

文章编号: 1001-0920(2009)10-1559-06

基于 LS_SVM 的不确定系统神经滑模控制方法研究

赵俊, 陈建军

(西安电子科技大学 机电工程学院, 西安 710071)

摘要: 针对一类参数大范围变化的不确定系统, 提出一种基于分类转换策略的神经滑模控制方法. 按小偏差原理对系统模型进行划分, 利用结合主成分分析的最小二乘支持向量机进行分类训练, 并分别设计基于径向基函数神经网络在线调整切换项增益的滑模控制器, 在线时利用分类器按系统数据自动选择相应的控制器. 同时, 引入结合混沌机制的量子粒子群算法, 并将其用于控制器近似最佳切换函数的构造. 仿真结果表明, 系统具有良好的跟踪性能和较强的鲁棒性, 有效地降低了抖振.

关键词: 不确定系统; 最小二乘支持向量机; 量子粒子群算法; 滑模控制; 神经网络

中图分类号: TP273

文献标识码: A

Study on neural network sliding-mode control for uncertain systems based on least square support vector machine

ZHAO Jun, CHEN Jian-jun

(School of Electromechanical Engineering, Xidian University, Xi'an 710071, China. Correspondent: ZHAO Jun, E-mail: sekel1982@yahoo.com.cn)

Abstract: A classifying and switching strategy based on least square support vector machine (LS_SVM) for the control of uncertain system with the parameters varying in a wide range is proposed. The original system model is divided into several models with small range of uncertainty. These models are classified by LS_SVM combined with principal component analysis (PCA) offline. For each model, the sliding-mode controller (SMC) with its gain tuned by radial basis function neural network (RBFNN) is designed and applied. In online situation, the designed SMC is selected automatically by LS_SVM based on system data. The quantum-behaved particle swarm optimization (QPSO) with chaos strategy is designed and applied to adjusting the parameters, so as to construct an optimized switching function. Finally, the system scheme is designed by the proposed strategy. Simulation results show the high tracking performance and strong robustness of the new strategy, as well as the effectively reduced chattering problem.

Key words: Uncertain system; Least square support vector machine; Quantum-behaved particle swarm optimization; Sliding mode control; Neural network

1 引言

对于现代工业过程中系统特性未知的不确定对象, 传统鲁棒控制方法易受到建模误差、参数变化及外部干扰等不确定因素的影响. 尤其当系统参数具有很大范围不确定性时, 传统方法显得十分保守, 难以进行有效地处理. 滑模变结构控制 (SMC) 是一种特殊的非线性控制方法, 具有对系统参数不确定和外界干扰鲁棒性强的优良特性. 然而, 该特性是以系统控制量的高频抖振换取的, 高频抖振的直接影响是易激发系统的未建模特性, 降低系统的控制品质^[1].

近几年来, 对降低抖振方法的研究已取得不少成果, 其中在线调整滑模控制器切换项增益是消除抖振的一种有效方法. 目前, 各种智能方法已被应用于滑模在线切换项增益的优化, 并且各种先进算法与滑模控制方法的有效结合运用也成为了研究热点^[2-5].

本文研究一类系统参数在很大范围内变化的不确定对象, 为克服上述的保守设计缺陷并进一步改善系统的性能, 提出如下分类转换控制策略: 在已知参数变化上下界前提下, 基于类似分段线性化的思想, 将系统进行分割. 对于分割后的多个小偏差范围模型, 利用最小二乘支持向量机 (LS_SVM) 结合主

收稿日期: 2008-10-20; 修回日期: 2009-03-11.

基金项目: 国家 863 计划项目 (2006AA04Z402).

作者简介: 赵俊 (1982—), 男, 南昌人, 博士生, 从事神经网络、智能控制与优化的研究; 陈建军 (1951—), 男, 河北保定人, 教授, 博士生导师, 从事电子机械可靠性与智能控制的研究.

成分分析(PCA)方法进行分类. 对每类模型分别设计滑模控制器(SMC), 并利用一种带混沌搜索策略的量子粒子群优化(QPSO)算法离线优化构造近似最佳切换函数. 同时, 利用径向基函数神经网络(RBFNN)结合误差反传算法(BP)在线调整切换项增益的方法降低系统的抖振. 为提高 LS_SVM 的分类及泛化性能, 利用带混沌搜索的 QPSO 优化其惩罚因子和核参数. 基于以上策略和优化配置, 对系统进行了设计与仿真.

2 控制系统设计

控制策略实施方案如图 1 所示. 图 1(a)为系统分割和分类策略示意, 将大范围不确定模型 Model 划分为若干类小偏差模型 Model- x , 同时为每类模型设计 SMC- x . 各类小偏差模型的系统参数在小区间内变化, 按小区间参数的均值来设计标称模型(nominal model), 用于采集 LS_SVM 学习的样本库. 离线时结合 PCA 分析, 训练 LS_SVM 用于分类, 在线时选择对应的 SMC 来实施控制策略. 图 1(b)为 LS_SVM 做出分类选择后对小偏差模型的控制结构具体结构, 它包含神经网络和优化算法的具体配置. 其中 chaos-QPSO 为带混沌搜索的量子粒子群离线优化算法, BP 为 RBFNN 的学习算法, r 为期望输入, e 为期望输入与实际输出之间的误差, u 为系统控制量, y 为实际输出.

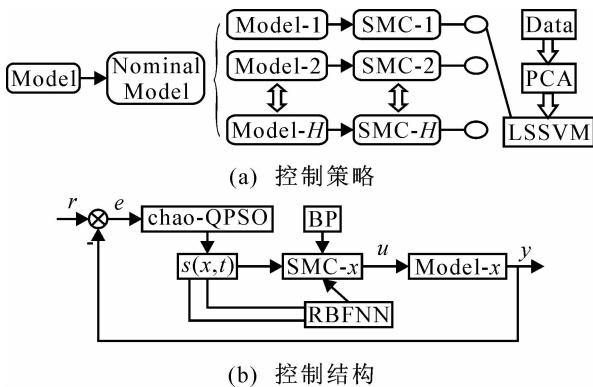


图 1 控制策略示意及其具体结构形式

3 神经滑模控制器设计

3.1 系统描述

根据文献[6]中基于 RBF 神经网络调节切换项增益的 SMC 设计方法, 考虑如下不确定对象:

$$\ddot{\theta}(t) = f(x, t) + g(x, t)u(t) + d(t). \quad (1)$$

其中: $x = [\theta \ \dot{\theta}]$, $d(t)$ 为外部干扰. 假设系统满足以下条件:

$$\begin{cases} 0 < g_{\min} \leq g(x, t) \leq g_{\max}; \\ |f - \hat{f}| \leq F(x, t); \\ \alpha = (g_{\max}/g_{\min})^{1/2} + 1, 1/\alpha \leq g/\hat{g} \leq \alpha; \\ |d| \leq D(x, t). \end{cases} \quad (2)$$

其中 \hat{f}, \hat{g} 分别为 $f(x, t)$ 和 $g(x, t)$ 的名义值.

3.2 滑模控制器设计及稳定性分析

定义跟踪误差 e 并设计滑模面为

$$s(x, t) = \mu e + \dot{e}, \quad (3)$$

其中 μ 为离线待优化参数. 令 $\dot{s}(x, t) = 0$, 并假设不确定性和干扰为零, 有

$$\begin{cases} \hat{f} + \hat{g}u_{eq} - \ddot{\theta}_d + \mu\dot{e} = 0, \\ u_{eq} = \hat{g}^{-1}(\ddot{\theta}_d - \hat{f} - \mu\dot{e}). \end{cases} \quad (4)$$

设计切换控制器为

$$u_n = -\hat{g}^{-1}K \operatorname{sgn}(s). \quad (5)$$

其中: K 为增益项, sgn 为符号函数. 这里 K 设计为

$$K = \alpha[(F + D + W + \beta) + (\alpha - 1)|\ddot{\theta}_d - \hat{f} - \mu\dot{e}|], |\ddot{\theta}_d| \leq W, \beta > 0. \quad (6)$$

总控制器为

$$u = u_{eq} + u_n. \quad (7)$$

下面进行稳定性分析. 定义 Lyapunov 函数 $V =$

$\frac{1}{2}s^2$, 文献[6]的推导如下:

$$\dot{V} = \dot{s} = s(f + gu + d - \ddot{\theta}_d + \mu\dot{e}). \quad (8)$$

将式(4)代入(8), 可得

$$\begin{aligned} \dot{V} &= s(f - \hat{f} - \hat{u} + g\hat{g}^{-1}\hat{u} - g\hat{g}^{-1}K \operatorname{sgn}(s) + d) = \\ &= s(f - \hat{f} + d) + s(\hat{g}\hat{g}^{-1} - 1)\hat{u} - g\hat{g}^{-1}K|s|. \end{aligned} \quad (9)$$

将式(6)代入(9), 并根据式(2)的系统假设, 可推导出

$$\dot{V} \leq |s| |g\hat{g}^{-1} - 1| |\hat{u}| - [W + \beta + (\alpha - 1)|\hat{u}|] |s|, \quad (10)$$

$$\dot{V} \leq -(W + \beta)|s| \leq -\beta|s|, \quad (11)$$

即所设计的控制器使系统渐近稳定.

3.3 利用 RBF 网络进行增益调节

RBF 网络是一种 3 层前向型网络, 网络输入输出关系可描述为

$$O_i^H = \exp\left(-\frac{\|I - c_i\|}{2b_i}\right), \quad i = 1, 2, \dots, K; \quad (12)$$

$$O = \omega O^H. \quad (13)$$

其中: O^H, O 分别为隐层输出和网络输出; I 为输入向量; K 为隐层节点数; c, b 分别为隐层神经元中心和宽度; ω 为隐层到输出层的权值. 网络的性能指标函数可取为

$$E = \frac{1}{2}e^2 = \frac{1}{2}[O(t) - O_m(t)]^2, \quad (14)$$

其中 O_m 为期望输入.

利用 RBF 网络进行增益调节时, 网络输入取 $[s, \dot{s}]$, 输出的绝对值即为切换项增益 K . 根据性能

指标函数,利用基于梯度的 BP 算法进行在线调整.

4 优化算法配置

从控制理论出发,在控制系统设计过程中涉及到的研究主要集中在控制策略的实施和控制系统性能评价两方面.一般而言,控制器设计时需确定若干参数,参数质量的优劣决定了控制器性能的好坏,控制器性能低劣直接降低了整个控制系统的整体性.在控制系统设计中,控制策略的合理实施和控制系统性能的保证都是至关重要的,只有对控制系统进行合理的设计、整定和维护,才能保证整个控制系统的控制品质.而实际控制时许多问题都可以包含在优化的范畴内.通常优化的方法是,采用合适的优化算法,在多维空间中同时确定若干个最优或近似最优值.本文在实施分类选择控制策略的同时,对系统配置了高效的优化算法,分为离线带混沌机制的 QPSO 和在线 BP 两部分.

4.1 离线切换函数的优化构造

常规 PSO 算法是 Kennedy 和 Eberhart 两位学者受到鸟群、鱼群觅食的启发,提出的一种基于群智能的全局性搜索算法.该算法采用速度-位置搜索模型,通过惯性权重协调全局搜索和局部搜索,使算法能以较大概率收敛到最优解,在处理函数优化问题上有着优越的性能.然而,当遇到变量维数灾或目标函数较为复杂的情形时,算法后期容易陷入局部极小.针对该问题,大量学者进行了深入的研究与改进,其中最新的成果是 Sun 等人^[7]从量子力学角度出发提出的新的算法模型——QPSO.通过研究粒子的收敛行为,认为粒子具有量子的行为.当粒子在空间进行搜索时,存在以当前粒子找到的局部最优为中心的 DELTA 势阱.在该算法模型中,量子空间中粒子满足聚集态的性质完全不同,且粒子的速度和位置不能同时确定,故它可以在整个解空间中进行搜索,其寻优能力要优于常规 PSO 算法.然而,当复杂问题的近似最优解未知时,QPSO 算法也如同其他全局性优化算法一样,容易陷入早熟和局部极值,且算法是批量处理数据,不适合于在线优化.为进一步提高算法求解的精度,本文利用两步混沌扰动结合 QPSO 离线优化 SMC 的切换函数参数 μ , 具体流程如下:

Step1 确定参数的搜索区间范围并进行编码,这里采用实数编码.由式(4),(5),(7)可知

$$u = \begin{cases} u_x = \hat{g}^{-1}[\ddot{\theta}_d - \dot{f} - \mu\dot{e} - K], & s > 0; \\ u_y = \hat{g}^{-1}[\ddot{\theta}_d - \dot{f} - \mu\dot{e} + K], & s < 0. \end{cases} \quad (15)$$

考虑到实际系统中的输出为有限值,故对控制量 u 的有限幅进行处理,假设其区间为 $[p_1, p_2]$,有

$$u = \begin{cases} p_1, & u \leq p_1; \\ p_2, & u \geq p_2. \end{cases} \quad (16)$$

由式(8),(15)和(16),并假设 $u_x > u_y$ 可得

$$\dot{s} = \begin{cases} (f + gp_1 + d - \ddot{\theta}_d + \mu\dot{e}), & u \leq p_1, s < 0; \\ (f + gp_2 + d - \ddot{\theta}_d + \mu\dot{e}), & u \geq p_2, s > 0. \end{cases} \quad (17)$$

由滑模稳定条件 $\dot{s} \leq 0$ 可知

$$\begin{cases} (f + gp_1 + d - \ddot{\theta}_d + \mu\dot{e}) \geq 0, & s < 0; \\ (f + gp_2 + d - \ddot{\theta}_d + \mu\dot{e}) \leq 0, & s > 0. \end{cases} \quad (18)$$

从而可由式(18)确定 μ 的搜索范围.

Step2 QPSO 搜索阶段.初始化种群规模、粒子维数等相关参数.选定适应度函数(即目标函数),这里定义为均方误差(MSE)形式.计算粒子的适应度值并按下式更新粒子位置:

$$Pbest = h * Pbest_t + (1 - h) * Gbest, \quad (19)$$

$$\vartheta = 1 - 0.5 * Gen / MaxGen, \quad (20)$$

$$Mbest = \sum_{i=1}^N Pbest_i / N, \quad (21)$$

$$Pos(t+1) = Pbest \pm \vartheta * |Mbest - Pos(t)| * \ln(1/\sigma). \quad (22)$$

其中:Pos 表示粒子的位置;Pbest,Gbest 分别表示粒子个体找到的最优点和所有粒子找到的最优点;Mbest 表示粒子群 Pbest 的中间位置; ϑ 表示收缩扩张系数; N 表示粒子数目;Gen,MaxGen 分别表示当前寻优代数 and 最大寻优代数; σ, h 均表示 0 至 1 之间的随机数.

Step3 第 1 步混沌辅助搜索.设置混沌辅助搜索的激发条件:迭代累积次数和一个微小正值.当 QPSO 的适应度值在设定的迭代累积次数中的变化小于微小正值时,保存当前参数,将其赋给混沌搜索的初始值.混沌算子选取经典模型 Logistic 映射,由于 Logistic 映射在(0,1)上对称,只需在(0,0.5)区间随机初始化混沌变量,且维数与当前参数一致.利用下式产生新的参数值:

$$\text{if } |err_{now}^k - err_{next}^{k=k+1, \dots, k+\epsilon}| \leq \zeta, \quad (23)$$

$$P_0 = P_0 + \chi(2X_i - 1), \quad (24)$$

$$X_{i+1} = 4X_i(1 - X_i), \quad i = i + 1. \quad (25)$$

其中: $err_{now}^k, err_{next}^{k=k+1, \dots, k+\epsilon}$ 分别表示当前第 k 次迭代时的最优值和第 k 次迭代到第 $k+\epsilon$ 次迭代的历次最优值; ζ 为微小正值;if 表示条件判断; P_0 为混沌搜索的初始值,也是当前种群中适应度值最好的粒子; χ 为搜索半径,调整它可以在较大范围内遍历搜索,但非常耗时; X 为混沌变量;式(25)为 Logistic 映射的算式表达,此时算式系数取 4,混沌变量 X 在(0,1)范围内不重复地遍历.这一步的主要目的是避免

QPSO 发生早熟,陷入局部极值. χ 的作用是微调,一般取较小值. 保存搜索到的更优值,否则调整 χ .

Step4 判断是否满足精度要求. 满足则继续执行下一步;否则,转 Step2.

Step5 第 2 步混沌局部细搜索. 该步是在混沌辅助搜索的 QPSO 算法达到设定精度要求后,额外施加的细搜索策略. 由于在较大范围内混沌优化非常费时,Step3 的主要目的是在全局范围内的局部进行微调,起辅助作用. 此步骤才是真正意义上的细搜索. 记 Step3 混沌辅助下 QPSO 搜索到的参数为 P' . 再次利用混沌优化方法 $P' = P' + v(2X_i - 1)$, $X_{i+1} = 4X_i(1 - X_i)$ ($i = i + 1$) 在小范围内遍历, v 为搜索半径. 反复调整 v 值,将所找到的参数记为最终参数 P_{final} .

4.2 在线 RBF 网络参数调整

依据指标函数(14),RBF 网络参数的调整算法为

$$\begin{cases} c(t) = c(t-1) + \eta \Delta c(t) + \lambda(c(t) - c(t-1)), \\ b(t) = b(t-1) + \eta \Delta b(t) + \lambda(b(t) - b(t-1)), \\ \omega(t) = \omega(t-1) + \eta \Delta \omega(t) + \lambda(\omega(t) - \omega(t-1)), \end{cases} \quad (26)$$

其中 η, λ 分别为学习率和惯量系数. 以权值 ω 为例,具体的调整算法为

$$\begin{aligned} \Delta \omega &= -\eta \frac{\partial E}{\partial \omega} = -\eta \frac{\partial e}{\partial \omega} = -\eta \frac{\partial O}{\partial \omega} \\ &= -\eta \frac{\partial O}{\partial u} \frac{\partial u}{\partial K} \frac{\partial K}{\partial \omega} \approx \\ &= -\eta (-\hat{g}^{-1}) \text{sgn}(s) O^H \text{sgn}(\omega O^H). \end{aligned} \quad (27)$$

5 LS_SVM 分类原理及其参数优化

支持向量机的理论具有严格的数学基础,从结构风险最小化原则出发,它能处理神经网络在系统辨识方面遇到的维数灾、数据过拟合、算法收敛到局部极小等问题^[8,9],被广泛应用于模式识别领域.

给定样本集 $\{x_k, y_k\}_{k=1}^Q, x_k \in R^m, y_k \in R$, 分别对应第 k 个样本的输入和输出, Q 为样本数. LS_SVM 采用下式构造最优分类函数:

$$y(x) = \text{sgn} \left[\sum_{k=1}^M \alpha_k \phi(x_k, x_j) + q \right]. \quad (28)$$

其中: M 为支持向量的个数; $\phi(x_k, x_j) = \varphi(x_k)^T \varphi(x_j)$ ($k, j = 1, 2, \dots, Q$) 为满足 Mercer 条件的核函数,其作用是将输入空间映射到高维空间; α 为 Lagrange 乘子; q 为常数. 其对应的优化问题为

$$\begin{aligned} \text{Min } J(\tau, \xi) &= \frac{1}{2} \tau^T \tau + \frac{\gamma}{2} \sum_{k=1}^Q \xi_k^2. \\ \text{s. t. } y_k &= \varphi(x_k)^T \tau + q + \xi_k; \\ \gamma &\geq 0, \xi_k \geq 0. \end{aligned} \quad (29)$$

其中: ξ 为拟合误差; γ 为惩罚因子,它是分类性能与模型复杂度的折衷; $\varphi(x_k)$ 为一非线性函数. 利用 Lagrange 乘法及 KKT 条件求解上述优化问题,可获得最优分类超平面.

优化 LS_SVM 相关参数的 chaos-QPSO 算法流程如下:

Step1: 按系统输入和输出建立训练样本集.

Step2: 选择核函数,本文选择常用的 RBF 核函数. 在正数范围内初始化正则化参数 γ 和核宽度 τ , 并将其按 $[\gamma, \tau]$ 编码为 2 维向量.

Step3: 初始化 QPSO 算法的基本参数,并定义适应度函数. 为提高泛化能力,将适应度函数定义为训练样本和测试样本的均方根误差(RMSE)的加权形式,其中权系数可调,即

$$\text{Fitness}(\gamma, \tau) = 0.2 * \text{RMSE}_{\text{train}} + 0.8 * \text{RMSE}_{\text{test}}. \quad (30)$$

Step4: chaos-QPSO 算法寻优阶段. 若不满足精度要求,则返回 Step3 重新初始化 QPSO 基本参数,直到满足精度要求为止.

6 系统仿真

6.1 模型划分

鉴于方法性研究,考虑如下较为简单的线性被控对象:

$$\begin{cases} \dot{x}_1 = x_2, \\ \dot{x}_2 = Ax_2 + Bu. \end{cases} \quad (31)$$

其中: $1 < A < 1000, 1 < B < 200$. 按标称模型将对象分割为 10 类,仿真时,以前 3 类模型为具体对象,如表 1 所示.

表 1 参数大范围系统分割结果

模型参数	标称模型		不确定模型	
	A*	B*	A	B
变化范围	500	100	1 ~ 1000	1 ~ 200
Model-1	50	10	1 ~ 100	1 ~ 20
Model-2	150	30	100 ~ 200	20 ~ 40
Model-3	250	50	200 ~ 300	40 ~ 60

表 1 中带 * 号的模型参数 A* 和 B* 表示标称模型的参数值,取不确定模型参数的均值.

基本的 LS_SVM 只能解决两类分类问题,利用多个两类分类 LS_SVM 可组成多类分类 LS_SVM 结构. 这里使用其中一种编码方案——1-a-r(one against rest). 该方案为每个类构建一个 LS_SVM,对每类的 LS_SVM 的训练样本库采用如下构成方式:属于该类的样本为正,其余均为负. 样本在不同的 LS_SVM 训练时正负不同,在训练时样本均需要重新标注. 为了取得较好的分类性能,需要足够多的系统信息构建样本库,这使得数据往往是高维向量,

导致计算复杂度剧增. 若人为减少信息和降低数据维数, 则可能导致缺乏足够的信息来描述系统行为, 从而分类性能变坏. 一种合理的处理方法是采用 PCA, 对数据进行特征提取, 以压缩数据简化计算.

6.2 仿真参数及结果

滑模控制器近似最佳切换函数的 chaos-QPSO 算法参数为: QPSO 离线迭代 500 次, 粒子数 $N = 10$, 单个粒子维数与优化参数个数相同, 为 1 维向量, 收缩扩张系数 ϱ 从 1 线性递减到 0.5. 混沌触发条件为: 累积迭代次数 $\epsilon = 100$, 微小正值 $\zeta = 0.001$, 辅助混沌搜索半径 χ 初值设为在混沌搜索前具有最佳适应度值的粒子 P_0 的 0.1%, 混沌局部细搜索的搜索半径设为 QPSO 搜索到的参数 P' 的 2%. 对 3 类模型获得的切换函数参数 μ 和误差指标 Error 分别为: $\mu_1 = 112.11, Error_1 = 8.6143e-005$; $\mu_2 = 133.86, Error_2 = 4.3575e-005$; $\mu_3 = 119.18, Error_3 = 1.2586e-005$. LS_SVM 参数寻优的算法参数为: 离线迭代 3000 次, 粒子数 $N = 20$, 粒子维数为 2 维向量, 其他参数同优化滑模切换函数参数时的情形, 获得的相关参数为: $\gamma = 118.1589, \sigma^2 = 7.8372$.

LS_SVM 分类器的构成是: 根据标称模型, 选取表征系统特性的输入 u , 输出 y 构成的数据样本对. 共分 3 类, 每个标称模型选取 60 组数据. 经过 PCA 分析, 获得相关 PCA 的数据点, 然后用于分类. 分类结果如图 2 所示. 训练分类正确率为 90.12%, 测试分类正确率为 89.25%, 测试样本按自定义关系式 $X_{test} = X_{train} + 0.1 * (2 * rand - 1)$ 采集. 其中: X_{test} 为测试样本, X_{train} 为训练样本, rand 为 (0, 1) 之

间的随机数. 从图中可以看出, LS_SVM 的性能良好, 能较好地进行分类.

对分割后小偏差模型的响应结果如图 3 所示. 该情形下期望 r 取正弦信号, 模型随时间变化的情形和信号具体幅值如下:

$$\begin{cases} A = 30, B = 8, t \leq 0.2; \\ A = 40, B = 12, 0.2 < t \leq 0.3; \\ A = 60, B = 14, 0.3 < t \leq 0.5; \\ A = 50, B = 10, 0.5 < t \leq 0.6; \\ \mu_1 = 112.11. \end{cases} \quad (32a)$$


$$\begin{cases} A = 150, B = 25, 0.6 < t \leq 0.8; \\ A = 155, B = 27, 0.8 < t \leq 0.9; \\ A = 145, B = 32, 0.9 < t \leq 1.2; \\ \mu_2 = 133.86. \end{cases} \quad (32b)$$

$$\begin{cases} A = 255, B = 50, 1.2 < t \leq 1.5; \\ A = 260, B = 55, 1.9 < t \leq 2.1; \\ A = 248, B = 47, 1.5 < t \leq 1.9; \\ \mu_3 = 119.18. \end{cases} \quad (32c)$$


$$\begin{cases} A = 160, B = 35, 2.1 < t \leq 2.3; \\ A = 140, B = 30, 2.3 < t \leq 2.5; \\ A = 180, B = 28, 2.5 < t \leq 2.7; \\ \mu_2 = 133.86. \end{cases} \quad (32d)$$

$$\begin{cases} A = 50, B = 10, 2.7 < t \leq 3; \\ \mu_1 = 112.11. \end{cases} \quad (32e)$$

$$r = \begin{cases} 0.5, 0 < t \leq 0.6; \\ 0.2, 0.6 < t \leq 1.2; \\ 0.1, 1.2 < t \leq 2.1; \\ 0.6, 2.1 < t \leq 2.7; \\ 0.7, 2.7 < t \leq 3. \end{cases} \quad (33)$$



(a) 训练分类



(b) 测试分类

图 2 LS_SVM 分类结果




图 3 信号跟踪

由图 3 可知, 对于在给定上下界范围内的模型参数变化, 采用分类转换策略时, 系统根据输入输出样本按 LS_SVM 自动选择合适的 SMC, 各个 SMC 对系统参数变化表现出较强的鲁棒性. 在不考虑噪声干扰的条件下, 跟踪误差很小, 取得了良好的控制品质. 为验证整个控制系统对模型参数变化的鲁棒性能, 图 4 给出了模型参数 A 和 B 增加自身 3% 变化时的结果, 在给定设计样本的条件下, 系统仍表现出

较好的鲁棒性和动静态性能. 图5给出了单一鲁棒控制器时的结果, 显然控制方法较为保守, 控制品质较差.




图4 参数变化时的鲁棒性验证结果




图5 单一鲁棒控制器响应结果

然而需要说明的是, 在海量样本和测试样本超出样本库取值范围较远的情形下, 分类效果并不理想. 在该情形下, 针对参数大范围变化, 模型的仿真测试中出现了跟踪突变的情况, 无法进行有效控制. 其原因是: 在线时, LS_SVM 的相关参数未能得到有效的实时调整. 本文在仿真研究时, LS_SVM 并没有在线训练的过程, 故离线时样本库需人为进行设计, 即以实际仿真时的期望信号为基准, 利用标称模型的方法采集合适的样本来构造样本库, 这并没有实现真正意义上的实时分类选择. 如何在海量样本条件下, 在线快速调整支持向量机的参数, 是需要进一步研究的课题.

7 结 论

本文提出了一种基于支持向量机分类选择的神经滑模控制策略. 通过对模型进行分割, 将大范围不确定转化为小偏差来处理. 基于 LS_SVM 良好的分类和泛化性能, 在设计样本库条件下, 使控制系统能根据实时样本对系统信息进行有效识别, 并自动选择合适的滑模控制器, 在保证系统稳定性的前提下进行有效控制. 同时, 配置带混沌搜索策略的 QPSO 算法优化控制系统中有关参数, 并引入 RBF 神经网络在线调整滑模切换项增益, 有效地降低了系统的抖振, 改善了系统的性能. 最后, 仿真结果取得了良好的控制品质, 为参数大范围变化的不确定系统控制问题提供了一种新的参考.

参考文献 (References)

- [1] 刘金琨, 孙富春. 滑模变结构控制理论及其算法研究与进展[J]. 控制理论与应用, 2007, 24(3): 407-418.
(Liu J K, Sun F C. Research and development on theory and algorithms of sliding mode control [J]. Control Theory and Applications, 2007, 24(3): 407-418.)
- [2] 张袅娜, 张德江, 冯勇. 基于混沌遗传算法的柔性机械手滑模控制器优化设计[J]. 控制理论与应用, 2008, 25(3): 451-455.
(Zhang N N, Zhang D J, Feng Y. The optimal design of terminal sliding controller for flexible manipulators based on chaotic genetic algorithm [J]. Control Theory and Applications, 2008, 25(3): 451-455.)
- [3] 郁明, 丛爽, 徐娟. 基于 GA 的非线性电机自适应模糊滑模控制器设计[J]. 系统仿真学报, 2008, 20(12): 3141-3145.
(Yu M, Cong S, Xu J. Design of nonlinear motor adaptive fuzzy sliding mode controller based on GA [J]. J of System Simulation, 2008, 20(12): 3141-3145.)
- [4] Ha Q P, Nguyen Q H, Rye D C, et al. Fuzzy sliding mode controllers with applications[J]. IEEE Trans on Industrial Electronics, 2001, 48(1): 38-41.
- [5] 林壮, 朱齐丹, 邢卓异. 基于遗传优化的水平欠驱动机械臂分层滑模控制[J]. 控制与决策, 2008, 23(1): 99-102.
(Lin Z, Zhu Q D, Xing Z Y. Hierarchical sliding mode control for horizontal under actuated manipulators with optimization based on GA [J]. Control and Decision, 2008, 23(1): 99-102.)
- [6] 刘金琨. 滑模变结构控制 Matlab 仿真[M]. 北京: 清华大学出版社, 2005: 227-229.
(Liu J K. Matlab simulation for sliding mode control [M]. Beijing: Tsinghua University Press, 2005: 227-229.)
- [7] Sun J, Feng B, Xu W B. Particle swarm optimization with particles having quantum behavior [C]. Proc of 2004 Congress on Evolution Computation. Piscataway: IEEE Press, 2004: 325-331.
- [8] Vapnik V, Golowich S, Smola A. Support vector method for function approximation, regression estimation and signal processing [C]. Advances Neural Information Processing System. Cambridge: MIT Press, 1997: 281-287.
- [9] 张学工. 关于统计学习理论和支持向量机[J]. 自动化学报, 2000, 26(1): 32-42.
(Zhang X G. Introduction to statistical learning theory and support vector machines [J]. Acta Automatica Sinica, 2000, 26(1): 32-42.)