

文章编号: 1000-8055(2013)04-0947-07

# 基于 ESN 的航空发动机状态组合预测方法

郭阳明, 付琳娟, 冉从宝, 马捷中

(西北工业大学 计算机学院, 西安 710072)

**摘 要:** 基于回声状态网络(ESN)预测模型, 结合小波分析和主元分析, 提出一种组合预测方法. 首先对含噪非线性时间序列进行小波降噪, 并重构时间序列产生训练样本, 再将训练样本通过主元分析进行降维处理, 降维后的时间序列数据则输入 ESN 模型进行预测分析. 对控制飞机动力输出的动压参数非线性时间序列数据进行了仿真对比实验, 结果表明: 组合预测方法的 5 步和单步预测速度累计提高了 66.97%, 预测的平均平方误差、标准均方根误差和归一化绝对误差也均有较大提高. 该方法与传统基于 ESN 的预测模型相比, 能有效地提高预测的效率和精度, 是一种有效的非线性时间序列预测方法.

**关 键 词:** 航空发动机; 状态预测; 回声状态网络; 小波分析; 主元分析 (PCA)

**中图分类号:** V233.7; TP183

**文献标志码:** A

## ESN-based combination method for aero-engine condition prediction

GUO Yang-ming, FU Lin-juan, RAN Cong-bao, MA Jie-zhong

(School of Computer Science,

Northwest Polytechnical University, Xi'an 710072, China)

**Abstract:** As a nonlinear time series prediction method, echo state network (ESN) attracts more attention because of its good approximation capability for the nonlinear system. Aiming at the characteristics of nonlinear time series in the aero-engine's condition prediction analysis, such as noise and presenting chaos, a combination method based on ESN was proposed. Firstly, the noise contained in nonlinear time series was reduced by the wavelet analysis. Then the training sample data were yielded via phase space reconstruction of the time series. After reducing the dimension of the training sample data by principal component analysis, all the remaining principal data were sent into the ESN prediction model. An actual dynamic pressure time series of aircraft power was conducted. The experiments compare the proposed method with traditional ESN prediction model on prediction accuracy and time cost. The results show that the prediction accuracy rate of proposed method within 5 steps and one-step are totally raised 66.97%, and the prediction of the mean square error, normalized root mean square error and normalized absolute error are also improved simultaneously. The proposed method is an effective nonlinear time series prediction method in practice.

**Key words:** aero-engine; health prediction; echo state network (ESN); wavelet analysis; principal components analysis (PCA)

**收稿日期:** 2012-04-20

**网络出版地址:** [http://www.cnki.net/kcms/detail/11.2297.V.20130417.1353.201304.947\\_032.html](http://www.cnki.net/kcms/detail/11.2297.V.20130417.1353.201304.947_032.html)

**基金项目:** 国家重点基础研究发展计划; 国家自然科学基金(61001023, 61101004); 航空科学基金(2010ZD53039); 陕西省自然科学基金(2010JQ8005)

**作者简介:** 郭阳明(1978—), 男, 河南南阳人, 副教授, 博士, 主要从事故障诊断与预测、可靠性设计与优化等方向的研究.

航空发动机系统是确保飞行器安全可靠运行,有效完成飞行使命的关键系统.因此,航空发动机监控及故障诊断技术的理论研究和工程实践一直以来都受到高度重视,特别是近年来基于状态监测的故障预测技术更为发动机健康状态分析和视情维修维护提供了新的途径<sup>[1]</sup>.但航空发动机系统复杂,往往难以建立精确的全系统数学模型,因此,利用表征发动机运行状态和影响发动机动力控制的非线性时间序列,对其运行和健康状态进行预测分析是当前较多采用的方法之一<sup>[2]</sup>.

时间序列预测是一种统计预测方法,它根据被预测对象过去和现在的观测数据随时间变化所反映出来的发展过程、方向和趋势,借助一定的规则对未来进行推测.该方法在故障预测与诊断、控制等方面有着广泛的应用<sup>[3]</sup>.但航空发动机工作环境复杂、恶劣,传统单一的故障诊断与预测方法并不能获得很好的效果.因此,本文提出结合诊断预测对象的特点,采用将多种合理方法组合,以获得较好预测结果的技术方案.即首先对采集的状态时间序列进行小波分析降噪和主元分析降维,之后送入基于回声状态网络(echo state networks, ESN)<sup>[4]</sup>的预测模型完成预测分析.

论文以某用于飞机发动机控制的实测动压非线性时间序列为对象,对提出的基于 ESN 的组合预测方法进行了仿真实验和分析.结果表明:本文方法具有较好的预测效果.

## 1 基于 ESN 的组合预测方法

研究表明 ESN 预测模型在对非线性时间序列进行预测时有着理想的预测效果,但是利用该模型进行预测所耗费的时间比较多,而且实测数据中的噪声污染也将降低 ESN 模型的预测精度<sup>[5]</sup>.因此,本文基于传统的 ESN 预测模型,结合被预测非线性时间序列的特点,融合小波分析降噪和主元分析(principal component analysis, PCA)降维,以提升预测性能.基于 ESN 的组合预测方法原理如图 1 所示.

### 1.1 回声状态网络的非线性时间序列预测原理

回声状态网络(ESN)是一种特殊类型的循环神经网络.ESN 采用上百至上千个隐层神经元形成一个巨大的储备池(dynamic reservoir, DR),取代传统循环神经网络的中间层. DR 计算模式的引入,克服了传统的神经网络基于梯度下降的学习算法带来的收敛慢、容易陷入局部极小、训练过

程复杂性等问题<sup>[5]</sup>. ESN 的网络结构如图 2 所示.




图 1 基于 ESN 的组合预测方法原理

Fig. 1 Principle of ESN-based combination method




图 2 ESN 网络的结构

Fig. 2 Structure of ESN

考虑图 2 所示的 ESN 网络结构,假设 ESN 系统分别有  $k, n$  和  $l$  个输入单元、隐层单元及输出单元.输入单元的序列、隐层的状态序列以及输出单元的序列在  $t$  时刻分别为

$$\begin{cases} u(t) = [u_1(t), u_2(t), \dots, u_k(t)] \\ x(t) = [x_1(t), x_2(t), \dots, x_n(t)] \\ y(t) = [y_1(t), y_2(t), \dots, y_l(t)] \end{cases} \quad (1)$$

则 ESN 的基本方程可表示为

$$\begin{cases} x(t+1) = \\ \text{tansig}[W_{n \times k}^{\text{in}} u(t+1) + W_{n \times n} x(t) + W_{n \times l}^{\text{back}} y(t)] \\ y(t+1) = \\ W_{l \times (k+n+l)}^{\text{out}} [u(t+1), x(t+1), y(t)] \end{cases} \quad (2)$$

其中  $W_{n \times k}^{\text{in}}$  为输入层的连接权值矩阵,  $W_{n \times l}^{\text{back}}$  为输出层到隐层的反馈权值矩阵,  $W_{l \times (k+n+l)}^{\text{out}}$  为输出层的连接权值矩阵,  $W_{n \times n}$  为 DR 内部的连接权值矩阵,该矩阵通常保持 1%~5%且谱半径一般小于 1 的稀疏连接,以保证 DR 具有动态记忆能力和一定的稳定性.

ESN 的训练过程可分为初始化  $W_{n \times k}^{\text{in}}, W_{n \times n}$ ,  $W_{n \times l}^{\text{back}}$  和利用样本数据求解隐层状态序列  $x(t)$  与输出权值矩阵  $W_{l \times (k+n+l)}^{\text{out}}, W_{n \times k}^{\text{in}}, W_{n \times n}$  和  $W_{n \times l}^{\text{back}}$  在

ESN 网络建立前随机生成,且一经产生就固定不变,而连接到输出的连接权矩阵  $W_{l \times (k+n+1)}^{\text{out}}$  则需要通过训练网络,以线性回归的方法计算得到<sup>[6]</sup>. 这样,训练后的 ESN 网络就可用于非线性时间序列的建模和预测.

### 1.2 基于小波分析的时间序列降噪方法

基于小波分析的降噪是通过将信号进行多分辨率分解,将时域信号表示为若干描述子频带的时域分量之和,从多个层次上对信号序列进行多尺度细化分析,从而将真实有用信号与噪声加以区分<sup>[7-8]</sup>. 利用小波分析进行降噪的原理如下:

设含有噪声的数据为  $f(t) = r(t) + e(t)$ , 其中  $r(t)$  为原信号,  $e(t)$  为噪声信号. 对  $f(t)$  用基小波  $\phi(t)$  作离散小波变换

$$\begin{aligned}\Psi(j, m) &= 2^{-\frac{j}{2}} \int f(t) \bar{\phi}_{j, m}(t) dt = \\ &2^{-\frac{j}{2}} \int [r(t) + e(t)] \bar{\phi}_{j, m}(t) dt = \\ &2^{-\frac{j}{2}} \int r(t) \bar{\phi}_{j, m}(t) dt + 2^{-\frac{j}{2}} \int e(t) \bar{\phi}_{j, m}(t) dt = \\ &R(j, m) + E(j, m)\end{aligned}\quad (3)$$

其中  $j$  表示小波的周期尺度,  $m$  是反映小波在时间上平移的时间因子,  $\bar{\phi}(t)$  是  $\phi(t)$  的复共轭函数,  $R(j, m)$  是复原信号经过小波变换后的系数,  $E(j, m)$  是噪声信号经过小波变换后的系数. 信号  $f(t)$  的奇异性与 Lipschitz 指数  $\alpha$  之间在二进小波变换下的关系为<sup>[9]</sup>

$$|\Psi(j, m)| \leq \omega 2^{ja} \quad (4)$$

其中  $\omega$  为常数.

由(4)式可以看出,对于有用信号,  $\alpha > 0$ , 其小波变换的模极大值随尺度的增大而增大;而噪声信号的  $\alpha \leq 0$ , 其小波变换的模极大值随尺度的增大而减小. 因此,在各个尺度上设定不同的阈值,通过判断模极大值点与阈值的大小关系,即小于该阈值的模极大值点认为是由噪声的小波变换引起的,将其置 0;大于该阈值的模极大值点则认为是由信号的小波变换引起的,予以保留. 然后,在此基础上进行小波逆变换重构信号,从而实现降噪的目的.

### 1.3 基于主元分析的降维方法

主元分析(PCA)是一种有效的维数压缩和特征提取方法. 该方法基于 Karhunen-Loève (K-L)分解,通过构造一组新的潜隐变量来降低原始数据空间的维数,再从新的映射空间抽取主要信息,构成对原始数据空间特性的理解. 由于投影空

间统计特征向量彼此正交,因此消除了变量间的关联性;而由原始数据变量线性组合构成映射空间的变量,则保证了在降低投影空间维数的同时,原始数据的主要信息得以保留<sup>[10-11]</sup>. PCA 的主要步骤如下:

- 1) 标准化处理输入样本矩阵  $X$ , 得到  $X^*$ ;
- 2) 建立相关矩阵  $S = X^{*T} X^*$ ;
- 3) 计算  $S$  的特征值  $\lambda$  与单位特征向量  $\beta$ , 并将  $\lambda_i$  按  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$  进行排序;
- 4) 计算  $h$  个特征值的方差贡献率,其中第  $\lambda_i$  的方差贡献率为

$$\eta_i = \left| \lambda_i / \sum_{i=1}^h \lambda_i \right| \times 100\% \quad (5)$$

- 5) 设定一阈值,计算前  $p$  个特征值累计方差贡献率  $\eta$ ,当  $\eta$  大于该阈值,则取前  $p$  个特征值作为新特征,以此来表征原始变量所含的大部分信息;

- 6) 提取前  $p$  个特征值对应的单位特征向量  $\hat{\beta} = [\beta_1, \beta_2, \dots, \beta_p]$ , 计算主元矩阵  $Z = X\hat{\beta}$ .

由此,实现了对目标数据的降维,且保留了原有数据的绝大部分信息.

## 2 基于 ESN 的组合预测方法在航空发动机健康分析中的应用

本文结合航空发动机非线性时间序列的特点,针对传统基于 ESN 预测模型在非线性时间序列预测中存在的不足,构建了小波分析降噪和主元分析降维相结合的 ESN 预测方法. 该方法利用小波分析的方法实现对时间序列的噪声平滑,以提高预测的精度;利用主元分析降维,以提高预测的速度.

### 2.1 实例描述

压力测量是实现发动机控制和发动机健康监测的重要手段<sup>[12]</sup>. 实际飞行中,动压是表征飞机飞行状况,控制动力输出的重要参数之一. 本文利用基于 ESN 的组合预测方法对某实测动压时间序列数据(如图 3 所示)进行预测,并与传统基于 ESN 的预测方法进行对比分析.




图3 实测动压数据

Fig. 3 Dynamic pressure data

研究表明动压数据是一个非线性混沌时间序列<sup>[13]</sup>,采用基于 ESN 的预测模型对其进行预测分析时,需要对获取的非线性时间序列进行相空间重构,形成样本数据,利用该样本数据训练逼近系统的动态特性非线性模型.本文选用 C-C 法<sup>[14]</sup>来确定相空间重构的参数.

## 2.2 预测的精度检验和步骤

本文引入平均平方误差( $E_{mse}$ )、标准均方根误差( $E_{nrmse}$ )和归一化绝对误差( $E_{nae}$ )3种误差评价函数从不同侧面反映预测的精度和效果.这3种误差评价函数的定义如下:

设有  $s$  个样本,  $y(t)$  为  $t$  时刻的期望输出(即观测值),  $\hat{y}(t)$  为  $t$  时刻的预测输出(即预测值),  $\bar{y}$  为期望输出的均值,  $\sigma_y = \left( \frac{1}{s} \sum_{t=1}^s (y(t) - \bar{y})^2 \right)^{\frac{1}{2}}$  为标准差.

### 1) 平均平方误差 $E_{mse}$

$$E_{mse} = \frac{1}{s} \sum_{t=1}^s [\hat{y}(t) - y(t)]^2 \quad (6)$$

### 2) 标准均方根误差 $E_{nrmse}$

$$E_{nrmse} = \frac{\left( \frac{1}{s} \sum_{t=1}^s (\hat{y}(t) - y(t))^2 \right)^{\frac{1}{2}}}{\sigma_y} \quad (7)$$

### 3) 归一化绝对误差 $E_{nae}$

$$E_{nae} = \frac{\sum_{t=1}^s |\hat{y}(t) - y(t)|}{\sum_{t=1}^s y(t)} \quad (8)$$

其中  $E_{mse}$  反映了预测误差平方的平均值,  $E_{nrmse}$  反映了预测值对观测值的平均偏离程度,而  $E_{nae}$  则将预测的平均绝对误差对观测值的均值归一化<sup>[15]</sup>.

本文组合预测模型的预测步骤如下:

1) 对原始时间序列样本数据进行小波分析降噪.

2) 重构相空间,生成样本数据.

3) 对样本数据进行主元分析降维.


4) 将降维后的样本送入模型,完成对 ESN 的训练.

5) 利用训练好的 ESN 预测模型完成预测分析.


## 2.3 基于传统 ESN 的预测方法

采用 C-C 法选择延迟时间为 74 和嵌入维数为 6,对获取的非线性动压时间序列进行相空间重构.重构的动压的延迟向量为  $X(t) = (x(t -$

$(6-6) \times 14, x(t - (6-5) \times 14, \dots, x(t - (6-1) \times 14))$ . 由此,可选择 ESN 网络的输入层节点数为 6,输出层神经元个数为 1. 设定隐层神经元个数为 300,内部隐层连接矩阵为 3%、谱半径为 0.5 的稀疏连接矩阵.利用构建的训练样本对 ESN 预测模型进行训练,并对动压参数进行单步预测和 5 步预测,其中前 50% 的数据(虚线左侧)被用于训练 ESN 网络,而剩余的 50% 数据为测试数据.预测效果及预测误差如图 4 和图 5 所示.




(a) ESN预测模型对动压的单步预测效果




(b) ESN预测模型对动压的单步预测误差

图 4 ESN 预测模型对动压的单步预测曲线

Fig. 4 One step prediction curve of dynamic pressure with the ESN model



(a) ESN预测模型对动压的5步预测效果



(b) ESN预测模型对动压的5步预测误差

图 5 ESN 预测模型对动压的 5 步预测曲线

Fig. 5 One step prediction curve of dynamic pressure with the ESN model

## 2.4 基于 ESN 的组合预测方法

采用本文方法进行预测,需首先对测得的动压数据利用小波分析方法进行降噪,降噪后的时间序列数据如图 6 所示。




图 6 降噪后的动压数据

Fig. 6 Dynamic pressure data after noise reduction

同样利用 C-C 法对降噪后的动压数据进行相空间重构,计算得到的延迟时间为 14,嵌入维数为 6,重构出的动压的延迟向量仍然为  $X(t) = (x(t), x(t-14), \dots, x(t-(6-1) \times 14))$ 。

利用主元分析对重构的延迟向量进行降维,本次实验取累计方差贡献率  $\eta \geq 0.95$  的前几个主元,其特征值及它们的方差贡献率如表 1 所示。


表 1 动压相空间的主元及方差贡献率

Table 1 Principal components and variance contribution of dynamic pressure phase space


| 序号 | 特征值       | 方差贡献率      |
|----|-----------|------------|
| 1  | 5.4388    | 0.90646    |
| 2  | 0.46416   | 0.077359   |
| 3  | 0.075893  | 0.012649   |
| 4  | 0.011723  | 0.0019538  |
| 5  | 0.0054133 | 0.00090222 |
| 6  | 0.0040479 | 0.00067465 |

从表 1 可以看出,前两个特征值的方差贡献率和为 0.9838 已经大于 0.95,所以只选择前两个主元重新构建延迟向量。

经过主元分析后,相空间的维数由原来的 6 降到了 2,因此在构建 ESN 网络时,其输入层节点数选择为 2,而隐层和输出层的节点数目及其他参数选择同 2.3 节中的 ESN 网络。同样用前 50% 的数据建立模型,对剩余 50% 的数据利用已有的模型进行预测。利用该模型对降噪后的动压非线性时间序列数据进行单步预测和 5 步预测的效果如图 7、图 8 所示,其中,虚线左侧的数据为训练样本数据,右侧的数据为测试样本数据。




(a) 本文方法对动压的单步预测效果




(b) 本文方法对动压的单步预测误差

图 7 本文方法对动压的单步预测曲线

Fig. 7 One step prediction curve of dynamic pressure with the proposed method



(a) 本文方法对动压的5步预测效果



(b) 本文方法对动压的5步预测误差

图 8 本文方法对动压的 5 步预测曲线

Fig. 8 Five steps prediction curve of dynamic pressure with the proposed method

## 2.5 结果分析

为了便于对比分析,将采用传统基于 ESN 的预测方法和本文组合预测方法获得的预测结果列于表 2 中。

由图 4、图 5、图 7、图 8 和表 2 可以看出,在预测时间上,对相同数据量的动压非线性时间序列,采用基于 ESN 的组合预测方法进行预测时,5 步预测时间从 5.031 s 减少到 3.594 s,而单步预测时间从 5.844 s 减少到 3.500 s,累计预测的速度提高了 66.97%。在预测精度上,基于 ESN 的组合预测方法对动压非线性时间序列预测的平均平

表 2 ESN 预测模型及本文方法进行动压时间序列预测的预测误差和预测时间

Table 2 Prediction error and time cost of dynamic pressure with proposed method and ESN model

| 预测步长 | 预测方法 | 预测时间/s | 预测误差        |             |           |
|------|------|--------|-------------|-------------|-----------|
|      |      |        | $E_{mse}$   | $E_{nrmse}$ | $E_{nae}$ |
| 单步   | ESN  | 5.844  | 0.000079609 | 0.224500    | 0.004162  |
|      | 本文方法 | 3.500  | 0.000064349 | 0.204810    | 0.003473  |
| 5 步  | ESN  | 5.031  | 0.000175    | 0.333570    | 0.005967  |
|      | 本文方法 | 3.594  | 0.000139    | 0.301890    | 0.005319  |

方误差、标准均方根误差和归一化绝对误差等误差精度也均有较大提高。

由此可见,融合小波降噪和主元分析的 ESN 预测模型不仅可以获得较高的预测精度,并且能有效地减少了训练 ESN 网络的时间,提高预测的速度,具有更好的推广应用价值。

### 3 结 论

本文针对航空发动机状态及健康预测分析应用中实测非线性时间序列的特点,综合考虑预测的误差和实时性,提出了基于 ESN 的组合预测方法。该方法以 ESN 预测模型为基础,利用小波分析和主元分析分别对预测时间序列进行降噪和降维处理,以达到提高预测精度和速度的目的。

分别采用传统的 ESN 预测模型和本文方法对实际采集的动压非线性时间序列数据进行了预测分析,给出了预测分析的具体步骤和实现过程,并对比了两种预测方法的预测精度和预测速度。仿真实验表明:本文方法的预测效果良好,更好地逼近了非线性时间序列,并在提高了预测的精度度的同时,在一定程度上减少了训练时间和预测时间,是一种更有实际应用价值的方法。

### 参考文献:

- [1] 郭阳明,蔡小斌,张宝珍,等.故障预测与健康状态管理技术综述[J].计算机测量与控制,2008,16(9):1213-1216,1219.  
GUO Yangming,CAI Xiaobin,ZHANG Baozhen,et al. Review of prognostics and health management technology [J]. Computer Measurement & Control, 2008, 16(9): 1213-1216,1219. (in Chinese)
- [2] 姜彩虹,孙志岩,王曦.航空发动机预测健康管理系统的的核心技术[J].航空动力学报,2009,24(11):2589-2594.  
JIANG Caihong,SUN Zhiyan,WANG Xi. Critical technologies for aero-engine prognostics and health management systems development [J]. Journal of Aerospace Power, 2009,24(11):2589-2594. (in Chinese)
- [3] Sorjamaa A,Hao J,Reyhani N,Ji Y,et al. Methodology for long-term prediction of time series[J]. Neurocomputing, 2007(70):2861-2869.
- [4] Jaeger H. The echo state approach to analyzing and training recurrent neural networks[R]. German: German National Research Center for Information Technology,2001.
- [5] 付林娟,翟正军,郭阳明.基于回声状态网络的多变量预测模型的研究[J].计算机测量与控制,2009,17(7):1356-1358,1361.  
FU Linjuan,ZHAI Zhengjun, GUO Yangming. Research on multivariate prediction model based on echo state networks [J]. Computer Measurement & Control, 2009, 17(7):1356-1358,1361. (in Chinese)
- [6] 雷正伟,徐章遂,米东,等.神经网络的预测性能的优化分析[J].计算机测量与控制,2004,12(1):15-16,20.  
LEI Zhengwei,XU Zhangsui,MI Dong,et al. Optimization analysis of neural network forecast performance [J]. Computer Measurement & Control, 2004,12(1):15-16,20. (in Chinese)
- [7] 陈果.一种转子故障信号的小波自适应降噪新方法[J].振动工程学报,2007,20(3):285-290.  
CHEN Guo. A new de-noising method for rotor faults signal [J]. Journal of Vibration Engineering, 2007, 20(3): 285-290. (in Chinese)
- [8] 游荣义,陈忠,徐慎初,等.基于小波变换的混沌信号相空间重构研究[J].物理学报,2004,53(9):2882-2888.  
YOU Rongyi,CHEN Zhong,XU Shenchu,et al. Study on phase-space reconstruction of chaotic signal based on wavelet transform [J]. Chinese Journal of Physics, 2004,53(9):2882-2888. (in Chinese)
- [9] Mallat S, Huang W. Singularity detection and processing with wavelets [J]. IEEE Trans on Information Theory, 1992,38(2):617-643.
- [10] 席剑辉,韩敏.主成分分析与神经网络的结合在多变量序列预测中的应用[J].控制理论与应用,2007,24(5):719-724.  
XI Jianhui,HAN Min. Prediction of multivariate time series based on principal component analysis and neural networks [J]. Control Theory & Application, 2007, 24(5): 719-724. (in Chinese)
- [11] 范明明.基于主成分分析的多变量混沌时间序列预测研究[D].辽宁大连:大连理工大学,2006.

- FAN Mingming. Study on predicting multivariate chaotic time series by principle component analysis[D]. Dalian Liaoning: Dalian University of Technology, 2006. (in Chinese)
- [12] 赵文涛, 李琼. 关于航空发动机健康监测与诊断技术的研究[J]. 飞机设计, 2010, 30(6): 30-34.
- ZHAO Wentao, LI Qiong. Research on aero-engine health monitoring and diagnosis methods[J]. Aircraft Design, 2010, 30(6): 30-34. (in Chinese)
- [13] 宋云雪, 彭朋, 史永胜. 民用发动机状态混沌预测算法[J]. 航空动力学报, 2011, 26(3): 675-679.
- SONG Yunxue, PENG Peng, SHI Yongsheng. Chaos arithmetic for civil aero-engine forecasting[J]. Journal of Aerospace Power, 2011, 26(3): 675-679. (in Chinese)
- [14] 秦奕青, 蔡卫东, 杨炳儒. 非线性时间序列的相空间重构技术研究[J]. 系统仿真学报, 2008, 20(11): 2969-2973.
- QIN Yiqing, CAI Weidong, YANG Bingru. Research on phase space reconstruction of nonlinear time series[J]. Journal of System Simulation, 2008, 20(11): 2969-2973. (in Chinese)
- [15] 付林娟. 复杂非线性系统的时间序列预测方法研究[D]. 西安: 西北工业大学, 2009.
- FU Linjuan. Research on prediction of time series in complex nonlinear system[D]. Xi'an: Northwestern Polytechnical University, 2009. (in Chinese)