

文章编号: 1000-8055(2005)03-0508-04

基于相空间重构和神经网络的 压气机机匣静压预测

吴云, 李应红, 尉询楷, 张朴
(空军工程大学 工程学院, 陕西 西安 710038)

摘要: 建立了基于相空间重构和径向基神经网络的压气机机匣静压的预测模型。对试验数据进行相空间重构, 分析其混沌特性, 根据重构相空间的最小嵌入维数确定网络输入参数的个数, 采用 K 均值聚类的方法优化网络的拓扑结构, 根据时间序列的最大李亚普诺夫指数确定预测模型的最大有效预测步数, 利用径向基神经网络的强大非线性映射能力, 实现对时间序列的非线性预测, 试验结果证明了该方法的有效性。该方法对压气机趋势监控具有一定的参考价值。

关键词: 航空、航天推进系统; 压气机; 相空间重构; 径向基神经网络; 时间序列预测

中图分类号: V 231.1

文献标识码: A

Compressor Casing Static Pressure Forecasting Via Phase Space Reconstruction and Neural Network

WU Yun, LI Ying-hong, WEI Xun-kai, ZHANG Pu

(The Engineering Institute, Air Force Engineering University, Xi'an 710038, China)

Abstract: A novel forecasting model for compressor casing wall pressure based on phase space reconstruction and radial basis function network was established. Phase space for the experimental pressure data was reconstructed, and corresponding chaotic characteristics were analyzed. Number of network input variables was determined through the computed minimum embedding dimension of the reconstructed phase space. The network's topology was optimized via K means clustering method, and the maximum effective forecasting steps was determined by computing the largest Lyapunov exponent of the examined pressure time series. Taking advantage of the strong nonlinear mapping capability of the radial basis function neural network, nonlinear forecasting of the measured time series was realized. The forecasting results successfully validate the feasibility and effectiveness of the newly developed algorithm, which may serve as a promising trend monitoring method for axial flow compressors.

Key words: aerospace propulsion system; compressor; phase space reconstruction; radial basis function network; time series forecasting

航空发动机是高度非线性的复杂系统, 对其进行精确的建模十分困难。试验所得的压气机

匣静压时间序列数据是发动机各部件通过复杂的相互作用产生的, 包含了发动机系统演化过程的

收稿日期: 2004-04-21; **修订日期:** 2004-07-29

作者简介: 吴云(1983-), 男, 江苏泰兴人, 空军工程大学工程学院飞行器与动力工程系硕士生, 主要从事航空发动机稳定性与故障诊断研究

信息。

根据Kolmogorov定理,任何一个时间序列都可以看成是由一个非线性机制确定的输入输出系统。因此,采用非线性逼近器如神经网络用作时间序列分析的预测器是完全可行的,文献[1~3]分别进行了BP网络,模糊神经网络和小波网络对混沌时间序列的预测。文献[4,5]进行了RBF网络对经典混沌时间序列的分析和预测,文献[6]对RBF网络用于航空发动机时间序列预测进行了探讨,但是对网络拓扑结构的确定未深入研究,对于最大有效预测步数也缺少详细的理论分析。

本文对试验实测的时间序列数据进行相空间重构和混沌特性分析,根据重构相空间的最小嵌入维数确定RBF网络最佳输入参数的个数,采用K均值聚类方法(K means clustering method)^[7]优化网络的拓扑结构,建立RBF网络预测模型,并将其用于某型发动机压气机机匣静压时间序列分析,得到了较好的预测效果。

1 时间序列相空间重构

某型发动机压气机机匣静压时间序列由台架试车获得,由于实测数据噪声含量较大,将影响相空间重构和非线性预测的质量,对其进行小波除噪,将除噪后的时间序列用于混沌特性分析和预测模型。

混沌时间序列预测的基础是状态空间的相重构理论,有效进行相空间重构是正确刻画系统动力学特征和时间序列非线性预报的前提。最小嵌入维数的确定和延迟时间的选择直接影响了重构相空间与原动力系统是否拓扑等价。

1.1 最小嵌入维数的确定

对时间序列 $x(i) (i=1,2,\cdots,N)$ 重构 m 维嵌入空间,为了保证该相空间完整保留原状态空间的拓扑结构,必须满足嵌入定理^[8]:如果原吸引子的维数为 d ,则嵌入空间的维数 $m \geq 2d+1$ 。

通过计算吸引子的关联维数来确定嵌入空间的最小嵌入维数,随着嵌入维数 m 的增大,关联维数的值不再变化,此时的 m 即为最小嵌入维数。计算得到时间序列的最小嵌入维数 m 为30。

1.2 延迟时间的选择

计算时间序列 $x(i) (i=1,2,\cdots,N)$ 的自相关

函数:
$$C = \frac{\sum_{i=1}^{N-\tau} (x_i - \bar{x})(x_{i+\tau} - \bar{x})}{\sum_{i=1}^{N-\tau} (x_i - \bar{x})^2}$$

其中, $\bar{x}$ 为时间序列的平均值。选择 C 值第一个拐点时的延迟时间为重构相空间的 τ 。计算得到延迟时间 τ 为5。

1.3 相空间重构

对时间序列 $x(i) (i=1,2,\cdots,N)$ 进行延时采样,延迟时间为 τ , τ 为 Δt 的整数倍,即 $\tau=k\Delta t, k \in \mathbb{Z}$,可以将原时间序列延拓成一个 m 维相空间的一个相型分布:

$$\begin{matrix} x(t_1) & x(t_1-\tau) & \cdots & x[t_1-(m-1)\tau] \\ x(t_2) & x(t_2-\tau) & \cdots & x[t_2-(m-1)\tau] \\ x(t_3) & x(t_3-\tau) & \cdots & x[t_3-(m-1)\tau] \\ \vdots & \vdots & \ddots & \vdots \end{matrix}$$

图1 为当嵌入维数 m 为30,延迟时间 τ 为5时重构相空间的吸引子。




图1 重构相空间的吸引子

Fig 1 A attractor of reconstructed phase space

1.4 最大李亚普诺夫指数和最大有效预测步数

采用C-C算法^[9]计算得到最大李亚普诺夫指数 L_E 为0.011,可知该时间序列是混沌的。根据混沌动力学理论^[10],混沌时间序列的最大有效预测步数为 $[1/L_E]+1$,其中 $[\cdot]$ 为取整函数,所以发动机压气机静子间压力时间序列的最大有效预测步数为10。

2 RBF网络预测模型

2.1 RBF网络

网络完成映射:

$$f: \{x(t), x(t-\tau), \cdots, x[t-(m-1)\tau]\} \rightarrow x(t+1)$$

数学表达式为:

$$f(x) = \theta_0 + \sum_{j=1}^h \theta_j \Phi(\|x - c_j\|)$$

式中: $x \in \{x(t), x(t-\tau), \cdots, x[t-(m-1)\tau]\}$ 为

网络的输入向量, $\Phi(\cdot)$ 为径向基函数, 取高斯函数 $\Phi(\|x - c_j\|) = \exp[-\|x - c_j\|^2/\sigma^2]$, c_j 为网络的隐层中心点, σ 为函数的宽度参数, $\|\cdot\|$ 取为欧几里德范数, $\theta_j (1 \leq j \leq h)$ 为网络的输出层连接权值, θ_0 为网络的偏置。

RBf 网络具有良好的逼近任意非线性映射的能力^[11], 若网络隐层径向基函数取高斯函数, 经过平移以及径向的拉伸压缩后, 其线性组合可以任意逼近 L^p 空间、Banach 空间以及 $C[x]$ 空间上的任意连续函数。

2.2 预测模型

重构相空间后, 对RBf 网络进行训练, 得到 t 时刻RBf 网络的一步预测模型为:

$$\hat{x}(t+1) = f\{x(t), x(t-\tau), \dots, x[t-(m-1)\tau]\} \quad (1)$$

第 l 步的RBf 网络预测模型为:

$$\hat{x}(t+l) = f\{x(t+l-1), \dots, x[t+l-1-(m-1)\tau]\} \quad (2)$$

其中: $\hat{x}(t+l-1)$ 为第 $l-1$ 步模型的预测值。

2.3 预测模型网络拓扑结构的确定

预测模型的拓扑结构对预测精度有很大的影响。由于基于最小嵌入维数的相空间重构完全保留了发动机系统状态空间的拓扑结构, 本文根据重构相空间的最小嵌入维数确定RBf 网络输入参数的个数, 采用 K 均值聚类方法优化网络的拓扑结构, 对隐层中心节点个数进行搜索, 达到最小泛化误差时停止搜索。训练完毕, 输入层节点个数取 30, 隐层中心节点个数取 100。

2.4 评价指标

为比较训练后网络的拟合能力, 计算如下的

评价指标:
$$E_{tr} = \sqrt{\sum_{i=1}^N \frac{(x_i - \hat{x}_i)^2}{N}}$$

式中: $\hat{x}_i$ 为 x_i 的估计值, N 为用于训练的样本个数。

为评价预测的效果, 计算如下的评价指标:

$$E_k = S_k/D_k$$

其中: $S_k = \sqrt{\sum_{i=N+1}^M \frac{(\hat{x}_{k,i} - x_{k,i})^2}{M-N}}$ 为 k 步预测的均方误差的平方根。式中: $\hat{x}_{k,i}$ 为 $x_{k,i}$ 的 k 步预测值, M 为样本总数。

$$D_k = \sqrt{\sum_{i=N+1}^M \frac{(\bar{x}_{k,i} - x_{k,i})^2}{M-N}}$$
 为预测阶段的标准差。式中: $\bar{x}_{k,i}$ 为预测阶段 $x_{k,i}$ 的均值。

3 应用分析

利用试验所得的时间序列重构相空间, 在相空间中寻找与 t 时刻相点最近的一组相点, 利用这些相点及下一时刻的数据, 作为训练数据对, 建立RBf 网络预测模型。本文用于训练的样本数为 700, 用于检验预测模型的样本个数为 300。RBf 网络输入层节点的数目取相空间的最小嵌入维数 30, 隐层节点个数取 100, 输出节点为 1 个。




图2 原始数据与拟合结果

Fig 2 Original data and training results

图 2 为原始数据与拟合结果对比图, E_{tr} 值为 1.8745×10^{-4} , 可以看出RBf 网络具有很好的逼近能力。为了验证RBf 网络的泛化能力和所建立的预测模型的正确性, 利用模型对时间序列进行单步和多步预测检验, 并将预测结果与试车结果进行了对比。

3.1 单步预测

根据所建立的单步预测模型(1)和 t 时刻以前的数据, 预测下一时刻的数据, 每次预测都以试验数据为基础, 每次预测都只预测下一个数据点。




图3 1步预测结果

Fig 3 Single-step forecasting results

单步预测结果如图 3 所示, E_1 值为 0.025 1, 可以看出, 预测结果与试车数据基本一致。

3.2 多步预测

根据多步预测模型(2), 对时间序列进行多步预测。图4 为5 步预测结果与试车数据的对比图。 E_5 值为0.223 7, 可以看出, 预测结果仍具有较高的精度。




图4 5步预测结果

Fig 4 Five-step forecasting results




图5 多步预测的 E_k 变化图

Fig 5 E_k in multi-step forecasting

图5 为多步预测的 E_k 值图。可以看出 E_k 值随着预测步数的增大不断增大, 到第10 步时 E_k 值为0.499 8, 从第11 步开始预测误差快速增大, 从第15 步开始 E_k 值均大于1, 预测模型开始失效。模型的实际有效预测步数同最大李亚普诺夫指数估算得到的最大预测步数(10 步) 基本相符。

4 结 论

本文根据混沌动力学理论, 建立了基于相空间重构和径向基神经网络的压气机机匣静压预测模型, 并对试验所得时间序列进行了单步和多步预测, 得出以下结论:

- (1) 利用RBF 网络的强大非线性映射能力, 将其用于压气机机匣静压时间序列的预测是可行的, 在一定的预测步数内有较高的精度。
- (2) 航空发动机试验得到的时间序列数据, 是系统中各个部件、各种影响因素, 通过复杂的相

互作用后产生的, 包含了有关发动机演化过程的信息。对其进行相空间重构, 可以挖掘到发动机系统的更多内在性质。在相空间重构的基础上对其建立非线性预测模型与常规的预测建模方法相比更能接近发动机的实际工作过程。

(3) 通过试车所得的时间序列构建RBF 网络预测模型研究发动机的工作特性, 是进行压气机状态监控的一条新思路, 具有一定的实用价值。

参考文献

[1] Ramazan Gencay, Liu Tung Nonlinear Modeling and Prediction with Feedward and Recurrent Networks[J]. *Physica D*, 1997, 108: 119~ 134

[2] Maguire L P, Roche B, McGinnity T M, et al Prediction Chaotic Time Series Using a Fuzzy Neural Network[J]. *Information Sciences*, 1998, 112: 125~ 136

[3] Cao Liangyue, Hong Yiguang, Fang Haiping, et al Predicting Chaotic Time Series with Wavelet Networks [J]. *Physica D*, 1995, 85: 225~ 238

[4] 李冬梅, 王正欧 基于RBF 网络的混沌时间序列的建模与多步预测[J]. *系统工程与电子技术*, 2002, 24(6): 81~ 83

L IDongmei, WANG Zhengou Modeling and Multi-Step Prediction of Chaotic Time Series Based on RBF Neural Networks[J]. *System Engineering and Electronics*, 2002, 24(6): 81~ 83

[5] 曾昭才, 段虞荣, 段荣光 基于径向基函数网络的混沌时间序列分析[J]. *重庆大学学报(自然科学版)*, 1999, 22(6): 113~ 120

ZENG Zhao-cai, DUAN Yu-rong, DUAN Rong-guang Chaotic Time Series Analysis Based on Radial Basis Function Networks[J]. *Journal of Chongqing University (Natural Science Edition)*, 1999, 22(6): 113~ 120

[6] 姜涛 航空发动机喘振/失速预估模型和故障检测研究[D]. 西安: 空军工程大学工程学院, 2002, 53- 75

[7] Robert J Schilling, James J Carroll, Ahmad F Al-Ajlouni Approximation of Nonlinear Systems with Radial Basis Function Neural Network [J]. *IEEE Transactions on Neural Network*, 2001, 12(1): 1~ 15

[8] Takens F. Detecting Strange Attractors in Fluent Turbulence[J]. *Lecture Notes in Mathematics*, 1981, 898: 366~ 381.

[9] 陶诏灵, 陈国华 基于C-C 方法的Lyapunov 指数的计算[J]. *南京气象学院学报*, 2002, 25(4): 555~ 559

TAO Zhao-ling, CHEN Guo-hua Computational Lyapunov Exponents Based on C-C Method[J]. *Journal of Nanjing Institute of Meteorology*, 2002, 25(4): 555~ 559

[10] 吕金虎, 陆君安, 陈士华 混沌时间序列分析及其应用[M]. 武汉: 武汉大学出版社, 2001.

[11] Schilling R J, Carroll J J, Al-Ajlouni A F. Approximation of Nonlinear Systems with Radial Basis Function Neural Networks[J]. *IEEE Transactions on Neural Networks*, 2001, 12(1): 1~ 15