

文章编号: 1000-8055(2002)03-0381-04

基于动态 RBF 网络的发动机起动过程模型辨识

姜 涛, 李应红

(空军工程大学 工程学院, 陕西 西安 710038)

摘要: 针对航空发动机在起动过程中各截面气流处于亚临界状态, 难以利用传统的气动热力学方法进行建模的问题, 本文利用发动机地面试验数据作为学习样本, 采用动态径向基(RBF)神经网络的方法, 建立了航空发动机起动过程动态模型。仿真结果表明, 利用该方法建立的发动机模型具有动态性好, 精度高的优点, 开辟了发动机中小转速建模的新途径。

关键词: 航空发动机; 起动; 神经网络; 辨识

中图分类号: V 233. 6⁺ 3

文献标识码: A

A Dynamic Identification Model of Aeroengine Starting Process Based on the RBF Network

J I A N G T a o , L I Y i n g - h o n g

(A i r F o r c e E n g i n e e r i n g U n i v e r s i t y , X i ' a n 7 1 0 0 3 8 , C h i n a)

Abstract: In the process of engine start, the airflow of every section is in subcritical condition. It's hard to construct a model with traditional thermodynamics methods. A dynamic identification model is set up in this paper based on Radial Basis Function network using ground test data as learning samples. The simulation results show the model has good dynamic performance and high accuracy, and opens a new way to building the model of engine at low speed.

Key words: aeroengine; start; neural network; identification

1 引 言

发动机在起动过程中, 各截面都处在亚临界状态, 在特性计算中所有的基于临界和超临界状态的假设都不再适用。同时发动机的起动过程又是非线性度很高的物理化学过程, 利用常规方法建发动机起动过程模型存在很大困难。

目前, 对线性系统已经有了多种普遍适用的辨识方法, 但是对非线性系统的辨识尚处于探索阶段。神经网络因其学习能力和非线性特性, 在进行非线性系统辨识方面具有很大的潜力, 为解决

复杂的非线性、不确定系统的辨识问题, 开辟了一条有效的途径。

有些文献利用BP 网络进行航空发动机模型辨识^[1], 但BP 网络存在着局部极小问题, 同时在结构设计时, 隐层数目和节点数目的选择, 尚无明确的方法。径向基函数神经网络是由J. Moody 和C. Darken 于80年代末提出的, 具有唯一的最佳逼近特性, 且无局部极小的优点。本文利用RBF 网络, 对某型发动机的起动过程模型进行辨识, 仿真结果表明, 该神经网络很好地逼近了发动机的起动过程特性曲线。

收稿日期: 2001- 07- 06; 修订日期: 2001- 14- 24

作者简介: 姜涛(1974-), 男, 空军工程大学工程学院博士生

2 RBF 网络的结构及原理

径向基函数神经网络,是具有单隐层的3层前馈网络,输入层由信号节点组成,第二层为隐含层,第三层为输出层,输入层到隐含层的变换函数为径向基函数(RBF),从隐含层到输出层的变换是线性的,结构见图1。




图1 RBF 网络结构

Fig 1 Structure of RBF neural networks

2.1 网络的输出计算

RBF 网络第 i 个隐层节点的输出为:

$$q_i = R(\|u - c_i\|) \quad (1)$$

式中: u 为 n 维输入向量; c_i 第 i 个隐节点的中心 ($i = 1, 2, \dots, m$); $\|\cdot\|$ 通常为欧式范数; $R(\cdot)$ 为 RBF 函数, 具有局部感受特性, 它有多种形式。

本文采用高斯函数:

$$R(\cdot) = \exp\left[-\frac{\|\cdot\|^2}{2\sigma^2}\right] \quad (2)$$

$$(\sigma > 0, v \geq 0)$$

网络输出层第 k 个节点的输出, 为隐层节点输出的线性组合:

$$y_k = \sum_i \omega_{ki} q_i - \theta_k \quad (3)$$

式中: ω_{ki} 为 q_i 到 y_k 的连接权; θ_k 第 k 个输出节点的阈值。

2.2 RBF 网络的学习算法

设有 P 级输入/输出样本, 定义目标函数:

$$J = \frac{1}{2} \sum_p \|d_p - y_p\|^2 \\ = \frac{1}{2} \sum_p \sum_k (d_{kp} - y_{kp})^2 \quad (4)$$

式中: d_p 为输出样本, y_p 在输入下的网络的输出向量。

通过学习, 使目标函数 $J \leq \epsilon$, ϵ 为任一小的正数。RBF 网络的学习算法由两部分组成: 无导师

学习、有导师学习。无导师学习对所有样本的输入进行聚类, 求得各隐层节点的 RBF 中心 c_i 。有导师学习是在隐层中心 c_i 确定后, 训练由隐层到输出层之间的权系数值, 由 (3) 式知, 它是一组线性方程组, 则求权系数问题就成为线性优化问题, 可用各种优化算法求得, 如 LMS 算法、最小二乘递推法等, 参见文献 [5]。

2.3 动态神经网络辨识结构

进行动态系统的辨识, 需用动态神经网络。从神经网络的输入输出, 与被辨识系统的输入输出关系上, 可分为 2 种辨识结构: 并联型与串—并型, 分别由下列方程描述:

$$y(k) = N[y(k-1), \dots, y(k-n);$$

$$u(k-1), \dots, u(k-m); W]$$

$$\hat{y}(k) = N[\hat{y}(k-1), \dots, \hat{y}(k-n);$$

$$u(k-1), \dots, u(k-m); W]$$

式中: W 为权系数矩阵。两种辨识结构分别对应着并联型和串—并型辨识模型。




图2 串—并型结构

Fig 2 Structure of series-parallel connection

由于输出反馈的并联结构在网络训练开始时, 很难使其输出收敛于系统的输出, 可能会出现不稳定, 串—并型结构用系统的输入输出作为辨识信息, 对网络进行训练, 有利于保证辨识模型的收敛和稳定, 因此, 本文选用串—并型结构辨识模型, 如图2所示。

3 发动机起动过程模型辨识

3.1 航空发动机起动过程描述

采用供油量作为系统的输入, 高、低压气机转子转速和排气温度为输出, 航空发动机的起动过

程可用如下离散形式的非线性方程表示:

$$\begin{pmatrix} Nl(k) \\ Nh(k) \\ T4(k) \end{pmatrix} = f \begin{pmatrix} Nl(k-1) \\ Nh(k-1) \\ T4(k-1) \\ mf(k-1) \\ H(k) \\ Ma(k) \end{pmatrix} \tag{5}$$

式中: Nl 为低压转子转速, Nh 为高压转子转速, $T4$ 为涡轮后温度, mf 为供油量, H 为飞行高度, Ma 为飞行马赫数, f 为非线性函数。

3.2 训练数据的预处理

为了排除不同大气条件的影响, 在对网络进行训练之前, 首先将数据换算到标准大气条件, 然后对数据进行归一化处理。




图3 训练样本与模型输出曲线对比

Fig 3 Curves of training sample and model output

4 辨识结果

本文利用某型航空发动机的地面试车两组起动数据, 第一组数据用来进行 RBF 动态神经网络模型的训练, 作为训练样本; 第二组数据用来对该动态神经网络模型的精度和泛化能力进行检验, 用作测试样本。

为了检查神经网络模型的训练精度, 将训练数据与模型输出相比较, 结果如图3所示, 实线表示训练数据曲线, “+”号为辨识模型输出结果。由图可以看出, 训练数据和辨识模型输出结果重合, 从而表明了神经网络模型的训练精度令人满意。




图4 检测样本与模型输出曲线对比

Fig 4 Curves of testing sample and model output

为了验证神经网络模型的泛化能力, 取第二组数据对所建立的发动机起动过程模型进行检验。首先对数据进行预处理, 将不同的大气条件换算到标准大气条件下, 然后进行仿真, 结果如图4所示。图中, 实线为测试样本数据曲线, 标注有黑

点的实线为模型仿真结果输出曲线。由图可以看出, 仿真结果很好地逼近了试车曲线, 只是在开始阶段, 误差较大, 起动开始20 s以后, 模型输出就基本上测量结果相吻合了。辨识输出的低压转子转速、高压转子转速和排气温度与试车结果相比最大相对误差分别为9.1%, 11.1%, 14.1%, 由此说明, 该神经网络模型具有较好的泛化能力。

5 结 论

通过以上的研究, 可以得出如下结论:

(1) 用 RBF 网络辨识发动机起过程模型, 具有方法简单, 学习速度快, 辨识精度较高的优点, 是可行的。

(2) 本文所采用的 RBF 网络的方法来进行航空发动机起动过程模型的辨识, 为发动机在中小转速建模问题, 开辟了一条新的途径。

参考文献

- [1] 刘小勇 采用BP 网络辨识航空发动机数学模型[J]. 航空动力学报, 1996, 11(2): 153- 156
- [2] 丁凯峰, 樊思齐 基于 RBF 网络的航空发动机模型辨识[J]. 航空动力学报, 2000, 15(2): 96- 98
- [3] 史忠科 神经网络控制理论[M]. 西安: 西北工业大学出版社, 1997.
- [4] 焦李成 神经网络的应用与实现[M]. 西安: 西安电子科技大学出版社, 1996
- [5] 徐丽娜 神经网络控制[M]. 哈尔滨工业大学出版社, 1999
- [6] Alexander S Poznyak, Wen Yu Nonlinear Adaptive Trajectory Tracking Using Dynamic Neural Networks [J]. IEEE Transaction on Neural Networks, 1999, 10(6):.
- [7] Sanchez E N. Dynamic neural network for nonlinear systems identification[J]. in Proc 33rd IEEE conf Decision Contr, 1994: 2480- 2481.

(责任编辑 王震华)