

一种时间序列分解的卫星周期性参数预测方法

周 枫 皮德常

(南京航空航天大学计算机科学与技术学院 南京 210016)

摘 要 卫星遥测参数预测对卫星故障发现有着重要的指导作用。针对周期性参数难以预测的问题,提出了一种基于时间序列分解的卫星周期性参数的预测方法。该方法首先在频域上使用小波分析对参数序列进行降噪并提取参数的周期;然后,在时域上对参数的时间序列进行分解,进一步得到参数的趋势项和随机项,并根据各项特点分别使用灰色模型和 ARMA 模型进行预测;最后,重组各部分的预测值,得到最终预测结果。通过对我国某卫星遥测数据的对比实验分析,验证了该方法的正确性和有效性。

关键词 卫星参数,时间序列,预测,小波分析,灰色模型

中图分类号 TP399 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.2.002

Prediction Algorithm for Seasonal Satellite Parameters Based on Time Series Decomposition

ZHOU Feng PI De-chang

(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract The prediction of satellite seasonal parameters plays a key guiding role for the satellite fault prediction. Considering the low prediction precision problem of satellite seasonal parameters, a prediction method for seasonal satellite parameters based on time series decomposition was proposed. Firstly, the wavelet analysis method is used to eliminate noise and extract the cycle from the parameter sequence in the frequency domain. Then, with the time series decomposition method in the time domain, the trend item and random item are generated. Thus the gray model(GM) and the autoregressive moving average model(ARMA) are used to predict these items respectively according to their characteristics. Finally, all the prediction parts are combined and the final predictive value is got. The contrast experimental prediction and analysis of satellite remote sensing data verify the effectiveness of the proposed method.

Keywords Satellite parameters, Time series, Prediction, Wavelet analysis, Grey model

1 引言

近年来我国航天事业蓬勃发展,在轨运行的卫星数量也逐年增多。卫星的控制精度高、工作模式多、复杂度高等特点给地面的在轨管理工作带来了极大挑战。对于在轨运行的卫星,地面监视系统通常根据其下传的遥测参数值对其运行情况进行判断,如门限值比对、状态字监视等。而随着新技术、新材料的应用,卫星突发性的失效已不是其主要失效模式,大多数失效是由其部件性能的退化造成的。从卫星运行的实际情况来看,卫星各器件的老化有一个逐渐衰退的过程,该过程在短期内难以通过监视卫星遥测参数的变化捕获,但可以通过对应参数值的长期变化趋势反映。因此,若能获得卫星参数中的缓慢变化特点并对其趋势进行分析预测,便能提高卫星参数值预测精度,进而实现对卫星健康状态的有效管理。

当前,国内外对不同环境中的电子机械设备的趋势分析及参数预测展开了较深入的研究^[1-3],但受实验条件和成本的限制,对卫星这类复杂环境中的参数预测研究非常有限。文

献[4]研究了卫星锂离子电池的性能参数预测和剩余寿命预测方法。文献[5]针对 GPS 卫星特点,使用了灰色模型对卫星钟差进行预报。邓聚龙^[6]提出的灰色模型 GM(1,1)具有计算量小、精准度高的特点,其因对样本的要求较低,现已经广泛应用于生命科学^[7]、环境科学、航空^[8]等领域。文献[9]将电池阵功率输出系统看成灰色系统,提出了一种新息灰模型用于预测卫星参数。然而,影响卫星参数值的空间因素繁多,如太阳电磁辐射、中性大气、等离子体、地球磁场、运行轨道、光照等,这些空间不确定因素或周期性因素与卫星材料和元器件相互作用产生效应,造成部分遥测参数值(如温度、功率等)呈周期性的波动,给 GM(1,1)这类适用于单一指数增长的方法带来了困难。因此,在研究卫星周期性参数的预测时,需首先考虑不确定因素和周期性因素对预测方法的影响。目前,针对卫星周期性参数的预测,我们还未看到相关研究,遇到此类问题常用的处理方法是选用非线性拟合能力较好的神经网络、ARMA 等模型进行优化^[10,11]。近年,离散小波变换(Discrete Wavelet Transform, DWT)的研究和应用逐渐深入。使用小波分析不仅能准确找出时间序列的周期,还可以

到稿日期:2014-12-20 返修日期:2015-05-16 本文受国家自然科学基金-民航联合基金(U1433116),航空科学基金(20145752033)资助。

周 枫(1988-),男,硕士生,主要研究方向为数据挖掘、大数据处理,E-mail:zhoufeng_nuaa@163.com;皮德常(1971-),男,博士,教授,博士生导师,CCF 会员,主要研究方向为数据挖掘、大数据管理与分析。

有效剔除噪声^[12],为周期性参数的预测和分析提供了一种新的途径。

为克服卫星周期性参数预测的困难,本文根据此类参数的特点,提出了一种基于时间序列分解的周期性参数的预测方法。该方法在使用小波分析方法降噪并提取周期后,通过时间序列分解的方法,进一步分离出参数的趋势、随机因素,并根据各自的特点分别预测,最终通过叠加得到参数的预测值。实验表明,该方法能够结合不同方法的优势,具有较高的预测精度。

2 相关概念

2.1 时间序列分解

根据时间序列相关理论,可将时间序列数据分解为几个相互正交的不可测因素,即趋势因素 T 、季节(周期)因素 S 、不规则(随机)因素 I 和循环因素 C 。其中,季节因素有较为明确的周期,而循环因素的周期相对较长且规律性弱,因此在短期研究中通常将其忽略。分解模型包含加法、乘法等类型,以加法模型为例,可将原序列表示为 $Y=T+S+I$,并按如下步骤逐步分解:

- (1) 运用居中移动平均法提取出趋势项 T 。
- (2) 剔除趋势项 $S+I=Y-T$,再根据周期大小将各周期内同频率下的值平均化,得到周期项 S 。
- (3) 根据 $I=Y-S-T$ 计算出随机项 I 。

2.2 GM(1,1)

GM(1,1)模型是一阶方程一个变量的灰色预测模型。通过对原序列累加,得到规律性较强的序列后进行建模,将模型得到的数据进行累减得到原始数据的预测值。

假设原始序列为

$$X^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)), n \geq 4 \quad (1)$$

为减少随机性,对原序列 1 次累加,得

$$X^{(1)} = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)), n \geq 4 \quad (2)$$

$$X^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), k=1, 2, \dots, n \quad (3)$$

建立 GM(1,1)模型为

$$\frac{dx^1(t)}{dt} + ax^1(t) = b \quad (4)$$

其中, $[a, b]^T$ 为模型参数:

$$[a, b]^T = (B^T B)^{-1} B^T Y \quad (5)$$

其中

$$B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \dots & \dots \\ -z^{(1)}(n) & 1 \end{bmatrix}, Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} \quad (6)$$

根据式(4)、式(5), $x^{(1)}(k)$ 在 k 时刻的时间响应式为

$$\hat{x}^{(1)}(k+1) = [x^{(0)}(1) - \frac{b}{a}]e^{-ak} + \frac{b}{a} \quad (7)$$

使用 1 次累减生成(1-IAGO),得到原始数据 $k+1$ 时刻的预测值:

$$\hat{x}^{(0)}(k+1) = [x^{(0)}(1) - \frac{b}{a}]e^{-ak}(1-e^a) \quad (8)$$

使用文献[13]的方法对模型进行评价,当模型精度不够理想时,可以对其残差建立残差 GM(1,1)模型,即对残差序

列进行一次类似于 GM(1,1)建模的处理,以修正预报模型。

2.3 ARMA 模型

时间序列 Y 在 t 时刻的值与其前 p 期的值和前 q 期状态的误差有关,则可以用自回归滑动平均模型即 ARMA 模型表示:

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (9)$$

式中, $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ 为自变量,其本质是同一变量在不同的时刻的值, e_t 是随机偏差, $e_{t-1}, e_{t-2}, \dots, e_{t-q}$ 分别为前期各步的预测误差,而 θ 为滑动系数。由于该模型同时包含了 p 期 Y 的历史数据、 q 期预测值与实际观察值的误差,因此该模型也表示为 ARMA(p, q)。

3 算法框架

卫星周期性参数的预测主要分为 5 步,框架如图 1 所示。




图 1 周期性参数的趋势分析及预测框架

步骤 1: 使用小波对卫星周期性参数进行降噪处理,并使用小波方差在频域上对序列进行周期分析。

步骤 2: 根据步骤 1 的计算结果,使用时间序列的分解方法对降噪序列进行分解,依次得到趋势项、周期项、随机项。

步骤 3: 对步骤 2 所得的趋势项,使用 GM(1,1)方法进行预测。若模型精度较小,则进一步使用残差修正的 GM(1,1)方法进行预测,得到精度高的预测模型。

步骤 4: 对步骤 2 所得的随机项,使用 ARMA 模型建模,对随机部分进行预测,得到预测精度高的随机项预测值。

步骤 5: 组合步骤 3、步骤 4 所得模型的预测值及对应的周期项,得到参数最终的预测值(加法模型的组合即对各项求和)。

上述步骤中,步骤 1 主要用于降低数据中因地面检测系统解码错误、内存刷新不及时以及复杂空间环境等因素导致的噪声,其原理是按需将噪声信号在某一尺度下经小波变换分解到不同的频带内,再将噪声所处频带置零(或直接提取有用信号所在的频带),进行小波重构,从而达到降噪的目的。小波方差可以更准确地诊断出多长周期的振动最强,从分段的小波方差中还能推断某一时段内多长周期的振动最突出,进而提取目标序列的周期。提取的周期作为步骤 2 时间序列分解的输入。考虑到本文选用的卫星周期性遥测参数振幅变化较小,步骤 2 选用了加法模型对降噪后的序列进行分解。

经时间序列分解模型分解得到的趋势项 T 通常具有平缓且单调的特点,如卫星长期在辐射环境中引起的性能逐渐退化。GM(1,1)模型对单调变化的序列具有较优的预测精度,步骤3对其建立 GM(1,1)模型并进行进一步预测。分解所得的随机项具有明显的平稳特征,ARMA 模型能够很好地应用于此类序列的预测问题并获得较优的精度。

对于复杂的卫星周期性参数序列,通常很难使用单一的模型进行预测,而不同的预测模型又适用于不同特点的时间序列。上述框架则根据此类序列的特点,将复杂的序列分解,分别建模预测,然后再组合,即把复杂的问题化解为简单的问题“分而治之”,较好地解决了此类复杂序列的预测问题。

4 实验

4.1 实验数据及环境

实验数据选自我国某卫星 2007 年 6 月 10 日至 2013 年 5 月 15 日 6 年的遥测数据,选择了受光照因素影响较强的太阳帆板功率参数(记为 PW)进行实验,取该参数每日固定时间点样本组成实验样本。算法使用 Matlab 语言实现,实验 PC 机的处理器为 Intel(R) Core(TM) i5-3210M、内存 4GB、硬盘 320GB、操作系统 Windows 7。根据本文所提方法步骤,具体实验过程如下。

4.2 小波降噪及周期提取

为降低原始数据中的噪声,首先利用小波分析的方法对太阳帆板功率 PW 数据进行了降噪处理(本实验采用 Demy 小波),并计算了不同频率下的小波方差,实验结果如图 2、图 3 所示。




图 2 小波降噪




图 3 周期提取

图 2 给出了经 Demy 小波不同层数分解重构的降噪后的部分结果。从图中不难看出,分解层数为 1 时数据几乎保留了所有的特征,但局部噪声明显,效果并不理想;而层数为 3 时序列虽然变得平滑有规律,但第 250 天附近的波形特征也出现了严重的丢失现象。由此,选择层数为 2 的降噪序列。

从图 3 不同频率的小波方差可看出,时间序列在频率为 365 时震动最强,即该参数序列有明显的年周期。该结果与卫星真实情况完全一致,因此使用该结果作为时间序列分解模型的输入。

4.3 时间序列分解

由 3.2 节所得的周期大小,根据时间序列分解的步骤,依次计算得到原始时间序列的趋势项 T 、周期项 S 、随机项 I 。其结果如图 4 所示。




图 4 时间序列加法模型的分解结果

图 4 直观显示了降噪序列及其分解后的 3 个部分。从图中不难发现,趋势项具有平缓且单调的特点,而随机项 I 具有平稳特征。此外,参数 PW 遥测值虽然在 6 年间受光照等因素影响呈现周期性波动,但其整体趋势是缓慢下降的,一定程度上反映了相应部件的性能退化,因此可进一步考虑对其进行性能退化分析。

4.4 参数预测

根据上述趋势项及随机项特点,按算法框架使用 GM(1,1) 和 ARMA 模型分别预测分析,最后叠加对应周期项,获得原始序列预测值。其中,当 GM(1,1) 模型精度较低时,可进一步使用残差修正的 GM(1,1) 模型进行预测,以提高算法适应性。实验使用趋势项 T 前 80% 的数据分别以 GM(1,1)、一次残差 GM(1,1)、二次残差 GM(1,1) 建模,根据文献[13]计算得到模型的评价,如表 1 所列。

表 1 趋势项 GM(1,1)模型评价

模型	p	c	评价
GM(1,1)	1.0000	0.1011	好
一次残差 GM(1,1)	0.282	1.1323	不适合
二次残差 GM(1,1)	0.0404	13.5176	不适合

表 1 中的 GM(1,1) 模型比残差模型更适合该参数的预测。这是由于参数 PW 分解出的趋势项单调特征明显且无扰动数据。因此,此处选用 GM(1,1) 模型对趋势项预测即可。同样选取随机项 I 前 80% 的数据,使用文献[14]的方法定阶,对其建立相应的 ARMA 模型并预测。

为验证所提方法的有效性,将上述实验的预测值与 4 种常见的预测方法进行比较分析,即 ARIMA (Autoregressive Integrated Moving Average Model)^[15]、残差修正 GM(1,1)、季节线性 ARMA^[14]、小波神经网络^[10]方法。选用平均相对误差(MRPE)、均方根误差(RMSE)和平均绝对百分比误差(MAPE)这 3 种常用指标对预测结果进行评价。进行连续 10 步预测,预测误差比较如表 2 所列。

表2 不同方法的预测误差比较

	本文方法	ARIMA (2,1,1)	残差修正 GM(1,1)	季节线性 ARMA	小波神经网络
MRPE($e-05$)	3.37	9.58	47.20	55.21	15.70
RMSE	0.146	4.829	19.359	21.203	0.585
MAPE($e-05$)(%)	6.74	19.12	93.86	109.76	31.41

从表2可知,对于卫星周期性参数,本文所提的组合方法比其他的预测模型精度更高。特别是,所提方法在预测卫星周期性参数时优于非线性拟合能力较好的小波神经网络方法。

图5直观显示了其中3种精度较高方法的连续10步预测结果。




图5 本文方法与ARIMA、小波神经网络的比较

从图5看出,随着步长增加,ARIMA模型的预测值偏离程度明显变大,特别是在拐点(Day=4)后尤为明显。小波和神经网络的组合模型以及本文方法偏离程度变化较小,而本文方法的预测结果更接近真实值,由此证明了所提方法的有效性。

结束语 本文针对受环境影响较大的周期性卫星遥测参数,提出了一种基于时间序列分解的参数预测方法。该方法根据此类参数的特点,在频域上使用小波进行降噪和周期提取,在时域上通过时间序列分解分离出趋势项、周期项和随机项,按各序列特点对趋势项建立GM(1,1)模型预测,对随机项建立ARMA模型预测,最后叠加得到参数的最终预测值。通过卫星数据实验分析,验证了本文方法的有效性。该方法不仅提高了卫星周期性参数的预测精度,其分解所得趋势项也为卫星性能退化趋势分析提供了新的思路,因而对卫星健康管理有着重要的实际意义。

鉴于卫星遥测数据的复杂性,还可以从如下方面进一步研究:

(1)当参数中存在多个不同频率的周期时,如何依次有效提取周期。

(2)实验经分解得到的随机项在第1250至1500天(见图4)之间出现明显波动,可进一步考虑将其用于卫星的故障检测。

参考文献

- [1] Lee J. Measurement of machine performance degradation using a neural network model[J]. Computers in Industry, 1996, 30(3): 193-209
- [2] Huang R, Xi L, Li X, et al. Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods[J]. Mechanical Systems and Signal Processing, 2007, 21(1): 193-207
- [3] Talbot D, Li S, Kahraman A. Prediction of Mechanical Power Loss of Planet Gear Roller Bearings Under Combined Radial and Moment Loading[J]. Journal of Mechanical Design, 2013, 135(12): 1-11
- [4] Liu D, Wang H, Peng Y, et al. Satellite lithium-ion battery remaining cycle life prediction with novel indirect health indicator extraction[J]. Energies, 2013, 6(8): 3654-3668
- [5] Zheng Zuo-ya, Chen Yong-qi, Lu Xiu-shan. An Improved Grey Model for the Prediction of Real-Time GPS Satellite Clock Bias [J]. Acta Astronomica Sinica, 2008, 49(3): 306-320 (in Chinese) 郑作亚, 陈永奇, 卢秀山. 灰色模型修正及其在实时GPS卫星钟差预报中的应用研究[J]. 天文学报, 2008, 49(3): 306-320
- [6] Deng J L. Introduction to Grey Mathematical Resource Science [M]. Wuhan: Huazhong University of Science & Technology Press, 2010 (in Chinese) 邓聚龙. 灰色数理资源科学导论[M]. 武汉: 华中科技大学出版社, 2010
- [7] Wang Q. A new model based on grey theory and neural network algorithm for evaluation of AIDS clinical trial[J]. Advances in Computational Mathematics and its Applications, 2013, 2(3): 292-297
- [8] Cui Jian-guo, Fu Kang-yi, Chen Xi-cheng, et al. Multiple Attribute Maintenance Decision Making of Aircraft Based on Grey-fuzziness and Analytical Hierarchy Process[J]. Acta Aeronautica Et Astronautica Sinica, 2014, 35(2): 478-486 (in Chinese) 崔建国, 傅康毅, 陈希成, 等. 基于灰色模糊与层次分析的多属性飞机维修决策方法[J]. 航空学报, 2014, 35(2): 478-486
- [9] Guo Xiao-hong, Xu Xiao-hui, Zhao Shu-qiang, et al. Satellite Telemetry Parameter Trend Forecast Algorithm Based on New Information and Applications [J]. Journal of astronautics, 2010 (8): 1939-1943 (in Chinese) 郭小红, 徐小辉, 赵树强, 等. 基于新息灰预测的卫星遥测参数状态预测及应用[J]. 宇航学报, 2010(8): 1939-1943
- [10] Wang Yu-pu, Lv Zhi-ping, Chen Zheng-sheng, et al. Research on the algorithm of wavelet neural network to predict satellite clock bias[J]. Acta Geodaetica et Cartographica Sinica, 2013, 42(3): 323-330 (in Chinese) 王子谱, 吕志平, 陈正生, 等. 卫星钟差预报的小波神经网络算法研究[J]. 测绘学报, 2013, 42(3): 323-330
- [11] Shen Bo-chang. Satellite attitude determination based on HRG and star sensor [D]. Harbin: Harbin Institute of Technology, 2010 (in Chinese) 沈博昌. 基于半球谐振陀螺仪与星敏感器的卫星姿态确定[D]. 哈尔滨: 哈尔滨工业大学, 2010
- [12] Wang Wei-hong, Cheng Shi-wei, Zhang Su-qiong, et al. Feature-preserving image denoising method combining F2dD and wavelet analysis[J]. Computer Science, 2013, 40(10): 265-268 (in Chinese) 王卫红, 程时伟, 张素琼, 等. EMD与小波分析结合的特征保持图像去噪方法[J]. 计算机科学, 2013, 40(10): 265-268
- [13] Tseng F M, Yu H C, Tzeng G H. Applied hybrid grey model to forecast seasonal time series[J]. Technological Forecasting and Social Change, 2001, 67(2): 291-302
- [14] Box G E P, Jenkins G M, Reinsel G C. Time series analysis: forecasting and control [M]. Beijing: Posts & Telecom Press, 2005 (in Chinese) 博克斯, 詹金斯, 赖因泽尔. 时间序列分析: 预测与控制[M]. 北京: 人民邮电出版社, 2005
- [15] Chen P, Pedersen T, Bak-Jensen B, et al. ARIMA-based time series model of stochastic wind power generation[J]. IEEE Transactions on Power Systems, 2010, 25(2): 667-676