

文章编号: 1000-8055(2007)11-1921-04

基于 QDRNN 网络的航空发动机多变量解耦控制

李华聪, 荣立烨, 朱玉斌

(西北工业大学 动力与能源学院, 西安 710072)

摘 要: 针对航空发动机非线性模型的复杂性, 通过对准对角递归神经网络(QDRNN)及梯度下降法(GMD)的分析, 研究了基于 QDRNN 网络的航空发动机多变量解耦 PID 控制系统. 阐明了该算法的结构和原理, 通过对设计点及非设计点的仿真. 研究表明, QDRNN 网络结构简单, 易于构造训练算法, 较好地解决了双变量控制系统中变量之间的耦合作用.

关 键 词: 航空、航天推进系统; 航空发动机; 准对角递归神经网络(QDRNN); 多变量控制; 解耦
中图分类号: V233.7 **文献标识码:** A

Multivariable decoupling control of aeroengine based on QDRNN

LI Huacong, RONG Liye, ZHU Yubin

(School of Power and Energy, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: Through analysis of QDRNN (quasidiagonal recurrent neural network) and GMD (gradient decent method), a multivariable decoupling PID (proportional integral, differential) control system based on QDRNN was presented to resolve the complex nonlinear model of aeroengine. The structure and principle of the algorithm were also illustrated through simulation of design points and non design points. The research results show that, a multivariable decoupling PID control system based on QDRNN is well suited for decoupling of variables in dual variable control system.

Key words: aerospace propulsion system; aeroengine; quasidiagonal recurrent neural network (QDRNN); multivariable control; decoupling control

航空发动机作为被控对象, 具有强耦合性以及明显不确定性特征. 随着航空发动机技术的不断进步, 性能的不断提高, 对于航空发动机控制的要求也随之提高. 神经网络以其强大的非线性逼近能力、自学习和适应能力等特点, 被广泛应用于控制系统建模、控制器设计、故障诊断和系统优化等领域^[1-4]. 神经网络在非线性系统解耦控制中的应用研究已取得很多成果, 与传统的前向神经网络相比, 递归网络具有较强的表达、处理瞬态信息的能力, 适合于解决非线性系统的动态问题^[5]. 本文选取的准对角递归神经网络^[6](QDRNN)是一种特殊的递归神经网络, 它的结构简单, 且容易构造训练算法.

针对航空发动机工作的复杂性, 本文将 QDRNN 网络与 PID 控制器结合, 构成了基于 QDRNN 网络的双变量动态解耦 PID 控制方法. 通过采用 QDRNN 网络对 PID 控制器参数在线整定, 得到了满意的控制效果.

1 QDRNN 神经网络的 Jacobian 信息辨识

QDRNN (quasidiagonal recurrent neural network) 神经网络是一种递归神经网络, 网络结构共有三层, 隐层为递归层, 同时考虑到隐层神经元之间的联系, 其结构如图 1 所示(图中 D 表示延迟).

收稿日期: 2006-10-16; 修订日期: 2007-02-08

作者简介: 李华聪(1962), 男, 黑龙江佳木斯人, 副教授, 硕士, 主要从事航空发动机控制元件和控制系统的研究。




图 1 QDRNN 神经网络结构

Fig1 Structure of QDRNN

在 QDRNN 神经网络中, 设 $I=[I_1, I_2, \dots, I_n]$ 为网络输入向量, $I_i(k)$ 为输入层第 i 个神经元的输入, 网络递归层第 j 个神经元的输出为 $X_j(k)$, $S_j(k)$ 为第 j 个递归神经元输入总合, $f(\cdot)$ 为 S 函数, $O(k)$ 为 QDRNN 网络的输出.

QDRNN 神经网络的算法为

$$O(k) = \sum_j W_j^0 X_j(k)$$

$$X_j(k) = f(S_j(k))$$

$$S_j(k) = W_{ij}^D X_j(k-1) + \sum W_{ij}^1 I_i(k)$$

式中, W^1 和 W^0 分别为网络输入层和输出层的权值向量, W^D 则为网络递归层的权值向量, 其表达式为如下的准对角阵.

$$W^D = \begin{bmatrix} w_{11}^D & w_{12}^D & \dots & 0 \\ w_{21}^D & w_{22}^D & w_{23}^D & \dots \\ \vdots & \vdots & \vdots & \vdots \\ 0 & \dots & w_{n-1,n-2}^D & w_{n-1,n-1}^D & w_{n-1,n}^D \\ & & & w_{n,n-1}^D & w_{n,n}^D \end{bmatrix}$$

同时, $f(x)$ 函数为 sigmod 函数, 即 $f(x) = \frac{1-e^{-x}}{1+e^{-x}}$

辨识误差为 $e_m = y(k) - y_m(k)$,

选取性能指标为 $J = \frac{1}{2} e_m^2 = \frac{1}{2} (y(k) - y_m(k))^2$

采用梯度下降法^[7]对权值进行修正

$$\Delta w_j^0(k) = -\frac{\partial J}{\partial w_j^0} = e_m(k) \frac{\partial y_m}{\partial w_j^0} = e_m(k) X_j(k)$$

$$w_j^0(k) = w_j^0(k-1) + \eta_D \Delta w_j^0(k) + \alpha(w_j^0(k-1) - w_j^0(k-2))$$

$$\Delta w_{ij}^1(k) = -\frac{\partial J}{\partial w_{ij}^1} = e_m(k) \frac{\partial y_m}{\partial w_{ij}^1} =$$

$$e_m(k) \frac{\partial y_m}{\partial X_j} \frac{\partial X_j}{\partial w_{ij}^1} = e_m(k) w_j^0 Q_{ij}(k)$$

$$w_{ij}^1(k) = w_{ij}^1(k-1) + \eta_D \Delta w_{ij}^1(k) + \alpha(w_{ij}^1(k-1) - w_{ij}^1(k-2))$$

其中, $Q_{ij}(k) = \frac{\partial X_i}{\partial w_{ij}} = f'(S_j) I_i(k)$

而, $\Delta w_{ij}^D = -\frac{\partial J}{\partial w_{ij}^D} = e_m(k) \frac{\partial y_m}{\partial X_j} \frac{\partial X_j}{\partial w_{ij}^D} = e_m w_j^0 P(k)$

$$w_{ij}^D(k) = w_{ij}^D(k-1) + \eta_D \Delta w_{ij}^D(k) + \alpha(w_{ij}^D(k-1) - w_{ij}^D(k-2))$$

式中

$$P(k) = \begin{cases} \frac{\partial X_j}{\partial w_{i,i}^D} = f'(S_j) X_i(k-1) & i = 1, \dots, l \\ \frac{\partial X_j}{\partial w_{i,i+1}^D} = f'(S_j) X_{i+1}(k-1) & i = 1, \dots, l-1 \\ \frac{\partial X_j}{\partial w_{i,i+1}^D} = f'(S_j) X_{i+1}(k-1) & i = 2, \dots, l \end{cases}$$

η , η_D , η_D 分别为输入、输出层和递归层的学习率, α 为惯性系数. 对象的 Jacobian 信息为: $\frac{\partial y}{\partial u} \approx \frac{\partial y_m}{\partial u} = \sum_j w_j^0 f'(S_j) w_{ij}^1$

2 QDRNN 网络在航空发动机控制中的应用

2.1 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. 选取供油量控制低压涡轮出口温度, 同时用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

$$\begin{bmatrix} \dot{n}_H \\ \dot{n}_L \end{bmatrix} = A \begin{bmatrix} n_H \\ n_L \end{bmatrix} + B \begin{bmatrix} m_f \\ A_8 \end{bmatrix}; \begin{bmatrix} T_5 \\ \pi_T \end{bmatrix} = C \begin{bmatrix} n_H \\ n_L \end{bmatrix} + D \begin{bmatrix} m_f \\ A_8 \end{bmatrix}$$

其中, A 、 B 、 C 、 D 为系数矩阵; n_H 为高压转子转速; n_L 为低压转子转速; T_5 为低压涡轮出口温度; π_T 为涡轮落压比; m_f 为主燃油供油量; A_8 为尾喷管喉部面积.

2.2 基于 QDRNN 网络的航空发动机控制系统

图 2 为基于 QDRNN 网络的航空发动机控




图 2 基于 QDRNN 网络的航空发动机双变量解耦控制系统结构框图

Fig 2 Block diagram of control system based on QDRNN

制系统的结构图. 该系统采用经典的 PID 控制, 通过 QDRNN 网络对 PID 控制器的参数 k_p, k_i, k_d 进行整定. 系统的输出为 $y_1(k), y_2(k)$.

根据图 2, 控制算法如下:

$$u(k) = k_p(k)x_1(k) + k_i(k)x_2(k) + k_d(k)x_3(k)$$
$$error(k) = r(k) - y(k)$$
$$x_1(k) = error(k)$$
$$x_2(k) = \sum_{i=1}^k (error(k) \times T)$$
$$x_3(k) = \frac{error(k) - error(k-1)}{T}$$

其中, T 为采样时间.

PID 的三项系数 k_p, k_i, k_d 采用 QDRNN 网络进行在线整定.

$$k_p = k_p(k-1) - \eta_p \frac{\partial E}{\partial k_p} = k_p(k-1) + \eta_p (r(k) - y(k)) \frac{\partial y}{\partial u} \frac{\partial u}{\partial k_p} =$$
$$k_p(k-1) + \eta_p (r(k) - y(k)) \frac{\partial y}{\partial u} x_1(k)$$
$$k_i = k_i(k-1) - \eta_i \frac{\partial E}{\partial k_i} = k_i(k-1) + \eta_i (r(k) - y(k)) \frac{\partial y}{\partial u} \frac{\partial u}{\partial k_i} =$$
$$k_i(k-1) + \eta_i (r(k) - y(k)) \frac{\partial y}{\partial u} x_2(k)$$
$$k_d = k_d(k-1) - \eta_d \frac{\partial E}{\partial k_d} = k_d(k-1) + \eta_d (r(k) - y(k)) \frac{\partial y}{\partial u} \frac{\partial u}{\partial k_d} =$$
$$k_d(k-1) + \eta_d (r(k) - y(k)) \frac{\partial y}{\partial u} x_3(k)$$

3 航空发动机 QDRNN 网络控制系统仿真

根据上述建立的基于 QDRNN 神经网络多变量解耦 PID 控制系统, 选择已有的某型涡扇发动机气动数学模型建立的小偏离相对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

$$\begin{bmatrix} \dot{n}_H \\ \dot{n}_L \end{bmatrix} = \begin{bmatrix} -2.2642 & -0.3802 \\ 2.96985 & -2.7508 \end{bmatrix} \begin{bmatrix} n_H \\ n_L \end{bmatrix} + \begin{bmatrix} 0.7128 & 1.0390 \\ 0.6345 & 1.6709 \end{bmatrix} \begin{bmatrix} m_I \\ A_8 \end{bmatrix}$$
$$\begin{bmatrix} T_5 \\ \pi_r \end{bmatrix} = \begin{bmatrix} -0.4276 & 0.1051 \\ 1.2810 & -0.0511 \end{bmatrix} \begin{bmatrix} n_H \\ n_L \end{bmatrix} +$$

$$\begin{bmatrix} 0.5064 & 0.3208 \\ -0.1308 & 0.1567 \end{bmatrix} \begin{bmatrix} m_I \\ A_8 \end{bmatrix}$$

对于本文设计中的学习效率 η_p, η_i, η_d , 考虑到学习速率对收敛速度及系统的稳定性的影响, 选择 $\eta_p = 0.50, \eta_i = 0.35, \eta_d = 0.10$.

3.1 设计点仿真

飞行条件为 $H = 0, Ma = 0$ 时. 图 3 表示当 $T_{5,r} = 1, \pi_{r,r} = 0$ 时, 航空发动机 T_5 和 π_r 的响应曲线; 图 4 表示当 $T_{5,r} = 0, \pi_{r,r} = 1$ 时, 航空发动机 T_5 和 π_r 的响应曲线.




图 3 $H = 0, Ma = 0, T_{5,r}$ 阶跃响应
Fig3 $H = 0, Ma = 0$, step response of $T_{5,r}$




图 4 $H = 0, Ma = 0, \pi_{r,r}$ 阶跃响应
Fig 4 $H = 0, Ma = 0$, step response of $\pi_{r,r}$

由图 3 和图 4 可知, 在设计点, 基于 QDRNN 神经网络的航空发动机多变量的 PID 解耦控制系统具有良好的解耦性.

3.2 非设计点仿真

飞行条件为 $H = 11 \text{ km}, Ma = 0.9$ 时. 图 5 表示当 $T_{5,r} = 1, \pi_{r,r} = 0$ 时, 航空发动机 T_5 和 π_r 的响应曲线. 图 6 表示当 $T_{5,r} = 0, \pi_{r,r} = 1$ 时, 航空发动机 T_5 和 π_r 的响应曲线.

飞行条件为 $H = 20 \text{ km}, Ma = 1.7$ 时. 图 7 表示当 $T_{5,r} = 1, \pi_{r,r} = 0$ 时, 航空发动机 T_5 和 π_r 的响应曲线. 图 8 表示当时 $T_{5,r} = 0, \pi_{r,r} = 1$, 航空发动机 T_5 和 π_r 的响应曲线.




图 5 $H=11\text{ km}, Ma=0.9, T_{5,r}$ 阶跃响应
Fig 5 $H=11\text{ km}, Ma=0.9, \text{step response of } T_{5,r}$




图 6 $H=11\text{ km}, Ma=0.9, \pi_{T,r}$ 阶跃响应
Fig 6 $H=11\text{ km}, Ma=0.9, \text{step response of } \pi_{T,r}$




图 7 $H=20\text{ km}, Ma=1.7, T_{5,r}$ 阶跃响应
Fig 7 $H=20\text{ km}, Ma=1.7, \text{step response of } T_{5,r}$




图 8 $H=20\text{ km}, Ma=1.7, \pi_{T,r}$ 阶跃响应
Fig8 $H=20\text{ km}, Ma=1.7, \text{step response of } \pi_{T,r}$

通过图 5~ 8 可以看出,对于航空发动机非设计点处,基于 QDRNN 神经网络的航空发动机多变量的 PID 解耦控制系统,在系统参数变化较大的情况下,仍然能够通过神经网络的在线学习自适应的调整 PID 控制器的参数,以达到解耦的目的,较好的消除了双变量控制系统的耦合。

4 结 论

本文采用了基于 QDRNN 神经网络的航空发动机多变量的 PID 解耦控制系统,针对航空发动机非线性模型的复杂性,较好的解决了双变量控制系统变量之间的耦合作用,同时保证了系统良好的稳态性能.由于 QDRNN 网络结构简单,并且有较好的非线性逼近能力,因此基于 QDRNN 网络构建的航空发动机解耦控制系统适合于发动机这样的大时变、非线性的控制对象。

参考文献:

[1] Kumpati S N, Ukhopadhyay S M. Intelligent control using neural networks [J]. IEEE Control, April, 1992: 14-18.

[2] Narendra K S, Parthasarathy K. Identification and control for dynamic systems using neural networks [J]. IEEE Trans. On Neural Networks, 1990, 1 (1) : 4-27.

[3] Chen T C, Sheu T T. Model reference neural network controller for induction motor speed control [J]. IEEE Transaction on Energy Conversion, 2002, 17 (2) : 157-163.

[4] Chow W S, Fang Y. A recurrent neural network based real-time learning control strategy applying to nonlinear systems with unknown dynamics [J]. IEEE Trans on Neural Network, 1998, 45 (1) : 151-161.

[5] Dray 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] 李鸿儒,王建辉,顾树生. 准对角递归神经网络及其算法的研究 [J]. 系统仿真学报, 2004, 07: 1542-1544.

LI Hongru, WANG Jianhui, GU Shusheng. Study on a quasi-diagonal recurrent neural network and its algorithm [J]. Acta Simulata Systematica Sinica, 2004, 07: 1542-1544.

[7] 刘金琨. 先进 PID 控制及其 MATLAB 仿真 [M]. 北京: 电子工业出版社, 2003.