

文章编号:1000-582X(2011)05-123-07

# 小样本贫信息条件下高炉冶炼烧结终点组合预测法

王爱民<sup>1,2</sup>, 宋强<sup>3</sup>, 李华<sup>4</sup>, 张运素<sup>4</sup>, 徐蕾<sup>4</sup>

(1. 武汉理工大学计算机学院, 湖北武汉 430070; 2. 安阳师范学院计算机信息与工程学院, 河南安阳 455002;  
3. 安阳工学院机械工程学院, 河南安阳 455000; 4. 安阳钢铁集团公司, 河南安阳 455004)

**摘要:** 由于烧结过程具有不确定性、多变量耦合、时变时滞的特点, 并且烧结终点受多种因素的影响, 采用传统控制方法难以将烧结终点控制在要求的范围内, 提出应用支持向量机优良的时序预测性能, 以及贝叶斯理论能够利用样本信息和先验知识来简化预测模型和优化参数的特性, 建立了贝叶斯支持向量机烧结终点的预报模型。首先对烧结终点的机理分析, 后分别叙述贝叶斯框架理论和 LS-SVM 算法, 并将贝叶斯证据框架应用于最小二乘支持向量机模型参数的自动选择, 建立起时间序列的烧结终点非线性预测模型。在贝叶斯推断的第一层, 进行模型参数的选择; 在贝叶斯推断的第二层, 进行模型超参数的选择; 在贝叶斯推断的第三层, 估计模型核参数, 然后利用贝叶斯最小二乘支持向量机算法 (LS-SVM) 对烧结终点进行预测, 并在此基础上构造了烧结终点的贝叶斯最小二乘支持向量机模型。仿真结果和多种模型比较表明, 本模型能在小样本贫信息条件下对烧结终点做出比较准确的预测, 并具有预测精度高、所需样本少、计算简便等优点, 取得了令人满意的结果。

**关键词:** 贝叶斯理论; LS-SVM; 烧结终点; 预测

**中图分类号:** TP273

**文献标志码:** A

## Combination forecasting method of BTP in blast furnace under the conditions of small samples and poor information

WANG Ai-min<sup>1,2</sup>, SONG Qiang<sup>3</sup>, LI Hua<sup>4</sup>, ZHANG Yun-su<sup>4</sup>, XU Lei<sup>4</sup>

(1. College of Computer Science & Technology, Wuhan University of Technology, Wuhan, Hubei 430070, P. R. China; 2. Computer Science Department, Anyang Normal University, Anyang, Henan 455002, P. R. China; 3. Mechanical Engineering Department, Anyang Institute of Technology, Anyang, Henan 455000, P. R. China; 4. Anyang Steel & Iron Corporation, Anyang, Henan 455004, P. R. China)

**Abstract:** The iron ore sintering process is a complex object with the characteristics of uncertainty, multivariable coupling, time-varying and time-delay. The burning-through-point (BTP) is affected by many factors and difficult to be controlled to the required precision by conventional control methods. A BTP prediction method is proposed by using the excellent time series prediction performance of support vector machines (SVMs), and the characteristic that Bayesian theory can make use of sample information and prior knowledge to simplify prediction model and optimize parameters. Firstly, the mechanism of BTP is analyzed, the Bayesian theory and LS-SVM are elaborated respectively, and the Bayesian evidence

收稿时间: 2010-11-30

基金项目: 国家自然科学基金资助项目(60973051); 河南省重大科技攻关项目(092102210112)

作者简介: 王爱民(1957-), 男, 武汉理工大学博士, 主要从事数据挖掘与智能技术的研究, (E-mail)wam508@126.com。

framework is applied to least squared support vector machine (LS-SVM) regression in order to infer non-linear models for predicting a time series. On the first level of inference, model parameters are selected and on the second level the hyper-parameters are selected. The kernel parameter are tuned on the third level framework, and on this level the relevant inputs are selected. A LS-SVM model is proposed on the basis of the Bayesian LS-SVM models. The results reveal that the BTP of sinter can be accurately predicted by this model even with small samples and poor information. It is concluded that the LS-SVM model is effective with the advantages of high precision, less samples required and simple calculation.

**Key words:** Bayesian theory; LS-SVM; BTP; prediction

烧结生产的主要目的是为高炉冶炼提供品相高、粒度大小均匀、化学成分比较稳定、强度高、冶金性能比较好的烧结矿原料。而判断烧结过程是否正常的重要标志之一是烧结终点,也就是烧结矿烧结结束时的位置,它与烧结矿产量、质量和经济成本学习相关,是烧结机运行操作和控制决策的主要依据。如果烧结终点提前,将会导致过烧现象,从而产生烧结机利用率不高,烧结机的有效烧结面积没有得到充分利用,烧结矿的产量明显下降。若烧结终点滞后,则会使混合料层没有得到充分燃烧,进而导致烧结块冷却不够,烧结块过脆,结块率降低,从而烧结矿质量下降,返矿率增加。在烧结过程中,如果对烧结终点提前进行准确预测,并根据烧结终点的预测值作相应的变化与调整,使烧结终点始终控制在设定值附近,这样不仅能够提高烧结矿的产量、质量以及节能降耗,而且能够带来显著的经济效益<sup>[1]</sup>。常用的烧结终点预测和判断方法有废气温度法、负压法、废气成分判断法以及根据基于风箱废气温度的烧结过程热状态识别方法等传统方法<sup>[1]</sup>和以灰色理论法<sup>[1]</sup>、人工神经网络<sup>[2-3]</sup>、遗传神经网络<sup>[4]</sup>、多元模糊线性回归<sup>[5]</sup>、模糊神经网络<sup>[6]</sup>等为代表的基于人工智能理论的方法。基于人工神经网络的预测方法获得了一些很成功的应用,但是在训练过程中不可避免地存在局部极小问题、收敛速度较慢、网络隐含层个数难以确定等问题,这些不足极大地限制了其应用。文献[4]提出了一种基于神经网络和遗传算法的方法来预测和控制烧结位置。LM 神经网络具有快速逼近能力,而遗传算法可以克服局部最优问题,从而既能使模型具有很强的鲁棒性和适应性,又能消除过程控制的不确定因素。仿真结果表明,该系统能提前 30 min 准确地预估控制点的位置,为大系统控制奠定了基础。但缺点是编码不太容易,收敛速度较慢,另外容易出现早熟现象,需要根据具体问题调整选择和变异策略。针对烧结工艺过程,文献[6]提出一种基于模糊神经网络的烧结终点预测模型。实际预测结果表明:利用此方法建立的预测模型能够较为准确地反映实际生产过程,具有较高

的预测精度。模型需要事先对数据源进行分类,模型的推广能力和具体使用的聚类方法有一定关系。而且如果数据的分类较多,会使模型的规则数增加过多,导致网络结构复杂化。

烧结过程是一个具有不确定性、非线性、强耦合、大滞后性等特点的复杂的物理、化学反应过程,采用机理模型或传统的控制技术难以满足烧结生产的要求。支持向量机是近年来的研究热点,应用非常多的机器学习理论,它是在统计学习理论上发展而来的一种新的高效学习方法。它将很多学习方法归纳其中,可以解决很多原来难以解决的实际问题,譬如小样本、贫信息、非线性、高维数、局部极小点等实际问题,而 LS-SVM 由于把非线性约束变为线性约束,这使网络的运算能力明显加快,因此在烧结终点问题中得到了很好的应用<sup>[7-8]</sup>。文献[7]采用支持向量机算法对烧结终点进行预测,结果表明支持向量机显示了良好的时序预测性能,烧结终点预报模型的预报精度比较高,能够比较准确地预报烧结终点,但是无论是支持向量机(SVM)还是最小二乘支持向量机( LS-SVM),它们对正则化参数、核参数以及其他与特定模型参数都比较敏感,要得到较好的预测结果,需要对这些参数进行反复地调试,经过很长的时间才能选择和确定合适的参数。在已有的文献中,这些参数的选择和确定是与建模者的经验水平有很大关系。

近年来,由于贝叶斯方法具备的逻辑一致性以及简单、灵活的特点,而且贝叶斯理论能够利用样本信息和先验知识,简化预测模型,优化参数,已经被广泛应用于预测模型的设计中,笔者将以这些文献为基础,将贝叶斯证据框架应用于 LS-SVM 的预测模型设计。与其他传统方法相比,该方法能够实现模型参数的自动选择和确定。在深入研究烧结终点(burning-through-point, BTP)变化规律的基础上,采用贝叶斯推断理论和最小二乘支持向量机的组合建模方法实现了高炉冶炼烧结终点的定量预报。

## 1 烧结终点的机理分析和影响因素

烧结过程有多道程序。首先,将各原矿石按一

定的比例要求配成烧结原料,经一次混合和二次混合制粒得到水分及粒度均匀的烧结混合料,将其均匀地铺在烧结机上,点火并抽风烧结,最终固结成成分适宜、具有一定强度和空隙度的烧结块。在烧结过程中,烧结料在烧结机上点火后,台车以一定的速度运动,烧结料随着从下至上负压抽风烧结,燃烧点逐渐向料层低层移动,最终在料层底层烧透,把烧透的点所对应的烧结机位置定义为烧结终点 BTP。铁矿石烧结过程存在着较大的滞后,要实现烧结终点实时优化控制首先要建立预测模型。进行烧结终点预测时,经常需要使用受不确定相关环境因素影响的历史数据进行预测,模糊数学为处理此类问题提供了有效手段<sup>[4]</sup>。

烧结终点是指烧结结束时的位置,用料层烧透时所对应的风箱位置来表示。一般认为 BTP 应当控制在倒数第 2 个风箱的位置。烧结终点涉及的因素众多,而且 BTP 无法直接监测,目前还没有能在线检测 BTP 的仪器,同时人为判断不可避免带有不确定性。笔者在不增加硬件设备的前提下,用 LS-SVM 方法解决 BTP 在线检测问题<sup>[4]</sup>。

在实际的烧结工艺过程中,烧结终点的影响因素有很多,如点火温度、料层厚度、混合料水分、台车速度、风量、混合料中的返矿、生石灰用量、燃料用量、废气温度、碱度、混合料粒度等。

## 2 贝叶斯和 LS-SVM 组合算法建模思想

### 2.1 LS-SVM 算法

SVM 方法的基本思想是:首先定义最优线性超平面,并把寻找最优线性超平面的算法归结为求解一个凸规划问题。进而基于 Mercer 核展开定理,通过非线性映射  $\phi$ ,把样本空间映射到一个高维乃至无穷维的特征空间(Hilbert 空间),使在特征空间中可以应用线性学习机的方法解决样本空间中的高度非线性分类和回归等问题。在 1999 年,Suykens 在标准 SVM 的基础上,在目标函数中增加了误差平方和项,将标准 SVM 中的不等式约束转化为等式约束,将二次规划问题转换到相应的对偶空间,因此他提出了最小二乘支持向量机(Least Squares Support Vector Machines, LS-SVM)方法,并解决了其中 SVM 所存在的鲁棒性、稀疏性和大规模运算问题,最小二乘支持向量机方法是采用最小二乘线性系统作为损失函数,代替了传统的支持向量机采用的二次规划方法。

设定数据集  $D = \{(x_1, y_1), \dots, (x_k, y_k), \dots, (x_N, y_N)\}$ ,  $x_k \in R^n, y_k \in R$ 。

在高维空间里构建最优决策函数即

$$y(x) = w^T \varphi(x) + b, \quad (1)$$

其中,非线性函数  $\varphi(\cdot): R^n \rightarrow R^{n_h}$  将原输入空间映射到高维特征空间,也就是将低维空间里的非线性函数映射到高维空间里的线性估计函数。在 LS-SVM 中,目标函数描述为:

$$\min J(w, e) = \frac{1}{2} w^T w + \gamma \frac{1}{2} \sum_{i=1}^N e_i^2, \quad (2)$$

$$\text{s. t. } y(x) = w^T \varphi(x_i) + b + e_i, t = 1, 2, \dots, N, \quad (3)$$

其中  $e_i$  为松弛因子。

利用拉格朗日定理求解该函数,可以得到:

$$L(w, b, e, \alpha) = J(w, e) - \sum_{i=1}^N \alpha_i \{w^T \varphi(x_i) + b + e_i - y_i\}, \quad (4)$$

其中  $\alpha_i$  是拉格朗日乘子。根据 Karush-Kuhn-Tucker(KKT)优化条件,可得到最优解的条件:

$$\begin{cases} \frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_{i=1}^N \alpha_i \varphi(x_i), \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i = 0, \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = \gamma e_i, \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow w^T \varphi_i + b + e_i - y_i = 0, \end{cases} \quad t = 1, 2, \dots, N \quad (5)$$

经过化简,得到如下线性方程组:

$$\begin{bmatrix} 0 & 1^T \\ 1 & \varphi(x_i)^T \varphi(x_i) + D \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}, \quad (6)$$

式中:  $y = [y_1, \dots, y_N]$ ,  $1 = [1, \dots, 1]$ ,  $\alpha = [\alpha_1, \dots, \alpha_N]$ ,  $D = \text{diag}[\gamma_1, \dots, \gamma_N]$ , 选择  $\gamma > 0$ , 保证矩阵

$$\varphi = \begin{bmatrix} 0 & 1^T \\ 1 & \varphi(x_i)^T \varphi(x_i) + D \end{bmatrix}. \quad (7)$$

上述方程可逆,则 LS-SVM 的算法优化问题就转化为如下所述的线性方程组。

$$\begin{bmatrix} b \\ \alpha \end{bmatrix} = \varphi^{-1} \begin{bmatrix} 0 \\ y \end{bmatrix}. \quad (8)$$

因此被控对象非线性回归模型如下:

$$y(x) = \sum_{i=1}^N \alpha_i \exp\{-\|x - x_i\|_2^2 / 2\sigma^2\} + b. \quad (9)$$

LS-SVM 构建的回归函数简单明了,很容易求解,简化了计算的复杂性,运算速度也大大加快。核函数对预测模型的精度和泛化能力有一定的影响。笔者选择支持向量机的标准高斯核函数 RBF 进行建模,函数中  $\sigma$  表示核宽度。

LS-SVM 算法中有 2 个最重要的参数,即正则

化参数  $\gamma$  和核函数  $\sigma$ , 它们的选择对算法性能有很大影响, 若正规化参数  $\gamma$  取得太小, 则对样本数据的惩罚系数就小, 导致训练误差变大, 算法的泛化性能就会变差; 若  $\gamma$  取得过大, 相应  $\frac{\omega^T \omega}{2}$  的权重就小, 算法的泛化性能变差。同样, 采用高斯核函数时, 核函数  $\sigma$  太小, 会对样本数据造成过学习现象, 核函数  $\sigma$  太大, 会对样本数据造成欠学习现象。因此必须合理确定这 2 个参数。

## 2.2 贝叶斯框架理论下的 LS-SVM

贝叶斯框架下的最小二乘支持向量机就是指用贝叶斯推断理论的方法来自动确定 LS-SVM 的正则化参数和核参数。证据框架将贝叶斯推断分为 3 个准则的推断, 贝叶斯证据框架下的基本思想是将参数分布的后验最大化, 然后在参数分布后验最大化的情况下得到最佳参数值或模型, 在最小二乘支持向量机中, 根据准则 1 来推断参数  $\omega$  和  $b$ , 利用准则 2 来推断正则化参数  $\gamma$ , 利用准则 3 可以用来估计核参数  $\sigma$ 。其整个推断的基础就是贝叶斯规则: 根据贝叶斯第一准则来估计自由参数  $\omega$ 。利用最大化参数的后验, 可以得到参数  $\omega$  的最佳值<sup>[11-12]</sup>。参数  $\omega$  的后验:

$$P(\omega/D, \gamma, H) = \frac{P(D/\omega, \gamma, H)P(\omega/\gamma, H)}{P(D/\gamma, H)} \quad (10)$$

在贝叶斯第二准则下, 利用贝叶斯参数推断模型来推断正则化函数。利用最大化参数  $\gamma$  的后验, 即可得到参数的最佳值  $\gamma$ <sup>[13-14]</sup>。参数  $\gamma$  的后验:

$$P(\gamma/D, H) = \frac{P(D/\gamma, H)P(\gamma, H)}{P(D/H)} \quad (11)$$

在贝叶斯第三准则下, 利用贝叶斯参数推断模型来推断支持向量机估计算法的最优核参数。利用最大化模型  $\sigma$  的后验, 即可得到最小二乘支持向量机核参数  $\sigma$  的最佳值<sup>[15-17]</sup>。模型  $\sigma$  的后验:

$$P(H, D) = \frac{P(D/H)P(H)}{P(D)} \quad (12)$$

## 2.3 贝叶斯框架下的 LS-SVM 实现步骤

基于 LS-SVM 的非线性时间序列预测模型是一个灰箱系统, 可以由 LS-SVM 来实现它的模型输入值与输出值之间所存在的非线性函数关系, 最小二乘支持向量机的模型参数正则化参数  $\gamma$  和核函数  $\sigma$  等根据贝叶斯证据框架下推导得出, 贝叶斯框架下的最小二乘支持向量机的建模步骤如下:

1) 首先对在烧结现场中采集的样本数据进行预处理。包括对一些异常数据的剔除处理、数据噪声消除、归一化处理, 将输入、输出的数据变为均值为 0、方差为 1 的平稳时间序列。

2) 选择支持向量机的估计算法。

3) 设定初始参数值, 对最小二乘支持向量机进行训练, 迭代推断模型参数  $\omega$  和  $b$ 。

4) 迭代推断正则化参数  $\gamma$ 。

5) 迭代推断核参数  $\sigma$ 。

6) 返回第 3) 步, 用所求的参数重新训练支持向量机模型, 从中遴选出最优模型及输入。

7) 用建立好的模型进行回归预测。

## 3 烧结终点预报分析

### 3.1 烧结终点的数学模型描述

烧结终点的预报问题的描述为

$$\begin{aligned} y(k+d) &= f(y(k), y(k-1), \dots, y(k-n+1)); \\ u_1(k), u_1(k-1), \dots, u_1(k-n+1); \\ u_2(k), u_2(k-1), \dots, u_2(k-n+1); u_p(k), \\ &u_p(k-1), \dots, u_p(k-n+1) \end{aligned}$$

其中:  $y$  为烧结终点时间序列;  $u$  为预报参数时间序列;  $p$  为用于预报的参数个数;  $y(k+d)$  为提前  $d$  步的烧结终点预报值。研究的目的是确定非线性函数  $f: y_n \times u_p \times n \rightarrow y_n$ , 考虑到被研究系统存在动态大时滞特性, 烧结终点的预报问题转化为非线性系统的动态系统辨识问题。最小二乘支持向量机 (LS-SVM) 的小样本、全局优化、泛化能力强为动态系统辨识提供了一条有效途径。用 LS-SVM 实现非线性映射关系:

$$\begin{aligned} y(k+d) &= LS-SVM_f(y(k), y(k-1), \dots, \\ &y(k-n+1); u_1(k), u_1(k-1), \dots, u_1(k-n+1); \\ &u_2(k), u_2(k-1), \dots, u_2(k-n+1); \\ &u_p(k), u_p(k-1), \dots, u_p(k-n+1)) \end{aligned}$$

利用烧结终点的实测值  $y_n$ , 确定 LS-SVM<sub>f</sub>, 使二次型精度性能指标函数  $E = (y - y_n)^2 / 2$  最小, 即是烧结终点预报值与实测值的误差满足给定的精度要求。

### 3.2 烧结终点的预报实例

某钢厂 360 m<sup>2</sup> 烧结机总长 104.5 m, 有效烧结面积 90 m, 烧结过程从台车布料到烧结矿在机尾卸下时, 大约需用 42 min。台车两侧各有 22 个风箱, 正常拐点风箱是 19 号风箱, 温度大约为 462 ℃, 烧结终点控制在倒数第 2 个风箱位置处, 即 21 号风箱。通过安装在风箱的热电偶检测台车下的废气温度。烧结终点对于预报参数的滞后时间大约为 8 min, 采样时间间隔为 2 min, 可提前 4 步预测烧结终点, 则时滞  $d=4$ 。用点火温度、烧结机速、混合料水分、料层厚度、透气性、20<sup>#</sup> ~ 22<sup>#</sup> 风箱废气温度值作为输入, 4 个采样时刻之后的烧结终点位置为输出。在预报过程中采入新参数, 存入数据库后去除

旧数据,使其不断增加新信息,缩短训练时间,使数据保持在 96 组左右(约 1 个烧结周期采样数据)。根据神经网络训练规律,最后最新的几组样本的训练误差与检验误差最小,也就是说不管样本集有多大,预报精度与最近的样本关系极大,因此须不断更新信息。网络过一定的时间就要训练,每隔 2 个烧结周期即重新训练,一边进行预报,一边用新数据训练网络更新权值,它们在不同的模块中进行,互不影响。

为评价预测模型的性能,分别使用了最大相对误差、均方根误差(RMSE)、相对均方根误差(RRMSE)对模型的预测准确性和跟踪变化趋势的能力进行了分析<sup>[14]</sup>,所用公式如下所示:

$$E_{\max} = \max\left(\frac{y_i - \hat{y}_i}{y_i}\right), \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (14)$$

$$RRMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i}\right)^2}. \quad (15)$$

在公式(13)-(15)中, $y_i$ 为实际数据向量中的第  $i$  个数据, $\hat{y}_i$ 为预测所得数据向量中第  $i$  个数据。式中  $n$  为样本数; $y_i$ 和 $\hat{y}_i$ 分别为烧结终点的测量值和预测值。

先用训练样本对 4 种预测模型分别进行训练,然后利用训练后的模型对烧结终点进行预测。训练样本数 96 组,测试样本 48 组,测试结果如表 1 所示。为了验证贝叶斯 LS-SVM 模型对烧结终点的预测准确率,分别用 3 种预测模型进行仿真计算。模型 1 采用灰色残差修正模型,即灰色 GM(1,1)模型,模型 2 采用 BP 神经网络模型,模型 3 采用 LS-SVM 预测模型,模型 4 选用本文的方法即贝叶斯 LS-SVM 模型。

模型 1 采用灰色 GM(1,1)预测模型的烧结终点仿真图见图 1 所示,灰色 GM(1,1)处理小样本数据能力比较强,如果数据忽大忽小并且数据很多的话,它就无能为力了,预测精度随数据数目的增多,预测性能变差。模型 2 采用 BP 神经网络对烧结终点进行预测,预测图见图 2,尽管它的预测精度和预测误差大大减小,但它存在着两大致命的缺点:一是模型训练时容易陷入局部最小而不可自拔;二是模型的泛化能力比较差。模型 3 的预测结果如图 3 所示,尽管其预测精度大大提高,但个别点的误差还是比较大的,正则化函数和核函数的优化耗费了不少时间;模型 4 由图 4 可以看出,贝叶斯支持向量机显示了良好的时序预测和泛化性能,经过贝叶斯推断理论选用的正则化参数  $\gamma=300$  和核函数  $\sigma^2=0.25$

比较合适,烧结终点预报模型的预报精度比较高,泛化能力强,收敛速度也明显加快,能够比较准确地预报烧结终点。

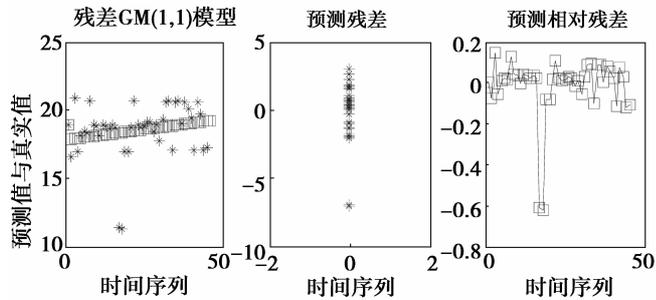


图 1 烧结终点的灰色残差修正模型仿真结果

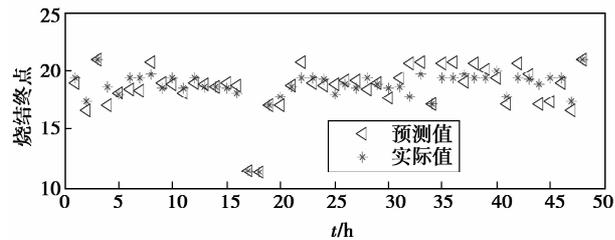


图 2 烧结终点的 BP 神经网络仿真结果

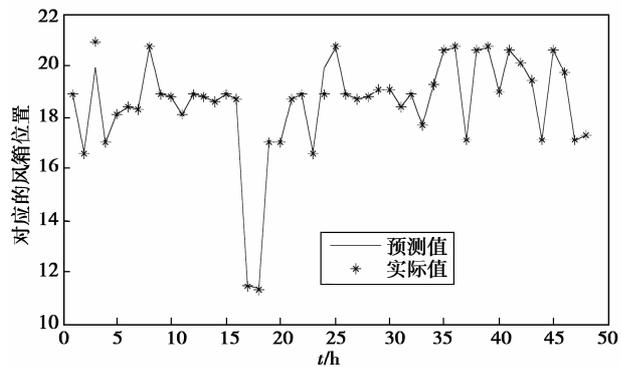


图 3 烧结终点的贝叶斯 LS-SVM 预测模型仿真结果

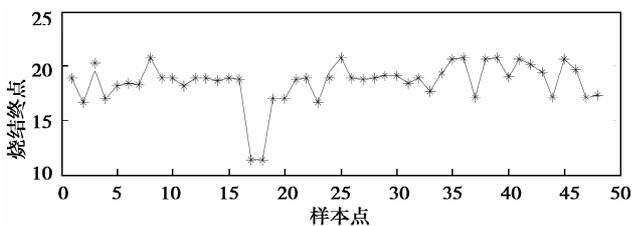


图 4 烧结终点的贝叶斯 LS-SVM 预测模型仿真结果 (数据消噪后)

表 1 预测结果误差分析

性能指标	$E_{\max}$	RMSE	RRMSE
GM(1,1)	1.874 4	0.745 6	2.017 8
BPNN	1.237	0.788 3	1.812
LS-SVM ( $\gamma=200, \sigma^2=0.2$ )	0.048 1	0.288 9	0.566 6
Bayesian LS-SVM ( $\gamma=300, \sigma^2=0.25$ )	0.039 8	0.271 7	0.457 8

从表 1 可以看出,贝叶斯框架理论下 LS-SVM 方法的预测性能都远远高于 PNN 预测模型和灰色模型。模型的预测能力远大于 GM(1,1) 模型和 BPNN 模型,显示了贝叶斯 LS-SVM 较强的预测鲁棒性,LS-SVM 是一种可用于线性回归的算法,与 BPNN 相比较,SVM 模型是专门针对小样本情况的,其目标是得到现有信息下的最优解而不仅仅是样本数趋于无穷大时的最优值;SVM 算法最终将预测问题转化成为一个二次型凸优化问题,从理论上说,这得到的将是全局最优点,这从根本上解决了神经网络预测所无法避免的局部极值、陷入死区等问题。LS-SVM 则对 SVM 进行了改进,用二次损失函数取代 SVM 中的不敏感损失函数,将不等式约束条件变为等式约束,将二次规划问题转变为线性方程组的求解,用最小二乘法实现了 SVM 算法,简化了计算的复杂性,贝叶斯理论可以进行三层推理实现正则化参数与核函数的自动确定。仿真结果表明,贝叶斯 LS-SVM 在用于预测建模时,在抗干扰能力和预测准确率方面有明显的优势。以烧结终点预测模型为基础的烧结过程智能优化控制系统已经在某钢铁企业烧结机上得到应用,并取得了一定的效益。当控制系统正常运行时,以预测模型得到的烧结终点预测值作为控制系统控制依据。烧结终点预测模型的最大预测偏差为  $\pm 0.13$  个风箱。

#### 4 烧结终点集成预测模型

在烧结过程中,由于种种原因,烧结矿石成分、烧结矿配比以及操作人员的工作经验水平等有可能发生变化,即使构建的 Bayesian LS-SVM 模型在刚开始运行时具有相当高的精度,但是随着时间的推移和工况条件的变化,仍有预测模型不能适应新情况的状态。因此为了提高预测模型的自适应性,使其适应各种工况的变化,必须对预测模型进行在线修正,充分结合专家知识,并对其实时更新,以使其跟踪工况的变化来提高模型的自适应性。

预报模型的自适应机制通常包括 3 个方面:一是学习样本的不断更新机制;二是预测模型的自学

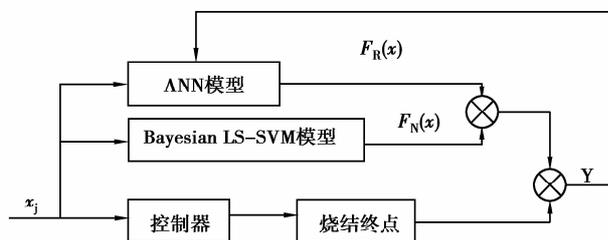


图 5 烧结终点的建模结构

习机制;三是模型输出的在线自修正能力。样本不断更新可以提高学习样本的可靠性,必须建立有效的更新机制以确保将异常数据剔除在外,又将那些能够真实反映工况变化的数据增加到样本集中来。随着预测模型的不断运行,其学习能力体现了它跟踪工况变化,自动调整参数和输出,以实现更加合理准确预测的性能。合理的学习机制可以大大提高预测模型的实时性、准确性和可靠性,是建立烧结终点预测模型不可或缺的一个环节。本模型选用的是等维新息法,就是用最新的数据加入训练样本集,删除最旧的数据,始终维持样本保持不变。为了稳妥起见,烧结终点的建模结构采用了双模型结构,当工况稳定时,选用 Bayesian LS-SVM 模型或修正模型,工况频繁变化时应用人工神经网络模型,两种模型相互独立相互补充。预测模型的最终输出结果:

$$F(x) = k_1 F_R(x) + (1 - k_1) F_N(x), \quad (16)$$

其中,  $k_1$  为权值,它的值可以根据实际计算求取。

#### 5 结 语

利用贝叶斯支持向量机模型对某厂烧结机的烧结终点进行测量和控制,取得了很好的结果:BTP 位置能够很好地稳定,与未采用此系统的烧结机相比原料组成与配比完全相同,对原料构成及其配比变化不敏感,能够在所有操作条件下,精确控制 BTP。系统自 2008 年 3 月投入运行以来,BTP 贝叶斯支持向量机控制器与传统控制系统相比,能大大加快系统对操作干扰的影响速度,其良好的效果可概括为:烧结矿质量高而稳定,提高了生产率,减轻操作人员的工作负荷,延长烧结设备的使用寿命并降低生产成本。无论在正常工况、欠烧工况,还是在过烧工况下,BTP 终点模型均具有迅速反应能力,可对烧结终点位置进行准确的预测和在线优化控制,使烧结终点位置在沿台车方向和垂直台车方向都保持相对恒定,烧结矿的质量、产量等工艺技术指标均得到了显著的改善。该系统的研究与开发应用,为烧结厂的正

常生产提供了保障。同时,由于该系统综合运用了烧结理论、现代控制理论、人工智能理论等学科知识,对于提高我国的烧结自动化控制水平,推广人工智能技术,具有十分重要的理论和实用价值。

#### 参考文献:

- [1] 范晓慧,王海东. 烧结过程数学模型与人工智能[M]. 长沙:中南大学出版社,2002.
- [2] 王亦文,桂卫华,王雅琳. 基于最优组合算法的烧结终点集成预测模型[J]. 中国有色金属学报, 2002, 12(1): 191-195.  
WANG YI-WEN, GUI WEI-HUA, WANG YA-LIN. Integrated model for predicting burning through point of sintering process based on optimal combination algorithm[J]. The Chinese Journal of Nonferrous Metal, 2002, 12(1): 191-195.
- [3] 张晓龙. 基于神经网络的烧结终点预测方法与应用[D]. 长沙:中南大学,2006.
- [4] 程武山. 基于遗传神经网络的烧结终点预测系统[J]. 烧结球团, 2004, 29(5): 18-22.  
CHENG WU-SHAN. A building of the genetic-neural network for sinter's burning through point [J]. Sintering and Pelletizing, 2004, 29(5): 18-22.
- [5] 向齐良,吴敏,向婕,等. 基于多元模糊线性回归的烧结终点预测方法[J]. 控制工程, 2007, 14(6): 603-605.  
XIANG QI-LIANG, WU MIN, XIANG JIE, et al. Prediction method based on multiple fuzzy linear regression for the burning through point [J]. Control Engineering of China, 2007, 14(6): 603-605.
- [6] 刘玉长,桂卫华,周子民. 基于软测量技术的模糊烧结终点控制研究[J]. 烧结球团, 2003, 27(2): 27-30.  
LIU YU-CHANG, GUI WEI-HUA, ZHOU JIE-MIN. Study on intelligent control of BTP based on soft-sensor technology [J]. Sintering and Pelletizing, 2003, 27(2): 27-30.
- [7] 吴晓峰,费敏锐. 基于支持向量机预报模型的烧结终点模糊控制[J]. 浙江大学学报:工学版, 2007, 41(10): 1721-1725.  
WU XIAO-FENG, FEI MIN-RUI. Fuzzy control applied to burning through point based on support vector machines prediction model [J]. Journal of Zhejiang University: Engineering Science, 2007, 41(10): 1721-1725.
- [8] 向其良. 基于烧结终点预测的烧结过程智能控制系统及应用研究[D]. 长沙:中南大学,2008.
- [9] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000, 26(1): 1-6.  
ZHANG XUE-GONG. Introduction to statistical learning theory and support vector machines [J]. Acta Automation Journal, 2000, 26(1): 1-6.
- [10] 克里斯安特尼 N,肖-泰勒丁. 支持向量机导论[M]. 李国正,王猛,曾华军,译. 北京:电子工业出版社,2004.
- [11] 李正欣,赵林度. 基于贝叶斯框架下 LS-SVM 的时间序列预测模型[J]. 系统工程理论与实践, 2007, 27(5): 143-145.  
LI ZHENG-XIN, ZHAO LIN-DU. Time series prediction based on LS-SVM within the Bayesian framework [J]. System Engineering-Theory and practice, 2007(5): 143-145.
- [12] 牛东晓,吕海涛,张云云. 贝叶斯框架下最小二乘支持向量机中长期电力负荷组合预测[J]. 华北电力大学学报, 2008, 35(6): 61-66.  
NIU DONG-XIAO, LV HAI-TAO, ZHANG YUN-YUN. Combination method of mid-long term load forecasting based on support vector machine within the Bayesian evidence framework [J]. Journal of North China Electric Power University, 2008, 35(6): 61-66.
- [13] 李方方,赵英凯. 贝叶斯框架下的 LSSVM 和贝叶斯网络及其应用[J]. 计算机工程与设计, 2007, 28(15): 3647-3649.  
LI FANG-FANG, ZHAO YING-KAI. LS-SVM algorithm of Bayesian framework and Bayesian regulation network and their applications [J]. Computer Engineering and Design, 2007, 28(15): 3647-3649.
- [14] SONG Q, WANG A M. Simulation and prediction of alkalinity in sintering process based on grey least squares support vector machines [J]. Journal of Iron and Research: International, 2009, 16(5): 1-7.
- [15] VAN GESTE T, SUYKENS J A K, BAESTAENS D E, et al. Financial time series prediction using least squares support vector machines within the evidence framework [J]. IEEE Transactions on Neural Networks, 2001, 12(4): 809-821.
- [16] 杨强,吴中福,余萍,等. 一种新型支持向量机[J]. 重庆大学学报:自然科学版, 2005, 28(2): 81-84.  
YANG QIANG, WU ZHONG-FU, YU PING, et al. A sort of new SVM [J]. Journal of Chongqing University: Natural Science Edition, 2005, 28(2): 81-84.
- [17] 梁栋,白晨光,温良英,等. 高炉透气性指数智能预测模型[J]. 重庆大学学报, 2009, 32(4): 376-386.  
LIANG DONG, BAI CHEN-GUANG, WEN LIANG-YIN, et al. Intellectual prediction of a permeability index for blast furnaces [J]. Journal of Chongqing University, 2009, 32(4): 376-386.