

## 多智能体粒子群优化的SVR模型预测控制

唐贤伦, 李洋, 李鹏, 刘念慈

(重庆邮电大学 工业物联网与网络化控制教育部重点实验室, 重庆 400065)

**摘要:** 参数的优化选择对支持向量回归机的预测精度和泛化能力影响显著, 鉴于此, 提出一种多智能体粒子群算法(MAPSO)寻优其参数的方法, 并建立MAPSO支持向量回归模型, 用于非线性系统的模型预测控制, 推导出最优控制率. 采用该算法对非线性系统进行仿真, 并与基于粒子群算法、基于遗传算法优化支持向量回归机的模型预测控制方法和RBF神经网络的预测控制方法进行比较, 结果表明, 所提出的算法具有更好的控制性能, 可以有效应用于非线性系统控制中.

**关键词:** 支持向量回归机; 多智能体; 粒子群优化; 模型预测控制

**中图分类号:** TP273

**文献标志码:** A

## Model predictive control based on SVR optimized by multi-agent particle swarm optimization algorithm

TANG Xian-lun, LI Yang, LI Peng, LIU Nian-ci

(Key Laboratory of Industrial Internet of Things & Networked Control, Ministry of Education, Chongqing University of Posts and Telecommunications, Chongqing 400065, China. Correspondent: TANG Xian-lun, E-mail: tangxianlun@hotmail.com)

**Abstract:** The prediction accuracy and generalization ability of the support vector regression(SVR) model depend on a proper setting of its parameters to a great extent. An optimal selection approach of SVR parameters is proposed based on the multi-agent particle swarm optimization(MAPSO) algorithm. On this basis, a model predictive control method based on the MAPSO-SVR is proposed and applied to the nonlinear predictive control scheme to select the optimal control inputs. For the nonlinear system, the simulation results show that the proposed method is effective and has an excellent adaptive ability and robustness. Compared with the model predictive controllers based on SVR optimized by particle swarm optimization algorithm(PSO-SVR), SVR optimized genetic algorithm(GA-SVR), and RBF neural network algorithm, the proposed method is superior to other methods.

**Key words:** support vector regression; multi-agent; particle swarm optimization; model predictive controller

### 0 引言

模型预测控制<sup>[1]</sup>是一种先进的计算机控制技术, 包含3大要素: 预测模型、滚动优化和反馈校正, 其中核心是预测模型. 但对于复杂多样的非线性系统而言, 难以得到精准的预测模型, 这使得传统的模型预测控制算法在非线性系统应用中无法获得期望的结果. 因此, 如何构建和确立优秀的预测模型便成为非线性模型预测控制领域的研究热点. 考虑到神经网络、模糊算法和一些学习机的非线性拟合能力, 将智能算法与传统模型预测控制算法相结合的思想广泛地应用于非线性系统中, 例如基于神经网络的预测

控制算法<sup>[2]</sup>、基于模糊算法的预测控制算法<sup>[3]</sup>等. 但是, 尽管这些算法可以完成对控制对象的预测控制, 神经网络和模糊算法仍存在过学习的问题. 支持向量回归机(SVR)建立在统计学习理论之上, 是结构风险最小化一致性原则的一种具体实现结构. 在模型预测控制中, 应用SVR提高了传统模型的抗干扰能力、扩大了其应用范围, 取得了较为理想的预测控制结果<sup>[4]</sup>. 但SVR在具体应用中存在突出问题, 即如何选取影响算法性能的参数目前仍无统一而有效的解决方案.

针对以上问题, 本文提出了基于多智能体粒子群优化的SVR模型预测控制算法, 通过多智能体粒

收稿日期: 2012-12-11; 修回日期: 2013-02-28.

基金项目: 国家自然科学基金项目(60905066); 重庆市自然科学基金项目(cstc2012jjA40021).

作者简介: 唐贤伦(1977—), 男, 教授, 博士, 从事预测控制、智能系统等研究; 李洋(1988—), 女, 硕士生, 从事智能控制的研究.

子群算法训练选取合适的 SVR, 利用直接建模法将其与传统模型预测控制相结合, 对非线性系统进行预测控制. 将该算法与 RBF 神经网络预测模型、基于粒子群 SVR(PSO-SVR) 和遗传算法优化的 SVR(GA-SVR) 的模型预测控制算法<sup>[5-6]</sup>作比较分析, 仿真结果表明了所提出算法优于其他几种算法, 具有更好的控制性能, 可有效应用于非线性系统控制中.

## 1 多智能体粒子群算法优化的支持向量回归模型

### 1.1 SVR 及其参数选取

支持向量机(SVM)由 Vapnik<sup>[7]</sup>于 1995 年首次提出, 是一种基于“小样本”的学习机, 目前可以将其分为支持向量分类机(SVC)<sup>[8]</sup>和 SVR 两种, 前者主要用于辨识分类, 后者主要用于函数逼近. SVM 的基本型主要是在分析线性分类问题时推导形成的, 后续的非线性支持向量分类机和 SVR 均在此基础上推演而来.

SVR<sup>[9]</sup>可以描述为一个优化问题, 假定 SVR 拟合线为

$$y = w^T \phi(x) + b. \quad (1)$$

其中:  $\phi(x)$  为将数据变换到高维特征空间的非线性映射,  $w$  和  $b$  为函数系数. 根据结构风险最小化一致性原则, 可以确定  $w$  和  $b$ . 针对“问题样本”(即不满足拟合函数的样本)引入松弛变量, 因此, 支持量回归拟合问题可以表示为

$$\begin{aligned} \min & \frac{1}{2} w^T w + C \sum_{i=1}^m (\xi_i + \xi_i^n); \\ \text{s.t.} & y_i - w^T x_i - b \leq \varepsilon + \xi_i, \\ & w^T x_i + b - y_i \leq \varepsilon + \xi_i^n, \\ & \xi_i, \xi_i^n \geq 0, i = 1, 2, \dots, m. \end{aligned} \quad (2)$$

其中:  $C \geq 0$  为惩罚系数,  $\xi_i \geq 0$  为越过上界的松弛量,  $\xi_i^n \geq 0$  为越过下界的松弛量,  $m$  为样本数. 约束中的前两个式子分别表示对样本约束的弱化处理.

式(2)通过对偶形式的拉格朗日多项式可以转化为

$$\begin{aligned} \max & -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (a_i - a_i^n)(a_j - a_j^n) K(x_i, x_j) - \\ & \varepsilon \sum_{i=1}^m (a_i + a_i^n) + \sum_{i=1}^m (a_i - a_i^n) y_i; \\ \text{s.t.} & \sum_{i=1}^m (a_i - a_i^n) = 0, a_i, a_i^n \in [0, C]. \end{aligned} \quad (3)$$

其中:  $a_i, a_i^n$  为拉格朗日乘子,  $K(x_i, x_j)$  为满足 Mercer 条件的核函数<sup>[10]</sup>.

由 KKT 条件可知, 二次规划问题(3)的解中只有少数样本的系数  $a_i - a_i^n$  不为 0, 故式(1)(最优回归估

计函数)可以表示为

$$y_i = \sum_{i \in SV} (a_i - a_i^n) K(x_i, x) + b. \quad (4)$$

由式(2)可见, 只要选取合适的惩罚参数  $C$ 、不敏感损失函数  $\varepsilon$  和核函数便可以确定 SVR 的具体形式, 从而对控制对象进行准确的预测. 因此, 影响 SVM 性能的关键参数<sup>[11]</sup>有惩罚参数  $C$ 、不敏感损失函数  $\varepsilon$  和核参数  $\gamma$ .

### 1.2 多智能体粒子群优化算法

#### 1.2.1 标准粒子群优化算法

粒子群优化(PSO)算法<sup>[4]</sup>是人们受到真实世界中鸟群搜索食物的行为的启示而提出的一种优化算法, 通过群体之间的信息共享和个体自身经验总结修正个体行动策略, 最终求取优化问题的最佳解. PSO 算法初始化为一群随机粒子, 通过迭代找到最优解, 在每一次迭代中, 粒子通过跟踪两个“极值”更新自己: 第 1 个极值是粒子本身所找到的最优解, 该极值称为个体极值  $p_{\text{best}}$ ; 第 2 个极值是整个种群目前找到的最优解, 该极值称为全局极值  $g_{\text{best}}$ . 每个粒子由下式更新自己的速度和在解空间的位置:

$$\begin{aligned} v_{t+1} &= w_t v_t + C_1 r_1 (p_{\text{best}} - x_t) + \\ & C_2 r_2 (g_{\text{best}} - x_t), \\ x_{t+1} &= x_t + v_{t+1}. \end{aligned} \quad (5)$$

其中: 下标  $t$  为迭代次数,  $x_t$  为第  $t$  次迭代时的粒子空间位置,  $v_t$  为第  $t$  次迭代时的粒子速度,  $w_t$  为惯性常数,  $C_1$  和  $C_2$  为学习因子,  $r_1$  和  $r_2$  为介于 (0, 1) 间的随机数.

#### 1.2.2 MAPSO 算法

标准粒子群算法中, 粒子间基本无相互联系, 每个粒子只与本身和当前最佳粒子进行通信协作. 因此, 为了增加粒子与粒子之间的协作, 增强种群多样性, 提高收敛速度, 提出将多智能体的概念引入到 PSO 算法中, 从而增强了 PSO 算法的智能性和代理能力, 使 PSO 算法中的种群粒子可以共同协作, 增强种群的多样性, 提高其收敛性和求解能力.

MAPSO(基于多智能体粒子群优化的支持向量回归机)算法<sup>[12]</sup>是结合 PSO 算法和多智能体的主要特性构造的一种新算法, 将 PSO 算法中的每个粒子理解为一个智能体, 故每个粒子不仅要执行 PSO 算法的更新进化原则, 而且参与实施与其邻居粒子的竞争和合作, 然后与全局最优进行信息交互, 最终根据自身经验和全局最优更新当前粒子的速度和位置, 从而改变自身的行动策略, 提高整体的收敛速度和寻优能力.

#### 1.3 MAPSO-SVR 算法步骤

将 MAPSO 算法应用到 SVR 中, 利用该算法对

SVR进行训练,具体步骤如下.

**Step 1:** 数据集的处理. 确定SVR的训练集和测试集.

**Step 2:** 粒子群的初始化. 参数设置并产生种群的初始位置和速度.

**Step 3:** 计算当前粒子适应值. 适应度函数值定义为

$$F = \frac{1}{N} \sum_{i=1}^N (y_i - y'_i),$$

其中  $y_i$  和  $y'_i$  分别为SVR训练输出值和期望输出值. 注意到, 在多组参数向量  $(C, \varepsilon, \gamma)$  对应的适应度函数值相同的情况下, 应选用参数  $C$  较小的那组粒子. 因为过高的  $C$  会导致过学习状态, 即训练集数据准确率较高而测试集数据预测准确率较低(回归机的泛化能力不强), 所以在能够达到最高预测准确率中的所有粒子中选取带有较小的惩罚参数  $C$  的那组粒子作为选择对象.

**Step 4:** 根据邻居信息, 更新粒子的个体最优位置. 每个粒子预定义一个邻居环境, 假设粒子  $L_{i,j} = (l_1, l_2, \dots, l_D)$  为其在优化问题解空间中的位置,  $M_{i,j}$  为  $L_{i,j}$  的  $M$  个邻居中拥有最佳适应值的粒子, 且  $M_{i,j} = (m_1, m_2, \dots, m_D)$ . 若  $L_{i,j}$  满足

$$f(L_{i,j}) \leq f(M_{i,j}), \quad (6)$$

则  $L_{i,j}$  是一个赢家, 其在解空间的位置保持不变; 否则是一个输家, 在解空间的位置根据  $L'_{i,j} = M_{i,j} + \text{rand}(-1, 1)(L_{i,j} - M_{i,j})$  进行更新.

**Step 5:** 根据式(5)更新粒子的位置和速度.

**Step 6:** 判断是否满足终止条件, 若满足则算法终止, 并确定最优粒子和SVR的最佳参数, 否则转至Step 3.

## 2 基于MAPSO-SVR的模型预测控制

模型预测控制利用显式的内部模型的状态或输出预测被控对象输出, 借助有限时域的滚动优化思想和反馈校正策略, 以对系统有重大影响的性能指标作为优化对象, 通过最优化计算确定在一个控制时域内的最优控制输入序列.

考虑到计算量和预测准确程度, 本文选用核函数  $K(x, x') = \gamma \langle x, x' \rangle + r^2$ , 这样有利于在滚动优化时获得最优的控制输入信号.

### 2.1 参数选择

在确定控制对象后, 进行数据采集, 数据集定义为  $(Y, X)$ . 其中:  $Y$  为样本的实际输出值,  $X$  为样本的特征属性向量. 将  $(Y, X)$  代入到MAPSO算法中, 对SVR的参数  $(C, \gamma, \varepsilon)$  进行寻优处理, 通过寻找最佳适应值, 确定参数  $(C_{\text{best}}, \gamma_{\text{best}}, \varepsilon_{\text{best}})$ , 并利用其修正式

(2)和(3)中的相应参数.

### 2.2 模型预测

一般情况下, 离散被控对象的输入输出关系可以描述为

$$\begin{aligned} y(k+1) = & f(y(k), y(k-1), \dots, y(k-n+1), u(k), \\ & u(k-1), \dots, u(k-m+1)), \\ \text{s.t. } & u_{\min} < u < u_{\max}. \end{aligned} \quad (7)$$

其中:  $f(\cdot)$  为非线性函数,  $n$  和  $m$  分别为输出信号和控制信号对控制系统输出的最大影响时域长度,  $u_{\min} < u < u_{\max}$  为控制量输出范围.

利用SVR对上述被控对象建模, 即使用非线性核函数将内积从当前空间映射到高维空间这一特性构造一个类似的函数逼近式

$$\begin{aligned} y(k+1) = & \hat{f}(y(k), y(k-1), \dots, y(k-\hat{n}+1), \\ & u(k), u(k-1), \dots, u(k-\hat{m}+1)), \\ \text{s.t. } & u_{\min} < u < u_{\max}. \end{aligned} \quad (8)$$

其中:  $\hat{f}$  为具有类似SVR结构的非线性函数;  $\hat{n}$  和  $\hat{m}$  为对式(7)中  $n$  和  $m$  的近似模拟, 当  $\hat{n}$  和  $\hat{m}$  分别大于等于  $n$  和  $m$  时, 具有较高的拟合精度. 将其改写为如下SVR形式:

$$y_m(k+1) = \sum_{i=1}^{n_{\text{sv}}} a_i [\gamma_{\text{best}} (I_i I(k)) + 1]^2 + b. \quad (9)$$

其中:  $y_m(k+1)$  为  $k+1$  步模型预测输出;  $n_{\text{sv}}$  为支持向量的个数;  $I_i$  为第  $i$  个支持向量,  $a_i$  为  $I_i$  对应的权重系数,  $b$  为偏移量,  $I_i$ 、 $a_i$  和  $b$  可通过支持向量回归算法获得;  $\gamma_{\text{best}}$  为寻优得到的最佳核参数;  $I_i I(k)$  为两个向量的内积,  $I(k)$  表示为

$$\begin{aligned} I(k) = & [y(k), y(k-1), \dots, y(k-\hat{n}+1), \\ & u(k), u(k-1), \dots, u(k-\hat{m}+1)], \end{aligned} \quad (10)$$

故有

$$\begin{aligned} I_i I(k) = & I_i(1)y(k) + I_i(2)y(k-1) + \dots + \\ & I_i(\hat{n})y(k-\hat{n}+1) + I_i(\hat{n}+1)u(k) + \\ & I_i(\hat{n}+2)u(k-1) + \dots + I_i(\hat{n}+\hat{m})u(k-\hat{m}+1). \end{aligned}$$

只有  $u(k)$  为未知量, 其余均已知, 为了分离出变量, 可表示为

$$\begin{aligned} I_i I(k) = & I_i \hat{I}(k) + I_i(\hat{n}+1)u(k), \\ \hat{I}(k) = & [y(k), y(k-1), \dots, y(k-\hat{n}+1), 0, \\ & u(k-1), \dots, u(k-\hat{m}+1)]. \end{aligned} \quad (11)$$

将式(11)代入(9),可得

$$y_m(k+1) = Au^2(k) + Bu(k) + C, \quad (12)$$

其中系数  $A, B, C$  均可由已知量获得.

### 2.3 反馈校正

由于模型失配和随机干扰等不确定因素对控制系统的影响,需要借助“经验值”对后面的模型预测值进行校正,有

$$\begin{aligned} e(k) &= y(k) - y_m(k), \\ y_p(k+1) &= y_m(k+1) + he(k). \end{aligned} \quad (13)$$

其中:  $y(k)$  为  $k$  时刻的被控对象实际输出值,  $y_m(k+1)$  为  $k+1$  时刻的模型预测输出值,  $y_p(k+1)$  为  $k+1$  时刻的校正预测输出值,  $h$  为误差权重系数.

### 2.4 滚动优化

在非线性模型预测控制中,除了伺服控制系统外,一般不要求控制系统尽可能快地返回设定值,而是希望沿着某一平滑曲线逐渐返回.柔化系数法是较常用的一种方法,其表达式如下:

$$\begin{aligned} y_r(k+1) &= a_r y(k) + (1 - a_r) y_{sp}, \\ y_r(k) &= y(k). \end{aligned} \quad (14)$$

在伺服控制系统中,有

$$y_r(k+1) = y_{sp}. \quad (15)$$

其中:  $y_r(k+1)$  为  $k+1$  时刻的参考输出值;  $a_r$  为柔化系数,取值在区间  $(0,1)$ ;  $y_{sp}$  为输出目标值.此处用最小二乘逼近法,确定目标函数如下:

$$\begin{aligned} \min J(k) &= q[y_p(k+1) - y_r(k+1)]^2 + \\ & p[u(k) - u(k-1)]^2, \\ \text{s.t. } & u_{\min} < u < u_{\max}. \end{aligned} \quad (16)$$

其中  $q$  和  $p$  分别为误差加权系数和控制加权系数.将式(12)和(13)代入(16),得到

$$\begin{aligned} \min J(k) &= \\ & q[y_p(k+1) - y_r(k+1)]^2 + \\ & p[u(k) - u(k-1)]^2 = \\ & a_{k1}u^4(k) + a_{k2}u^3(k) + a_{k3}u^2(k) + \\ & a_{k4}u(k) + a_{k5}, \\ \text{s.t. } & u_{\min} < u < u_{\max}. \end{aligned} \quad (17)$$

其中  $a_1, a_2, a_3, a_4$  可用已知量表示.式(17)是一个变量有界多项式极值问题,可以通过求导的方法求其最小值,求得导数为

$$\frac{\partial J(k)}{\partial u(k)} = 4a_{k1}u^3(k) + 3a_{k2}u^2(k) + 2a_{k3}u(k) + a_{k4}. \quad (18)$$

式(18)为一元三次常系数方程,可用  $u_1(k), u_2(k)$  和  $u_3(k)$  表示该方程的3个根.去掉3个根中的

复数根,将剩下的根、 $u_{\min}$  和  $u_{\max}$  代入式(16),取得最小  $J$  值的输入控制信号即为最优输入控制信号,因此最优控制可记为

$$u_{\text{op}}(k) = \{u_i(k) | \min J(u_i(k)), i = 1, 2, 3, 4, 5\}.$$

其中:  $u_{\text{op}}(k)$  为最优输入控制信号,  $u_4(k)$  和  $u_5(k)$  分别为  $u_{\min}$  和  $u_{\max}$ .

由以上分析可知,基于SVR和模型预测控制的直接建模法得到的SVR非线性系统模型预测控制的程序流程如图1所示.

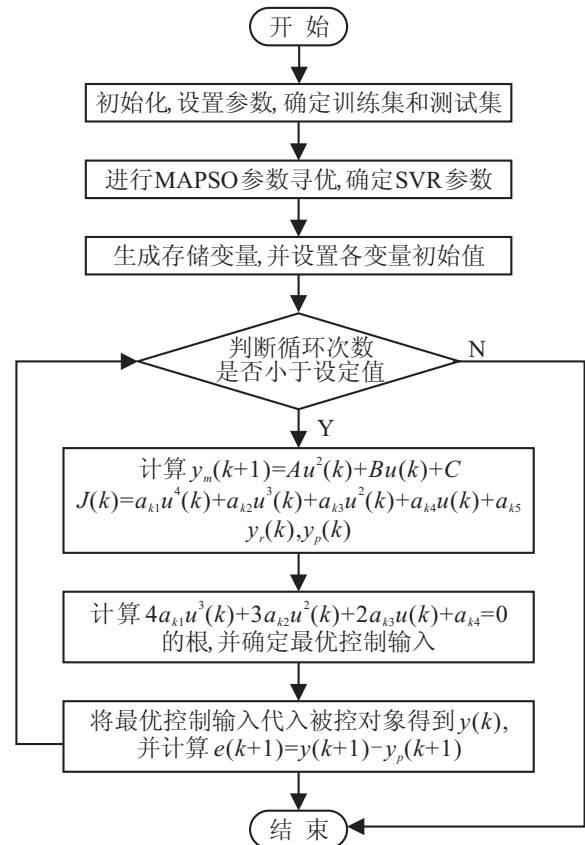


图1 SVR非线性系统预测控制程序流程

### 3 算例分析

为了验证MAPSO模型预测控制算法在非线性系统中的预测控制性能,本文对一非线性系统对象模型进行性能跟踪测试实验,并与RBF神经网络控制算法、基于粒子群优化算法的支持向量回归(PSO-SVR)和遗传算法优化SVR<sup>[13]</sup>(GA-SVR)的模型预测控制方法进行对比分析.

假设非线性系统对象模型如下:

$$y(k+1) = \frac{y(k)}{1+y^2(k)} - 0.5y(k-1) + u^3(k).$$

其中:  $y$  为被控对象输出,  $u$  为控制信号输入.提取该模型随机生成的100个数据作为不同算法的训练集和测试集,以此实现SVR模型的确定,并比较不同算法间的控制精度.假设每个样本的输出只与当前输入和若干过去时刻的输出有关,并将其作为样本的特征

属性,将系统的输出作为样本标签,以此定义模型预测控制中SVR的样本属性值和样本标签.将所提出方法与PSO-SVR和GA-SVR的模型预测控制器进行比较,模型的主要参数设置见表1.分别采用上述算法对模型进行参数寻优,实验结果如图2所示.

表1 不同模型参数设置

算法	参数						
	迭代次数	种群规模	交叉概率	变异概率	环境大小	权重上限	权重下限
GA-SVR	100	36	0.7	0.0035			
PSO-SVR	100	36				0.9	0.4
MAPSO-SVR	100	36			66	0.9	0.4





图2 不同算法的寻优效果

由图2可见,MAPSO-SVR参数寻优算法得到的预测模型的适应度函数明显优于PSO-SVR算法和GA-SVR算法,即MAPSO-SVR的参数寻优效果好于PSO-SVR算法和GA-SVR算法.同时,MAPSO-SVR的收敛速度也优于其他两种算法,基本在迭代40~50次即可达到较为理想的效果,具有良好的收敛性能.综上所述,MAPSO-SVR算法的寻优效率比PSO-SVR和GA-SVR高.


将MAPSO-SVR、PSO-SVR、GA-SVR算法寻优得到的参数组合分别带入模型预测控制算法中进行预测控制,3种算法训练得到的模型预测控制效果和RBF神经网络的预测控制效果如图3所示,实线为系统实际输出,虚线为各控制系统模型输出.

由图3(b)和图3(c)可见,PSO-SVR和GA-SVR算法训练得到的预测模型在非线性模型预测控制系统输出响应过程中均出现较为明显的超调,且PSO-SVR预测模型动态性能也不稳定.图4中,MAPSO-SVR、GA-SVR、PSO-SVR和RBF算法对应的均方根误差依次为0.0006351,0.008431,0.002132,0.0060.因此,综合图3(d)和图4可见,基于RBF神经网络的模型预测控制系统基本没有出现超调,但是预测初期振荡明显,且误差明显高于基于MAPSO-SVR的预测控制系统.由图3(a)MAPSO-SVR控制系统的跟踪性能情况可知,其预测跟踪结果基本上无超调现象出现,整体动态性能良好,具有较高的控制精度,基本实现


了对控制对象稳、快、准的预测控制,表现出较好的预测控制效果.




(a) MAPSO-SVR控制系统跟踪性能



(b) PSO-SVR控制系统跟踪性能



(c) GA-SVR控制系统跟踪性能



(d) RBF控制系统跟踪性能

图3 不同算法的预测控制效果




图4 不同模型的跟踪误差

## 4 结 论

本文提出将粒子群算法与多智能体思想相结合

来改进 SVR 模型预测控制系统中 SVR 的参数选择问题. 该方法既调用了粒子群的迭代机制, 又利用了多智能体的协作能力, 其优化所得的模型预测系统有效地解决了非线性系统难以建模的问题, 仅通过对样本数据的处理便能够获得有效的预测模型, 从而实现对非线性系统进行控制跟踪. 仿真结果表明, 所提出方法与基于 GA-SVR、PSO-SVR 的模型预测控制算法和 RBF 神经网络预测控制算法相比, 具有较好的收敛速度和寻优能力, 表现出良好动态性能和控制效果.

#### 参考文献(References)

- [1] Melanie Nicole Zeilinger, Colin Neil Jones, Manfred Morari. Real-time suboptimal model predictive control using a combination of explicit MPC and online optimization[J]. IEEE Trans on Automatic Control, 2011, 56(7): 1524-1534.
- [2] 张日东, 王树青. 基于神经网络的非线性系统多步预测控制[J]. 控制与决策, 2005, 20(3): 332-336.  
(Zhang R D, Wang S Q. Neural network based multi-step predictive control for nonlinear system[J]. Control and Decision, 2005, 20(3): 332-336.)
- [3] 曹玉苹, 田学民. 基于 SVM 和 Kalman 预测的非线性系统故障预报[J]. 控制与决策, 2009, 24(3): 477-480.  
(Cao Y P, Tian X M. Nonlinear system fault prognosis based on SVM and Kalman predictor[J]. Control and Decision, 2009, 24(3): 477-480.)
- [4] 唐贤伦, 庄陵, 胡向东. 铁水硅含量的混沌粒子群支持向量机预报方法[J]. 控制理论与应用, 2009, 26(8): 838-842.  
(Tang X L, Zhuang L, Hu X D. The support vector regression based on the chaos particle swarm optimization algorithm for the prediction of silicon content in hot metal[J]. Control Theory & Applications, 2009, 26(8): 838-842.)
- [5] 穆朝絮, 张瑞民, 孙长银. 基于粒子群优化的非线性系统最小二乘支持向量机预测控制算法[J]. 控制理论与应用, 2010, 27(2): 164-168.  
(Mu C X, Zhang R M, Sun C M. LS-SVM predictive control based on PSO for nonlinear systems[J]. Control Theory & Applications, 2010, 27(2): 164-168.)
- [6] Kennedy J, Eberhart R C. Particle swarm optimization[C]. Proc of IEEE Int Conf on Neural Networks. Perth: IEEE, 1995, 4: 1942-1948.
- [7] Vapnik V N. The nature of statistical learning theory[M]. New York: Springer, 1995: 280-292.
- [8] Ramy Baly, Hazem Hajj. Wafer classification using support vector machines[J]. IEEE Trans on Semiconductor Manufacturing, 2012, 25(3): 373-383.
- [9] Juang Chia-feng, Hsieh Cheng-da. A fuzzy system constructed by rule generation and iterative linear svr for antecedent and consequent parameter optimization[J]. IEEE Trans on Fuzzy Systems, 2012, 20(2): 372-384.
- [10] Hsu C W, Lin C J. A simple decomposition method for support vector machine[J]. Machine Learning, 2002, 46(1/2/3): 219-314.
- [11] Vanessa Gómez Verdejo, Manel MartínezRamón. Support vector machines with constraints for sparsity in the primal parameters[J]. IEEE Trans on Neural Networks, 2010, 22(8): 1269-1283.
- [12] Kazemi Kargar H, Aghmasheh R, Zareie Govar G R. Multi-agent-based particle swarm optimization approach for PSS designing in multi-machine power[C]. The 2nd IEEE Int Conf on Power and Energy. Johor Bahru: IEEE, 2008: 73-78.
- [13] 赵明渊, 唐勇, 傅翀, 等. 基于带特征染色体遗传算法的支持向量机特征选择和参数优化[J]. 控制与决策, 2010, 25(8): 1133-1138.  
(Zhao M Y, Tang Y, Fu C, et al. Feature selection and parameter optimization for SVM based on genetic algorithm with feature chromosomes[J]. Control and Decision, 2010, 25(8): 1133-1138.)

(责任编辑: 郑晓蕾)