



## 基于 PSO-SVM 模型的转炉终点预测

刘增山<sup>1</sup>, 冯亮花<sup>1</sup>, 康小兵<sup>2</sup>

(1 辽宁科技大学材料与冶金学院, 鞍山 114051; 2 河北燕山钢铁集团有限公司, 迁安 064400)

**摘要:** 转炉冶炼过程包含着复杂的多相、高温的物理化学反应, 建立可靠的转炉终点预测模型对有效减少钢水分波动、提高钢铁品质有重要的意义。以某钢厂 200 t 转炉实际生产数据为依据, 采用粒子群优化算法选取支持向量机模型最优惩罚参数 C 和核参数 g 的方法建立预测模型, 对转炉终点碳质量分数和温度进行预测。将数据处理后得到 425 组数据, 数据划分为训练集数据和测试集数据, 并对其进行归一化预处理, 其中, 随机选取 50 组为测试集数据。结果表明, 转炉终点预测模型的终点钢水碳含量 (误差 $\pm 0.015\%$ ) 的命中率为 84%, 终点温度 (误差 $\pm 15^\circ\text{C}$ ) 的命中率为 80%。与 BP 神经网络模型和 RBF 模型相比, 基于粒子群算法优化的支持向量机模型具有精度高、泛化能力强的特点。

**关键词:** 转炉炼钢; PSO-SVM 模型; 终点温度; 终点钢水碳含量; 预测模型

**DOI:** 10. 20057/j. 1003-8620. 2023-00257 **中图分类号:** TF713

## Converter Endpoint Prediction Based On PSO-SVM Model

Liu Zengshan<sup>1</sup>, Feng Lianghua<sup>1</sup>, Kang Xiaobing<sup>2</sup>

(1 School of Materials and Metallurgy, University of Science and Technology Liaoning, Anshan 114051, China;

2 Hebei Yanshan Iron and Steel Group Co., Ltd., Qian'an 064400, China)

**Abstract:** The converter smelting process contains complex multi-phase and high-temperature physical and chemical reactions, and it is of great significance to establish a reliable converter endpoint prediction model to effectively reduce the fluctuation of molten steel composition and improve the quality of steel. Based on the actual production data of a 200 t converter in a steel mill, the particle swarm optimization algorithm is used to select the optimal penalty parameter C and kernel parameter g of the support vector machine model to establish a prediction model, and the carbon mass fraction and temperature at the end point of the converter are predicted. After data processing 425 sets of data were obtained and divided into training set data and test set data, and normalized them, of which 50 groups were randomly selected as test set data. The results show that the accuracy of carbon mass fraction (error  $\pm 0.015\%$ ) and temperature (error  $\pm 15^\circ\text{C}$ ) is 81.8% and 80% respectively. Compared with BP neural network model and RBF model, support vector machine model optimized by particle swarm optimization has higher accuracy and better generalization ability.

**Key Words:** Converter Steelmaking; PSO-SVM Model; Endpoint Temperature; End-point Carbon Content; Predictive Models

转炉炼钢终点控制<sup>[1-3]</sup>技术是转炉生产的关键环节, 提高转炉终点控制精度有利于提高产品质量、减少补吹次数、降低转炉冶炼过程中原辅料消耗和提高转炉炼钢效率。由于转炉冶炼是一个复杂的高温物理化学反应过程, 反应复杂, 影响因素多, 难以在吹炼条件下在线检测钢液的成分与温度, 因此, 转炉终点控制一直以来都是转炉冶炼控制的难点之一。转炉终点控制经历了人工控制, 静态模型控制<sup>[4-5]</sup>, 动态模型控制<sup>[6-7]</sup>等, 实际生产中, 为提高控制精度, 往往是几种控制手段结合使用, 尽管如此, 转炉终点成分及温度的命中率还是不太

高。20 世纪 80 年代, 神经网络技术的出现为转炉炼钢终点控制提供了新途径。

神经网络作为一种高效数据分析以及目标预测的手段, 已被应用于较多冶金工艺过程, 并取得了令人满意的预测精度。在转炉冶炼工序, 神经网络主要应用于转炉终点预测。目前, 很多学者利用神经网络建立了转炉炼钢终点预测模型<sup>[8-16]</sup>和终点控制模型<sup>[17-18]</sup>以及转炉炼钢过程的预测模型<sup>[19-22]</sup>。基于智能算法的数据预测模型, 在一定程度上可以实现转炉终点碳含量和终点温度的预测, 但转炉炼钢过程复杂, 由于终点碳含量和温度的指标之间彼

**基金项目:** 国家自然科学基金资助项目 (52074151), 辽宁省科学技术厅资助项目 (2022 JH2/101300079)

**作者简介:** 刘增山 (1999—), 男, 硕士; **E-mail:** 167896851@qq.com; **收稿日期:** 2023-12-18

**通信作者:** 冯亮花 (1974—), 女, 博士, 教授; **E-mail:** fenglianghua1974@126.com

此影响,增大了模型训练的困难程度。如BP神经网络需要设置很多的网络训练参数,并且训练的速度比较慢以及泛化能力较差,BP网络训练过程容易出现局部极小的问题;RBF神经网络的训练需要大量的参数,对噪声数据敏感。支持向量机是一种二分类模型,它的目标是通过搜索一个超平面来划分数据样本,分割的准则为间距最大化,并将其转换成一个凸二次优化问题。支持向量机<sup>[23-24]</sup>在非线性分类、模式识别、函数逼近等领域具有广阔的应用前景,突破了以往基于生物仿生学的思想而构建机器学习算法的局限。此外,支持向量机的快速迭代算法以及相关的简化算法也受到极大的关注。王旭生<sup>[25]</sup>等基于支持向量机建立了转炉终点碳含量和钢水温度的预测模型。汪森<sup>[26]</sup>等建立了一种改进的孪生支持向量机的转炉终点预测模型,并取得了较好的效果,证明了支持向量机在转炉应用的可行性。

相比于神经网络,支持向量机方法为解决小样本情况下高维数据有效建模提供了良好的数学基础,并具有拟合效果好、趋近于整体最优、维度数目要求低等优点。因此,提出了基于粒子群算法优化的支持向量机的模型来预测转炉终点钢水碳含量和温度,以提高钢水的质量。

## 1 基于 PSO 优化 SVM 的转炉终点预测模型建立

### 1.1 数据预处理

以某钢厂 200 t 转炉 500 组实际生产数据为基础,建立一个样本数据库。经过检查后有的数据严重偏离平均值,基于  $3\sigma$  准则进行处理后得到 425 组数据。其中 375 组作为训练集数据,50 组作为测试集数据。由于转炉实际生产过程中的影响因素有很多,并且这些影响因素的参数具有不同的数量级和单位,应该归一化处理这些参数,利用公式(1)将数据参数限定到  $[0, 1]$  内,从而有效去除奇异值带来的不良影响。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, $x$  表示为模型的实际输入或实际输出数据; $x_{\max}$  和  $x_{\min}$  分别表示为模型的实际输入或实际输出的最大值和最小值; $x'$  表示实际数据经过归一化处理后的数据。

### 1.2 转炉终点预测模型的算法原理

#### 1.2.1 支持向量机(SVM)

支持向量机回归(Support Vector Regression,

SVR)是在支持向量机<sup>[27]</sup>(Support Vector Machine, SVM)的基础上发展起来的一种回归算法。与经典的线性回归算法相比,SVR的目标不是直接拟合数据,而是通过在特征空间中找到一个超平面,使得样本点尽可能地接近于该超平面附近,在容忍界限内允许一定的误差。SVR的思想是将回归问题转化为一个寻优问题。通过引入一个边界带(margin),将输出值限制在该边界带内,同时尽量减少边界带之外样本点的数量。在SVR中,提出了一种新的方法,即利用核函数把输入的特征映射到一个高维的特征空间,并在此基础上搜索最优超平面。

1) 设定最优分类超平面:

$$\omega\phi(x) + b = 0 \quad (2)$$

式中, $\omega$  为权重; $b$  为偏差; $\phi(x)$  为核函数。

线性可分的数据分类的决策函数可表示为

$$f(x) = \text{sgn}(\omega\phi(x) + b) \quad (3)$$

2) 松弛变量可以在一定程度上体现非线性数据特性,故为解决部分数据无法线性可分的问题,本文将松弛变量和惩罚系数引入至目标函数中,则目标函数为:

$$\begin{cases} \min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m \varepsilon_i \\ \text{s.t. } y_i(\omega\phi(x) + b) \geq 1 - \varepsilon_i \end{cases} \quad (4)$$

式中, $y_i$  为输出类别, $y_i \in [-1, 1]$ ;  $i=1, 2, \dots, m$ ;  $\varepsilon_i$  为松弛变量, $\varepsilon_i = \max(0, 1 - y_i(\omega\phi(x) + b))$ ,每一个样本都对应一个松弛变量,表征不满足约束的程度; $C$  为惩罚系数,惩罚系数的作用是增强模型的分类能力,分类错误越大惩罚越严重,惩罚系数可使最终分类结果接近实际情况。

3) 通过拉格朗日函数将不等式约束增添至目标函数内,并根据对偶性原理将其转化成对偶问题,即:

$$\begin{cases} \max Q(\alpha) = \left\{ \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \phi(x_i) \phi(y_j) \right. \\ \left. \text{s.t. } 0 \leq \alpha_i \leq C \quad \sum_{i=1}^m y_i \alpha_i = 0 \right. \end{cases} \quad (5)$$

式中, $Q(\alpha)$  为目标函数; $\alpha_i, \alpha_j$  为拉格朗日乘子; $y_j$  为输出类别, $y_j \in [-1, 1]$ 。根据库恩-塔克尔条件, $\alpha_i$  需要满足以下条件:

$$\alpha_i [y_i(\omega\phi(x) + b) - 1 + \varepsilon_i] = 0 \quad (6)$$

支持向量就是当拉格朗日乘子不等于0时对应的样本。对式(5)进行求解,可以得到最优分类

函数:

$$f(x) = \text{sgn} \left[ \sum_{i=1}^p y_i \alpha_i K(x, x_i) + b \right] \quad (7)$$

式中,  $p$  为支持向量数。在式(7)的基础上采用径向基函数核函数化简求解, 得到最终的核函数为

$$K(x, x_i) = \exp(-g \|x - x_i\|^2), g > 0 \quad (8)$$

式中:  $g$  为核参数。样本数据投影到维度空间这一过程会受到径向基函数核函数中的核参数  $g$  大小的影响, 因此, 选用合适的  $C$  和  $g$  会使 SVM 分类更精准。

### 1.2.2 粒子群优化算法(PSO)

粒子群算法<sup>[28]</sup> (Particle Swarm Optimization, PSO) 是启发于鸟群觅食规律, 提出了一种简化数学模型, 经过多年改良形成了粒子群优化算法, 因其易于实现、原理简单、具有全局收敛性, 在实际应用中表现出良好的性能。考虑到粒子群的全局寻优问题和局部寻优问题, 给出了一种基于线性衰减惯性权重的改进粒子群算法。改进粒子群优化算法的粒子运动速度和运动位置更新公式<sup>[29]</sup>如下:

$$v_{iQ}^{k+1} = \omega v_{iQ}^k + c_1 r_1 (p_{iQ}^k - x_{iQ}^k) + c_2 r_2 (g_{iQ}^k - x_{iQ}^k) \quad (9)$$

$$x_{iQ}^{k+1} = x_{iQ}^k + v_{iQ}^{k+1} \quad (10)$$

$$\omega = \omega_{\max} - (\omega_{\max} - \omega_{\min}) * \text{iter} / \text{iter}_{\max} \quad (11)$$

式中,  $v_{iQ}^k, v_{iQ}^{k+1}, x_{iQ}^k, x_{iQ}^{k+1}$  分别是当前时刻的速度、下一时刻的速度、当前时刻的位置、下一时刻的位置,  $x_{iQ}^k, x_{iQ}^{k+1}$  代表着局部的最优解,  $p_{iQ}, g_{iQ}$  为局部极值和整体最优值;  $c_1, c_2$  是学习系数;  $r_1, r_2$  是  $[0, 1]$  之间的随机数;  $\omega$  是惯性权重系数,  $\omega_{\max}, \omega_{\min}$  分别为最大、最小权重系数;  $\text{iter}, \text{iter}_{\max}$  分别为当前迭代次数和总的迭代次数。

### 1.2.3 PSO-SVM 预测模型的实现方法

SVM 模型包含两个关键的参数  $C$  与  $g$ 。这里  $C$  为惩罚系数, 即对模型误差的包容度。  $C$  越大, 容忍误差值越小, 容易造成过拟合。  $C$  越小, 容忍误差值越大, 容易造成欠拟合。  $C$  过大或过小, 都会导致拟合性能变差。  $g$  是选择 RBF 函数作为核函数后, 该函数自带的一个参数。核参数  $g$  决定了新的特征空间中数据位置的分布情况, 核参数  $g$  值越小, 支持向量的数量越多,  $g$  值越大, 模型的支持向量的数量越

少。支持向量的数量直接关系到模型的训练和预测的速度。

本文中 PSO-SVM 模型的训练过程如图 1 所示: (1) 导入某钢厂 200 t 转炉冶炼实际生产数据, 按比例随机划分为两个样本数据集, 分别为训练数据集和测试数据集, 另一方面对两个样本数据集进行归一化处理; (2) 对 SVM 进行初始化设置, 并且设置参数循环范围, 训练 SVM 模型并结合 PSO 迭代, 更新局部极值和整体最优值, 得到全局中最优惩罚系数  $C$  和核函数参数  $g$ ; (3) 将经过 PSO 迭代计算后的最优参数赋值给 SVM 模型参数中, 将测试集数据带入模型进行迭代训练得到预测值, 将得到的预测值进行逆向归一化处理; (4) 计算预测值与实际值之间的误差以及模型的命中率, 得到预测模型的精度。

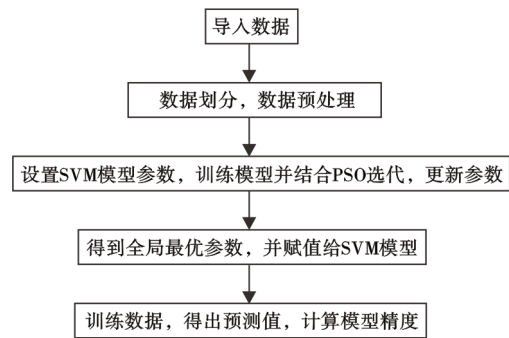


图1 PSO-SVM 模型训练流程  
Fig. 1 PSO-SVM model training process

### 1.3 建模参数的选取

支持向量机回归所逼近的是对多输入单输出, 所以, 建立终点钢水碳含量和终点温度两个模型。为了验证模型的预测精度, 本模型利用采集的 500 组 200 t 转炉实际生产数据进行验证, 在经过 1 节的叙述得到 425 组满足要求的数据, 其中 375 组作为训练集数据, 50 组作为测试集数据。选取模型的输入变量见表 1。

## 2 仿真试验及结果

试验选用的计算机为 8GB 内存, 处理器为 Intel (R) Core(TM) i7-9700 3.00GHz, 选用的软件是 Matlab R2023a。将上述数据预处理后得到的 425 组数

表1 输入参数和输出参数  
Table 1 Input and output parameters

模型	输入变量					输出参数
碳含量预测	$\omega[C]_{\text{iron}}$	$\omega[\text{Si}]_{\text{iron}}$	$\omega[\text{Mn}]_{\text{iron}}$	$\omega[\text{P}]_{\text{iron}}$	$\omega[\text{S}]_{\text{iron}}$	钢液碳含量
温度预测	铁水重量	铁水温度	废钢量	石灰加入量	总耗氧量	钢液温度

据,随机划分为训练集数据和测试集数据,其中的 375 组为训练集数据,50 组为测试集数据,输入模型进行训练和测试。

支持向量机模型通过粒子群优化算法得到的最佳超参数见表 2。终点碳模型支持向量机的惩罚系数 C 为 0.192 4,核参数 g 为 3.094 2;终点温度支持向量机的惩罚系数 C 为 0.100 0,核参数 g 为 1.484 4。

表 2 SVM 模型的最优参数组合

参数	参数范围	终点碳模型最佳值	终点温度模型最佳值
C	(0.1, 100)	0.192 4	0.100 0
g	(0.1, 100)	3.094 2	1.484 4

PSO-SVM 模型的预测折线图和误差分布分别如图 2 和图 3 所示,终点钢水碳含量模型当误差精度  $\leq 0.02\%$  时,只有 3 炉次不在范围内,其中最大误差为 0.021%;终点温度模型当误差精度  $\leq 20\text{ }^\circ\text{C}$  时,只有 4 炉次不在范围内,其中最大误差为  $24\text{ }^\circ\text{C}$ 。

为检验模型的实用性,采用以下指标:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

$$\text{SSE/SST} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (14)$$

$$\text{SSR/SST} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (15)$$

$$\text{HR} = \frac{|\{y_i - \hat{y}_i| \leq \text{设定误差的样本数量}\}}{n} \times 100 \quad (16)$$

式中, n 为测试集数据样本的个数,  $y_i$  (%或  $^\circ\text{C}$ ) 是测试集样本的实际值,  $\bar{y}_i$  (%或  $^\circ\text{C}$ ) 是测试集样本的平均值,  $\hat{y}_i$  (%或  $^\circ\text{C}$ ) 是预测模型的输出值。RMSE (%或  $^\circ\text{C}$ ) 为均方根误差,它表示测试集样本的实际值和预测值之间差异(称为残差)的样本标准差,MAE (%或  $^\circ\text{C}$ ) 为平均绝对值误差,它表示为测试集样本实际值与预测值之间绝对误差的平均值,这两个指标越小,说明建立的模型的误差越小;SSE/SST 和 SSR/SST 是检验建立的转炉终点预测模型拟合程度的性能参数,SSR/SST 越接近于 1 或者 SSE/SST 越小,说明模型的拟合程度越好,但是,要是 SSE/SST 极其小,则会遇到过拟合问题,表示预测模型不能根据已有数据对终点进行准确预测。HR (%) 表示为转炉终点预测模型在误差范围内的终点(碳质量分数和温度)的命中率。

PSO-SVM 模型与其他模型回归性能对比见表 3,在终点钢水碳含量的预测中,PSO-SVM 模型的 RMSE 为 0.010, SVM 模型、BP 模型和 RBF 模型的 RMSE 分别为 0.015, 0.016、0.014, PSO-SVM 模型的预测误差最小; PSO-SVM 模型的 SSE/SST 为 0.11, SVM 模型、BP 模型和 RBF 模型的 SSE/SST 分别为 0.17、0.18、0.30, PSO-SVM 模型的 SSE/SST 比其他三种模型都更小; PSO-SVM 模型的 SSR/SST 为 0.96, SVM 模型、BP 模型和 RBF 模型的 SSR/SST 分别为 0.90、1.11、0.88, PSO-SVM 模型的 SSR/SST 更接近于 1; PSO-SVM 的终点命中率为 84%, 相较于 SVM 模型提高了 9%, 在四个模型中最高。

在终点温度模型的预测中, PSO-SVM 模型的 RMSE 为 11.18, SVM 模型、BP 模型和 RBF 模型的 RMSE 分别为 12.00、11.57、13.05, PSO-SVM 模型的预测误差最小; PSO-SVM 模型的 SSE/SST 为 0.07,

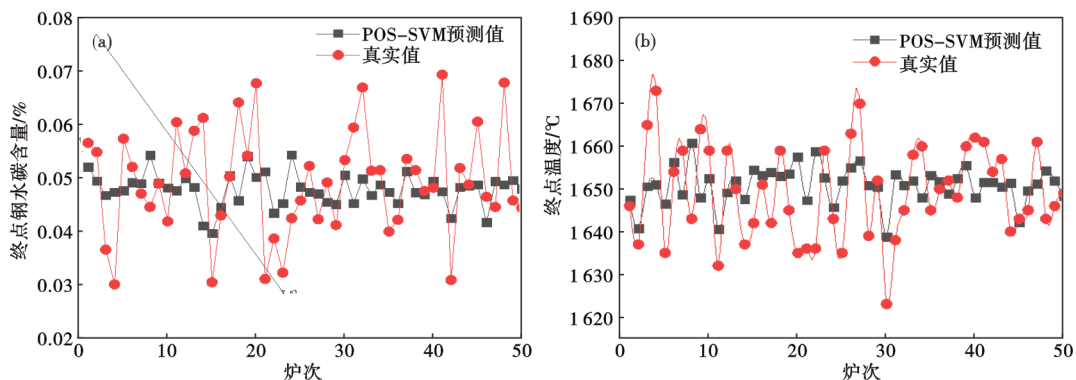


图 2 终点钢水碳含量和温度的预测模型结果:(a)钢水碳含量,(b)温度

Fig. 2 Prediction model results of the molten steel carbon content and temperature at the end point : (a)the molten steel carbon content, (b)temperature




图3 碳含量和温度的误差分布:(a)碳质量分数,(b)温度  
Fig. 3 Error distribution of carbon mass fraction and temperature : (a) carbon mass fraction, (b) temperature

表3 四种模型回归性能对比

Table 3 Comparison of the regression performance of the four models

模型	指标	PSO-SVM	SVM	BP	RBF
碳质量分数	RMSE	0.010	0.015	0.016	0.014
	MAE	0.007 5	0.011	0.012	0.10
	SSR/SST	0.96	0.90	1.11	0.88
	SSE/SST	0.11	0.17	0.18	0.30
	HR( $\pm 0.015\%$ )/%	84.0	75.0	60.0	73.3
温度模型	RMSE	11.18	12.00	11.57	13.05
	MAE	9.56	9.94	9.25	10.36
	SSR/SST	0.94	0.91	0.93	1.12
	SSE/SST	0.07	0.13	0.02	0.12
	HR( $\pm 15\text{ }^\circ\text{C}$ )/%	80.0	78.0	71.0	73.3

### 参考文献

- [1] 任燕雄, 彭超, 许君诚, 等. 转炉炼钢终点控制技术研究与分析[J]. 中国金属通报, 2022(10): 20-22.
- [2] 李少帅. 转炉炼钢终点控制技术浅析[J]. 冶金与材料, 2023, 43(2): 90-92.
- [3] 王冠华. 转炉冶炼中高碳钢过程及终点控制分析[J]. 冶金与材料, 2023, 43(2): 105-107.
- [4] 薛月凯. 转炉冶炼静态控制模型的研究[D]. 唐山: 河北联合大学, 2012.
- [5] 孙凤梅, 崔绍刚, 卢金强, 等. 50 t转炉静态控制模型开发及生产实践[J]. 上海金属, 2013, 35(6): 34-37.
- [6] 郭亚芬, 杜斌. 宝钢有副枪转炉吹炼终点控制模型研究与应用[J]. 冶金自动化, 2003, 27(S1): 45-48.
- [7] 岳峰, 包燕平, 崔衡, 等. 基于副枪控制的转炉终点预测模型[J]. 炼钢, 2009, 25(1): 38-40+59.
- [8] 王希政. 基于RBF神经网络的转炉炼钢终点碳温预测模型[D]. 沈阳: 东北大学, 2015.
- [9] 苏春阳, 陈君, 姜亚清. 基于PCA-BP神经网络的LF精炼终点温度预测[J]. 特殊钢, 2023, 44(6): 39-44.
- [10] 郑忠, 史战东, 高小强, 等. 两种转炉炼钢终点控制模型比较[J]. 特殊钢, 2008, 29(6): 20-22.
- [11] Han M, Liu C. Endpoint prediction model for basic oxygen furnace steel-making based on membrane algorithm evolving extreme learning machine [J]. Applied Soft Computing, 2014, 19: 430-437.
- [12] Wang X Z, Han M, Wang J. Applying input variables selection technique on input weighted support vector machine modeling for BOF endpoint prediction[J]. Engineering Applications of Artificial Intelligence, 2010, 23(6): 1012-1018.
- [13] 刘冬梅, 陈斌, 王淑阁, 等. 改进训练方法的模糊神经网络模型预报转炉终点磷的研究和应用[J]. 特殊钢, 2007, 28(2): 41-43.
- [14] Han M, Cao Z J. An improved case-based reasoning method and its application in endpoint prediction of basic oxygen furnace[J]. Neurocomputing, 2015, 149: 1245-1252.
- [15] 铤明涛, 李娇娇, 王楠, 等. 基于FOA-GRNN模型的转炉炼钢终点预报[J]. 材料与冶金学报, 2019, 18(1): 31-36+57.
- [16] 刘闯, 韩敏, 王心哲. 基于膜算法进化极限学习机的氧气转炉炼钢终点预报模型[J]. 大连理工大学学报, 2014, 54(1): 124-130.
- [17] 谷茂强. 基于数据驱动的转炉终点控制模型研究与应用[D]. 北京: 北京科技大学, 2023.
- [18] 杜贤敏. 转炉炼钢终点预报与控制模型的研究[D]. 沈阳: 东北大学, 2014.
- [19] 高绪东. BP神经网络在高炉铁水硅预报中的应用[J]. 中国冶金, 2014, 24(6): 24-26+39.
- [20] 崔桂梅, 李静, 张勇, 等. 基于T-S模糊神经网络模型的高炉铁水温度预测建模[J]. 钢铁, 2013, 48(11): 11-15.
- [21] 任彦军, 王家伟, 张晓兵, 等. 基于LM算法BP神经网络的高

SVM模型、BP模型和RBF模型的SSE/SST分别为0.13、0.02、0.12; PSO-SVM模型的SSR/SST为0.94, SVM模型、BP模型和RBF模型的SSR/SST分别为0.91、0.93、1.12, PSO-SVM模型的SSR/SST更接近于1; PSO-SVM模型的终点命中率为80%, 相较于SVM模型提高了2%, 在四个模型中排名第一。

### 3 结论

为了精准预测转炉炼钢终点碳含量和终点温度, 提高炼钢的生产效率, 根据某钢厂200 t转炉的实际数据, 经过数据预处理和模型训练, 基于PSO-SVM建立了终点预测模型, 得出以下结论:

(1) 仿真结果表明, 终点碳质量分数预测模型在 $\pm 0.015\%$ 精度范围内的命中率为84%; 终点温度预测模型在 $\pm 15\text{ }^\circ\text{C}$ 精度范围内的命中率为80.0%。

(2) PSO-SVM终点钢水碳含量预测模型和终点温度预测模型的SSR/SST分别为0.96和0.94, 均高于其他三种模型, RMSE分别为0.01和11.18, 在三种模型中最低。结果表明, PSO-SVM终点预测模型在预测精度上优于SVM模型、BP模型和RBF模型。

炉-转炉界面铁水温度预报模型[J]. 钢铁, 2012, 47(9): 40-42+49.

[22] 赵路朋, 吴 铿, 朱 利, 等. 基于BP神经网络的烧结矿性能预报模型[J]. 钢铁, 2017, 52(9): 11-15.

[23] 秦 波, 吴庆朝, 张娟娟, 等. 基于PSO优化SVM的转炉炼钢用氧量预测研究[J]. 测控技术, 2014, 33(12): 121-124.

[24] 王建国, 吴庆朝, 秦 波, 等. 粒子群优化支持向量机的BOF用氧量预报研究[J]. 铸造技术, 2014, 35(8): 1806-1809.

[25] 王旭生, 贾金锁. 基于支持向量机的转炉炼钢终点预测研究[J]. 无线互联科技, 2017(2): 115-117.

[26] 汪 森, 李胜利, 高 闯, 等. 80 t转炉终点预报TSVR模型精度[J]. 钢铁, 2020, 55(7): 53-57.

[27] 罗 娜. 数据挖掘中的新方法——支持向量机[J]. 软件导刊, 2008, 7(10): 30-31.

[28] Aydin I, Karakose M, Akin E. A multi-objective artificial immune algorithm for parameter optimization in support vector machine [J]. Applied Soft Computing, 2011, 11(1): 120-129.

[29] Shi Y, Eberhart R. A modified particle swarm optimizer [C]. 1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence. 2002: 69-73.

## “特种冶金”专刊预告

《特殊钢》编辑部 特邀东北大学姜周华教授担任专刊主编, 东北大学董艳伍教授、北京科技大学杨树峰教授为专刊副主编, 拟于2024年第4期出版“特种冶金”专刊(正刊)。专刊旨在宣传报道中国特殊钢领域的高端新产品和特种冶金新工艺、新装备、新技术等方面的科研成果和应用实践, 以引领特种冶金工艺技术的创新发展。

专刊的征稿范围广泛, 包括与真空感应熔炼、电渣冶金、真空自耗重熔、电子束重熔等特种冶金技术密切相关的内容。选题方向涵盖特种冶金工艺、产品、装备等, 品种涉及轴承钢、不锈钢、工模具钢、超高强度钢、高温合金、耐蚀合金、精密合金等。

专刊将于2024年7月出版, 敬请关注。

《特殊钢》编辑部