

文章编号: 1000-8055(2007)03-0490-05

基于自调整神经元的航空发动机 多变量自适应解耦控制

朱玉斌¹, 樊思齐¹, 张秀华², 李华聪¹

(1. 西北工业大学 动力与能源学院, 西安 710072;

2. 西北工业大学 电子信息学院, 西安 710072)

摘 要: 根据航空发动机性能控制要求, 通过分析自调整神经元及最速下降学习方法, 研究了基于自调整神经元的航空发动机多变量自适应解耦控制系统. 利用自调整神经元的结构简单、各神经元之间没有权值连接及在线学习的优点, 在线整定多变量 PID 控制器的参数. 阐明了该方法的结构和原理, 并进行了航空发动机多变量自适应解耦控制系统的设计. 大量的仿真结果表明, 系统具有良好的解耦特性和自适应能力.

关 键 词: 航空、航天推进系统; 航空发动机; 自调整神经元; 多变量控制; 解耦控制; 自适应控制

中图分类号: V233. 7

文献标识码: A

Multivariable adaptive decoupling control based on auto-tuning neurons for aeroengine

ZHU Yu-bin¹, FAN Si-qi¹, ZHANG Xiu-hua², LI Hua-cong¹

(1. School of Power and Engine,

Northwestern Polytechnical University, Xi'an 710072, China;

2. School of Electronics and Information,

Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: According to the requirements of aeroengine performance control, a new neural network called auto-tuning neurons and gradient descent learning method are presented. A multivariable decoupling control algorithm based on the auto-tuning neurons is used for aeroengine multivariable control systems in this paper. The main difference between an auto-tuning neuron and a general neuron is that there are adjustable parameters of the activation function used in an auto-tuning neuron. Unlike traditional fully connected neural network, there are no synaptic connections among the independent neurons. The emphasis is focused on the research of the algorithm and the properties of the controller, as well as their application to the aeroengine control by means of computer simulation. Finally the aeroengine multivariable control system is designed. Simulation shows that the system has perfect performance of decoupling and adaptive capabilities.

Key words: aerospace propulsion system; aeroengine; auto-tuning neurons;
multivariable control; decoupling control; adaptive control

收稿日期: 2006-03-09; 修订日期: 2006-10-08

作者简介: 朱玉斌(1977-), 男, 江西彭泽人, 西北工业大学动力与能源学院博士生, 主要从事航空推进系统控制研究.

现代航空发动机是一个复杂的非线性系统.在控制系统中,各变量和回路之间存在耦合作用.这种耦合作用会影响系统的稳态性能和动态性能.采用多变量控制^[1]是消除变量之间耦合的有效方法之一.而对于航空发动机这种复杂的非线性系统,基于常规的线性方法进行解耦控制器的设计难以满足实际系统的要求,而采用模糊解耦则存在模糊推理规则库缺乏行之有效的建立方法.

而神经网络由于具有高精度逼近任意的非线性函数、很强的自学习和自适应能力,因而广泛用于控制系统的建模、控制器的设计、故障诊断和系统优化^[2-5]等方面.常规的神经网络结构包括输入层、隐层和输出层,每一层包含若干个彼此相连的节点.因此,无论是前向网络还是反馈网络,一般都有较多的连接权.这在训练和计算过程中需要花费较多的时间去找到合适的连接权值.过多的连接权无疑也增加了硬件实现的复杂度.

本文针对航空发动机的性能控制,采用结构简单而有效的自调整神经元设计了基于自调整神经元的航空发动机多变量自适应解耦控制系统.利用自调整神经元在线整定 PID 控制器的参数.由于自调整神经元无相互连接权,结构得到大大的简化.

1 自调整神经元

自调整神经元 (Auto-tuning Neurons)^[6-8]是一种结构简单、彼此之间无相互连接权的神经元.因此,在任意两个自调整神经元节点之间没有连接权值.在本文的多变量自适应控制系统中,每一个神经元看成一个独立的自适应控制器.其神经元的个数和系统的输入变量的个数一致.其主要思想是在每个神经元应用自适应算法调整阈值和激励函数的参数.本文的激励函数为修正的双曲正切函数.自调整神经元的模型结构如图 1 所示.




图 1 自调整神经元的基本结构图

Fig. 1 Basic architecture of auto-tuning neuron

$I = [I_1, I_2, \dots, I_n]^T$ 为自调整神经元的输入, ϕ 为阈值, $O = [O_1, O_2, \dots, O_n]^T$ 为神经元的输出.其数学模型可描述为:

$$\begin{aligned} \text{net}(k) &= I(k) - \phi(k) \\ O(k) &= h(\text{net}) = a \cdot \frac{1 - e^{-b \cdot \text{net}}}{1 + e^{b \cdot \text{net}}} \end{aligned}$$

这里的激励函数 $h(\cdot)$ 为双曲正切函数, a 为双曲正切函数的饱和度, b 为倾斜度. 自调整神经元的激励函数的输出范围和曲线的形状主要由参数 a, b 决定. 图 2 为 a, b 对函数的输出范围和形状的关系. 图中实线表示 $a = 5, b = 0.5, 1, 5$ 时, b 对函数的输出范围和形状的关系. 虚线表示 $a = 3, b = 0.5, 1, 5$ 时 a, b 对函数的输出范围和形状的关系.




图 2 双曲正切函数与 a, b 的关系

Fig. 2 Modified Hyperbolic tangent functions for different a and b

令: $\theta = [\phi, a, b]^T$, 由上述数学模型可知, θ 代表神经元的可调参数. 通过在线调整 θ 使系统达到较好的控制性能. 由图 2 可知自调整神经元的输出没有限定在一个固定的间隔. 因此, 自调整神经元在实际应用中更加灵活和有效.

2 自调整神经元的学习算法

取性能指标:

$$\begin{aligned} J(k+1) &= \frac{1}{2} \sum_i^n [y_{di}(k+1) - y_i(k+1)]^2 = \\ &= \frac{1}{2} \sum_i^n e_i^2(k+1) \end{aligned}$$

式中: y_i 为系统的第 i 个输出, y_{di} 为系统的第 i 个期望输出. n 为系统输出个数. k 为神经元迭代的步数. $[O_{i1}, O_{i2}, O_{i3}]^T$ 表示第 i 个自调整神经元的输出.

根据链式求导规则, 可得:

$$\begin{aligned} \frac{\partial J}{\partial a_{im}} &= \left\{ \sum_i^n \frac{\partial J}{\partial y_i} \cdot \frac{\partial y_i}{\partial u_i} \right\} \frac{\partial u_i}{\partial O_{im}} \cdot \frac{\partial O_{im}}{\partial a_{im}} \\ \frac{\partial J}{\partial b_{im}} &= \left\{ \sum_i^n \frac{\partial J}{\partial y_i} \cdot \frac{\partial y_i}{\partial u_i} \right\} \frac{\partial u_i}{\partial O_{im}} \cdot \frac{\partial O_{im}}{\partial b_{im}} \\ \frac{\partial J}{\partial \phi_{im}} &= \left\{ \sum_i^n \frac{\partial J}{\partial y_i} \cdot \frac{\partial y_i}{\partial u_i} \right\} \frac{\partial u_i}{\partial O_{im}} \cdot \frac{\partial O_{im}}{\partial \phi_{im}} \end{aligned}$$

这里： a_{im} ， b_{im} ， ϕ_{im} 和 O_{im} 分别表示饱和度、改进后的双曲正切函数的形状、阈值大小和第 i 个神经元的输出。 u_i 表示第 i 个控制器输出。

由性能指标 J 可知：

$$\frac{\partial J}{\partial y_i} = -e_i$$

在大多数过程系统中,对于 u_i 和 y_i 来说,系统要么是正响应,要么是负响应^[6]。因此, $\partial y_i / \partial u_i$ 可用 $\text{sgn}(\partial y_i / \partial u_i) = 1$ 或 -1 代替。

由自调整神经元数学模型可得：

$$\begin{aligned} \frac{\partial O_{im}}{\partial a_{im}} &= \frac{O_{im}}{a_{im}} \\ \frac{\partial O_{im}}{\partial b_{im}} &= \frac{a_{im} \cdot \text{net}_{im}}{2} \cdot \left(1 + \frac{O_{im}}{a_{im}}\right) \cdot \left(1 - \frac{O_{im}}{a_{im}}\right) \\ \frac{\partial O_{im}}{\partial \phi_{im}} &= -\frac{a_{im} \cdot b_{im}}{2} \cdot \left(1 + \frac{O_{im}}{a_{im}}\right) \cdot \left(1 - \frac{O_{im}}{a_{im}}\right) \end{aligned}$$

根据最速下降法， a_{im} ， b_{im} ， ϕ_{im} 的权值调整方法如下：

$$\begin{aligned} a_{im}(k+1) &= a_{im}(k) + \eta_{im} \left\{ \sum_l^n e_l \cdot \text{sgn} \frac{\partial y_l}{\partial u_i} \right\} \cdot \frac{\partial u_i}{\partial O_{im}} \cdot \frac{O_{im}}{a_{im}} \\ b_{im}(k+1) &= b_{im}(k) + \eta_{im} \left\{ \sum_l^n e_l \cdot \text{sgn} \frac{\partial y_l}{\partial u_i} \right\} \cdot \frac{\partial u_i}{\partial O_{im}} \cdot \frac{a_{im} \cdot \text{net}_{im}}{2} \cdot \left(1 + \frac{O_{im}}{a_{im}}\right) \cdot \left(1 - \frac{O_{im}}{a_{im}}\right) \\ \phi_{im}(k+1) &= \phi_{im}(k) - \eta_{im} \left\{ \sum_l^n e_l \cdot \text{sgn} \frac{\partial y_l}{\partial u_i} \right\} \cdot \frac{\partial u_i}{\partial O_{im}} \cdot \frac{a_{im} \cdot b_{im}}{2} \cdot \left(1 + \frac{O_{im}}{a_{im}}\right) \cdot \left(1 - \frac{O_{im}}{a_{im}}\right) \end{aligned}$$

其中： $i = 1, 2$ ， $m = 1, 2, 3$ 。 η_{im} 为学习速率，当学习速率增大时，可以提高收敛速度，但易于产生振荡和不稳定。因此， η_{im} 值的选择要较为合适。

3 航空发动机自调整神经网络控制算法

3.1 航空发动机线性数学模型

某型涡扇发动机控制系统为双变量控制结构。选用供油量控制低压涡轮出口温度，尾喷管喉部面积控制涡轮的落压比。建立某型涡扇发动机相对增量形式的线性状态空间模型为：

$$\begin{pmatrix} \dot{n}_H \\ \dot{n}_L \end{pmatrix} = A \begin{pmatrix} n_H \\ n_L \end{pmatrix} + B \begin{pmatrix} m_f \\ A_8 \end{pmatrix}$$

$$\begin{pmatrix} T_5 \\ \pi_T \end{pmatrix} = C \begin{pmatrix} n_H \\ n_L \end{pmatrix} + D \begin{pmatrix} m_f \\ A_8 \end{pmatrix}$$

式中： A, B, C, D 为系数矩阵。 n_H 表示高压转子转速， n_L 表示低压转子转速， T_5 为低压涡轮出口温度， π_T 表示涡轮的落压比， m_f 表示主燃油供油量， A_8 表示尾喷管喉部面积。

3.2 基于自调整神经网络航空发动机控制系统的结构

图3为基于自调整神经元的航空发动机控制系统结构图。由图3可知，系统由PID控制器、自调整神经元和对象组成。通过神经元在线整定PID控制器的参数。自调整神经元的学习方法为最速下降法(Gradient Descent Method)。控制量为 $u(k)$ 。




图3 基于自调整神经元航空发动机控制系统结构图

Fig.3 Block diagram of control system based on auto-tuning neuron

由于图3控制器为PID控制器，故：

$$u_i = K_{pi} \cdot x_{i1}(k) + K_{ii} \cdot x_{i2}(k) + K_{di} \cdot x_{i3}(k)$$

且：

$$K_{pi} = O_{i1}, K_{ii} = O_{i2}, K_{di} = O_{i3} (i = 1, 2)$$

$$e_i(k) = y_{di} - y_i$$

$$x_{i1}(k) = e_i(k) - e_i(k-1)$$

$$x_{i2}(k) = e_i(k)$$

$$x_{i3}(k) = e_i(k) - 2e_i(k-1) + e_i(k-2)$$

其中：

$$y_d = [y_{d1}, y_{d2}]^T = [T_{5,r}, \pi_{T,r}]^T,$$

$$y = [T_5, \pi_T]^T$$

故：

$$\partial u_i / \partial O_{i1} = x_{i1}(k)$$

$$\partial u_i / \partial O_{i2} = x_{i2}(k), \partial u_i / \partial O_{i3} = x_{i3}(k)$$

4 航空发动机自调整神经网络控制系统仿真和结果分析

根据上述建立的基于自调整神经元的航空发动机多变量解耦自适应控制系统.利用已有的某型涡扇发动机气动数学模型建立小偏离增量形式的线性模型.以该航空发动机的地面状态 ($H=0$, $Ma=0$) 为仿真设计点,其归一化相对增量状态空间模型为:

$$\begin{pmatrix} \dot{n}_H \\ \dot{n}_L \end{pmatrix} = \begin{pmatrix} -2.2642 & -0.3802 \\ 2.96985 & -2.7508 \end{pmatrix} \begin{pmatrix} n_H \\ n_L \end{pmatrix} + \begin{pmatrix} 0.7128 & 1.0390 \\ 0.6345 & 1.6709 \end{pmatrix} \begin{pmatrix} m_f \\ A_8 \end{pmatrix}$$
$$\begin{pmatrix} T_5 \\ \pi_T \end{pmatrix} = \begin{pmatrix} -0.4276 & 0.1051 \\ 1.2810 & -0.0511 \end{pmatrix} \begin{pmatrix} n_H \\ n_L \end{pmatrix} + \begin{pmatrix} 0.5064 & 0.3028 \\ -0.1308 & 0.1567 \end{pmatrix} \begin{pmatrix} m_f \\ A_8 \end{pmatrix}$$

按照上述方法进行神经网络控制器的设计.通过在线学习整定 PID 控制器的参数,使系统达到满意的解耦控制效果.

在本文的设计中 η_1, η_2, η_3 为 a, b 和 ϕ 的学习效率,当学习速率加大时,收敛速度加快,但易使系统产生振荡和不稳.而学习速率减小时,收敛的速度较慢.因此需要折衷考虑,经过综合考虑,本文选择的 $\eta_1=0.35, \eta_2=0.20$ 和 $\eta_3=0.10$.




图 4 $Ma=0, H=0$, $T_{5,r}$ 阶跃响应

Fig. 4 Step response of $T_{5,r}$ at Mach 0 and 0

图 4 为在飞行条件 ($H=0$ km, $Ma=0$) 下, $T_{5,r}$ 阶跃时,即 $T_{5,r}=1, \pi_{T,r}=0$ 时,航空发动机 T_5 和 π_T 的响应图.图 5 为飞行条件 ($H=0$ km, $Ma=0$) 下, $\pi_{T,r}$ 为单位阶跃时,即: $T_{5,r}=0, \pi_{T,r}=1$ 时,发动机 T_5 和 π_T 的响应;图 6 和图 7 分别表示飞行条件为 $H=11$ km, $Ma=0.9$ 时, T_5 和 π_T 的阶

跃响应图;图 8 和图 9 分别表示飞行条件为 $H=20$ km, $Ma=1.7$ 时, T_5 和 π_T 的阶跃响应图.




图 5 $Ma=0, H=0$ km, $\pi_{T,r}$ 阶跃响应

Fig. 5 Step response of $\pi_{T,r}$ at Mach 0 and 0 km




图 6 $Ma=0.9, H=11$ km, $T_{5,r}$ 阶跃响应

Fig. 6 Step response of $T_{5,r}$ at Mach 0.9 and 11 km




图 7 $Ma=0.9, H=11$ km, $\pi_{T,r}$ 阶跃响应

Fig. 7 Step response of $\pi_{T,r}$ at Mach 0.9 and 11 km

图 4 和图 5 表明基于自调整神经网络航空发动机多变量自适应解耦控制系统在设计点处具有满意的动态性能和良好的解耦特性.图 6~图 9 表明在偏离设计点处,虽然系统的参数变化较大,控制系统通过自学习功能在线调整控制器的参数




图 8 $Ma=1.7$, $H=20\text{ km}$, $T_{5,r}$ 阶跃响应

Fig. 8 Step response of $T_{5,r}$ at Mach 1.7 and 20 km




图 9 $Ma=1.7$, $H=20\text{ km}$, $\pi_{T,r}$ 阶跃响应

Fig. 9 Step response of $\pi_{T,r}$ at Mach 1.7 and 20 km

使系统仍然有满意的动态特性,并得到解耦,消除了双变量控制系统变量之间的耦合作用。

5 结 论

本文针对航空发动机难以建立精确数学模型的特点,采用自调整神经网络在线自适应的调节多变量 PID 控制器的参数。研究表明,基于自调整神经网络航空发动机多变量自适应解耦控制系

统结构简单、有效,易于实现,在不需要精确的建立数学模型的情况下通过自身的训练和学习,实现了多变量系统的解耦控制,系统具有较强的自适应能力。

参考文献:

- [1] 孙护国,樊思齐,李华聪,等. 基于 LMI 的航空发动机多变量 H_∞ 固定阶控制的研究[J]. 航空动力学报, 2004, 19(3): 387-391.
SUN Huguo, FAN Siqi, LI Huacong et al. LMI based multi-variable fixed-order control for an aeroengine[J]. Journal of Aerospace Power, 2004, 19(3): 387-391.
- [2] Kelouwani S, Agbossou K. Nonlinear model identification of wind turbine with a neural network[J]. IEEE Transactions on Energy Conversion, 2004, 19(3): 607-612.
- [3] 刘建勋,李应红,陈永刚,等. 航空发动机递归神经网络分路式解耦控制[J]. 航空动力学报, 2005, 20(2): 287-291.
LIU Jianxun, LI Yinghong, CHEN Yonggang, et al. Aero-engine separate decoupling control based on recursive neural networks[J]. Journal of Aerospace Power, 2005, 20(2): 287-291.
- [4] Patnaik S N, Coroneos R M, Gupitill J D, et al. A subsonic aircraft design optimization with neural network and regression approximators[R]. AIAA 2004-4606.
- [5] Kpbayashi T, Simon D L. A hybrid neural network-genetic algorithm technique for aircraft engine performance diagnostics[R]. AIAA 2001-3763.
- [6] Chang W D, Hwang R C, Hsieh J G. A multivariable on-line adaptive PID controller using auto-tuning neurons [J]. Engineering Applications of Artificial Intelligence, 2003, 16(1): 57-63.
- [7] Chang W D, Hwang R C, Hsieh J G. Adaptive control of multivariable dynamic systems using independent self-tuning neurons[C]. Proceeding of the Tenth International Conference on Tools with Artificial Intelligence, Taipei Taiwan: 1998. 68-73.
- [8] Chen C T, Chang W D. A feedforward neural network with function shape autotuning [J]. Neural Networks, 1996, 9(4): 627-641.