

# 基于神经网络的非线性时间序列故障预报

胡寿松<sup>1</sup> 张正道<sup>2</sup>

**摘要** 对模型未知非线性系统, 将系统输出组成时间序列并通过空间嵌入的方法转化为一个离散动态系统. 利用线性 AR 模型拟合时间序列的线性部分, 用神经网络拟合时间序列的非线性部分并补偿外界未知的扰动, 提出了通过对状态的观测实现时间序列一步预测的方法. 利用滚动优化的思想将一步预测推广, 提出了时间序列的  $N$  步预测方法, 证明了时间序列预测误差有界. 通过对预测误差进行概率密度估计和检验, 提出了故障的预报方法. 对 F-16 歼击机的结构故障预报结果表明了方法的有效性.

**关键词** 非线性时间序列, 神经网络, 滚动预测, 概率密度估计, 故障预报  
**中图分类号** TP18

## Fault Prediction for Nonlinear Time Series Based on Neural Network

HU Shou-Song<sup>1</sup> ZHANG Zheng-Dao<sup>2</sup>

**Abstract** According to the Takens embedding theorem, the nonlinear time series combined with system output is converted into discrete dynamic system. An autoregressive model is used to fit the linear part of series; the neural network is used to fit the nonlinear part of series and to compensate for the unknown disturbance. The prediction of time series is achieved by the observation of system states. So a one-step prediction method is proposed. Using the so-called moving horizon optimization method, one-step prediction is extended to  $N$ -steps prediction. The boundedness of prediction error is proved. The fault is predicted by the prediction error through density function estimation and hypothesis test. The simulation of the structure fault prediction of a fighter F-16 proved the efficiency of the model.

**Key words** Nonlinear time series, neural network, moving horizon prediction, density estimation, fault prediction

### 1 引言

故障检测和诊断是 20 世纪后期才发展起来的一个新兴的研究方向, 也是当前控制理论研究的热点之一. 但是随着对系统可靠性和安全性要求的进一步提高, 人们还希望能够在故障对系统的危害显现之前就预先知道故障的有关信息, 由此提出了故障预报这一个新的研究方向. 目前故障预报研究进展较为缓慢, 基于时间序列预测的方法是现有的主要预报方法.

时间序列预测方法将数据看作一个按时间次序排列的数据序列, 通过相邻数据之间的相关性, 建立拟合时间序列的数学模型. 目前, 对线性时间序列分析方法及其应用的研究已经比较成熟. Ho 将由故障

发生的时间间隔构成的数据建立 ARIMA 模型, 并实现了对系统故障的一步预报<sup>[1]</sup>. 相对而言, 非线性时间序列的分析要困难得多, 目前仅对一些特殊的序列, 如双线性时间序列, 有较完善的理论分析. Zhang 对非线性时间序列通过设计鲁棒跟踪控制律实现了系统故障的一步预报<sup>[2]</sup>. 实际工作中, 大量的时间序列都是非线性的甚至是混沌的, 此时用经典的时间序列分析方法来处理则会带来较大的分析误差, 而非线性时间序列方法分析的难度又很大, 因此神经网络在这方面得到了广泛的应用.

目前, 包括 BP 网络, RBF 网络, 回归神经网络等多种神经网络结构都在时间序列分析中得到了应用<sup>[3~5]</sup>. Tse 利用回归神经网络对化工厂的冷却塔的鼓风机进行故障预报<sup>[6]</sup>. Xu 利用基于神经网络时间序列预测模型, 预测引擎系统的可靠性和故障<sup>[7]</sup>. BuHamra 利用 ARIMA 模型分析时间序列确定神经网络的输入层结构<sup>[8]</sup>. Leung 给出了用于时间序列建模的最优 RBF 网络结构<sup>[9]</sup>. 但是, 神经网络在应用中还存在以下问题: 1) 神经网络的结构不易确定, 且神经网络建模通常需要训练, 训练数据的分布对建模的性能有直接的影响; 2) 是神经网络建模后对训练集以外数据的外推能力没有较好的分析方法; 3) 是神经网络建模仅对训练时的模型有较好的拟合能力, 任何微小的测量偏差, 不确定扰动等都会导致拟合能力的急剧下降甚至使神经网络完全丧失

收稿日期 2005-12-26 收修改稿日期 2006-4-27  
Received December 26, 2005; in revised form April 27, 2006  
国家自然科学基金重点项目 (60234010), 国防基础科研项目 (K1603060318), 航空科学基金 (05E52031) 资助  
Supported by National Natural Science Foundation of P. R. China (60234010), National Defense Basic Research Program of China (K1603060318), and the Aeronautical Science Foundation (05E52031)

1. 南京航空航天大学自动化学院 南京 210016 2. 江南大学通信与控制工程学院 无锡 214122  
1. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016 2. College of Communication and Control Engineering, Jiangnan University, Wuxi 214122  
DOI: 10.1360/aas-007-0744

对该序列的拟合能力.

本文将非线性时间序列的一步预测问题转化为离散非线性动态系统的观测问题并设计了神经网络自适应观测器. 利用神经网络在线权值调整, 使一步预测的误差一致有界. 利用滚动优化思想, 在一步预测的基础上构造  $N$  步滚动预测结构. 利用得到的  $N$  步预测误差时间序列, 判断故障的有无, 从而实现故障预报.

## 2 问题的描述

首先考虑非线性时间序列的一步预测问题. 为简化讨论, 不妨假设观测数据为一维.

设有非线性时间序列  $\{x(t) | x(t) \in \mathbf{R}^1\}$ ,  $t = 0, 1, \dots, L$ . 其  $T$  时刻的一步预测问题可以描述为<sup>[5]</sup>

$$x(T+1) = f(x(T), x(T-1), \dots, x(T-p)) \quad (1)$$

其中,  $L \in \mathbf{Z}^+$ , 表示整个时间序列的长度,  $p \in \mathbf{Z}^+$ , 表示嵌入空间的维数.

构造如下向量:  $\mathbf{X}(T) = [x(T-p), \dots, x(T-1), x(T)]^T$ ,  $Y(T) = [0, 0, \dots, 0, 1]\mathbf{X}(T)$ , 则

$$\left\{ \begin{array}{l} \mathbf{X}(T+1) = \begin{bmatrix} x(T-p+1) \\ x(T-p+2) \\ \vdots \\ x(T) \\ x(T+1) \end{bmatrix} = \\ \begin{bmatrix} x(T-p+1) \\ x(T-p+2) \\ \vdots \\ x(T) \\ f(x(T), \dots, x(T-p)) \end{bmatrix} = \mathbf{F}(\mathbf{X}(T)) \\ Y(T) = [0 \ 0 \ \dots \ 0 \ 1]\mathbf{X}(T) \end{array} \right. \quad (2)$$

其中,  $\mathbf{F}(\mathbf{X}(T))$  为  $p+1$  维函数向量. 由此一个嵌入维数为  $p$  的一维时间序列预测问题就转化成如式 (2) 所示的  $p+1$  维未知非线性离散动态系统的状态观测问题.

## 3 基于神经网络的时间序列预测

### 3.1 时间序列的一步预测

按照时间序列方法的建模与预测方法, 对于序列 (1), 一定可以找到一个线性自回归 (LAR) 模型

来拟合. 这样一个非线性时间序列就可以看作一个 LAR 模型描述的线性序列和一个未知的非线性序列的和, 即

$$x(T+1) = \sum_{i=0}^p \eta_i x(T-i) + f'(x(T), x(T-1), \dots, x(T-p)) \quad (3)$$

其中:  $\eta_i \in \mathbf{R}$ ,  $i = 0, 1, \dots, p$ , 且令自回归系数  $\eta_p \neq 0$ . 将式 (3) 代入式 (2), 得

$$\begin{bmatrix} x(T-p+1) \\ x(T-p+2) \\ \vdots \\ x(T) \\ x(T+1) \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ 0 & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & \dots & 1 \\ \eta_p & \eta_{p-1} & \eta_{p-2} & \dots & \eta_0 \end{bmatrix} \begin{bmatrix} x(T-p) \\ x(T-p+1) \\ x(T-p+2) \\ \vdots \\ x(T) \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ f'(x(T), x(T-1), \dots, x(T-p)) \end{bmatrix}$$

令  $C = [0 \ 0 \ \dots \ 0 \ 1]$ , 有

$$\begin{cases} \mathbf{X}(T+1) = A\mathbf{X}(T) + \mathbf{F}'(\mathbf{X}(T)) \\ Y(T) = C\mathbf{X}(T) \end{cases} \quad (4)$$

**引理 1**<sup>[10]</sup>. 对于任意定义在紧集  $\Omega$  上的非线性函数  $f(x)$  及  $\varepsilon > 0$ , 一定存在一个 RBF 神经网络  $f_{NN}(x) = W^*\varphi(x)$ , 满足:  $\sup_{x \in \Omega} |f(x) - f_{NN}(x)| \leq \varepsilon$ , 且  $0 < \|\varphi(\hat{x})\| \leq \bar{\varphi}$ ,  $\|W^*\| \leq \bar{W}$ .

由引理 1, 非线性函数  $\mathbf{F}'(\mathbf{X}(T))$  可以用神经网络表示, 则系统 (4) 可以写成

$$\begin{cases} \mathbf{X}(T+1) = A\mathbf{X}(T) + W^*\varphi(\mathbf{X}(T)) + \varepsilon \\ Y(T) = C\mathbf{X}(T) \end{cases} \quad (5)$$

对于系统 (5) 设计如下全阶观测器

$$\begin{cases} \hat{\mathbf{X}}(T+1) = \mathbf{A}\hat{\mathbf{X}}(T) + \hat{\mathbf{W}}\boldsymbol{\varphi}(\hat{\mathbf{X}}(T)) + \\ \quad \mathbf{K}(Y(T) - \hat{Y}(T)) \\ \hat{Y}(T) = \mathbf{C}\hat{\mathbf{X}}(T) \end{cases} \quad (6)$$

令  $\tilde{\mathbf{X}}(T) = \mathbf{X}(T) - \hat{\mathbf{X}}(T)$ ,  $\tilde{Y}(T) = Y(T) - \hat{Y}(T)$ ,  $\tilde{\mathbf{W}}(T) = \mathbf{W}^*(T) - \hat{\mathbf{W}}(T)$   
则误差方程为

$$\begin{cases} \tilde{\mathbf{X}}(T+1) = (\mathbf{A} - \mathbf{K}\mathbf{C})\tilde{\mathbf{X}}(T) + \tilde{\mathbf{W}}\boldsymbol{\varphi}(\mathbf{X}(T)) + \\ \quad \tilde{\mathbf{W}}\boldsymbol{\varphi}(x(T)) + \varepsilon \\ \tilde{Y}(T) = \mathbf{C}\tilde{\mathbf{X}}(T) \end{cases} \quad (7)$$

**定理 1.** 对系统 (5), 设计的神经网络观测器为 (6), RBF 神经网络的权值矩阵按如下自适应律修正

$$\hat{\mathbf{W}}(T+1) = \hat{\mathbf{W}}(T) + P(\mathbf{A} - \mathbf{K}\mathbf{C})\tilde{\mathbf{x}}(T)\hat{\boldsymbol{\varphi}}^T - \lambda \|P\| \hat{\mathbf{W}}(T) \quad (8)$$

其中:  $P = P^T > 0$ , 且满足

$$(\mathbf{A} - \mathbf{K}\mathbf{C})^T P (\mathbf{A} - \mathbf{K}\mathbf{C}) - P = -Q \quad (9)$$

$$S = Q - (\mathbf{A} - \mathbf{K}\mathbf{C})^T P P (\mathbf{A} - \mathbf{K}\mathbf{C}) \|\boldsymbol{\varphi}\|_2^2 > 0 \quad (10)$$

$$\lambda > \frac{\bar{\varepsilon} + \bar{\mathbf{W}}\bar{\boldsymbol{\varphi}}}{2 \|P\| \|\hat{\mathbf{W}}(T)\boldsymbol{\varphi}(\hat{x}(T))\|} \quad (11)$$

其中:  $Q = Q^T > 0$ ,  $\alpha > 0$ , 则闭环误差系统 (7) 是一致最终有界 (UUB) 的.

**证明.** 由式 (4) 可知, 系统  $(\mathbf{A}, \mathbf{C})$  可观, 所以方程 (9) 必有正定解  $P$ .

对方程 (7) 选取如下的 Lyapunov 函数:

$$V(T) = \tilde{\mathbf{X}}(T)^T P \tilde{\mathbf{X}}(T) + \text{tr}(\tilde{\mathbf{W}}^T(T) P \tilde{\mathbf{W}}(T))$$

则  $\Delta V(T) = V(T+1) - V(T) = \tilde{\mathbf{X}}(T+1)^T P \tilde{\mathbf{X}}(T+1) + \text{tr}(\tilde{\mathbf{W}}^T(T+1) P \tilde{\mathbf{W}}(T+1)) - \tilde{\mathbf{X}}(T)^T P \tilde{\mathbf{X}}(T) - \text{tr}(\tilde{\mathbf{W}}^T(T) P \tilde{\mathbf{W}}(T))$

令  $A_m = (\mathbf{A} - \mathbf{K}\mathbf{C})$ ,  $\hat{\mathbf{W}}(T+1) = \hat{\mathbf{W}}(T) + \Delta \mathbf{W}(T)$ ,  $a_1 = (2\lambda \|P\| - \bar{\varphi}^2 \|P\|) \|\tilde{\mathbf{W}}\|^2$ ,  $a_2 = (2\bar{\varepsilon}\bar{\boldsymbol{\varphi}} \|P\| + 2\bar{\varphi}^2 \|P\| \|\hat{\mathbf{W}}\| + 2\lambda \bar{\mathbf{W}} \|P\|)$ ,  $c_1 = \bar{\varepsilon}^2 \|P\| + \bar{\varphi}^2 \|P\| \|\hat{\mathbf{W}}\|^2 + 2\bar{\varepsilon}\bar{\boldsymbol{\varphi}} \|P\| \|\hat{\mathbf{W}}\| + \lambda^2 \|P\| \|\hat{\mathbf{W}}\|^2$ , 代入式 (8)~(11), 得

$$\Delta V(T) \leq -\tilde{\mathbf{x}}^T S \tilde{\mathbf{x}} - a_1 \|\tilde{\mathbf{W}}\|^2 + a_2 \|\tilde{\mathbf{W}}\| + c_1 = -\tilde{\mathbf{x}}^T S \tilde{\mathbf{x}} - a_1 \left( \|\tilde{\mathbf{W}}\| - \frac{a_2}{2a_1} \right)^2 + c_1 + \frac{a_2^2}{4a_1}, \text{ 所以当}$$

$$\|\tilde{\mathbf{X}}(T)\| > \sqrt{(c_1 + \frac{a_2^2}{4a_1}) / \lambda_{\min}(S)} \text{ 或 } \|\tilde{\mathbf{W}}(T)\| \geq$$

$$\sqrt{(c_1 + \frac{a_2^2}{4a_1}) / a_1 + \frac{a_2}{2a_1}} \text{ 时, 有 } \Delta V(T) < 0. \text{ 所以}$$

方程 (7) 是一致最终有界 (UUB) 的.  $\square$

**推论 1.** 对于非线性时间序列  $\{x(t) | x(t) \in \mathbf{R}^1\}$ , 采用 (6) 进行一步预测, 神经网络的权值调整规律如 (8), 则序列的一步预测误差一致有界.

**证明.** 由式 (7):  $\tilde{Y}(T+1) = \mathbf{C}\tilde{\mathbf{X}}(T+1)$ ,

$$\text{则: } \|\tilde{Y}(T+1)\| \leq \|\mathbf{C}\| \|\tilde{\mathbf{X}}(T+1)\|$$

由 (2) 和 (4) 可得

$$|x(T+1) - \hat{x}(T+1)| \leq \|\tilde{\mathbf{X}}(T+1)\|$$

又因为方程 (7) 是一致最终有界的, 所以一步预测误差  $|x(T+1) - \hat{x}(T+1)|$  一致有界.  $\square$

### 3.2 时间序列的 $N$ 步预测

利用递推预测和滚动优化的思想, 将时间序列的一步预测推广到  $N$  步预测, 当  $N$  小于嵌入维数  $p$  时, 非线性时间序列  $\{x(t) | x(t) \in \mathbf{R}^1\} (t = 0, 1, \dots, L)$ , 在  $T$  时刻的  $N$  步预测问题可以转化为如下一组一步预测问题

$$\begin{cases} \hat{x}(T+2) = f(\hat{x}(T+1), x(T), \dots, x(T-p+1)) \\ \dots \\ \hat{x}(T+N) = f(\hat{x}(T+N-1), \hat{x}(T+N-2), \dots, \\ \quad x(T), \dots, x(T+N-p-1)) \end{cases} \quad (12)$$

由 (4) 得

$$\begin{cases} \mathbf{X}(T+N) = \mathbf{A}\mathbf{X}(T+N-1) + \\ \quad \mathbf{F}'(\mathbf{X}(T+N-1)) \\ Y(T+N) = \mathbf{C}\mathbf{X}(T+N) \end{cases}$$

将非线性函数  $\mathbf{F}'(\mathbf{X}(T+N-1))$  用神经网络表示, 则上式可以写成

$$\begin{cases} \mathbf{X}(T+N) = \mathbf{A}\mathbf{X}(T+N-1) + \\ \quad \mathbf{W}^*\boldsymbol{\varphi}(\mathbf{X}(T+N-1)) + \varepsilon \\ Y(T+N) = \mathbf{C}\mathbf{X}(T+N) \end{cases} \quad (13)$$

构造如下向量:  $\hat{\mathbf{X}}(T+N) = [x(T+N-p), \dots, x(T), \dots, \hat{x}(T+N-1), \hat{x}(T+N)]^T$ , 对于系统 (13) 设计如下全阶观测器

$$\begin{cases} \hat{\mathbf{X}}(T+N) = \mathbf{A}\hat{\mathbf{X}}(T+N-1) + \hat{\mathbf{W}}^* \boldsymbol{\varphi} \times \\ (\hat{\mathbf{X}}(T+N-1)) + \mathbf{K}(Y(T) - \hat{Y}(T+N-1)) \\ \hat{Y}(T+N) = \mathbf{C}\hat{\mathbf{X}}(T+N) \end{cases} \quad (14)$$

$$\begin{aligned} \tilde{\mathbf{X}}(T+N) &= \mathbf{X}(T+N) - \hat{\mathbf{X}}(T+N), \\ \tilde{Y}(T+N) &= Y(T+N) - \hat{Y}(T+N), \\ \tilde{\mathbf{W}}(T+N) &= \mathbf{W}^*(T+N) - \hat{\mathbf{W}}(T+N) \end{aligned}$$

则误差方程为

$$\begin{cases} \tilde{\mathbf{X}}(T+N) = (\mathbf{A} - \mathbf{K}\mathbf{C})\tilde{\mathbf{X}}(T+N-1) + \\ \tilde{\mathbf{W}}\boldsymbol{\varphi}(\tilde{\mathbf{X}}(T+N-1)) + \boldsymbol{\varepsilon} \\ \tilde{Y}(T+N) = \mathbf{C}\tilde{\mathbf{X}}(T+N) \end{cases} \quad (15)$$

其结果可以描述为以下的定理.

**定理 2.** 对于满足  $\|x(t)\| < \zeta (\zeta > 0)$  的非线性时间序列  $\{x(t) | x(t) \in \mathbf{R}^1\}$ ,  $(t = 0, 1, \dots, L)$  在  $T$  时刻的  $N$  步预测问题. 若  $N$  小于等于嵌入维数  $p$ , 则  $N$  步预测估计误差  $|x(T+N) - \hat{x}(T+N)|$  有界.

需要说明的是: 定理中要求的  $\|x(t)\|$  有界条件, 对任何实际系统来说都是满足的.

#### 4 基于非参数密度估计时间序列的故障预报

由于现代化控制系统的复杂性, 精确的系统模型难以建立. 因此, 无模型的智能故障预报方法近年来日益受到关注. 但是这类方法最大的困难就是需要故障训练样本或者故障先验知识. 对于许多复杂系统, 故障试验的代价高、危险性大, 所需的训练数据或先验知识难以全部获得, 甚至只能得到系统正常运行的数据而无法得到故障数据, 这严重地影响了故障预报的准确性. 为此, 本文设计了一种利用系统正常运行数据进行故障预报的方法.

基于以上提出的时间序列  $N$  步预测方法, 可以得到  $N$  步预测的输出误差  $\tilde{x}_N(k)$ ,  $(k = 1, 2, \dots)$ . 该误差信号中包含了故障发生的信息, 故此可以利用它进行故障预报.

非参数密度估计故障预报算法由假设检验, 决策判断和概率密度估计三个部分组成, 如图 1 所示.

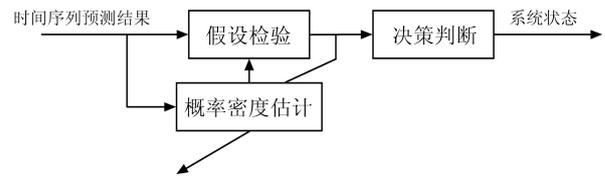


图 1 非参数密度估计故障预报器的组成结构  
Fig. 1 The structure of fault predictor based on nonparametric density estimation

令分类  $\omega_1, \omega_2$  分别对应于正常和故障状态. 类先验概率为  $P(\omega_1)$  和  $P(\omega_2)$ , 概率密度函数表示为  $p(x|\omega_1)$  和  $p(x|\omega_2)$ . 根据 Bayes 决策:  $x \in \omega_1$  当且仅当  $p(x|\omega_1) > p(x|\omega_2) [P(\omega_2)/P(\omega_1)]$ . 由于类  $\omega_2$  没有任何的先验知识, 因此,  $P(\omega_1), P(\omega_2)$  及  $p(x|\omega_2)$  均未知, 仅  $p(x|\omega_1)$  可根据非参数密度估计方法进行估计. 因此采用如下的统计检验方法<sup>[11]</sup>: 对  $N+1$  时刻的样本  $X_{N+1}$ , 取直到  $N$  时刻的所有正常类的样本组成测试集  $M = \{X_i | X_i \in \omega_1, i \in \{1, \dots, N\}\}$ ; 随机选择  $y \in M$ , 令  $L(y) = \log p(y|\omega_1)$ , 同样地令  $L(X_{N+1}) = \log p(X_{N+1}|\omega_1)$ , 根据概率的经验解释, 得到如下的假设检验

$$P(L(y) \leq L(X_{N+1})) > \varphi \text{ 则} \\ X_{N+1} \in \omega_2 \quad (16)$$

式中  $0 < \varphi < 1$ , 为一个人为规定的限. 它既表示假设检验的置信度, 同时也影响系统故障预报的性能.  $\varphi$  增大则系统的故障误检率降低但故障漏检率升高; 反之,  $\varphi$  减小则系统的故障误检率升高但故障漏检率降低. 通过调节  $\varphi$  可以调整预报器的预报性能.

#### 5 仿真示例

采用美制 F-16 歼击机作为仿真对象研究对突变故障的预报. 由于歼击机操纵系统和传感器均具有多个硬件冗余, 因此只考虑其结构故障. 假设歼击机初始在高度 500 m 低空作 0.45 Ma 的低速直线飞行, 飞机采样周期为 12.5 ms. 定义控制变量为  $\mathbf{U} = [\delta_e, \delta_a, \delta_r]^T$ , 其中  $\delta_e, \delta_a, \delta_r$  分别表示升降舵、副翼、方向舵偏转角单位为 deg/s. 设定故障类型为左升降舵卡死在  $-5^\circ$ , 故障发生的时间为第 1.5 秒. 以俯仰角速度分量 (单位为 rad/s) 为例进行仿真与分析, 取嵌入延时维数  $p = 5$ , 俯仰角速度的一步预测和两步预测结果如图 2(b) 和 2(c) 所示. 从仿真结果可以看到, 对 F-16 歼击机, 在系统模型未知的情况下, 对系统输出时间序列通过文中提出的方法进行两步预报, 预报序列可以很好地跟踪实际序列的变化. 由图 2(d) 可知系统在故障实际发生时间之后一个采样周期之内就判定了故障的发生. 对歼击机而言一般认为其结构故障如果在发生后的 8 个采样

周期内还不能被控制, 则将导致飞行事故的发生. 因此本文方法实现了突变故障的预报.

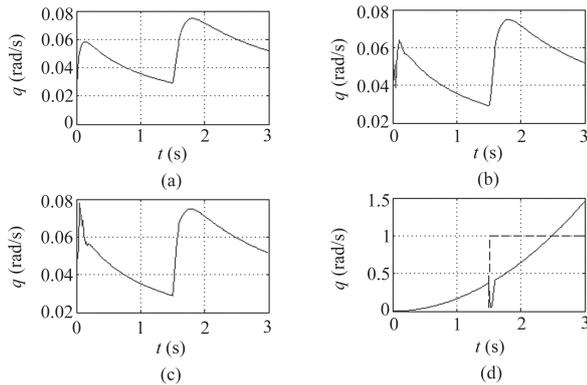


图 2 故障时俯仰角速度分量的预测及故障预报结果  
(a) 故障时俯仰角速度实际变化曲线; (b) 故障时俯仰角速度一次预测曲线; (c) 故障时俯仰角速度两次预测曲线; (d) 根据两步预测曲线的故障预报结果)

Fig. 2 The prediction result of the pitching rate

## 6 结论

利用系统观测器和滚动优化的思想, 将非线性时间序列的一步预报问题转化成非线性离散动态系统的观测问题. 利用线性 AR 模型拟合序列中的线性部分, 利用在线神经网络拟合序列中的非线性部分并且补偿拟合误差. 通过滚动优化, 由一步预测推广到  $N$  步预测. 证明了预测误差一致有界. 仿真结果表明, 该方法对有未知观测噪声的非线性时间序列有较好的预测结果. 利用概率密度估计和假设检验方法, 成功实现了故障预报. 该方法对突变的和缓变的故障都可以进行预报.

## References

- 1 Ho S L, Xie M. The use of ARIMA models for reliability forecasting and analysis. *Computers & Industrial Engineering*, 1998, **35**(1): 213~216
- 2 Zhang Z D, Hu S S. Modeling time series based fault prediction for model-unknown nonlinear system. In: Proceedings of the 2nd International Conference on Impulsive Dynamical System and Applications. Wuxi, China, 2002. 1641~1649
- 3 Wedding D K, Cios K J. Time series forecasting by combining RBF networks, certainty factors, and the Box-Jenkins model. *Neurocomputing*, 1996, **10**(2): 149~168
- 4 Zhang G P, Patuwo B E, Hu M Y. A simulation study of artificial neural networks for nonlinear time-series forecasting. *Computers & Operations Research*, 2001, **28**(3): 381~396
- 5 Cowper M R, Mulgrew B, Unsworth C P. Nonlinear prediction of chaotic signals using a normalized radial basis function network. *Signal Processing*, 2002, **82**(5): 775~789
- 6 Tse P W, Atherton D P. Prediction of machine deterioration using vibration based fault trends and recurrent neural networks. *Journal of Vibration and Acoustics*, 1999, **121**(7): 355~362
- 7 Xu K, Xie M, Tang L C, Ho S L. Application of neural networks in forecasting engine systems reliability. *Applied Soft Computing*, 2003, **2**(4): 255~268
- 8 BuHamra S, Smaoui N. The Box-Jenkins analysis and neural networks: prediction and time series modeling. *Applied Mathematical Modeling*, 2003, **27**(10): 805~815
- 9 Henry L, Titus L, Wang S C. Prediction of noisy chaotic time series using an optimal radial basis function neural network. *IEEE Transactions on Neural Networks*, 2001, **12**(5): 1163~1172
- 10 Park J, Sandberg J W. Universal approximation using radial basis functions network. *Neural Computation*, 1991, **3**(2): 246~257
- 11 Yeung D Y, Chow C. Parzen-window network intrusion detectors. In: Proceedings of the 16th International Conference on Pattern Recognition. IEEE, 2002. 4: 385~388



胡寿松 南京航空航天大学教授, 中国自动化学会理事. 主要研究方向为复杂系统故障诊断, 鲁棒控制与智能自修复控制. 本文通信作者.

E-mail: hushousong@nuaa.edu.cn

(HU Shou-Song Professor at Nanjing University of Aeronautics and Astronautics and a director of China Association of Automation. His research interest covers fault diagnosis, robust control, and intelligent self-repairing control of complex system. Corresponding author of this paper.)



张正道 江南大学讲师. 于南京航空航天大学获得博士学位. 主要研究方向为复杂系统的故障诊断与故障预报.

(ZHANG Zheng-Dao Lecturer of Jiangnan University. He received his Ph. D. from the Nanjing University of Aeronautics and Astronautics. His research interest covers fault diagnosis and fault prediction of complex systems.)