

引用格式:王洋,华容.组合时延预测的无人机传感器故障诊断研究[J].电光与控制,2019,26(5):86-89. WANG Y, HUA R. A combined time-delay prediction model for fault diagnosis of UAV sensors[J]. Electronics Optics & Control, 2019, 26(5):86-89.

## 组合时延预测的无人机传感器故障诊断研究

王洋, 华容

(上海应用技术大学电气与电子工程学院, 上海 201418)

**摘要:** 主要针对无人机传感器故障种类较多、类型复杂等特点,通过灰色模型与 Elman 神经网络对时延进行建模预测,利用最小方差原理得到组合时延预测模型,最后将其应用于无人机传感器故障诊断,并通过仿真验证组合预测模型对故障诊断时延具有较高的预测精度,证明了该诊断方法的有效性。

**关键词:** 故障诊断; 无人机传感器; 灰色模型; Elman 神经网络; 时延; 预测

**中图分类号:** TP231 **文献标志码:** A **doi:**10.3969/j.issn.1671-637X.2019.05.017

## A Combined Time-Delay Prediction Model for Fault Diagnosis of UAV Sensors

WANG Yang, HUA Rong

(School of Electrical and Electronic Engineering, Shanghai Institute of Technology, Shanghai 201418, China)

**Abstract:** Considering the fault characteristics of UAV sensors of multiple and complex fault types, we modeled and predicted the time delay by using grey model and Elman neural network, and used the principle of minimum variance to determine the best combination of model weighting coefficients. The method was applied to the fault diagnosis of UAV sensors. The simulation result showed that the combined prediction model has a high precision in predicting the fault diagnosis delay, and proved the validity of the proposed diagnostic method.

**Key words:** fault diagnosis; UAV sensor; grey model; Elman neural network; time delay; prediction

### 0 引言

随着计算机能力的提高和微型化,人工智能以及超精密技术的进步,无人机的机载电子设备越来越多,系统也越来越复杂,这对无人机的可靠性、维修性提出了越来越高的要求,无人机在线故障诊断系统由此诞生<sup>[1-2]</sup>。在传感器故障诊断方面,国内外已经进行了大量的研究,文献[3]针对多传感器的相关时序测量数据,提出了一种基于传感器故障检测的动态主元分析(DPCA)方法,仿真实验表明该方法能有效地检测和识别出故障传感器。

目前时延预测在网络控制系统方面取得了一定的进展,按其研究方法可分为如下4种:1)基于回归方法

的时延建模预测<sup>[4-7]</sup>,采用回归方法的预测需要对模型精确建模,其模型的参数求解过程复杂,很难在线递推,不适合时延动态变化范围很大的情况;2)神经网络具有非线性辨识能力,且运算速度快,因此可使用神经网络来进行时延的预测<sup>[8-10]</sup>,但易陷于局部最优值以及过分依赖输入时延序列的自相关系数;3)支持向量机对于非线性、小样本以及高维模式识别问题有独特的优势,可以用于具有强非线性的网络时延的预测<sup>[11]</sup>,但是基于SVM的算法存在参数不容易确定的问题;4)对时延数据进行分析,研究其分布规律进而进行预测也是研究方向之一<sup>[12]</sup>,但基于统计分析预测存在的问题是分布参数难以求解,同时由于时延的随机性,其预测精度很难保证。

### 1 GM(1,1)时延预测模型

GM(1,1)时延预测模型是灰色模型的基本模型,设网络时延序列 $D^0$ 为

$$D^0 = \{d^0(k)\} \quad k = 1, 2, \dots, n \quad (1)$$

收稿日期:2018-04-10

修回日期:2019-01-11

基金项目:上海市“联盟计划”资助项目(LM201756)

作者简介:王洋(1992—),男,江苏沭阳人,硕士生,研究方向为四旋翼飞行器的导航与控制。

由于时延序列是随机变化的,无法直接建立对它的预测模型,因此对序列  $D^0$  进行一次累加生成序列  $D^1$  为

$$D^1 = \{d^1(k)\} \quad k=1,2,\dots,n \quad (2)$$

式中

$$d^1(k) = \sum_{k=1}^n d^0(k) \quad (3)$$

则有

$$d^0(k) + ad^1(k) = b \quad (4)$$

式中,  $a, b$  为待定系数。式(4)为 GM(1,1) 时延预测模型的基本形式。GM(1,1) 时延预测模型建模基本形式以平均的观念对时延序列进行分析,可采用  $D^1$  紧邻均值生成序列  $z^1(k) = 0.5(d^1(k) + d^1(k-1))$  来代替  $d^1(k)$ , 由此可得

$$d^0(k) + az^1(k) = b \quad k=2,3,\dots,n \quad (5)$$

求微分可得

$$\frac{dd^1(t)}{dt} + ad^1(t) = b \quad (6)$$

按照最小二乘法进行参数  $a, b$  的辨识,即

$$\hat{a} = [a \quad b]^T = (Z^T Z)^{-1} Z^T Y \quad (7)$$

$$\text{式中: } Y = \begin{bmatrix} d^0(2) \\ d^0(3) \\ \vdots \\ d^0(n) \end{bmatrix}; Z = \begin{bmatrix} -z^1(2) & 1 \\ -z^1(3) & 1 \\ \vdots & \vdots \\ -z^1(n) & 1 \end{bmatrix}。$$

由此可得到 GM(1,1) 的预测模型为

$$\hat{d}^1(k+1) = (d^0(1) - b/a)e^{-ak} + b/a \quad (8)$$

$$\hat{d}^0(k+1) = \hat{d}^1(k+1) - \hat{d}^1(k) \quad (9)$$

## 2 Elman 神经网络

Elman 神经网络采用动态反向传播学习算法,即梯度下降法对网络进行训练,目标是通过网络各层的权值调节,使样本输出和辨识输出的均方误差达到最小。设网络外部输入序列为  $u(t)$ , 反馈层输出为  $y_c(t)$ , 网络的输出为  $y(t)$ ,  $w^1, w^2, w^3$  分别为反馈层至隐层、输入层至隐层以及隐层至输出层的连接权矩阵,具体学习算法为

$$E(K) = \frac{1}{2}(y_d(k) - y(k))^T(y_d(k) - y(k)) \quad (10)$$

$$\Delta w_{ij}^3 = \eta_3 \delta_j^0 x_j(k) \quad (11)$$

$$\Delta w_{jq}^2 = \eta_2 \delta_j^h u_q(k-1) \quad (12)$$

$$\Delta w_{ji}^1 = \eta_1 \sum_{i=1}^m (\delta_i^0 w_{ij}^3) \frac{\partial x_j(k)}{\partial w_{ji}^1} \quad (13)$$

$$\delta_i^0 = (y_{di}(k) - y_i(k)) g'(\cdot) \quad (14)$$

$$\frac{\partial x_j(k)}{\partial w_{ji}^1} = f'_j(\cdot) x_i(k-1) + a \frac{\partial x_j(k-1)}{\partial w_{ji}^1} \quad (15)$$

$$\delta_j^h = \sum_{i=1}^m (\delta_i^0 w_{ij}^3) f'_j(\cdot) \quad (16)$$

式中:  $i=1,2,\dots,m; j=1,2,\dots,n; q=1,2,\dots,r; \eta_1, \eta_2, \eta_3$  分别为  $w^1, w^2, w^3$  的学习步长。

## 3 组合时延预测模型

GM(1,1) 时延预测模型对于平稳的序列预测精度较高,当时延序列波动较大时,其预测精度降低。而 Elman 神经网络对于非线性时延序列预测效果好,但其易于陷入局部最优。因此采用组合预测模型,利用 GM(1,1) 模型弱化原始时延序列的随机性和累加序列的规律性,再利用 Elman 神经网络的非线性,求取更好的预测效果。组合预测模型如图 1 所示。




图 1 组合预测模型

Fig. 1 Combined prediction model

其预测方法如下:设  $d(1), d(2), \dots, d(n)$  为历史时延序列,利用历史时延数据对  $d(n+1)$  进行预测,设  $\hat{d}_1(i)$  与  $\hat{d}_2(i)$  分别为 GM(1,1) 模型与 Elman 神经网络的时延预测值,  $\hat{d}(i)$  为组合模型的预测时延,建立互补组合预测模型为

$$\hat{d}(i) = \gamma \hat{d}_1(i) + (1-\gamma) \hat{d}_2(i) \quad 0 < 1 < \gamma \quad (17)$$

通过确定最佳权重系数  $\gamma$  实现最佳的组合预测模型。设有如下的误差序列:  $e_1(i) = d(i) - \hat{d}_1(i), e_2(i) = d(i) - \hat{d}_2(i)$ 。求取各个误差序列的方差

$$D(e) = \gamma^2 D(e_1) + (1-\gamma)^2 D(e_2) + 2\gamma(1-\gamma) V_c(e_1, e_2) \quad (18)$$

通过求解  $\frac{dD(e)}{d\gamma} = 0$  可使方差  $D(e)$  最小,则有

$$\gamma_{\text{best}} = \frac{D(e_1) - V_c(e_1, e_2)}{D(e_1) + D(e_2) - 2V_c(e_1, e_2)} \quad (19)$$

当  $\gamma = \gamma_{\text{best}}$  时,即可满足组合预测模型预测误差序列的方差为 0,由于 GM(1,1) 与 Elman 神经网络独立建模,可认为误差序列  $e_1, e_2$  之间相互独立,因此可得到组合预测模型的预测时延为

$$\hat{d}(i) = \frac{D(e_2) \hat{d}_1(i) + D(e_1) \hat{d}_2(i)}{D(e_2) + D(e_1)} \quad (20)$$

通过测试软件得到历史时延数据,按照式(19)可计算得到  $\gamma_{\text{best}}$ ,进而得到组合预测模型。

## 4 仿真研究

### 4.1 组合时延预测研究

首先选取 500 组实航数据作为时延样本数据,前 400 组数据用于 GM(1,1) 与 Elman 神经网络组合模型的建模训练,后 100 组数据用于模型的验证。

GM(1,1)时延队列长度为 20,Elman 神经网络输入层数为 20,最大迭代次数为 3000,迭代目标为 0.0001,隐层个数为 10,输出层个数为 1,经训练之后得到 GM(1,1)模型的参数  $b = 147.8073, a = -0.0093$ 。图 2a 为 GM(1,1)模型的 100 组预测时延与实际时延的对比,图 2b 为 Elman 神经网络的 100 组预测时延与实际时延的对比,按式(19)可求得  $\gamma_{best} = 0.2964$ ,图 2c 为组合预测模型的预测时延与实际时延的对比图。为了对比验证本文时延预测方法的准确性,图 2d、图 2e 分别给出了 LS-SVM 模型与 AR 模型的预测时延与实际时延的对比,其中,LS-SVM 模型的参数  $\gamma = 32.03, \sigma^2 = 4.361$ ,AR 模型的阶数  $p = 10$ 。

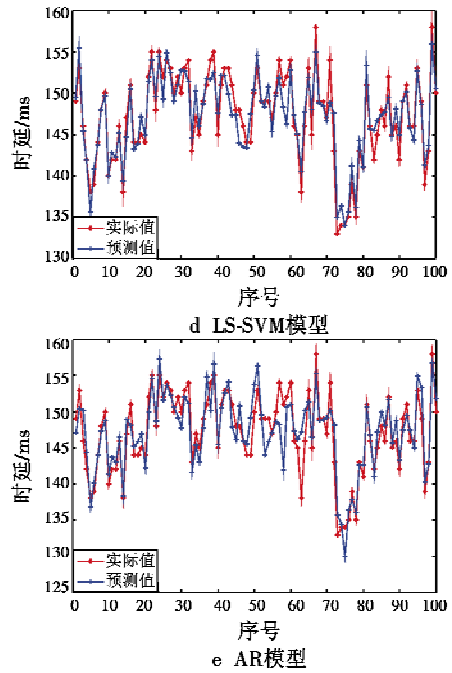
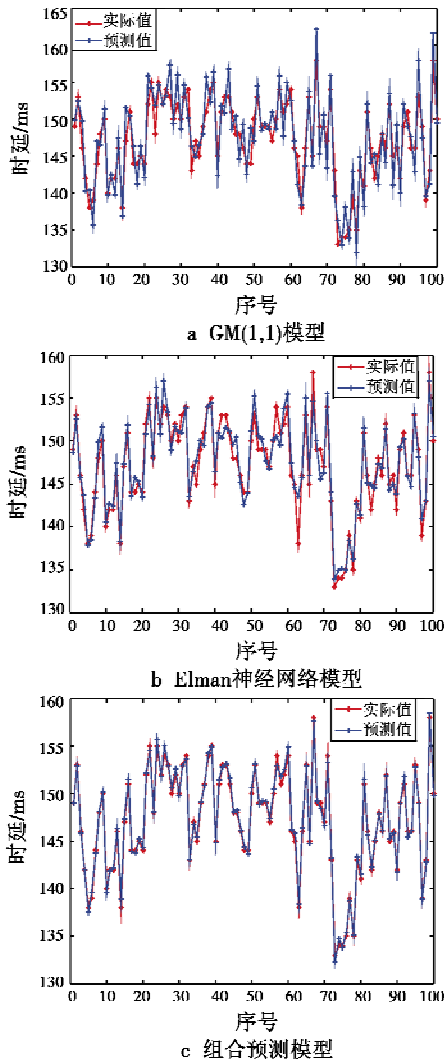


图 2 不同模型的预测时延与实际时延对比

Fig.2 The prediction delay of different models vs their actual delay

表 1 为 5 种模型的 MSE 对比。从图 2 的预测时延与实际时延的对比曲线以及表 1 的 MSE 值对比可知,本文提出的组合预测模型较其他方法具有更高的预测精度,由于本文采用最小方差求出了灰色模型与 Elman 神经网络组合模型的权重系数,因此提高了预测精度。

表 1 5 种预测模型的 MSE 对比

Table 1 MSEs of 5 prediction models

模型	预测误差(MSE)
GM(1,1)模型	5.6395
Elman 模型	1.4369
组合预测模型	0.1557
LS-SVM 模型	3.6220
AR 模型	6.3256

### 4.2 故障诊断研究

对于定高飞行下的传感器故障诊断研究,在 200 s 时加入卡死 0°处故障,将基于灰色模型与 Elman 神经网络预测方法应用于传感器故障诊断,仿真结果如图 3 所示。

由图 3 可知,在 200 s 时发生卡死 0°处故障,及时诊断出传感器的卡死故障。

无人机横侧向运动的飞行模式有定向直飞、左转弯、右转弯,在右转弯 10 km 以下滚转角给定 30°情况下,对速率陀螺输出的滚转角进行实时监控,在 250 s 时加入 3°恒偏差,其故障诊断仿真结果如图 4 所示。

由图 4 可知,当传感器发生故障时,所用方法可以




图3 卡死0°处故障诊断

Fig. 3 Fault diagnosis of being stuck at 0°




图4 3°恒偏差故障诊断

Fig. 4 Fault diagnosis of 3° constant deviation

及时检测出传感器故障发生的时刻,证明了该方法的可靠性和准确性。

## 5 结束语

本文针对网络控制系统的时延预测问题,提出一种组合预测模型方法,通过求取两种模型最佳的组合权重系数达到最佳的预测模型,仿真实验表明了本文方法较其他方法具有更高的预测精度,并且能有效地进行无人机传感器的故障诊断。

## 参考文献

- [1] 李斌,章卫国,宁东方,等. 基于神经网络信息融合的智能故障诊断方法[J]. 计算机仿真, 2008, 25(6): 35-37, 58.
- [2] 周星宇,李春涛,姚瑞,等. 无人机飞行控制软件负荷均衡策略设计[J]. 电光与控制, 2018, 25(6): 25-30.
- [3] KU W F, STORER R H, GEORGAKIS C. Disturbance detection and isolation by dynamic principal component analysis [J]. *Chemometrics and Intelligent Laboratory Systems*, 1995 (30): 179-196.
- [4] 杜大军,费敏锐,宋杨,等. 网络控制系统的简要回顾及展望[J]. 仪器仪表学报, 2011, 32(3): 713-720.
- [5] HU T J, HUANG X X, TAN Q. Time delay prediction for space teleoperation based on non-Gaussian auto-regressive model [C]//*Proceedings of International Conference on Modeling, Identification and Control*, 2012: 567-572.
- [6] 时维国,邵诚,孙正阳. 基于 AR 模型时延预测的改进 GPC 网络控制算法[J]. 控制与决策, 2012, 27(3): 477-480.
- [7] YANG M, RU J, LI X R, et al. Predicting internet end-to-end delay: a multiple-model approach [C]//*The 24th Annual Joint Conference of the IEEE Computer and Communications Societies*, 2005: 2815-2819.
- [8] 宋杨,涂小敏,费敏锐. 基于 FARIMA 模型的 Internet 时延预测[J]. 仪器仪表学报, 2012, 33(4): 757-763.
- [9] LI H Y, WANG H, CHAO G. Internet time-delay prediction based on autoregressive and neural network model [C]//*International Conference on Communications, Circuits and Systems*, 2006: 1758-1761.
- [10] RAHMANI B, MARKAZI A H D, MOZAYANI N. Real time prediction of time delays in a networked control system [C]//*The 3rd International Symposium on Communications, Control and Signal Processing*, 2008: 1242-1245.
- [11] 李春茂,肖建,张玥. 网络控制系统的时延估计和自适应预测控制[J]. 西南交通大学学报, 2007, 42(2): 175-180.
- [12] FU X H, FU X. A predictive algorithm for time delay internet network [C]//*IEEE International Conference on Electronics, Communications and Control (ICECC)*, 2011: 666-669.
- [8] 赵科东,孙永荣,周晓达,等. ARINC661 目标符号显控方式的研究与设计[J]. 电光与控制, 2017, 24(10): 59-63.
- [9] 郑澄,孙永荣,王晖,等. 基于 ARINC661 的触摸屏显控系统研究与设计[J]. 电光与控制, 2015, 22(4): 62-65, 69.
- [10] 叶中脉. 航电仿真系统接口监控软件的设计与实现 [D]. 成都: 电子科技大学, 2012.
- [11] 王达,孙永荣,王岩,等. ARINC661 座舱显示系统通信数据监控存储分析软件的设计[J]. 航空计算技术, 2014, 44(2): 110-113, 117.
- [12] 李笑瑜,孙永荣,赵科东. ARINC661 多显示器座舱系统中的 UA 画面处理技术[J]. 电光与控制, 2018, 25(6): 95-97, 114.

(上接第 80 页)