

文章编号: 1001-0920(2008)04-0450-05

## 基于 IGS 和 SVM 的烧结返矿量智能集成预测模型

王春生, 吴敏, 曹卫华

(中南大学信息科学与工程学院, 长沙 410083)

**摘要:** 针对烧结返矿量难以进行有效预测的问题, 提出一种智能集成预测模型. 首先利用改进灰色系统和支持向量机两个单一模型分别对返矿量进行预测; 然后基于预测精度的数学期望和标准差, 通过求取最优加权系数, 建立烧结返矿量智能集成预测模型进行返矿量集成预测. 运行结果表明, 该集成模型的预测精度高于单一模型, 能有效地对返矿量进行预测.

**关键词:** 返矿量预测; 智能集成预测模型; 预测精度; 多目标规划

**中图分类号:** TP273

**文献标识码:** A

## Intelligent integrated prediction model for quantity of sintering return mines based on IGS and SVM

WANG Chunsheng, WU Min, CAO Wei-hua

(School of Information Science and Engineering, Central South University, Changsha 410083, China. Correspondent: WU Min, E-mail: min@csu.edu.cn)

**Abstract:** Based on the fact that the quantity of return mines is hard to predict effectively, an intelligent integrated prediction model is proposed. The quantity of sintering return mines is respectively predicted by using two single models, improved gray system (IGS) and support vector machine (SVM). Then, based on two precision indicators of mean and deviate, an intelligent integrated prediction model is introduced to predict the quantity of sintering return mines by calculating optimal weight coefficient. The prediction results show that the prediction precision of the integrated model is higher than that of single model, and it can predict the quantity of sintering return mines effectively.

**Key words:** Quantity of return mines prediction; Intelligent integrated prediction model; Prediction precision; Multi-objectives programming

### 1 引言

烧结过程是一个十分复杂的连续生产过程, 其最终产品是烧结矿, 其中粒度小于 5 mm 的烧结矿就是所谓的返矿. 它是烧结过程的中间产物, 并作为原料返回烧结生产的首道工序再次参与配料, 返矿配比的确定需要知道其产生量. 然而, 影响返矿量的因素很多, 它不仅与配料情况有关, 而且与烧结过程的许多因素有关, 如: 混合料透气性及含水量、点火温度和料层厚度等, 因此难以直接根据生产条件计算出返矿量. 采用化验值来计算返矿量在时间上滞后 3~4 个小时, 无法进行实时控制.

目前, 返矿配比是根据操作人员的经验来确定

的, 但是返矿的产生量往往是随机的, 这种方法缺少数据的支持, 所得到的配比仅考虑了当前的料位和过去时间段料位的变化情况, 未考虑未来一段时间返矿量的变化. 为了给返矿配比的确定提供数据上的支持, 保证烧结生产的稳定进行, 对烧结返矿量进行准确预测具有重要的意义.

针对烧结返矿量预测问题, 一些学者进行了深入研究<sup>[1,2]</sup>. 这些研究表明: 灰色系统预测是一种较为实用的返矿量预测方法, 但是预测精度不高, 同时, 返矿量变化趋势复杂, 受多个因素影响, 难以用单一模型进行有效预测. 灰色系统预测具有所需样本小、建模简单的特点, 由于采用生成模块进行建模, 不存在误差累积问题, 得到了广泛的应用<sup>[3,4]</sup>.

收稿日期: 2007-01-09; 修回日期: 2007-05-13.

基金项目: 国家杰出青年基金项目(60425310).

作者简介: 王春生(1966—), 男, 河南禹州人, 博士生, 从事复杂系统建模与优化控制的研究; 吴敏(1963—), 男, 广东化州人, 教授, 博士生导师, 从事过程控制、鲁棒控制等研究.

支持向量机与灰色系统一样对小样本预测具有优势,同时能较好地解决非线性、高维数和局部极小点等问题,近年来,已成为人们研究的热点<sup>[5,6]</sup>.

本文针对烧结返矿量预测问题,将改进灰色系统模型具有弱化数据序列波动性的特点与支持向量机具有对小样本进行非线性预测的优势相结合,提出一种基于改进灰色系统和支持向量机的智能集成预测模型,并对该集成预测模型的建立及其数学规划解法进行分析.最后结合工程实际,对集成预测模型的有效性进行了验证.

## 2 改进灰色系统和支持向量机预测模型

### 2.1 改进灰色系统预测模型

传统的灰色预测模型对于历史记录较短、零散分布的数据序列,往往会产生欠拟合或过拟合现象,导致预测精度降低.基于此,本文采用均值平滑法,提出了一种改进的灰色系统预测模型.在保留传统灰色预测模型优点的基础上,克服了传统灰色预测模型的不足,使所建模型具有弱化数据波动的能力.

已知某烧结厂的返矿量原始记录数据序列为  $X^{(0)} = \{X^{(0)}(1), X^{(0)}(2), \dots, X^{(0)}(n)\}$ .考虑到运用灰色模型预测时,如果原始数据有较大波动,容易造成预测结果不准确,误差较大,为减弱突变值的影响,均衡原始数列的趋势,尽量使原始数列趋势与指数的递增规律保持一致,进而提高预测的精度.本文采用均值平滑法,引入均值生成算子  $x^*(k) = 0.5x(k) + 0.5x(k-1)$  对返矿量原始数据进行平滑处理,得到平滑后的序列  $X^{(0)*}$ ,然后对其进行一阶累加生成序列  $X^{(1)}$  如下:

$$\begin{aligned} X^{(1)} &= \{x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)\}, \\ x^{(1)}(k) &= \sum_{i=1}^k x^{(0)*}(i). \end{aligned} \tag{1}$$

将返矿量原始数列累加生成后,弱化了原始数列中数据波动的影响.建立白化微分方程

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b. \tag{2}$$

记  $A = [a, b]^T$ ,用最小二乘法确定参数

$$A = (B^T B)^{-1} B^T Y_N. \tag{3}$$

其中

$$B = \begin{bmatrix} -0.5(x^{(1)}(1) + x^{(1)}(2)) & 1 \\ -0.5(x^{(1)}(2) + x^{(1)}(3)) & 1 \\ \dots & \dots \\ -0.5(x^{(1)}(n-1) + x^{(1)}(n)) & 1 \end{bmatrix},$$
$$Y_N = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \dots \\ x^{(0)}(n) \end{bmatrix}.$$

将求得的  $a$  和  $b$  代入式(2),通过求解微分方程得到 GM(1,1) 预测模型,即  $x^{(1)}$  随时间变化的规律

$$\hat{x}^{(1)}(k+1) = [x^{(0)}(1) - \frac{b}{a}]e^{-ak} + \frac{b}{a}, \quad k = 0, 1, \dots \tag{4}$$

对式(4)做累减生成还原,得到返矿量原始数列  $X^{(0)}$  灰色预测模型为

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 1, 2, \dots \tag{5}$$

### 2.2 支持向量机预测模型

本文选取某烧结厂实际返矿量数据进行建模,将数据分为两部分,其中前 24 个时刻的数据作为训练回归样本用于预测模型的学习训练,并进行相关参数估计,其余的数据用来验证预测模型的有效性.

为降低建模误差,首先对原始数据进行归一化处理,然后根据 Takens 理论进行相空间重构,将一维的时间序列转化为矩阵形式以获得数据间的关联关系.为使重构的相空间能充分反映系统运动的特征,需要恰当地选择嵌入维  $m$  和延迟时间  $\tau$  的大小.  $m$  以模型预测误差最小时来确定,经计算  $m$  取 6 比较合理.取  $\tau$  为位移观测间隔  $t$ ,并取  $t$  为单位 2(即  $t = 2$  h).建立自相关输入  $x_t = (x_{t-1}, x_{t-2}, \dots, x_{t-m})$  与输出  $y_t = \{x_t\}$  之间的映射关系  $f: R^m \rightarrow R$ .这样原始的一维时间序列变形后得到用于预测学习的样本  $(x_1, x_2, \dots, x_n)$ .

规范数据样本后,即可进行基于支持向量机的学习训练,其回归函数表示为

$$y_t = \sum_{i=1}^{n-m} (x_i - x_i^*) K(x_i \cdot x_t) + b, \quad t = m+1, \dots, n. \tag{6}$$

注意到  $x_{n-m+1} = \{x_{n-m+1}, x_{n-m+2}, \dots, x_n\}$  没有利用,因此可得到  $n+1$  时刻的返矿量预测值

$$y_{n+1} = \sum_{i=1}^{n-m} (x_i - x_i^*) K(x_i \cdot x_{n-m+1}) + b. \tag{7}$$

得到  $x_{n-m+1} = \{x_{n-m+1}, x_{n-m+2}, \dots, x_n\}$  后,可进一步得到样本数据:  $x_{n-m+2} = \{x_{n-m+2}, x_{n-m+3}, \dots, x_n, \hat{x}_{n+1}\}$ ,其中  $\hat{x}_{n+1}$  是第  $n+1$  时刻的返矿量预测值.依此递推,得到第  $l$  时刻返矿量支持向量机预测模型

$$y_{n+l} = \sum_{i=1}^{n-m} (x_i - x_i^*) K(x_i \cdot x_{n-m+l}) + b. \tag{8}$$

根据预测模型,逐步对未来时刻的返矿量进行预测.这里每预测一步,将增加的预测值添加到训练样本中,同时保持总训练样本数不变.支持向量机预测模型选取径向基函数作为核函数,通过计算参数

实验,确定相关参数的值。

### 3 返矿量智能集成预测模型

#### 3.1 智能集成预测模型的建立

为了使预测结果尽可能接近实际返矿量,提高模型的预测精度,基于集成思想,将上述两个预测模型进行并联加权集成<sup>[7,8]</sup>。同时考虑预测精度的数学期望和标准差这两个指标,以其数学期望最大化和标准差最小化为目标函数,建立返矿量智能集成预测模型,该模型的集成形式如图1所示。

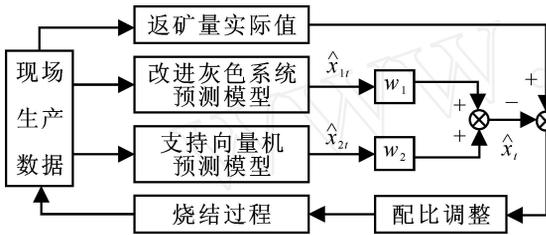


图1 返矿量预测模型的集成

图1中: $\hat{x}_{1t}$ 和 $\hat{x}_{2t}$ 分别表示改进灰色系统和支持向量机预测模型在第 $t$ 时刻的烧结返矿量预测值, $\hat{x}_t = w_1 \hat{x}_{1t} + w_2 \hat{x}_{2t}$ 是集成预测模型在第 $t$ 时刻的烧结返矿量预测值, $w_1$ 和 $w_2$ 分别是改进灰色系统和支持向量机预测模型的最优加权系数。

令

$$e_{it} = \begin{cases} (x_t - \hat{x}_{it}) / x_t, & |(x_t - \hat{x}_{it}) / x_t| \leq 1; \\ 1, & |(x_t - \hat{x}_{it}) / x_t| > 1. \end{cases}$$

其中: $e_{it}$ 为第 $i$ 个模型在第 $t$ 时刻的预测相对误差,矩阵 $E = (e_{it})_{m \times n}$ 为集成预测模型的相对误差矩阵。

令

$$A_{it} = \begin{cases} 1 - |e_{it}|, & |e_{it}| \leq 1; \\ 0, & |e_{it}| > 1. \end{cases}$$

其中 $A_{it}$ 为第 $i$ 个预测模型在第 $t$ 时刻的预测精度。

$E(A_i) = \sum_{t=1}^n P_t A_{it}$ 为第 $i$ 个预测模型预测精度序列

的数学期望, $(A_i) = \left[ \sum_{t=1}^n P_t (A_{it} - E(A_i))^2 \right]^{\frac{1}{2}}$ 为第 $i$ 个预测模型预测精度序列的标准差,其中 $P_t$ 为各预测模型预测精度序列的离散概率分布,并满足 $\sum_{t=1}^n P_t = 1, P_t \geq 0, t = 1, 2, \dots, n$ 。如果对预测模型预测精度的离散概率分布的先验信息不确定,则取 $P_t = 1/n$ 。

若以 $A_t$ 和 $e_t$ 分别表示集成预测模型在第 $t$ 时刻的预测精度和预测相对误差,则有

$$A_t = 1 - |e_t| = 1 - |(x_t - \hat{x}_t) / x_t| =$$

$$1 - \left| \sum_{i=1}^m w_i (x_t - \hat{x}_{it}) / x_t \right| = 1 - \left| \sum_{i=1}^m w_i e_{it} \right|. \quad (9)$$

集成模型预测精度的数学期望和标准差分别为

$$E(A) = \sum_{t=1}^n P_t A_t = \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right), \quad (10)$$

$$(A) = \left[ \sum_{t=1}^n P_t (A_t - E(A))^2 \right]^{\frac{1}{2}} =$$

$$\left[ \sum_{t=1}^n P_t A_t^2 - [E(A)]^2 \right]^{\frac{1}{2}} = \left\{ \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right)^2 - \left[ \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right) \right]^2 \right\}^{\frac{1}{2}}. \quad (11)$$

显然 $E(A)$ 和 $(A)$ 为单一预测模型在集成预测模型中的加权系数 $w_1, w_2, \dots, w_m$ 的函数,因此基于预测精度的返矿量集成模型可表示为如下模型:

$$\max E(A) = \max_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right), \quad (12)$$

$$\min (A) = \min_{t=1}^n \left\{ \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right)^2 - \left[ \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right) \right]^2 \right\}^{\frac{1}{2}}.$$

$$\text{s.t.} \begin{cases} \sum_{i=1}^m w_i = 1, \\ w_i \geq 0, i = 1, 2, \dots, m. \end{cases} \quad (13)$$

上述模型的两个目标之间是不可协调的: $E(A)$ 追求最大化, $(A)$ 追求最小化。如果存在 $W^* = (w_1^*, w_2^*, \dots, w_m^*)^T$ 使其同时满足这两个目标,那么它就是上述模型的最优解,但这很难实现。本文采用线性加权和法,对模型中的两个目标分别赋予权系数 $\mu$ 和 $1 - \mu$ ,将多目标规划问题转化为单目标规划问题,生成新的目标函数如下:

$$J(w_1, w_2, \dots, w_m) = \mu E(A) - (1 - \mu) (A) = \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right) - (1 - \mu) \left\{ \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right)^2 - \left[ \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right) \right]^2 \right\}^{\frac{1}{2}}. \quad (14)$$

从而将模型的多目标规划问题转化为单目标规划问题,得到如下返矿量集成预测模型(记为模型):

$$\max J(w_1, w_2, \dots, w_m) =$$

$$\begin{aligned} & \mu \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right) - \\ & (1 - \mu) \left\{ \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right)^2 - \right. \\ & \left. \left[ \sum_{t=1}^n P_t \left( 1 - \left| \sum_{i=1}^m w_i e_{it} \right| \right) \right]^2 \right\}^{\frac{1}{2}}, \\ & \text{s. t.} \begin{cases} \sum_{i=1}^m w_i = 1, \\ w_i \geq 0, i = 1, 2, \dots, m. \end{cases} \end{aligned} \quad (15)$$

其中  $\mu$  体现了预测者对  $E(A)$  和  $\sigma(A)$  两目标的相对偏好程度,  $0 \leq \mu \leq 1$ .

### 3.2 最优加权系数的确定

可以看出:绝对值的存在使得模型的目标函数不可导,模型实际上是不可微非线性规划,同时加权系数的位置也比较分散,当样本点数  $n$  较大时,模型的结构变得十分庞大,求解十分困难.为此,本文提出一种方法,其基本思想是将这种不可微非线性规划问题转化为可微非线性规划问题来求解.

显然,集成预测模型在第  $t$  时刻的预测精度序列  $\{A_{it}\}$  满足如下不等式:

$$\sum_{i=1}^m w_i A_{it} - A_t < 1. \quad (16)$$

其中  $A_{it}$  为第  $i$  个单一预测模型在第  $t$  时刻的预测精度;  $w_1, w_2, \dots, w_m$  为各模型的加权系数,且满足

$$\begin{aligned} & \sum_{i=1}^m w_i = 1, w_i \geq 0, \\ & i = 1, 2, \dots, m, t = 1, 2, \dots, n. \end{aligned} \quad (17)$$

可以证明,集成预测模型在第  $t$  时刻预测精度序列  $\{A_{it}\}$  的数学期望  $E(A)$  和标准差  $\sigma(A)$ ,  $m$  个单一预测模型预测精度序列  $\{A_{it}\}$  的数学期望  $E(A_i)$  和标准差  $\sigma(A_i)$  使下列等式成立:

$$E(A) = \sum_{i=1}^m \rho_i E(A_i) + (1 - \rho_0), \quad (18)$$

$$\begin{aligned} \sigma(A) = & \rho_0 \left[ \sum_{i=1}^m w_i^2 \sigma^2(A_i) + \right. \\ & \left. \sum_{i,j} w_i w_j \rho_{ij} \sigma(A_i) \sigma(A_j) \right]^{\frac{1}{2}}. \end{aligned} \quad (19)$$

其中  $\rho_0 \in [0, 1]$  和  $\rho_{ij}$  为第  $i$  个预测模型预测精度与第  $j$  个预测模型预测精度的相关系数,表示为

$$\rho_{ij} = \frac{\sum_{t=1}^n P_t (A_{it} - E(A_i)) (A_{jt} - E(A_j))}{\sigma(A_i) \sigma(A_j)}. \quad (20)$$

同样可以证明,在集成预测模型的相对误差矩阵  $E = (e_{it})_{m \times n}$  中,若任意第  $t$  列元素  $e_{1t}, e_{2t}, \dots, e_{mt}$  的符号完全相同,则模型的预测精度序列  $\{A_{it}\}$  的

数学期望  $E(A)$  和标准差  $\sigma(A)$  满足

$$E(A) = \sum_{i=1}^m w_i E(A_i), \quad (21)$$

$$\begin{aligned} \sigma(A) = & \left[ \sum_{i=1}^m w_i^2 \sigma^2(A_i) + \right. \\ & \left. \sum_{i,j} w_i w_j \rho_{ij} \sigma(A_i) \sigma(A_j) \right]^{\frac{1}{2}}. \end{aligned} \quad (22)$$

根据式(18) ~ (20),返矿量智能集成预测模型可进一步等价如下优化模型:

$$\begin{aligned} & \max J(w_1, w_2, \dots, w_m) = \\ & \mu \left[ \sum_{i=1}^m w_i E(A_i) + (1 - \rho_0) \right] - \\ & (1 - \mu) \rho_0 \left[ \sum_{i=1}^m w_i^2 \sigma^2(A_i) + \right. \\ & \left. \sum_{i,j} w_i w_j \rho_{ij} \sigma(A_i) \sigma(A_j) \right]^{\frac{1}{2}}, \\ & \text{s. t.} \begin{cases} \sum_{i=1}^m w_i = 1, \\ w_i \geq 0, i = 1, 2, \dots, m. \end{cases} \end{aligned}$$

其中  $\rho_0 \in [0, 1]$ . 若预测模型相对误差的符号一致,则取  $\rho_0 = 1$ ; 若不一致,则不一致的程度越严重,  $\rho_0$  的取值将越小.

与模型相比,模型的最大特点是去掉了模型中目标函数的绝对值,从而由一个不可微非线性规划变为模型的可微非线性规划,易于求解.由上所述可得模型的求解步骤如下:

Step1: 利用单一预测模型对烧结返矿量进行预测,得到预测值序列  $\{\hat{x}_{it}\}$ , 据此计算不同时刻的预测精度序列  $\{A_{it}\}$  及其均值  $E(A_i)$ , 方差  $\sigma^2(A_i)$  和相关系数  $\rho_{ij}$ .

Step2: 给定常数  $\rho_0 \in [0, 1]$  以及相对偏好系数  $\mu \in [0, 1]$ , 按照返矿量集成预测模型计算最优加权系数  $w_1^*, w_2^*, \dots, w_m^*$ .

Step3: 根据最优加权系数,按照  $x_t = w_1^* x_{1t} + w_2^* x_{2t} + \dots + w_m^* x_{mt}$  对返矿量进行预测.

## 4 运行结果分析

取某烧结厂的实际返矿量数据进行建模,将所有数据按照  $N$ (训练集)  $M$ (测试集) = 1 : 1 的标准进行划分,这样 24 个样本作为训练回归样本用于预测模型的学习训练,另外 24 个时刻的样本用来验证预测模型的有效性.两个单一预测模型的预测相对误差和预测精度序列值见表 1.

可以看出,两个单一模型的相对误差  $e_{1t}$  和  $e_{2t}$  的符号不完全一致,取  $\rho_0 = 0.1$ ,  $P_t = 1/24$ , 按照上

表 1 3 个模型预测精度序列值及相对误差比较表

| 时刻 | 预测相对误差 $e_{it}$ |               |            | 预测精度序列值 $A_{it}$ |               |            |
|----|-----------------|---------------|------------|------------------|---------------|------------|
|    | 改进灰色 $e_{1t}$   | 支持向量 $e_{2t}$ | 集成模型 $e_t$ | 改进灰色 $A_{1t}$    | 支持向量 $A_{2t}$ | 集成模型 $A_t$ |
| 1  | -0.075 0        | 0.033 5       | -0.017 9   | 0.925 0          | 0.966 5       | 0.982 1    |
| 2  | -0.043 9        | 0.029 5       | -0.005 3   | 0.956 1          | 0.970 5       | 0.994 7    |
| 3  | -0.065 7        | 0.016 6       | -0.022 4   | 0.934 3          | 0.983 4       | 0.977 6    |
| 4  | -0.026 0        | 0.031 1       | 0.004 1    | 0.974 0          | 0.968 9       | 0.995 9    |
| 5  | -0.020 8        | 0.018 3       | -0.000 2   | 0.979 2          | 0.981 7       | 0.999 8    |
| 6  | -0.044 4        | -0.024 5      | -0.033 9   | 0.955 6          | 0.975 5       | 0.966 1    |
| 7  | 0.044 5         | -0.009 8      | 0.015 9    | 0.955 5          | 0.990 2       | 0.984 1    |
| 8  | 0.038 6         | -0.015 5      | 0.010 1    | 0.961 4          | 0.984 5       | 0.989 9    |
| 9  | 0.023 4         | -0.016 0      | 0.002 7    | 0.976 6          | 0.984 0       | 0.997 3    |
| 10 | -0.011 4        | 0.018 5       | 0.004 4    | 0.988 6          | 0.981 5       | 0.995 6    |
| 11 | -0.027 8        | 0.019 2       | -0.003 1   | 0.972 2          | 0.980 8       | 0.996 9    |
| 12 | -0.017 6        | 0.021 4       | 0.003 0    | 0.982 4          | 0.978 6       | 0.997 0    |
| 13 | -0.019 7        | 0.016 4       | -0.000 7   | 0.980 3          | 0.983 6       | 0.999 3    |
| 14 | -0.024 1        | 0.015 6       | -0.003 2   | 0.975 9          | 0.984 4       | 0.996 8    |
| 15 | -0.033 1        | 0.018 8       | -0.005 8   | 0.966 9          | 0.981 2       | 0.994 2    |
| 16 | -0.018 1        | 0.021 3       | 0.002 6    | 0.981 9          | 0.978 7       | 0.997 4    |
| 17 | -0.016 2        | 0.009 2       | -0.002 8   | 0.983 8          | 0.990 8       | 0.997 2    |
| 18 | -0.015 1        | 0.015 6       | 0.001 0    | 0.984 9          | 0.984 4       | 0.999 0    |
| 19 | -0.018 8        | 0.012 2       | -0.002 5   | 0.981 2          | 0.987 8       | 0.997 5    |
| 20 | -0.040 3        | 0.016 6       | -0.010 3   | 0.959 7          | 0.983 4       | 0.989 7    |
| 21 | -0.021 4        | 0.026 2       | 0.003 7    | 0.978 6          | 0.973 8       | 0.996 3    |
| 22 | -0.035 5        | 0.023 3       | -0.004 6   | 0.964 5          | 0.976 7       | 0.995 4    |
| 23 | -0.048 6        | 0.019 4       | -0.012 8   | 0.951 4          | 0.980 6       | 0.987 2    |
| 24 | -0.040 3        | 0.032 5       | -0.002 0   | 0.959 7          | 0.967 5       | 0.998 0    |

述模型 的求解步骤,利用 Matlab 最优化工具箱计算得到最优加权系数分别为  $w_1^* = 0.473 3, w_2^* = 0.526 7$ . 从而得到集成预测模型为  $\hat{x}_t = 0.473 3\hat{x}_{1t} + 0.526 7\hat{x}_{2t}$ , 其预测相对误差和预测精度序列见表 1.

为了对 3 个模型的预测效果和性能进行评价, 本文采用均方根相对误差 MSE 和绝对值平均相对误差 MAPE 这两个指标, 预测效果比较如表 2 所示, 3 个预测模型的预测结果如图 2 所示.

表 2 预测效果评价表

| 评价指标 | 改进灰色系统模型 | 支持向量机模型 | 集成预测模型  |
|------|----------|---------|---------|
| MSE  | 0.035 8  | 0.021 1 | 0.010 8 |
| MAPE | 0.032 1  | 0.020 0 | 0.007 3 |

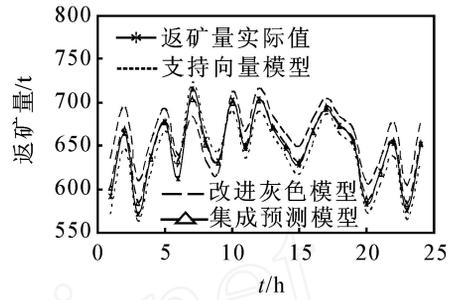


图 2 3 个模型预测结果

可以看出, 当采用改进灰色系统和支持向量机方法分别对烧结返矿量进行预测时, 支持向量机预测模型的预测精度和预测性能高于改进灰色预测模型. 但是, 采用本文提出的方法对两种单一预测模型的预测结果进行加权集成后, 得到的集成预测模型的预测精度要高于单一预测模型, 其预测性能比支持向量机的预测性能有较大提高. MSE 从 2.11 % 减少到 1.08 %, MAPE 从 2 % 减少到 0.73 %, 这都说明集成预测模型的预测精度和性能要高于改进灰色系统和支持向量机预测模型, 图 2 也可说明这一点.

### 5 结 论

本文针对烧结返矿量预测问题, 提出了一种以预测精度的数学期望和标准差为目标函数的智能集成预测模型. 它将灰色系统和支持向量机预测模型进行有效集成, 最后结合实际工程应用, 对智能集成预测模型的有效性进行了验证. 结果表明: 利用本文方法所建立的集成预测模型能够获得更高的预测精度, 其预测效果和性能优于灰色系统和支持向量机预测模型. 本文提出的智能集成方法较好地解决了复杂的烧结返矿量预测问题, 是一种有效的预测方法, 可以推广应用到其他类似的复杂工业过程.

### 参考文献(References)

[1] 郑德玲, 赵志坚, 刘顺心. 灰色系统理论在烧结返矿量预测中的应用[J]. 控制与决策, 1999, 14(3): 245-248.  
(Zheng De-ling, Zhao Zhi-jian, Liu Shun-xin. Application of grey system theory in forecasting of quantity of sintering return mines [J]. Control and Decision, 1999, 14(3): 245-248.)

[2] 梁开, 方康玲. 烧结返矿量预测中的灰色-时序组合模型[J]. 中南大学学报, 2005, 36(增 1): 639-641.  
(Liang Kai, Fang Kang-ling. Grey-time series combination model in forecasting sintering return mines [J]. J. of CENT South University, 2005, 36(S1): 639-641.)

(下转第 459 页)

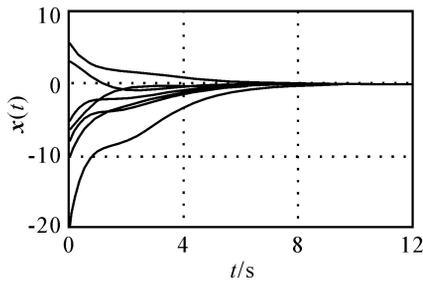


图 5 系统状态  $x(t)$

可见,系统达到设计要求.

### 5 结 论

本文针对一类系统矩阵和输入矩阵存在不确定性的多变量系统,基于终端滑模设计方法,利用微分估计器技术,提出一种二阶滑模控制方法.实现了无抖振滑模控制,提高了系统的动态响应速度,并实现系统鲁棒递阶控制.仿真结果表明了所提方法的有效性.

### 参考文献(References)

[1] Erbatur K, Kawamura A. Chattering elimination via fuzzy boundary layer tuning[J]. IECON, 2002, 3(3): 2131-2136.

[2] Xu J X, Lee T H, Pan YJ. On the sliding mode control for DC servo mechanisms in the presence of unmodeled

dynamics[J]. Mechatronics, 2003, 13(7): 755-770.

[3] Levant A. Higher-order sliding modes, differentiation and output-feedback control[J]. Int J of Control, 2003, 76(9): 924-941.

[4] Bartolini G, Ferrara A, Usai E. Applications of a suboptimal discontinuous control algorithm for uncertain second order systems[J]. Int J of Robust and Nonlinear Control, 1997, 7(4): 299-319.

[5] Chiacchiarini H G, Desages A C. Variable structure control with a second-order sliding condition: Application to a steam generator [J]. Automatica, 1995, 131(8): 1157-1168.

[6] Elmali H, Olgac N. Implementation of sliding model control with perturbation estimation[J]. IEEE Trans on Control Systems Technology, 1996, 4(1): 79-85.

[7] Lukyanov A G, Utkin V I. Optimal linear systems with degenerate criteria [C]. Proc of the American Control Conf. Philadelphia, 1998: 2884-2888.

[8] Wolfram Research. Advanced numerical method document [EB/OL]. <http://documents.wolfram.com/applicans/anm/BlockHessenbergForms/41.html>. 2003.

[9] Feng Y, Yu X H, Man Z H. Non-singular adaptive terminal sliding mode control of rigid manipulators[J]. Automatica, 2002, 38(12): 2159-2167.

(上接第 454 页)

[3] 袁基伟, 史忠科. 一种基于灰色预测模型 GM(1,1)的运动车辆跟踪方法[J]. 控制与决策, 2006, 21(3): 300-304.  
(Yuan Ji-wei, Shi Zhong-ke. A method of vehicle tracking based on GM(1,1) [J]. Control and Decision, 2006, 21(3): 300-304.)

[4] Albert W L Yao, Chi S C, Chen J H. An improved Grey-based approach for electricity demand forecasting [J]. Electric Power Systems Research, 2003, (67): 217-224.

[5] 常玉清, 邹伟, 王福利, 等. 基于支持向量机的软测量方法研究[J]. 控制与决策, 2005, 20(11): 1307-1310.  
(Chang Yu-qing, Zou Wei, Wang Fu-li, et al. Research on soft sensing method based on support vector machines [J]. Control and Decision, 2005, 20(11): 1307-1310.)

[6] 董辉, 傅鹤林, 冷伍明. 支持向量机的时间序列回归与预测 [J]. 系统仿真学报, 2006, 18(7): 1785-1788.

(Dong Hui, Fu He-lin, Leng Wu-ming. Support vector machines for time series regression and prediction[J]. J of System Simulation, 2006, 18(7): 1785-1788.)

[7] 陈华友, 侯定丕. 基于预测有效度的优性组合预测模型研究[J]. 中国科学技术大学学报, 2002, 32(2): 172-180.  
(Chen Hua-you, Hou Ding-pi. Research on superior combination forecasting model based on forecasting effective measure [J]. J of University of Science and Technology of China, 2002, 32(2): 172-180.)

[8] 陈晓方, 桂卫华, 王雅琳, 等. 基于智能集成策略的烧结块残硫软测量模型[J]. 控制理论与应用, 2004, 21(1): 75-80.  
(Chen Xiao-fang, Gui Wei-hua, Wang Ya-lin, et al. Soft-sensing model of sulfur content in agglomerate based on intelligent integrated strategy [J]. Control Theory and Applications, 2004, 21(1): 75-80.)