

基于 DRNN 网络的航空发动机多变量解耦控制*

朱玉斌, 樊思齐, 任新宇, 时瑞军

(西北工业大学 动力与能源学院, 陕西 西安 710072)

摘 要: 通过分析对角递归神经网络 (DRNN) 及带动量项的梯度学习方法 (GDM), 针对某型涡扇发动机的性能控制, 研究了基于对角递归神经网络的多变量自学习解耦控制算法及其在航空发动机控制中的应用。阐明了该方法的结构和原理。并在设计点处进行了发动机多变量解耦控制系统设计。在偏离设计点时, 大量的仿真结果表明, 系统具有较好解耦和自适应能力。

关键词: 航空发动机; 对角递归神经网络⁺; 多变量控制; 解耦⁺

中图分类号: V233.7 文献标识码: A 文章编号: 1001-4055 (2006) 02-0150-04

A multivariable decoupling control based on DRNN for aeroengine

ZHU Yu-bin, FAN Si-qi, REN Xin-yu, SHI Rui-jun

(School of Power and Energy, Northwestern Polytechnic Univ., Xi'an 710072, China)

Abstract A new neural paradigm called diagonal recurrent neural network (DRNN) and Gradient Decent Method (GDM) were presented. A multivariable decoupling control algorithm based on the diagonal recurrent neural network was used for aeroengine control. A generalized GDM was developed and used to train diagonal recurrent neuroidentifier. The emphasis was focused on the research of the algorithm and the properties of the controller as well as their application to aeroengine control by computer simulation. Finally, the aeroengine control system based on DRNN was designed. Simulation shows that the system has fine performance of decoupling and adaptive capabilities.

Key words Aeroengine; Diagonal recurrent neural network⁺; Multivariable control; Decoupling⁺

1 引 言

神经网络由于具有高精度逼近任意的非线性函数、很强的自学习和适应能力, 因而广泛应用于控制系统的建模、控制器设计、故障诊断和系统优化^[1~4]等方面。传统的前向神经网络尤其是 BP 神经网络或 RBF 网络, 结构和算法简单, 因而在基于被控对象数学模型的自适应神经网络控制中倍受青睐。但由于前馈神经网络属于静态网络, 在处理非线性动态系统中存在不能反映动态映射和动态记忆能力。而全反馈递归网络虽然具有动态映射和动态记忆能力, 但结构复杂, 如全反馈的 Hopfield 网络。

针对以上问题, 本文采用了结构简单而有效的对角递归神经网络^[5] (DRNN) 对系统进行动态辨识, 采用带动量项的梯度优化算法进行权值学习, 由 DRNN

获得对象的 Jacobian 信息 $\partial y / \partial u$, 并结合 PID 控制器设计了航空发动机多变量解耦与自适应控制系统。

2 对角递归神经网络

对角递归神经网络 (Diagonal Recurrent Neural Network) 是一种回归神经网络, 网络结构共有三层, 即输入层、输出层和隐层。其中隐层为回归层。它是在部分递归网络 Elman 网络的基础上, 将隐含层权值矩阵做了进一步简化, 变为对角阵, 即隐层的每一个神经元仅接受自己的输出反馈, 而与其它神经元无反馈连接。这样既简化了网络, 减少了需调整的参数, 又保持了网络的自反馈特性。从而大大地减少了计算量, 缩短了训练时间。与 Elman 网络相比, DRNN 网络结构简单, 而与传统的前馈神经网络相比, 它又能反映动态映射, 具有动态记忆能力。DRNN 的模型

* 收稿日期: 2005-04-25; 修订日期: 2005-07-20。

作者简介: 朱玉斌 (1977—), 男, 博士生, 研究领域为推进系统综合控制。E-mail: zhuyubin1978@hotmail.com

结构图如图 1 所示。




Fig 1 Architecture of diagonal recurrent neural network

其中 $I_i(k)$ 为 DRNN 网络的第 i 个输入, $O(k)$ 为 DRNN 网络的输出, $S_j(k)$ 为第 j 个回归神经元节点的输入总和, $x_j(k)$ 为第 j 个回归神经元节点的输出。 W_{ij}^l, W_j^d, W_j^o 分别表示为输入层、隐层和输出层权值。图中的 D 表示延迟。DRNN 的输入输出映射关系可由下列数学模型描述

$$O(k) = \sum_j W_j^o X_j(k), X_j(k) = f(s_j(k)) \quad (1)$$

$$S_j(k) = W_j^d X_j(k-1) + \sum_i W_{ij}^l I_i(k) \quad (2)$$

式中 $f(x)$ 函数为 Sigmoid 函数, 即

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (3)$$

3 DRNN 的优化学习算法

取性能指标 $J = \frac{1}{2} (y(k) - y_m(k))^2$, 辨识误差

$E_m(k) = y(k) - y_m(k)$ 。式中 $y(k)$ 为系统输出, $y_m(k)$ 为辨识器输出, k 为网络迭代的步数。

由数学模型式 (1), (2) 可求得网络输出层对输入层权值、隐层权值和输出层的权值的偏导数可表示为

$$\frac{\partial y_m(k)}{\partial W_{ij}^l} = W_j^o Q_{ij}(k), \frac{\partial y_m(k)}{\partial W_j^d} =$$

$$W_j^o P_j(k), \frac{\partial y_m(k)}{\partial W_j^o} = x_j(k) \quad (4)$$

$$P_j(k) = f'(s_j) (x_j(k-1) + W_j^d P_j(k-1)) \quad (5)$$

$$Q_{ij}(k) = f'(s_j) (I_i(k) + W_j^d Q_{ij}(k-1)) \quad (6)$$

DRNN 各层权值的调整采用带动量项的梯度算法^[6]。

$$\Delta W_{ij}^o(k) = \frac{\partial J(k)}{\partial W_{ij}^o} = - \frac{\partial J(k)}{\partial y_m(k)} \cdot$$

$$\frac{\partial y_m(k)}{\partial W_j^o} = E_m(k) x_j(k) \quad (7)$$

$$W_{ij}^o(k) = W_{ij}^o(k-1) + \eta_o \Delta W_{ij}^o(k) + \alpha (W_{ij}^o(k-1) - W_{ij}^o(k-2)) \quad (8)$$

$$\Delta W_{ij}^l(k) = - \frac{\partial J(k)}{\partial W_{ij}^l} = \frac{\partial J(k)}{\partial y_m(k)} \cdot \frac{\partial y_m(k)}{\partial x_j(k)} \cdot$$

$$\frac{\partial x_j(k)}{\partial W_j^d} = E_m(k) W_j^o Q_{ij}(k) \quad (9)$$

$$W_{ij}^l(k) = W_{ij}^l(k-1) + \eta_l \Delta W_{ij}^l(k) + \alpha (W_{ij}^l(k-1) - W_{ij}^l(k-2)) \quad (10)$$

$$\Delta W_j^d(k) = \frac{\partial J(k)}{\partial W_j^d} = - \frac{\partial J(k)}{\partial y_m(k)} \cdot \frac{\partial y_m(k)}{\partial x_j(k)} \cdot$$

$$\frac{\partial x_j(k)}{\partial W_j^d} = E_m(k) W_j^o P_j(k) \quad (11)$$

$$W_j^d(k) = W_j^d(k-1) + \eta_d \Delta W_j^d(k) + \alpha (W_j^d(k-1) - W_j^d(k-2)) \quad (12)$$

$$P_j(k) = \frac{\partial x_j}{\partial W_j^d} = f'(s_j) x_j(k-1),$$

$$Q_{ij}(k) = \frac{\partial x_j}{\partial W_{ij}^l} = f'(S_j) I_i(k) \quad (13)$$

式中 η_l, η_d, η_o 分别为输入层、隐含层和输出层的学习效率。当学习步长加大时, 可使收敛速度加快, 但易产生振荡和不稳。 α 为惯性系数, 加入惯性系数后, 权值修正不但取决于梯度, 还取决于上一步权值变化。由此得到对象的 Jacobian 信息

$$\frac{\partial y}{\partial u} \approx \frac{\partial y_m}{\partial u} = \sum_j W_j^o f'(S_j) W_{ij}^l \quad (14)$$

4 DRNN 网在航空发动机控制中的应用

4.1 航空发动机线性数学模型

某型涡扇发动机控制系统是双变量的控制结构。选用供油量控制低压转子转速, 尾喷口面积控制低压涡轮后温度。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

$$\begin{bmatrix} \dot{n}_L \\ \dot{T}_5 \end{bmatrix} = \mathbf{A} \begin{bmatrix} n_L \\ T_5 \end{bmatrix} + \mathbf{B} \begin{bmatrix} m_f \\ A_8 \end{bmatrix}, \begin{bmatrix} n_L \\ T_5 \end{bmatrix} = \mathbf{C} \begin{bmatrix} n_L \\ T_5 \end{bmatrix} + \mathbf{D} \begin{bmatrix} m_f \\ A_8 \end{bmatrix} \quad (15)$$

式中 $\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}$ 为系数矩阵。 n_L 表示低压转子转速, T_5 为低压涡轮出口温度, m_f 表示主燃油供油量, A_8 表示尾喷口的喉道面积。

4.2 基于 DRNN 神经网络航空发动机控制系统的结构

基于 DRNN 神经网络航空发动机多变量解耦控制系统的结构如图 2 所示。

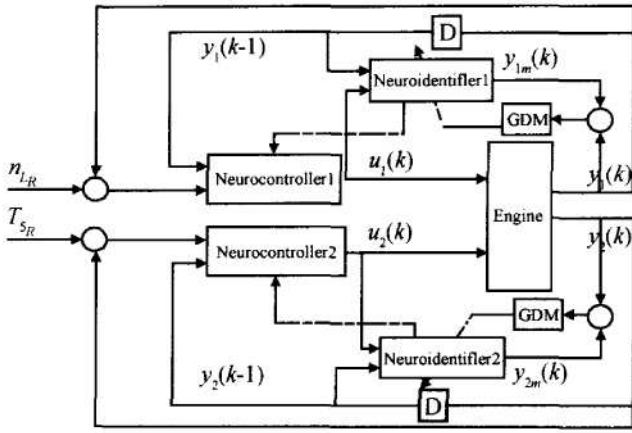


Fig 2 Block diagram of control system based on DRNN

从图 2 可以看出, 系统由神经网络辨识器、控制器和对象组成, 系统的辨识器由 DRNN 网络实现。控制器采用 PID 控制结构, PID 的参数由 DRNN 网络进行调整, GDM 为神经网络的学习方法, 控制量为 $u(k)$ 。

$$u(k) = k_p(k)x_1(k) + k_i(k)x_2(k) + k_d(k)x_3(k) \quad (16)$$

$$\text{Error}(k) = r(k) - y(k) \quad (17)$$

$$x_1(k) = \text{Error}(k) \quad (18)$$

$$x_2(k) = \sum_{i=1}^k (\text{Error}(k) \times T) \quad (19)$$

$$x_3(k) = \frac{\text{Error}(k) - \text{Error}(k-1)}{T} \quad (20)$$

式中 T 为采样时间。三个参数 k_p, k_i, k_d 由 DRNN 神经网络进行调整。

定义性能指标

$$J_c = \frac{1}{2} (r(k) - y(k))^2 \quad (21)$$

$$k_p = k_p(k-1) - \eta_p \frac{\partial J_c}{\partial k_p} = k_p(k-1) + \eta_p (r(k) - y(k)) \frac{\partial y}{\partial u} x_1(k) \quad (22)$$

$$k_i = k_i(k-1) - \eta_i \frac{\partial J_c}{\partial k_i} = k_i(k-1) + \eta_i (r(k) - y(k)) \frac{\partial y}{\partial u} x_2(k) \quad (23)$$

$$k_d = k_d(k-1) - \eta_d \frac{\partial J_c}{\partial k_d} = k_d(k-1) + \eta_d (r(k) - y(k)) \frac{\partial y}{\partial u} x_3(k) \quad (24)$$

式中 η_p, η_i, η_d 分别为系数的学习步长, $\partial y / \partial u$ 为对象的 Jacobian 信息, 该信息由前述设计的 DRNN 网络辨识得到。

5 航空发动机多变量解耦控制仿真与结果分析

根据已建立基于 DRNN 神经网络航空发动机多变量解耦控制系统。建立涡扇发动机小偏离增量形式模型, 以该涡扇发动机地面状态 $H = Q, Ma = 0$ 为仿真设计点, 其归一化相对增量状态空间模型为

$$\begin{bmatrix} n_L \\ T_5 \end{bmatrix} = \begin{bmatrix} -4.6394 & -1.6616 \\ 0.9531 & -0.7533 \end{bmatrix} \begin{bmatrix} n_L \\ T_5 \end{bmatrix} + \begin{bmatrix} 0.6401 & 1.023 \\ -0.342 & 0.236 \end{bmatrix} \begin{bmatrix} m \\ A_8 \end{bmatrix}$$

神经网络输入、隐层节点数的选择目前还没有统一的方法, DRNN 网络的隐层节点数的选择一般为输入层节点数的两倍加 1 个。即: 输入节点数为 n , 隐层节点数一般可以选为 $2n + 1$ 个。但是隐层的节点数的选择应在满足精度的前提下, 节点数尽可能的少。具体的个数只能通过试探得到。这里经过充分试探选择隐层节点数为 7 个, 输入节点数为 3 个。DRNN 网络的输出节点数只有一个。

η_i, η_p, η_d 为输入层、隐含层和输出层的学习效率, 由于当学习速率加大时, 收敛速度加快, 但易产生振荡和不稳。当学习速率减小时, 收敛的速度较慢。经过综合考虑, 本文选择的 $\eta_i = 0.25, \eta_p = 0.35, \eta_d = 0.4$ 。惯性系数为 α 加入惯性系数后, 权值修正不但取决于梯度, 还取决于上一步权值变化。本文中的 $\alpha = 0.04$ 。输入层、输出层和隐层的权值初值为 $[-1, 1]$ 之间的随机值。加入惯性系数能使系统跳出局部极小点。

在进行闭环控制仿真前, 对神经网络进行离线训练。为了使训练样本的输入尽量满足系统的要求, 确保训练完成后系统能够对未出现的信号仍能产生期望的输出。因此, 将训练样本的输入取为 $[-1, 1]$ 之间均匀分布的白噪声, 根据这些输入产生用于离线训练的 500 个训练样本。

按照上述方法进行了控制器和辨识器的设计。通过自身学习调整权值参数, 使系统取得满意的解耦和控制效果。

图 3 为在飞行条件 ($H = 0\text{km}, Ma = 0$) 下, n_{LR} 为单位阶跃时, 即: $n_{LR} = 1, T_{5R} = 0$ 时, 发动机 n_L 和 T_5 的响应; 图 4 为飞行条件 ($H = 0\text{km}, Ma = 0$) 下, T_{5R} 为单位阶跃时, 即: $n_{LR} = 0, T_{5R} = 1$ 时, 发动机 n_L 和 T_5 的响应; 图 5 和图 6 分别表示飞行条件为 $H = 9\text{km}, Ma = 0.9$ 时, n_L 和 T_5 的阶跃响应图; 图 7 和图 8 分别




Fig. 3 Step response of $n_{L,R}$ at Mach 0 and 0 km




Fig. 4 Step response of $T_{5,R}$ at Mach 0 and 0 km




Fig. 5 Step response of $n_{L,R}$ at Mach 0.9 and 9 km




Fig. 6 Step response of $T_{5,R}$ at Mach 0.9 and 9 km




Fig. 7 Step response of $n_{L,R}$ at Mach 1.5 and 18 km




Fig. 8 Step response of $T_{5,R}$ at Mach 1.5 and 18 km

表示飞行条件为 $H = 18\text{km}$, $Ma = 1.5$ 时, n_L 和 T_5 的阶跃响应图。

从以上仿真来看,在偏离设计点的飞行条件下,系统也表现出良好的性能。当飞行条件变化时,系统达到了较好的自适应性。从图 3~8 可以看出,系统具有较好的解耦特性,消除了发动机双变量耦合的影响,而且系统的响应时间较短,能够满足系统的控制要求。

6 结 论

研究表明,基于对角递归神经网络航空发动机多变量解耦控制系统结构简单、有效,易于实现。在不需精确的建模的情况下,通过自身的训练和学习,实现了多变量系统的解耦控制,并且还有一定的自适应能力。大量的仿真结果表明,基于对角递归神经网络的航空发动机多变量解耦控制方法是有效、可行的,系统也具有较好的解耦特性。它用于航空发动机控制系统中能够满足响应特性的要求。

参考文献:

- [1] Chen Tien-Chi, Sheu Tsong-Teng. Model reference neural network controller for induction motor speed control [J]. *IEEE Transaction on Energy Conversion*, 2002, 17(2).
- [2] 丁凯锋, 樊思齐. 基于 Adaline 网的航空发动机自适应控制 [J]. 推进技术, 2001, 22(1). (DING Kaifeng, FAN Siqi. Aeroengine adaptive control based on adaline network [J]. *Journal of Propulsion Technology*, 2001, 22(1).)
- [3] Toprak Suha, Erkm en Aydan M, Akm andor I Sinan. Identification and control of a radial turbojet with neural network and fuzzy logic [R]. AAA 98-1016
- [4] Rajkumar Vaidyanathan, Nilay Papila, Wei Shyy. Neural network and response surface methodology for rocket engine component optimization [R]. AAA 2000-4880
- [5] Ku Chao-Chee, Lee Kwang Y. Diagonal recurrent neural networks for dynamic systems control [J]. *IEEE Transactions on Neural Networks*, 1995, 6(1).
- [6] 刘金琨. 先进 PID 控制及其 MATLAB 仿真 [M]. 北京: 电子工业出版社, 2003

(编辑: 张奕春)