

ARIMA-SVR 组合模型在卫星遥测 参数预测中的应用*

顾昕雨^{1,2} 肖志刚¹

1(中国科学院国家空间科学中心 北京 100190)

2(中国科学院大学 北京 100049)

摘要 为辅助卫星在轨运行提供决策分析支持,结合卫星遥测参数的时间序列特性,利用一种 ARIMA-SVR 组合预测方法,通过对卫星遥测参数进行预测,判定实际遥测数据是否处于正常范围。该组合模型利用 ARIMA 模型对预处理后的数据进行线性拟合,并利用 SVR 模型对数据的非线性部分进行补偿。以 KX09 卫星星敏 A 的温度遥测数据为基础,分别利用组合模型对短期及中期星敏 A 温度进行预测,得出短期和中期均方根误差(RMSE)分别为 0.768 和 0.968,相比单一 ARIMA 模型,短中期 RMSE 分别提高 46.2% 和 16.4%。此外,对该卫星陀螺 B 的 x 轴角速度进行了短中期预测:短期预测中,组合模型比单一 ARIMA 模型的 RMSE 提高 71.2%;中期预测中,组合模型比单一 ARIMA 模型的 RMSE 提高 64.2%。实验结果表明,ARIMA-SVR 组合模型为保证卫星在轨正常运行提供了有效的决策分析支持。

关键词 卫星正常运行,遥测参数预测,时间序列,ARIMA-SVR 组合模型

中图分类号 V474

Research on the Application of ARIMA-SVR Combination Model in Satellite Telemetry Parameter Prediction

GU Xinyu^{1,2} XIAO Zhigang¹

1(National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

2(University of Chinese Academy of Sciences, Beijing 100049)

Abstract In order to provide decision analysis support for assisting the in-orbit operation of satellite, combining with the time series characteristics of satellite telemetry parameters, an ARIMA-SVR combination prediction method is used to judge whether the actual telemetry data is in the normal range through the prediction of satellite telemetry parameters. In this model, ARIMA model is used to linearly

* 中国科学院科学卫星任务运控技术项目资助 (Y829141A9S)

2021-01-06 收到原稿, 2021-11-13 收到修定稿

E-mail: guxinyu_gab@163.com

fit the preprocessed data, and SVR model is used to compensate the nonlinear part of the data. Based on the telemetry data of temperature of star sensor A in KX09 satellite, the combination model was used to predict the short-term and medium-term temperature of star sensor A, and the Root Mean Square Error (RMSE) of the short-term and medium-term temperature of star sensor A was 0.768 and 0.968, respectively. Compared with the single ARIMA model, the RMSE of the short and medium-term temperature of star sensor A was 46.2% and 16.4% higher than that of the single ARIMA model respectively. In addition, the x -axis angular velocity of gyro B on the satellite is predicted in short and medium term. In the short term prediction, the RMSE of the combined model is increased by 71.2% compared with that of the single ARIMA model. In the medium prediction, the RMSE of the combination model is 64.2% higher than that of the single ARIMA model. Experimental results show that the ARIMA-SVR combination model provides effective decision analysis support for ensuring the healthy in-orbit operation of satellites.

Key words Satellite healthy operation, Telemetry parameter prediction, Time series, ARIMA-SVR combination model

0 引言

卫星在轨运行过程中,空间天气、温度、光照等外部因素均对其运行环境造成一定影响,导致卫星各部件性能随外部环境改变而发生一定变化。这些变化可能会使卫星在运行过程中出现故障,造成不可挽回的事故损失。卫星在轨运行过程中会生成大量遥测数据,这些数据能够直接、客观反映卫星各部件的工作状态,是预测及处理卫星故障的重要基础^[1]。为了提高卫星在轨运行的安全性,降低卫星运行中存在的风险,研究者提出了不同的方法,预测飞行器遥测数据的变化趋势,并通过真实数据与预测数据趋势的对比,及时发现数据异常。

卫星遥测数据会随着时间变化,因此一定程度上可以视为时间序列。结合中国科学院先导专项卫星的实际遥测数据,可将遥测参数大致分为三类:第一类是平稳性遥测参数,随时间变化缓慢;第二类是突变型遥测参数,随时间呈跳跃性变化;第三类是周期性遥测参数,随时间呈周期性变化^[2]。针对不同环境的数据预测有研究提出了不同的方法。Zhang 等^[3]通过人工神经网络(ANN)对非线性时间序列数据进行预测,验证了神经网络对非线性时间序列数据的处理优势;在神经网络基础上,有研究提出了优化算法与神经网络相结合的组合模型,例如 Donate 等^[4]提出了遗传算法与神经网络相结合的模式,并通过实验

证明了该模型在时间序列预测中具有一定优势;Zhu 等^[5]将 LSTM 用于卫星轨道预报,证明 LSTM 在遥测时序数据处理方面有一定作用;Ren 等^[6]通过马特拉小波变换算法对卫星太阳翼输出功率进行短期预测,提高了对具有非平稳及周期性数据特性的遥测数据的预测精度。

除此之外,在卫星遥测数据预测领域,常用的预测算法还有自回归移动平均模型(ARMA)。Yu^[2]验证了 ARMA 的适用性。ARMA 模型的验证表明其更适用于平稳数据的预测,但是卫星遥测数据具有非线性、周期性、不平稳等特点,单一的 ARMA 模型不能精确预测卫星遥测数据。针对时间序列数据不平稳的特点,ARIMA 模型可以对其差分使得时间序列变为平稳序列,但是对于时间序列存在的非线性特征不能充分处理。SVM 模型作为机器学习中的常用模型,在预测研究中具有良好的泛化性能,SVM 用于回归问题时即为 SVR。Liu 等^[7]利用 SVR 对光伏发电功率进行残差修正,提高了预测精度。

基于卫星遥测数据的特点,本文将 ARIMA 预测模型与 SVR 预测模型相结合,利用 ARIMA-SVR 组合模型对卫星时序遥测数据进行短期及中期预测,通过与单一 ARIMA 模型的预测结果进行比对,验证组合模型在时序遥测数据预测中的适用性,为卫星正常在轨运行管理提供决策分析技术支持。

1 研究方法

1.1 ARIMA 模型

ARIMA 模型全称为自回归积分滑动平均模型 (Autoregressive Integrated Moving Average Model)。ARIMA 模型的基本思想是, 利用时间序列自身的滞后序列和随机扰动项及其滞后序列, 描述时间序列发展规律^[8]。ARIMA(p, d, q) 包括移动平均过程 (MA)、自回归过程 (AR)、自回归移动平均过程 (ARMA) 和自回归滑动平均混合过程 (ARIMA)。该模型的一般形式为

$$y_t = \mu + \sum_{i=1}^p \gamma_i y_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t. \quad (1)$$

其中: μ 为常数系数; p 为自回归阶数; q 为移动平均阶数; ϵ_t 为随机误差, 通常是白噪声序列, 且符合正态分布; γ_i 和 θ_i 为待求参数。对于非平稳序列, 先对其进行 d 阶差分获得平稳序列, 再进行建模。

1.2 SVR 模型

支持向量机 (SVM) 是基于统计学 VC 维理论和结构风险最小化理论建立的机器学习算法^[9]。当 SVM 应用于回归问题时即为支持向量回归 (SVR), 给定非线性数据集 $\{x_i, y_i\}$, 其中 x_i 为样本输入, y_i 为样本输出, 将样本从低维空间直接映射到更高维的特征空间, $\varphi(x_i)$ 表示 x_i 映射后的特征向量^[10]。超平面公式如下:

$$f(x_i) = \omega^T \varphi(x_i) + b. \quad (2)$$

其中 ω, b 均为待定参数。传统模型中认为 $f(x_i)$ 与 y_i 完全重合时才是最佳模型, 此时损失计为零。但 SVR 模型允许 $f(x_i)$ 与 y_i 之间最多有 e 的偏差, 即当 $f(x_i)$ 与 y_i 之间差的绝对值大于 $2e$ 时才计入损失, 即训练样本落入以 $f(x_i)$ 为中心的 $2e$ 宽度带内时则认为训练正确^[11]。训练 SVR 的过程实际就是寻找最优的 ω 和 b 使 $f(x_i)$ 逼近 y_i ^[10]。此时 ω 和 b 的求解可以视为一个凸二次规划问题, 即

$$\begin{aligned} \min_{\omega, b, \xi_i, \hat{\xi}_i} & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\xi_i + \hat{\xi}_i); \\ \text{s.t. } & f(x_i) - y_i \leq \varepsilon + \xi_i; \\ & y_i - f(x_i) \leq \varepsilon + \hat{\xi}_i; \\ & \xi_i \geq 0, \quad \hat{\xi}_i \geq 0, \quad i = 1, 2, \dots, m. \end{aligned} \quad (3)$$

其中, ξ_i 和 $\hat{\xi}_i$ 为松弛变量, ε 为 $f(x_i)$ 与 y_i 之间的偏差,

C 为正则化常数。 ω 可表示为

$$\omega = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \varphi(x_i). \quad (4)$$

则所求 SVR 的回归模型为

$$f(x) = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) k(x, x_i) + b. \quad (5)$$

其中 $k(x, x_i)$ 为核函数。

2 基于 ARIMA-SVR 组合模型的预测方法

卫星遥测数据是连续变化的时间序列, ARIMA 模型可以较好地体现时间序列中的线性特质。由于运行环境等因素的影响, 时序遥测数据体现出一定的非线性特征, 而 SVR 方法适用于非线性特征的映射。因此本文利用 ARIMA-SVR 组合模型对时序遥测数据进行预测, 具体流程如图 1 所示。

ARIMA-SVR 组合模型的预测首先对数据进行预处理, 处理后的训练集作为 ARIMA 模型的输入, ARIMA 建模预测获得初始预测结果, 原始数据与




图 1 基于 ARIMA-SVR 组合模型的卫星遥测数据预测建模流程

Fig. 1 Modeling process of satellite telemetry data prediction based on ARIMA-SVR combination model

ARIMA 预测值的残差作为 SVR 模型的输入, 再将 SVR 预测的残差值与 ARIMA 预测初始值相加得到最终预测结果。具体过程如下。

(1)数据预处理。卫星在轨运行中产生的遥测数据可能因为环境影响、部件故障等因素出现缺失和异常值, 会对预测产生不良影响。数据预处理主要作用是对异常值和缺失值进行修正和填补。将偏差大于三倍标准差的值判断为异常值, 筛选出异常值和缺失值后, 将异常值视为缺失值, 缺失值利用均值填补。

(2)ARIMA 建模。首先对输入的时间序列进行平稳性判断, 如果该数据为平稳性数据, 则继续后续步骤; 如果不平稳, 则对数据进行 d 阶差分直至平稳。绘制平稳数据的自相关图(ACF)和偏自相关图(PACF)判断截尾拖尾, 得到参数 p 和 q , 以 BIC 值为判断标准确定最佳参数, BIC 值越小, 模型表现越好。利用定阶后的 ARIMA 模型预测训练集数据, 得到预测结果 $\hat{y}_i'$, 计算残差

$$e_i = y_i - \hat{y}_i'. \quad (6)$$

(3)SVR 残差预测。对于非线性模型, 利用核函数映射到特征空间, 然后进行回归。利用符号 S 表示 SVR 模式的确定语句量, 有

$$S = \text{SVR}(K, C, \gamma). \quad (7)$$

其中: K 表示核函数类型, 常用的核函数有线性核函数、径向基(高斯)核函数、多项式核函数; C 为惩罚因子; γ 为核函数的核系数, 其值必须大于 0。利用 PSO 寻优核函数参数, 训练模型后获得残差预测值 $\hat{e}_i$ 。

(4)将 ARIMA 预测结果与 SVR 残差预测结果结合, 相加得到最终预测结果, 即

$$\hat{y}_i = \hat{y}_i' + \hat{e}_i. \quad (8)$$

模型预测效果的评价是整个模型预测的最后一步, 通过评价标准判断模型优劣, 从而得知该模型在本次预测中的适用性。模型预测误差越小, 说明该模型的预测精度越高。常用的模型评价标准有多种, 本文采用均方根误差(RMSE, 定义符号 E_{RMS})评价模型的预测效果。

RMSE 是预测值与真实值之间偏差的平方和与次数比值的平方根^[12], RMSE 值越小, 效果越好。其计算公式为

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}. \quad (9)$$

其中, y_i 为真实值, $\hat{y}_i$ 为预测值。

3 实验验证

3.1 实验数据选取

卫星的星敏感器是卫星姿态控制系统的重要部件之一, 星敏感器的温度变化会对卫星遥测数据产生影响, 因此这里选择中国科学院先导专项 KX09 卫星的星敏 A 温度作为实验数据, 分别进行短期和中期预测实验。目前通常要求卫星的监视预测需求为: 短期预测时间为圈次级(每圈次 90 min 左右, 经历一次阳照区阴影区), 一般为 1~16 个圈次(1.5~10 h); 中期预测时间为天级(一般为 1~7 天, 每天约 16 个圈次)。选取 2020 年 9 月 20 日 21:51 LT 至 2020 年 9 月 21 日 04:43 LT 连续 100 条星敏 A 温度数据, 共计 6 h 进行短期预测。卫星飞行一圈的时间约为 90 min, 样本数据的选取大约为卫星飞行 4 圈的时间。按照 4:1 比例划分训练集与测试集, 对数据进行预处理后绘出数据变化趋势, 短期数据时序如图 2 所示。

3.2 ARIMA 建模

如图 2 所示, 星敏 A 为时间序列, 对短期星敏 A 的温度数据进行平稳性检测, 可以看出该部分温度时序基本稳定, 不需要差分。在判定温度数据时序稳定后, 首先给出自相关和偏相关结果(见图 3)。

图 3 中蓝色部分为置信区间, 纵坐标分别为自相关及偏自相关系数。依据图 3 中信息, 初定模型为 ARIMA(0, 0, 5)、ARIMA(2, 0, 0) 以及 ARIMA(2, 0,




图 2 2020 年 9 月 20 日 21:53 LT 至 2020 年 9 月 21 日 04:43 LT KX09 星敏 A 温度变化

Fig. 2 Temperature change of KX09 star sensor A from 20 September 2020 21:53 LT to 21 September 2020 04:43 LT

5)。基于 BIC 准则, 选定 BIC 值最小的 ARIMA(2, 0, 5) 为最佳模型。使用 ARIMA(2, 0, 5) 模型的初步预测结果如图 4 所示。

3.3 SVR 建模

3.3.1 SVR 核函数选择

对所选数据选择不同核函数, 三种核函数的拟合效果如图 5 所示。由图 5 可以看出, 径向基核函数(RBF)的拟合效果表现最好。为了验证观测结果的正确性, 利用 RMSE 判别标准对三种核函数的拟合效果进行评价, 结果列于表 1。

由表 1 可以看出, 径向基核函数(RBF)的 RMSE 值最小, 说明径向基核函数(RBF)在回归模型中的表现最好, 在接下来的预测中, SVR 核函数的选择即为




图 3 星敏 A 温度短期数据的自相关与偏相关结果
Fig. 3 Autocorrelation function and partial autocorrelation function of short-term temperature data of the star sensor A




图 4 2020 年 9 月 20—21 日 ARIMA 模型预测结果
Fig. 4 Results of ARIMA model prediction on 20—21 September 2020

径向基核函数(RBF)。

3.3.2 核函数参数选择

径向基核函数中有两个参数 C 和 γ 。其中 C 为惩罚系数, γ 为核函数的核系数, 且 γ 值必须大于 0。将原始数据与 ARIMA 模型拟合数据作差, 获取残差序列, 将残差序列输入 PSO 模型参数寻优, PSO 算法的参数设置见表 2。寻优后的适应度函数如图 6 所示, 其中寻优后的 $C=7.14$, $\gamma=0.17$ 。

将原始数据与 ARIMA 初始预测数据的残差代入 SVR 预测模型, SVR 参数 $C=7.14$, $\gamma=0.17$, 残差




图 5 2020 年 9 月 20 日三种 SVR 核函数拟合效果
Fig. 5 Fitting effect of three SVR kernel functions on 20 September 2020

表 1 三种核函数的 RMSE 值对比
Table 1 Comparison of RMSE of three kernel functions

核函数	RMSE
RBF	0.936
Linear	1.532
Poly	1.533

表 2 PSO 算法参数设置
Table 2 Parameter setting of PSO algorithm

参数名称	数值
粒子数量	100
粒子维度	2
最大迭代次数	500
局部学习因子	2
全局学习因子	2
惯性因子	0.8
参数最大值	15
参数最小值	0.001




图 6 短期温度序列的 PSO 适应度函数曲线
Fig. 6 PSO fitness function curve of short-term temperature series




图 7 2020 年 9 月 20—21 日 SVR 模型残差预测结果
Fig. 7 Results of SVR model residual prediction on 20—21 September 2020

预测结果如图 7 所示。

将 SVR 预测结果与 ARIMA 预测结果相加, 最终预测结果如图 8 所示, 从预测趋势可以看出组合模型的拟合效果比单一 ARIMA 模型表现好。

3.4 预测结果及对比分析

本文还选取 KX09 卫星 2020 年 9 月 20 日至 9 月 30 日共计 10 天的星敏 A 温度数据, 利用同样方法进行中期预测。组合模型与单一 ARIMA 模型短中期预测的 RMSE 结果比较列于表 3。可以看出: 短期预测中, 组合模型比单一 ARIMA 模型的 RMSE 提高了 46.2%; 中期预测中, 组合模型比单一 ARIMA 模型的 RMSE 提高了 16.4%。由 RMSE 值可以看出, 组合模型更适用于短期预测。

由于温度数据为平稳数据, 为了验证组合算法的适用性, 这里还利用卫星姿控系统中陀螺 B 的 x 轴角速度数据进行短中期预测。姿态控制系统是卫星姿




图 8 2020 年 9 月 20—21 日 ARIMA-SVR 组合模型预测结果

Fig. 8 Results of ARIMA-SVR combinational model prediction on 20—21 September 2020

表 3 温度预测结果 RMSE 统计
Table 3 RMSE statistics of prediction results of temperature

模型	RMSE	
	短期	中期
ARIMA	1.428	1.159
ARIMA-SVR	0.768	0.968

态控制的重要部件, x 、 y 、 z 轴的角速度与姿态控制密切相关。选择 2021 年 1 月 18 日 05:38 LT 至 2021 年 1 月 18 日 07:08 LT 卫星飞行一圈 (90 min) 共计 450 条数据进行角速度短期预测; 选取 2021 年 1 月 17 日至 2021 年 1 月 20 日 (3 天) 共计 10537 万条陀螺 B 的 x 轴角速度数据进行中期预测。短期角速度时序如图 9 所示。

短期角速度序列经检验后确定为不平稳序列, 需要对其做一阶差分后进行预测。依据温度预测步骤得出短中期预测结果, 短中期预测的组合模型与单一 ARIMA 模型预测的 RMSE 结果比较列于表 4。可以看出: 短期预测中, 组合模型比单一 ARIMA 模型的 RMSE 提高了 71.2%; 中期预测中, 组合模型比单一 ARIMA 模型的 RMSE 提高了 64.2%。由 RMSE 值可以看出, 组合模型更适用于短期预测。

4 结语

ARIMA 模型对不平稳时间序列的预测效果较好, 但对于时间序列存在的非线性特征不能充分处


图9 陀螺B的 x 轴角速度短期时序Fig. 9 Short-term timing diagram of x -axis angular velocity of Gyro B

表4 角速度预测结果 RMSE 统计

Table 4 RMSE statistics of prediction results of angular velocity

模型	RMSE	
	短期	中期
ARIMA	2.708	3.181
ARIMA-SVR	0.779	1.138

理,因此利用 SVR 模型补偿卫星遥测数据中的非线性特征,可以获得一种有效的非线性时间序列组合预测方法。本文利用 ARIMA-SVR 组合模型对 KX09 卫星的星敏 A 温度以及陀螺 B 的 x 轴角速度进行了短期和中期预测。在星敏 A 温度的短期预测中,组合模型比单一 ARIMA 模型的 RMSE 提高了 46.2%;中期预测中,组合模型比单一 ARIMA 模型的 RMSE 提高了 16.4%。在陀螺 B 的 x 轴角速度短期预测中,组合模型比单一 ARIMA 模型的 RMSE 提高了 71.2%;中期预测中,组合模型比单一 ARIMA 模型的 RMSE 提高了 64.2%。实验证明该模型在卫星遥测数据的预测中具有实际应用价值,可用于卫星遥测数据趋势的预测,未来对卫星遥测数据预测进行研究时,可利用出现异常的数据,对异常数据进行预测,观察预测结果,分析异常的出现是否存在规律性。

参考文献

- [1] REN Guoheng. Correlation Analysis and Research on the Telemetry Data of Synchronous Satellites[D]. Xi'an: Xi'an Technological University, 2011 (任国恒. 同步卫星遥测数据相关性分析与研究[D]. 西安: 西安工业大学, 2011)
- [2] YU Wenyan. Application and Research of Machine Learning in Payload PHM System[D]. Beijing: University of

Chinese Academy of Sciences (National Space Science Center, the Chinese Academy of Sciences), 2018 (余文艳. 机器学习在有效载荷PHM系统中的应用研究[D]. 北京: 中国科学院大学(中国科学院国家空间科学中心), 2018)

- [3] ZHANG G P, PATUWO B E, HU M Y. A simulation study of artificial neural networks for nonlinear time-series forecasting[J]. *Computers & Operations Research*, 2001, **28**(4): 381-396
- [4] DONATE J P, LI X D, SÁNCHEZ G G, *et al.* Time series forecasting by evolving artificial neural networks with genetic algorithms, differential evolution and estimation of distribution algorithm[J]. *Neural Computing and Applications*, 2013, **22**(1): 11-20
- [5] ZHU Junpeng, ZHAO Hongli, DU Xin, *et al.* Application of long short-term memory neural network to orbit prediction of satellite[J]. *Journal of Ordnance Equipment Engineering*, 2017, **38**(10): 127-132 (朱俊鹏, 赵洪利, 杜鑫, 等. 长短时记忆神经网络在卫星轨道预报中的研究[J]. *兵器装备工程学报*, 2017, **38**(10): 127-132)
- [6] REN Guoheng, ZHU Bian, ZHU Hai. Application of Mal-lat algorithm in short-term forecasting of telemetry data[J]. *Journal of Wuhan Institute of Technology*, 2014, **36**(2): 73-78 (任国恒, 朱变, 朱海. 马特拉算法在遥测数据短期预测中的应用[J]. *武汉工程大学学报*, 2014, **36**(2): 73-78)
- [7] LIU Jiaqing, ZHANG Hongpeng, GUO Xihai, *et al.* Prediction model of photovoltaic power generation based on SVR residual correction[J]. *Electric Power Engineering Technology*, 2020, **39**(5): 146-151 (刘家庆, 张弘鹏, 郭希海, 等. 基于SVR残差修正的光伏发电功率预测模型[J]. *电力工程技术*, 2020, **39**(5): 146-151)
- [8] HUANG Hongmei. Applied Time Series Analysis[M]. Beijing: Tsinghua University Press, 2016 (黄红梅. 应用时间序列分析[M]. 北京: 清华大学出版社, 2016)
- [9] ZHANG Sen, SHI Weiren, SHI Xin, *et al.* Water quality prediction based on partial least squares and Support Vector Machine[J]. *Computer Engineering and Applications*, 2015, **51**(15): 249-254 (张森, 石为人, 石欣, 等. 基于偏最小二乘回归和SVM的水质预测[J]. *计算机工程与应用*, 2015, **51**(15): 249-254)
- [10] LUO Xueke, HE Yunxiao, LIU Peng, *et al.* Water quality prediction using an ARIMA-SVR hybrid model[J]. *Journal of Yangtze River Scientific Research Institute*, 2020, **37**(10): 21-27
- [11] ZHOU Zhihua. Machine Learning[M]. Beijing: Tsinghua University Press, 2016 (周志华. 机器学习[M]. 北京: 清华大学出版社, 2016)
- [12] XIANG Chao. Prediction and Research of Steam Coal Price Based on ARIMA and SVR Model[D]. Beijing: University of International Business and Economics, 2019 (向超. 基于ARIMA-SVR组合模型的动力煤价格预测与实证研究[D]. 北京: 对外经济贸易大学, 2019)

(责任编辑: 宋雅娜)