

文章编号: 1000-8055(2009)08-1866-06

航空发动机全包线自适应解耦控制器设计

彭靖波, 谢寿生, 吴 勇, 翟旭升
(空军工程大学 工程学院, 西安 710038)

摘 要: 为实现航空发动机在全包线的解耦控制, 在飞行包线内选择了若干点, 使用遗传算法对单神经元自适应解耦控制器的比例系数进行了离线优化。以优化得到的若干组参数为训练样本, 离线训练径向基函数(RBF)神经网络, 训练后的网络可映射高度、马赫数与比例系数之间的非线性关系, 飞行包线内任意点的解耦控制器比例系数即可由该网络得到。仿真表明: 在设计点和非设计点, 系统均具有良好的动态特性和解耦特性。该方法结构简单、易于实现, 具有实用价值。

关 键 词: 航空发动机; 单神经元; 遗传算法; 径向基函数(RBF)神经网络; 解耦控制

中图分类号: V233.7

文献标识码: A

Design of an adaptive decoupling controller of aero engine over whole envelop

PENG Jing bo, XIE Shou sheng, WU Yong, ZHAI Xu sheng

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

Abstract: In order to achieve decoupling control of aero engine over whole envelop, genetic algorithm was used to optimize the proportion parameters of single neural adaptive decoupling controller based on various points within envelop, whilst several groups of parameters optimized by the algorithm were used as sample data to train radial basis function(RBF) network, helping to map height and mach number on proportion parameters after tuning. The proportion parameters at every operating point can be calculated by RBF neural network. The simulation results show that the control system has a fine performance of dynamic and decoupling capability over whole envelop, and the proposed method is simple, feasible and effective.

Key words: aero engine; single neural; genetic algorithm (GA);
radial basis function (RBF) neural network; decoupling control

现代航空发动机多采用复杂的多变量控制系统, 随着控制参数和回路的增加, 各变量和回路之间的耦合作用也越来越明显, 使得系统的稳态和动态特性变坏。因此, 消除变量之间的耦合作用是航空发动机控制系统设计的重要要求。对于航空发动机这种复杂的非线性对象, 使用常规的线性系统解耦方法显然难以满足要求。

神经网络以其高精度非线性逼近能力、很强的自适应和自学习能力, 在控制系统设计、辨识建

模、和非线性系统解耦方面应用广泛^[1-3]。目前对航空发动机解耦控制系统的设计也多采用神经网络、模糊控制等智能算法^[4-8]。文献[4]提出利用动态识别神经网络(DRNN)对被控对象进行在线辨识并由此得到对象的 Jacobian 信息, 通过带动量项的梯度优化算法对控制器的参数进行优化达到解耦的目的; 文献[5]则采用递归网络辨识获得对象的 Jacobian 信息, 利用自调整机构对 PID(proportion integration differentiation)控制器参数进

收稿日期: 2008 08 15; 修订日期: 2008 12 21

作者简介: 彭靖波(1980-), 男, 湖南南县人, 博士生, 研究领域为航空发动机分布式控制与故障诊断。

行优化完成解耦; 文献[7]提出了 P 范数的耦合度概念并给出了多目标优化解耦控制算法; 文献[8]则提出了一种自学习模糊解耦控制器, 将多变量模糊解耦控制和模型参考自学习控制结合起来, 利用模糊逆模型在线产生和修正模糊解耦控制系统的规则库, 在航空发动机上取得了较好的控制效果。

针对航空发动机分布式数字控制系统, 本文采用结构更为简单、且具有自学习和自适应能力的单神经元构成自适应控制器, 通过遗传算法 (GA) 离线单神经元自适应控制器的比例系数使其具有快速的跟踪参考输入的能力, 实现了发动机在飞行包线某一点的解耦控制, 最后利用径向基函数 (RBF) 网络映射高度、马赫数与比例系数之间非线性关系, 由此设计了全飞行包线范围内的航空发动机解耦控制器。

1 单神经元自适应控制器

单神经元自适应控制器结构如图 1 所示, 由 1 个自适应神经元构成, 可直接通过学习给出控制规律




图 1 单神经元控制器
Fig. 1 Structure of single neural controller

在图 1 中, 控制器输出

$$u(t) = k \sum_{i=1}^n w_i(t) x_i(t) \bigg/ \sum_{i=1}^n w_i(t) \tag{1}$$

单神经元控制器通过对权系数的调整来实现自组织、自适应功能。权系数采用有监督的 H Ebb 学习规则

$$\begin{aligned} w_i(t+1) = \\ w_i(t) + d \times [r(t) - y(t)] \times u(t) \times x_i(t) \end{aligned} \tag{2}$$

式中 $r(t)$ 为参考输入; $y(t)$ 为对象实际输出值; $x_i(t)$ 为神经元输入信号; $w_i(t)$ 为对应于 $x_i(t)$ 的权值; k 为神经元比例系数; d 为神经元学习速度; $u(t)$ 为神经元的输出。神经元输入信号 $x_i(t)$ 的取法对控制系统性能有很大影响, 一般取参考输入与对象实际输出值之间的偏差, 即

$$x_i(t) = e_i(t) = r(t-i+1) - y(t-i+1) \tag{3}$$

由于神经元的自学习功能, 权系数初值的选取对其以后的学习结果影响不大, 经少数几次迭代即可得到满意控制效果的权系数。参数 d 的取值自由度较大, 取较大的值可以提高学习速率, 增强网络适应性, 取较小的值可以增强学习的平稳性。比例系数 k 的选择非常重要, 取值较大时系统响应速度快, 但动态超调量大, 取值较小时系统响应速度慢, 学习较平稳。若 k 取得过小, 响应将无法跟踪给定值。权系数根据 $r(t) - y(t)$, $u(t)$, $x_i(t)$ 的变化来调整, 不依赖于被控对象数学模型。

在单神经元自适应控制系统中, 自适应神经元能够通过自组织关联进行递进式学习, $r(t) - y(t)$ 决定了神经元的持续动作, 直至偏差减小为零, 当 k 的取值使之有足够的搜索能力时, 神经元就能够使偏差减小到零。

2 航空发动机全包线单神经元自适应解耦控制结构

2.1 航空发动机数学模型

某型航空涡扇发动机采用双变量控制结构, 使用主燃烧室供油量 m_f 和喷口面积 A_e 作为控制量, 涡轮后燃气温度 T_5 和低压转速 n_L 作为被控量, 在给定高度和马赫数条件下, 不考虑部件容腔效应和非定常热交换, 发动机非线性数学模型为

$$\begin{cases} n_L = f_1(n_L, n_H, T_5, A_e) \\ n_H = f_2(n_L, n_H, T_5, A_e) \\ y = f(n_L, n_H, T_5, A_e) \end{cases} \tag{4}$$

其中 $y = [T_5, n_L]^T$, 对上式在给定工作点处泰勒展开并对所有向量的分量均取相对增量形式, 可得发动机相对增量形式的线性数学模型

$$\begin{aligned} \begin{bmatrix} \Delta \dot{n}_L \\ \Delta \dot{n}_H \end{bmatrix} &= A \begin{bmatrix} \Delta n_L \\ \Delta n_H \end{bmatrix} + B \begin{bmatrix} \Delta m_f \\ \Delta A_e \end{bmatrix} \\ \begin{bmatrix} \Delta T_5 \\ \Delta n_L \end{bmatrix} &= C \begin{bmatrix} \Delta n_L \\ \Delta n_H \end{bmatrix} + D \begin{bmatrix} \Delta m_f \\ \Delta A_e \end{bmatrix} \end{aligned} \tag{5}$$

2.2 基于 GA 的航空发动机单神经元自适应解耦控制结构及原理

根据上述航空发动机模型, 设计航空发动机单神经元控制系统结构如图 2 所示, 系统由两个单神经元控制器、参数优化机构 GA 和对象组成。如前所述, 单神经元自适应控制器的比例系数的

选取非常重要,通过合理的选择比例系数可以实现输出快速跟踪给定值,从而实现发动机变量之间的解耦,这里通过 GA 离线整定单神经元控制器的比例系数.图中 $e_T, \dot{e}_T, \ddot{e}_T$ 分别为涡轮后温度期望值与实际值的偏差、偏差变化率和偏差变化量的变化率. $e_n, \dot{e}_n, \ddot{e}_n$ 分别为低压转速期望值与实际值的偏差、偏差变化率和偏差变化量的变化率.

$$u_T(t)=k_T\frac{w_{T1}(t)\dot{e}_T(t)+w_{T2}(t)e_T(t)+w_{T3}(t)\ddot{e}_T(t)+w_{T4}(t)e_n(t)}{w_{T1}(t)+w_{T2}(t)+w_{T3}(t)+w_{T4}(t)}\tag{12}$$

$$u_n(t)=k_n\frac{w_{n1}(t)\dot{e}_n(t)+w_{n2}(t)e_n(t)+w_{n3}(t)\ddot{e}_n(t)+w_{n4}(t)e_T(t)}{w_{n1}(t)+w_{n2}(t)+w_{n3}(t)+w_{n4}(t)}\tag{13}$$




图 2 航空发动机单神经元解耦控制系统
Fig. 2 Structure of single neural decoupling control system for aero engine

具体算法流程为

- Step 1: $t=1$, 初始化权系数 $w_{ij}, w_{ij}, (j=1, 2, 3, 4)$;
- Step 2: 按照式(6)~(11)计算神经元的输入信号;
- Step 3: 按照式(12)~(13)计算神经元输出;
- Step 4: 将神经元输出作用于被控对象,按照式(2)修正权系数;
- Step 5: $t=t+1$, 返回 Step 2.

控制器的设计原则是通过 GA 优化比例系数 k_T, k_n ,以减弱或消除动态耦合,至少应实现或减弱静态耦合,使各输出较好的跟踪各自给定值.因此设定 GA 适应度函数为

$$F_i=\frac{1}{J_i}\tag{14}$$

$$J_i=\sum_{t=1}^m[w_1|e_T(t)|+w_2|e_n(t)|+w_3\sigma_T+w_4\sigma_n]$$

其中 i 为迭代代数; w_1, w_2, w_3 和 w_4 为权重;

$$e_T(t)=T_{50}(t)-T_5(t)\tag{6}$$

$$e_n(t)=n_{L0}(t)-n_L(t)\tag{7}$$

$$\dot{e}_T(t)=e_T(t)-e_T(t-1)\tag{8}$$

$$\dot{e}_n(t)=e_n(t)-e_n(t-1)\tag{9}$$

$$\ddot{e}_T(t)=\dot{e}_T(t)-\dot{e}_T(t-1)\tag{10}$$

$$\ddot{e}_n(t)=\dot{e}_n(t)-\dot{e}_n(t-1)\tag{11}$$

σ_T, σ_n 为两个通道的超调量,通过 w_1, w_2 来保证系统的稳态解耦,通过 w_3, w_4 来实现动态解耦.

GA 优化的具体流程参见文献[9]所述改进遗传算法.

2 3 基于 RBF 网络的全包线单神经元解耦控制器设计

现代理论研究已经证明,三层神经网络可以逼近任意非线性系统,而多变量插值的径向基函数(RBF)网络更是具有良好的逼近任意非线性映射和处理系统内在难以解析表达的规律性的能力.其网络结构如图 3 所示,具体原理可参见文献[10]及其它相关文献




图 3 RBF 网络结构
Fig. 3 Structure of RBF network

若在飞行包线内选取若干点进行单神经元解耦控制器的设计,可得到若干组比例系数,显然,由于发动机的强非线性,各组比例系数与高度、马赫数的关系必然也是非线性的.若由 RBF 网络对这些数据进行训练,即可得到高度 H 、马赫数 Ma 与比例系数 $[k_T, k_n]$ 之间的非线性关系.基于此思想,本文首先在飞行包线内选取 20 个点由 GA 离线优化得到 20 组单神经元比例系数,然后这些数据作为样本训练 RBF 网络,从而得到 $[H, Ma]$

与 $[k_T, k_n]$ 的非线性映射关系. 回归检验结果如表 1 中前 8 组数据所示(篇幅所限, 只列出了 8 组). 为了检验网络的泛化能力, 另取 4 个点在网络进行检验, GA 优化的原始数据与网络检验数据如表 1 中后 4 组数据所示, 网络具有较强的泛化能力, 可以适应于全包线.

由此, 基于 RBF 网络的全包线单神经元解耦控制系统由两个单神经元控制器、RBF 网络和发动机对象组成. RBF 网络根据当前飞行状态输出两个单神经元控制器的比例系数 $[k_T, k_n]$, 单神经元控制器通过自身的自学习和自适应能力实现发动机的解耦控制.

表 1 飞行包线内部分点比例系数

Table 1 Propotion parameters of some points in envelop

H/ km	Ma	原始数据		检验数据	
		k_T	k_n	k_T	k_n
0	0	18. 524	13. 998	18. 53	14. 003
9	0	16. 387	14. 307	16. 378	14. 31
19	1 1	15. 544	11. 409	15. 551	11. 307
17	2 2	8 098	9 869	8 106	9 86
13,	2 2	9 83	10 692	9 823	10 692
2	1 1	16 977	14 785	16 975	14. 78
9	1	15 119	13 203	15 124	13 204
20	2 2	7. 394	9 032	7. 387	9 044
5	0 5	17. 169	14 941	17. 162	14. 95
11	1	16 08	9 733	16 071	9 739
15	1 5	12 388	9 626	12 379	9 64
18	2	10 59	11 181	10 618	11 201

3 仿真结果

以某型涡扇发动机为例, 根据气动热力模型建立其小偏差动态数学模型建立相对增量形式线性数学模型如式(5)所示, 在 $H = 0\text{ km}$, $Ma = 0$ 点, 其系数矩阵为

$$A = \begin{bmatrix} 0 & 9673 & 0 & 0068 \\ - & 0 & 0002 & 0 & 9661 \end{bmatrix}, B = \begin{bmatrix} 0 & 0062 & 0 & 0113 \\ 0 & 0071 & 0 & 005 \end{bmatrix}$$
$$C = \begin{bmatrix} 0 & 008 & 0.156 \\ 1.000 & 0 \end{bmatrix}, D = \begin{bmatrix} 0 & 382 & - & 0 & 111 \\ 0 & 0 \end{bmatrix}$$

其中各系数均进行了归一化处理, 考虑两个通道执行机构连续形式的传递函数为

$$G_T(S) = \frac{1}{0.2S + 1}, \quad G_n(S) = \frac{1}{0.3S + 1}$$

针对上述模型, 按照图 2 构造的单神经元自适应解耦控制系统, 通过 GA 对单神经元控制器比例系数进行离线优化, 并经 RBF 网络映射后得到了全包线范围的单神经元自适应解耦控制器. 选取 $H = 0\text{ km}$, $Ma = 0$; $H = 11\text{ km}$, $Ma = 1.0$ 和 $H = 15\text{ km}$, $Ma = 1.5$ 三个点进行仿真. 解耦控制效果如图 4、图 5、图 6 所示, 由图可见, 当单独对 Δn_{L0} 施加阶跃输入时, 系统输出 Δn_L 响应迅速且能马士稳定, ΔT_5 则表现为略微振荡后迅速跟踪给定值. 当单独对 ΔT_{50} 施加阶跃输入时, 解耦效果也非常明显. 可见, 经优化后的单神经元自适应控制器能够在全包线范围内对带执行机构的发动机实现解耦控制, 且具有良好的动态特性.




图 4 解耦控制仿真($H = 0\text{ km}$, $Ma = 0$)
Fig. 4 Decoupling control simulation ($H = 0\text{ km}$, $Ma = 0$)




图 5 解耦控制仿真($H=11\text{ km}, Ma=1.0$)

Fig. 5 Decoupling control simulation ($H=11\text{ km}, Ma=1.0$)




图 6 解耦控制仿真($H=15\text{ km}, Ma=1.5$)

Fig. 6 Decoupling control simulation ($H=15\text{ km}, Ma=1.5$)

4 结 论

本文针对航空发动机各控制变量和回路之间的耦合作用,设计了一类全包线自适应解耦控制器.该控制器由 RBF 网络和单神经元自适应解耦控制器组成.首先在包线内的若干点通过 GA 离线优化获得若干组比例系数,然后利用 RBF 网络映射高度、马赫数与比例系数之间非线性关系.在实际应用时,只需根据飞行状态由 RBF 网络获得单神经元解耦控制器的比例系数,然后通过单神经元解耦控制器的自学习自适应能力实现对发动机的解耦控制.研究表明,该控制器结构、算法简单有效,在分布式数字控制系统中易于实现;对被控对象模型要求不高,不需要被控对象的 Jacobian 信息,直接通过对误差的学习产生控制规律;对航空发动机控制具有良好的动静态特性和解耦能力.

参考文献:

[1] Wittenmark B, Middleton R, Goodwin G C. Adaptive decoupling of multivariable systems [J]. Controller, 1987, 46(6): 1993-2009

[2] Phom D T, Liu X. Training of elman networks and dynamic system modeling[J]. International Journal of System Science, 1996, 27(2): 221-226

[3] Chen S, Billings S A. Neureal networks for nonlinear dynamics system modeling and identification [J]. Int. J. Control, 1992, 56(2): 319-346

[4] 朱玉斌,樊思齐,任新宇,等.基于 DRNN 网络的航空发动机多变量解耦控制[J].推进技术,2006,27(2): 150-153

ZHU Yubin, FAN Siqi, REN Xinyu, et al. A multivariable decoupling control based on DRNN for aeroengine [J]. Journal of Propulsion Technology, 2006, 27(2): 150-153 (in Chinese)

[5] 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. (in Chinese)

[6] 朱玉斌, 樊思齐, 张秀华, 等. 基于自调整神经元的航空发动机多变量自适应解耦控制[J]. 航空动力学报, 2007, 22(3): 490-494

ZHU Yubin, FAN Siqi, ZHANG Xiuhua, et al. Multivariable adaptive decoupling control based on autotuning neurons for aero engine[J]. Journal of Aerospace Power, 2007, 22(3): 490-494. (in Chinese)

[7] 杨刚, 孙健国. 航空发动机多目标优化解耦控制设计方法[J]. 航空发动机, 2006, 32(4): 31-35

YANG Gang, SUN Jianguo. An aero engine decoupling control method based on multi-objective optimization[J]. Aeroengine, 2006, 32(4): 31-35. (in Chinese)

[8] 任新宇, 樊思齐. 航空发动机多变量自学习模糊解耦控制[J]. 推进技术, 2004, 25(6): 535-537

REN Xinyu, FAN Siqi. Aero engine multivariable learning fuzzy decouple control [J]. Journal of Propulsion Technology, 2004, 25(6): 535-537. (in Chinese)

[9] 彭靖波, 谢寿生, 王运生, 等. 基于遗传算法的发动机控制通道数学模型辨识[J]. 推进技术, 2007, 28(6): 653-656

PENG Jingbo, XIE Shousheng, WANG Yunsheng, et al. Mathematic model identification of aero engine main control passage based on genetic algorithm [J]. Journal of Propulsion Technology, 2007, 28(6): 653-656. (in Chinese)

[10] 彭靖波, 谢寿生. 基于 RBF 神经网络的压气机特性仿真[J]. 推进技术, 2006, 27(1): 30-32

PENG Jingbo, XIE Shousheng. Compressor characteristic simulation based on RBF neural network [J]. Journal of Propulsion Technology, 2006, 27(1): 30-32. (in Chinese)