

文章编号:1000-8055(2011)07-1672-09

神经网络在无人机电控活塞发动机试验中应用

郭荣化, 吴玉生, 陈庆荣

(中国华阴兵器试验中心, 陕西 华阴 714200)

摘 要: 分析了无人机电控活塞发动机试验特点以及试验中存在的难点, 针对电控发动机高海拔标定试验中进气歧管压力(manifold air pressure, 简称 MAP)传感器数据的传统线性插值方法不能完全表述电控发动机非线性特性的缺陷, 提出采用 BP(back propagation)神经网络模型的解决方案. 为避免目前应用神经网络方法中所存在的不足, 通过采用原始数据分组方法进行网络训练误差的实时反馈和控制, 较好地解决了神经网络训练过程中容易陷入“局部最优”和“过拟合”状态, 并对 BP 神经网络预测结果给予了详细研究, 训练误差和预测误差分析结果表明了该方法的可行性和计算结果的可信性.

关 键 词: 标定试验; 神经网络; 电子控制单位参数; 无人机; 电控活塞发动机

中图分类号: V434.3

文献标志码: A

Application of neural networks in the test for electronic-controlled gasoline engine of unmanned aerial vehicle

GUO Rong-hua, WU Yu-sheng, CHEN Qing-rong

(Huayin Ordnance Test Center of China, Huayin Shaanxi 714200, China)

Abstract: The characters and difficulties in the test for electronic-controlled gasoline engine of unmanned aerial vehicle (UAV) were analyzed in detail. For mending the traditional liner interpolation methods, which are not completely in conformity with nonlinear characteristics of electronic-controlled gasoline engine, a solution was applied in the predication for the manifold air pressure (MAP) of high-altitude calibration of electronic-controlled gasoline engine, by adopting back propagation (BP) neural networks. To avoid the limitation of neural networks in application at present stage, a grouping method of raw-data was put forward to control the feedback of the training error in real-time; this method provided a good solution for the problem that the neural network training result easily leads to the situation of “local optimum” and “over-fitting”. The prediction results based on BP neural networks have been studied thoroughly; and the results of the training error and the prediction error reveal that the method is feasible and the result is effective.

Key words: calibrating test; neural networks;
parameters of electronic-controlled unit (ECU);
unmanned aerial vehicle (UAV); electronic-controlled gasoline engine

1 无人机电控发动机试验特点和难点

小型航空活塞电控发动机采用燃油喷射系统

以一定的压力将燃油喷入发动机进气歧管或气缸, 电子控制单元(ECU)综合利用各种传感器输入的信息进行数学运算和逻辑判断, 对各个工况下所需的燃油量进行实时计算处理, 并能根据不

收稿日期:2010-06-23; 修订日期:2011-03-04

作者简介:郭荣化(1979—), 男, 湖南永州人, 工程师, 硕士, 从事无人机及其动力系统试验技术研究.

同工况修正点火提前角,可使发动机在各个工况下的混合气浓度达到最佳状况,发动机电子控制系统主要由传感器、电子控制单元和执行器三部分组成,如图 1 所示。




图 1 无人机电控发动机系统组成

Fig. 1 System of electronic-controlled gasoline engine of unmanned aerial vehicle

电控发动机具备提升发动机功率、改善经济性和工作可靠性,提高无人机续航时间、加速性能,并兼有为无人机提供稳定的怠速动力和优良的低温起动性能等优点,能满足目前低速无人机发展中对动力系统日益严格的要求,是未来中小型无人机动力系统发展的一种趋势。

无人机用发动机工作时环境变化较大,主要表现在高度和工作环境温度上,随着飞行高度升高,空气密度变小,发动机绝对背压下降,动力性也随之下降。如我国自行研制的 HS-700 小型二冲程航空发动机工作高度为 0~6 km 范围时,额定功率减少近 50%,燃油消耗率增加约为 15%,故此,在电控发动机试验中需要将地面和台架试验中飞行高度以及其他参数经过一定换算准则修正到无人机各种使用高度的工作情况。

按照理论上的要求,如若能获取发动机在无人机使用中各种环境和工况下的控制参数,然后制成电控发动机查询用的进气歧管压力(manifold air pressure,简称 MAP)/进气压力传感器是最优的,但是这种理论需求实际上无法实施:

1) 电控发动机在每一工况和使用高度都进行试验,以此来获得 MAP,需要进行难以估计的地面和台架试验量,导致试验周期无限延长,成本高,工程上难以应用;

2) 无人机电控发动机使用高度为几千米不等,在海拔 5000 m 以上进行发动机台架试验十

分困难,在尚未试验的使用高度和工况,需采用一定的算法对 MAP 进行换算。

故此,解决上述问题的传统方法一般是采用在有限个工况点的台架试验数据基础上,进行线性插值,以此来获得 MAP 图,对于无法标定的海拔高度,进行线性插值外推的办法。如果发动机所处的工况不在已知的节点,单参数可以按照线性插值方法,两参数可以采用二维线性插值方法,也可以利用目前应用一些数值工程软件来进行计算。这种办法的优点是简单易行,但是电控发动机作为控制对象,发动机的输入(节气门开度、喷油时间、点火提前角、海拔高度等)与其输出(动力性、经济性、排放指标等)之间是一种强耦合非线性、非稳态及不适应性的动力学系统关系,简单的线性插值外推方法把这种复杂非线性函数变化关系假设成特定的非线性或者线性关系,这在理论上存在一定的缺陷。

2 神经网络的应用和缺点

人工神经网络(artificial neural networks,简称 ANN)方法可以在一定程度上避免这种理论缺陷,利用神经网络本身反映事物的非线性变化规律来直接对事物的非线性特性进行估计。

神经网络的结构类型很多,多层前向网络应用较为广泛,其中最常用的两种是 BP(back propagation)神经网络和 RBF(radial basis function)神经网络,另外还有基于这两种网络的多种改进模型。文献[1]通过仿真结果指出:采用局部激励函数的 RBF 网络“泛化”能力在多个方面都优于 BP 网络,但是在解决具有相同精度要求的问题时,BP 网络的结构要比 RBF 网络简单;当已知的数据量比较少的时候用 BP 网络不能很好地反映实际情况,采用 RBF 网络效果较好,但当训练样本增多时,RBF 网络的隐层神经元数远远高于前者,使得 RBF 网络的复杂度大大增加,结构过于庞大,从而运算量也有所增加。本文所要解决的问题样本量较大,初始数据共有 315 组,而且经过初步试用 RBF 网络,训练误差较大,基于上述原因,本文选择采用 BP 网络。

在理论上已经证明,一个具有三层的 BP 网络,当其中隐单元的数不加限制时,它可以以任意精度逼近任何一个非线性函数^[2]。故此,在没有准确数学模型的情况下,应用 BP 神经网络进行电控 MAP 优化,能达到发动机在整个工况范围内稳定工作且具有良好控制性能。应用神经网络方

法进行发动机电控系统喷油换算的另一个原因是在电控发动机进行高海拔试验的时候,构建了室外测试体系,相对室内环境信息采集受环境和各种因素影响,数据可能存在不完整或者含有干扰、伪缺、错误和不确定信息,不能完全精确反映发动机真实性能和状况,这也给传统插值和回归处理造成很大困难。而神经网络对信息的处理具有自学习、分布-记忆、自联想、容错性和高度非线性映射能力,对这种信息含糊、不确定、有干扰和假象的复杂情况可以通过不断学习,做出合理的决策、估计和有效的预测。

目前,神经网络方法在发动机试验和控制方面,有很多研究成果,如文献[3-4]提出了利用BP神经网络和RBF神经网络对试飞数据进行处理;文献[5-8]利用神经网络方法对发动机燃油消耗率、怠速和扭矩等进行了预测和控制;文献[9-11]将神经网络方法应用到电控发动机标定试验中。但上述研究中,都没能很好地解决神经网络方法本身存在一些缺点:无法较好地避免神经网络容易陷入局部极小(local minimum);没有很好的解析式来表示如何选取BP网络的隐含节点数;已学习好的网络的泛化能力较差等问题。这些不足,给神经网络应用带来很大不便。

本文从无人机用电控发动机试验参数获取入手,依据电控发动机试验数据的具体情况出发进行BP神经网络建模;利用试凑法确定网络拓扑结构,保证了较好的训练效果;采用先进的试验数据分组方法,较有效地克服了局部极小和泛化能力差的问题。

3 试验数据获取和神经网络模型建立

在工程应用领域中,应用BP神经网络的好坏很大一部分工作需要进行输入特征选择和训练样本集的准备,若样本集代表性差、矛盾样本多、数据归一化存在问题,那么,使用多复杂的综合算法、多精致的网络结构,建立起来的模型预测效果不会多好。

这里主要包括试验方法的选择,通过试验获得原始数据,并在此基础上进行数据分析、变量选择及对数据进行预处理等。本文研究对象是HS-700发动机高海拔电控喷油参数MAP的优化,喷油时间 t 受发动机转速 n 、节气门开度 φ 、海拔高度 H 、点火提前角 θ 、进气温度 T 等参数影响,由

于发动机的结构复杂,影响喷油时间的因素较多,同时还承受一些不确定因素的干扰,本文选择影响喷油的主要因素:汽油机工况的转速 n 、节气门开度 φ 和反应海拔高度变化的大气压力 p ,3个参数来作为神经元输入,以此确定输出神经元喷油脉宽 t ,神经网络输入和输出关系如式(1)所示。

$$t = f(n, \varphi, p) \quad (1)$$

本文神经网络原始训练数据,来源于在海拔400,2140,3000,4233m四个不同高度、七根螺旋桨对HS-700发动机电控喷油脉宽标定的315组数据,试验设备和试验具体过程在此不做详细介绍,主要测试体系如图2所示。

从理论上讲,BP神经网络对其输入无限制,但由于样本的各个参数不相同,发动机转速、风门开度、喷油时间等的数量级差别很大,为了一开始就使各变量的重要性处于同等地位,能使网络所有权值都在一个不太大的范围之内,对样本进行归一化处理,以此来减轻网络训练时的难度,所谓归一化是指把某向量除以该向量的长度,使其长度等于一。

本文将神经网络数据首先归一化为均值为0,方差为1的范围内,采用归一计算方法如式(2)所示。

$$y = (y_{\max} - y_{\min}) \times \frac{x - x_{\min}}{x_{\max} - x_{\min}} + y_{\min} \quad (2)$$

式中 $y_{\max}$ 和 $y_{\min}$ 为该变量可能达到的最大和最小的实际值; $x_{\max}$ 和 $x_{\min}$ 分别为与 $y_{\max}$ 和 $y_{\min}$ 相对应的标定后的值,对单极性sigmoid函数而言,为0.9和0.1,对双极性sigmoid函数为0.9和-0.9。

y 为实际 x 的标定值,即训练样本输出的期望值。

运行时,再按下式由网络值 y 算出实际值 x ,式中各参数含义和上述相同。

$$x = (x_{\max} - x_{\min}) \times \frac{y - y_{\min}}{y_{\max} - y_{\min}} + x_{\min} \quad (3)$$

隐层设计是指确定网络隐层层数和隐单元的数目,因为BP网络的输入层和输出层是由实际需要解决的问题所确定,可以改变的仅为隐含层的层数和各隐含层的单元数。对隐含层和节点数的设计问题,有些文献提出了一些经验公式的办法,但是经验公式的办法针对不同的问题效果不尽一致,为此本文采用隐含层数和隐单元数动态




图 2 电控活塞发动机试验测试体系

Fig. 2 Test system for electronic-controlled gasoline engine

变化的“试凑法”来进行网络拓扑结构的设计,首先确定隐含层为 1 层,然后依次递增 1 层,在每层控制隐单元数变化,综合考虑不同结构的训练误差和“泛化”能力来确定最后的网络拓扑结构。

控制隐单元数目的变化时,通常的做法是:首先使隐单元的数目可变,放入足够多的隐单元,通过学习将那些不起作用的隐单元剔除,直到不可收缩为止。另一种做法正好相反:在开始时放入比较少的神经元,学习到一定次数后,如果不成功则再增加隐单元的数目,直到达到比较合理的隐单元数目为止。但是第一种方法容易使网络出现“过拟合”状态,故此本文选用第二种方法,经过反复试凑,确定对本文问题具备较为优良的网络隐层数为 3,隐层节点数分别为:20,16,13。输入为发动机转速、节气门开度和大气压力的 AD(analog-to-digital)值,输出为喷油脉宽时间,网络拓扑结构为:3×20×16×13×1。前面隐含层拥有较多的单元数,可以对网络功能有所改善。

各层神经元中间传递函数通常采用 sigmoid 型函数,一般是 log-sigmoid 型函数或 tan-sigmoid 型函数,log-sigmoid 型函数的输入值可取

任意值,输出值在 0 和 1 之间;tan-sigmoid 型函数的输入值可取任意值,输出值在 -1 和 1 之间。本文各隐层间传递函数分别采用的是线性函数、log-sigmoid 型函数和线性函数。

训练方法采用 Levenberg-Marquardt 反传算法,该方法具备稳定、收敛速度快的优点,缺点需求内存大。该算法的权值调整率选取为^[12]

$$\Delta w = (J^T J + \mu J)^{-1} J^T e \quad (4)$$

式中 J 为误差对权值微分的 Jacobian 矩阵; e 为误差向量; μ 为自适应调整的学习率。当式中 μ 较大时,接近于梯度下降法,当 μ 较小时,变成了 Gauss-Newton 法。

4 神经网络模型训练终止控制

值得注意的是神经网络计算不能一味地追求训练误差最小,这样很容易出现过拟合,导致预测能力降低。一般情况下,训练能力差时,预测能力也差,并且一定程度上,随训练能力的提高,预测能力也提高。但这种趋势有一个极限,当达到此极限时,随训练能力提高,预测能力反而下降,即出现所谓“过拟合”现象。此时,网络学习了过多的样

本细节,而不能反映样本内含的规律.在实际应用中,应结合物理工程背景进行适当控制.

为此,本文采用先进的数据分组思想,在训练过程设置不同的控制条件,使网络能跳出局部极小点而收敛于全局极小点,能同时较好地保证神经网络模型训练效果和预测能力.具体做法为:在315组数据中,随机抽取60%组数据作为网络训练数据(train-data);随机抽取20%组数据作为训练过程中检验和修正数据(validation-data);剩下20%组数据作为网络预测(test-data).原始数据分类可以依据情况,选取不同比例,但是基本原则应该保证较多的数据量进行网络训练才能保证良好的效果.值得指出的是,validation-data和test-

data是有本质区别的,其中前者是在训练过程中不断提供给网络训练修正,实时参与训练过程,具备控制网络“泛化”性能的作用;而后者只是在网络训练完成后,进行检验网络训练效果,不参与网络训练,对网络结构和能力不起作用,但可以用于训练效果和网络误差分析.

BP神经网络进行自我训练结束的判决条件主要有:①最大训练次数;②最大训练时间;③训练误差达到要求;④validation-data误差持续增加的训练次数超过net.trainParam.maxfail参数.上述条件任意一个发生,训练都将终止.神经网络的样本学习过程实质就是一个运用最优化算法求取极值的运算过程,详细的训练过程如图3所示.




图3 神经网络训练控制流程

Fig. 3 Control process of training neural network

5 神经网络模型输出误差分析

5.1 网络训练误差分析

神经网络模型和大多数优化算法一样,随着每次选取的初值不同,运算结果也会有所不同.这是神经网络的固有特性,为此需要找出训练结果良好的网络,来进行实际应用.本文选取的网络训练结果较为理想,训练终止的条件是正常的

validation-data 误差引起,如图4所示.

因为将原始数据分为训练、验证和测试数据三类,分别为60%,20%和20%,在网络训练过程中三类数据误差逐渐减少,当在第6次训练过程后,训练数据的误差达到了0.001,验证数据的误差达到了0.023382,这种误差已经足够满足一般工程要求的喷油脉宽精度,随后的训练次数中train-data 误差减少非常缓慢,而 validation-data




图 4 BP 神经网络训练终止图

Fig. 4 Photos which BP neural networks finished the training

误差略有增加(net. trainParam. maxfail 参数为 6, 即连续 6 次训练中检测 validation-data 误差是否有增加,若出现增加则表明网络出现了“过拟合”状态,网络训练在第 7~12 次训练中持续出现 validation-data 误差增加,此时为了防止网络的‘过拟合’状态而训练终止). Test-data 误差在第 6 次后反而有所增加,超过了训练误差(图 5 所示),即在第 6~12 次训练中出现了“过拟合”状态,故此在第 6 次训练完成后,是较好的训练网络. 训练过程和三组数据误差变化如图 5 所示.




图 5 BP 神经网络训练误差结果

Fig. 5 Training-error of BP neural networks

BP 网络训练的目标是:网络由采集的发动机转速 n 、节气门开度 φ 、海拔高度气压 AD 值所预测的喷油脉宽 t_i 值,和实际喷油的时间 t_0 之间误差最小. 采用回归估计来判断误差,数学上常用表示的总变异平方误差,其值为变异平方和和残差平方和相加,如下式所示^[2]:

$$S^{\text{st}} = \sum_{i=1}^n (t_i - \bar{t})^2 = \sum_{i=1}^n (\bar{t} - \hat{t}_i)^2 + \sum_{i=1}^n (t_i - \hat{t}_i)^2 = S^{\text{sr}} + S^{\text{se}} \quad (5)$$

式中 i 和 n 为输入数据个数分别为第 i 个和第 n 个; t_i 为第 i 个输入的喷油脉宽; $\bar{t}$ 为输入数据的平均喷油脉宽; $\hat{t}_i$ 表示第 i 个最优估计喷油脉宽.

那么复测定系数(拟合优度系数) R 为^[2]

$$R^2 = S^{\text{sr}} / S^{\text{st}} \quad (6)$$

式中 R 是衡量神经网络模型好坏的参数之一, R 越接近 1, 这表示训练中误差越少,拟合度越高. 比如此次训练完成的网络中,训练数据的 R^2 为 0.99, 这表示用于训练的数据中,平均能有 99% 的数据被神经网络准确表示出来. 图 6 给出了用于 BP 神经网络的 train-data 和 validation-data 的拟合情况和 R 值. 可以看出网络效果是非常显著和稳定的,能输出接近的期望值. 另外, validation-data 和 test-data 误差都很小,误差值也较为接近,除了表示网络具备良好的泛化能力外,也说明了训练中数据分类和随机抽取的效果是成功的.

BP 网络最有价值的是它的泛化能力,即网络输入训练学习“未曾见过”的数据时,利用网络各点之间的权值和传输函数,也能给出正确映射,如图 6 所示,对 validation-data 的预测能力达到了 97.44%, test-data 的 R 值为 0.99436, 即网络对测试数据的预测能力达到 98.88%. 故此,利用 BP 训练好的网络,来作为换算模型是可行的,其结果能满足精度要求.

5.2 HS-700 发动机电控喷油地面试验与飞行

高度试验数据换算误差分析

利用上述训练好的 BP 网络,将节气门开度、转速和海拔高度的气压 AD 值作为神经网络的输入,由训练好的神经网络预测在各种海拔高度的喷油脉宽,以及进行各种海拔换算.

通过 BP 网络检验海拔 400m 和 2000m 的试验数据,对应用模型换算数据和实际试验测试的数据比较,绝大部分预测值的喷油误差控制在 ± 0.4 ms 以内,极个别工况点的误差稍大,但最大的喷油时间误差也只有 1.43ms,误差如图 7 和

图 8 所示. 通过神经网络模型, 可以获得无人机飞行中各种海拔高度的 MAP 图及相对海拔高度 400 m 的喷油量修正参数. 如图 9 和图 10 给出了

2000 m 海拔高度的喷油 MAP 和修正量.

对 5000, 6000 m 尚未标定的海拔高度的喷油 MAP 进行换算, 如图 11 和图 12 所示, 喷油脉宽




图 6 训练数据拟合误差

Fig. 6 Fitting-error of training-data




图 7 海拔 400 m 神经网络计算误差分布

Fig. 7 Distribution of calculation error of BP neural networks at 400 m above sea level




图 8 海拔 400 m 神经网络计算误差

Fig. 8 Calculation error of BP neural networks at 400 m above sea level

随着海拔高度上升,而逐渐缩短,趋势和分析是一致的.在6000 m的时候,换算的喷油脉宽基本保持在3~8.5 ms之间,其结果是可信的.并根据神

经网络模型换算结果和基本喷油 MAP 比较,可以得到在各个海拔高度的喷油脉宽修正参数,如图13和图14所示.




图9 海拔2000m神经网络计算 MAP

Fig. 9 Calculation MAP of BP neural networks at 2000m above sea level




图12 海拔6000m神经网络计算 MAP

Fig. 12 Calculation MAP of BP neural networks at 6000m above sea level




图10 海拔2000m喷油脉宽修正量

Fig. 10 Correction quantity of fuel injection at 2000m above sea level




图13 海拔5000m喷油脉宽修正量

Fig. 13 Correction quantity of fuel injection at 5000m above sea level




图11 海拔5000m神经网络计算 MAP

Fig. 11 Calculation MAP of BP neural networks at 5000m above sea level




图14 海拔6000m喷油脉宽修正量

Fig. 14 Correction quantity of fuel injection at 6000m above sea level

6 结 论

电控发动机在无人机飞行时能否发挥出优良的性能,关键取决于电控系统与发动机的台架和地面试验数据。本文介绍了无人机用电控发动机试验特点,以及在电控发动机试验中如何实现地面台架试验数据和空中飞行数据的换算模型的建立和应用,并通过数据分组实时控制 BP 神经网络误差的办法,较好地避免神经网络易出现“局部最小”和“过拟合”的缺点,误差结果证明换算模型和结果是可行和可信的。

由于该方法不需要对发动机进行具体数学建模,对于发动机复杂非线性系统,而且目前无成熟准确数学模型可采用时,不失为一种简单有效、经济可行的电控发动机试验处理手段;同时,神经网络在小型航空活塞电控发动机试验中的成功应用,也可为试验中尚无准确数学模型的试验数据预测、折算(如无人机地面试验和空中飞行试验数据换算、射表试验中用小射程的外弹道试验来预测远射程弹道特性)等同类问题的解决办法,提供了一定参考和借鉴意义。

致谢:

本论文的撰写过程中受到西安交通大学曾科教授悉心指导,在此谨向曾老师表示衷心的感谢和崇高的敬意;同时感谢西北工业大学爱生技术集团公司提供试验环境以及在试验期间的大力支持。

参考文献:

- [1] 刘永,张立毅. BP 和 RBF 神经网络的实现及其性能比较[J]. 电子测量技术, 2007, 30(4): 77-80.
LIU Yong, ZHANG Liyi. Implementation of BP and RBF neural network and their performance comparison[J]. Electronic Measurement Technology, 2007, 30(4): 77-80. (in Chinese)
- [2] 张恒喜,郭基联,朱家元,等. 小样本多元数据分析方法及应用[M]. 西安:西北工业大学出版社, 2002.
ZHANG Hengxi, GUO Jilian, ZHU Jiayuan, et al. Multivariate data analysis methods and applications with few observations[M]. Xi'an: Northwestern Polytechnical University Press, 2002. (in Chinese)
- [3] 李映颖,朱立贵,张德全,等. 基于 BP 和 RBF 神经网络对试飞数据预处理比较研究[J]. 计量与测试技术, 2009, 36(2): 1-2.
LI Yingyi, ZHU Ligui, ZHANG Dequan, et al. The pre-treatment of the pre-processing data with BP and RBF neural network[J]. Metrology & Measurement Technique, 2009, 36(2): 1-2. (in Chinese)
- [4] 叶志锋,杨固东,苏伟生. 基于试车数据的发动机神经网络模型[J]. 南京航空航天大学学报, 2007, 39(1): 26-29.
YE Zhifeng, YANG Gudong, SU Weisheng. Neural network model of aeroengine based on experimental data[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2007, 39(1): 26-29. (in Chinese)
- [5] Kara T N, Baysec S. Prediction of torque and specific fuel consumption of a gasoline engine by using artificial neural networks[J]. Applied Energy, 2010, 87(1): 349-355.
- [6] 任天睿. 基于 BP 神经网络模型的发动机怠速预测控制[D]. 南京:南京理工大学, 2003.
REN Tianrui. The idle speed control-model of engine based on BP neural network[D]. Nanjing: Nanjing University of Science and Technology, 2003. (in Chinese)
- [7] Sayin C, Ertunc H M, Hosoz M, et al. Performance and exhaust emissions of a gasoline engine using artificial neural network[J]. Applied Thermal Engineering, 2007, 27(1): 46-54.
- [8] 邓元望,张邦基,龚金科,等. CFA6470HEV 发动机燃油经济性的 BP 神经网络建模及优化[J]. 汽车工程, 2009, 31(2): 141-145, 155.
DENG Yuanwang, ZHANG Bangji, GONG Jinke, et al. BP neural network modeling and optimization on engine fuel economy of CFA6470HEV[J]. Automotive Engineering, 2009, 31(2): 141-145, 155. (in Chinese)
- [9] Hou X, Gong X, Du C, et al. Calibration and optimization for electronically controlled parameters of gasoline engine based on the RBF neural network[J]. China Mechanical Engineering, 2009, 20(18): 2264-2267.
- [10] 刘鑫. 基于神经网络的汽油机电控标定技术研究[D]. 武汉:武汉理工大学, 2008.
LIU Xin. Study on calibration technology for electronic controlled gasoline engine based on neural network[D]. Wuhan: Wuhan University of Technology, 2008. (in Chinese)
- [11] 张翠平. 电控汽油机燃油喷射及点火控制系统的设计与实验研究[D]. 太原:太原理工大学, 2007.
ZHANG Cuiping. Design and experimental research of fuel injection and ignition control system for electronically controlled gasoline[D]. Taiyuan: Taiyuan University of Technology, 2007. (in Chinese)
- [12] Levenberg K. A method for the solution of certain nonlinear problems in least squares[J]. Quart. Appl. Math., 1944, 2(2): 164-168.