

文章编号: 1000-8055(2010)09-2139-09

基于稀疏最小二乘支持向量机的航空发动机动态过程辨识

王海涛, 谢寿生, 武 卫, 苗卓广, 吴 勇
(空军工程大学 工程学院 飞机推进系统实验室, 西安 710038)

摘 要: 针对现有最小二乘支持向量机(LS-SVM)稀疏性不足的难题,提出一种稀疏化策略,应用此方法建立了航空发动机动态过程模型.在对原始样本预求解过程中,该策略使用改进 Gram-Schmidt 正交化算法对非线性映射矩阵实施递归分解,同时以阈值监督输出向量的残差化过程,从而优选训练样本,降低样本规模,节省内存,提高 LS-SVM 学习速度.仿真表明,基于优选样本的学习模型较之其他训练样本学习模型提高了回归精度和速度,验证了方法的可行性;基于实际试验数据建立的航空发动机动态过程模型在类似过程参数预测以及性能递推预估仿真表明,高压转子相对转速误差低于 0.2%,低压转子相对转速误差低于 0.35%,涡轮后燃气温度误差小于 3.5 °C,满足控制与仿真的需要.

关 键 词: 航空发动机; 非线性系统辨识; 性能预测; 仿真; 最小二乘支持向量机; 稀疏化策略
中图分类号: V235.1 **文献标识码:** A

Dynamic process identification of aircraft engine based on a novel sparse least square support vector machines

WANG Hai-tao, XIE Shou-sheng, WU Wei, MIAO Zhuo-guang, WU Yong
(Aircraft Propulsion System Laboratory, The Engineering Institute,
Air Force Engineering University, Xi'an 710038, China)

Abstract: A novel sparse strategy was proposed for the least square support vector machines regression, and the dynamic process identification of aircraft engine was analyzed in particular. In the process of solving the original sample, the special nonlinear mapping matrix was recursively decomposed by using the modified Gram-Schmidt method, and the excellent sample was selected when the square of remaining output reached the threshold value; thus, the new sample quantity was reduced and the least square support vector machines (LS-SVM) regression model training speed was enhanced by saving memory. The simulation result shows that, the algorithm has better sparseness, less training time and equivalent precision; and the aircraft engine dynamic process simulation shows that the predicting error of high rotor's relative rotational speed is less than 0.2%, the predicting error of the low rotor's relative rotational speed is less than 0.35%, and the predicting error of the temperature at the exit of high-pressure turbine is less than 3.5 °C. The model is suitable for aircraft engine's control and system simulation.

Key words: aircraft engine; nonlinear system identification; performance forecast; simulation; least square support vector machines; sparse strategy

收稿日期: 2009-08-02; **修订日期:** 2010-01-12

基金项目: 2110 工程实验室建设项目

作者简介: 王海涛(1981-),男,安徽太和人,博士生,主要从事航空推进系统建模与控制研究. E-mail: wanght_v2009@126.com

航空发动机动态过程模型在控制算法设计与仿真、性能预测、状态监控与故障诊断等领域有着重要作用^[1]. 采用非线性系统辨识理论建立发动机大偏离动态过程模型是控制领域重要研究方向之一, 国内外均开展了相关研究, 如国内早期采用神经网络及其改进方法进行研究^[2-4], 近几年采用神经网络作为辨识器开展了相关的自适应控制、解耦控制研究等^[5-8], 均取得较好效果. 国外基于神经网络模型以及多项式非线性模型等也开展了相关研究, 如内模控制、预测控制等^[9-11]. 然而神经网络存在结构不易确定, 训练时间过长以及训练方法易陷入局部极小值的不足, 而多项式模型也存在对结构敏感的问题.

随着智能算法的发展, 采用结构风险最小化准则的支持向量机避免了传统机器学习中的过学习、维数灾难、局部极小等问题^[12-13], 具有良好的泛化能力, 在航空发动机模型辨识中也取得较好的应用^[14-15]. 根据实际需要, Suykens 提出最小二乘支持向量机 (least squares support vector machines, 简称 LS-SVM), 用于解决分类和函数估计问题^[16]. 这种方法将原先的不等式约束转化为等式约束, 用求解线性规划方法代替支持向量机的二次规划方法, 提高了计算效率, 将支持向量机用于工程实际向前推进一步.

然而恰恰由于等式约束, 最小二乘支持向量机牺牲了稀疏性. 为此, 国内外学者进行了大量研究, 如 Suykens 等提出了基于最小支持权重的剪枝算法^[17], Jiao 等提出了一种用于分类的快速剪枝算法^[18], 赵永平等为缩短训练时间在 Jiao 法基础上更提出了改进算法^[19], 均取得较好效果. 本文基于改进递归 Gram-Schmidt 正交化算法提出一种稀疏化策略, 将回归稀疏性难题转化为样本优选问题, 降低参训样本规模, 提高训练速度, 并基于该方法开展航空发动机动态过程辨识及仿真研究.

1 最小二乘支持向量机基本算法

对于个数为 l 的样本序列 $(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i), \dots, (x_l, y_l)$, 其中输入量 $x_i \in \mathbb{R}^n$, 输出量 $y_i \in \mathbb{R}$, 采用最小二乘支持向量机进行函数估计, 优化问题可以描述如下:

$$\min \quad \phi(w, b, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^l e_i^2 \quad (1)$$

$$\text{s. t.} \quad \begin{cases} y_i = w^T \phi(x_i) + b + e_i \\ i = 1, 2, \dots, l \end{cases} \quad (2)$$

其中 $\phi(\cdot): \mathbb{R}^n \rightarrow \mathbb{R}^{nh}$, 是将输入向量映射到高维特征空间的映射函数; 权值向量 $w \in \mathbb{R}^{nh}$, 误差变量 $e_i \in \mathbb{R}$ 和偏置值 $b \in \mathbb{R}$; 惩罚系数 $\gamma > 0$. 定义 Lagrange 函数形式为

$$L(w, b, e, \alpha) = \phi(w, b, e) + \sum_{i=1}^l \alpha \{ w^T \phi(x_i) + b + e_i - y_i \} \quad (3)$$

其中 Lagrange 乘数 $\alpha \in \mathbb{R}$. 根据 KKT (Karush-Kuhn-Tucker) 条件对上式进行优化, 有如下结果:

$$\frac{\partial L}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^l \alpha \phi(x_i) \quad (4)$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^l \alpha = 0 \quad (5)$$

$$\frac{\partial L}{\partial e_i} = 0 \Rightarrow \alpha = -\gamma e_i, \quad i = 1, 2, \dots, l \quad (6)$$

$$\frac{\partial L}{\partial \alpha} = 0 \Rightarrow w^T \phi(x_i) + b + e_i - y_i = 0 \quad (7)$$

将式(4)、式(6)代入式(7)中, 可得

$$\sum_{j=1}^l \alpha \phi(x_j)^T \phi(x_i) + b + \frac{\alpha}{\gamma} - y_i = 0 \quad (8)$$

整理式(5)和式(8)可以得到最小二乘支持向量机的基本表达形式, 如式(9)所示.

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \Omega + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (9)$$

其中 $y = [y_1, y_2, \dots, y_l]^T$; $\mathbf{1} = [1, 1, \dots, 1]^T$; $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_l]^T$; $\mathbf{I}$ 为单位阵; $\Omega = \Omega_{l \times l}$, 其中 $\Omega_{i,j} = K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$, $i, j = 1, 2, \dots, l$; $K(x_i, x_j)$ 为核函数. 记

$$H = \begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \Omega + \gamma^{-1} \mathbf{I} \end{bmatrix}, \quad Y = \begin{bmatrix} 0 \\ y \end{bmatrix}, \quad \theta = \begin{bmatrix} b \\ \alpha \end{bmatrix},$$

因此式(9)也可描述为

$$H\theta = Y \quad (10)$$

对式(9)或式(10)求解, 即得到系数 α 和 b , 从而得到最小二乘支持向量机回归模型, 其表达式如下:

$$y(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (11)$$

由于最小二乘支持向量机没有 ε 不敏感域的概念, 故其解不具有稀疏性. 另外从约束条件以及回归模型也可以看出, l 个训练样本对目标输出都有贡献, 但如果能从 l 个样本中选择出 n_{sv} 个较优样本, 即间接实现了稀疏性. 仍以式(9)为例, 下面给出乘子系数的详细解法.

在此定义 $Q = \Omega + \gamma^T I$, 将式(9)展开可以得到如下表达式:

$$\begin{cases} \mathbf{1}^T \mathbf{a} = 0 \\ \mathbf{1}b + Q\mathbf{a} = \mathbf{y} \end{cases} \quad (12)$$

由式(12)可以得到

$$Q^{-1}\mathbf{1}b + \mathbf{a} = Q^{-1}\mathbf{y} \quad (13)$$

所以 $\mathbf{1}^T Q^{-1}\mathbf{1}b + \mathbf{1}^T \mathbf{a} = \mathbf{1}^T Q^{-1}\mathbf{y}$, 由于 $\mathbf{1}^T \mathbf{a} = 0$, 所以 $\mathbf{1}^T Q^{-1}\mathbf{1}b = \mathbf{1}^T Q^{-1}\mathbf{y}$. 由于 Q 是对称正定的, 因此 $b = (\mathbf{1}^T Q^{-1}\mathbf{y}) / (\mathbf{1}^T Q^{-1}\mathbf{1})$, 将该结论代入式(13), 可以得到: $\mathbf{a} = Q^{-1}(\mathbf{y} - \mathbf{1} \times b)$.

整理上述过程, 可得:

$$\begin{cases} b = \frac{\mathbf{1}^T Q^{-1}\mathbf{y}}{\mathbf{1}^T Q^{-1}\mathbf{1}} \\ \mathbf{a} = Q^{-1}(\mathbf{y} - \mathbf{1} \times b) \end{cases} \quad (14)$$

因此, 通过式(14)可以确定 Lagrange 乘子系数 $\mathbf{a}$ 和偏置 b , 最终建立模型.

2 稀疏化策略

由上分析可知, 建立最小二乘支持向量回归模型的问题最终归结于系数的求解, 即求解高维线性方程组, $H\theta = Y$, 其中高维映射矩阵 $H = [h_1, h_2, \dots, h_n]$, $n = l+1$; $Y = [0, y_1, \dots, y_l]^T$; $\theta = [b, \mathbf{a}, \mathbf{a}, \dots, \mathbf{a}]^T$, $\mathbf{a}, i = 1, 2, \dots, l$ 对应为每一个训练样本的支持权重. 因此, 模型稀疏性可归结为从 l 个训练样本中选择 n_{sv} ($n_{sv} \leq l$) 个最优样本. 为此, 本文提出基于改进的 CGS (Classical-Gram-Schmidt) (MCGS) 算法^[21] 解决最优支持向量选择的策略, 将最优样本的选择问题转化为输入量 h_i 对输出向量 Y 的影响问题.

MCGS 算法基于选主元策略决定待直交化矩阵 H 的列向量的引入次序, 并同时以 CGS 算法对其实施直交化. 记重排后的矩阵为 H_c , 相应的, 其直交化矩阵为 $Q_c = [q_1, q_2, \dots, q_n]$, 最小二乘解为 θ_c , 则择优算法流程如下:

Step 1: 对于 $i = 1, 2, \dots, n$, 记 $q_i^{(i)} = h_i$, 计算 $g_i^{(i)} = \langle q_i^{(i)}, Y \rangle / d_i^{(i)}$; $d_i^{(i)} = \langle q_i^{(i)}, q_i^{(i)} \rangle$
 $[e_{rr}]_i^{(i)} = (g_i^{(i)})^2 / d_i^{(i)} / \langle Y, Y \rangle$

在 $[e_{rr}]_i^{(i)}, i = 1, 2, \dots, n$ 中选择最大值, 假定 $[e_{rr}]_1^{(1)} = \max\{[e_{rr}]_i^{(i)}, 1 \leq i \leq n\}$, 则 $q_1 = q_1^{(1)}$ 项被选作矩阵 Q_c 的第一列, 并以 $g_1 = g_1^{(1)}$ 作为 G_c 的第一个元素, 记 $[e_{rr}]_1 = [e_{rr}]_1^{(1)}$. 同时记 $d_1 = d_1^{(1)} = \langle q_1, q_1 \rangle$, 相应的, 以 h_{i_1} 作为矩阵 H_c 的第一列, 不妨仍记为 h_1 ; θ_{i_1} 作为相应最小二乘解 θ_c

的第一个元素, 同样仍记为 θ . 记 $\text{index}(1) = I_1$. 计算 $Y^{(1)} = Y - g_1 q_1$.

Step k ($k > 1$): 对于 $i = 1, 2, \dots, n$, 且 $i \notin \{\text{index}(1), \text{index}(2), \dots, \text{index}(k-1)\}$, 执行如下算法, 对于 $j = 1, 2, \dots, k-1$,

$$\begin{aligned} r_{jk}^{(i)} &= \langle q_j, h_i \rangle / d_j; \quad q_k^{(i)} = h_i - \sum_{j=1}^{k-1} r_{jk}^{(i)} q_j; \\ d_k^{(i)} &= \langle q_k^{(i)}, q_k^{(i)} \rangle; \quad g_k^{(i)} = \langle q_k^{(i)}, Y^{(k-1)} \rangle / d_k^{(i)}; \\ [e_{rr}]_k^{(i)} &= (g_k^{(i)})^2 / d_k^{(i)} / \langle Y, Y \rangle. \end{aligned}$$

下面同样对 $[e_{rr}]_k^{(i)}, i \in \{\text{index}(1), \text{index}(2), \dots, \text{index}(k-1)\}$, 进行最大值的筛选, 假设 $[e_{rr}]_k^{(i_k)} = \max\{[e_{rr}]_k^{(i)}, 1 \leq i \leq n, i \notin \{\text{index}(1), \text{index}(2), \dots, \text{index}(k-1)\}\}$, 则 $q_k = q_k^{(i_k)}$ (相应于矩阵 H 的 h_{i_k}), 被选作矩阵 Q_c 的第 k 列, 并以 $g_k = g_k^{(i_k)}$ 作为 G_c 的第 k 个元素, $[e_{rr}]_k = [e_{rr}]_k^{(i_k)}$. 相应的, 以 h_{i_k} 作为矩阵 H_c 的第 k 列, 同理仍记为 H_{i_k} , 并以 θ_{i_k} 作为相应的最小二乘解 θ_c 的第 k 个元素, 同样不妨仍记为 θ . 记 $d_k = d_k^{(i_k)} = \langle q_k, q_k \rangle$, 记 $\text{index}(k) = I_k$. 计算 $Y^{(k)} = Y^{(k-1)} - g_k q_k$.

迭代过程在第 n_{sv} 步终止, 当且仅当残差序列 $\mathcal{E} = Y^{(n_{sv})}$ 满足 $J_N(n_{sv}) = \sqrt{\langle \mathcal{E}, \mathcal{E} \rangle} / N < \rho_{s1}$, 这里 ρ_{s1} 为设定的理想阈值, 其值可以通过系统输出向量的信噪比及迭代过程中基于残差的损失函数稳定值来设定, N 为数据采样长度. 以上是一个择优过程, 即选择出那些对输出向量 Y 影响较大的项.

当然, 在计算过程中如果某一迭代步骤中 $\langle q_k^{(i)}, q_k^{(i)} \rangle$ 小于某一预定较小值, 则模型中的相应项 h_i 将不被作为候选项, 以避免计算机编程中的浮点溢出^[20-22].

上面根据改进的 Gram-Schmidt 正交化算法将主要贡献项选择出来, 对于最小二乘支持向量机而言, 即间接选择出 n_{sv} 个较优支持向量 (即有序的稀疏化优选样本), 序号对应为 $\text{index}(1), \text{index}(2), \dots, \text{index}(n_{sv})$. 由于 $n_{sv} \leq l$, 因此间接实现了稀疏化. 基于优选样本再次训练, 即可得到新的相对稀疏型最小二乘支持向量机. 该稀疏化策略在对高维映射矩阵正交化过程中考虑了总体样本的影响, 采用阈值控制着迭代过程, 避免过拟合等, 进而从总体样本集中选择出较优样本, 避免了文献[17]中的多次训练回归机、循环迭代筛选样本的过程, 计算量较小, 间接实现了文献[17-19]中的剪枝法. 该过程采用正交化算法, 数值计算过程稳定.

3 仿真实例

采用最小二乘支持向量回归机拟合 Sinc 函数 $f(x) = \sin x/x, x \in [-10, 10]$, 说明稀疏性策略的有效性. 核函数为径向基函数, $k(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right)$, 通过网格搜索算法预先确定 $\sigma = 0.1, \gamma = 100$. 步骤如下:

3.1 样本产生与模型训练

在 $x \in [-10, 10]$ 内, 随机产生 500 个样本 $(x_1, y_1), (x_2, y_2), \dots, (x_{500}, y_{500})$. 根据这 500 个样本进行训练, 无疑会得到较高的拟合精度; 然而, 这 500 个样本是冗余的, 为此采用本文提出的稀疏化策略进行筛选. 设定输出残差比阈值为 0.001, 最终筛选出 89 个优良有序样本, 其余 411 个样本属于非重要项或称为冗余项.

3.2 模型测试仿真

根据这 89 个样本进行重新训练, 即可得到较优的拟合模型. 为了验证择优方法的有效性, 下面基于优选样本与其他抽样样本进行训练比较, 分成两类: 一类为择优样本, 其按影响重要性的次序已经排列; 一类是基于原始训练样本的随机选择样本.

测试输入为 $x = \sin[(i - 250)/100 \times \pi/4] \times 7.5, i = 1, 2, \dots, 501$. 分别取几个典型节点个数, 择优模型记为 model, 随机抽样训练模型记为 rand, 误差对比结果如表 1 所示.

表 1 平均误差对比

Table 1 Comparison of the average error

样本数/个	平均误差(model)	平均误差(rand)
29	0.5005	1.4756
39	0.4293	1.3695
49	0.0258	0.2415
59	0.0231	0.0292
69	0.0160	0.0191
79	0.0114	0.0133
89	0.0095	0.0122

由表 1 可知, 样本个数等于 49 时, 择优模型较之随机训练模型误差有明显不同, 两者对比分别如图 1 和图 2 所示, 其中图 1 为择优样本训练所得模型, 图 2 为随机样本训练所得模型, 可见经稀疏化择优模型精度较之同等数量随机样本训练模型精度高; 这种现象随着样本个数递减更加明

显, 随着样本个数的增加趋于模糊. 当然, 如果残差比设定的阈值放大, 则稀疏化程度更高, 但模型精度会有所下降; 反之, 若阈值减小, 则稀疏化程度低; 阈值为零, 则没有稀疏化, 因此阈值需要合理的设定.




图 1 稀疏择优样本训练模型输出与真实值的对比
Fig. 1 Comparison between the sparse model value and true




图 2 随机样本训练模型输出与真实值的对比
Fig. 2 Comparison between the rand model value and true

4 航空发动机动态过程辨识

4.1 动态过程模型描述

某发动机的非加力主控制系统, 表征发动机工作状态的参数主要有三个: 高压转子转速 N_2 , 低压转子转速 N_1 和涡轮后燃气温度 t_6 . 其调节规律主要是根据发动机进气总温分段保持其中一个物理参数或者相似参数不变; 其被控参数主要包括 N_2, N_1 和 t_6 等, 控制参数主要是主燃烧室燃油消耗量 w_f , 调节参数为进口导流叶片角 α 和喷口临界截面积 A_8 等. 因此, 该型发动机非加力主控制系统的动态过程其非线性动态映射可描述如式(15)所述

$$\begin{cases} N_2(k+1) = f_1(N_2(k), \cdots, N_2(k-l_1), N_1(k), \cdots, N_1(k-l_2), t_6(k), \cdots, t_6(k-l_3), \\ \quad w_f(k), \cdots, w_f(k-l_4), A_8(k), t_1(k), \alpha_1(k), \cdots, \alpha_1(k-l_5)) \\ N_1(k+1) = f_2(N_2(k), \cdots, N_2(k-l_1), N_1(k), \cdots, N_1(k-l_2), t_6(k), \cdots, t_6(k-l_3), \\ \quad w_f(k), \cdots, w_f(k-l_4), A_8(k), t_1(k), \alpha_1(k), \cdots, \alpha_1(k-l_5)) \\ t_6(k+1) = f_3(N_2(k), \cdots, N_2(k-l_1), N_1(k), \cdots, N_1(k-l_2), t_6(k), \cdots, t_6(k-l_3), \\ \quad w_f(k), \cdots, w_f(k-l_4), A_8(k), t_1(k), \alpha_1(k), \cdots, \alpha_1(k-l_5)) \end{cases} \quad (15)$$

其中 l_1, l_2, l_3, l_4 和 l_5 为输入时延,根据发动机动态惯性和控制特点分别设定 $l_1 = 2, l_2 = 2, l_3 = 2, l_4 = 2, l_5 = 1$; f_1, f_2 和 f_3 为非线性映射函数,即需要辨识的非线性关系. 根据该型发动机地面试车数据,分别以 N_2, N_1 和 t_6 作为输出设计学习机.

4.2 数据归一化及辨识分析

为了便于特征矩阵计算的收敛,首先依据下式将样本输入向量归一化于 $[0, 1]$ 区间,同时在模型输出阶段实施反归一化. 通过网格搜索算法预先设定 $\lambda = 153.68, \sigma = 10.51$, 保证数据的收敛. 在建模过程中设定阈值 0.001, 依据辨识用数据的 200 帧采样, 根据本文所提策略从中筛选出 67 个较优样本作为建模输入, 重新进行动态过程辨识建模, 下面进行类似过程的性能预测及性能递推预估仿真.

4.3 性能预测

为了验证辨识模型的精度, 分别将学习样本和同一台发动机类似过程的非辨识用样本重新输入, 使用辨识模型进行预测. 模型输出结果与发动机实际试验值对比如图 3~图 8 所示. 从对预测结果分析来看, 在较大动态范围内, 高压转子相对转速误差低于 0.2%, 低压转子相对转速低于




图 3 高压转速模型输出与试验值对比(辨识用过程)

Fig. 3 Comparison result of high rotor relative rotation speed between model simulation and test (data used in identification)

0.35%, 涡轮后燃气温度偏差低于 3.5 °C 在非辨识用过程中, 高低压转子转速均低于 0.2%, 涡轮后燃气温度低于 2 °C




图 4 低压转速模型输出与试验值对比(辨识用过程)

Fig. 4 Comparison result of low rotor relative rotation speed between model simulation and test (data used in identification)




图 5 涡轮后温度模型输出与试验值对比(辨识用过程)

Fig. 5 Comparison result of temperature at the exit of high pressure turbine between model simulation and test (data used in identification)

4.4 性能递推预估

在类似动态过程中, 如果已知控制供油量、高压压气机进口导流叶片角、喷口位置和 N_2, N_1 和 t_6 等的基准点, 则可以通过递推的方式给出动态




图 6 高压转速模型输出与试验值对比(非辨识用过程)

Fig. 6 Comparison result of high rotor relative rotation speed between model simulation and test (data not used in identification)




图 7 低压转速模型输出与试验值对比(非辨识用过程)

Fig. 7 Comparison result of low rotor relative rotation speed between model simulation and test (data not used in identification)




图 8 涡轮后温度模型输出与试验值对比(非辨识用过程)

Fig. 8 Comparison result of temperature at the exit of high pressure turbine between model simulation and test (data not used in identification)

过程的响应,估算出这些参数随时间的变化曲线.估算方法如图 9 所示.




图 9 动态过程模型性能递推估算方法

Fig. 9 Recursive method of dynamic process model

基本思想是依据某一初始时刻的 N_2 , N_1 和 t_6 作为基准点,根据当前时刻的 $w_f(k)$, $w_f(k-1)$, $\alpha(k)$, $t_1(k)$, $A_8(k)$ 等,递推出下一时刻的 $\hat{N}_2(k+1)$, $\hat{N}_1(k+1)$, $\hat{t}_6(k+1)$;将得到的模型输出作为新的基准点,然后将已知的 $w_f(k+1)$, $w_f(k)$, $\alpha(k+1)$, $t_1(k+1)$, $A_8(k+1)$ 等作为输入,递推下一时刻的 N_2 , N_1 和 t_6 .依次递推,不断迭代,从而预估出发动机动态过程的性能.

重新对上述辨识用过程和另一非辨识用过程进行性能估算仿真.其中对辨识用过程从第 10 帧开始进行预估仿真,以后的 N_2 , N_1 和 t_6 采用模型递推输出数据代替,递推了 80 帧,如图 10~图 12 所示.




图 10 高压转速预估值与试验值对比(辨识用数据)

Fig. 10 Contrast between recursive result of high rotor relative rotation speed and test (data used in identification)




图 11 低压转速预估值与试验值对比(辨识用数据)

Fig. 11 Contrast between recursive result of low rotor relative rotation speed and test (data used in identification)




图 12 涡轮后温度预估值与试验值对比(辨识用数据)

Fig. 12 Contrast between recursive result of temperature at the exit of high pressure turbine and test (data used in identification)

随后,依据上述辨识模型,又针对该台发动机另一次类似阶段的动态过程进行预估分析,如图 13~图 15 所示。

可以看出,递推预估过程的误差总体比预测过程偏大,但是仍具有较高精度,其中 N_2 、 N_1 小于 0.2%, t_6 小于 2°C;而在非辨识用数据采用递推估计结果与试验结果对比来看,也具有较高精度,其中 N_2 小于 0.2%, N_1 小于 0.25%, t_6 小于 3.5°C,保持了参数的变化趋势。总结对比上述预测及性能递推预估的仿真结果,最大误差对比如表 2 所示。综上所述,模型精度较高,满足控制与仿真的需要。




图 13 高压转速预估值与试验值对比(非辨识用数据)

Fig. 13 Contrast between recursive result of high rotor relative rotation speed and test (data not used in identification)




图 14 低压转速预估值与试验值对比(非辨识用数据)

Fig. 14 Contrast between recursive result of low rotor relative rotation speed and test (data not used in identification)




图 15 涡轮后温度预估值与试验值对比(非辨识用数据)

Fig. 15 Contrast between recursive result of temperature at the exit of high pressure turbine and test (data not used in identification)

表 2 预测与预估最大误差对比

Table 2 Contrast of max absolute error between forecast simulation and recursive simulation

参数类型	参数预测	递推预估
N_2 / % (辨识用)	0.1956	0.1353
N_1 / % (辨识用)	0.3263	0.2203
t_6 / °C (辨识用)	3.2347	1.8536
N_2 / % (推广泛化)	0.1106	0.1210
N_1 / % (推广泛化)	0.1803	0.1850
t_6 / °C (推广泛化)	0.9253	3.2513

5 结 论

本文基于改进 Gram-Schmidt 正交化递归算法提出最小二乘支持向量机的一种稀疏化策略,建立结构最优的简约支持向量回归模型,常规非线性函数的逼近仿真验证了所提方法的有效性.使用该方法以及某航空发动机地面试车数据建立了动态过程非线性模型,在类似阶段的动态过程预测以及性能递推预估仿真表明,模型精度较高,能够用于航空发动机状态监控、性能预测及类似动态过程仿真等.所提方法也可应用于其他工业过程模型辨识领域.

当然,该稀疏化策略中的阈值确定准则值得进一步研究:如何合理确定正交化过程阈值?阈值大小与模型精度之间有什么定量关系?阈值设定与系统输出所受噪声干扰强度有何定性和定量的影响?另外,由于本文辨识与泛化数据均为地面试验数据,进口条件如 t_1 等变化有限,因此,全飞行包线各区域的动态过程模型仍需开展相应的高空试验或高空台模拟试验,获取相应的更充分激励的数据.另外在更低转速范围时,还应考虑其他调节量(放气活门开度等);在加力过程中,还应考虑加力供油量等因素.以上这些方面都有待进一步研究.

参考文献:

[1] 孙健国.面向 21 世纪航空动力控制展望[J].航空动力学报,2001,16(2):97-102.

SUN Jianguo. Prospects of aeroengine control development in the early time of the 21th century[J]. Journal of Aerospace Power, 2001, 16(2): 97-102. (in Chinese)

[2] 刘小勇,樊思齐.采用 BP 网络辨识航空发动机数学模型[J].航空动力学报,1996,11(2):153-156.

LIU Xiaoyong, FAN Siqi. Aeroengine model identification

with back-propagation neuelnetworks[J]. Journal of Aerospace Power, 1996, 11(2): 153-156. (in Chinese)

[3] 谢寿生,樊思齐.采用内积原理建立航空发动机神经网络辨识模型[J].推进技术,1998,19(1):11-15.

XIE Shousheng, FAN Siqi. The set-up of neural network identification model for aeroengine using inner product principle[J]. Journal of Propulsion Technology, 1998, 19(1): 11-15. (in Chinese)

[4] 徐亮,黄金泉.适用于全包线的航空发动机 BP 网络模型的动态辨识[J].南京航空航天大学学报,2001,33(4):334-337.

XU Liang, HUANG Jinquan. Dynamic identification with neural networks for aircraft engines in the full envelope [J]. Journal of Nanjing University of Aeronautics and Astronautics, 2001, 33(4): 334-337. (in Chinese)

[5] 黄金泉,蔡红武,孙建国.航空发动机多变量三层神经网络控制[J].航空动力学报,1999,14(2):191-194.

HUANG Jinquan, CAI Hongwu, SUN Jianguo. Multivariable control for aeroengine with 3-lay neural networks[J]. Journal of Aerospace Power, 1999, 14(2): 191-194. (in Chinese)

[6] 郭迎清.航空发动机神经网络自适应控制研究[J].航空动力学报,2001,16(1):83-86.

GUO Yingqing. A new neural network adaptive control scheme research[J]. Journal of Aerospace Power, 2001, 16(1): 83-86. (in Chinese)

[7] 刘建勋,李应红,陈永刚,等.航空发动机递归神经网络分路式解耦控制[J].航空动力学报,2005,20(2):287-292.

LIU Jianxun, LI Yinghong, CHEN Yonggang, et al. Aeroengine separate decoupling control based on recursive neural networks [J]. Journal of Aerospace Power, 2005, 20(2): 287-292. (in Chinese)

[8] 朱玉斌,樊思齐,任新宇,等.基于 DRNN 网络的航空发动机多变量解耦控制[J].推进技术,2006,27(2):150-153.

ZHU Yubin, FAN Siqi, REN Xinyu, et al. A multivariable decoupling control based on DRNN for aeroengine [J]. Journal of Propulsion Technology, 2006, 27(2): 150-153. (in Chinese)

[9] Chiras N, Evans C, Rees D. Nonlinear gas turbine modeling using feed-forward neural networks [R]. GT-2002-30035, 2002.

[10] Chiras N, Evans C, Rees D. Global nonlinear modeling of gas turbine dynamics using NARMAX structure [J]. ASME Journal of Engineering and Power, 2004, 124(4): 817-826.

[11] Mu Junxia, Rees D. Approximate model predictive control for gas turbine engines[C] //Proceeding of the 2004 American Control Conference. Boston, Massachusetts: AACC, 2004:5704-5709.

[12] Vapnik V N. 统计学习理论的本质[M]. 张学工,译.北京:清华大学出版社,2000.

[13] 李应红,尉询楷,刘建勋.支持向量机的工程应用[M]. 北京:国防工业出版社,2004.

- [14] 尉询楷,李应红,王剑影,等. 基于支持向量机的航空发动机辨识模型[J]. 航空动力学报,2004,19(5):684-688.
WEI Xunkai, LI Yinghong, WANG Jianying, et al. A novel aeroengine identification model based on support vector machines[J]. Journal of Aerospace Power, 2004, 19(5): 684-688. (in Chinese)
- [15] 郝英,孙健国,杨国庆,等. 基于支持向量机的民航发动机故障检测研究[J]. 航空学报,2005,26(4):434-438.
HAO Ying, SUN Jianguo, YANG Guoqing, et al. Civil aviation engine fault detection using support vector machines[J]. ACTA Aeronautica et Astronautica Sinica, 2005, 26(4):434-438. (in Chinese)
- [16] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3):293-300.
- [17] Suykens J A K, Lukas L, Vandewalle J. Sparse approximation using least squares support vector machines[C] // Proc. of IEEE Int. Symposium on Circuits and System. Piscataway: IEEE, 2000:757-760.
- [18] Jiao L C, Bo L F, Wang L. Fast sparse approximation for least squares support vector machine[J]. IEEE Trans. on Neural Networks, 2007, 18(3):685-697.
- [19] 赵永平,孙健国. 一种快速稀疏最小二乘支持向量回归机[J]. 控制与决策,2008,23(12):1347-1352.
ZHAO Yongping, SUN Jianguo. Fast method for sparse least squares support vector regression machine[J]. Control and Decision, 2008, 23(12):1347-1352. (in Chinese)
- [20] Billings S A, Chen S, Korenberg M J. Identification of MIMO nonlinear systems using a forward regression orthogonal estimator[J]. International Journal of Systems Science, 1989, 49(6):2157-2189.
- [21] Chen S, Chng E S, Alkadhimi K. Regularized orthogonal least squares algorithm for constructing radial basis function networks[J]. International Journal of Control, 1996, 64(5):928-937.
- [22] 曹建福,韩崇昭,方洋旺. 非线性系统理论与应用[M]. 西安:西安交通大学出版社,2001:317-318.