

# 电弧炉终点温度的 GASVR\_GM 预报模型研究

Study on the GASVR\_GM Prediction Model for Endpoint Temperature of EAF

张捍东 汤敏 张莉

(安徽工业大学电气信息学院,安徽 马鞍山 243002)

**摘要:** 电弧炉终点温度是炼钢过程中的重要指标之一,决定了钢水的质量和整体成本。电弧炉终点温度预报模型的建立是实现炼钢自动化的重要环节,为了得到高精度的终点温度预报值,提出了一种 GASVR\_GM 的钢水终点温度预报模型。该模型以定量因素为主,采用遗传算法优化的支持向量回归机预报终点温度;再运用灰色模型进行预报误差的补偿,解决非定量因素的影响,实现滚动预报。试验仿真表明,与智能软测量方法相比,GASVR\_GM 预报模型具有更高的精度和鲁棒性。

**关键词:** 电弧炉(EAF) 支持向量回归机(SVR) 遗传算法(GA) 灰色模型(GM) 终点预报 滚动预报

**中图分类号:** TP273+.5 **文献标志码:** A

**Abstract:** The endpoint temperature of electric arc furnace (EAF) is one of the most important indexes of the steelmaking process, it determines both the quality of molten steel and the overall cost. The prediction model establishment of the endpoint temperature is an important part for implementing automation of steelmaking. In order to obtain highly accurate predictive value of the endpoint temperature, the GASVR\_GM prediction model is proposed. This model is mainly based on quantitative factors, it predicts the endpoint temperature by adopting the support vector regression machine optimized with genetic algorithm, then compensates the predictive error by using grey model to solve the influence from non-quantitative factors for implementing rolling prediction. The experimental simulation indicates that comparing with intelligent soft sensing method, the GASVR-GM prediction model possesses higher accuracy and robustness.

**Keywords:** Electric arc furnace(EAF) Support vector regression(SVR) Genetic algorithm(GA) Grey model(GM) Endpoint prediction Rolling prediction

## 0 引言

电弧炉炼钢与转炉炼钢是目前主要的两种炼钢方法,2010年电弧炉钢产量约占全球粗钢产量的30%(我国仅约10%),并呈逐年上升趋势。与转炉炼钢相比,采用废钢做主要原料的电弧炉炼钢流程投资建设成本低、占地面积小、达产快、资源和环境负荷低。同时,考虑到未来可能征收的能源税和温室气体排放税以及能源、环保准入制度,发展电弧炉将具有更长远的技术经济意义。

电弧炉炼钢的出钢温度和成分(碳含量、磷含量)等终点参数对于冶炼过程至关重要,准确的终点参数预报将使得钢水质量可控,冶炼时间缩短,从而保障后续生产和优化库存管理。本文将对电弧炉终点温度展开预报研究。

## 1 终点温度预报概述

近年来,电弧炉终点温度预报的方法主要有:①基于电弧炉内部反应的机理模型<sup>[1-3]</sup>,建模过程中存在着大量假设和简化,使得模型过于粗糙,很难取得更好的效果;②基于电弧炉炉口光谱图像辨识的模型<sup>[4]</sup>,模型的可靠性和稳定性有待验证,少量的理论研究尚未应用到生产环境中;③基于大量电弧炉生产数据的“黑箱”模型,常用的有人工神经网络、知识推理技术、模糊逻辑技术和专家系统等人工智能技术<sup>[5-7]</sup>,而统计学习理论(statistical learning theory, SLT)的兴起带来了电弧炉终点参数预报模型研究的热潮<sup>[8-10]</sup>。

在这样的背景下,将人工智能技术和统计学习理论融合到电弧炉终点参数预报问题的研究越来越受到关注。1993年,张俊杰等人提出带有知识库的炼钢终点自适应预报模型<sup>[5]</sup>,首次引出电弧炉终点参数预报命题。由于选用的变量过少,且过分依赖专家经验,因而该模型只适用于特定对象,推广能力弱,预报精度不高。2004年和2007年,刘焜等人提出采用神经网络和增量模型的电弧炉终点参数预报模型<sup>[6-7]</sup>。该模型在一定程度上消除了系统误差,提高了预报精度,但是

国家863高技术研究发展计划基金资助项目(编号:2007AA05Z242、2007AA05Z421)。

修改稿收到日期:2012-03-14。

第一作者张捍东(1963-),男,2003年毕业于东北大学控制科学与控制工程专业,获博士学位,教授;主要从事工程优化技术与应用和机器人路径规划及相关技术的研究。

对于有动态调节系数的系统,预报效果难以让人满意。2006年,袁平等提出基于灰色模型和最小二乘支持向量机的电弧炉终点预报模型<sup>[8]</sup>,将定量因素和非定量因素的影响分离出来,但由于模型的参数固定,不能跟随系统的变化而变化,后续精度难以得到保证。2009年,张绍德等人提出基于灰色马尔科夫和支持向量机的电弧炉终点预报模型<sup>[10]</sup>,并采用粒子群算法在线优化支持向量机参数。但其将非定量因素作为预报终点温度的基准,忽视了定量因素在炼钢过程中所起到的决定性作用;并且灰色马尔科夫模型在数据波动较大时难以逼近实际对象,伴随误差的传递,整体模型的精度将会大大下降。

考虑到影响电弧炉终点温度的因素众多,本文在分析问题,既考量了可观测的定量因素对终点温度的影响,又将不可观测的非定量因素的影响加入到模型之中。模型先采用遗传算法(genetic algorithm, GA)在线优化参数的支持向量回归机(support vector regression, SVR),针对影响电弧炉终点温度的定量因素进行建模、预报终点温度;再通过灰色模型(grey model, GM(1,1))对 GASVR 模型的预报值与实际值之间的偏差进行误差补偿修正,从而反映非定量因素对系统的影响。GASVR 与 GM(1,1)模型的结合,从两个方面考量了不同因素对系统的影响,特别是灰色模型采用误差补偿的思想分析非定量因素对系统的影响,使得模型更加逼近真实系统,提高了模型的精度。

## 2 问题描述

电弧炉采用电极和炉料间放电产生的电弧,使电能能在弧光中转变为热能,并借助辐射和电弧的直接作用,加热并融化金属和炉渣,从而冶炼出各种成分的钢。该过程是一个伴随着强随机性的、复杂的物理、化学反应。

从电弧炉炼钢外部特性来看,该过程是一个“部分信息明确、部分信息未知”的灰色系统,因而将影响电弧炉终点温度的因素分为定量因素和非定量因素。

在精简了一些重复的和不必要的因素后,得到定量因素有:电耗、热停工时间、废钢加入量、铁水加入量、氧耗、合金加入量、碳粉加入量、石灰石加入量、预熔渣加入量、填充料加入量、“测温后通电时间”和“测温后吹氧时间”共12种。由于钢液的最后一次取样测温并不一定代表一个冶炼周期的结束,出于微调终点参数的目的或等待钢包的时间过长,采样测温后可能会增加额外通电或吹氧过程。此时的电耗和氧耗会计

入整体冶炼周期内,那么这种情况下的电耗和氧耗就不能真实反映出测温时刻的电能和氧气的消耗量,所以增加“测温后通电时间”和“测温后吹氧时间”这两个定量因素,将会更加准确地还原出测温时刻的电弧炉相关参数。

非定量因素有:各种物理及化学反应的强度、造渣的质量、各种能量损耗(如废气、冷却水、提电极、炉盖提升、炉盖旋出、炉壳导热、炉盖辐射带走的能量损耗)以及随着炉次的增加,电极的消耗、水冷炉盖的消耗、炉壁受到钢水侵蚀变薄甚至是气象条件等因素。

在实际处理中,采用定量因素建模产生的终点温度预报误差序列来反映非定量因素对系统的影响,从而在定量因素作用的基础上体现出非定量因素对终点温度连续影响变化的一种规律。

区别于以往文献中对定量因素和非定量因素的处理方式,本文采用的预报模型结构将定量因素作为影响电弧炉终点温度的主要因素。首先采用 GASVR 对定量因素  $x(k)$  和  $y(k)$  建立模型,预报  $\hat{y}(k+1)$ ,并以此为基准;再采用 GM(1,1) 对 GASVR 预报值与实际值的误差序列作出误差预测  $\hat{\Delta}(k+1)$ ;最后将 GASVR 的预报值和 GM(1,1) 的预测误差相加,得到最终的电弧炉终点参数预报值  $\tilde{y}(k+1)$ 。采用这样的模型结构,体现了定量和非定量因素对系统影响的主要矛盾和次要矛盾关系,并充分发挥了 SVR 在回归问题上的出色性能和 GM(1,1) 解决“小样本、贫信息”系统的优势。GASVR\_GM 预报模型的整体结构如图 1 所示。




图 1 GASVR\_GM 预报模型的整体结构

Fig. 1 Overall structure of the GASVR\_GM prediction model

## 3 终点温度预报模型

### 3.1 GASVR 终值预报模型

统计学习理论<sup>[11-12]</sup>是 Vapnik 等在 20 世纪 60 年代所提出的,其核心思想是通过控制学习机器的容量实现对推广能力的控制,它为研究有限样本情况下机器学习的理论和方法提供了理论框架。在这一理论基础之上发展形成了新的通用学习方法——支持向量机(support vector machine, SVM)。SVM 利用 VC 维(Vapnik-Chervonenkis dimension),将经验风险最小化拓展到结构风险最小化(structure risk minimization,

SRM)。与神经网络、最小二乘法等模型相比,支持向量机有效改善了过学习和维数灾难这两个机器学习的经典问题。随着对支持向量机理论研究的不断深入,越来越多的学者将 SVM 推广到回归问题的应用中,于是出现了支持向量回归机。在支持向量的学习中,模型是否优异很大程度上取决于试验参数的选取。传统选取参数的方式有:经验法、试验试凑法、梯度下降法、交叉验证法和贝叶斯法等。随着遗传算法、粒子群算法、人工免疫等智能优化方法在不同领域中的成功应用,学者们开始对如何应用这些方法选取最优支持向量机的参数进行了研究。2002 年,Liang X 和 Liu F 提出了遗传算法选择支持向量机中的多个参数<sup>[13]</sup>;2005 年,Liu H J 等提出了基于遗传算法选择参数的新权支持向量机<sup>[14]</sup>;2007 年,Tzeng W C 等提出了运用实数型遗传算法选择预测破产几率支持向量机模型的参数<sup>[15]</sup>;2009 年,Avci E 提出了运用混合遗传算法支持向量机对数字调制分类选择优化特征子集和核参数<sup>[16]</sup>。下文对定量因素,通过对 12 种输入变量和对应的终点温度,采用 GASVR 来进行回归分析,得到基本的预报模型。

### 3.1.1 支持向量回归机

支持向量回归机是处理回归问题的一种新颖的学习型算法。训练样本通过机器学习建立回归机模型,将机器训练为回归机,再进行样本点的回归函数估计,得到预报模型,其原理如图 2 所示。




图 2 SVR 回归预报原理图

Fig.2 Principle of the support vector regression prediction

常见的支持向量回归机有  $\nu$ -支持向量回归机 ( $\nu$ -SVR)、 $\varepsilon$ -支持向量回归机 ( $\varepsilon$ -SVR) 和最小二乘支持向量回归机 (LSSVR)。其中, $\nu$ -SVR、 $\varepsilon$ -SVR 和 LSSVR 这三者的区别在于选择的参数表示含义不同,后两个仅仅是凸规划问题描述不同。 $\nu$ -SVR 是用一个数量上有意义的参数  $\nu$  代替参数  $\varepsilon$ ,其中  $\nu$  既可以是交错训练点的个数所占总训练点数的份额的上界,又可以是支持向量的个数所占总训练点数的份额的下界。若两者选取同样的  $C$  值,当  $\varepsilon$  和  $\nu$  满足一定的对应关系时,两个算法能得到基本一致的决策函数,即回归函数一致。考虑到在  $\varepsilon$ -SVR 和 LSSVR 中,需要事先确定参数  $\varepsilon$ ,而在某些情况下,选择合适的  $\varepsilon$  很难,所以本文采用自动计算参数  $\varepsilon$  的  $\nu$ -SVR。此时模型的原始问题<sup>[12,17]</sup>为:

$$\begin{cases} \min_{\omega, b, \xi_i^*} \left\{ \frac{1}{2} \|\omega\|^2 + C \left[ \nu \varepsilon + \frac{1}{l} \sum_{i=1}^l (\xi_i + \xi_i^*) \right] \right\} \\ \{ [\omega \varphi(x_i)] + b \} - y_i \leq \varepsilon + \xi_i \\ y_i - \{ [\omega \varphi(x_i)] + b \} \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \\ \varepsilon \geq 0 \\ i = 1, 2, \dots, l \end{cases} \quad (1)$$

鉴于各定量因素对终点温度的影响是非线性的,本文模型引入了核函数。核函数的采用解决了算法中维数灾难的问题。在构造判别函数时,先在特征空间中比较向量,然后再对结果作非线性变换,其大量的工作是在输入空间中进行的,大大简化了计算。常见的核函数有多项式核函数、RBF 核函数和 Fourier 核函数等。本文采用 RBF 核函数,它具有适用性强和所需确定的参数少等特点,尤其针对非线性问题具有很好的拟合效果,其形式如下所示:

$$K(x, x') = \exp\left(\frac{-\|x-x'\|^2}{\sigma^2}\right) \quad (2)$$

将式(1)引入核函数,并采用拉格朗日转换成以下对偶问题,即:

$$\begin{cases} \max_{\alpha_i^*} \left[ -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) K(x_i, x_j) + \sum_{i=1}^l (\alpha_i^* - \alpha_i) y_i \right] \\ \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C/l, \\ \sum_{i=1}^l (\alpha_i^* - \alpha_i) \leq C\nu \\ i = 1, 2, \dots, l \end{cases} \quad (3)$$

最后,构造并求解上述对偶问题的等价凸二次规划:

$$\begin{cases} \min_{\alpha_i^*} \left[ \frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) K(x_i, x_j) - \sum_{i=1}^l (\alpha_i^* - \alpha_i) y_i \right] \\ \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C/l, \\ \sum_{i=1}^l (\alpha_i^* - \alpha_i) \leq C\nu \\ i = 1, 2, \dots, l \end{cases} \quad (4)$$

求出凸二次规划的非零向量解  $\bar{\alpha}^* = (\bar{\alpha}_1, \bar{\alpha}_1^*, \dots, \bar{\alpha}_l, \bar{\alpha}_l^*)$  即为支持向量。建立预报模型的步骤如下。

- ① 确定训练样本集。

② 为上述已确定的支持向量算法和核函数  $K(x, x')$  选取合适的支持向量机参数,即  $\nu \in (0, 1], C > 0$  和参数  $\sigma$ 。

③ 求解式(4)中的凸优化问题,求得解:

$$\bar{\alpha}^{(*)} = (\bar{\alpha}_1^*, \bar{\alpha}_1^*, \bar{\alpha}_2^*, \bar{\alpha}_2^*, \dots, \bar{\alpha}_l^*, \bar{\alpha}_l^*)^T \quad (5)$$

④ 选取  $\bar{\alpha}^{(*)}$  位于开区间  $(0, C/l)$  中的两个分量  $\bar{\alpha}_i$  和  $\bar{\alpha}_k^*$ , 求出对应的支持向量和  $(x_i, y_k)$ , 再代入式(6)计算  $\bar{\omega}$  和  $\bar{b}$ 。

$$\begin{aligned} \bar{\omega} &= \sum_{i=1}^l (\bar{\alpha}_i^* - \bar{\alpha}_i) \varphi(x_i) \\ \bar{b} &= \frac{1}{2} \{ y_j + y_k - [ \sum_{i=1}^l (\bar{\alpha}_i^* - \bar{\alpha}_i) K(x_i, x_j) + \sum_{i=1}^l (\bar{\alpha}_i^* - \bar{\alpha}_i) K(x_i, x_k) ] \} \end{aligned} \quad (6)$$

⑤ 利用式(7)求解目标函数最优时对应的参数  $\bar{\varepsilon}$ , 即:

$$\bar{\varepsilon} = \sum_{i=1}^l (\bar{\alpha}_i^* - \bar{\alpha}_i) K(x_i, x_j) + \bar{b} - y_j \quad (7)$$

⑥ 将利用最优化方法求解出的参数代入回归算式中,得到回归模型,即:

$$\hat{y} = \bar{\omega} \varphi(x) + \bar{b} = \sum_{i=1}^l (\bar{\alpha}_i^* - \bar{\alpha}_i) K(x_i, x_j) + \bar{b} \quad (8)$$

### 3.1.2 遗传算法优化 SVR 参数

支持向量回归机中的参数(惩罚因子  $C$ 、RBF 核函数参数  $\sigma$ 、参数  $\nu$ )对预报精度有很大的影响。传统方法采用固定值参数难以体现出滚动预报中模型的细微变化,且模型难以收敛到全局最小,而通过遗传算法对参数的在线寻优既可以有效地解决这些问题,又省去了人工参数寻优的繁琐过程。因此,本文将遗传算法和支持向量回归机相结合,提出一种支持向量回归机参数自动选择的方法<sup>[18]</sup>。GA 优化 SVR 参数的流程图如图 3 所示。

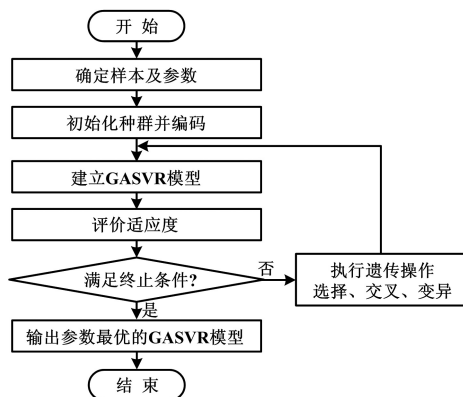


图 3 GA 优化 SVR 参数的流程图

Fig.3 Flowchart of SVR parameters optimization by GA

采用遗传算法优化 SVR 参数的步骤如下。

① 确定训练样本集,并根据经验确定 SVR 参数

( $C, \sigma, \nu$ ) 在模型中的取值范围,以及 GA 算法中相应参数的值。

② 产生初始种群,并进行二进制编码。

③ 运用得到的参数建立 GASVR 模型。

④ 采用  $k$ -折交叉校验方法计算适应度,将初始种群代入 SVR 模型进行训练,并得出个体适应度;评价后选择适应度最好的种群个体,同时将此时的参数值定义为全局最优参数值。

⑤ 判断算法是否满足终止条件:若满足条件,则跳转至步骤⑥;若不满足,则对种群按照一定规则执行遗传操作(选择、交叉、变异),并返回步骤③。

⑥ 对全局最优参数值进行二进制解码,输出最佳 SVR 参数值,结合训练样本建模,获得最佳的回归模型。

根据仿真结果分析,选取 GA 参数如下:二进制编码位数为 20 位;最大进化代数为 200 代;个体数为 30 个;代沟为 0.8;交叉概率为 0.7;变异概率为 0.01;  $k$ -折交叉校验参数为 5。

### 3.2 GM(1,1) 偏差预报模型

电弧炉终点温度的影响因素存在许多的不确定性,非定量因素无法避免地被考虑进来。GASVR 对非定量因素产生的噪声和噪声不稳定的情况不能很好地预报和控制。单纯使用 GASVR 进行终点温度预报,精度难以达到更高层次,于是采用 GM(1,1) 对 GASVR 预报值与实际值之间的误差序列做出预报补偿。这样既结合了 GM(1,1) 算法的预测精度高、可检验性强的特点,又保留了 GASVR 结构风险最小、全局最优解等优势,从而提高了整体模型的泛化能力和预报稳定性。

灰色模型<sup>[19]</sup>由我国学者邓聚龙于 1992 年提出,是解决“外延明确、内涵不明确”对象的不确定性理论。GM(1,1) 代表一阶单变量灰色模型,灰色系统理论是通过原始数据的整理来寻求其变化规律的。这是一种就数据寻找数据现实规律的途径,特别适用于本文中的“小样本、贫信息”不确定系统。

首先,计算出已得到的前  $n$  组 GASVR 预报值与实际值的误差序列,记该原始误差序列为:

$$\Delta^{(0)} = \{ \Delta^{(0)}(1), \Delta^{(0)}(2), \dots, \Delta^{(0)}(n) \} \quad (9)$$

接着,为了保证原始误差序列中各值的非负性和统一性,并为了简化计算,对原始误差序列进行归一化处理,将其归一化到  $[0.1, 0.9]$  范围内,得到新的误差序列:

$$\Delta_c^{(0)} = \{ \Delta_c^{(0)}(1), \Delta_c^{(0)}(2), \dots, \Delta_c^{(0)}(n) \} \quad (10)$$

进而,为弱化误差序列的随机性,使得误差序列呈

现出单调性,令  $\Delta_c^{(1)}(1) = \Delta_c^{(0)}(1)$ 、 $\Delta_c^{(1)}(k) = \sum_{i=1}^k \Delta_c^{(0)}(i)$ , 形成递增的累加(1-AGO)序列:

$$\Delta_c^{(1)} = \{\Delta_c^{(1)}(1), \Delta_c^{(1)}(2), \dots, \Delta_c^{(1)}(n)\} \quad (11)$$

同时,令  $z^{(1)}(n) = 0.5 \times [\Delta_c^{(1)}(n) + \Delta_c^{(1)}(n-1)]$ , 求得紧邻均值生成序列:

$$z^{(1)} = \{z^{(1)}(2), z^{(1)}(3), \dots, z^{(1)}(n)\} \quad (12)$$

从而由 GM(1,1) 定义式得到系统的白化模型为:

$$\Delta_c^{(0)}(k) + a z^{(1)}(k) = b \quad (13)$$

另外,找出与之对应的微分方程:

$$\frac{d\Delta_c^{(1)}}{dt} + a\Delta_c^{(1)} = b \quad (14)$$

于是,求解微分方程,得到 GM(1,1) 白化型响应式为:

$$\hat{\Delta}_c^{(1)}(k+1) = \{\Delta_c^{(0)}(1) - b/a\} e^{-ak} + b/a \quad (15)$$

然后,利用式(16)进行参数估计(即最小二乘估计)。

$$[a \quad b]^T = (B^T B)^{-1} B^T y_N \quad (16)$$

其中,

$$B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix} \quad (17)$$

$$y_N = [\Delta_c^{(0)}(2), \Delta_c^{(0)}(3), \dots, \Delta_c^{(0)}(n)] \quad (18)$$

将上面所求参数代入白化型响应式,便得到预测误差值,即:

$$\hat{\Delta}_c^{(0)}(k+1) = \hat{\Delta}_c^{(1)}(k+1) - \hat{\Delta}_c^{(1)}(k) \quad (19)$$

对预测误差值  $\hat{\Delta}_c^{(0)}(k+1)$  通过反归一化变换,得到 GM(1,1) 模型的预测误差值  $\hat{\Delta}^{(0)}(k+1)$ 。最后将 GASVR 得到的终点温度预报值  $\hat{y}(k+1)$  和 GM(1,1) 得到的预测误差值  $\hat{\Delta}^{(0)}(k+1)$  相加,便得到最终的电弧炉终点温度预报值  $\tilde{y}(k+1)$ 。

#### 4 实例验证

采集某钢厂 80 t 电弧炉有效生产数据 200 炉。由于该电弧炉为即将投产项目,目前系统处于磨合阶段,工人的熟练程度、炉体本身的调试状态、相关配套系统的配合和大量的偶发情况等均影响着电弧炉终点参数,因此与相关文献中终点温度变化范围在 40 K 以内相比,本实例中终点温度变化范围达到 130 K,远远大于正常情况,具有波动大、随机性强等特点。在此数据基础上,采用本文提出的方法建立预报模型。

##### 4.1 实例数据

为了保证预报精度,模型采用滚动预报的方法。GASVR\_GM 模型的训练数据和验证数据的结构如图 4 所示。




图 4 模型训练数据与验证数据结构图

Fig.4 The structures of model training data and verification data

整体模型共有数据 200 组,其中 150 组作为训练数据,GASVR 训练数据为 100 组,GM(1,1) 训练数据为 50 组;剩余 50 组作为验证数据。首先采用前 100 组数据训练 SVR 模型,采用 5-折交叉检验作为 GA 的适应度函数,形成 GA 优化 SVR 模型参数的 GASVR 模型,并开始滚动预报得到后面 100 组的预报数据。再采用 GASVR 预报数据的前 50 组预报误差作为 GM(1,1) 的训练数据,并滚动预报出 50 组数据。最后,将 GASVR 预报的后 50 组数据和 GM(1,1) 预测的 50 组数据相加,即为模型最终的预报值。与其他文献直接采用模型的拟合误差作为误差序列进行误差预测补偿不同,本文采用模型的预报误差作为误差序列进行误差预测补偿,虽然需要的训练数据有所增加,但所得的模型更加逼近对象。

##### 4.2 预报结果分析

采用 GASVR\_GM 模型滚动预报电弧炉出钢温度,在预报误差范围设定在  $\pm 10$  K 内,预报炉数为 50 炉时,预报命中率达到 92%,其结果如图 5 所示。




图 5 GASVR\_GM 模型预报结果

Fig.5 The prediction results of GASVR\_GM model

在添加和不添加“测温后通电时间”和“测温后吹

氧时间”以及不同结构(SVR、GASVR 和 GASVR\_GM)下,对基于不同精度的预测模型的命中率进行了比较,结果如表 1 所示。其中,GSG 为模型 GASVR\_GM(1,1)的缩写。

表 1 不同定量因素和结构下模型精度比较

Tab.1 Comparison of the model accuracies under different quantitative factors and structures

精度 K	未添加/%			添加/%		
	SVR	GASVR	GSG	SVR	GASVR	GSG
±5	13	24	38	22	52	66
±10	29	36	72	56	84	92
±15	37	41	86	72	92	92

由表 1 可以看出,在添加“测温后通电时间”和“测温后吹氧时间”两个定量因素后,基于三种结构的预报模型精度均有显著的提高。采用 GA 优化的 SVR 模型相比原始 SVR 模型具有很大的优势,在各误差范围内的命中率都有大幅的提升,效果明显。在增加 GM(1,1)模型后,整体模型命中率再次提升,但由于少数误差较大点的存在,使得模型精度陷入瓶颈,命中率提升相对较小。在生产状况趋于平稳后,数据回归到正常水平,模型应表现出更佳的命中率。

### 5 结束语

本文首先从定量因素和非定量因素对电弧炉终点参数影响的主次关系的分析出发,确定了以定量因素为主预报终点值、非定量因素为辅寻找终点预报误差的规律进行误差补偿的总体框架。同时,增加“测温后通电时间”和“测温后吹氧时间”两个定量因素,解决测温、通电和吹氧三者之间的实际关系,以更加准确地描述系统的真实情况,提高了模型精度。在结合系统的实际特性和问题的基础上,采用 GASVR\_GM 的结构建模,效果明显优于单一模型或简单的组合模型。遗传算法的应用避免了 SVR 模型人工选择参数的繁琐过程,GASVR 预报终点温度的基准值保证了整体模型的稳定性,GM(1,1)模型修正预报误差保证了整体模型的高精度。在实际应用中,针对试生产数据的波动远高于正常水平的情况,模型依旧有较高的预报命中率,显示出较强的泛化能力。综合来看,采用 GASVR\_GM 对于电弧炉终点参数预报是一个可行的方法。

### 参考文献

- [1] Bekker J G,Graig I K,Pistorius P C. Modeling and simulation of an electric arc furnace process[J]. ISIJ(Iron Steel Inst Jpn),1999,39(1):23-32.
- [2] Nyssen P, Colin R, Knoops S, et al. On-line EAF control with a dynamic metallurgical model [ C ] // Proceedings of 7th European Electric Steelmaking Conference, Venice, 2002:293-304.
- [3] 刘锴,何平,刘浏. 电弧炉工艺模型及其研究现状[J]. 钢铁研究学报,2004,16(2):1-5.
- [4] 温宏愿,赵琦,陈延如,等. 光谱图像分析用于转炉终点实时预测[J]. 光电工程,2008,35(5):135-139.
- [5] 张俊杰,王顺晃. 电弧炉炼钢过程终点自适应预报及专家操作指导系统[J]. 自动化学报,1993,19(4):463-467.
- [6] 刘锴,刘浏,何平,等. 增量神经网络模型预报 100 t 电弧炉终点碳、磷和温度的应用[J]. 特殊钢,2004,25(3):42-43.
- [7] 刘锴,刘浏,何平,等. 增量模型预报电弧炉终点碳含量及温度的研究[J]. 冶金自动化,2007(1):5-8.
- [8] 袁平,王福利,毛志忠. 基于 G-SVM 的电弧炉终点预报研究[J]. 钢铁研究学报,2006,18(10):7-10.
- [9] Blachnik M, Maczka K, Wiecek T. A model for temperature prediction of melted steel in the electric arc furnace (EAF) [ J ]. 2010,6114:371-378.
- [10] 张绍德,毛雪菲,毛雪芹,等. 基于 grey Markov-支持向量机的电弧炉终点参数预报[J]. 控制理论与应用,2009,26(12):1443-1448.
- [11] Vapnik V N. The nature of statistical learning theory [ M ]. New York:Springer-Verlag,1999.
- [12] 邓乃扬,田英杰. 支持向量机:理论、算法与拓展 [ M ]. 北京:科学出版社,2009.
- [13] Liang Xuefeng, Liu Fang. Choosing multiple parameters for SVM based on genetic algorithm [ C ] // 6th International Conference on Signal Processing, 2002:117-119.
- [14] Liu Shuang, Jia Chuanying, Ma Heng. A new weighted support vector machine with GA-based parameter selection [ J ]. Proceedings of 2005 International Conference on Machine Learning and Cybernetics, 2005(7):4351-4355.
- [15] Wu C H, Tzeng G H, Goo Y J, et al. A real-valued genetic algorithm to optimize the parameters of support vector machine for predicting bankruptcy [ J ]. Expert Systems with Applications, 2007, 32(2):397-408.
- [16] Brereton R G, Lloyd G R. Support vector machines for classification and regression [ J ]. Analyst, 2010, 135(2).
- [17] 曾绍华. 支持向量回归机算法理论研究与应用 [ D ]. 重庆:重庆大学,2006.
- [18] 赵洪波. 基于遗传算法的进化支持向量机研究 [ J ]. 绍兴文理学院学报, 2004, 24(9):25-28.
- [19] 邓聚龙. 灰预测与灰决策 [ M ]. 武汉:华中科技大学出版社,2002.

《自动化仪表》 中文核心期刊 中国科技核心期刊  
 邮发代号: 4-304; 2013 年定价: 15 元/月, 全年价: 180 元; 国外代号: M 721