

基于 FIG-SVR 的姿控发动机推力校准斜率预测

陈文丽, 马军强, 杨思锋, 田国华
(北京航天试验技术研究所 北京, 100074)

摘 要: 为了对某型号姿控发动机高空模拟试验推力现场校准斜率进行趋势预测, 提出了一种模糊信息粒化 (fuzzy information granulation, FIG) 和支持向量回归机 (support vector regression, SVR) 相结合的时间序列预测方法。借助模糊信息粒化方法将推力现场校准的斜率映射为包含区间最小值 Low、中值 R 和最大值 Up 3 个参数的模糊信息粒, 以降低样本的维数, 并以其为输入构建 SVR 回归模型。预测结果表明, 基于模糊信息粒化 SVR 确定的预测区间较好地反映了推力现场校准斜率的变化趋势。

关键词: 姿控火箭发动机试验; 推力校准斜率; FIG-SVR; 预测

中图分类号: V434-34 **文献标识码:** A **文章编号:** 1672-9374 (2015) 03-0103-05

Prediction on thrust calibration slope based on FIG-SVR for attitude control rocket engine

CHEN Wen-li, MA Jun-qiang, YANG Si-feng, TIAN Guo-hua
(Beijing Institute of Aerospace Testing Technology, Beijing 100074, China)

Abstract: In order to predict the trend of thrust calibration slope for attitude control engine space simulation test, a method of time series prediction based on fuzzy information granulation (FIG) and support vector regression (SVR) is proposed in this paper. With the method of FIG, the thrust calibration slope is mapped as fuzzy information granulations (including minimum value Low, medium value R and maximum value Up) to reduce the dimension of the samples. The extracted parameters mentioned above are applied to SVR for proceeding regressive modeling. The prediction result shows that this method based on FIG-SVR can effectively predict the trend of the thrust calibration slope.

Keywords: attitude control rocket engine test; thrust calibration slope; FIG-SVR; prediction

收稿日期: 2015-01-12; 修回日期: 2015-02-05

作者简介: 陈文丽 (1987—), 女, 硕士, 研究领域为液体火箭发动机试验测试技术

0 引言

在姿控发动机高空模拟试验中,推力是评价发动机性能的关键参数之一,该参数的稳态测量精度一般要求高于0.5%^[1-3]。为了测得高精度的推力值,需要试验前在现场对推力测量系统进行多回程反复校准,以分析各种影响因素。推力校准关注的焦点是推力校准的斜率,因为在发动机点火过程中,实测推力的电压量到工程物理量的换算与推力校准的斜率有关^[4]。因此,准确预测推力校准斜率的变化趋势,对了解推力测量系统状态以及分析试验台工艺系统对推力测量系统的影响具有重要意义。

推力校准斜率预测的精确度由推力测量系统所用数学模型的精确度来决定。由于推力测量系统结构复杂,包含推力架、传感器、工艺管路、发动机等,且各组成部件之间存在较大的非线性,很难从理论角度对影响因素进行量化,因此,建立准确的测量系统数学模型十分困难。

支持向量回归机(SVR)是由Vapnik等人提出的一种建立在统计学习理论和结构风险最小化原则基础上的机器学习方法。它利用了Mercer核、松弛向量等多项技术,具有所需样本小、结构简单、泛化能力强等多种优点,被广泛应用于回归预测中^[5-7]。但是,当样本规模较大时,SVR算法的泛化能力和精度就会大大下降。模糊信息粒化理论(Theory of Fuzzy Information Granulation, FIG)建立在模糊逻辑理论和信息粒化理论基础上,是一种处理海量信息的数据挖掘方法,现已成为人工智能领域的研究热点^[8-9]。基于以上因素,本文在分析历史推力校准斜率数据特点的基础上,探索FIG和SVR相结合的推力校准斜率时序预测方法,并用其对推力校准斜率的变化趋势进行研究。

1 基于FIG-SVR回归预测建模

1.1 模糊信息粒化算法模型

模糊信息粒化的概念最早是由Zadeh教授提出^[10]。模糊信息粒是以模糊集形式表示的信息粒,是针对对象的功能相近性、相似性和函数性等划

分的集合,其密集性或稀疏性完全取决于信息粒的边界定义。其算法的思想是通过模糊集的方法对时间序列进行模糊粒化,以降低问题求解的复杂度。过程包括2个步骤,即划分窗口步骤和模糊化步骤^[11]。划分窗口是将所给的数据序列分割成一个个的子数据集,每个子数据集作为一个操作窗口;模糊化是对每个划分窗口进行模糊处理,生成子模糊集。模糊信息粒化的核心就是对原始数据序列 X 进行窗口划分,在每个窗口子集上建立一个合理的模糊集,使其能够忽略掉一个数据区间上无关紧要的细节,同时又能够合理地代表原始数据。具体过程是:对于给定的数据序列 X 以及论域 G ,在其上建立一个模糊粒子 p ,使得

$$p=x \text{ is } G \quad (1)$$

其本质是确定一个函数 $p=A(x)$ 的过程。 $A(x)$ 描述变量 x 属于模糊论域 G 的隶属程度。常用的模糊粒子有三角形模糊粒子、高斯型模糊粒子和抛物线型模糊粒子。根据推力校准斜率数据的特点,本文选用三角形模糊粒子,其隶属函数 $A(x)$ 如式(2)所示。

$$A(x)=\begin{cases} 0 & x < a \\ \frac{x-a}{m-a} & a \leq x \leq m \\ \frac{b-x}{b-m} & m < x \leq b \\ 0 & x > b \end{cases} \quad (2)$$

式中: x 为输入的时间序列; a 、 m 和 b 为参数,对于单个模糊粒子而言, a 描述的是相应原始数据变化的最小值, m 描述的是相应原始数据变化的平均水平, b 描述的是相应原始数据变化的最大值。

1.2 支持向量回归预测算法模型

支持向量回归预测模型是基于统计学VC维理论和结构风险最小原理(SRM)的有监督学习算法,其特点是通过引入核函数,将原样本属性空间的非线性问题映射为高维特征空间的线性规划问题。其算法原理为^[11-12]:

给定数据样本 $\{x_i, y_i\}_{i=1}^k$, $x_i \in R^d$, $y_i \in R$,

SVR 通过引入不敏感损失函数 ξ 来简化回归问题, 因此该算法也称为 ξ -SVR。映射空间的线性模型估计函数为

$$y=f(x)=(\omega, \varphi(x))+b \quad \varphi: R^d \rightarrow G, \omega \in G \quad (3)$$

式中 b 为偏置量。在优化估计函数时, 对优化目标取极值

$$\min J = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^k (\xi_i^* + \xi_i) \quad (4)$$

使得

$$\begin{cases} y_i - (\omega, \varphi(x_i)) - b \leq \varepsilon + \xi_i \\ (\omega, \varphi(x_i)) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, (i=1, 2, \dots, k) \end{cases} \quad (5)$$

式中: C 为惩罚因子, 用于实现经验风险和置信风险的折中, C 越大对数据的拟合能力越高; ξ_i 和 ξ_i^* 为松弛因子, 用于控制线性不可分边界; ε 用于控制回归逼近误差和模型的泛化能力, 其值越大, 支持向量就越多, 但精度也越差。应用中, 常利用 (4) 和 (5) 式的对偶式, 得到

$$\begin{aligned} W(\alpha, \alpha^*) &= -\frac{1}{2} \sum_{i,j=1}^k (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \\ &+ (\varphi(x_i), \varphi(x_j)) + \sum_{i,j=1}^k (\alpha_i - \alpha_i^*) (y_i - \varepsilon) \end{aligned} \quad (6)$$

其约束条件为

$$\begin{cases} \omega = \sum_{i=1}^k (\alpha_i - \alpha_i^*) x_i \\ 0 \leq \alpha_i, \alpha_i^* \leq C \\ \sum_{i=1}^k (\alpha_i - \alpha_i^*) = 0 \end{cases} \quad (7)$$

则回归估计函数可表示为

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) (\varphi(x_i), \varphi(x)) + b \quad (8)$$

用核函数代替 (8) 式中的内积运算, 得到的非线性支持向量回归函数为

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (9)$$

核函数 $K(x_i, x) = (\varphi(x_i), \varphi(x))$ 。对于给定的非线性时间序列 $\{x_1, x_2, \dots, x_i\}$, 利用已知 x_i 的历史

数据来预测 x_{i+1} , 则可建立映射 $f: R^m \rightarrow R$, 满足

$$\hat{x}_{i+1} = f(x_i, x_{i-1}, \dots, x_{i-m+1}) \quad (10)$$

SVR 预测模型结构如图 1 所示^[13]。

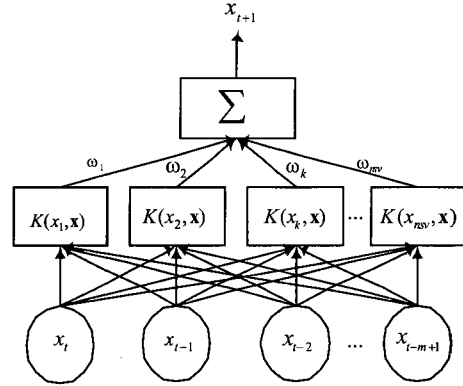


图 1 支持向量回归预测模型结构

Fig. 1 Structure of prediction model based on support vector regression

2 模型测试分析

本文以某型号姿控发动机高空模拟热标试车推力测量系统为研究对象, 以历史上连续 52 次试车的推力校准斜率为原始数据构成数据阵列 $X = \{XSm1, XSm2, \dots, XSm52\}$, 对 X 进行模型窗口的划分、训练和测试。其中, $\{XSm1, XSm2, \dots, XSm48\}$ 作为 FIG-SVR 预测模型的训练样本, 其变化趋势如图 2 所示。

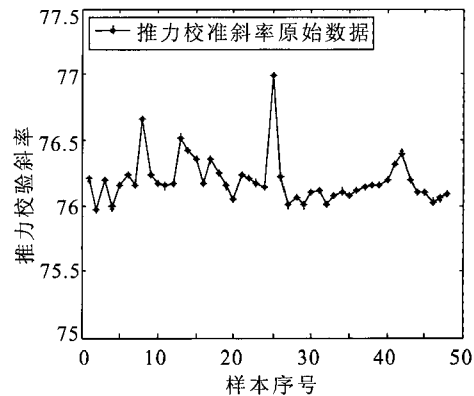


图 2 推力校准斜率原始数据

Fig. 2 Raw values of thrust calibration slope

选取 {XSm49,XSm50, ⋯XSm52} 作为测试样本, 窗口划分尺度 $N=4$ 。SVR 采用交叉验证方法进行参数的寻优, 核函数选取为径向基函数, 预测流程如图 3 所示。模糊粒化及预测结果如图 4 和图 5 所示。

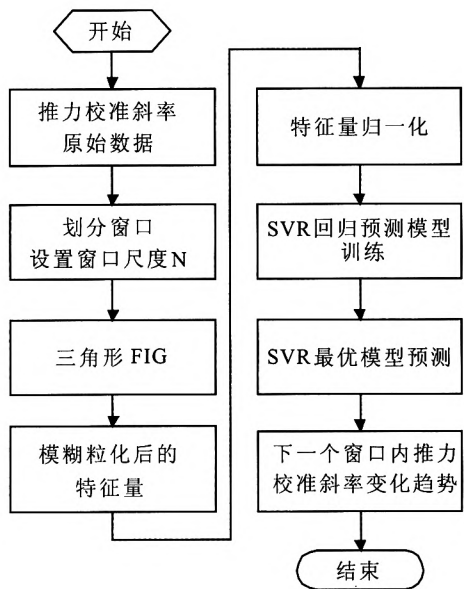


图 3 基于 FIG-SVR 的时间序列预测流程
Fig. 3 Prediction procedure with time sequence based on FIG-SVR

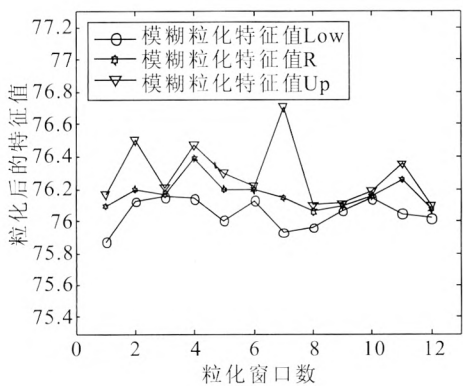
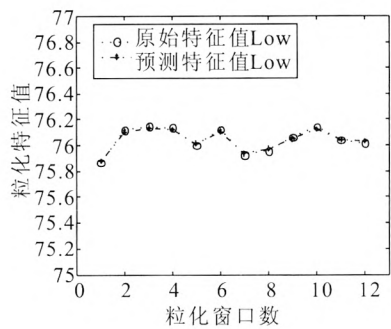


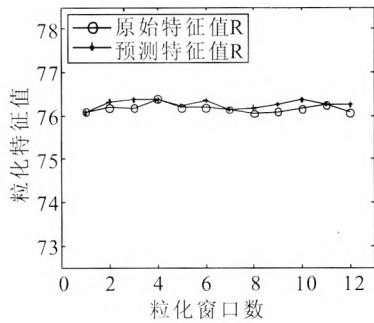
图 4 推力校准斜率 FIG 粒化值
Fig. 4 Granulation values of thrust calibration slope based on FIG

由图 4 可知, 经过 FIG 粒化后的特征量较好地反映了推力校准斜率原始数据的变化趋势,

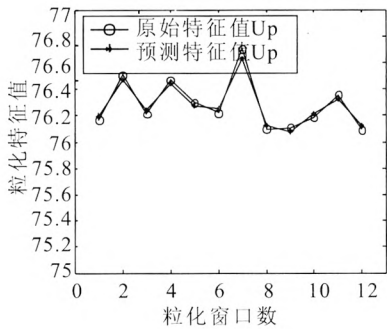
且样本数量大大减少。由图 5 可知, 经过 SVR 回归拟合, 三个特征量 Low, R 和 Up 的预测值和实际值重合性较好, 趋势走向也基本一致, 由此说明该信息粒化 SVR 区间预测算法能很好地跟踪原始数据的变化趋势。以 {XSm49, XSm50, ⋯XSm52} 为测试样本, 采用已经训练好的三角形模糊信息粒化 SVR 模型进行趋势预测, 预测结果见表 1。



(a) 粒化特征量 Low 原值和预测值



(b) 粒化特征量 R 原值和预测值



(c) 粒化特征量 Up 原值和预测值

图 5 粒化特征量 Low, R 和 Up 原值和预测值
Fig. 5 Raw and prediction values of Low,R and Up

表 1 推力校准斜率区间预测结果

Tab. 1 Prediction result interval of thrust calibration slope

测试样本	XSm49	XSm50	XSm51	XSm52
实际校准斜率	76.107 2	76.047 2	76.121 6	76.133 3
实际变化范围	[Low R Up] = [76.0401 76.1144 76.1270]			
预测变化范围	[Low* R* Up*]=[76.0450 76.1060 76.1416]			
Low 相对误差/%	0.006 44			
R 相对误差/%	0.011 03			
Up 相对误差/%	0.019 18			

由表 1 可知, 测试样本 {XSm49,XSm50,⋯ XSm52} 换算成的模糊粒子 Low/R/Up 与 FIG-SVR 模型预测输出 Low*/R*/Up* 非常接近, 由此也说明了该算法的优越性。

3 结论

以某型号姿控发动机高空模拟试验推力测量系统为研究对象, 以推力测量中至关重要的推力校准斜率作为输入数据, 实现了推力校准斜率的时间序列粒化与区间预测。预测结果表明, 基于模糊信息粒化支持向量回归 (FIG-SVR) 的预测准确率较高, 达到了预测推力校准斜率未来变化趋势的要求, 对保证推力测量系统可靠运行, 指导技术人员定期维护, 缩短试验准备时间具有重要的意义。

参考文献:

[1] 郭霄风. 液体火箭发动机试验[M]. 北京: 宇航出版社, 1990.
[2] 刘国球, 任汉芬, 朱宁昌, 等. 液体火箭发动机原理[M]. 北京: 中国宇航出版社, 2005.
[3] 胡世祥. 运载火箭推进系统[M]. 北京: 国防工业出版社, 2002.

[4] 朱子环, 耿卫国, 陈锋. 液体火箭发动机试验推力校准控制系统的设计[J]. 计算机测量与控制, 2008, 16(11): 1575-1577.
[5] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000, 26(1): 32-41.
[6] TIPPING M E, FAUL A C. Fast marginal likelihood maximization for sparse Bayesian model[C]// Proceedings of the Ninth International Workshop on Artificial Intelligence and Statistics. Florida: [s.n.], 2003: 120-127.
[7] 田英杰. 支持向量回归及其应用研究[D]. 北京: 中国农业大学, 2005.
[8] 和麟, 姜南, 黄潇瑶, 等. 基于模糊信息粒化 SVM 的飞机发电机故障预测[J]. 设计与研究, 2012(7): 7-10.
[9] 张蕾. 基于小波和信息粒化 BP 神经网络的轴承故障诊断[J]. 机械科学与技术, 2012, 31(1): 49-52.
[10] ZADEH L A. Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic [J]. Fuzzy Sets and Systems, 1997, 90(2): 111-127.
[11] 李洋. 基于信息粒化的机器学习分类及回归预测分析 [D]. 北京: 北京师范大学数学科学学院, 2009.
[12] 林左鸣, 谭瑞松. 航空故障诊断与健康管理技术[M]. 北京: 航空工业出版社, 2013.
[13] 彭勇, 陈俞强. 基于信息粒化得 SVM 时序回归预测 [J]. 计算机系统应用, 2013, 22(5): 163-167.

(编辑: 陈红霞)