

文章编号: 1000-8055(2007)01-0137-05

航空发动机的支持向量机 自适应 PID 控制

梁 华, 李应红, 尉询楷, 刘建勋
(空军工程大学 工程学院, 陕西 西安 710038)

摘 要: 首先介绍了支持向量机(SVM)的原理,建立了支持向量机回归(SVMR)模型.将 SVMR 与基于支持向量机的控制器相结合,组成自适应 PID 支持向量机控制(SVMC)系统.最后用于某型航空发动机,通过在选定的设计点处进行控制系统的设计,利用支持向量机强大非线性映射能力、网络结构的自动最优优化特性,使控制系统在发动机偏离设计点工作时控制系统仍保持很好的性能.为通用非线性控制提供了一种新的控制思路.

关 键 词: 航空、航天推进系统;支持向量机;航空发动机;自适应控制

中图分类号: V233.7

文献标识码: A

Support vector machines PID adaptive control in aeroengine

LIANG Hua, LI Ying-hong, WEI Xun-kai, LIU Jian-xun

(The Engineering Institute, Air Force Engineering University, Xi'an 710038, China)

Abstract: The support vector machine principal and the support vector machine return model are introduced first, and the self-adaptive PID support vector machines' controller is established. It makes use of support vector machines' strong nonlinear mapping ability, and network's structure is optimally auto-created. Finally, the aeroengine controller is designed at the design point. Application results in an aeroengine show that the controller possesses much better performance when the work of the aeroengine deviates from the design point. The presented control strategy introduces a new way for nonlinear control.

Key words: aerospace propulsion system; support vector machines; aero engine; self-adaptive control

航空发动机的工作具有高度的非线性和大时变特性,其工作参数不仅随工况变化,而且随飞行条件而变.要控制发动机,控制器必须具有极强的鲁棒性,常规的方法难以胜任,因此,建立基于非线性的预测控制模型是非常必要的^[1].

目前有些学者将神经网络用于航空发动机预测控制,并取得了许多成果^[2-4].但神经网络存在局部最小值、过拟合以及网络拓扑结构难以确定的问题;网络权值是在样本趋于无穷大假设下的

训练结果,但实际过程中得到的数据是有限的.特别是在航空航天等领域,样本数据更是缺乏.支持向量机专门针对小样本的统计问题而建立的,采用结构风险最小化原则,根据有限的样本信息在模型的复杂性和学习能力之间寻求最佳折衷,以期获得最好的泛化能力.得到的是全局最优点.支持向量机的拓扑结构由支持向量决定,避免了传统神经网络过于依靠经验的缺点^[5-9].本文首先介绍了支持向量机的基本原理,给出了基于支持向

量机的辨识模型, 设计了支持向量机自适应 PID 控制器. 最后应用于某型航空发动机转速自适应控制, 给出了应用结果和结论. 验证了控制模型的有效性和准确性.

1 回归型 SVM 简介

1.1 SVM 的结构

假设已知 x_t 预测 $\hat{x}_{t+1}$, 可建立 $f: R^m \rightarrow R$ 满足:

$$\hat{x}_{t+1} = f(x_t, x_{t-\tau}, \dots, x_{t-(m-1)\tau}) \tag{1}$$

考虑用支持向量机来完成对上述非线性映射的逼近. 结合混沌序列的要求, 所建立的支持向量机模型结构采用如图 1 所示的回归型支持向量机.




图1 SVM 预测器的结构
Fig. 1 Architecture of support vector regression machines

1.2 SVM 回归的基本原理

用于函数逼近的支持向量机基本原理是: 给定 l 组样本数据 $\{x_i, y_i\}, i = 1, 2, \dots, l$, 其中 $x_i \in R^m, y_i \in R$ 利用一个非线性映射 Φ 将数据 x 映射到高维特征空间 F , 并在这个空间进行线性逼近, 找到映射 f 使其能够很好的逼近给定数据组. 由统计学习理论可知, 该函数具有以下形式:

$$f(x) = (\omega \cdot \Phi(x)) + b, \Phi: R^m \rightarrow F, \omega \in F \tag{2}$$

则函数逼近问题等价于使如下泛函最小:

$$R_{reg}[f] = R_{mp}[f] + \lambda \|\omega\|^2 = \sum_{i=1}^l C(e_i) + \lambda \|\omega\|^2 \tag{3}$$

其中 $e_i = f(x_i) - y_i, l$ 表示样本容量, $C(\cdot)$ 是损失函数, λ 为规则化常数, x 为支持向量. 求解 (3) 式等价于求解如下的优化问题.

$$\begin{aligned} \min J &= \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i^* + \xi_i) \tag{4} \\ \text{s. t. } &\begin{cases} y_i - (\omega \cdot \Phi(x)) - b \leq \varepsilon + \xi_i^* \\ (\omega \cdot \Phi(x)) + b - y_i \leq \varepsilon - \xi_i \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{aligned}$$

式中: C 用于控制模型复杂度和逼近误差的折中, ε 用于控制回归逼近误差管道的大小, 应用中常常利用 (4) 式的对偶式, 同时引入核函数方法, 则 (4) 式转化为:

$$\begin{aligned} \max J &= -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(x_i, x_j) + \\ &\sum_{i=1}^l \alpha_i^* (y_i - \varepsilon) - \sum_{i=1}^l \alpha_i (y_i + \varepsilon) \tag{5} \\ \text{s. t. } &\begin{cases} \sum_{i=1}^l \alpha_i = \sum_{i=1}^l \alpha_i^* \\ 0 \leq \alpha_i \leq C \\ 0 \leq \alpha_i^* \leq C \end{cases} \end{aligned}$$

理论上, 位于边界上的点 (满足 $0 \leq \alpha_i, \alpha_i^* \leq C$), $\delta_k = \text{sign}(\alpha_k - \alpha_k^*)$ 可以得到预测误差的唯一确定值, 出于稳定性考虑, 推荐采用边界点上的平均值:

$$b = \text{average}_k \{ \delta_k + y_k - \sum_i (\alpha_i - \alpha_i^*) K(x_i, x_k) \}$$

求解上述凸二次规划得到的非线性映射可表示为:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x) + b \tag{6}$$

2 支持向量机自适应 PID 控制

2.1 SVM 自适应 PID 控制系统结构图

为了用 SVM 解决自适应 PID 控制问题, 本文采用了典型的辨识和控制结构, 如下图 2 所示. 图中: y 为被控对象的实际输出; $\hat{y}$ 为支持向量机辨识器 (SVMR) 的输出; e 为 y 与 $\hat{y}$ 之间的偏差, 即辨识误差, 它取决于 SVM 的近似能力; r 为参考输入; e 为参考输入 r 与系统输出 y 之间偏差. 支持向量机控制器 (SVMC) 的作用是使控制误差 e 尽可能地小, 即被控对象输出 y 很好地跟随参考输入 r .

2.2 支持向量机辨识器 (SVMR) 的设计

航空发动机的工作过程往往具有高度的非线性, 考虑用 SVMR 来建模其动态行为. 通常离散系统 $i+1$ 时刻的输入可以表示为:

$$y_{i+1} = f(y^i, \dots, y^{i-m+1}; r^i, \dots, r^{i-m+1}) = f(x^i)$$




图 2 SVM 自适应 PID 控制系统结构图
Fig.2 Structure of SVM self adaptive controlling system

其中:

$\mathbf{x}_i = (y_i, \dots, y_{i-n+1}; r_i, \dots, r_{i-m+1}), \mathbf{x} \in \mathbf{R}^{m+n}$

为了设计 SVM 辨识器, 首先考虑构造训练样本集 Z:

$$[(y_{n-1}, \dots, y_0, r_{n-1}, \dots, r_{n-m}), y_n] = (\mathbf{x}_n, y_n)$$
$$[(y_n, \dots, y_1, r_n, \dots, r_{n-m+1}), y_{n+1}] = (\mathbf{x}_{n+1}, y_{n+1})$$

采用支持向量机回归的方法就可以将非线性的样本数据映射为高维空间的线性输出:

$$y_{k+1} = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}_{k+1}) + b \tag{7}$$

$\mathbf{x}_i$ 为支持向量, 对应于 Vapnik 的 ϵ 不敏感损失函数的 $\beta = \alpha_i - \alpha_i^*$ 不为 0 的向量, 为第 i 个支持向量的输入. β 和 b 为对 (3) 式最小化时求出.

2.3 支持向量机控制器(SVMC)的设计

控制器的主要任务是基于 SVMR 产生的一个控制信号 e_c 使控制误差 e 最小. 由于控制过程是可逆的, 则 2.2 部分的逆模型为:

$$r_i = f^{-1}(y_{i+1}, \dots, y_{i-n}; r_i, \dots, r_{i-m})$$

本文采用 SVM 回归来估计过程的逆模型. 设:

$$\mathbf{y}_i = (y_{i+1}, \dots, y_{i-n}; r_{i+1}, \dots, r_{i-m})$$

对 $y_{i-p}p = 0, 1, \dots, n; i = 1, 2, \dots, l$ 其中 l 为样本数目, 若 $p < i$, 则 $y_{i-p} = y_0$. 于是可建立样本数据 $(\mathbf{y}_i, r_i)$, 建立 r_k 的支持向量机控制模型:

$$r_k = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(\mathbf{y}_i, \mathbf{y}_k) + b \tag{8}$$

SVMC 的数学描述为

输入层:

$$\begin{cases} l_1(k) = e(k) \\ l_2(k) = \sum_0^k e(k) \\ l_3(k) = \Delta e(k) = e(k) - e(k-1) \end{cases}$$

式中 $e(k) = r_k - y_k$ 为控制误差, $l_1(k), l_2(k), l_3(k)$ 分别对应 $e(k)$ 的比例、积分及微分.

输出层:
$$u(k) = \sum_{i=1}^3 \omega_i l_i(k)$$

该 PID 控制器采用的性能指标为:

$$\min J_c = \frac{1}{2} \sum_i [r_{k+1} - y_{k+1}]^2 \tag{9}$$

经过适当的训练后, y^k 将会逼近 y^k , 则对 (9) 式的最小化可以用 (10) 式代替.

$$\min J'_c = \frac{1}{2} \sum_i [r_{k+1} - y_{k+1}]^2 \tag{10}$$

即: 在对 SVMR 模块的控制信号进行在线训练的同时, 利用 (10) 式的训练指标即: $\frac{\partial J'_c}{\partial \omega} = 0$ 来

优化 ω , 进而修正控制器 SVMC 的参数, 利用支持向量机强大的非线性映射能力和网络结构的自动最优化特性实现复杂非线性系统的预测控制.

本文支持向量机回归的损失函数均采用 ϵ 不敏感损失函数, 这是因为 ϵ 不敏感损失函数具有很好的稀疏性. 对于非线性模型的核函数均采用 RBF 核函数 $k(\mathbf{x}_i, \mathbf{x}) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2 / 2\sigma^2)$ 其中的中心为支持向量 $\mathbf{x}_i$. 宽度 σ 是预先指定的一个常量.

3 SVM 自适应 PID 控制用于发动机控制系统

这里研究以燃油流量为输入, 以发动机低压转子转速为输出的转速控制系统. 某型航空涡扇发动机的传递函数为:

$$\frac{y(s)}{r(s)} = \frac{b_1 s + b_0}{s^2 + a_1 s + a_0} e^{-\tau s}$$

这里 r 为燃油流量, y 为低压转子的转速, τ 为燃烧延迟. 模型航空涡扇发动机在地面设计状态有: $a_1 = 4.6321, a_0 = 6.2688, b_1 = 0.7645, b_0 = 1.6725, \tau = 0.25$.

3.1 对象模型的辨识仿真

首先对 SVMC 在进行离线训练. 训练中输入信号采用 600 个随机信号. 前 400 个作为训练样本, 后 200 个用作测试样本. 由于被控系统为二阶系统, 故采用回归向量:

$$\mathbf{x}_i = [(y_i, y_{i-1}), r_i]$$

SVM 的设计参数为 $\sigma = 0.3, \epsilon = 0.001, C = 200$.

图 3 为测试集样本的拟合情况, 图 4 为测试集样本的拟合情况, 由图可见, 模型输出基本反映了训练和测试样本, 表明支持向量机具有较好的辨识精度和泛化能力. 这时的网络参数反映了设计点发动机燃油供油量与发动机低压转子转速 (n_1) 间的动态关系.




图 3 训练样本和模型输出对比

Fig. 3 Contrast of training results and training data




图 4 测试样本和模型输出对比

Fig. 4 Contrast of training results and test data

3.2 控制系统的仿真

以同样方式完成对 SVMC 的训练. 然后对 SVMR 模块的控制信号进行在线训练. 图 5 是在设计点处系统的阶跃响应. 由图可见, 系统调节时间为 1.5 s, SVMC 没有超调.




图 5 设计点处转速的阶跃响应

Fig. 5 Step response of n_1 at the design point

偏离了设计状态, 发动机的动态特性发生了

改变, 辨识器 SVMR 通过在线修正, 自动更新网络参数. 同时给控制器 SVMC 提供信息, 自动优化控制器的网络参数. 这样 SVMR 和 SVMC 通过自动学习, 优化自身参数, 直到达到满意的控制性能, 实现网络的自适应控制.

图 6 为在飞行条件($H = 8\text{ km}$, $Ma = 1.1$) 下系统的阶跃响应, SVMC 调节时间为 1.8 s, 且没有超调; 图 7 为在 $H = 14\text{ km}$, $Ma = 1.7$ 下系统的阶跃响应, SVMC 调节时间为 2.0 s, 只有轻微超调. 结果表明: SVMC 在偏离设计点的飞行条件下表现出了较好的控制效果, 满足了实际的要求.




图 6 $H = 8\text{ km}$, $Ma = 1.1$ 时转速的阶跃响应

Fig. 6 Step response of n_1 at $H = 8\text{ km}$, $Ma = 1.1$




图 7 $H = 14\text{ km}$, $Ma = 1.7$ 时转速的阶跃响应

Fig. 7 Step response of n_1 at $H = 14\text{ km}$, $Ma = 1.7$

4 结 论

本文提出了基于支持向量机的航空发动机转速自适应 PID 控制的理论, 并进行了仿真, 从仿真结果来看, 该方法具有预测控制精度高、推广泛化能力强的优点. 只需设计发动机设计点的控制器, 然后在非设计状态利用支持向量机强大非线性映射能力、网络结构的自动最优化特性, 实现了

发动机转速的自适应控制;而且该方法具有很强的自学习和自适应能力,非常适合像航空发动机这样大时变非线性的复杂控制系统.为机器学习理论在航空发动机控制中的应用开辟了新的途径,对通用的非线性控制具有一定的作用指导.

参考文献:

[1] 李应红, 魏询楷, 刘建勋. 支持向量机的工程应用[M]. 北京: 兵器工业出版社, 2004, 98-102.

[2] 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.

[3] HUNT K J, SBARBARO D. Neural networks for nonlinear adaptive model control[J]. IEE Proc D, 1991, 138(5): 428-435.

[4] 孙海忠. 支持向量机及其在控制中的应用[D]. 浙江: 浙江大学, 2003.

[5] Vapnik V. The nature of statistical learning theory [M]. New York: Springer, 1999.

[6] Smola A. A tutorial on support vector regression[R]. NG TR-98-030, Royal Holloway College, University of London, UK, 1998.

[7] CAO L J, GU Q M, Dynamic support vector machines for non-stationary time series forecasting[J]. Intelligent Data Analysis, 2002, 6(1): 67-83.

[8] HU Q, RANGAIAH G P. Adaptive internal model control of nonlinear process [J]. Chemical Engineering Science, 1999, 54(9): 1205-1218.

[9] 刘建勋, 李应红, 陈永刚, 等. 航空发动机 LQR 控制的模糊神经网络方法[J]. 航空动力学报, 2004, 19(6): 838-843.
LIU Jianxun, LI Yinghong, CHEN Yonggang, et al. Aero-engine LQR control based on fuzzy-neural networks [J]. Journal of Aerospace Power, 2004, 19(6): 838-843.