

SVM 在气体减压器稳定性能中的应用

孙士元¹, 王拥军¹, 陈 阳², 王宝山¹, 陈经禄¹
(1. 北京航空航天大学 数学与系统科学学院, 北京 100191;
2. 北京航空航天大学 宇航学院, 北京 100191)

摘 要: 使用支持向量机(SVM)研究涡轮气封减压试验系统中高压卸荷膜片式减压器的稳定性问题, 主要集中于以往方法不易涉及的多结构参数变化, 针对稀疏易有残缺的小样本空间, 与 BP(back propagation)神经网络模型进行对比, 得出 SVM 方法在所研究数据集上的一些结论: SVM 模型预测性能在多结构参数变化情形下优于 BP 神经网络模型, 预测误差平均降低了 25.5%; SVM 的泛化性好于 BP; 在双参数、三参数情形下, SVM 模型为气体减压器的设计提供了更好的决策支持, 给出了优化结构参数的设计建议。
关 键 词: 支持向量机 (SVM); 减压器; 稳定性; 核函数; 过拟合; 泛化性
中图分类号: V432 **文献标志码:** A

Application of SVM in stability of gas pressure reducing regulator

SUN Shi-yuan¹, WANG Yong-jun¹, CHEN Yang²,
WANG Bao-shan¹, CHEN Jing-lu¹
(1. School of Mathematics and Systems Science,
Beijing University of Aeronautics and Astronautics, Beijing 100191, China;
2. School of Astronautics,
Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

Abstract: Support vector machine (SVM) was used to study the stability problem of high pressure unloading diaphragm pressure reducing regulator in the turbine gas seal pressure reducing test system. The research mainly focused on multi-structural parameters variation, which was difficult to solve by the classical methods. By comparing SVM and back propagation (BP) neural network model in the scarce and incomplete data set, several conclusions were proposed; the prediction models of SVM can get 25.5% less error in average and are superior to BP neural network model in the situation of multi-structural parameters variation; the generalization of SVM is also better than BP's in sparse samples space; suggestions of adjusting parameters are given for achieving good stability, and better decision-making is provided by SVM models in design of pressure reducing regulator, with double parameter combinations and tri-parameter combinations.
Key words: support vector machine (SVM); pressure reducing regulator; stability; kernel function; over fitting; generalization

减压器是流体管路系统中的降压和稳压元件,其动力学特性得到广泛研究.许多方法对减压器建模并使用数值方法探讨其稳定性问题^[1-9],如 4 阶龙格-库塔法^[1,9],流固耦合方法^[7],有限体积瞬变仿真方法^[8],粒子群优化算法^[9]等.这些方法和模型多采用等温条件^[1,5-6],在阀芯和孔节流上

采用基于压差的压强-流量关系式^[2-3]、线性化^[4,6]等理想情况,实验数据和仿真数据的差异可能会影响某些结论.数值方法研究减压器工作时的稳定性问题可以对单结构参数变化情形做出描述,但是很难描述多个结构参数耦合变化的情况.使用数据挖掘中的一些方法,可以对多结构参数耦合变化情形提供帮助.

BP 神经网络模型是目前应用最广泛的神经网络模型之一,有很强的非线性映射能力,建模后相当于得到一个黑匣子. SVM 是新兴的数据挖掘重要方法,基于统计学理论基础,具有严格的数学基础^[10],建立的模型可用显式描述,建模过程比 BP 速度快很多. SVM 在小样本空间中的性能优秀,本文涉及数据集是稀少残缺的小样本空间, SVM 可以发挥很好的作用.

BP 神经网络模型可以对单结构参数、多结构参数情形做出描述和预测^[11]. SVM 和 BP 在单结构参数情形下预测性能基本一致,故本文使用 SVM 模型研究减压器的稳定性能时,着重于多结构参数情形下与 BP 神经网络模型的预测图形、误差性能进行对比和分析.

本文首先简要介绍减压器的稳定性问题,给出稳定性指标;随后简述 SVM 的基本原理.第 3 部分是核心工作,研究中使用相同的数据集,对 SVM 和 BP 神经网络(下文简称 BP)的预测性能进行比较.多结构参数情形下, SVM 和 BP 的预测模型产生了较大的差异,通过将两者的预测图形、误差分析进行对比,找出产生差异的原因,不难理解选取 SVM 模型的合理性.泛化性是预测模型的重要衡量指标,本文总结 SVM 和 BP 的泛化性特点之后,针对所研究数据集的特点提出了初步提高泛化性的方法.给出多结构参数情况下减压器设计的决策支持参考,对减压器的设计有一定指导意义.

1 减压器仿真模型与稳定性性能指标

本文研究的高压卸荷膜片式减压器模型基于文献[12-13].图 1 为涡轮气封减压试验系统的数值仿真模型.图中量符号及代号的含义参见文献[12-13].模块化建模时把此系统化为流体、气体管道、气体容积、气体阀门、气体减压器、缓开阀等部分.认为气体管流为一维理想气体流动,管道壁面选用绝热模型或径向一维传热模型,采用常物性控制器,采用经典 4 级 4 阶龙格-库塔法对上述动态过程进行数值仿真.

电磁阀 GV1 下游腔与电磁阀 GV2 上游腔之




图 1 涡轮气封减压试验系统的数值仿真模型^[12-13]

Fig. 1 Numerical simulation model of the turbine gas seal pressure reducing test system^[12-13]

间管路压强为 p_2 . M_{vc} 为阀芯质量、 d_{v3} 为阻尼孔直径、 L_2 为低压腔长度、 L_1 为高压腔长度、 λ_s 为减压器弹性元件材料的阻尼系数、 C_m 为膜片刚度,本文所研究参数在标准算例中设置见表 1.

表 1 标准算例的结构参数设置

Table 1 Structure parameters setting of standard example

参数	数值	参数	数值
M_{vc}/kg	0.082 2	d_{v3}/m	0.001
L_2/m	0.021 28	L_1/m	0.033 06
λ_s/s	0.000 4	$C_m/10^5 (\text{N/m})$	4.033

涡轮气封减压试验系统所用的逆向卸荷膜片式减压器在工作过程中存在稳定性问题,标准算例仿真得到的减压器阀芯和高、低压腔压强动态变化曲线出现了无固定频率的振荡,从而导致整个系统工作不稳定.对于振荡现象,可以选取减压器 GPRR1 低压腔压强 p_2 在一定时间内的相对变化量为衡量减压器稳定性的指标.式(1)和式(2)为稳定性值($S_{\text{GPRR1-}p_2}$)的计算公式,稳定性指标值越小,减压器越稳定^[11].

$$p_{\text{refer}} = \frac{1}{n+1} \sum_{i=0}^n p_2(t_i) \tag{1}$$

$$S_{\text{GPRR1-}p_2} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left[\frac{p_2(t_i) - p_2(t_{i-1})}{p_{\text{refer}}} \right]^2} \tag{2}$$

一组仿真数据可通过式(1)和式(2)计算获得一个稳定性指标值.为了解稳定性变化趋势,单结构参数变化需求的样本量在 10^2 级别,尚可依靠数值仿真模型;对于多结构参数耦合变化需求的样本量十分巨大,现实中无法获得足量的样本空间,因此必须使用可靠的方法基于小样本空间建立稳定性的预测模型,因此本文选用 SVM 研究方法.

2 支持向量机

SVM 由 Vapnik 提出,20 世纪 90 年代中后期得到全面深入地发展. SVM 基于统计学习理论和结构经验风险最小化理论,拥有严格的数学理论基

础^[10]. SVM 建模推导详细过程见文献[14-15].

使用线性函数 $f(x)=\omega \cdot x+b$ 拟合数据 $\{x_i,y_i\},i=1,2,\cdots,n$, 其中 x_i 为样本值特征向量, y_i 为实数, 设不敏感损失函数为 ϵ , 本文设为 0.001, 引入松弛因子 ξ_i,ξ_i^* , 回归函数应满足

$$\begin{cases} y_i-\omega \cdot x_i-b \leq \epsilon+\xi_i \\ \omega \cdot x_i+b-y_i \leq \epsilon+\xi_i^* \end{cases} \quad (3)$$
$$i=1,2,\cdots,n$$

所建 Lagrange 方程如下, C 是惩罚因子, 本文设为 1.

$$L(\omega,\xi_i,\xi_i^*)=\frac{1}{2}\|\omega\|^2+C\sum_{i=1}^n(\xi_i+\xi_i^*)-$$
$$\sum_{i=1}^n\alpha_i(\epsilon+\xi_i-y_i+\omega \cdot x_i+b)-$$
$$\sum_{i=1}^n\alpha_i^*(\epsilon+\xi_i^*+y_i-\omega \cdot x_i-b)-$$
$$\sum_{i=1}^n(\eta_i\xi_i+\eta_i^*\xi_i^*) \quad (4)$$

经求解可得拟合函数为

$$f(x)=\sum_{sv}(\alpha_i-\alpha_i^*)(x \cdot x_i)+b \quad (5)$$

其中 sv 表示支持向量集. 一般数据集无法用线性函数拟合, 需要以低维到高维的变换 $\phi(x)$ 代替 x , 并引入核函数 $K(x,x_i)=\phi(x) \cdot \phi(x_i), K(x,x_i)$, 可以在特征向量原始空间中隐式计算 $\phi(x) \cdot \phi(x_i)$ 的内积.

SVM 预测模型的预测效果与核函数及核函数参数的选取有关, 下文均选取 Pearson VII 型 (PUK) 核函数. PUK 核函数有 ω,σ 两个参数可调节, PUK 核函数一般形态如下:

$$K(x_i,x)=$$
$$\frac{1}{[1+(2\sqrt{\|x_i-x\|^2} \cdot \sqrt{2^{1/\omega}-1}/\sigma)^2]^\omega} \quad (6)$$

式中 x 为自变量, 通过改变参数 ω,σ , Pearson VII 函数可以拟合任意单峰光滑曲线^[16-17]. 对于 Pearson VII 型核函数而言, 其两个参数取值越大, 核函数的拟合能力越弱, 泛化能力会增强; 两个参数取值越小, 核函数的拟合能力就越强, 泛化能力就会降低. 因此在使用 Pearson VII 型核函数时, 应该同时兼顾拟合能力和泛化性能, 使两者达到一种良好的均衡状态^[18]. 鉴于此, 本文在建模过程中以 (ω,σ) 取 $(1,1)$ 为起始取值, 在兼顾训练误差和预测误差的基础上对参数进行调整, 获得较好的预测模型.

3 训练生成预测模型及分析

通过对多个结构和控制参数的调节试算研究

表明: 减压器阻尼孔直径(d_{v3})、卸荷孔直径(d_{v4})、高压腔长度(L_1)、低压腔长度(L_2)、阀芯质量(M_{vc})、膜片刚度(C_m)、主弹簧预压缩量(x_2)、弹性元件材料的阻尼系数(λ_s)等结构参数的变化都会影响减压器的动力学特性, 从而影响减压器的工作稳定性^[11]. 传统研究方法可以描述一个结构参数的变化情况, 本文研究方法能够胜任多个结构参数耦合变化的情形. 本文的重要结果就是给出在相应多结构参数耦合变化下的稳定区域.

所研究参数随机取标准值 1/10 到 10 倍之间的随机数值, 其余参数取标准值. 表 2 列出参与训练的样本点情况, 每组样本点随机分成两部分, 约 90% 作为训练样本, 约 10% 不进行训练来考察模型. 下文中所得预测模型中, 结构参数取值在蓝色区域中时(见下文各图色谱)稳定性较好. 模型训练过程中, 使用 Weka 平台的标准算法.

表 2 样本数量列表

Table 2 List of sample number

变化参数	样本数	变化参数	样本数
M_{vc}	113	d_{v3}	138
L_2	75	L_1	426
λ_s	78	C_m	90
L_2,M_{vc}	629	M_{vc},λ_s	226
d_{v3},L_2	214	$d_{v3}\lambda_s$	212
d_{v3},C_m	169	d_{v3},M_{vc},λ_s	1011
L_1,M_{vc},λ_s	845	d_{v3},C_m,λ_s	1122

3.1 单结构参数

单结构参数下(下文简称单参数)SVM 和 BP 预测性能良好且预测模型基本一致, 这里仅给出 SVM 预测模型的误差情况. 表 3 为单参数 SVM 预测模型的误差情况.

表 3 SVM 预测模型误差情况(单参数)

Table 3 Error situation of SVM prediction models (single parameter)

参数	e_{trabs}	$e_{trre}/\%$	e_{unabs}	$e_{unre}/\%$
M_{vc}	0.000776	0.3594	0.001147	0.5229
d_{v3}	0.001969	1.499	0.004782	5.498
L_1	0.000794	0.3800	0.000925	0.4448
L_2	0.000889	0.4870	0.001312	0.6535
C_m	0.001696	102.5	0.003461	82.42
λ_s	0.001670	1.354	0.001612	1.114

表 3 中 e_{trabs} 为训练样本绝对误差平均值; e_{trre} 为训练样本相对误差率平均值; e_{unabs} 为未训练样本绝对误差平均值; e_{unre} 为未训练样本相对误差率平均值. 误差的计算公式如下:

$$e_{\text{trabs}} = \frac{1}{n} \sum_{i=1}^n |P_i - R_i| \tag{7}$$

$$e_{\text{trre}} = \frac{1}{n} \sum_{i=1}^n (|P_i - R_i| / R_i) \tag{8}$$

式中 P_i 为模型对训练样本稳定性的预测值, R_i 为训练样本稳定性真实值. e_{unabs} 和 e_{unre} 计算公式中 P_i 和 R_i 为未训练样本稳定性的预测值和真实值.

SVM 模型在表 3 四项参考指标表现良好, 绝对误差在忍受范围之内. C_m 参数的相对误差率比较高, 绝对误差值良好.

3.2 双结构参数

双结构参数(下文简称双参数)变化下, 样本点分布如图 2.

表 4、表 5 为 BP 和 SVM 预测模型的误差.

BP 和 SVM 模型得到的预测图形如图 3.

文献[11]中 BP 预测图形会产生奇异区域和断层的问题, 图 3 中 BP 预测图形也产生类似问题. 图 3(a)中右上和左下部分之间有断层现象; 图 3(c)中 d_{v3} 参数 0.002~0.004 段上部有奇异区域; 图 3(e)中中部和下部有断层痕迹; 图 3(g)图中 d_{v3} 参数 0~0.0008 段中部有奇异区域. 这些预测部分错误, 很难依靠调整 BP 的模型参数消除, 这是由于样本空间是稀疏残缺的, 此时 BP 的泛化性无法得到保障. 在图 3 中可以看到 SVM 预测图形是可信的, 泛化性良好.




图 2 双参数样本分布情况
Fig. 2 Distribution of samples of double parameters

表 4 BP 预测模型误差情况 (双参数)


Table 4 Error situation of BP prediction models
(double parameters)

参数	e_{trabs}	$e_{\text{trre}}/\%$	e_{unabs}	$e_{\text{unre}}/\%$
M_{vc}, λ_s	0.01018	7.503	0.01227	9.763
d_{v3}, λ_s	0.01349	13525	0.02697	8638
d_{v3}, L_2	0.009835	949.3	0.009480	1903
d_{v3}, C_m	0.004999	1570	0.008258	2371


表 5 SVM 预测模型误差情况 (双参数)

Table 5 Error situation of SVM prediction models
(double parameters)


参数	e_{trabs}	$e_{\text{trre}}/\%$	e_{unabs}	$e_{\text{unre}}/\%$
M_{vc}, λ_s	0.001579	0.914	0.001604	1.015
d_{v3}, λ_s	0.011239	11017	0.02250	4174
d_{v3}, L_2	0.009525	168.9	0.008301	21.53
d_{v3}, C_m	0.005918	809.1	0.005665	1321




(a) BP的 M_{vc}, λ_s 预测图形




(b) SVM的 M_{vc}, λ_s 预测图形




(c) BP的 d_{v3}, λ_s 预测图形



(d) SVM的 d_{v3}, λ_s 预测图形



(e) BP的 d_{v3}, L_2 预测图形



(f) SVM的 d_{v3}, L_2 预测图形




图 3 BP 和 SVM 预测图形的对比
Fig. 3 Comparison of BP and SVM on prediction graphics

由图 3(b)可知, M_{vc} , λ_s 耦合变化时, 当 M_{vc} 超过 0.5 时, 无论怎样调节 λ_s 的值, 减压器的稳定性都不会太好, M_{vc} 低于 0.5 时, λ_s 在 0.002 ~ 0.003 之间适当取值稳定性较好. 由图 3(d), d_{v3} , λ_s 耦合变化时, d_{v3} 高于 0.0015, λ_s 高于 0.0006 时, 减压器稳定性良好. 由图 3(f), d_{v3} , L_2 耦合变化时, d_{v3} 介于 0.002 ~ 0.003 之间时, L_2 高于 0.1 效果好, d_{v3} 高于 0.003 时, L_2 取值高于 0.05 较好. 由图 3(h), d_{v3} , C_m 耦合变化时, d_{v3} 低于 0.004 时, 随着 d_{v3} 变小, C_m 的取值范围由高于 0.8×10^6 变为高于 1.6×10^6 才能使稳定性较好, 而当 d_{v3} 高于 0.004 时, C_m 高于 0.8×10^6 时稳定性较好.

由上分析可知, 在两个结构参数耦合变化时, 由于互相的影响, 结构参数在保证稳定性的前提下的取值范围会发生变化, 如图 3(b)何图 3(d)中 λ_s 在保证稳定性前提下的取值范围相差就较大, 因此耦合变化中结构参数的设计很重要.

3.3 三结构参数



三结构参数(下文简称三参数)变化下, 样本点分布如图 4.


表 6、表 7 为 BP 与 SVM 预测模型的误差.
BP 和 SVM 得到的预测图形如图 5.

图 5(a)中, BP 预测图形在左上角有奇异区域和断层现象; 图 5(c)与图 5(e)中, BP 预测图形有断层现象, 这是由样本点组的稀疏性和残缺性造成. SVM 的预测图形是可信的, 表现良好的泛化性.

依据图 5(b)可知, d_{v3} , M_{vc} , λ_s 耦合变化时, 若 d_{v3} 低于 0.003, 稳定性不会太好, d_{v3} 高于 0.003 并逐渐变大时, 随着 M_{vc} 自 0.8 变小, 若使

稳定性较好, λ_s 的取值由高于 0.0025 逐渐放宽至高于 0.0002. 如上结论限于条件无法于平面图中完全体现出. 这里本文结论与文献[11]中结论不同, 文献[11]结论为: 当 d_{v3} 增大到一定值后, 不管 M_{vc} , λ_s 如何变化, 稳定性都非常好^[11].





(c) d_{v3} , C_m , λ_s 样本点组分布情况

图 4 三参数样本分布情况


Fig. 4 Distribution of samples of tri-parameter

表 6 BP 预测模型误差情况 (三参数)


Table 6 Error situation of BP prediction models (tri-parameter)				
参数	e_{trabs}	$e_{trre} / \%$	e_{unabs}	$e_{unre} / \%$
$d_{v3}, M_{vc}, \lambda_s$	0.01334	9393	0.01658	15355
L_1, M_{vc}, λ_s	0.00329	2.972	0.00452	3.588
d_{v3}, C_m, λ_s	0.00503	6287	0.00537	6006

表 7 SVM 预测模型误差情况 (三参数)


Table 7 Error situation of SVM prediction models (tri-parameter)				
参数	e_{trabs}	$e_{trre} / \%$	e_{unabs}	$e_{unre} / \%$
$d_{v3}, M_{vc}, \lambda_s$	0.01179	8258	0.01809	17909
L_1, M_{vc}, λ_s	0.00209	18.05	0.00374	2.695
d_{v3}, C_m, λ_s	0.00370	4174	0.00411	4461




(a) BP 的 d_{v3} , M_{vc} , λ_s 预测图形



(b) SVM 的 d_{v3} , M_{vc} , λ_s 预测图形



(c) BP 的 L_1 , M_{vc} , λ_s 预测图形



(d) SVM 的 L_1 , M_{vc} , λ_s 预测图形




图 5 BP 和 SVM 预测图形的对比

Fig. 5 Comparison of BP and SVM on prediction graphics

依据图 5(d)可知, d_{v3} , M_{vc} , λ_s 耦合变化时, M_{vc} 低于 0.2, λ_s 取 0.003 附近的值时, 稳定性会比较好, 同时可以得到此时 L_1 对稳定性影响很小的结论.

依据图 5(f)可知, d_{v3} , C_m , λ_s 耦合变化时, 若 d_{v3} 高于 0.005, C_m 高于 2×10^6 , λ_s 对稳定性影响不大, 若 d_{v3} 在 0.01 附近, C_m 在零附近, λ_s 需要高于 0.001. 若 d_{v3} 低于 0.005, C_m 低于 2×10^6 , 稳定性基本取决于 d_{v3} 和 C_m . 因此可以得到此种情况下 λ_s 对稳定性影响有限的结论.

3.4 SVM 的过拟合控制


过拟合是指预测模型对训练样本拟合效果好, 对未训练样本拟合效果明显变差. 用 SVM 训练样本的过程中, 应遵循避免过拟合现象同时降低绝对误差和相对误差等参考指标的原则选择 SVM 的核函数参数. 本文使用的核函数有两个可调参数, 通过调节参数可以使 SVM 的预测模型在训练误差和预测误差之间取得一个折中. 实际的建模过程中 (ω, σ) 由 (1, 1) 起始取值, 此时训练误差与预测误差比较接近, 在此基础之上对核函数参数进行调整, 以获得较为优良的预测模型. 表 8 为研究 M_{vc} 参数时 SVM 核函数的两个参数不同组合对应的绝对误差和相对误差率.

表 8 中 (ω, σ) 在 (0.2, 0.2) 处未训练样本绝对误差和相对误差率均为最低, 随着两个参数的降低, 过拟合现象越来越严重. 图 6 为 (ω, σ) 取 (0.2, 0.2) 和 (1, 1) 时 M_{vc} 的预测图形.


表 8 SVM 不同参数组合误差情况

Table 8 Error situation of SVM in different parameters

ω	σ	e_{trabs}	$e_{trre} / \%$	e_{unabs}	$e_{unre} / \%$
1	1	0.001644	0.7913	0.001727	0.8186
0.9	0.9	0.001457	0.6915	0.001545	0.7246
0.8	0.8	0.001283	0.6015	0.001587	0.7367
0.7	0.7	0.001161	0.5421	0.001598	0.7399
0.6	0.6	0.001026	0.4732	0.001404	0.6451
0.5	0.5	0.0009908	0.4574	0.001459	0.6704
0.4	0.4	0.0009406	0.4346	0.001361	0.6238
0.3	0.3	0.0008636	0.3994	0.001341	0.6109
0.2	0.2	0.0006558	0.3048	0.001256	0.5730
0.1	0.1	0.0001177	0.0551	0.001524	0.6911



(a) (ω, σ) 取 (0.2, 0.2) 时 M_{vc} 预测图形



(b) (ω, σ) 取(1, 1)时 M_{vc} 预测图形

图 6 SVM 的 M_{vc} 预测图形

Fig. 6 Prediction graphic of M_{vc} by SVM

(ω, σ) 取(1,1)时预测图形更光滑,但是各项误差参考值均高于(0.2,0.2)。若各项误差参考值均在忍受范围之内,选取(1,1)更容易获得直观上的信赖。而实际的稳定性图形,(0.2,0.2)更接近于真实情况。相比之下,BP 无法像 SVM 一样更加灵活的在光滑和误差之间进行调节,SVM 若倾向于更光滑,则可以展现与 BP 相似的性能。SVM 的优势此时体现在误差和过拟合的忍受范围内可以提供更好的模型。

3.5 SVM 和 BP 在小样本空间泛化性的对比

模型的预测能力也称泛化性。限于实际条件,仿真数据的样本生成速度很慢,平均4h才可以生成一个样本,因此本文所研究数据集是稀疏的,维数越高则稀疏程度越高。同样实验数据也是宝贵稀少的,因此泛化性很重要。

通过图 3、图 5 中双参数和三参数变化的 7 个例子,可以知道在高维情形下,样本的稀疏性会严重影响 BP 的泛化性,SVM 的泛化性表现良好。由此可知,样本空间对 BP 的泛化性影响很大,而对 SVM 的泛化性影响较小。文献[10]中 BP 是基于经验风险最小化,SVM 是基于结构风险最小化,本文与文献[10]结构一致。即 BP 的泛化性基于样本空间,SVM 的泛化性基于方法本身。

单参数 C_m ,双参数 $d_{v3}, \lambda_s; d_{v3}, L_2; d_{v3}, C_m$ 和三参数 $d_{v3}, M_{vc}, \lambda_s; d_{v3}, C_m, \lambda_s$ 情形中存在相对误差率过大的现象,这是由于稳定性值变化十分剧烈,相差甚至可达数万倍,表 9 为 SVM 的 $d_{v3}, M_{vc}, \lambda_s$ 预测模型未训练样本中相对误差率最高的

5 例,最高的样本点的相对误差率为483 041%。

表 9 高相对误差率样本

Table 9 Samples of high relative error rate

$S_{GPRR1-p_2}$ 原值/ 10^5	$S_{GPRR1-p_2}$ 预测值	相对误差率/%
1.465	0.070 80	483 041
1.486	0.068 81	462 962
1.466	0.014 77	100 668
1.505	0.011 28	74 826
1.465	0.006 281	42 763

实验表明, $S_{GPRR1-p_2}$ 值在 1.5×10^5 附近的样本点(属于稳定区域)在预测模型中同样属于稳定区域,预测效果良好。若暂不考虑这些点,可以看到如表 10 所示,相对误差率大幅降低,而实际的预测模型的预测能力与原来基本没有区别。此时相对误差率参考意义不大,预测模型是可信的。

表 10 剔除部分点后的误差情况

Table 10 Error situation after eliminating part points

参数	e_{trabs}	$e_{ttre}/\%$	e_{unabs}	$e_{unre}/\%$
C_m	0.003 53	10.032	0.006 66	28.262
d_{v3}, λ_s	0.010 55	12.004	0.019 95	24.500
d_{v3}, L_2	0.008 65	17.187	0.011 60	21.404
d_{v3}, C_m	0.008 03	7.804 9	0.010 50	7.043 2
$d_{v3}, M_{vc}, \lambda_s$	0.015 46	26.216	0.021 38	16.559
d_{v3}, C_m, λ_s	0.019 32	30.461	0.038 84	68.009

在当前的预测模型中,虽然存在某些情况相对误差率过大的情况,预测模型的可信度并没有降低。如果可以通过改善核函数及其参数降低模型的相对误差率,SVM 的泛化性优势会更大。

4 结 论

总结本文,可以得到如下结论:

1) 对于稀疏易有残缺的小样本空间,SVM 可以更好地适应数据集,生成可信赖的预测模型,有很好的泛化性。特别在本文研究的双参数、三参数情形下,BP 的泛化能力明显弱于 SVM。

2) 在二维和三维的结构参数耦合变化情形下,对比 SVM 和 BP 模型的预测图形和误差分析,给出可以信赖的减压器设计的决策支持参考。

3) 对于未来需要研究的更加复杂的模块(相对于减压器),会涉及更多的结构参数组合,数据

集的稀疏程度会更高。维数更高的样本空间中，SVM 会展现更好的性能。

SVM 的性能仍有提升的空间，下一步的工作可以通过改进算法以及核函数及其参数的选取来降低相对误差率。

参考文献：

[1] 张雪梅,张黎辉,金广明,等. 减压器动态过程的数值仿真[J]. 航空动力学报,2004,19(4):541-545.
ZHANG Xuemei, ZHANG Lihui, JIN Guangming, et al. Numerical simulation of the dynamic process for pressure regulator[J]. Journal of Aerospace Power, 2004, 19(4): 541-545. (in Chinese)

[2] Rami E G, Jean-Jacques B, Pascal G, et al. Stability study and modeling of a ppressure regulating station[J]. International Journal of Pressure Vessels and Piping, 2005, 82(1):51-60.

[3] Rami E G, Jean-Jacques B, Bruno D, et al. Modelling of a pressure regulator[J]. International Journal of Pressure Vessels and Piping, 2007, 84(4):234-243.

[4] Zafer N, Luecke G R. Stability of gas pressure regulators[J]. Applied Mathematical Modelling, 2008, 32(1):61-82.

[5] 赖林,李清廉,郑丽,等. 大流量气体减压器振动问题研究[J]. 国防科学技术大学学报,2009,31(2):1-4.
LAI Lin, LI Qinglian, ZHENG Li, et al. Research of the vibration failure of the large flux PRV[J]. Journal of National University of Defense Technology, 2009, 31(2):1-4. (in Chinese)

[6] 尤裕荣,曾维亮. 气体减压阀的稳定性分析[J]. 火箭推进, 2009, 35(5):34-38.
YOU Yurong, ZENG Weiliang. Analysis on pneumatic pressure reducing valve stability[J]. Journal of Rocket Propulsion, 2009, 35(5):34-38. (in Chinese)

[7] 何德胜,郭正,鲍福廷,等. 采用流固耦合方法数值分析减压器动态响应[J]. 固体火箭技术,2010,33(6):713-718.
HE Desheng, GUO Zheng, BAO Futing, et al. Numerical analysis about dynamic response of a pressure regulation valve using fluid and solid coupling method[J]. Journal of Solid Rocket Technology, 2010, 33(6):713-718. (in Chinese)

[8] 陈阳,蔡国飙,张振鹏,等. 双组元统一推进系统减压器稳性仿真[J]. 北京航空航天大学学报,2010,36(10):1135-1139.
CHEN Yang, CAI Guobiao, ZHANG Zhenpeng, et al. Numerical simulation on dynamic stability of pressure reducing regulator in integral bipropellant propulsion system

[J]. Journal of Beijing University of Aeronautics and Astronautics, 2010, 36(10):1135-1139. (in Chinese)

[9] 郑赞韬,池元成,陈阳. 基于均匀设计的粒子群优化在减压器优化设计中的应用[J]. 航空动力学报,2012,27(4):882-889.
ZHENG Yuntao, CHI Yuancheng, CHEN Yang. Particle swarm optimization of pressure reducing regulator based on uniform design[J]. Journal of Aerospace Power, 2012, 27(4):882-889. (in Chinese)

[10] Vapnik V N. The nature of statistical learning theory[M]. 2nd ed. New York:Springer-Verlag Incorporation, 2000.

[11] 陈经禄,王拥军,陈阳. 使用 BP 神经网络模型研究逆向卸荷膜片式减压器的稳定性能[J]. 航空动力学报,2013,28(9):2112-2120.
CHEN Jinglu, WANG Yongjun, CHEN Yang. Research of stability of the pressure reducing regulator using BP model[J]. Journal of Aerospace Power, 2013, 28(9):2112-2120. (in Chinese)

[12] 陈阳,高芳,张黎辉,等. 减压器动态仿真的有限体积模型[J]. 推进技术,2006,27(1):9-14.
CHEN Yang, GAO Fang, ZHANG Lihui, et al. Finite volumemodel for numerical simulation on dynamic process of pressure reducing regulator [J]. Journal of Propulsion Technology, 2006, 27(1):9-14. (in Chinese)

[13] 陈阳,高芳,张振鹏,等. 气体薄膜调节阀控制系统工作过程的动态仿真[J]. 火箭推进,2006,32(6):28-34.
CHEN Yang, GAO Fang, ZHANG Zhenpeng, et al. Dynamic simulation of working process for control system of a pneumatic diaphragm control valve[J]. Journal of Rocket Propulsion, 2006, 32(6):28-34. (in Chinese)

[14] Cristianini N, Shawe-Taylor J. An introduction to support vector machines and other Kernel-based learning methods [M]. Cambridge:Cambridge University Press, 2000.

[15] HAN Jiawei, Kamber M. 数据挖掘概念与技术[M]. 范明, 孟小峰, 译. 北京:机械工业出版社, 2007.

[16] ZHENG Qifu, HUANG Haifeng, ZHANG Youzheng, et al. Support vector machine based on universal Kernel function and its application in quantitative structure-toxicity relationship model[R]. Chengdu: International Forum on Information Technology and Applications, 2009.

[17] Vapnik V, Chapelle O. Bounds on error expectation for support vector machine [M]. Cambridge, MA: Massachusetts Institute of Technology Press, 2000.

[18] Vapnik V. An overview of statistical learning theory[J]. IEEE Transactions on Neural Networks, 1999, 10(5):988-999.

(编辑:王碧珺)