

DOI:10.19651/j.cnki.emt.2105734

基于 IFSVR 和 PSO 算法的转炉炼钢终点预测

侯丽芳

(烟台汽车工程职业学院 烟台 264000)

摘要: 转炉炼钢在炼钢过程中占有重要地位,对转炉过程进行精准的控制是至关重要的。转炉炼钢的控制过程是建立在转炉终点预测的基础上,所以,为了实现精准炼钢,建立转炉炼钢的终点预测模型是有必要的。针对转炉炼钢终点预报的特点,提出了一种改进的模糊支持向量回归机(IFSVR)模型。IFSVR是在模糊支持向量回归机(FSVR)的基础上,对参数 ϵ 进行优化。此外,为了提高优化效率,粒子群优化算法(PSO)被用于 IFSVR 的参数优化中,进而提高建模速率。仿真结果表明,所提出的模型是有效可行的。在不同的误差范围内(含碳量模型为 0.005%,温度模型为 10℃),含碳量和温度的命中率分别达到 91%和 94%,双命中率达到 90%,为实际转炉应用提供了重要参考,该方法也适用于预测模型其他冶金应用。

关键词: 转炉炼钢;终点预测;模糊支持向量回归机;粒子群优化算法

中图分类号: TP181 文献标识码: A 国家标准学科分类代码: 520.2040

End-point prediction of basic oxygen furnace steelmaking based on IFSVR and PSO

Hou Lifang

(Yantai Automobile Engineering Professional College, Yantai 264000, China)

Abstract: Basic oxygen furnace (BOF) steelmaking plays an important role in the steelmaking process, so it is very important to control the converter process accurately. The control process of BOF steelmaking is based on the end point prediction of BOF. Therefore, in order to achieve accurate steelmaking, it is necessary to establish the end point prediction model of BOF steelmaking. According to the characteristics of BOF end-point prediction, an improved fuzzy support vector regression (IFSVT) algorithm is proposed in this paper. IFSVR is built by introducing the parameter based on fuzzy support vector regression (FSVR). In addition, in order to improve the optimization efficiency, particle swarm optimization (PSO) algorithm is used in the parameter optimization of IFSVR, so as to improve the modeling speed. The experimental results show that the proposed models are effective and feasible. Within different error bounds (0.005% for carbon content model and 10℃ for temperature model), the hit rates of carbon content and temperature realize 91% and 94%, respectively. And a double hit rate of 90% is obtained, which can provide a significant reference for real BOF applications, and the proposed method is also appropriate for the prediction models of other metallurgical applications.

Keywords: basic oxygen furnace; end-point prediction; fuzzy support vector regression; particle swarm optimization

0 引言

转炉炼钢^[1]的目标是获得所需的钢水温度和碳含量。转炉炼钢是一个非常复杂的物理化学过程。一般过程中采用的控制方法不能用于转炉。由于转炉炼钢终点预报的特点,通过对终点温度和碳含量的准确预报,可以及时调整炉内添加的原辅材料,提高终点命中率。

近年来,转炉炼钢终点预测模型取得了一些重要进

展^[2-6]。其中,人工智能方法在转炉炼钢控制过程中扮演着重要的角色。它能够实现智能控制,提高冶炼质量和效率。例如,文献[4]利用神经网络建立预测模型,实现钢液中的目标终点条件。文献[5]基于进化膜算法,提出了一种极限学习机(extreme learning machine, ELM)抗干扰端点预测模型。文献[6]在改进基于实例推理方法的基础上,建立了预测模型。这些成果都是建立在统计和智能方法的基础上的。

收稿日期:2021-01-25

• 68 •

目前,最为流行的人工智能算法是深度学习^[7]。但它需要大量的训练数据,针对转炉炼钢数据集,深度学习难以胜任。相反,基于支持向量回归机(support vector regression, SVR)^[8]的预测模型被证实是最有效的预测算法之一。文献[9-11]采用 SVR 及其改进版本实现了转炉炼钢终点预测。

尽管 SVR 有好的泛化能力,但对噪声较敏感。为解决这个问题,本文提出了改进的模糊支持向量回归机(improved fuzzy SVR, IFSVR)算法,并用来建立转炉炼钢的终点预测模型。以此提高终点预报的精度,进而提高目标产品收率,实现节能减排。

1 基于 PSO 的 IFSVR 预测模型

1.1 IFSVR

给定训练集为 $X = \{(x_i, y_i, \tau_i)\}_{i=1}^n \in \mathbf{R}^{n \times d}$, 其中 $x_i \in \mathbf{R}^{d \times 1}$ 为输入特征, $y_i \in \mathbf{R}$ 为对应的输出值, τ_i 为对应样本的模糊隶属度,且有 $\rho_i < \tau_i \leq 1$, 这里 ρ_i 是一个非常小的正数。

模糊支持向量回归机(fuzzy support vector regression, FSVR)^[12]通过训练一个回归函数 $f(x) = \mathbf{w}^T x + b$ 来描述输入特征和输出值之间的关系。其基本思想是对不同的样本赋予不同的误差权重,以此抑制噪声点和异常点对模型的不利影响,提高预测精度。本文借鉴文献[13]的思想,将参数 ε 引入到 FSVR 的目标函数中,提出了 IFSVR 模型,其相应的数学模型为下列优化问题。

$$\begin{aligned} \min_{\mathbf{w}, b} & \frac{1}{2} \mathbf{w}^T \mathbf{w} + c_1 \tau^T (\xi + \xi^*) + c_2 \varepsilon \\ \text{s. t. } & \mathbf{y} - (\mathbf{Xw} + b\mathbf{e}) \leq \varepsilon \mathbf{e} + \xi, \\ & (\mathbf{Xw} + b\mathbf{e}) - \mathbf{y} \leq \varepsilon \mathbf{e} + \xi^*, \\ & \varepsilon, \xi, \xi^* \geq 0 \end{aligned} \quad (1)$$

式中: $c > 0$ 是惩罚因子,用来调整回归函数的光滑性和允许超过 ε 范围的误差之和; ξ 和 ξ^* 是松弛因子,用来表示允许超出拟合误差的样本; $\mathbf{e} \in \mathbf{R}^{n \times 1}$ 为全 1 列向量。

优化问题(1)的拉格朗日函数是:

$$\begin{aligned} L = & \frac{1}{2} \mathbf{w}^T \mathbf{w} + c_1 \tau^T (\xi + \xi^*) + c_2 \varepsilon + \boldsymbol{\alpha}^T (\mathbf{y} - (\mathbf{Xw} + b\mathbf{e}) - \varepsilon \mathbf{e} - \xi) + \boldsymbol{\beta}^T ((\mathbf{Xw} + b\mathbf{e}) - \mathbf{y} - \varepsilon \mathbf{e} - \xi^*) - \boldsymbol{\gamma}^T \xi - (\boldsymbol{\gamma}^*)^T \xi^* - \lambda \varepsilon \end{aligned} \quad (2)$$

式中: $\boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\gamma} \in \mathbf{R}^{n \times 1}$ 和 $\lambda \in \mathbf{R}$ 是 Lagrange 乘子。

其 KKT 条件为:

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \mathbf{X}^T \boldsymbol{\alpha} + \mathbf{X}^T \boldsymbol{\beta} = 0 \quad (3)$$

$$\frac{\partial L}{\partial b} = -\mathbf{e}^T \boldsymbol{\alpha} + \mathbf{e}^T \boldsymbol{\beta} = 0 \quad (4)$$

$$\frac{\partial L}{\partial \xi} = c_1 \tau - \boldsymbol{\alpha} - \boldsymbol{\gamma} = 0 \quad (5)$$

$$\frac{\partial L}{\partial \xi^*} = c_1 \tau - \boldsymbol{\beta} - \boldsymbol{\gamma}^* = 0 \quad (6)$$

$$\frac{\partial L}{\partial \varepsilon} = c_2 - \mathbf{e}^T \boldsymbol{\alpha} - \mathbf{e}^T \boldsymbol{\beta} - \lambda = 0 \quad (7)$$

由 KKT 条件式(5)~(7)可得:

$$0\mathbf{e} \leq \boldsymbol{\alpha} \leq c_1 \tau, 0\mathbf{e} \leq \boldsymbol{\beta} \leq c_1 \tau, \mathbf{e}^T (\boldsymbol{\alpha} + \boldsymbol{\beta}) \leq c_2 \quad (8)$$

结合式(4)~(8),化简 Lagrange 函数式(2),可得:

$$\begin{aligned} L = & \frac{1}{2} \mathbf{w}^T \mathbf{w} - (\boldsymbol{\alpha} - \boldsymbol{\beta})^T \mathbf{Xw} + \boldsymbol{\alpha}^T \mathbf{y} - \boldsymbol{\beta}^T \mathbf{y} = \\ & \frac{1}{2} \mathbf{w}^T \mathbf{w} - \mathbf{w}^T \mathbf{w} + \boldsymbol{\alpha}^T \mathbf{y} - \boldsymbol{\beta}^T \mathbf{y} = -\frac{1}{2} \mathbf{w}^T \mathbf{w} + \boldsymbol{\alpha}^T \mathbf{y} - \boldsymbol{\beta}^T \mathbf{y} = \\ & -\frac{1}{2} (\mathbf{X}^T (\boldsymbol{\alpha} - \boldsymbol{\beta}))^T (\mathbf{X}^T (\boldsymbol{\alpha} - \boldsymbol{\beta})) + \boldsymbol{\alpha}^T \mathbf{y} - \boldsymbol{\beta}^T \mathbf{y} = \\ & -\frac{1}{2} (\boldsymbol{\alpha} - \boldsymbol{\beta})^T \mathbf{X} \mathbf{X}^T (\boldsymbol{\alpha} - \boldsymbol{\beta}) + (\boldsymbol{\alpha} - \boldsymbol{\beta})^T \mathbf{y} \end{aligned} \quad (9)$$

从而可得到原始优化问题(1)的对偶问题,如式(10)所示。

$$\begin{aligned} \min_{\boldsymbol{\alpha}, \boldsymbol{\beta}} & \frac{1}{2} (\boldsymbol{\alpha} - \boldsymbol{\beta})^T \mathbf{X} \mathbf{X}^T (\boldsymbol{\alpha} - \boldsymbol{\beta}) - (\boldsymbol{\alpha} - \boldsymbol{\beta})^T \mathbf{y} \\ \text{s. t. } & 0\mathbf{e} \leq \boldsymbol{\alpha}, \boldsymbol{\beta} \leq c_1 \tau, \\ & \mathbf{e}^T (\boldsymbol{\alpha} + \boldsymbol{\beta}) \leq c_2 \end{aligned} \quad (10)$$

在本文中,样本的模糊隶属度的计算参考文献[14]。给定了样本的模糊隶属度 τ_i 后,就可以利用求解标准 SVR 的算法求解式(10)的最优解。一旦获得式(10)的最优解 $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$, 即可获得原始优化问题(1)的最优解 \mathbf{w} 和 b , 最终可获得回归函数 $f(x)$ 。

$$\mathbf{w} = \mathbf{X}^T (\boldsymbol{\alpha} - \boldsymbol{\beta}) \quad (11)$$

$$b = \begin{cases} \frac{1}{T_1} \sum_{i \in T_1} y_i - x_i \mathbf{w} - \varepsilon, T_1 = \{i \mid 0 < \alpha_i < c_1 \tau_i\} \\ \frac{1}{T_2} \sum_{j \in T_2} \varepsilon + y_j - x_j \mathbf{w}, T_2 = \{j \mid 0 < \beta_j < c_1 \tau_j\} \end{cases} \quad (12)$$

1.2 PSO 算法

粒子群优化算法(particle swarm optimization, PSO)^[15]于 1995 年由 Kennedy 和 Eberhart 提出。其思想源于对鸟群捕食行为的研究,具有简单易行、收敛速度快和设置参数少等特点。因此,本文利用 PSO 算法来优化 IFSVR 算法中的参数。PSO 算法的具体流程如图 1 所示,这里,适应度由预测精度表示,即:

$$fit(c_1, c_2, \delta^2) = \frac{size(\mathbf{T}, 1)}{n} \times 100\% \quad (13)$$

式中: δ^2 为核半径参数; $\mathbf{T} = \{x_i \mid y_i - \hat{y}_i \leq \Delta\}$; $size(\mathbf{T}, 1)$ 表示集合 \mathbf{T} 中元素的个数; \hat{y}_i 是通过 IFSVR 预测模型得到的预测值; y_i 为实际输出值; Δ 是人为设定的误差上界。

2 转炉炼钢终点信息预测模型

2.1 转炉炼钢数据预处理

终点碳含量和温度是检验炼钢质量的主要因素。炼钢的最终目标是将终点碳含量和温度控制在一个满意的范围

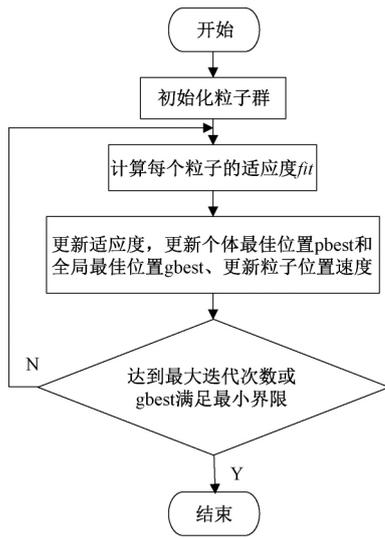


图 1 PSO 优化算法流程

内。为了设计精准的转炉炼钢控制模型,首先要准确建立终点预报模型。控制任务是在预测模型的基础上实现的,预测模型的关键是确定输入变量,输入变量一般是终点碳含量或温度的影响因素。在文献[16]中,分析了转炉吹炼终点的机理,指出表 1 中的影响因素可以作为终点预测模型的独立输入变量。

表 1 独立输入输出变量

	变量	符号	单位
输入变量	铁水量	x_1	吨
	C 含量	x_2	%
	Si 含量	x_3	%
	Mn 含量	x_4	%
	P 含量	x_5	%
	S 含量	x_6	%
	废钢量	x_7	吨
	铁水温度	x_8	°C
	白云石原石	x_9	吨
	石灰	x_{10}	吨
	氧累	x_{11}	Nm ³
输出变量	碳含量	y_1	%
	温度	y_2	°C

在整个转炉冶炼过程的实际应用中,对于转炉冶炼数据的预处理是仅次于模型建立。考虑到各特征的数量级不同,导致数值之间存在较大的差异。这导致在训练模型的过程中,需要较长的时间才能寻到或无法寻到模型的最优解,从而使算法被迫偏移到了较大取值数据的侧重上,导致小数值对模型的影响力被削弱,从而得不到理想的预测结果。

为了解决该问题,在训练模型之前,对转炉炼钢数据进

行归一化处理是十分必要的。归一化的方法有很多,本文采用线性变换法将输入输出样本变换到[0,1]之间。其公式如下:

$$\hat{x}(k) = \frac{x(k) - \min(x(k))}{\max(x(k)) - \min(x(k))} \quad (14)$$

式中: $x(k)$ 表示第 k 个输入数据; $\min()$ 和 $\max()$ 分别表示 $x(k)$ 中的最小值和最大值; $\hat{x}(k)$ 为归一化后的第 k 个输入数据。

2.2 转炉炼钢静态预测模型的建立

在 2.1 节中,可获得一组合格的转炉炼钢数据集,将获得的数据集划分为训练集和测试集两部分。训练集用来建立预测模型,测试集用来验证模型的准确性。模型参数 (c_1, c_2, δ^2) 的选择对模型非常重要,因此,本文利用了 PSO 优化算法来获得终点碳含量模型和终点温度模型的最佳参数。一旦确定模型参数,就完成了预测模型的建立。建立模型的具体流程如图 2 所示。

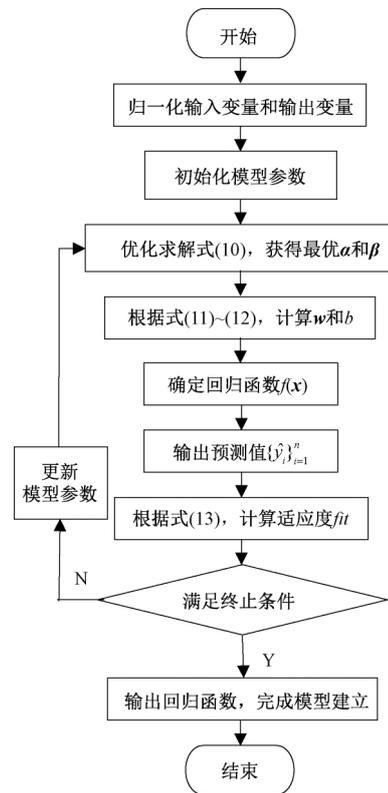


图 2 转炉炼钢预测模型的建立流程

3 实验结果与分析

3.1 评价指标

为了验证本文提出的 IFSVR 算法的有效性,从泛化能力和训练效率两方面进行了一系列的数值实验。为了使得 IFSVR 预测结果更具有说服力,将 IFSVR 与 FSVR、SVR 和 BP 进行了对比。所有的实验都是在主频为 2.9 GHz 的 Intel i7 处理器,内存为 16 GB RAM 的 Windows 10 台式电

脑进行的。

为了评价所提出的模型的性能,一系列的评价标准^[17]被定义。假设测试样本的总数为 m , y_i 为样本 x_i 的实际输出值, \hat{y}_i 是样本 x_i 的预测值, $\bar{y} = \frac{1}{m} \sum_{i=1}^m y_i$ 是 $\{y_i\}_{i=1}^m$ 的平均值。因此,相应的评价指标可定义为:

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (15)$$

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (16)$$

$$\text{SSE/SST} = \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (17)$$

$$\text{SSR/SST} = \frac{\sum_{i=1}^m (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (18)$$

其中, RMSE 是均方根误差, MAE 是平均绝对误差。一般情况下,较小的 SSE/SST 表明模型具有更好的性能。但是,如果 SSE/SST 值非常小,也不是很好的结果,这可能会导致回归函数出现过拟合问题。评价转炉模型性能的另一个重要标准是命中率(hit rate, HR)。它指的是合格样本数量与总样本数量的比值,可用式(13)计算。对于数据集集中的任何一个样本,如果预测值与实际值之间的绝对误差小于某一误差界 Δ , 则说明该样本是令人满意的样本,即合格样本。

3.2 人工数据集仿真实验

在建立转炉炼钢预测模型之前,需要对理论模型进行回归,验证 IFSVR 的可行性和有效性,选取下列函数生成 256 个训练样本和 500 个测试样本。

$$y_i = \sin x_i / x_i, x_i \in [-4\pi, 4\pi] \quad (19)$$

为了验证 IFSVR 的抗噪声性能,人为的在输入样本中加入 0 均值和 0.1 方差的高斯白噪声,并引入少数离群样本点。IFSVR 的仿真效果如图 3 所示,其中“实线”表示回归曲线,“— —”线为 IFSVR 模型的上界,“点圈”线为 IFSVR 模型的下界。从图 3 中可以看出,IFSVR 算法的回归效果与理论模型曲线的拟合效果良好,具有一定的抗噪声能力,可以用来建立转炉炼钢终点预测模型。

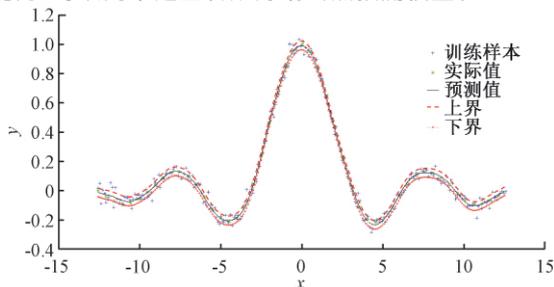


图 3 IFSVR 对人工函数的回归效果

3.3 粒子群算法优化过程仿真分析

为了验证 PSO 算法对 IFSVR 中参数的优化性能,本节以转炉炼钢终点温度和碳含量的预测模型为例进行仿真对比试验。这里,设置粒子群数为 20,迭代次数为 20。IFSVR 的参数取值范围是 $[0, 20]$ 。终点碳含量和温度的收敛拟合曲线如图 4 和 5 所示,其中横轴表示迭代次数,纵轴表示最优个体适应度值。从图 4 和 5 中可以看出,随着迭代次数的增加,两个模型的最优适应度值都在逐步增加。当迭代次数达到 11 和 12 次时,碳模型和温度模型的适应度值不再发生变化,趋于平稳。此时,可以得到碳模型和温度模型的最优参数,如表 2 所示。

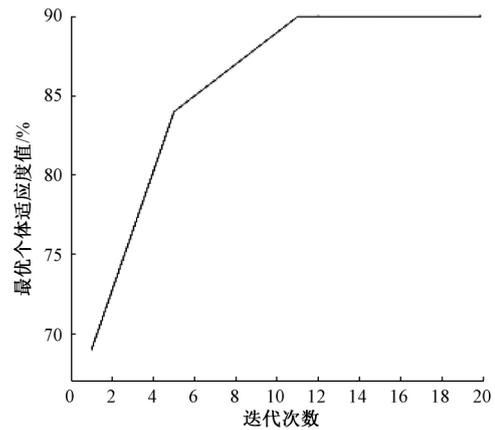


图 4 终点碳含量预测时的 PSO 算法收敛曲线

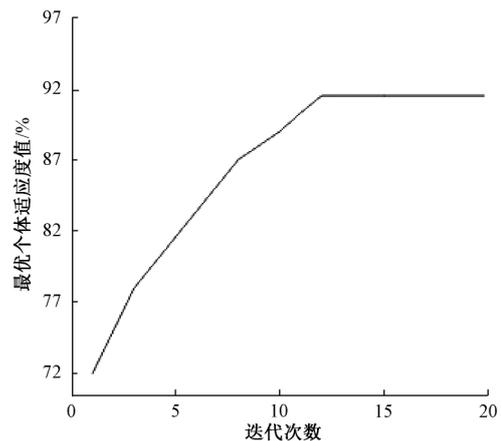


图 5 终点温度预测时的 PSO 算法收敛曲线

表 2 碳温预测模型参数表

模型	c_1	c_2	δ^2
碳含量模型	2.873 0	2.786 8	10.631 8
温度模型	2.221 2	2.913 8	2.262 1

3.4 转炉炼钢预测模型的实验仿真

本文所用的转炉炼钢数据均来自中国某钢厂。首先建立了含有 130 组 260 t 转炉数据的数据库。然后,随机将

130 组样本划分为训练样本和测试样本两部分,训练样本 100 组,测试样本 30 组。为满足现场的要求,本次实验选取的碳含量模型的误差容限为 $\pm 0.005 \text{ wt}\%$,温度模型的误差容限为 $\pm 10 \text{ }^\circ\text{C}$ 。

为了验证本文提出的算法的有效性,本节分别对 IFSVR、FSVR, SVR 和 BP 进行建模,并按照式(15)~(18)进行相关指标的计算。表 3 所示为基于 4 种算法的转炉终点预测模型比较结果。

表 3 4 种碳温预测模型的预测效果对比

模型	指标	IFSVR	FSVR	SVR	BP
碳含量模型 ($\pm 0.005 \text{ wt}\%$)	RMSE/ $\text{wt}\%$	0.002 5	0.003 0	0.003 4	0.003 9
	MAE/ $\text{wt}\%$	0.001 9	0.002 7	0.002 7	0.003 3
	SSE/SST	0.649 9	0.813 9	0.777 5	0.718 7
	SSR/SST	0.805 1	0.704 9	0.659 9	0.512 3
	单命中率/ $\%$	91	89	86	74
温度模型($\pm 10 \text{ }^\circ\text{C}$)	RMSE/ $^\circ\text{C}$	4.043 3	5.248 0	5.684 5	6.390 9
	MAE/ $^\circ\text{C}$	3.011 1	4.508 6	4.951 1	5.308 6
	SSE/SST	0.461 7	0.437 4	0.480 2	0.566 8
	SSR/SST	0.781 8	0.707 0	0.611 5	0.613 2
	单命中率/ $\%$	94	89	84	70
	双命中率/ $\%$	90	85	82	67

从表 3 中可以看出,对于碳含量模型,所提出的 IFSVR 算法的 RMSE、MAE、SSE/SST 和 SSE/SSR 均好于其他 3 个算法,并且 IFSVR 可实现 91% 的单命中率,高于其他 3 个算法。结果表明,提出的 IFSVR 模型对碳含量预测具有最佳的拟合性能。

同样,温度预测的性能比较也列在表 3 中。从表中可以看出,IFSVR 模型的 RMSE、MAE 和 SSR/SST 结果都是 4 个算法中最优的。虽然 IFSVR 模型的 SSE/SST 处于第 2 位,但该模型的温度预测命中率可达 94%,高于其他 3 个算法的命中率。此外,IFSVR 算法实现了 90% 的双命中率,明显高于其他 3 种方法。从以上分析可以看出,本文提出的碳含量和温度模型更为有效,为实际应用提供了参考。

4 结 论

考虑到不同的输入特征对输出变量的贡献程度不同,本文提出了一种新的回归模型 IFSVR,并将其应用于转炉炼钢终点预报。该方法的优点在于它将传统方法 FSVR 中的参数引入到 IFSVR 目标函数中,通过参数调整它的权重,建立了 IFSVR 模型。IFSVR 模型可以对重要样本进行增强,抑制噪声,提高预测精度。此外,PSO 方法取代了网格搜索进行参数选择,大大缩短了 IFSVR 的建模时间。对比实验结果表明,所提出的模型是有效可行的。在不同的误差范围内,碳含量和温度的命中率分别可达到 91% 和 94%。同时可获得 90% 的双命中率,为转炉的实际应用提供了重要参考。但是,本文建立的模型属于静态模型,所以未来工作将关注于如何建立一个动态控制模型,用于计算在流动阶段的氧含量和冷却剂添加量。

参考文献

- [1] LI C R, ZHAO H W, YIN Q. Prediction model of end-point carbon content for BOF based on LM BP neural network [J]. *Advanced Materials Research*, 2011, 189-193: 4446-4450.
- [2] 李鹏举, 刘辉, 王彬, 等. 基于火焰动态形变特征的转炉炼钢终点判定[J]. *仪器仪表学报*, 2015, 36(11): 2625-2633.
- [3] 冯士超, 王艳红, 丁瑞锋. 转炉炼钢终点控制技术应用现状[J]. *冶金自动化*, 2016, 40(2): 1-6.
- [4] HE F, ZHANG L. Prediction model of end-point phosphorus content in BOF steelmaking process based on PCA and BP neural network[J]. *Journal of Process Control*, 2018, 66: 51-58.
- [5] 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(1): 430-437.
- [6] HAN M, CAO Z. An improved case-based reasoning method and its application in endpoint prediction of basic oxygen furnace [J]. *Neurocomputing*, 2015, 149: 1245-1252.
- [7] GOODFELLOW I, BENGIO Y, COURVILLE A. *Deep Learning*[M]. The MIT Press, 2016.
- [8] CHEN P H, LIN C J, SCHÖLKOPF B. A tutorial on support vector machines [J]. *Applied Stochastic Models in Business & Industry*, 2010, 21(2): 111-136.
- [9] GAO C, SHEN M, LIU X, et al. End-point static

- control of basic oxygen furnace (BOF) steelmaking based on wavelet transform weighted twin support vector regression[J]. Complexity, 2019, 2019(6): 1-16.
- [10] XU L F, LI W, ZHANG M, et al. A model of basic oxygen furnace(BOF) end-point prediction based on spectrum information of the furnace flame with support vector machine (SVM) [J]. Optik-International Journal for Light and Electron Optics, 2011, 122(7): 594-598.
- [11] SHAO Y, ZHOU M, CHEN Y, et al. BOF endpoint prediction based on the flame radiation by hybrid SVC and SVR modeling[J]. Optik-International Journal for Light and Electron Optics, 2014, 125(11): 2491-2496.
- [12] CHENG M, HOANG N, ROY A, et al. A novel time-depended evolutionary fuzzy SVM inference model for estimating construction project at completion[J]. Engineering Applications of Artificial Intelligence, 2012, 25(4): 744-752, 2012.
- [13] XU Y T, LI X, PAN X, et al. Asymmetric ν -twin support vector regression[J]. Neural Computing & Applications, 2017(2): 1-16.
- [14] ABE S. Support Vector Machines for Pattern Classification[M]. IEEE, 2013.
- [15] KENNEDY J, EBERHART R. Particle swarm optimization[C]. Icn'95-International Conference on Neural Networks, IEEE, 2002, 4: 1942-1948.
- [16] 郑威迪. 基于 LWOA 和 LSSVM 的炼钢终点预测与控制研究[D]. 鞍山:辽宁科技大学,2019.
- [17] GAO C, SHEN M, LIU X, et al. End-point prediction of BOF steelmaking based on KNNWTSVR and LWOA[J]. Transactions of the Indian Institute of Metals, 2018, 72(1):257-270.

作者简介

侯丽芳,讲师,主要研究方向为汽车轻量化。

E-mail: houlifang042200@163.com