 所谓的交叉就是对于选中用于繁殖下一代的个体, 随机地选择 2 个个体中的相同位置, 按交叉概率在选中的位置实行交换, 这一过程反映了随机信息交换, 目的在于产生新的基因组合, 也即产生新的个体. 一般交叉概率取值为 0.25 ~ 0.75; 而所谓的变异就是根据生物遗传中基因变异的原理, 以变异概率对一些个体的某些位执行变异操作, 本文遗传算法中的个体采用的是二进制编码, 因此在执行变异操作时, 就是对执行变异的串的对应位求反, 即把 1 变为 0, 把 0 变为 1. 变异概率与生物变异极小的情况一致, 所以, 变异的取值较小, 一般取 0.01 ~ 0.15. 从问题求解的角度来看, 当所有的个体一样时, 交叉是无法产生新的个体的, 这时只能靠变异产生新的个体. 因此变异增加了全局优化的特质. 上述的 3 个算子可以根据不同的问题进行适当的调整. 为了使 BP 网络在对测试样本进行预测时, 其预测值与期望值之间的残差尽可能的小, 因此, 选择网络对测试样本的预测值与其期望值的误差向量的 2 范数作为遗传算法的目标函数, 其有关遗传算法的其他操作参数设置见表 3.

$$f_{obj} = n_{orm}(Y_i - T_{i_test}) = n_{orm}(e_i) = \sqrt{\sum_{j=1}^N e_i^2}.$$

表 3 遗传算法操作参数设定

参数名称	数值
种群中个体数目	40.00
最大遗传代数	40.00
变量的二进制位数	10.00
交叉概率	0.70
变异概率	0.01
代沟	0.95

3 实验及仿真

3.1 实验数据的获取及处理

分别进行 3 组实验: 1) 燃料电池车辆在平地道路的路况下运行. 在这部分实验中, 车辆动力系统中的辅助能源——蓄电池组未参与工作, 即燃料电池堆在无辅助能源的条件下进行工作, 图 2(a) 为在该实验条件下燃料电池堆各参数的动态响应曲线, 将这组实验数据作为神经网络的训练样本; 2) 燃料电池车辆在平地道路的路况下运行, 但在这部分实验中, 车辆动力系统中的辅助能源——蓄电池组参与工作, 即燃料电池堆在蓄电池作为辅助能源的条件下进行工作, 图 2(b) 为在该实验条件下燃料电池堆各参数的动态响应曲线, 将该组实验数据作为测试样本来对训练好的 BP 神经网络进行测试; 3) 燃料电池车辆在一定坡道上运行(爬坡工况), 图 2(c) 为在爬坡工况下燃料电池堆各参数的动态响应曲线, 将该组实验数据作为验证神经网络泛化能力的验证样本.

从理论上讲, BP 神经网络对其输入参数是无限制的, 但是由于样本中并不是所有的指标都是一样的, 这就可能会导致原始样本中一些变量间的数量级会有很大差别, 为使各输入变量一开始就处于同等重要的地位, 故对所有样本的原始输入变量按下式进行处理^[17]:

$$p_i = (p_i - m_{ean}) / S.D = (p_i - (\sum_{i=1}^n p_i / n)) / \sqrt{\sum_{i=1}^n (p_i - m_{ean})^2 / n}, \quad (1)$$

式中 p_i 为网络的输入变量; $m_{ean} = \sum_{i=1}^n p_i / n$; $S.D$ 为均量偏差, 即


$$S.D = \sqrt{\sum_{i=1}^n (p_i - m_{can})^2 / n}.$$

与输入不同的是,本文的BP神经网络的输出变量只有1个,因此,并未对其原始数据按(1)式处理.值得注意的是,对于有多个输出变量的神经网络,对原始的输出变量数据进行归一化处理是非常有必要的.因为BP神经网络算法的依据是减小输出层各神经元的预测输出与期望输出之间误差的平方和.如果之前不对原始输出变量进行处理,使得一些输出变量在数值上相差较大,很显然那些具有较大输出值的神经元的误差会成为整个网络误差的主要成分,由此而得到算法的“重点照顾”,而对于那些


数值较小的输出变量却不能得到算法的“很好的照顾”,从而导致其相对误差较大.

3.2 仿真及结果

如前文所述,为了使BP神经网络在对测试样本进行预测时,网络的预测值与期望值之间误差尽可能的小,所以选择测试样本的网络预测值与期望值间的误差向量的2范数作为遗传算法的目标函数,也即适应度函数.经过遗传算法优化后的BP神经网络的最佳初始权值和阈值如表4所示.将得到的最佳的初始权值和阈值矩阵赋给新建的BP神经网络,并利用训练样本对其进行训练.




(a) 平地道路实验中电堆各参数变化曲线(未与蓄电池连接)



(b) 平地道路实验中电堆各参数变化曲线(与蓄电池连接)

图2 3组实验



(c) 爬坡实验中电堆各参数变化曲线(与蓄电池连接)

图 2(续)

表 4 优化后的权值和阈值

隐含层与输出层连接权值	隐含层阈值	输出层与隐含层连接权值	输出层阈值
-0.567 9	0.796 7	0.143 7	0.102 6
0.566 0	0.880 7	-0.826 0	
-0.446 7	-0.444 8	0.718 5	
-0.042 0	-0.165 2	0.591 4	
-0.147 6	0.951 1	-0.534 7	
-0.865 1	0.755 6	-0.820 1	
-0.468 2	-0.781 0	0.685 2	
0.904 2	-0.951 1	0.540 6	
0.071 4	0.849 5	-0.822 1	
0.425 2	0.360 7	0.521 0	
0.970 7	0.648 1	-0.519 1	
0.571 8	0.493 6	0.808 4	
0.984 4	0.753 7	-0.192 6	
-0.700 9	-0.595 3	0.014 7	
-0.409 6	-0.829 9	-0.790 8	
-0.755 6	-0.685 2	0.468 2	
-0.663 7			
0.655 9			
-0.223 9			
-0.194 5			
0.290 3			
-0.071 4			
0.298 1			
0.108 5			
-0.137 8			
0.706 7			
-0.347 0			
-0.423 3			
-0.223 9			
-0.722 4			
-0.943 3			
-0.865 1			

图 3 为训练样本(前 1 200 s)的电堆电压的实测值与经过训练后的 BP 神经网络的预测值的对比图. 由图 3 可看出,网络的预测值与实验值 2 者之间是基本吻合的. 图 4 为训练样本电堆电压实测值与 BP 神经网络预测值的误差曲线图. 由图 4 可清晰地看到,在起初阶段,网络的预测值与实测值之间的误差波动比较大,这是由于车辆处于刚启动阶段,这时燃料电池堆并未处于稳定的工作状态,使得实测的实验数据波动比较大;随后,当电堆处于稳定的工作状态时 2 者之间的误差值基本保持在 ± 1 V 之间. 这一仿真结果表明网络的训练是成功的.

针对已经训练好的网络,利用测试样本对其进行测试. 图 5(a)、图 5(b)为测试样本电堆输出电压的实测值与 BP 网络预测值的对比图,同样,由图 5 可以看到 2 者之间是基本吻合的,图 6 为测试样本电堆电压的实测值与网络预测值之间的误差曲线. 由图 6 可以看到,网络的预测值与实测值间的误差基本保持在 ± 3 V 之间. 这一仿真结果证明所建立的神经网络能够对测试样本进行很好地预测.

根据前面所建立的网络模型,为了进一步验证其泛化能力,将燃料电池车辆爬坡工况下的实验数据作为验证样本,利用建立的 BP 神经网络进行仿真. 图 7 为验证样本电堆电压实测值与网络预测值的对比图. 由图 7 可看出,网络的预测值与实测值之间是基本保持吻合的,这一结果充分证明了本文所建立的 BP 神经网络具有一定的泛化能力. 2 者的误差曲线如图 8 所示,由图 8 可看到 2 者的误差值基本保持在 ± 2 V 之间.




图3 网络预测值与实测值的比较(训练样本)






图4 误差曲线(训练样本)



(a) 测试样本前 300 s

图5 网络预测值与实测值的比较



(b) 测试样本 300 ~ 600 s

图5(续)




图6 误差曲线(测试样本)




图7 网络预测值与实测值的比较(验证样本)

此外,为了观察3组实验(训练样本、测试样本和验证样本)的电压实测值与利用遗传算法优化的BP神经网络预测值之间的相关性,对其作线性回归分析.图9(a)为训练样本的线性回归分析图,可以看到实测值与网络预测值的相关系数达到 $R = 0.998$,再次证明所建立的BP网络的训练是成功的.图9(b)为测试样本的线性回归分析图,从图9(b)中可观察到对于测试样本其实验值与网络的预测值的相关系数达到了 $R = 0.993$.这一结果充分证明了

所建立的网络对测试样本的预测是非常成功的.图9(c)为验证样本的线性回归分析图,验证数据作为另外1组独立的数据来验证本文所建立的BP神经网络的泛化能力,从其线性回归分析图中可看到,BP神经网络的预测值与实验值的相关系数 $R = 0.996$.进一步证实了本文所建立的BP神经网络具有一定的泛化能力.除了相关系数之外,表5中描述的为3组数据的最佳线性拟合,其中 T 表示目标电压值,即实验中实测的电压值, Y 表示预测电压值.






图8 误差曲线(验证样本)

表5 各组实验数据的最佳线性拟合


实验组	电压的最佳线性拟合
训练样本	$Y = 0.9967T + 0.2465$
测试样本	$Y = 0.9837T + 1.8383$
验证样本	$Y = 0.9867T + 0.6572$



(a) 训练样本回归分析



(b) 测试样本回归分析



(c) 验证样本回归分析

图9 3组实验回归分析

4 结论

上述的仿真结果表明,本文所采用的基于遗传算法优化的BP神经网络的方法实现质子交换膜燃料电池复杂非线性系统的动态仿真是完全可行的,网络的仿真值与实验的实测值具有较高的拟合精度.利用遗传算法优化的BP神经网络建立质子交换膜燃料电池电堆电压的输出特性模型,得到以下结论:1) 可避免机理建模中繁琐的非线性微分方程的计算求解,能够较好地反映出系统输出动态特性;2) 针对BP神经网络的初始权值和阈值通常无法准确获得而对网络的训练造成较大影响这一问题,通过引入遗传算法,来优化网络的最佳初始权值和阈值,从而使BP神经网络获得更好的训练结果,使得网络获得较高的预测精度和良好的泛化能力;3) 本文所使用的建模方法还可适用于燃料电池的系统设计,并对其优化和控制等领域有一定的参考价值.

5 参考文献

- [1] 郑怡颖,赵治国.车用质子交换膜燃料电池动态建模与仿真[J].机械与电子,2012(4):53-57.
- [2] Marcos V,Moreira,Gisele E da Silva. A practical model for evaluating the performance of proton exchange membrane fuel cells [J]. Renewable Energy,2009,34: 1734-1741.
- [3] Amphlett J C,Baumert R M,Mann R F,et al. Performance modeling of the Ballard Mark IV solid polymer electrolyte fuel cell(I. mechanistic model development) [J]. Electrochemical Science and Technology,1995,142: 1-8.
- [4] Springer T E,Zawodzinski T A,Gottesfeld S. Polymer electrolyte fuel cell model [J]. Journal of Electrochemical Society,1991,138: 2334-2342.
- [5] Lee J H,Lalk T R. Modeling fuel cell stack systems [J]. Journal of Power Sources,1998,73: 229-241.
- [6] Jemi S,Hissel D,Pera M C,et al. On-board fuel cell power supply modeling on the basis of neural network methodology [J]. Journal of Power Sources,2003,124: 479-486.
- [7] 徐腊梅. 质子交换膜燃料电池模拟与优化 [M]. 北京: 国防工业出版社,2012.
- [8] Markku O,Kauko L. Validation of genetic algorithm results in a fuel cell model [J]. Journal of Hydrogen Energy,2010,35: 618-625.
- [9] 史峰,王辉,郁磊,等. MATLAB 智能算法 [M]. 北京: 北京航空航天大学出版社,2011.
- [10] Ogaji S,Singh R,Pilidis P. Modeling fuel cell using artificial intelligence [J]. Journal of Power Sources,2006,154: 192-197.
- [11] 张德丰. MATLAB 神经网络编程 [M]. 北京: 化学工业出版社,2011.
- [12] Chavez-Ramirez A U,Munoz-Guerrero R. High power fuel cell simulator based on artificial neural network [J]. Hydrogen Energy,2010,35: 125-123.
- [13] Napoli G,Ferraro M,Sergi F,et al. Data driven models for a PEM fuel cell stack performance prediction [J]. Hydrogen Energy,2013,38: 628-638.
- [14] 关潮辉,丁树良. 基于 IRT 模型的 BP 神经网络参数估计的进一步研究 [J]. 江西师范大学学报: 自然科学版,2014,38(4): 434-436.
- [15] 周开利,康耀红. 神经网络模型及其 MATLAB 仿真程序设计 [M]. 北京: 清华大学出版社,2005.
- [16] 于鹏,王京. 数据插值技术对基于遗传编程算法符号回归的影响研究 [J]. 江西师范大学学报: 自然科学版,2014;38(3): 286-289.
- [17] Saengrungs A,Abtahi A,Zilouchian A. Neural network model for a commercial PEM fuel cell system [J]. Journal of Power Sources,2007,172: 749-759.

The Simulation Study on Dynamic Characteristics of PEMFC Based on BP Neural Network Optimized by Genetic Algorithm

JIAN Qifei,WU Hao

(College of Mechanical & Automobile Engineering ,South China University of Technology ,Guangzhou Guangdong 510640 ,China)

Abstract: For a 2 kW PEMFC stack power system of a lightweight electric vehicle using BP neural network which have be optimized by genetic algorithm ,the model of the characteristic of voltage output of the stack is established , and part of the measured data of the PEMFC is taken as the training samples of the BP neural network that be optimized by genetic algorithm to train the network. Then using the trained neural network model ,the output voltage of the system is predicted and compared with the test data. The result show that the maximum relative errors between the network predicted voltage and the measured output voltage are keep in 4% .

Key words: PEMFC; genetic algorithm; BP neural network; model of voltage output

(责任编辑: 王金莲)