

一种基于支持向量机的内模控制方法

王定成^{1,2}, 方廷健²

(1. 中国农业大学 精细农业研究中心, 北京 100083; 2. 中国科学院 合肥智能机械研究所, 安徽 合肥, 230031)

摘要: 在基于数据的基础上, 采用 SVM 回归理论建立系统的正向模型和设计逆模控制器. 首先简要介绍了 SVMR 的原理, 然后将其应用于内模控制问题, 并建立了 SVMR 模型. 其次, 在控制过程可逆的条件下设计了 SVMR 控制器. 最后将该控制方法应用于一可逆非线性系统和具未知干扰的温室环境控制问题, 仿真结果表明该方法与神经网络 IMC 相比, 具有较简单的模型和较好的控制性能.

关键词: 支持向量机(SVM); 支持向量机回归(SVMR); 内模控制(IMC); 非线性

中图分类号: TP18 **文献标识码:** A

Internal model control approach based on support vector machines

WANG Ding-cheng^{1,2}, FANG Ting-jian²

(1. The Research Center of Precision Agriculture, China Agricultural University, Beijing 100083, China;

2. The Institute of Intelligent Machinery, Chinese Academy of Sciences, Anhui Hefei 230031, China)

Abstract: The system process was modeled and an inverse model controller using support vector machine regression (SVMR) was designed. First, the SVMR principle was briefly introduced. Second, the SVMR was applied to the internal model control (IMC) problem, and the SVMR internal model was developed. Third, an SVMR controller for internal model control problem was proposed under the inverse condition of control process. Finally, the control algorithm was applied to the reversible nonlinear system and greenhouse environment with unknown disturbance and compared with neural networks IMC using simulation, and the results showed that the SVMR IMC has a simplified model and good control performance.

Key words: support vector machines (SVM); SVMR; IMC; non-linear

1 引言 (Introduction)

内模控制具有设计简单、调节性能好、鲁棒性强以及能消除不可测干扰的影响等特点^[1,2], 支持向量机成功地克服了神经网络等学习方法的局部极小点、过学习以及结构和类型的选择过分依赖经验等固有的缺陷^[3], 因而, 采用支持向量机回归理论设计内模控制器的研究具有重要的意义.

2 支持向量机回归的原理 (Support vector machines regression (SVMR))

2.1 支持向量机 (Support vector machines (SVM))




图 1 支持向量机结构示意图

Fig. 1 Sketch map of SVM

支持向量机是从线性可分情况下的最优分类面发展而来的, 其基本思想可参见文献[3~5]. 支持向量机形式上类似一个神经网络, 输出是中间节点的线性组合, 每个中间节点对应一个支持向量. 其结构如图 1 所示.

2.2 支持向量机回归原理 (Support vector machines regression (SVMR))

支持向量机回归的基本思想是通过一个非线性映射 Φ 将数据映射到高维特征空间 F , 并在这个空间进行线性回归, 如式(1)所示:

$$f(x) = (w \cdot \Phi(x)) + b \quad (\Phi: \mathbb{R}^N \rightarrow F, w \in F), \quad (1)$$

其中 b 是阈值. 这样, 在高维特征空间的线性回归就对应于低维输入空间的非线性回归, 免去了在高维空间 w 和 $\Phi(x)$ 点积的计算. 由于 Φ 是固定不变的, 因此影响 w 的有经验风险的总和 R_{emp} 以及使其在高维空间平坦的 $\|w\|^2$, 则有

$$R(w) = R_{emp} + \lambda \|w\|^2 = \sum_{i=1}^l e(f(x_i) - y_i) + \lambda \|w\|^2. \quad (2)$$

l 表示样本的数目, $e(\cdot)$ 是损失函数, λ 是调整的常数. 最小化 $R(w)$ 即得用数据点表示的 w :

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \Phi(x_i). \quad (3)$$

其中 $\alpha_i - \alpha_i^*$ 是最小化 $R(w)$ 的解. 考虑方程(1)和(3), $f(x)$ 可表示为

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i, x) + b. \quad (4)$$

其中, $k(x_i, x) = \Phi(x_i) \cdot \Phi(x)$ 称为核函数, 是满足 Mercer 条件的任何对称的核函数, 对应于特征空间的点积^[5].

式(4)中的 b 取在边界上的一点就可以计算, 但为了稳定性的目的, 本文使用边界点上的平均值^[4]

$$b = \text{average}_k \{ \delta_k + y_k - \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i, x_k) \}. \quad (5)$$

其中, δ_k 为预测误差.

3 支持向量机内模控制 (Support vector machine internal model control (SVM IMC))

支持向量机内模控制结构如图 2 所示, 主要由内部模型、内模控制器以及输入、反馈通道的滤波器等组成.




图 2 SVMR 内模控制系统

Fig. 2 SVMR IMC system

3.1 SVMR 建立内部模型 (SVMR internal modeling)

考虑一个离散单输入单输出非线性模型

$$\begin{cases} y(k+1) = \\ f(y(k), \dots, y(k-n), u(k), \dots, u(k-m)), \\ y \in \Xi^n, u \in \Xi^m, m \leq n. \end{cases} \quad (6)$$

其中, u 和 y 分别代表对象的控制输入和系统的输出. 设有连续的控制输入

$$u(k-m), u(k-m+1), \dots, u(k)$$

(当 $k-m+r < 0$ 时, $u(k-m+r) = u(0), r = 0, 1, 2, \dots, m$)

和输出

$$y(k-n), y(k-n+1), \dots, y(k)$$

(当 $k-m+r < 0$ 时, $y(k-m+r) = y(0), r = 0, 1, 2, \dots, n$),

则相应的输出为 $y(k+1)$.

设

$$X(i) = (y(i), y(i-1), \dots, y(i-n), u(i), u(i-1), \dots, u(i-m)) (i = 1, 2, \dots, N),$$

则

$$y(i+1) = f(X(i)). \quad (7)$$

构造学习样本集 $(X(i), y(i+1))$, 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

$$\hat{y}(k+1) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(X(i), X(k)) + b. \quad (8)$$

$X(i)$ 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. $X(k)$ 为第 k 个支持向量机的输入. β 和 b 为优化式(2)的结果.

支持向量机回归的损失函数采用 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, 而其他的损失函数却没有稀疏性^[4]. 对于非线性模型的核函数一般采用 RBF 核函数 $k(X(i), X) = \exp(-|X - X(i)|^2 / 2\sigma^2)$. 其中的中心为支持向量 $X(i)$. 宽度 σ 是需要预先指定的一个常量.

模型可以通过离线学习也可以在线学习. 已经训练好的支持向量机回归模型可以进行在线模型修正. 在线模型修正采用文献[6]介绍的训练方法, 这种方法采用逐步更新的方法, 减少了训练的时间, 因而可以在线对所采集的数据进行模型修正. 每次修正后, 对其后的数据进行验证, 即通过比较其后的 M 个系统的实际输出 $y(k+1)$ 和估计的输出 $\hat{y}(k+1)$, 若 $|y(k+1) - \hat{y}(k+1)| > \epsilon$, 则认为所估计的模型为系统的模型; 否则, 将所验证的输入输出数据与原来的支持向量的点一起重新进行优化, 建立新的过程模型. 如此反复, 进行在线的模型修正.

3.2 SVMR 设计内模控制器 (SVMR controller for IMC)

如果控制过程是可逆的, 则可以采取适当的方法建立过程的逆模型, 这个逆模型就是本文所设计的控制器. 因此, 必须首先考虑过程的可逆性. 对于式(6)所示的非线性系统若存在一个 Ξ^{m+n+1} 的子集 A , 当 $[y(k), \dots, y(k-n), u(k), \dots, u(k-m)]^T \in A$ 时, 对于任意两个不同输入 $u_1(k)$ 和 $u_2(k)$, 都有式

$$f(y(k), \dots, y(k-n), u_1(k), \dots, u_1(k-m)) \neq$$

$f(y(k), \dots, y(k-n), u_2(k), \dots, u_2(k-m))$
 成立,则系统在 $[y(k), \dots, y(k-n), u(k), \dots, u(k-m)]^T$ 处是可逆的^[7].

定理 如果式(6)对于 $u(k)$ 是严格单调的,那么系统在 $[y(k), \dots, y(k-n), u(k), \dots, u(k-m)]^T$ 处是可逆的,详细证明见文献[7].

假设系统是可逆的,则在 3.1 部分的模型的逆模型就是控制器,即

$$u(k) = f^{-1}(y_r(k+1), \dots, y(k-n), u(k-1), \dots, u(k-m)). \quad (9)$$

对于非线性控制,过程的逆模型往往很难得到,由于过程是可逆的,因而逆模型一定存在,可以采取诸如神经网络等类似的方法来估计过程的逆模型.由于 SVM 回归具有神经网络的特点并且弥补了其固有的缺陷,因而本文采用第 2 部分所叙述的 SVM 回归来估计过程的逆模型.设

$$Y(i) = (y_r(i+1), y(i), \dots, y(i-n), u(i-1), \dots, u(i-m)).$$

对于 $y(i-q)$ ($q = 0, 1, \dots, n, i = 1, 2, \dots, N, N$ 为样本数据的数目),若 $q < i$,则 $y(i-q) = y(0)$;对于 $u(i-r)$, $r = 0, 1, \dots, m$,若 $r < i$,则 $u(i-r) = u(0)$. 于是可以建立样本数据 $(Y(i), u(i))$. 采用第 2 部分的支持向量机回归方法建立 $u(k)$ 的支持向量机模型:

$$u(k) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(Y(i), Y(k)) + b. \quad (10)$$

通过样本的学习求出式(10)中的参数 $\alpha_i - \alpha_i^*$ 和 RBF 函数的中心值 $Y(i)$ (即支持向量).支持向量机回归模型的损失函数采用 ϵ 不敏感损失函数,核函数采用 RBF 核函数,即可求出参数.模型的训练同 3.1 部分的训练方法.

4 SVMR 内模控制的仿真研究 (Simulation for SVMR IMC)

例 1 取文献[7]中的非线性系统

$$y(k+1) = y(k)/(1+y^2(k)) + u^3(k) + v.$$

易证系统是单调的,根据 3.2 部分的定理可知系统是可逆的.采用 SVM 回归内模控制方法来跟踪方波信号,噪声干扰 v 为随机的阶跃干扰,幅度为 0.2. 在 $k = 50, \dots, 80$ 时的干扰为负阶跃干扰,在 $k = 110, \dots, 150$ 时的干扰为正的阶跃干扰.正向模型和逆向模型的 SVM 回归的损失函数为 ϵ 不敏感损失

函数,核为 RBF,核函数的宽度 $\sigma = 0.2$,误差 $e = 0.01$. 仿真实验结果如图 3 所示.图 3、图 4 中实线为被响应的参考信号,圆点线为系统的输出信号,短划线为内部模型的输出.图 4 是采用 RBF 神经网络的跟踪结果,其中的正向模型采用 2-30-1 的模型,调整参数为 2×10^{-5} ,逆向模型采用 2-30-1 的模型,调整参数为 1×10^{-4} .比较图 3 和图 4,可以看出有阶跃干扰出现时,支持向量回归内模控制系统能很快地抵消干扰,说明系统具有很好的鲁棒性.




图 3 采用 SVMR IMC 跟踪有干扰的方波
 Fig. 3 Tracking square wave using SVMR IMC




图 4 采用神经网络 IMC 跟踪有干扰的方波
 Fig. 4 Tracking square wave using NN IMC with perturbation

例 2 温室环境控制中的应用.

温室环境是非线性、时变、大时延的动态环境,因此很难建立精确的气候模型,传统的控制方法很难对其进行有效的控制.本文采用 SVMR 内模控制来进行环境温度的控制.温室控制模型取文献[8]的近似模型,其离散模型为

$$y(k+1) = e^{-T_s/T} * y(k) + k * (1 - e^{-T_s/T}) * u(k-d).$$

式中: k 为稳态增益, T 为时间常数, T_s 为模型的采样时间, d 为纯滞后. 设 $k = 38, T = 380, T_s = 60, d = 2$. 采用 SVMR 内模控制的结果如图 5 所示.采用 RBF 神经网络内模控制的仿真结果如图 6 所示.图 5、图 6 所示干扰为负的阶跃干扰,模拟天空中的云突然遮住了太阳所引起的干扰.实线为设定值,短划线为系统的输出信号,圆点线为内部模型的输出.

从图5中可以看出在没有干扰出现时模型预测输出曲线与实际输出曲线完全重合在一起,在有干扰出现时能很快地抵消干扰.从图5和图6中可以看出支持向量机回归内模控制比神经网络内模控制具有更好的鲁棒性.此外,支持向量机回归内模控制方法需要的训练样本(40个样本)比神经网络内模控制所需要的样本(2000个样本)也少得多,在实验中模型的调整也难得多.因此在温室环境控制中支持向量机回归内模控制是一个理想的控制方法.




图5 支持向量机回归内模控制温室温度控制曲线

Fig. 5 Result of greenhouse temperature control using SVMR IMC




图6 神经网络内模控制温室温度控制曲线

Fig. 6 Result of greenhouse temperature control using NN IMC

5 结论(Conclusion)

SVM回归内模控制将内模控制和支持向量机回归有机地结合起来.实验说明了支持向量机内模控制具有很好的鲁棒性和稳定性.将SVM回归理论应用于内模控制,不需要了解对象太多的先验知识,只需了解被控对象的输入输出数据就可以对非线性

系统进行控制,因此控制的实现非常简单.这种控制理论是内模控制中的一种重要的新方法,具有重要的研究价值.

参考文献(References):

- [1] HU Q, SAHA P, RANGAIAH G P. Experimental evaluation of an augmented IMC for non-linear systems [J]. *Control Engineering Practice*, 2000, 8(10): 1167 - 1176.
- [2] HU Q, RANGAIAH G P. Adaptive internal model control of non-linear process [J]. *Chemical Engineering Science*, 1999, 54(9): 1205 - 1220.
- [3] MÜLLER K R, SMOLA A J, RÄTSCHE G, et al. Predicting time series with support vector machines [C]. GERSTNER W, GERMOND A, HASLER M, et al. *Proc of Int Conf on Artificial Neural Networks '97, Springer Lecture Notes in Computer Science*. New York: Springer, 1997: 999 - 1004.
- [4] VAPNIK V. *The Nature of Statistical Learning Theory* [M]. New York: Springer, 1999.
- [5] BOSER B E, GUYON I M, VAPNIK V N. A training algorithm for optimal margin classifiers [C] // HAUSSLER D. *Proc of the 5th Annual Association for Computing Machinery Workshop on Computational Learning Theory*. Pittsburgh, PA: ACM Press, 1992: 144 - 152.
- [6] OSUNA E, FREUND R, GIROSI F. An improved training algorithm for support vector machines [C] // *Proc of IEEE Neural Networks for Signal Processing*. Los Alamitos, CA: IEEE Press, 1997: 276 - 285.
- [7] HUNT K J, SBARBARO D. Neural networks for non-linear internal model control [J]. *IEE Proc-D*, 1991, 138(5): 431 - 438.
- [8] ALBERT S, LOUIS D A, RICHARD M P. Application of pseudo-derivative-feedback algorithm in greenhouse air temperature control [J]. *Computer and Electronics in Agriculture*, 2000, 26(3): 283 - 302.

作者简介:

王定成 (1967—),男,在中国农业大学精细农业研究中心作博士后研究工作.主要研究领域为机器学习,智能控制,信号处理. E-mail: dcwang@mail.ustc.edu.cn;

方廷健 (1939—),男,中国科学院合肥智能机械研究所研究员,中国科学技术大学博士生导师.主要研究领域为模式识别,机器学习,智能控制.