

文章编号: 1000-8055(2005)02-0287-06

航空发动机递归神经网络分路式解耦控制

刘建勋, 李应红, 陈永刚, 尉询楷
(空军工程大学 工程学院, 陕西 西安 710038)

摘要: 针对航空发动机多变量控制中变量之间的耦合问题, 提出了一种基于递归神经网络的分路式动态解耦控制方法, 给出了发动机双路式解耦控制系统的结构及其解耦原理和算法。利用递归小波网络较强的动态非线性映射能力, 在线完成发动机各控制通道的模型辨识, 并回馈对应的灵敏度信息; 神经网络PD控制器根据回馈的信息在线自适应调整参数, 实现发动机各通道的准确跟踪和分路独立控制。仿真表明, 该方法在保证控制系统良好的动态和稳态性能的同时, 有效地减小了各回路之间的耦合影响, 能够成功应用于发动机控制系统的解耦。

关键词: 航空、航天推进系统; 航空发动机; 多变量控制; 解耦; PD; 递归神经网络; 小波

中图分类号: V 233. 7

文献标识码: A

Aeroengine Separate Decoupling Control Based on Recursive Neural Networks

L U Jian-xun, L I Ying-hong, CHEN Yong-gang, WEI Xun-kai

(The Engineering Institute, Air Force Engineering University, Xi'an 710038, China)

Abstract: To solve the problem of coupling in aeroengine multivariable control system, a dynamic decoupling control method based on recursive wavelet neural networks is presented. The structure of engine decoupling control system, as well as its decoupling principle and algorithm, is given. The structure includes two separate control loops. The two recursive wavelet networks, which employed normalized wavelet basic functions, were used as the decoupling identifier, and two PD neural networks were used as the controller. The wavelet networks identify the dynamic model of the engine and feed back the sensitivity information through on-line learning. The neural network PD controller updates the weights adaptively according to the on-line sensed information, and accomplishes self-governed control of each engine control loop. The simulation results of a turbofan engine show that the proposed method can effectively reduce the coupling influence of each control loop and assure satisfactory transient performance. It can be successfully applied to decoupling of aeroengine control system.

Key words: aerospace propulsion system; aeroengine; multivariable control; decoupling; PD; recurrent neural networks; wavelet

收稿日期: 2004- 03- 22; **修订日期:** 2004- 06- 22

作者简介: 刘建勋(1977-), 男, 河南周口人, 空军工程大学工程学院博士生, 主要从事航空发动机建模、控制与故障诊断研究

在航空发动机控制系统中,各变量和回路之间的耦合影响会使得系统的动态性能和稳态性能变坏。发动机最大状态工作时,耦合作用的存在还有可能导致超温、超转现象的发生。因此,消除变量之间的耦合作用是发动机控制系统设计的要求之一。文献[1]根据发动机双变量线性模型的传递函数矩阵提出了一种非理想解耦方案,对于解耦后的转速和温度控制子系统分别采用模型参考自适应控制方法进行设计。但对于航空发动机这样的非线性对象,基于线性模型进行的解耦控制器设计显然不能满足系统的实际要求,有必要探索研究更为有效的解耦控制方法。

目前,神经网络在非线系统解耦控制中的应用研究已取得了许多成果,发展了前馈补偿解耦控制、广义预测解耦策略^[2,3]等方法。文献[4]提出利用递归神经网络建立被控对象的逆模型,将逆模型作为对象的控制器来实现解耦。递归网络具有较强的表达、处理瞬态信息的能力,适合于解决非线性动态系统问题^[5]。小波神经网络则是近年来发展起来的一种局部基函数网络^[6],由于基函数具有可调的分辨尺度,这种网络具有较强的非线性学习功能,加之小波基函数具有紧支集,神经元之间的相互影响小,因此学习速度较快,小波网络现已成为系统建模与控制的有力工具^[7,8]。本文对发动机双变量PD控制系统进行了智能化改进,提出了一种基于递归小波网络的分路式动态解耦控制方法。文中以某型发动机的离散化线性模型为对象给出了解耦控制的仿真结果。

1 发动机分路式解耦控制方法

给定飞行高度和马赫数,选择主燃烧室供油量和喷口面积作为控制量,且不考虑部件容腔效应和非定常热交换,得到发动机模型为:

$$\begin{cases} n_L = f_1(n_L, n_H, m_f, A_e) \\ n_H = f_2(n_L, n_H, m_f, A_e) \\ y = f(n_L, n_H, m_f, A_e) \end{cases} \quad (1)$$

式中: n_L 为低压转子转速, n_H 为高压转子转速, m_f 为主燃烧室供油量, A_e 为喷口面积, y 为输出参数向量。令 $y = (T_5, n_L)^T$, 得到以涡轮后燃气温度 T_5 和 n_L 作为被控量的发动机模型。

对于以上两输入两输出的非线性对象,常规的神经网络解耦策略通常采用一个神经网络直接实现解耦控制,但采用一个目标函数来表征多变量的解耦性能较为复杂,而且在网络学习过程中通道间

会相互影响,这大大降低了学习速度和系统的综合性能。为此,提出了如图1所示的分路式




图1 航空发动机分路式解耦控制结构

Fig 1 Structure of separate decoupling control of aeroengine

解耦控制结构。图中,两个解耦辨识网络分别负责 T_5 和 n_L 两个输出通道的辨识,控制网络分别实现发动机各通道的独立控制。这种解耦控制方法简单易行,学习速度也相对较快。解耦辨识部分采用了递归小波神经网络,利用该网络较强的非线性动态映射能力,能够在线完成对通道的准确建模,并回馈相应的灵敏度信息。控制网络部分采用神经网络PD控制器,根据解耦辨识网络反馈的灵敏度信息自适应调整网络的输出,同时实现控制器参数的自整定。通过解耦辨识网络与控制网络的共同作用,完成对指定回路的准确跟踪,从而实现发动机的实时解耦控制。

2 算法实现

2.1 递归小波网络结构及算法

递归小波网络^[9]是采用小波基函数的动态反馈网络,其结构如图2所示。图中, w_{ij}^I 为输入层第 i 个节点到隐层第 j 个节点的连接权, w_j^H 为隐层第 j 个节点到输出层的连接权, w_j^D 为递归层的连接权,输入、输出层采用线性神经元,隐层采用小波基神经元。

选取小波基函数:

$$\Psi(x) = (1 - x^2)e^{-x^2/2}$$

网络输入:

$$I_i(k) = [u(k-1), u'(k-1), y(k-1)]^T$$

其中: u 和 u' 分别为2个通道中控制网络(即神经网络PD控制器)的输出, y 为对应于 u 的发动机输出(即 T_5 或 n_L)。下面以图1中的一个通道为例,给出网络的具体算法。




图2 递归小波神经网络结构

Fig 2 Structure of recurrent wavelet networks

取递归小波网络的隐层神经元个数为 10 个,期望输出为 $O_d(k) = y(k)$, 则网络的输入输出变换关系如下:

$$net_j(k) = \sum_{i=1}^3 W_{ij}^I I_i(k) + W_j^D S_j(k-1)$$
$$S_j(k) = \Psi \left(\frac{net_j(k) - a_j}{b_j} \right)$$
$$O(k) = \sum_{j=1}^{10} W_j^H S_j(k)$$

式中: a_j 和 b_j 分别表示小波基函数的平移系数和伸缩系数。定义评价准则函数为:

$$E(k) = \frac{1}{2} e(k)^2 = \frac{1}{2} [O_d(k) - O(k)]^2 \tag{2}$$

对于递归网络, 参数的修正是一个动态递归的过程, 因此需要采用动态BP 学习算法训练网络。推导得到如下表达式:

$$\frac{\partial E(k)}{\partial W_j^H} = S_j(k)$$
$$\frac{\partial E(k)}{\partial W_j^D} = -e(k)W_j^H P_j(k)$$
$$\frac{\partial E(k)}{\partial W_{ij}^I} = -e(k)W_j^H Q_{ij}(k)$$
$$\frac{\partial E(k)}{\partial a_j} = -e(k)W_j^H A_j(k)$$
$$\frac{\partial E(k)}{\partial b_j} = -e(k)W_j^H B_j(k)$$

令:

$$C_j = \frac{1}{b_j} \Psi \left(\frac{net_j(k) - a_j}{b_j} \right)$$

则:

$$P_j(k) = C_j[S_j(k-1) + W_j^D(k)P_j(k-1)]$$

$$Q_{ij}(k) = C_j[I_i(k) + W_j^D Q_{ij}(k-1)]$$
$$A_j(k) = C_j[-1 + W_j^D(k)A_j(k-1)]$$
$$B_j(k) = C_j \cdot \left[W_j^D(k)B_j(k-1) - \frac{net_j(k) - \alpha}{b_j} \right]$$

最后归纳出动态解耦辨识算法如下:

$$W_{ij}^I(n) = W_{ij}^I(n-1) - \eta \frac{\partial E}{\partial W_{ij}^I} \tag{3}$$

$$W_j^D(n) = W_j^D(n-1) - \eta \frac{\partial E}{\partial W_j^D} \tag{4}$$

$$W_j^H(n) = W_j^H(n-1) - \eta \frac{\partial E}{\partial W_j^H} \tag{5}$$

$$a_j(n) = a_j(n-1) - \eta \frac{\partial E}{\partial a_j} \tag{6}$$

$$b_j(n) = b_j(n-1) - \eta \frac{\partial E}{\partial b_j} \tag{7}$$

其中: n 表示迭代次数, $\eta > 0$ 为学习速率。
为了提高算法的收敛速度, 在仿真过程中引入了步长自适应调整机制, 调整算法描述为: 若 $E(n) > C \cdot E(n-1)$ (C 为大于 1 的实数), 适当减小学习率 η 同时取消对参数的修正; 若 $E(n) < E(n-1)$, 适当增加学习率, 保留参数修正; 其他情况下不作调整。

2.2 神经网络PID 控制器

控制网络的输入为:

$$X_1(k) = e_c(k) = y_d(k) - y(k)$$
$$X_2(k) = \frac{e_c(k) - e_c(k-1)}{T}$$

$$X_3(k) = \sum_{i=0}^k e_c(i) T_s = X_3(k-1) + e_c(k) T$$

其中 T 为采样时间。输出为:

$$U(k) = \sum_{i=0}^3 X_i(k)W_i(k) - \theta$$

定义指标函数为:

$$J = \frac{1}{2} [y_d(k) - y(k)]^2 \tag{8}$$

网络权值以及阈值的修正公式如下:

$$\frac{\partial J}{\partial W_i} = \frac{\partial J}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial W_i} = -e_c(k) \frac{\partial y}{\partial u} X_i \tag{9}$$

$$\frac{\partial J}{\partial \theta} = \frac{\partial J}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial \theta} = e_c(k) \frac{\partial y}{\partial u} \tag{10}$$

$$W_i(n) = W_i(n-1) - \eta \frac{\partial L}{\partial W_i} \quad (11)$$

$$\theta(n) = \theta(n-1) - \eta \frac{\partial L}{\partial \theta} \quad (12)$$

其中 $\eta > 0$ 为学习速率, $\partial y / \partial u$ 的值由递归小波网络解耦辨识器得到:

$$\frac{\partial y}{\partial u} \approx \frac{\partial O}{\partial u} = \sum_{j=1}^{10} \frac{\partial O}{\partial \Psi_j} \frac{\partial \Psi_j}{\partial net_j} \frac{\partial net_j}{\partial u} = \sum_{j=1}^{10} W_j^H \Psi_j^I \frac{1}{b_j} \quad (13)$$

根据以上给出的解耦控制算法,可以看出,每个控制回路都有各自的准则函数 $E \rightarrow E_{\min}$ 和 $J \rightarrow J_{\min}$, 各回路按照准则函数的要求完成对发动机各通道从输入到输出的动态映射,进行 PD 控制器参数的在线调整。由于准则函数中包含了各通道的输出必须实时跟踪其给定的期望值的要求,因此最终

$$\begin{bmatrix} \Delta n_L(k+1) \\ \Delta n_H(k+1) \end{bmatrix} = \begin{bmatrix} 0.9673 & 0.0068 \\ -0.0002 & 0.9661 \end{bmatrix} \begin{bmatrix} \Delta n_L(k) \\ \Delta n_H(k) \end{bmatrix} + \begin{bmatrix} 0.0062 & 0.0113 \\ 0.0071 & 0.0050 \end{bmatrix} \begin{bmatrix} \Delta m_f(k) \\ \Delta A_e(k) \end{bmatrix}$$

$$\begin{bmatrix} \Delta T_5(k) \\ \Delta n_L(k) \end{bmatrix} = \begin{bmatrix} 0.008 & 0.156 \\ 1.000 & 0.000 \end{bmatrix} \begin{bmatrix} \Delta n_L(k) \\ \Delta n_H(k) \end{bmatrix} + \begin{bmatrix} 0.382 & -0.111 \\ 0.000 & 0.000 \end{bmatrix} \begin{bmatrix} \Delta m_f(k) \\ \Delta A_e(k) \end{bmatrix}$$

其中各系数矩阵的元素进行了归一化处理,这样避免了参数值差异过大而带来的不利影响。

将 2 个通道的执行结构分别考虑为如下的 Z 传递函数(采样时间 T 为 0.01 s):

$$G_1(z) = \frac{(1 - e^{-5T})z^{-1}}{1 - e^{-5T}z^{-1}}$$

$$G_2(z) = \frac{(1 - e^{-3.3T})z^{-1}}{1 - e^{-3.3T}z^{-1}}$$

针对以上的对象模型,在不进行解耦控制时得到系统的动态响应如图 3 所示。由图可以看出,当改变供油量的给定值 m_{f0} 时, T_5 和 n_L 将同时发生变化,改变喷口面积的给定值 A_{e0} 时, T_5 和 n_L 也都将发生改变,控制变量间的耦合比较严重,在系统设计时有必要消除或减弱这种变量间的耦合现象。

根据图 1 构成航空发动机双路式解耦控制系统。仿真过程须注意: (1) 进行闭环控制仿真之前,首先进行递归小波网络的离线训练,旨在确定合适的网络连接权系数和小波基函数参数的初值,使网络获得对发动机各通道特性的预先描述。在离线训练的过程中必须使训练样本的输入尽量满足发动机各通道的持续激励要求,使被控对象的大部分模态都被激励,确保当网络学习完成后对于在学习过程中未出现的信号仍能产生所期望的输出。为此,将训练样本的输入取为 $[-1, 1]$ 之间均匀分布的白噪

能够使得整个控制系统具有较好的解耦性能。以发动机 $m_f \rightarrow T_5$ 通道为例,若给定涡轮后排气温度的期望值为 $T_{50}(k)$,则根据当前时刻该控制回路的实际输出 $T_5(k)$,可以得到指标函数为 $[T_{50}(k) - T_5(k)]^2/2$,递归小波网络的评价准则函数为 $[T_5(k) - O(k)]^2/2$ 。利用所给出的辨识算法及控制算法,可以实现 $T_5(k)$ 对 $T_{50}(k)$ 的实时跟踪。

3 仿真

考虑到航空发动机非线性模型的表达过于复杂,且进行动态性能计算时实时性不好,参照文献 [10] 的研究思路,选用某型涡扇发动机的稳态点的离散化线性模型进行控制性能仿真。在高度 $H = 0$ km、马赫数 $M_a = 0$ 时,某型发动机的双变量离散化状态空间模型为:

声,根据这些输入产生出用于离线




图 3 无解耦控制器时的系统响应

Fig. 3 Response without decoupling controller

辨识的500个训练样本, 这样就能保证当学习样本和实时控制中的实际输入不一样时也能得到良好的控制效果; (2) 在解耦辨识网络不工作的情况下, 提前进行多次控制系统的仿真分析, 并优化选择出较为合理的神经网络PD控制器的初始权值; (3) 闭环控制仿真时, 递归小波网络在离线训练结果的基础上进行在线学习和调整, 当对象偏离工作点时能实时修正网络的参数, 及时准确地反映对象的特性; (4) 由于仿真时采用的发动机模型为小偏差线性模型, 因此对控制量 m_f 和 A_e 分别考虑了约束, 限制它们的相对变化量不超过 $\pm 5\%$; (5) 为保证仿真结果不出现波动现象, 尽量取较小的学习速率进行动态过程仿真, 可将 η 和 η 分别取为0.1和0.05。




图4 解耦控制仿真 ($H = 0\text{ km}, M a = 0$)

Fig 4 Decoupling control simulation
($H = 0\text{ km}, M a = 0$)

图4给出了发动机控制系统的仿真结果, 图中还给出了两个控制量的变化情况。由图可以看出, 回路间的耦合影响基本得到了消除, 两种阶跃输入情况下控制系统都几乎不存在稳态误差。分析表明, 当涡轮后燃气温度的给定值发生阶跃变化时, 燃油控制通道立即调大主供油量, 同时为了防止因

供油量升高而引起的低压转子转速升高, 喷口控制通道调小喷口面积, 两者的共同作用使得排气温度快速上升, 低压转子转速则发生微小的偏离后最终稳定在初始状态; 同理可以分析出调整低压转子转速的给定值时控制量和输出量的变化情况。




图5 解耦控制仿真 ($H = 5\text{ km}, M a = 1.0$)

Fig 5 Decoupling control simulation
($H = 5\text{ km}, M a = 1.0$)

当飞行条件改变时, 描述发动机模型的参数也要发生变化。但由于解耦辨识器和控制器的自适应特性, 只要选择合适的连接权系数的初值, 采用本文的方法仍然能获得满意的性能指标。图5给出了在高度 $H = 5\text{ km}$, 马赫数 $M a = 1.0$ 时发动机解耦控制的仿真结果, 可以看出解耦效果和动态特性是令人满意的。在对发动机全包线的控制性能进行仿真时发现, 对飞行包线内的大多数工作点来说, 采用一组典型的连接权系数的初值即可基本满足系统解耦控制的要求, 但不同工作点之间动态响应的调节时间差异较大。为了获得更好的综合性能, 可以对每一个工作点分别选取连接权系数的初值, 这样就能够保证解耦算法很好地适应整个飞行包线。

4 结 论

(1) 提出的航空发动机双路式解耦控制结构及思想, 相当于在实际发动机双变量PD控制系统

的基础上引入了基于递归小波网络的在线辨识过程,以及PD控制器参数的自适应调整机制,可看作是实际发动机控制系统的智能化改进,这一特点使得该控制结构易于工程实现。

(2) 仿真算例表明,分路式解耦控制方法能够有效地实现发动机稳态点控制系统的解耦,同时保证了系统良好的稳态和动态性能。由于递归小波神经网络具有很强的处理非线性瞬态信息的能力,因此基于递归小波网络构建的发动机解耦控制系统非常适合于发动机这样的大时变、非线性的复杂控制对象。

参考文献

- [1] 樊丁,梁春燕. 航空发动机非理想解耦自适应控制[J]. 航空动力学报, 2000, 15(3): 328~330
FAN Ding, LIANG Chun-yan. Incompletely Decoupled Adaptive Control in Aeroengine System [J]. *Journal of Aerospace Power*, 2000, 15(3): 328~330
- [2] 靳其兵,曾东宁,王云华. 多变量系统的神经网络解耦新方法[J]. 东北大学学报, 1999, 20(3): 250~253
JIN Qi-bing, ZENG Dong-ning, WANG Yun-hua. New Decoupling Method Based on Neural Network for Multivariable System [J]. *Journal of Northeastern University*, 1999, 20(3): 250~253
- [3] 贺国艳. 神经网络解耦预测函数控制[J]. 控制工程, 2002, 9(4): 63~70
HE Guo-yan. Predictive Function Control Based on neural Network Decoupling [J]. *Control Engineering of China*, 2002, 9(4): 63~70
- [4] 邱阿瑞,孙健. 利用人工神经网络进行感应电动机解耦控制[J]. 清华大学学报, 1999, 39(7): 13~15
QIU A-rui, SUN Jian. Decoupling Control of Induction Motors Using Artificial Neural Networks [J]. *Journal of Tsinghua University*, 1999, 39(7): 13~15
- [5] Draye J S. Dynamic Recurrent Neural Networks: A Dynamical Analysis [J]. *IEEE Transaction on Systems, Man, and Cybernetics, Part B: Cybernetics*, 1996, 26(5): 692~706
- [6] Zhang J. Wavelet Neural Network for Function Learning [J]. *IEEE Transaction on Signal Processings*, 1995, 43(6): 1485~1497.
- [7] 陈谋,姜长生,吴庆宪. 基于小波神经网络的自适应飞/推控制系统设计[J]. 航空动力学报, 2003, 18(3): 420~426
CHEN Mou, JIANG Chang-sheng, WU Qing-xian, et al. Design for Adaptive Flight/Propulsion Control System Based Wavelet Neural Networks [J]. *Journal of Aerospace Power*, 2003, 18(3): 420~426
- [8] 王忠勇,张端金,方浩. 一种基于小波网络的自校正控制方法[J]. 控制理论与应用, 2001, 18(2): 270~273
WANG Zhong-yong, ZHANG Duan-jin, FANG Hao. An Approach to Self-Tuning Control Based on Wavelet Network [J]. *Control Theory and Applications*, 2001, 18(2): 270~273
- [9] Rao S S. Recurrent Wavelet Networks [J]. *IEEE Transaction on Neural Networks*, 1994: 3143~3147.
- [10] 郭迎清. 航空发动机神经网络自适应控制研究[J]. 航空动力学报, 2001, 16(1): 83~86
GUO Ying-qing. A New Neural Network Adaptive Control Scheme Research [J]. *Journal of Aerospace Power*, 2001, 16(1): 83~86