

文章编号: 1000-8055(2005)06-01061-05

航空发动机神经网络内模控制

张 鹏, 黄金泉

(南京航空航天大学 能源与动力学院, 江苏 南京 210016)

摘要: 基于神经网络内模控制理论研究了神经网络内模控制方法在航空发动机控制系统中的应用, 建立了基于 E l m a n 网络的航空发动机多变量内模控制系统。采用 E l m a n 网络建立发动机内模型和内模控制器, 详细介绍了建模、控制的算法及其实现过程。取部分飞行条件下的数据作为学习样本, 采用动态 B P 算法对神经网络权值进行调整, 并在飞行包线内其它工作点对整个控制系统进行了仿真。结果表明, 使用神经网络建立的航空发动机内模控制系统具有良好的控制品质和较强的自适应能力。

关 键 词: 航空、航天推进系统; 航空发动机; 内模控制; E l m a n 神经网络; 多变量控制

中图分类号: V 233.7

文献标识码: A

Application of Internal Model Control System Based on Neural Network in Aeroengine

ZHANG Peng, HUANG Jin-quan

(College of Energy and Power,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: The Internal Model Control (MC) system based on recurrent neural network and its application to aeroengines were studied. An aeroengine multivariable control system was developed using neural network MC method. Both the aeroengine internal model and the controller were constructed via E l m a n neural networks. A recurrent back-propagation algorithm was used to train the weights of the neural network and the control algorithm was analyzed. Numerical simulation results show the effectiveness of this method and self-learning ability of the system.

Key words: aerospace propulsion system; aeroengine; Internal Model Control (MC); elman neural network; multivariable control

航空发动机是一个复杂的非线性动力系统, 其控制系统的研究一直是国内外发动机领域的工作重点。随着发动机控制参数的增加和控制目标的复杂化, 传统的控制方法已经难以满足要求。利用人工神经网络对于复杂非线性不确定系统的自适应学习能力, 直接采用神经网络控制技术或者与其它控制技术相结合的方法^[1~3], 开辟了航空发动机控制系统设计的新途径。本文将内模控制

(Internal Model Control) 理论与神经网络技术结合, 提出了一种基于 E l m a n 神经网络的航空发动机内模控制方法, 利用 E l m a n 网络结构上的优势, 解决了由于前向静态网络对于高阶动态系统建模困难, 从而影响控制精度的问题。仿真结果表明, 此方法不需要发动机精确模型信息, 可以对内模型和控制器权值进行在线调整以适应被控对象的不确定性, 控制系统具有较好的鲁棒性和自适

收稿日期: 2005- 01- 25; 修订日期: 2005- 06- 06

作者简介: 张鹏(1979-), 男, 山东青岛人, 南京航空航天大学能源与动力学院博士生, 主要从事航空发动机控制研究

应能力。

1 E lman 神经网络原理

E lman 网络是一种典型的局部递归内时延反馈型动态神经网络,网络结构如图1所示。




图1 E lman 网络结构示意图

Fig 1 Architecture of elman neural network

E lman 网络除了包括前向网络所具有的输入层、隐层、输出层结构之外,还包含了与隐层节点数量相同的反馈结构单元。反馈结构单元用来记忆隐层单元上一时刻的输出值,可视为是隐层节点输出的一步延迟。

$$x(t) = f[W^3 x_c(t) + W^1 u(t-1)] \quad (1)$$

$$x_c(t) = \alpha x_c(t-1) + x(t-1) \quad (2)$$

$$y(t) = g[W^2 x(t)] \quad (3)$$

其中: $u(t) \in R^r$ 为网络的输入, W^1 为输入层至隐层的连接权矩阵, $x(t) \in R^h$, $x_c(t) \in R^h$ 分别为隐层和反馈结构层节点的输出, W^3 为反馈结构层至隐层的连接权矩阵, W^2 为隐层至输出层的连接权矩阵, $y(t) \in R^m$ 为网络的输出, $f(\cdot)$, $g(\cdot)$ 分别为隐层及输出层的激励函数。 $0 \leq \alpha < 1$ 为结构单元自连接反馈增益因子, $\alpha = 0$ 时, 网络为标准的 E lman 网络, $\alpha \neq 0$ 时, 为改进 E lman 网络。

假设网络在 τ 时刻的输出向量为 $y(\tau)$, 目标输出向量为 $y_d(\tau)$, 定义误差函数为:

$$E(\tau) = \frac{1}{2} [y_d(\tau) - y(\tau)]^T [y_d(\tau) - y(\tau)]$$

选择隐层与输出层的激励函数:

$$f(x) = \frac{1}{1 + e^{-x}}, \quad g(x) = x$$

采用动态BP算法^[4]计算各层网络权值的调整量:

$$\Delta w_{ji}^2 = \eta \delta_{x_j}(\tau)$$

$$(i = 1, 2, \dots, m; j = 1, 2, \dots, h) \quad (4)$$

$$\Delta w_{ji}^1 = \eta \delta_{u_q}(\tau-1)$$

$$(j = 1, 2, \dots, h; q = 1, 2, \dots, r) \quad (5)$$

$$\Delta w_{jl}^3 = \eta_b \sum_{i=1}^m (\delta_{w_{ij}^2}) \frac{\partial x_i(\tau)}{\partial w_{jl}^3}$$

$$(j = 1, 2, \dots, h; l = 1, 2, \dots, h) \quad (6)$$

其中: η , η_b 和 η 分别是连接权矩阵 w^1 , w^2 和 w^3 中元素的学习步长。

$$\delta_i = y_{d,i}(\tau) - y_i(\tau) \quad (7)$$

$$\delta_j = \sum_{i=1}^m (\delta_{w_{ij}^2}) f_j'(\cdot) \quad (8)$$

$$\frac{\partial x_i(\tau)}{\partial w_{jl}^3} = f_j'(\cdot) x_i(\tau-1) + \alpha \frac{\partial x_i(\tau-1)}{\partial w_{jl}^3} \quad (9)$$

2 航空发动机神经网络内部模型和内模控制器

考虑某型发动机中间状态以上的工作情况, 建立基于 E lman 神经网络的航空发动机多变量内模控制系统, 如图2所示。




图2 航空发动机转速神经网络内模控制系统

Fig 2 Scheme of neural network MC control system for aeroengine

控制系统参考输入指令: $y_r = [N_{1r}, P_{36r}]^T$, 控制量 $u = [W_{fm}, A_8]^T$, 输出 $y = [N_1, P_{36}]^T$ 。其中, N_{1r} 和 P_{36r} 分别为低压转子转速 N_1 以及高压转子出口与涡轮出口总压之比 P_{36} 的参考值, W_{fm} 为燃油量, A_8 为尾喷口面积。

在非线性系统的神经网络内模控制系统中, 被控对象的神经网络内模型(NNM)和内模控制器(NNC)的设计是整个系统的关键所在^[5]。对于航空发动机, 其数学模型可用差分方程表示如下:

$$y(\tau+1) = h[y(\tau), \dots, y(\tau-n), u(\tau), \dots, u(\tau-m)] \quad (10)$$

其中: $h(\cdot)$ 为未知非线性函数。

利用多层前向静态神经网络(如BP, RBF网络), 通过辨识方法建立如(10)式所描述的发动机数学模型, 其本质是一种变动态时间建模为静态空间建模的方法。对于未知阶次系统而言, 若假设

系统阶次较低,神经网络模型不能反映系统的特性;而随着系统阶次的增加,膨胀的网络结构使得网络的学习十分困难,且输入节点的增多使得网络对于外部噪声信号特别敏感,导致网络稳定性下降。相比之下,Elman 网络作为一种典型的局部递归神经网络,其结构内部存在反馈环节,无需使用过多的状态输入作为网络训练信号,而且可以以紧凑的格式保留系统以前的信息,并在网络中反映出所有的历史信息对当前系统响应的影响,因而更适合于非线性动态系统的辨识建模^[6]。

本文中采用 Elman 神经网络建立发动机的内模型(如图3)。为保证所建立的内模型在整个飞行包线内的通用性,对输入输出变量进行了相似处理,将在部分飞行条件下的所得到的数据换算至标准状况下^[7]。以各变量的设计点为基准,对输入输出数据进行归一化,消除由于变量的取值范围不同而导致的网络学习困难。




图3 发动机神经网络内模型

Fig 3 Neural network internal model of aeroengine

发动机神经网络内模型输入:

$$u(\tau) = [W_{fm}(\tau), A_{8}(\tau)]^T$$

$$y(\tau) = [N_1(\tau), P_{36}(\tau)]^T$$

输出:

$$\hat{y}(\tau+1) = [\hat{N}_1(\tau+1), \hat{P}_{36}(\tau+1)]^T$$

网络输入节点个数为4,输出节点个数为2,隐层的节点的个数按照在满足建模精度要求的前提下尽量少的原则,通过反复试凑的方法确定为11。定义误差函数:

$$E_{NNM} = (1/2) e_1^T e_1 =$$

$$(1/2) [y(\tau+1) - \hat{y}(\tau+1)]^T$$

$$[y(\tau+1) - \hat{y}(\tau+1)]$$

采用动态BP 算法实现对神经网络内模型权值的调整。

根据内模控制理论,在被控对象稳定的前提下,神经网络内模控制器(NNC)即被控对象的神经网络逆模型,否则为被控对象稳定部分的逆模

型^[5]。使用 Elman 网络建立神经网络内模控制器(见图2),其输入为转速与压比的参考量 $y_r(\tau)$,以及反馈误差信息 $e_2(\tau) = y_r(\tau) - y(\tau)$;输出为控制信号 $u(\tau)$ 。选取控制器的误差函数为:

$$E_{NNC} = (1/2) e_2^T e_2 =$$

$$(1/2) [y_r(\tau) - y(\tau)]^T [y_r(\tau) - y(\tau)]$$

按照使误差函数最小的原则,计算NNC 权值的修正量:

$$\begin{aligned} \Delta w_{ij}^{cl} &= \eta \frac{\partial E_{NNC}}{\partial w_{ij}^{cl}} = \\ &= \eta [y_r(\tau) - y(\tau)]^T \frac{\partial y(\tau)}{\partial w_{ij}^{cl}} = \\ &= \eta e_2^T(\tau) \frac{\partial y(\tau)}{\partial u} \frac{\partial u}{\partial w_{ij}^{cl}} \end{aligned} \quad (11)$$

其中: w_{ij}^{cl} 为神经网络控制器中 l 层的权值, η 为对应各层权值的学习步长。

在NNC 权值和阈值的计算方法(11)中包含了 $\partial y / \partial u$ 项的计算,对于类似航空发动机的复杂非线性系统, $\partial y / \partial u$ 往往不可直接求解,而神经网络内模型(NNM)经过训练后,已经可以很好反映系统的特性,因此使用 $\partial \hat{y}(\tau) / \partial u$ 代替 $\partial y(\tau) / \partial u$ 进行计算。根据已经建立的 Elman 神经网络内模型:

$$\hat{y}(\tau) = W^{I2} \cdot f[W^{I3} x_c(\tau) + W^{I1} u(\tau-1)]$$

以及图3中所确定的网络结构,可以计算:

$$\frac{\partial \hat{y}(\tau)}{\partial u} \approx \frac{\partial y(\tau)}{\partial u} =$$

$$\sum_{i=1}^{11} w_{1,i}^{I2} \cdot f_i(1 - f_i) \cdot w_{i,2}^{I1} \quad (12)$$

将(12)代入(11)中,计算神经网络控制器各层权值的修正量。

3 仿真结果及分析

采用可以进行飞行包线内各点动、稳态计算的某型涡扇发动机部件级非线性模型为研究对象,在对本文所提出的航空发动机神经网络内模控制系统进行仿真。航空发动机神经网络内模型采用离线训练与在线学习相结合的方法建立,首先使用飞行包线内部分工作条件下,采样周期 0.02 s,燃油量输入为方波信号,尾喷口面积在限制范围内取值条件下,发动机的输入输出响应数据作为训练样本,对神经网络内模型进行离线训练,并在包线内选取了典型的飞行条件对内模型的精度进行了检验。由检验结果(见表1)可以发现,采用 Elman 神经网络建立的发动机内模型输

出与发动机模型实际输出的相对误差不超过2%。在整个系统工作过程中,对于NNM 和发动机模型输出的误差值进行在线监控,当由于发动

表1 飞行包线内的发动机内模型精度检验

Table 1 Errors of the neural network internal model under different flight conditions within the full envelope

高度 H /km	马赫数 $M a$	相对误差/%
0	0.2	1.45
0	1.2	1.52
6	0.6	1.47
6	1.4	1.56
12	0.8	1.64
12	1.6	1.49
18	1.2	1.59
18	1.9	1.68

机特性变化或者外界干扰的存在,引起NNM 与发动机模型两者之间的相对误差值超过一定阈值 θ 时(本文中选取 $\theta=3\%$),在线的调整NNM 的参数,确保其对于发动机模型的跟踪精度。神经网络

控制器权值初始值为近似于零随机数,网络权值采用在线调整的方法,依据参考输入 y_r 与对象实际输出 y 的误差 e_2 ,以及由NNM 所构成误差反传通道提供的信息,计算权值的修正量,对控制器的权值进行调整。

在飞行包线内不同高度、马赫数条件下,参考输入指令为幅值5%的方波信号,对控制系统进行了仿真。图4(a)、图5(a)分别是在飞行条件 $H=6\text{ km}, M a=0.8$ 及 $H=10\text{ km}, M a=1.4$ 情况下,保持压比参考输入不变,转速输入为幅值5%的方波信号,发动机模型的响应曲线;图4(c)、图5(b)为保持转速参考输入不变,压比输入为幅值5%的方波信号的响应曲线。在飞行包线内的其它工作点进行仿真,同样得到了良好的控制效果,限于篇幅,此处没有一一列出。图6为发动机在 $H=12\text{ km}, M a=1.6$ 条件下,压比与转速参考输入同为5%的方波,发动机模型的仿真结果曲线。

由以上仿真结果可以看出,在包线内不同飞行条件下,整个控制系统都表现出了较好的动、静态性能,保证了较高的控制精度;神经网络内模型和内模控制器通过在线调整参数,具有良好的自适应能力,能够满足发动机非线性和不确定性的






图4 $H=6\text{ km}, M a=0.8$ 单变量方波输入响应曲线
Fig 4 Response of single square wave input at $H=6\text{ km}, M a=0.8$

图5 $H = 10 \text{ km}, M a = 1.4$ 单变量方波输入响应曲线Fig 5 Response of single square wave input at $H = 10 \text{ km}, M a = 1.4$ 图6 $H = 12 \text{ km}, M a = 1.6$ 双变量方波输入响应曲线Fig 6 Response of multiple square wave input at $H = 12 \text{ km}, M a = 1.6$

要求; 多变量控制表现出了良好的解耦效果。

4 结 论

研究了基于 Elman 神经网络的航空发动机内模控制方法, 使用 Elman 网络建立航空发动机的内模控制系统, 在某型号发动机模型上进行了仿真实验。结果表明: 在整个飞行包线内, 基于 Elman 神经网络的航空发动机内模控制系统表现出了较好的动、静态性能, 达到了较高的控制精度, 对于发动机的非线性和不确定性具有良好的适应能力, 且多变量控制亦具有较好的解耦效果。

参考文献

- [1] 黄金泉, 蔡红武, 孙健国. 航空发动机多变量三层神经网络控制[J]. 航空动力学报, 1999, 14(2): 192~194
HUANG Jin-quan, CAI Hong-wu, SUN Jian-guo. Multivariable Control for Aeroengine with 3-Layer Neural Networks [J]. Journal of Aerospace Power, 1999, 14(2): 192~194
- [2] 丁凯峰, 樊思齐. 基于 Adaline 网的航空发动机自适应控制

[J]. 推进技术, 2001, 22(1): 58~60

- DING Kaifeng, FAN Siqi. Aeroengine Adaptive Control Based on Adaline Network [J]. Journal of Propulsion Technology, 2001, 22(1): 58~60
- [3] 蒋衍君, 黄金泉. 航空发动机自适应神经网络 PD 控制[J]. 航空动力学报, 2000, 15(3): 334~336
JIANG Yan-jun, HUANG Jin-quan. Adaptive Neural Network PD Control for an Aeroengine [J]. Journal of Aerospace Power, 2000, 15(3): 334~336
- [4] Pham D T, Liu X. Training of Elman Networks and Dynamic System Modeling [J]. International Journal of Systems Science, 1996, 27(2): 221~226
- [5] Isabelle Rivals, Leon Peronnaz. Nonlinear Internal Model Control Using Neural Networks: Application to Processes with Delay and Design Issues [J]. IEEE Transactions on Neural Networks, 2000, 11(1): 80~90
- [6] Masumi I. Prediction of Time Series by a Structure Learning of Neural Network [J]. Fuzzy Set and System, 1996, 82(2): 167~176
- [7] Volponi A J. Gas Turbine Parameter Corrections [J]. Journal of Engineering for Gas Turbines and Power, 1999, 12(1): 613~621.