

无人机涡喷发动机的神经网络自适应 PID 控制*

马 静¹, 杨育武², 王镛根¹

(1. 西北工业大学 航空动力与热力工程系, 陕西 西安 710072; 2. 西安远东公司军品研究所, 陕西 西安 710073)

摘 要: 将基于 RBF 神经网络的辨识网络与基于 BP 网络的控制器相结合, 组成自适应 PID 神经网络控制系统。RBF 神经网络采用离线学习在线修正权值和阈值, 为加快收敛速度, 应用带惯性项的梯度下降法。大量仿真结果表明, RBF 网络较 ELM, 标准 BP 及改进的 BP 等网络具有明显优点。对某型无人机涡喷发动机控制系统的仿真结果表明此控制方式具有鲁棒性好、响应速度快、稳态误差小等优点。

关键词: 无人驾驶飞机; 涡轮喷气发动机; 人工神经网络; 自适应控制

中图分类号: V233.7

文献标识码: A

文章编号: 1001-4055 (2003) 06-0517-04

Neural network PID adaptive control in pilotless aircraft turbojet engine

MA Jing¹, YANG Yu-wu², WANG Yong-gen¹

(1. Dept. of Aeroengine Engineering, Northwestern Polytechnical Univ., Xi'an 710072, China;

2. The Military Products Research Inst. of Xi'an YuanDong Company, Xi'an 710073, China)

Abstract: The work presented here aims establishing the self-adaptive PID neural network control on the basis of the combination of the identification network of the RBF neural network and the controller of the BP neural network. RBF neural network adopts the off-line training and the on-line adaptation of weight and threshold value. In order to speed up the convergence, the grads descent method with inertia item was used. Massive stimulation proves the superiority of the RBF network to the ELM and the standard and the ameliorated BP. Stimulation to the pilotless aircraft turbojet engine proves several advantages of this controlling method, such as good robustness, sensitive response, and minimal stable error.

Key words: Pilotless aircraft; Turbojet engine; Artificial neural network; Adaptive control

1 引 言

无人机涡喷发动机是一个非线性对象, 其数学模型的参数不仅随工况变化, 而且随飞行条件而变。在全飞行包线内要控制发动机, 控制器必须具有极强的鲁棒性。这对于常规的控制方法是难以胜任的, 因此一般都将飞行包线划成若干个区域, 每个区域设计一个控制器。显然, 这将使控制系统变得异常复杂。

神经网络具有学习、自适应、并行处理以及能以无限精度逼近一个连续有界的非线性函数等突出优点。而 PID 控制具有结构和控制算法简单, 参数物理意义明确, 以及对模型依赖小等优点。即使在新控制理论和新控制方法不断涌现的今天, PID 控制仍然在众多领域广泛被采用。将神经网络和 PID 控制结合

在一起, 充分发挥各自长处, 将使航空发动机控制系统在全飞行包线内的分区的多个控制器被一个神经网络自适应 PID 控制器所代替。

2 神经网络控制器的结构和算法

在基于 RBF 网络的 PID 控制中, 采用了神经网络自校正控制方式, 它包括神经网络控制器(NNC)和神经网络辨识器(NNI)两部分^[1~4], 结构如图 1 所示。

NNI 选用 3 层 RBF 网络。已经证明三层前向网络可逼近任意有界连续非线性函数; 为加快收敛速度, 辨识算法采用带惯性项的梯度下降法。

RBF 神经网络辨识器采用全连接的三层前向网络。

对象的数学描述:

* 收稿日期: 2003-01-13; 修订日期: 2003-05-23。

作者简介: 马 静 (1972—), 女, 硕士, 讲师, 研究领域为航空动力装置及控制理论。E-mail: youngrong@sohu.com




Fig. 1 NN self-adaptive controlling system

$$y(k+1) = f[y(k), \dots, y(k-n+1), u(k), \dots, u(k-m+1)] \quad (1)$$

输入矢量:

$$\mathbf{x}_k = [x_1(k), x_2(k), \dots, x_{nl}(k)]^T \quad (2)$$

$$x_i(k) = \begin{cases} y(k-i) & (1 \leq i \leq n) \\ u(k-i-n+1) & (n+1 \leq i \leq nl) \end{cases} \quad (3)$$

其中 m, n 分别为系统输入 $u(k)$, 输出 $y(k)$ 的阶次。

RBF 网络的输出为:

$$\hat{y}(x) = \sum_{i=1}^{n_h} \omega_i \phi_i(x, \mu_i) \quad (4)$$

式中 $\phi_i(x, \mu_i) = \exp(-\frac{\|x - \mu_i\|^2}{2h_i^2})$ 为高斯函数; μ_i , h_i 分别为隐层的第 i 个神经元中心和均方差宽度。

学习指标:

$$J_1 = \sum_{k=0}^{n_h} \frac{1}{2} [y(k+1) - \hat{y}(k+1)]^2 \quad (5)$$

权系数调整:

隐含层到输出层的线性权值

$$\omega_i(k+1) = \omega_i(k) - \eta_1 [y(k+1) - \hat{y}(k+1)] \cdot \phi_i(x, \mu_i) + \alpha [\omega_i(k) - \omega_i(k-1)] \quad (6)$$

输入层到隐含层的 RBF 中心和均方差宽度

$$\begin{aligned} \mu_i(k+1) &= \mu_i(k) - \eta_2 [y(k+1) - \hat{y}(k+1)] \cdot \omega_i \phi_i(x, \mu_i) \frac{\|x - \mu_i\|^2}{h_i^3} + \alpha [\mu_i(k) - \mu_i(k-1)] \\ h_i(k+1) &= h_i(k) - \eta_3 [y(k+1) - \hat{y}(k+1)] \cdot \omega_i \frac{x_i - \mu_i}{h_i^2} + \alpha [h_i(k) - h_i(k-1)] \end{aligned} \quad (7)$$

$$\begin{aligned} \mu_i(k+1) &= \mu_i(k) - \eta_3 [y(k+1) - \hat{y}(k+1)] \cdot \omega_i \frac{x_i - \mu_i}{h_i^2} + \alpha [\mu_i(k) - \mu_i(k-1)] \\ h_i(k+1) &= h_i(k) - \eta_3 [y(k+1) - \hat{y}(k+1)] \cdot \omega_i \frac{x_i - \mu_i}{h_i^2} + \alpha [h_i(k) - h_i(k-1)] \end{aligned} \quad (8)$$

式中 $i = 1, 2, \dots, n_h$, n_h 为隐层神经元数, η_1, η_2, η_3 为学习速率, α 为动量因子。而 $\alpha [\omega_i(k) - \omega_i(k-1)]$ 或 $\alpha [h_i(k) - h_i(k-1)]$ 称之为惯性项, 目的是为了加快收敛速度。

NNC 为 2 层前向网络数学描述为

输入层:

$$\begin{cases} l_1(k) = e(k) \\ l_2(k) = \sum_{i=0}^k e(i) \\ l_3(k) = \Delta e(k) = e(k) - e(k-1) \end{cases} \quad (9)$$

式中 $e(k) = r(k) - y(k)$

$$\text{输出层} \quad u(k) = \sum_{i=1}^3 k_i l_i(k) \quad (10)$$

学习指标:

$$J_{ck} = \sum_{k=0}^{n_h} \frac{1}{2} [r(k+1) - \hat{y}(k+1)]^2 \quad (11)$$

权值修正:

$$\Delta k_i(k) = \lambda [r(k) - \hat{y}(k)] l_i(k) \frac{\partial \hat{y}(k)}{\partial u(k)} \quad (12)$$

式中 $0 < \lambda < 1$

$$\frac{\partial \hat{y}(k)}{\partial u(k)} = \sum_{i=1}^m \omega_i \phi_i(x, \mu_i) \frac{h_i(k+1) - u(k)}{h_i^2} \quad (13)$$

3 无人机涡喷发动机控制的仿真研究

航空发动机作为飞机的动力装置, 在很大程度上决定了飞机的性能和用途。

3.1 确定网络结构和输入向量

某型无人机的发动机模型作为控制对象。输入、输出量分别为燃油流量 m_f 和发动机转速 n 。

发动机简化模型如下:

$$G(s) = \frac{n(s)}{m_f(s)} = \frac{K}{Ts + 1} e^{-\tau s} \quad (14)$$

式中 K 为发动机放大系数, T 为发动机时间常数, τ 为燃烧室燃烧滞后时间。

K 和 T 值随发动机不同高度 H 和 M 而变化, 在地面状态下:

$$K = K_0, T = T_0, \tau = 0.3s$$

在高空额定状态下为

$$K = 1.39K_0, T = 2.137T_0, \tau = 0.3s$$

其中 $K_0 = 0.367, T_0 = 0.496$

按图 1 构成转速控制系统。为提高 NNI 的辨识精度, 先进行离线学习, 以便确定网络输入层、隐层、输出层的节点个数和所需的权值、阈值的初始值; 然后在线修正网络权值和阈值, 为 NNC 提供所需信息。

3.2 仿真^[3]

仿真参数^[5] 选择如下: NNC 的学习效率 λ 为 0.2, 动量因子为 0.95。在 NNI 的输入端分别加斜坡

信号;径向基函数的扩展常数选为 0.008, 允许误差为 0.001。

(1) 对象模型的辨识仿真
神经网络辨识结果如图 2 所示。
图 2 中曲线 *a* 为地面状态的辨识结果, *b* 为空中额定状态的辨识结果; 1 为对象实际输出, 2 为 RBF 网络辨识结果。辨识的误差见图 3。

作为对比, 表 1 列出了辨识器选取不同结构的神经网络的仿真性能对比, 包括 RBF 网络、ELM 网络和各种算法的 BP 网络的仿真结果进行对照。

Table 1 NN stimulating feature comparison				
Type	Structure of NN	Train step	Error	Train time
RBF	$1 \times 46 \times 1$	46	10^{-16}	4s
ELM	$1 \times 10 \times 1$	500	10^{-3}	32s
Standard BP	$1 \times 20 \times 10 \times 1$	50000	1.23×10^{-1}	1406s
Improved BP	$1 \times 50 \times 1$	8000	0.8×10^{-2}	785s
BP of L-M algorithm	$1 \times 55 \times 1$	500	0.2×10^{-2}	48s

(2) 控制系统的仿真
以斜坡信号作为整个控制系统的输入。控制器 NNC 网络的权值由 PID 控制器预置初值以减小学习时间。




Fig. 2 Identification result of sinusoidal input




Fig. 5 Slope response of the system in air (1)




Fig. 3 Identification error of the sinusoidal input




Fig. 4 Slope response of the system on ground




Fig. 6 Slope response of the system in air (2)

地面学习、地面应用: 地面状态下仿真结果如图 4 所示, 图中曲线 1 为控制系统输入, 2 为被控系统的输出响应, 3 为神经网络控制器 (NNC) 输出控制信号。

(3) 神经网络控制鲁棒性检验
神经网络控制鲁棒性检验结果见表 2。

Table 2 NN control feature comparison				
Train method		Structure of NN	Train time	Error
Train ground App. in air	Object identify	$1 \times 54 \times 1$	5s	0.045
	Control system	3×1	118s	0.22
Train ground and air APP. in air	Object identify	$1 \times 54 \times 1$	3s	0.025
	Control system	3×1	68s	0.12

表 2 中地空学习指采用地面和空中的数据样本点同时让神经网络进行学习; 空中应用指采用空中数据作为实际输入。

地面学习、空中应用: 空中各状态下, 在斜坡信号输入时的仿真结果如图 5 所示。

地空学习、空中应用: 空中各状态下, 在斜坡信号输入时的仿真结果如图 6 所示。

图 5, 图 6 中曲线 1: $K = 1.39K_0$, $T = 2.137T_0$, 曲线 2: $K = 3.252K_0$, $T = 4.02T_0$, 曲线 3: $K = 2.04K_0$, $T = 1.28T_0$, 曲线 4 为控制系统的输入。

比较图 5 和图 6 可见: 图 6 响应曲线的超调量、调节时间比图 5 明显要小。表明神经网络在学习过程中输入的样本点的数目, 以及与实际应用中的输入信号的符合程度, 在很大程度上决定了神经网络控制效果的好坏。

4 结 论

(1) 虽然 BP 网络泛化能力(即相近输入产生相近输出, 不同输入产生不同输出, 具有连续模拟输入输出能力)较强, 但对于辨识追求的是精确性。从表 1 可见, RBF 神经网络用于无人机发动机的辨识, 结构简单, 精度高, 学习时间短, 辨识误差小。所以其辨识性能优于表 1 中所列的其它网络。

(2) 神经网络自适应 PID 控制系统不仅使系统的稳态误差(在论文中的输入信号形式作用下)为零, 更具有学习能力强、鲁棒性好等优点, 特别适合类似于航空发动机的具有不同飞行条件、不同工作状态的系统的控制。

(3) 对于同一类型的神经网络, 各层神经元的数目越多, 网络可调参数增加, 逼近能力增强, 误差减少, 学习时间缩短。但对于特定的控制对象, 数学模

型已定, 就有一个最佳的网络结构和网络参数(如 BP 网络的学习效率、动量系数, ELMAN 网络的初始自适应学习率、增加比例、减小比例和 RBF 网络的扩展系数), 并不是神经元数目越多越好。过多的神经元会使系统可调参数也过多, 不能在学习时间里, 全部达到最优值。

参考文献:

- [1] Robert M S, Jearr J E S. Gaussian networks for direct adaptive control[J]. *IEEE Trans on Neural Network*, 1992, (6).
- [2] Yan li, Narainhan S P S. Stale neuro-flight controller using fully tuned radial basis function networks[J]. *Journal of Guidance, Control, And Dynamics*, 2001, (4).
- [3] Calise A J, Rysdyk R T. Nonlinear adaptive flight control using neural networks[J]. *IEEE Control Systems Magazine*, 1998, (6).
- [4] 王永骥, 涂 健. 神经元网络控制[M]. 北京: 机械工业出版社, 1997.
- [5] 从 爽. 面向 MATLAB 工具箱的神经网络理论与应用[M]. 合肥: 中国科技大学出版社, 2002.

(编辑: 梅 瑛)

(上接第 516 页)

- [4] Olynick D R, Henline W D. Navier-Stokes heating calculations for benchmark thermal protection system sizing[J]. *Journal of Spacecraft & Rockets*, 1996, 33(6).
- [5] Mayer E, P R. Rocket plume impingement heat transfer on plane surfaces[J]. *Journal of Spacecraft & Rockets*, 1987, 24(4).
- [6] Nelson H F, Fields J C. Heat transfer in two-phase solid-rocket plumes[J]. *Journal of Spacecraft & Rockets*, 1996, 33(4).
- [7] Miller Eugene. Prediction of the dissipation of a solid-rocket

contrail[J]. *Journal of Propulsion & Power*, 2000, 16(5).

- [8] Pessoa Filho J B, Cotta R M. Thermal radiation from solid propellant rocket exhaust plumes[J]. *Heat & Technology*, 1996, 14(1).
- [9] Christou C T, Loda R T, Levin D A. Simulation of range-resolved DIAL measurements on in-flight rocket plumes[J]. *Journal of Thermophysics & Heat Transfer*, 1993, 7(2).

(编辑: 朱立影)