

基于 RVM 的液体火箭发动机 试验台故障预测方法

马军强, 杨思锋, 戴芳立
(北京航天试验技术研究所, 北京 100074)

摘 要: 液体火箭发动机试验台故障预测问题实际上是与试验台相关的参数预测问题, 通过预测相关参数在试验台运行过程中的变化趋势, 可以判断试验台未来某一时刻是否可能发生故障。由于液体火箭发动机试验台系统复杂、不易建模, 提出了一种相关向量机 (relevance vector machine, RVM) 故障预测模型。在模型的训练阶段, 根据数据序列的特征, 分别采用单参量、相空间重构和多参量的方法进行了模型的训练, 然后利用训练好的模型对试验台总体健康度和启动过程推力进行了趋势预测。预测结果表明, 该方法能有效地跟踪试验台可能发生的故障及故障发展趋势。

关键词: 液体火箭发动机试验台; 相关向量机; 故障预测

中图分类号: V434-34 **文献标识码:** A **文章编号:** 1672-9374 (2015) 03-0080-07

RVM-based fault prediction method for liquid rocket engine test stand

MA Jun-qiang, YANG Si-feng, DAI Fang-li
(Beijing Institute of Aerospace Testing Technology, Beijing 100074, China)

Abstract: The fault prediction of liquid rocket engine test stand is actually the prediction of parameters associated with the test rig. By predicting the variation trends of those parameters, whether the test rig will get fault at a certain time in the future can be judged. As liquid rocket engine test-stand system is complex and difficult to model, a model based on relevance vector machine (RVM) is proposed in this paper. At the training stage of the model, the single-parameter method, phase space reconstruction method and multi-parameter method are used respectively to train the model according to the features of the data sequence, and then the trend of overall health degree and start-up thrust of the test stand is predicted by the trained model. The prediction result shows that this method based on RVM can effectively predict the possible fault and its trend.

Keywords: liquid rocket engine test stand; RVM; fault prediction

收稿日期: 2014-11-20; 修回日期: 2014-11-28

作者简介: 马军强 (1986—), 男, 硕士研究生, 研究领域为液体火箭发动机试验台故障预测

0 引言

液体火箭发动机试验台系统复杂, 在进行发动机单机或全系统试验时, 需要试验台各系统的紧密协作配合, 任何一个系统出现故障轻则影响试验的正常进行, 重则会影响试验的成败。因此, 建立准确、可靠的液体火箭发动机试验台故障预测模型, 在试验准备阶段对试验台的状态进行预测, 对指导试验技术人员的正常工作和试验台维护具有重要的指导意义。

试验台故障预测的精确度通常由所用的数学模型的精度来决定。由于液体火箭发动机试验台系统复杂, 各组成部件之间存在很强的非线性, 同时, 点火过程中恶劣的试验工况又使其故障多发, 因而, 建立准确、实用的数学模型十分困难。此外, 受到传感器技术和试验成本的限制, 试验台故障数据和故障子样非常少, 所以基于小样本的故障预测方法成为了一种研究方向。

相关向量机 (RVM) 是一种基于贝叶斯概率学习模型的有监督小样本学习理论。在贝叶斯框架下, 其利用自相关判定理论 (ARD) 移除不相关的数据点, 从而获得稀疏化的模型。它克服了神经网络故障预测需要较多训练样本的缺陷, 同时也克服了支持向量机故障预测核函数必须满足 Mercer 条件的限制。由于其对解的稀疏性要求比较高, 因此在保证预测精确度的同时, 相关向量个数较少, 也因此其在故障预测领域展现了很好的应用前景。

1 基于 RVM 的回归预测建模

RVM 是由美国 Tipping 博士提出的基于稀疏 Bayesian 概率学习理论的算法模型, 目前在图像识别、医学检测等领域已得到了应用研究^[9], 但在液体火箭发动机试验台故障预测领域的研究较少。

1.1 模型描述

给定训练集 $\{x_n, t_n\}_{n=1}^N$, $x_n \in \mathbf{R}^d$, $t_n \in \mathbf{R}$, 有监督学习的目的就是应用这些训练数据和先验知识设计一个模型, 使设计的模型对于新的输入 x^* , 预

测出输出 y^* 。RVM 预测模型的输出为

$$y(x, w) = \sum_{i=1}^N w_i K(x, x_i) + w_0 \quad (1)$$

式中: $K(x, x_i)$ 为核函数 (这里的核函数的选择不受 Mercer 定理的限制, 可以使用高斯核、多项式核、样条核等); w_i 为可调参数权值; N 为样本数。假定目标值是独立的, 且含有噪声, 即

$$t_n = y(x_n, w) + \varepsilon_n \quad (2)$$

式中 ε_n 为噪声, 服从均值为 0, 方差为 σ^2 的 Gauss 分布, 则训练样本集的似然函数为

$$p(t|w, \sigma^2) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left\{-\frac{1}{2\sigma^2} \|t - \Phi(x)w\|^2\right\} \quad (3)$$

$$t = [t_1, t_2, \dots, t_N]^T, w = [w_0, w_1, \dots, w_N]^T$$

$\Phi(x)$ 是一个 $N \times (N+1)$ 的核函数矩阵, 即

$$\Phi(x) = [\phi(x_1), \phi(x_2), \dots, \phi(x_N)]^T \quad (4)$$

$$\phi(x_n) = [1, K(x_n, x_1), \dots, K(x_n, x_N)]$$

通过最大似然函数法求出的最优 w 能够使经验风险最小, 但通常会导致过学习。为了避免这种情况, 采用稀疏 Bayesian 方法对权值 w 赋予先验的条件概率分布, 即

$$p(w|\alpha) = \prod_{i=0}^N N(w_i | 0, \alpha_i^{-1}) \quad (5)$$

进一步将超参数 α 及噪声方差 $\beta = \sigma^2$ 定义为超先验的 Gamma 分布, 即

$$p(\alpha) = \prod_{i=0}^N \text{Gamma}(\alpha_i | a, b) \quad (6)$$

$$p(\beta) = \text{Gamma}(\beta | c, d) \quad (7)$$

其中 $\text{Gamma}(\alpha | a, b) = \Gamma(a)^{-1} b^a \alpha^{a-1} e^{-b\alpha}$, $\Gamma(a) = \int_0^\infty t^{a-1} e^{-t} dt$ 。

参数 a, b, c 和 d 通常假设为非常小的常值。

根据上述描述, 可得 RVM 回归预测模型的结构如图 1 所示。




图1 RVM回归预测模型结构

Fig. 1 Structure of RVM regression prediction model

1.2 模型推导

根据贝叶斯公式所有未知参数后验公式如下

$$p(w, \alpha, \sigma^2 | t) = \frac{p(t | w, \alpha, \sigma^2) p(w, \alpha, \sigma^2)}{p(t)} \quad (8)$$

给定新观测点 \$x^*\$, 则相应的预测值 \$t^*\$ 的概率分布为

$$p(t^* | t) = \int p(t^* | w, \alpha, \sigma^2) p(w, \alpha, \sigma^2 | t) dw d\alpha d\sigma^2 \quad (9)$$

考虑到

$$p(w, \alpha, \sigma^2 | t) = p(w | t, \alpha, \sigma^2) p(\alpha, \sigma^2 | t) \quad (10)$$

$$p(w | t, \alpha, \sigma^2) = \frac{p(t | w, \sigma^2) p(w | \alpha)}{p(t | \alpha, \sigma^2)}$$

$$= (2\pi)^{-\frac{N+1}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(w-\mu)^T \Sigma^{-1}(w-\mu)\right\} \quad (11)$$

式中: \$\Sigma = (\sigma^{-2} \Phi^T \Phi + A)^{-1}\$, 为权重的后验协方差矩阵, \$A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)\$; \$\mu = \sigma^{-2} \Sigma \Phi^T t\$, 为权重的后验均值向量。对于(10)式中超参数的后验 \$p(\alpha, \sigma^2 | t)\$, 用 Delta 函数的峰值来逼近。为了预测, 不要求 \$p(\alpha, \sigma^2 | t) \approx \delta(\alpha_{MP}, \sigma_{MP}^2)\$, 仅要求

$$\begin{aligned} & \int p(t^* | w, \alpha, \sigma^2) \delta(\alpha_{MP}, \sigma_{MP}^2) d\alpha d\sigma^2 \\ & \approx \int p(t^* | \alpha, \sigma^2) p(\alpha, \sigma^2 | t) d\alpha d\sigma^2 \end{aligned} \quad (12)$$

又 \$p(\alpha, \sigma^2 | t) \propto p(t | \alpha, \sigma^2) p(\alpha) p(\sigma^2)\$, 于是 RVM 学习转变为寻求超参数后验最大值的问题, 也就是求关于 \$\alpha\$ 的 \$p(t | \alpha, \sigma^2)\$ 最大值, 即

$$\begin{aligned} p(t | \alpha, \sigma^2)_{\max} &= \int p(t | w, \sigma^2) p(w | \alpha) dw \\ &= (2\pi)^{-\frac{N}{2}} \left| \sigma^2 I + \Phi A^{-1} \Phi^T \right|^{-\frac{1}{2}} \times \end{aligned}$$

$$\exp\left\{-\frac{1}{2} t^T (\sigma^2 I + \Phi A^{-1} \Phi^T)^{-1} t\right\} \quad (13)$$

1.3 超参数优化

由于不能直接获得使(13)式最大的 \$\alpha\$ 和 \$\sigma^2\$ 的解析表达式, 因此采用迭代法进行估计, 即

$$\begin{aligned} \alpha_i^{\text{new}} &= \frac{\gamma_i}{\mu_i} \\ (\sigma^2)^{\text{new}} &= \frac{\|t - \Phi \mu\|}{N - \sum \gamma_i} \end{aligned} \quad (14)$$

式中 \$\gamma_i = 1 - \alpha_i \Sigma_{ii}\$, \$\Sigma_{ii}\$ 为权重后验协方差矩阵的第 \$i\$ 个对角元素。RVM 学习算法经反复迭代至满足某个预设收敛条件。在迭代过程中大部分 \$\alpha_i\$ 会趋于 \$\infty\$, 进而得到对应的 \$w_i\$ 趋于 0, 从而导致解的稀疏性。非零 \$w_i\$ 对应的学习样本称为相关向量 (RV)。RVM 预测模型的算法流程如图 2 所示。

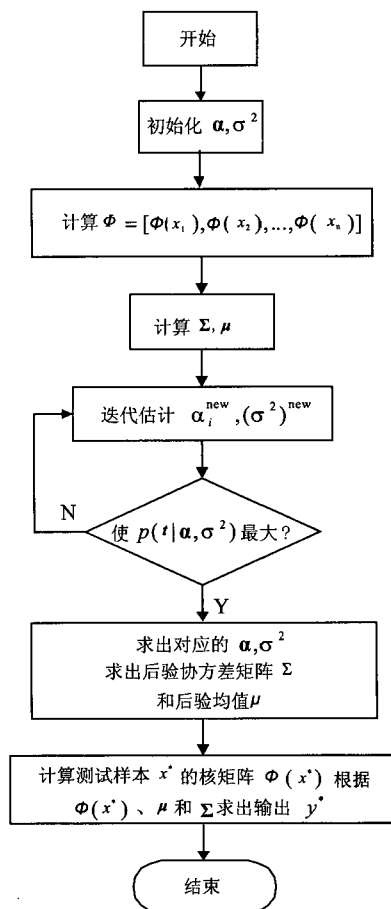


图2 RVM算法流程

Fig. 2 Flow chart of RVM algorithm

若给定一个新的输入值 x^* , 则可通过以下两步实现预测

$$p(t^* | t, \alpha_{MP}, \sigma_{MP}^2) = \int p(t^* | w, \sigma_{MP}^2) p(w | t, \alpha_{MP}, \sigma_{MP}^2) dw \quad (15)$$

$$p(t^* | t, \alpha_{MP}, \sigma_{MP}^2) = N(t^* | y^*, \sigma_*^2) \quad (16)$$

新输入值的预测均值^[9] $y^* = \mu^T \phi(x^*)$, 预测方差 $\sigma_*^2 = \sigma_{MP}^2 + \phi(x^*)^T \sum \phi(x^*)$ 。

2 模型测试分析

试验台故障预测问题实际上是试验台相关参数的预测问题, 通过对试验台整体系统或子系统相关参数变化趋势的预测, 可以判断未来某一时刻试验台系统是否可能发生故障。

2.1 试验台单参量综合故障预测

液体火箭发动机试验台的综合健康度是反映

试验台综合健康状况的一个关键指标, 它是对试验台综合健康状况^[10]的定量度量, 取值范围为 0~1。取值为 0 时, 表示处于严重故障状态; 取值为 1 时, 表示处于 100% 的健康状态。

通过对历史试验数据的分析并借助灰色综合评价方法可计算出试验台单参数健康度, 再据此利用模糊数据融合方法可逐级计算出试验台子系统健康度和综合健康度。因此, 通过对试验台综合健康度变化趋势的预测, 可有效把握试验台未来的健康状况, 从而为试验技术人员工作和维护提供指导。本节选取某轨 / 姿控发动机高空模拟试验台连续 10 次试车的综合健康度值 CV 构成数据序列 $X = \{x_1, x_2, \dots, x_{10}\}$, 对序列 X 进行相空间重构^[12-13], 以获得数据间的关联关系, 形成 RVM 预测模型的训练样本数据阵列 $X_{trainSm}$, $X = \{0.7366, 0.7342, 0.7311, 0.7271, 0.7216, 0.7141, 0.7037, 0.6892, 0.6689, 0.6406\}$ 。如表 1 所示。

表 1 基于 RVM 的单参量故障预测训练和测试样本

Tab. 1 Training and testing samples of single-parameter fault prediction based on RVM

样本序号	输入 X^*		输出 y		预测值 y^*
XtrainSm1	0.736 6	0.734 2	0.731 1	0.727 1	0.727 6
XtrainSm2	0.734 2	0.731 1	0.727 1	0.721 6	0.721 7
XtrainSm3	0.731 1	0.727 1	0.721 6	0.714 1	0.713 9
XtrainSm4	0.727 1	0.721 6	0.714 1	0.703 7	0.703 4
XtrainSm5	0.721 6	0.714 1	0.703 7	0.689 2	0.688 9
XtrainSm6	0.714 1	0.703 7	0.689 2	0.668 9	0.668 8
XtrainSm7	0.703 7	0.689 2	0.668 9	0.640 6	0.640 9
PredictSm1	0.689 2	0.668 9	0.640 6	Prediction1	0.601 9
PredictSm2	0.668 9	0.640 6	Prediction1	Prediction2	0.548 2
PredictSm3	0.640 6	Prediction1	Prediction3	Prediction3	0.474 0
PredictSm4	Prediction1	Prediction2	Prediction4	Prediction4	0.372 2

根据重构后的训练样本阵列进行 RVM 预测模型的训练, 并采用一步迭代预测法预测试验台未来 4 次试车的综合健康度。核函数选取为线性样条函数 Spline, 如式(17)所示。仿真时核参数

$\sigma=5$ 。

$$K(x_i, x_j) = 1 + x_i x_j + x_i x_j \min(x_i, x_j) - \frac{x_i + x_j}{2} \min(x_i, x_j)^2 + \frac{\min(x_i, x_j)^3}{3} \quad (17)$$

根据单参量 RVM 预测模型得到的某高空模拟试验台综合健康度发展趋势如图 3(a)所示。从图中可以看出,经过多次试车之后,试验台综合健康度值不断减小,健康状况不断下降,符合前

10 次试车试验台健康度变化趋势,因此需要试验技术人员适时实施维护。图 3(b)为训练误差图。同时,通过比较训练输出值和 RVM 模型输出值可知,该 RVM 模型的预测精确度较高。




图 3 基于 RVM 的单参量综合故障预测

Fig. 3 Single-parameter comprehensive fault prediction based on RVM

2.2 试验台多参量故障预测

在液体火箭发动机高空模拟试验点火过程中(尤其是热标试车),发动机推力是评价发动机性能的一个重要指标,也是综合评价试验台能力的一个重要参数^[1]。在试验台整体系统给定时,发动机的推力 F_{ac} 与试验台氧化剂管路系统流量 q_{mo} 、燃料管路系统流量 q_{mf} 和燃烧室压力 p_c 有关,可

以归纳为 $F_{ac}=f(p_c,q_{mo},q_{mf})$, 故可用参量 q_{mo} , q_{mf} 和 p_c 来预测推力的变化趋势(预测值记为 F_{ac}^*)。多参量预测模型的训练样本和测试样本来自某次轨控发动机热标试车点火启动段的试车数据,并且进行了归一化处理,以在不减少数据间联系的情况下加快模型的学习速度^[15]。训练样本共 13 组,测试样本共 9 组,见表 2。

表 2 基于 RVM 的多参量故障预测训练和测试样本

Tab. 2 Training and testing samples of multi-parameter fault prediction based on RVM					
样本序号	p_c	q_{mo}	q_{mf}	F_{ac}	F_{ac}^*
XtrainSm1	0.000 0	0.000 0	0.000 0	0.000 0	0.000 2
XtrainSm2	0.126 8	0.343 4	0.432 0	0.029 6	0.024 3
XtrainSm3	0.312 5	0.608 0	0.499 8	0.132 9	0.153 2
XtrainSm4	0.457 6	0.611 9	0.553 4	0.287 2	0.266 3
XtrainSm5	0.597 0	0.623 3	0.561 2	0.381 3	0.374 9
XtrainSm6	0.684 9	0.632 9	0.596 7	0.452 4	0.459 8
XtrainSm7	0.792 4	0.676 3	0.644 4	0.556 9	0.576 2
XtrainSm8	0.853 3	0.694 6	0.732 3	0.686 6	0.668 4
XtrainSm9	0.884 7	0.793 9	0.833 9	0.773 0	0.760 5
XtrainSm10	0.922 2	0.884 8	0.881 3	0.851 2	0.837 6

续表

样本序号	p_c	q_m	q_{mf}	F_{ac}	F_{ac}^*
XtrainSm11	0.941 2	0.924 5	0.909 9	0.876 5	0.878 6
XtrainSm12	0.968 8	0.949 9	0.951 0	0.925 5	0.930 0
XtrainSm13	0.986 5	0.966 5	0.961 8	0.850 8	0.955 8
PredictSm1	0.989 3	0.968 9	0.981 3	—	0.968 5
PredictSm2	0.991 2	0.978 3	0.982 7	—	0.973 5
PredictSm3	0.994 4	0.980 2	0.987 8	—	0.979 5
PredictSm4	0.996 4	0.984 1	0.992 1	—	0.984 5
PredictSm5	0.997 5	0.991 3	0.994 6	—	0.988 7
PredictSm6	0.998 2	0.992 9	0.997 3	—	0.991 1
PredictSm7	0.998 9	0.996 7	0.999 5	—	0.993 9
PredictSm8	1.000 0	1.000 0	1.000 0	—	0.996 1
PredictSm9	1.000 0	1.000 0	1.000 0	—	0.996 1

注：表中数据为归一化数值


核函数选取为高斯型核函数，如式(18)所示。
仿真时核参数 $\sigma=2.7$ 。

$$K(x_i, x_j) = \exp\left\{-\frac{\|x_i - x_j\|^2}{\sigma^2}\right\}$$


(18)

预测结果如图 4 所示。由图 4(a)可知，某工

况下点火启动段推力的预测结果变化趋势较符合
发动机启动后推力的发展趋势，且预测结果的变
化趋势比较稳定，符合发动机在正常工作状态下的
特点。由图 4(b)可知，训练误差也较小。由此
可见，该模型对多参量因素影响下的预测也具有
较好的准确性。



(a) 推力趋势预测图



(b) 训练误差图

图 4 基于 RVM 的多参量故障预测

Fig. 4 Multi-parameter fault prediction based on RVM

3 结束语

针对小样本问题研究并给出了基于相关向量

机的故障预测模型，并将其应用于某液体火箭发
动机试验台故障预测仿真中。研究表明，无
论是对于单参量相空间重构预测还是多参量直接

预测,通过选取符合样本本身特点的核函数和核参数,RVM预测模型都能给出很好的预测效果,并且相关向量个数较少,极大地体现了RVM预测模型的稀疏性和算法的优越性。因此,RVM所具有的辨识复杂非线性系统的能力以及针对小样本数据的预测能力,决定了该算法有望在液体火箭发动机试验台故障预测中得到进一步的应用。

参考文献:

- [1] 郭宵峰,李耀华,陈鸿彦,等.液体火箭发动机试验[M].北京:宇航出版社,1990.
- [2] 张恒喜,郭基联,朱家元,等.小样本多元数据分析及应用[M].西安:西北工业大学出版社,2002.
- [3] 范庚,马登武,张继军.一种基于小样本数据的装备故障预测方法[J].弹箭与制导学报,2012,32(2): 225-228.
- [4] BISHOP C M, TIPPING M E. Variational relevance vector machines [C]// Proceedings of Uncertainty in Artificial Intelligence. USA: Morgan Kaufmann, 2000: 46-53.
- [5] TIPPING M E. Baseline Matlab implementation of "Sparse Bayesian" model estimation [EB/OL]. [2009-02-22]. <http://miketipping.com/papers.htm>.
- [6] TIPPING M E. Bayesian inference: an introduction to principle and practice in machine learning [EB/OL]. [2006-06-26]. <http://miketipping.com/papers.htm>.
- [7] TIPPING M E, FAUL A C. Fast marginal likelihood maximisation for sparse Bayesian model [EB/OL]. [2006-06-26]. <http://www.miketipping.com/papers.htm>.
- [8] 李刚,邢书宝,薛惠锋.基于RBF核的SVM及RVM模式分析性能比较[J].计算机应用研究,2009,26(5): 1782-1784.
- [9] 范庚,马登武,邓力,等.基于灰色相关向量机的故障预测模型[J].系统工程与电子技术,2012,34(2): 424-428.
- [10] 郭阳明,蔡小斌,张宝珍,等.故障预测与健康状态管理技术综述[J].计算机测量与控制,2008,16(9): 1213-1219.
- [11] 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.
- [12] 李夕海,刘代志,张斌,等.基于重采样的混沌时间序列相空间重构研究[J].信号处理,2006,22(2): 248-251.
- [13] 刘孝贤,冯晨.相空间重构中的K-L变换[J].山东大学学报(工学版),2004,34(6): 41-46.
- [14] 廉建鑫.基于RVM和混合优化算法的变压器故障诊断与预测应用研究[D].太原:太原理工大学,2012.
- [15] 田干,张伟,杨正伟,等.SVM方法在液体火箭发动机故障预测中的应用研究[J].2010,24(1): 1-9.
- [16] 杨淑莹.模式识别与智能计算-Matlab技术实现.2版[M].北京:电子工业出版社,2011.

(编辑:陈红霞)

(上接第79页)

5 结束语

扭矩现场校准技术研究是当前国内外扭矩计量专业发展的方向和重点。本文主要介绍了一种基于力偶矩加载原理的扭矩现场校准装置,可有效解决涡轮增压水力试验系统扭矩传感器现场校准的难题,为航天液体火箭发动机的精准调整提供了技术保障,同时具有一定的推广和使用价值。

参考文献:

- [1] 商维绿.现代扭矩测量技术[M].上海:上海交通大学出版社,1999.
- [2] 陈曦.现场扭矩测试技术和方法[J].船舶工程,2012,34(增刊): 22-24.
- [3] 李友先.扭矩校准技术现状与发展趋势[J].计量与测试技术,2013,40(11): 36-38.
- [4] SUE P, WILSON D. High precision torque measurement on a rotating load coupling for power generation operations, IEEE 978-1-4577-1772-7/12[R]. USA: IEEE, 2012.
- [5] 张有颐.转矩测量技术[M].北京:中国计量出版社,1986.
- [6] 王海林,杨兰.扭矩现场校准测试技术分析[J].工业计量,2013(增刊): 7-10.

(编辑:马杰)