

文章编号:1004-9037(2014)05-0828-05

基于灰色粒子群神经网络的航天器参量预测

顾 胜^{1,2} 魏蛟龙²

(1. 北京航天飞行控制中心,北京,100094;2. 华中科技大学电子与信息工程系,武汉,430074)

摘要:针对航天器精确预测与健康管理的需求,将粒子群算法、灰色理论与神经网络的优势相结合,提出了一种灰色粒子群神经网络组合参量预测方法,实现了灰色模型、粒子群算法、神经网络模型的优势互补。针对某卫星南帆板输出电流参量的预测实例,采用总平均绝对误差、总平均绝对百分比误差、总均方根误差3个预测结果评价指标,对灰色粒子群神经网络模型、粒子群神经网络模型、灰色模型和残差修正灰色模型的预测结果进行了比较,结果证明灰色粒子群神经网络模型的预测精度较高,在航天器参量预测领域具有很好的应用前景。

关键词:航天器;粒子群优化;灰色理论;神经网络

中图分类号:TP202

文献标识码:A

Prediction Based on Particle Swarm Optimization-Grey Neural Network of Spacecraft Parameter Values

Gu Sheng^{1,2}, Wei Jiaolong²

(1. Beijing Aerospace Control Center, Beijing, 100094, China;

2. Department of Electronic and Information Engineering, Huazhong University of Science and Technology, Wuhan, 430074, China)

Abstract: Aiming at the requirements of precise prediction and health management of spacecraft, a method for combinational prediction of parameter values called particle swarm optimization-grey neural network is promoted. The method enables particle swarm optimization algorithms, grey theory and neural network to complement each other. Firstly, a prognosis for output current values of southern sailboard of a certain satellite is taken as an example. Then, three evaluation indexes of prediction, including mean absolute error, mean absolute percentage error and root mean square error, are chosen to evaluate the results of different step-length prediction is of particle swarm optimization-fuzzy neural network. The results show that the particle swarm optimization-fuzzy neural network is effective. Secondly, the mean absolute percentage errors of particle swarm optimization-fuzzy neural network, grey model-particle swarm optimization neural network, particle swarm optimization neural network and grey model are calculated. The results show that the model of particle swarm optimization-fuzzy neural network is the most precise one and more efficient in prediction than others. It has vast application prospects in the field of prediction of spacecraft parameter values.

Key words: spacecraft; particle swarm optimization; grey theory; neural network

引 言

近年来,我国航天事业蓬勃发展,在轨运行的航天器数量逐年增多。现代航天器系统日趋复杂,致命故障损失越来越严重,给地面在轨管理工作带

来了极大的挑战。长期的监测信息表明,航天器发生异常时一般伴有状态的突变或缓变,分析预测运行信息中的某些关键参数,可及时发现航天器故障,并分析其在轨运行的性能。为了保证航天器在轨飞行期间安全可靠运行,有必要对其故障发展趋势进行研究,以便于开展基于参量状态的飞行控制

及维护措施,提升航天器执行科研试验任务的安全性[1-3]。

通常,基于数据的航天器故障预测方法以航天器的测量数据为基础,结合各种算法进行航天器故障趋势预测,为基于参量状态的维护控制提供参考[4]。美军利用GPS卫星遥测数据对原子钟故障进行了成功预测。文献[4]对基于遥测数据的飞行器故障预测若干方法进行了对比,对时间序列模型在航天器故障预测中的应用进行了详细研究。文献[5]对发动机的检测参数给出了一种健康状况估计方法;文献[6]针对卫星遥测数据趋势性特点,使用灰色理论方法对卫星电池功率做了预测研究;文献[7]提出了灰色理论。灰色GM(1,1)模型是其中一种很适用的趋势预测模型,具有累加生成操作特点,该操作能有效降低数据的随机性。目前GM(1,1)在热导、环境科学、农业、航天等方面得到了广泛应用[8-11]。然而,GM(1,1)模型主要适用于单一指数增长模式,当序列中有个别数据出现扰动时对预测结果影响较大。航天系统的复杂性使得预测方法必须考虑其非线性特征。而神经网络、混沌理论的发展则为其提供了有效的途径。其中,文献[12,13]采用神经网络预测的手段给出了一种健康状况预测方法。

为综合考虑航天器线性与非线性特征,本文根据监测数据特点,提出一种基于灰色粒子群神经网络(GM-particle swarm optimization neural network back propagation, GM-PSOBP)的航天器参量故障预测方法,该方法结合结合卫星帆板参量数据变化特点,充分利用GM(1,1)模型和PSOBP模型优势,有效提升了航天器故障预测精度。

1 粒子群优化算法的反向传播

PSOBP^[14]是基于粒子群优化算法的反向传播(Back propagation, BP)网络模型参数优化方法,它能提高BP网络模型的收敛速度和预测精度,其建模流程如图1所示。

(1) 初始化BP神经网络结构。结合具体情况,设定网络的输入层、隐含层、输出层的神经元个数。

(2) 初始化粒子群优化(Particle swarm optimization, PSO)算法模型参数和每个粒子的初始位置与初始速度。初始化种群数目 n 、最大迭代次数 k 、惯性权重 ω 以及加速常数 c_1 和 c_2 ;粒子维度 d 是神经网络中所有权值和阈值数目的总和。初

始化种群中每个粒子的位置 x_i^k 和速度 v_i^k ,其中 x_i^k 的初始值范围为 $[-1, 1]$, v_i^k 的初始值范围为 $[-v_{\max}, v_{\max}]$,取 $v_{\max} = 5$,视具体情况做调整。

(3) 计算每个粒子的适应值。使用神经网络的均方误差作为PSO的适应值函数,通过PSO算法强大的搜索性能使网络的均方误差满足精度要求。公式如下

$$f = \frac{1}{2m} \sum_{k=1}^m \sum_{t=1}^q (y_t^k - c_t^k)^2 \quad (1)$$

式中: m 为样本个数; q 为网络输出神经元的个数; y_t^k 为第 k 个样本的第 t 个网络输出神经元的期望输出值; c_t^k 为第 k 个样本的第 t 个网络输出神经元的实际输出值。

将每个粒子的位置 x_i^k 所代表的权值和阈值代入神经网络,计算网络的实际输出,然后按式(1)计算每一个粒子在每一维空间的适应值。

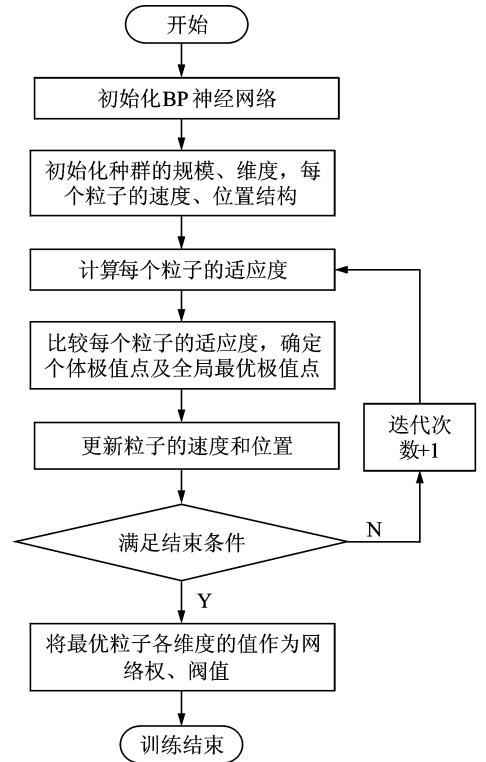


图1 PSOBP建模流程

Fig. 1 Modeling process of PSOBP

(4) 比较粒子的适应值与自身最优值 p_{best} 。如果当前值比 p_{best} 更优,则置 p_{best} 为当前值,应置个体最优位置 p_b 为当前位置。比较粒子的适应值与种群最优值 g_{best} 。如果当前值比 g_{best} 更优,则置 g_{best} 为当前值,应置种群最优位置 g_b 为当前位置。

(5) 使用式(2,3)更新每个粒子的速度和位置。

$$v_{i,k}^{k+1} = \omega v_{i,m}^k + c_1 r_1 (p_{i,k}^k - x_{i,k}^k) + c_2 r_2 (g_m^k - x_{i,k}^k) \quad (2)$$

$$x_{i,k}^{k+1} = x_{i,k}^k + v_{i,k}^{k+1} \quad (3)$$

式中： $v_{i,k}^k$ 是第 i 个粒子的第 k 次迭代后在第 m 维上的速度； r_1 和 r_2 为两个独立的随机数，都服从 $[0,1]$ 均匀分布； $p_{i,k}^k$ 是第 k 次迭代后粒子 i 的个体最优值在第 m 维的位置； g_m^k 是第 k 次迭代后全局最优值在第 m 维的位置； $x_{i,k}^k$ 是第 i 个粒子的第 k 次迭代后在第 m 维上的位置； c_1 和 c_2 是算法的加速系数，通常的取值范围是 $[1,2]$ ； ω 为惯性权重系数，通常的取值范围是 $[0.8, 1.2]$ 。

(6) 比较次数是否达到最大迭代次数或式(1)均方误差精度是否满足要求，若预测精度满足要求，则算法收敛，最后一次迭代的全局最优值 g_{best} 中每一维的权值和阈值即是所求的值，算法结束；否则返回第(3)步，算法继续迭代。

(7) 用训练好的网络对残差序列的后续 m 个值进行预测，从而得到残差预测序列 $\hat{e} = \{\hat{e}(1), \hat{e}(2), \dots, \hat{e}(n+m)\}$ 。

灰色预测模型 GM(1,1) 与粒子群神经网络 PSOBP 两种预测模型分别有各自的优点，它们在预测方面表现较好。灰色系统和神经网络都可看作是数值化的函数估计器，将灰色系统与神经网络融合，构造一种组合模型，可以取长补短，对复杂的不确定性问题进行更好的求解。

2 灰色粒子群神经网络算法

2.1 算法框架

GM(1,1) 模型应用于数据序列与测试时，由于其非线性能力不强，导致残差序列含有很多非线性的模糊信息，但传统的残差修正模型建模条件苛刻(主要是序列符号要求和序列长度要求)，往往并不能进行残差修正。算法借鉴灰色残差修正模型的基本思想，对残差序列使用 PSOBP 模型进行修正，从而建立一种组合预测模型灰色粒子群神经网络，其算法框架如图 2 所示。

2.2 GM-PSOBP 建模步骤

GM-PSOBP 建模步骤如下：

(1) 建立 GM(1,1) 预测模型。设原始数据序列： $X = \{x(1), x(2), \dots, x(n)\}$ ，对原始序列建立灰色 GM(1,1) 模型，得到原始序列的 GM(1,1) 模型预测结果序列

$$\hat{X}_{\text{GM}} = \{\hat{x}_{\text{GM}}(1), \hat{x}_{\text{GM}}(2), \dots, \hat{x}_{\text{GM}}(n+m)\} \quad (4)$$

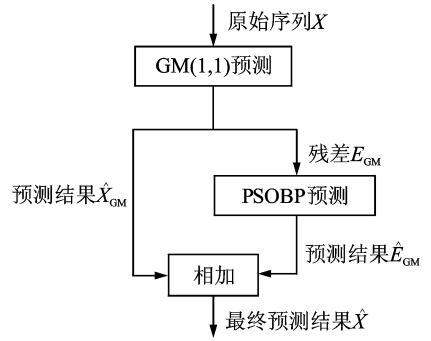


图 2 GM-PSOBP 算法框架

Fig. 2 Algorithm framework of GM-PSOBP

(2) 计算 GM(1,1) 预测模型的残差序列

$$e = \{e(1), e(2), \dots, e(n)\} \quad (5)$$

式中： $e(i) = \hat{x}_{\text{GM}}(i) - x(i)$ 。

(3) 建立残差序列的 PSOBP 预测模型。设预测阶数为 m ，即用 $\{e(i-m), e(i-m+1), \dots, e(i-1)\}$ 的数据预测 i 时刻的值 $e(i)$ ，从而构造出神经网络的训练数据矩阵

$$\mathbf{NN}_{\text{in}} = \begin{bmatrix} e(1) & e(2) & \dots & e(m+1) \\ e(2) & e(3) & \dots & e(m+2) \\ \vdots & \vdots & \ddots & \vdots \\ e(n-m) & e(n-m+2) & \dots & e(n) \end{bmatrix} \quad (6)$$

其中，前 m 列为训练输入，最后一列为训练输出。

(4) 按 PSOBP 建模流程构建 PSOBP 模型，并完成网络训练。

(5) 计算最终的组合模型预测序列

$$\hat{X} = \{\hat{x}(1), \hat{x}(2), \dots, \hat{x}(n+m)\} \quad (7)$$

式中： $\hat{x}(i) = \hat{x}_{\text{GM}}(i) + \hat{e}(i)$ 。

2.3 GM-PSOBP 模型优势分析

GM-PSOBP 模型改进了 GM(1,1) 残差修正模型中可建模残差序列的限制条件，即不要求残差的符号一致，不要求残差的长度大于等于 4，以及对 GM(1,1) 模型均可修正等。

GM-PSOBP 模型相比于单一的 GM 模型或 PSOBP 模型具有以下优势：

(1) GM(1,1) 模型主要适用于单一指数增长模式，而当原始序列中有个别数据出现扰动时，对预测结果影响较大。由于其非线性能力不强，残差序列含有很多未被挖掘的非线性、模糊的信息。GM-PSOBP 模型在 GM(1,1) 模型的基础上，用 PSOBP 模型修正其参差序列，吸取了 PSOBP 模

型的优点,具有强大的非线性映射能力,良好的自适应能力和泛化能力,对噪声有较强的适应能力。

(2)PSOBP 模型应用于预测时,将系统看作一个黑箱,只考虑系统的输入与输出,忽略了系统中某些可用的确定性信息。GM-PSOBP 模型先利用 GM(1,1)模型找出系统的总体变化趋势,再把系统中的非线性复杂成分分离出来,然后用 PSOBP 模型进行预测,一定程度上弥补了 PSOBP 模型的不足。

2.4 预测效果评价方法

为了检验算法的精度,提高评价结果的可信度,采用多个不同的训练数据,对不同的算法分别进行多次实验,然后综合考虑多次实验结果,从而对预测精度给出更准确的评价。

设对时间序列做 k 次实验,每次实验的训练集元素个数均为 n ,预测期数和验证集数据期数均为 v ,但训练集的起点不同,第 i 次实验的训练集数据为 $[x_{T_0+i-n}, x_{T_0+i-n+1}, \dots, x_{T_0+i-1}]$,测试集数据为 $[x_{T_0+i}, x_{T_0+i+1}, \dots, x_{T_0+i+v-1}]$ 。第 j 次实验的第 i 步预测的误差记为 e_i^j ,其对应的原始值记为 y_i ,得到下面的 3 个评价标准:

(1)总平均绝对误差(Total mean absolute error, TMAE)

$$TMAE = \frac{1}{k} \sum_{j=1}^k \left(\frac{1}{v} \sum_{i=1}^v |e_i^j| \right) \quad (8)$$

(2)总平均绝对百分比误差(Total mean absolute percentage error, TMAPE)

$$TMAPE = \frac{1}{k} \sum_{j=1}^k \left(\frac{1}{v} \sum_{i=1}^v \left| \frac{e_i^j}{y_i} \right| \right) \times 100\% \quad (9)$$

(3)总均方根误差(Total root mean square error, TRMSE)

$$TRMSE = \sqrt{\frac{1}{k} \sum_{j=1}^k \left(\frac{1}{v} \sum_{i=1}^v (e_i^j)^2 \right)} \quad (10)$$

3 实例验证

对某卫星南帆板输出电流进行预测实验。用 PSOBP 算法,令训练集序列长度 = 400,设置神经网络参数:输入层节点数 = 1,隐含层节点数目 = 11,输出层节点数目 = 1;设置粒子群优化模型参数:粒子数 = 30,惯性权重 $\omega = 0.8$,加速常数 $c_1 = 2, c_2 = 2$,最大训练次数 = 60 000。预测 100 个数据的预测误差为: MAE = 0.304 36, MAPE = 0.498 94%, RMSE = 0.347 3。

采用 GM-PSOBP 算法,在基本参数设置与 PSOBP 算法相同的情况下,设置回归长度 = 21,预测 100 个数据的预测误差为: MAE = 0.283 87, MAPE = 0.465 01%, RMSE = 0.331 88。

GM-PSOBP 与 PSOBP 预测结果如图 3 所示。用 GM(1,1)模型对其进行预测,训练集序列长度为 400,当预测长度为 100 时,预测误差 MAE = 2.028 2, MAPE = 3.336 4%, RMSE = 2.213 6;对 GM(1,1)进行残差修正预测,同样设定训练序列长度为 400,当预测长度为 100 时,预测误差 MAE = 3.428 5, MAPE = 5.544 3%, RMSE = 3.939 0。GM(1,1)与残差修正 GM(1,1)预测 100 个数据的结果如图 4 所示。

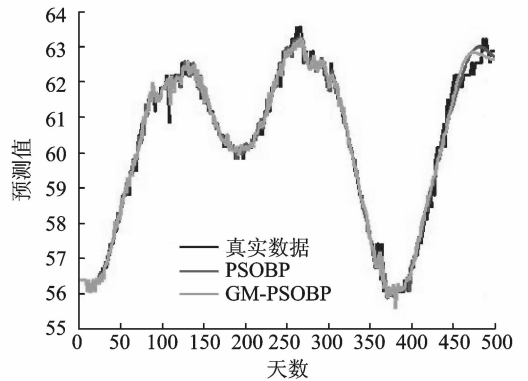


图 3 GM-PSOBP 与 PSOBP 预测结果
Fig. 3 Prediction results of GM-PSOBP and PSOBP

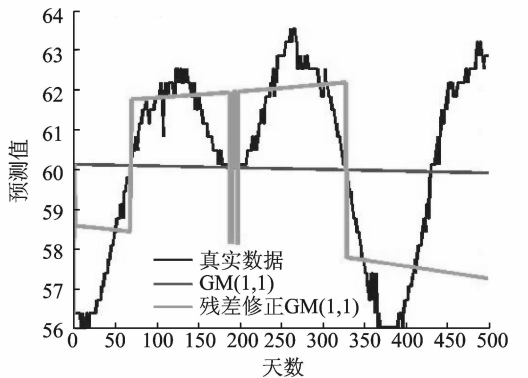


图 4 GM(1,1)与残差修正 GM(1,1)预测结果
Fig. 4 Prediction results of GM(1,1) and residual GM(1,1)

GM-PSOBP 与 PSOBP, GM(1,1), 残差修正 GM(1,1)预测的 MAE, MAPE 与 RMSE 比较结果如表 1 所示。4 种预测模型都能够对南帆板输出电流进行有效预测。但 PSOBP 模型与 GM-PSOBP 模型的预测误差远小于 GM(1,1)模型和残差修正 GM(1,1)模型,其中 GM-PSOBP 模型的预测误差最小。参照国际上对预测方法的评价

价^[14],GM-PSOBP 方法属高精度预测算法。

表 1 4 种算法的预测误差的比较

Table 1 Comparison of four algorithms prediction error

算法	TMAE	TMAPE/%	TRMSE
GM	2.028 2	3.336 4	2.213 6
修正 GM	3.428 5	5.544 3	3.939 0
PSOBP	0.304 4	0.498 9	0.347 3
GM-PSOBP	0.283 9	0.465 0	0.331 9

4 结 束 语

本文针对航天器精确预测与健康管理的需要,成功地将粒子群算法、灰色理论与神经网络的优势相结合,提出了一种灰色粒子群神经网络组合量预测方法 GM-PSOBP。该方法先利用 GM(1,1)模型优势找出系统总体变化趋势,同时把非线性复杂成分分离出来用 PSOBP 模型进行预测,最后将两部分预测结果叠加输出。通过真实监测数据上预测实验,并与粒子群神经网络模型、灰色模型和残差修正灰色模型的预测结果进行了比较。结果证明,GM-PSOBP 方法与其他预测方法相比具有更高的精度。本文提出的 GM-PSOBP 方法在航天器参量预测领域具有很好的应用前景。

实验中发现,当数据量较大时参数的设置会影响算法的效率。尽管 PSO 方法优化了神经网络方法参数的寻找,但 PSO 本身同样需要合适的参数。参数如何设置使得算法整体效率更高有待进一步研究。此外,将其改进为增量式算法,实现航天器参量的实时预测将是下一步研究重点。

参 考 文 献:

- [1] Rehage D, Carl U B, Vahl A. Redundancy management of fault tolerant aircraft system architectures - reliability synthesis and analysis of degraded system states [J]. Aerospace Science and Technology, 2005, 9(4):337-347.
- [2] Varma S, Kumar K D. Fault tolerant satellite attitude control using solar radiation pressure based on nonlinear adaptive sliding mode [J]. Acta Astronautica, 2010, 66(3/4):486-500.
- [3] Jin J, Ko S, Ryoo C. Fault tolerant control for satellites with four reaction wheels [J]. Control Engineering Practice, 2008, 16(10):1250-1258.
- [4] Dimogianopoulos D, Hios J, Fassois S. Aircraft engine health management via stochastic modeling of flight data interrelations [J]. Aerospace Science and

Technology, 2012, 16(1):70-81.

- [5] Xue W, Guo Y Q. Aircraft engine sensor fault diagnosis based on estimation of engine's health degradation [J]. Chinese Journal of Aeronautics, 2009, 22(1):18-21.
- [6] 谷吉海,姜兴滑,巴兴强. 动态新息 GM(1,1)在卫星电池阵功率预测中的应用[J]. 哈尔滨工业大学学报, 2003, 35(1): 28-30.
Gu Jihai, Jiang Xingwei, Ba Xingqiang, et al. Application of dynamic innovation GM(1,1) to power prediction of satellite battery array[J]. Journal of Harbin Institute of Technology, 2003, 35(1): 28-30.
- [7] 邓聚龙. 灰色论基础[M]. 武汉:华中科技大学出版社, 2002.
Deng Julong. Introduction to grey system theory [M]. Wuhan: Huazhong University of Science & Technology Press, 2002.
- [8] Chiang J Y, Chen C K. Application of grey prediction to inverse nonlinear heat conduction problem [J]. International Journal of Heat and Mass Transfer, 2008, 51(3/4): 576-585.
- [9] Lin Chiunsin, Liou Fenmay, Huang Chihpin. Grey forecasting model for CO2 emissions: A Taiwan study [J]. Applied Energy, 2011, 88 (11): 3816-3820.
- [10] Huang Changjun, Tang Zhengqi. Application of improved error GM(1,1) model on predicting of cultivated land in Yiyang [J]. Energy Procedia, 2011, (5): 1172-1176.
- [11] Zuo Y Z, Yong Q C, Xiu S L. An improved grey model and its application research on the prediction of real-time GPS satellite clock errors[J]. Chinese Astronomy and Astrophysics, 2009, 33(1): 72-89.
- [12] Tayarani-Bathaie S S, Vanini Z N S, Khorasani K. Dynamic neural network-based fault diagnosis of gas turbine engines [J]. Neurocomputing, 2014, 125(11):153-165.
- [13] Ogaji S O T, Singh R. Advanced engine diagnostics using artificial neural networks [J]. Applied Soft Computing, 2003, 3(3):259-271.
- [14] Khan K, Sahai A. A comparison of BA, GA, PSO, BP and LM for training feed forward neural networks in e-learning context[J]. International Journal of Intelligent Systems and Applications, 2012, 4(7): 23-29.

作者简介:顾胜(1973-),男,博士生,高级工程师,研究方向:航天工程测量控制、故障预测,E-mail:bjgusheng@163.com;魏蛟龙(1965-),男,教授,博士生导师,研究方向:现代网络通信技术、人工智能、计算机测量与控制。