

文章编号: 1000-8055(2000)03-0334-03

航空发动机自适应神经网络 PD 控制

蒋衍君 黄金泉

(南京航空航天大学 203 教研室, 江苏 南京 210016)

摘要: 本文提出了一种航空发动机多变量自适应神经网络 PD 控制方法, 采用基于共轭梯度的神经网络学习算法在线整定控制器参数。该控制器的设计无需知道发动机精确模型, 具有响应速度快、抗干扰能力强和鲁棒性好等优点。控制器不仅算法简单, 实现容易, 而且适用范围广。

关键词: 航空发动机; 神经网络; 多变量控制; 自适应控制

中图分类号: V 233. 7

文献标识码: A

1 引言

随着控制理论和技术的日趋成熟完善, 各种先进的控制方法不断出现, 但目前大多数工业过程仍采用 PD 控制。PD 控制器具有直观、实现简单及鲁棒性好等一系列优点。但在 PD 控制中, 一个关键的问题就是 PD 参数整定。传统的方法是在获取对象数学模型的基础上, 根据某一整定原则来确定 PD 参数, 然而实际的航空发动机是一个复杂的非线性系统, 难以建立精确的数学模型, 而且模型参数随着发动机工作状况和飞行条件而变化, 这就要求在 PD 控制中参数的整定不依赖于发动机对象数学模型, 且 PD 参数能在线调整以满足实时控制的要求。近年来已提出了多种自校正 PD 调节方法^[1~3], 将神经网络引入到 PD 控制参数整定中^[4], 无疑是一个新的着眼点。神经网络在控制中应用最广泛的学习算法就是反向误差传播算法(简称 BP 算法)。该算法使加权值向负梯度方向收敛使性能指标最小。直接应用 BP 算法进行控制存在的问题, 因为 BP 算法收敛速度较慢, 不能满足实时控制的要求, 且学习率不易选取。文献[5]提出了一种航空发动机神经网络自适应控制在线算法, 但这种方法物理概念不直观。为此, 本文提出一种基于共轭梯度学习算法的神经网络 PD 控制方法, PD 控

制器的比例、积分、微分系数即是神经网络权值, 通过共轭梯度法训练网络的权值来达到在线调整 PD 控制器参数的目的。仿真结果表明, 此方法对发动机非线性和建模的不确定性具有很好的自适应性和鲁棒性。

2 发动机神经网络 PD 控制器

考虑某涡扇发动机多变量控制, 中间状态以上要求用转速控制指令(参考输入) N_{1r} 控制风扇转速 N_1 , 用压比控制指令 P_{36r} 控制燃烧室出口静压与低压涡轮出口总压之比 P_{36} ^[5]。发动机非线性模型可表示为:

$$\dot{x} = f(x, u, d), \quad y = g(x, u, d) \quad (1)$$

其中: x 为状态向量, $y = [N_1, P_{36}]^T = [y_1, y_2]^T$ 为输出向量, $u = [W_f, A_8]^T = [u_1, u_2]^T$ 为控制输入, W_f 为供油量, A_8 为尾喷口面积, $f(\cdot)$ 和 $g(\cdot)$ 为未知的光滑函数向量, d 为未知有界扰动向量。

参考模型为:

$$\dot{x}_m = A_m x_m + B_m r, \quad y_m = C_m x_m \quad (2)$$

其中: x_m 为参考模型状态向量, $r = [N_{1r}, P_{36r}]^T = [r_1, r_2]^T$ 为给定输入, $y_m = [y_{m1}, y_{m2}]^T = [N_{1m}, P_{36m}]^T$ 为发动机参考模型输出向量, A_m, B_m 和 C_m 为参考模型系统矩阵、控制矩阵和输出矩阵。

当采样周期 T 较小时, 离散化后的 PD 控制算法的表示式为:

收稿日期: 1999- 09- 01; 修订日期: 2000- 04- 07

基金项目: 航空科学基金资助项目(99C52027); 国家教委留学回国人员科研资助项目

作者简介: 蒋衍君(1975-), 男, 南京航空航天大学 203 教研室, 硕士生

$$u_i(k) = K_{pi}\left\{ e_i(k) + \frac{T}{T_{ii}}\sum_{j=1}^k e_i(j) + \frac{T_{Di}}{T}[e_i(k) - e_i(k-1)] \right\} \quad i = 1, 2 \quad (3)$$

增量形式为: $\Delta u_i(k) = \sum_{j=1}^3 w_{ij}Z_{ij}(k)$ (4)

其中: $e(t) = y_m(t) - y(t) = [e_1, e_2]^T$, K_{pi} , T_{ii} 和 T_{Di} 分别为比例增益、积分时间常数和微分时间常数。 $\Delta u_i(k) = u_i(k) - u_i(k-1)$, $w_{ii} = K_{pi}$

$w_{i2} = K_{pi}T/T_{ii}$, $w_{i3} = K_{pi}T_{Di}/T$

$Z_{i1}(k) = e_i(k) - e_i(k-1)$, $Z_{i2}(k) = e_i(k)$

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

选取神经网络的输入量 $Z_{i1}(k)$, $Z_{i2}(k)$ 和 $Z_{i3}(k)$, 权重为 w_{i1} , w_{i2} 和 w_{i3} 则神经网络输出为:

$$u_i(k) = u_i(k-1) + \sum_{j=1}^3 w_{ij}Z_{ij}(k) \quad i = 1, 2 \quad (5)$$

与文献[6]相比, 本文提出的神经网络 PD 控制器结构简易, PD 控制器的参数即为神经网络的权重, 网络学习算法简单, 控制器编程代码短, 物理概念清晰、易懂。




图1 神经网络 PD 控制系统结构

采用神经网络构成的某涡扇发动机 PD 控制系统如图 1 所示。

3 发动机神经网络 PD 学习算法

采用BP 算法的 PD 神经网络存在收敛速度较慢, 学习率不易选取, 初始训练权值时稳定性较差等缺点, 而采用共轭梯度法^[7]可解决这个问题。选取性能指标:

$$J_w(k) = (1/2) [y_m(k) - y(k)]^T \cdot [y_m(k) - y(k)] \quad (6)$$

其中: w 表示网络的权值向量。

设 $J_w(k)$ 对 w 的负梯度方向为:

$$D(k) = - \nabla J_w(k) = - \sum_{i=1}^2 [y_{mi}(k) - y_i(k)] \frac{\partial y_i(k)}{\partial w} \quad (7)$$

网络的权向量修正公式为:

$$W^{(k+1)} = W^{(k)} + g^{(k)} \cdot P(k) \quad (8)$$

其中最佳搜索方向的步长 $g^{(k)}$ 由下式求得:

$$\frac{dJ[W^{(k)}g^{(k)} \cdot P(k)]}{dg^{(k)}} = 0 \quad (9)$$

这里 $W^{(k)}$ 表示第 k 步迭代的权向量, $P(k)$ 表示第 k 步的搜索方向, 可由共轭梯度法求得:

$$P(k) = - \nabla J_w(k) + \beta(k-1) \cdot P(k-1) \quad (10)$$

其中: $\beta(k-1)$ 为共轭系数。

$$\beta(k-1) = \frac{[\nabla J(W(k))]^T [\nabla J(W(k-1))]}{[\nabla J(W(k))]^T [\nabla J(W(k-1))]} \quad (11)$$

4 控制系统仿真

发动机模型为某涡扇发动机非线性模型, 能进行飞行包线内各点的稳态和瞬态的模拟仿真计算^[8]。设参考模型为二阶系统, 传递函数为:

$$G_i(s) = \omega_{hi}^2 / (s^2 + 2\xi_i\omega_{hi}s + \omega_{hi}^2) \quad (i = 1, 2) \quad (12)$$

其中: $i = 1, 2$ 分别为转速回路与压比回路参考模




图2 转速阶跃响应 5% ($H = 0, M a = 0$)




图3 压比阶跃响应 5% ($H = 10 \text{ km}, M a = 0.8$)

型传递函数。为满足转速回路带宽大于 5 rad/s , 压比回路带宽大于 10 rad/s , 选取转速参考模型自然频率 $\omega_{n1} = 11 \text{ rad/s}$, 压比回路参考模型自然频率 $\omega_{n2} = 27 \text{ rad/s}$, 为避免系统动态响应超调, 取阻尼系数, $\xi_i = 1.0 (i = 1, 2)$ 。仿真过程中, 供油量 W_f 和尾喷口面积 A_8 根据实际系统中物理极限加入了相应的约束条件。图 2 和图 3 分别为转速和压比阶跃仿真结果, 图 4 为正弦响应仿真结果。




图 4 正弦响应($H = 10 \text{ km}, M_a = 0.8$)

由以上仿真结果可以看出, 发动机 PD 神经网络控制具有较满意的动、静态性能, 对发动机非

线性和模型的不确定性有一定的适应能力。

5 结 论

发动机多变量 PD 神经网络控制采用模型参考方法, 在线调整神经网络的权重, 具有良好的动、静态性能。由于多变量控制系统结构采用分散控制的方法, 因此控制系统能降低各分系统间的耦合作用。控制器结构和算法简单, 能在微机上实时实现。并且控制过程直观, 通过神经网络权值学习自动调整 PD 控制器比例、积分、微分系数, 物理概念十分清晰, 易于工程人员理解, 可望在实际中硬件实现。

参 考 文 献

- 1 Yusof R, Omatu S A Multivariable Self-Tuning PD Controller[J]. *Int J. Control*, 1993, 57(30): 1387- 1403
- 2 陶永华, 尹怡欣, 葛芦生. 新型 PD 控制及其应用[M]. 北京: 机械工业出版社, 1998: 220- 245
- 3 胡泽新, 周金荣, 黄道. 多变量非线性自整定 PD 控制器[S]. *控制理论与应用*, 1996, 13(2): 268- 271
- 4 Willis M J, Montague G A. Auto-Tuning PI(D) Controllers with Artificial Neural Networks[C]. *In Proc 12th WC IFAC*, Sydney, Australia, 1993: 61- 64
- 5 黄金泉. 航空发动机神经网络自适应控制: [博士学位论文][D]. 南京航空航天大学, 1998
- 6 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): 191- 194
- 7 童调生. 电气工程最优控制[M]. 北京: 机械工业出版社, 1989: 214- 225
- 8 蒋衍君. 航空发动机神经网络控制: [硕士学位论文][D]. 南京航空航天大学, 2000

(责任编辑 王震华)

Adaptive Neural Network PD Control for an Aeroengine

Jiang Yanjun, Huang Jinquan

(2nd Dept NanJing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: A multivariable adaptive neural network PD control scheme is proposed for a turbofan engine. The parameters of the controller are adjusted by on-line conjugate gradient method. The precise model of the engine is not necessary for the design of the control system. The designed controller has many advantages such as fast response, strong interference-free ability and good robustness. The control algorithm is simple, easy to realize and adaptable to full flight envelope.

Key words: aeroengines; neural networks