

# 基于随机森林与支持向量机的热轧带钢凸度 加权预测模型研究<sup>①</sup>

周亚罗<sup>1</sup>, 李子轩<sup>1</sup>, 张少川<sup>1</sup>, 刘文广<sup>2</sup>, 张瑞成<sup>1</sup>

(1.华北理工大学 电气工程学院, 河北 唐山 063210; 2.首钢京唐钢铁联合有限责任公司, 河北 唐山 063200)

**摘要:** 针对传统带钢凸度预测方法预测精度低、速度慢的问题,建立了基于随机森林和支持向量机的热轧带钢凸度加权预测模型。采用改进长鼻浣熊算法分别对随机森林、支持向量机和随机森林与支持向量机加权预测模型的参数进行优化,提高凸度预测精度。以某公司热轧 1 580 mm 生产线实测数据进行凸度预测仿真研究,随机森林与支持向量机加权预测模型的均方根误差为 2.23  $\mu\text{m}$ ,与随机森林模型、支持向量机模型预测精度进行比较,加权预测模型的精度分别提高了 7.08%、2.62%。

**关键词:** 凸度预测; 热轧带钢; 支持向量机; 长鼻浣熊算法; 凸度; 随机森林

中图分类号: TG335

文献标志码: A

doi:10.3969/j.issn.0253-6099.2024.06.031

文章编号: 0253-6099(2024)06-0144-07

## Weighted Prediction Model of Hot Rolled Strip Crown Based on Random Forest and Support Vector Machine

ZHOU Yaluo<sup>1</sup>, LI Zixuan<sup>1</sup>, ZHANG Shaochuan<sup>1</sup>, LIU Wenguang<sup>2</sup>, ZHANG Ruicheng<sup>1</sup>

(1. College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, Hebei, China; 2. Shougang Jingtang United Iron and Steel Co., Ltd., Tangshan 063200, Hebei, China)

**Abstract:** In view of low prediction accuracy and slow speed of traditional prediction methods for strip crown, a weighted prediction model based on random forest (RF) and support vector machine (SVM) was established. The parameters of models based on RF, SVM, and a combination of RF and SVM were optimized respectively by adopting the improved coati optimization algorithm (ICOA), so as to improve crown prediction accuracy. A 1 580 mm production line of a hot-rolling mill in one company was taken in a simulation research on crown prediction based on its actual measurement. The root mean square error of the weighted prediction model based on RF and SVM is 2.23  $\mu\text{m}$ . It is found that this weighted prediction model has its prediction accuracy increased by 7.08% and 2.62% respectively, compared with the models based on RF and SVM respectively.

**Key words:** crown prediction; hot rolling strip; support vector machine (SVM); coati optimization algorithm (COA); crown; random forest (RF)

钢铁行业是国民经济的基础性支柱产业<sup>[1]</sup>,热轧带钢生产在现代钢铁工业体系中占据重要地位。在轧制过程中,热轧带钢产品会出现凸度命中率低以及边降、卷曲、楔形、局部高点等板形不良问题,严重影响热轧带钢的成材率。有效控制热轧带钢产品凸度<sup>[2]</sup>可减少楔形等缺陷的出现,从而改善产品质量。

传统的凸度预测模型通常采用由物理原理和经验

公式构建的机理模型<sup>[3-4]</sup>,具有一定准确性和可解释性。但是,由于实际生产的复杂性和不确定性,机理模型的建立需要进行多种简化和假设,导致机理模型预测结果和生产实际存在偏差。机器学习<sup>[5-9]</sup>可以高效地处理复杂的数据和非线性关系,提高预测模型的准确性和实时性。轧钢过程是非线性、强耦合的复杂系统,本文利用随机森林(random forests, RF)与支持向

① 收稿日期: 2024-05-25

基金项目: 河北省自然科学基金资助项目(F2018209201);唐山市科技局科技计划资助项目(22130213G)

作者简介: 周亚罗(1982—),女,河北安平人,硕士,副教授,主要研究方向为复杂系统的建模与控制。E-mail:550589525@qq.com

量机(support vector machine,SVM)加权预测模型对末机架出口凸度进行预测,并采用改进长鼻浣熊算法(improvement coati optimization algorithm,ICOA)分别对RF的决策树数量和最大分裂节点个数、SVM的惩罚因子和核函数宽度以及加权预测模型的加权系数进行优化,进一步提高热轧带钢凸度预测模型的精度。

## 1 基础理论

### 1.1 凸度

凸度是指带钢中部标志点厚度 $h_c$ 与两侧标志点的平均厚度之差<sup>[10]</sup>,根据两侧标志点与边部的距离,凸度可用 $C_{20}$ 、 $C_{40}$ 、 $C_{100}$ 表示,实际应用中常用 $C_{40}$ 作为控制指标,凸度示意图见图1。




图1 带钢凸度计算示意图

凸度 $C_{40}$ 计算公式如下:

$$C_{40} = h_c - \frac{h_r + h_r}{2} \quad (1)$$

式中: $h_c$ 为带钢中部标志点的厚度; $h_r$ 和 $h_r$ 分别为带钢两侧标志点的厚度; $i$ 为标志点距带钢边部的距离, $i=40$  mm。

轧件形状、轧辊形状以及轧制条件等因素影响有载辊缝的形状,有载辊缝<sup>[11]</sup>又决定带钢凸度。因此,在分析带钢的断面形状凸度时,需要综合考虑轧件形状、轧辊形状、轧制条件等各方面的影响因素。轧件形状主要包括带钢厚度、中间坯凸度等,在轧制力作用下通过轧辊弹跳影响末机架出口凸度。轧辊形状包括工作辊有效凸度等,工作辊有效凸度影响工作辊之间辊缝的几何形状,从而直接影响带钢形变,通过控制工作辊有效凸度,可以减少不良板形、表面缺陷和尺寸偏差的问题。轧制条件主要包括轧制力、窜辊量、弯辊力、温度、速度等,当温度较高时,带钢易发生形变,有助于减少轧制力以及变形抗力从而减小带钢凸度;低温轧制时会增加带钢变形抗力,但会提高带钢的力学性能。

### 1.2 支持向量机(SVM)

SVM<sup>[12]</sup>是基于结构风险最小化、解决回归问题的常见机器学习算法,其原理是将样本从初始空间映射

到高维度的空间,通过超平面将样本分隔开。超平面计算公式如下:

$$f(x) = \omega^T \times \varphi(x) + b \quad (2)$$

式中: $f(x)$ 为预测值; $\omega^T$ 为超平面法向量; $\varphi(x)$ 为非线性映射; $b$ 为超平面平移量。

引入惩罚因子和松弛变量后软间隔SVM目标函数如公式(3)所示:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i) \quad (3)$$

式中: $C$ 为惩罚因子; $\xi_i$ 、 $\xi_i$ 均为松弛变量。

求解有约束的极小值问题引入拉格朗日乘子法求解后,最终求解公式如下:

$$\begin{aligned} \min_{a_i, \hat{a}_i} & \sum_{i=1}^m \sum_{j=1}^m [(a_i - \hat{a}_i)(a_j - \hat{a}_j)K(x_i, x_j)] - \\ & \sum_{i=1}^m \sum_{j=1}^m y_i(a_j - \hat{a}_j) \quad (4) \\ \text{s. t.} & \sum_{i=1}^m (a_i - \hat{a}_i) = 0, 0 \leq a_i, \hat{a}_i \leq C \end{aligned}$$

式中: $a_i$ 、 $\hat{a}_i$ 为拉格朗日乘子; $K(x_i, x_j)$ 为核函数。核函数将特征从低维转换到高维,同时将高维空间的内积运算转换为低维空间的核函数计算,即在低维下求解高维问题,加快了计算速度。为了获得更好的非线性映射,SVM核函数选用RBF核函数:

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}} \quad (5)$$

式中: $x_i$ 和 $x_j$ 为第 $i$ 个和第 $j$ 个样本数据; $\sigma$ 为径向基函数的宽度。

### 1.3 随机森林(RF)

RF算法由Breiman<sup>[13]</sup>在2001年提出,是集成学习中常见的预测模型。其核心思想为随机抽取样本建立不同特征组合的决策树,通过平均法从建立的决策树中输出最终预测结果。模型如图2所示。

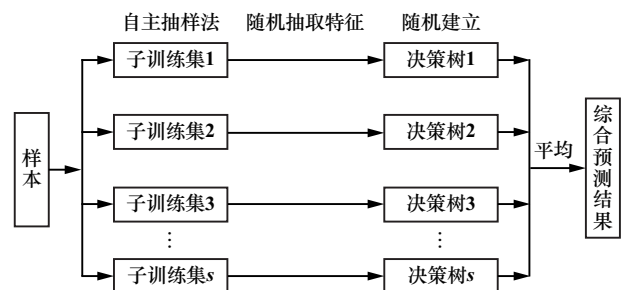


图2 随机森林预测过程示意图

RF预测过程如下:

步骤1:从预测模型训练集 $D$ 个样本中随机、有放

回地抽取  $M$  个样本组成子训练集,将子训练集用于每个决策树训练中。

步骤 2:在生成决策树过程中,利用随机选取的部分特征进行训练,并针对选取的不同特征的节点分裂  $n$  次,增强随机森林预测模型的泛化性。

步骤 3:重复步骤 1 和步骤 2,构建  $s$  个决策树。

步骤 4:输出各个决策树预测结果的平均值。

#### 1.4 长鼻浣熊算法 (COA)

根据自然界长鼻浣熊捕食和逃离捕食者的行为, Mohammad Dehghani<sup>[14]</sup> 等人在 2023 年提出了长鼻浣熊算法 (coati optimization algorithm, COA)。通过模拟长鼻浣熊的集体行为,使 COA 具有收敛速度快、稳定性好、全局寻优能力强的优点。

长鼻浣熊在猎食过程中分为攻击和捕猎鬣蜥行为,由一半浣熊上树靠近并驱赶鬣蜥,等鬣蜥落地之后,再由剩下的长鼻浣熊猎杀。由公式(6)模拟所有长鼻浣熊的位置:

$$x_{i,j} = b_{jl} + r \times (b_{ju} - b_{jl}) \quad (6)$$

式中: $x_{i,j}$  为长鼻浣熊的位置; $b_{ju}$  和  $b_{jl}$  为寻优参数的上限和下限; $r$  为  $[0,1]$  内的随机数; $i$  为长鼻浣熊的种群数量; $j$  为求解问题变量的维度。

由公式(7)模拟长鼻浣熊在树上的位置:

$$X_{i,j}^{P1} = x_{i,j} + r \times (x_{best} - I \times x_{i,j}) \quad (7)$$

式中: $X_{i,j}^{P1}$  为长鼻浣熊在树上的位置; $x_{best}$  为猎物鬣蜥的位置; $I$  为  $[1,2]$  内的随机整数。

当鬣蜥被驱赶下树时,落于搜索空间的随机位置,地面剩余的长鼻浣熊根据鬣蜥的位置进行移动。鬣蜥落地后的位置如公式(8)所示。

$$a_{jiguana} = b_{jl} + r \times (b_{ju} - b_{jl}) \quad (8)$$

$$X_{i,j}^{P2} = \begin{cases} x_{i,j} + r \times (a_{jiguana} - x_{i,j}) & F_{iguana} < F_i \\ x_{i,j} + r \times (x_{i,j} - a_{jiguana}) & F_{iguana} \geq F_i \end{cases} \quad (9)$$

式中: $a_{jiguana}$  为鬣蜥落地后的随机位置; $X_{i,j}^{P2}$  为等待鬣蜥落地的浣熊的位置; $F_{iguana}$  为鬣蜥位置对应的目标函数的值; $F_i$  为浣熊位置对对应目标函数的值。

在逃离捕食者过程中,每只浣熊根据当前位置随机生成新的位置:

$$b_{jl}^{local} = \frac{b_{jl}}{t}, \quad b_{ju}^{local} = \frac{b_{ju}}{t} \quad (10)$$

$$X_{i,j}^{P2} = x_{i,j} + (1 - 2r) \times [b_{jl}^{local} + r \times (b_{ju}^{local} - b_{jl}^{local})] \quad (11)$$

式中: $b_{jl}^{local}$  和  $b_{ju}^{local}$  为逃离捕食者过程的寻优参数的下限和上限; $t$  为迭代次数; $X_{i,j}^{P2}$  为等待浣熊逃离捕食者的

位置。

#### 1.5 改进长鼻浣熊算法 (ICOA)

针对长鼻浣熊算法在预测模型中容易陷入局部最优的问题,提出了黄金正弦、莱维飞行策略对长鼻浣熊算法进行改进,提高算法的寻优能力。

1) 黄金正弦算法<sup>[15]</sup> 根据正弦和单位圆的联系,引用黄金分割系数更新位置公式,提高搜索速度,使局部寻优和全局寻优达到平衡。引用黄金正弦算法的思想,将黄金分割系数与正、余弦引入长鼻浣熊算法内。

2) 为了避免长鼻浣熊算法在处理高维度数据易陷入局部最优的问题,引入莱维飞行<sup>[16]</sup> 机制,增强长鼻浣熊算法的全局寻优能力,并跳出局部最优值。

改进的长鼻浣熊算法更新公式为:

$$X_{i,j}^{P1'} = \begin{cases} x_{i,j} \times |\sin r_1| + \sin r_1 \times x_1 \times x_{best} - & r_2 \geq 0.5 \\ x_2 \times I \times x_{i,j} + S_{levy} & \\ x_{i,j} \times |\cos r_1| + \cos r_1 \times x_1 \times x_{best} - & r_2 < 0.5 \\ x_2 \times I \times x_{i,j} + S_{levy} & \end{cases} \quad (12)$$

式中: $X_{i,j}^{P1'}$  为改进后的长鼻浣熊位置; $x_1$  和  $x_2$  均为黄金分割系数,取值分别为  $-0.74, 0.74$ ;  $r_1$  为  $[0, 2\pi]$  内的随机数; $S_{levy}$  为莱维飞行公式更新的位置; $r_2$  为  $[0, 1]$  内的随机数。

## 2 预测模型的建立

### 2.1 数据预处理

在数据采集过程中,数据集包含噪声,可能出现较大测量误差,并且数据集的量纲不一样,为了预测模型的准确性,首先采用拉依达准则去除包含较大误差的样本<sup>[17]</sup>,然后采用归一化<sup>[18]</sup> 缩小数据之间相对大小并使数据具有参照性。拉依达准则如下:

$$|x_i - \bar{x}| > 3 \sqrt{\frac{\sum_{i=1}^m (x_i - \bar{x})^2}{m - 1}} \quad (13)$$

归一化公式如下:

$$x_i' = 2 \times \frac{x_i - x_{imin}}{x_{imax} - x_{imin}} - 1 \quad (14)$$

式中: $x_i$  为样本; $x_i'$  为归一化后的样本; $x_{imin}$  和  $x_{imax}$  分别为样本数据中最小值与最大值; $\bar{x}$  为样本平均值; $m$  为样本数量。

### 2.2 支持向量机预测模型的建立

支持向量机在进行多特征、小样本数据预测时,可能出现过拟合现象,超参数惩罚因子  $C$  和核函数宽度

$\sigma$  影响预测精度。针对以上问题,本文提出了改进长鼻浣熊算法优化支持向量机的惩罚因子  $C$  和核函数宽度  $\sigma$  的预测模型。ICOA 优化 SVM 参数流程如图 3 所示。

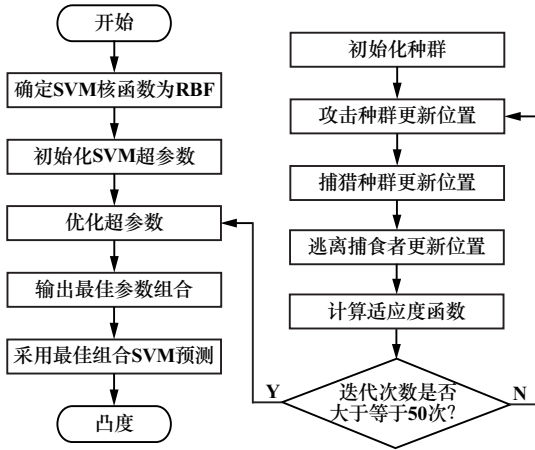


图 3 ICOA 优化 SVM 参数流程图

### 2.3 随机森林预测模型的建立

决策树的数量  $s$  和最大节点分裂次数  $n$  是随机森林凸度预测模型训练过程的关键因素。 $s$  影响模型的预测精度和计算复杂度, $s$  过大时,有助于提高模型预测精度,但计算时间会变长; $n$  能控制树的深度,有效避免过拟合的现象。本文利用 ICOA 对随机森林凸度预测模型的超参数  $s$ 、 $n$  寻优,将最优超参数组合代入随机森林预测模型中,提高模型的预测性能和鲁棒性。ICOA 优化 RF 参数流程如图 4 所示。

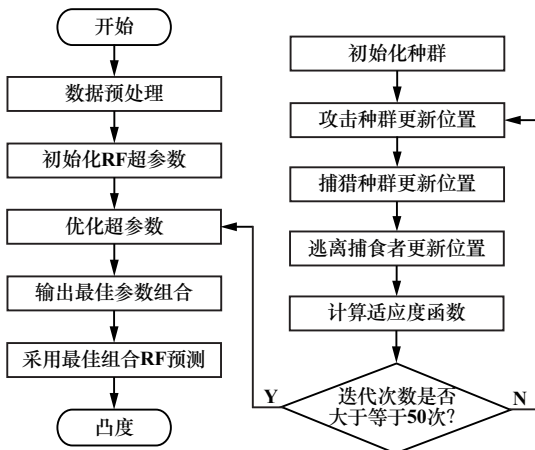


图 4 ICOA 优化 RF 参数流程图

### 2.4 随机森林与支持向量机加权预测模型的建立

为了提高末机架出口凸度预测的准确度,本文提出了支持向量机和随机森林加权的末机架出口凸度预测模型。支持向量机、随机森林分别对非线性数据、多特征数据处理能力强,两者结合可以有效减轻支持向

量机在多特征数据上可能出现的过拟合问题,从而提高预测模型的泛化能力。此外,支持向量机、随机森林模型采用不同的机理与策略,两者相结合可提高末机架出口凸度预测模型的鲁棒性。随机森林与支持向量机加权预测模型末机架出口凸度计算式如下:

$$Y = C_1 \times Y_{pre}^{ICOA-SVM} + C_2 \times Y_{pre}^{ICOA-RF} \quad (15)$$

式中: $Y$  为加权求和预测模型最终输出; $Y_{pre}^{ICOA-SVM}$  为 ICOA 优化 SVM 的输出; $Y_{pre}^{ICOA-RF}$  为 ICOA 优化 RF 的输出; $C_1$ 、 $C_2$  分别为 SVM、RF 模型的权重。

## 3 仿真分析

为了验证改进算法有效性和加权凸度预测模型精准性,本文在测试平台操作系统为 Windows 10 家庭版的环境下进行 10 次算法有效性实验和 5 次加权预测模型对比实验。

### 3.1 改进算法有效性分析

为了验证 ICOA 的性能,在 CEC2005 中选择 4 个基准测试函数进行测试, $f_1$ 、 $f_2$  和  $f_3$  为单峰函数,验证测试算法的寻优速度; $f_4$  为多峰函数,且全局最优解位于搜索空间的边界上,验证算法的全局寻优能力,测试函数如表 1 所示。

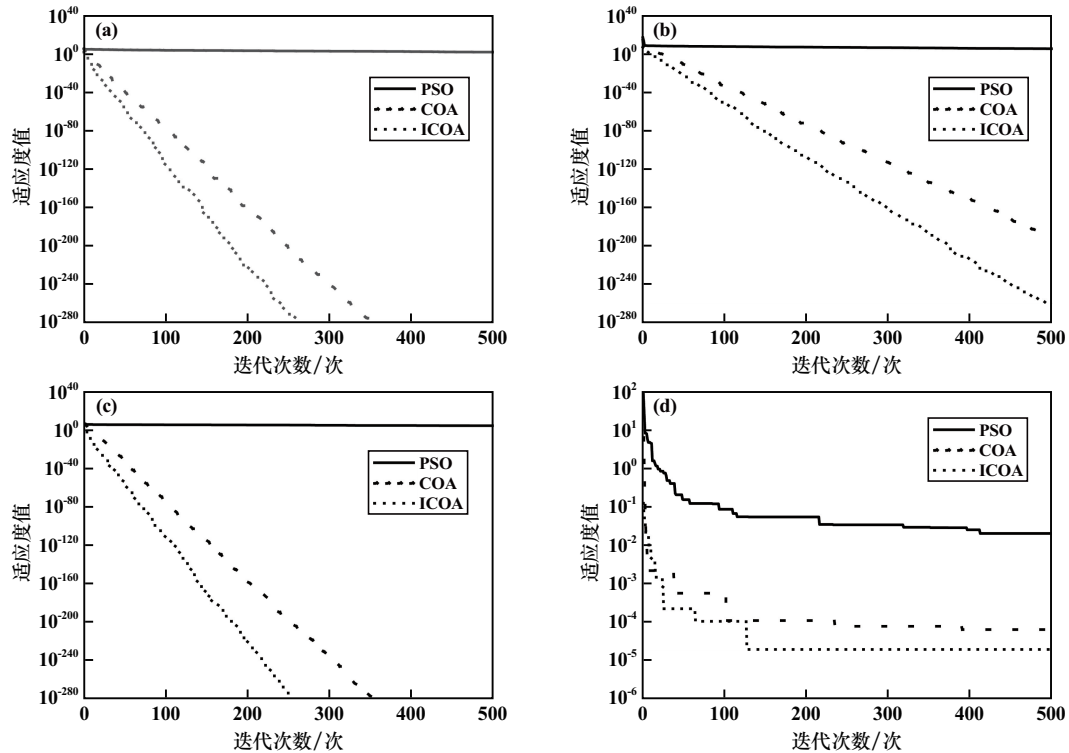
表 1 测试函数

测试函数	定义域	最小值
$f_1(x) = \sum_{i=1}^{30} x_i^2$	$[-100, 100]$	0
$f_2(x) = \sum_{i=1}^{30}  x_i  + \prod_{i=1}^{30}  x_i $	$[-10, 10]$	0
$f_3(x) = \sum_{i=1}^{30} \sum_{j=1}^i x_j$	$[-100, 100]$	0
$f_4(x) = \sum_{i=1}^{30} x_i^4 + \text{rand}$	$[-1.28, 1.28]$	0

本文选用粒子群优化算法 (PSO)、COA 以及 ICOA 对表 1 中的测试函数进行对比实验,为保证算法对比的有效性,设置种群为 60,最大迭代次数为 500,测试 10 次,迭代过程如图 5 所示,迭代结果如表 2 所示。

由图 5 可知,4 个测试函数中,粒子群算法的收敛速度慢、跳出局部最优的能力差。改进的长鼻浣熊算法收敛速度更快,收敛精度更高。

从表 2 可知,ICOA 在  $f_1$  和  $f_3$  函数中均能找到理论最小值,在函数  $f_2$  和  $f_4$  中并没有寻到理论最小值,但平均值低于 COA 算法和 PSO 算法的平均值。综上所述,相比 PSO 算法、COA 算法,ICOA 算法在基准函数中全局寻优能力更强,搜索速度更快。



(a)  $f_1$  收敛曲线; (b)  $f_2$  收敛曲线; (c)  $f_3$  收敛曲线; (d)  $f_4$  收敛曲线

图5 测试函数适应度值收敛曲线

表2 测试函数求解指标统计

函数	不同算法求解指标平均值		
	ICOA	COA	PSO
$f_1$	0	0	21.599 4
$f_2$	$6.765 7 \times 10^{-262}$	$3.656 9 \times 10^{-196}$	0.395 7
$f_3$	0	0	582.341 2
$f_4$	$2.912 2 \times 10^{-05}$	$5.666 8 \times 10^{-05}$	0.015 16

表3 预测模型输入参数与输出参数列表

序号	特征参数	单位
1~7	工作辊有效凸度( $F_1 \sim F_7$ )	mm
8~14	出口厚度( $F_1 \sim F_7$ )	mm
15~21	轧制力( $F_1 \sim F_7$ )	kN
22~28	弯辊力( $F_1 \sim F_7$ )	kN
29~35	窜辊量( $F_1 \sim F_7$ )	mm
36	宽度	mm
37	中间坯凸度	mm
38	中间坯厚度	mm
39	精轧入口温度	℃
40	精轧出口温度	℃
41	穿带速度	m/s
42	末机架出口凸度	mm

注: $F_1 \sim F_7$ 为机架编号,共7座机架。

### 3.2 热轧带钢凸度预测实验

以国内某钢铁企业热轧 1 580 mm 生产线精轧机组为背景,精轧机组由 7 台 CVC 轧机组成,每台轧机主要由工作辊、窜辊等组成,选取目标凸度为 40  $\mu\text{m}$  的钢种数据 1 053 组,根据拉依达准则将有异常点的 25 组数据删除,最终选取了 1 028 组数据,其中 728 组数据作为训练集,300 组数据作为测试集。工作辊有效凸度、各机架出口厚度、窜辊量和弯辊力等 41 种特征作为 RF、SVM、RF 与 SVM 加权预测模型的输入,适应度函数为均方误差。各输入、输出参数如表 3 所示。

#### 3.2.1 预测模型中参数寻优实验

为了验证改进长鼻浣熊算法在 RF、SVM、RF 与 SVM 加权预测模型中的收敛速度和精度,采用粒子群算法、麻雀算法(SSA)、改进长鼻浣熊算法分别对 RF 中的决策树数量、最大节点分裂次数,SVM 中的惩罚因子和核函数宽度,RF 与 SVM 加权预测模型的加权系数进行寻优对比。算法参数设置如表 4 所示。在

表4 预测模型寻优参数设置

模型名称	种群大小	最大迭代次数	上限	下限
RF 预测模型	30	50	500	10
SVM 预测模型	30	50	256	-256
RF 与 SVM 加权预测模型	30	50	1	-1

RF、SVM、RF 与 SVM 加权预测模型的优化过程中,不同预测模型的训练集适应度函数迭代曲线如图 6~8 所示。

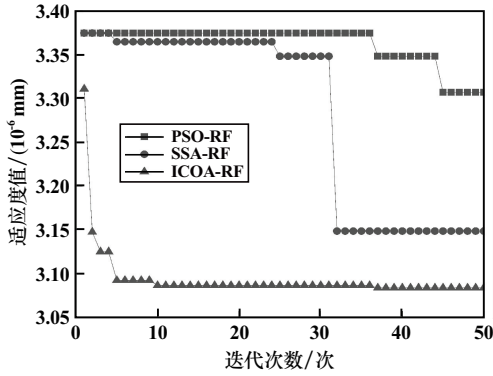


图 6 RF 预测模型收敛曲线

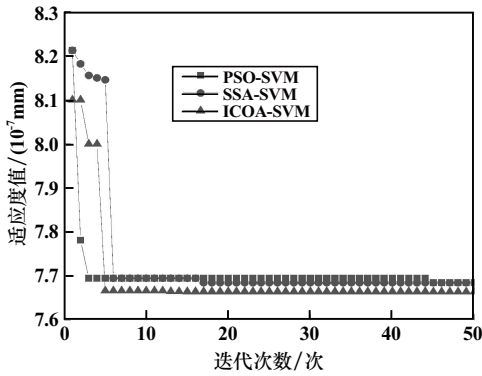


图 7 SVM 预测模型收敛曲线




图 8 RF 与 SVM 加权预测模型收敛曲线

由图 6 可知,在优化 RF 过程中,ICOA 在第 10 次迭代开始收敛,最终收敛值为  $3.08 \times 10^{-6}$ 。PSO 和 SSA 收敛精度和速度均不及 ICOA 算法。

由图 7 可知,在优化 SVM 过程中,ICOA 在第 5 次迭代开始收敛,最终收敛值为  $7.67 \times 10^{-7}$ ,收敛精度和速度都优于 PSO 和 SSA 算法。

由图 8 可知,在 RF 与 SVM 加权预测模型中,ICOA 算法收敛速度最快,精度最高,在第 36 次迭代开始收敛,最终收敛值为  $7.02 \times 10^{-7}$ 。RF、SVM、RF 与 SVM 加权预测模型中,RF 与 SVM 加权预测模型的适应度值最低,说明 RF 与 SVM 加权预测模型更有利于

热轧带钢凸度的预测。

改进的长鼻浣熊算法优化后 RF 预测模型的决策树数量  $s = 127$ ,最大节点分裂次数  $n = 319$ ,对 SVM 预测模型寻优后的惩罚因子  $C = 40.386 4$ ,核函数宽度  $\sigma = 1.320 3$ ,支持向量机和随机森林加权预测模型寻得加权参数  $C_1 = 0.888 6, C_2 = 0.113 1$ 。

### 3.2.2 凸度预测模型对比实验

为了对比 ICOA-RF 与 SVM 加权预测模型的预测效果,将 ICOA-RF、ICOA-SVM 预测模型用于凸度预测中,对以上模型进行 5 次实验,并以均方误差(MSE)、平均绝对百分比误差(MAPE)2 种性能指标进行评价。

$$MSE = \frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2 \quad (16)$$

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (17)$$

式中: $\hat{y}_i$  为真实值; $y_i$  为预测值; $m$  为样本个数。均方误差表示预测值和真实值之间差异平方的均值,平均绝对百分比误差代表预测值相对于真实值的平均相对误差。最终取各指标平均值作为评价指标。预测结果对比和预测误差对比分别如图 9 和图 10 所示。




图 9 预测结果对比

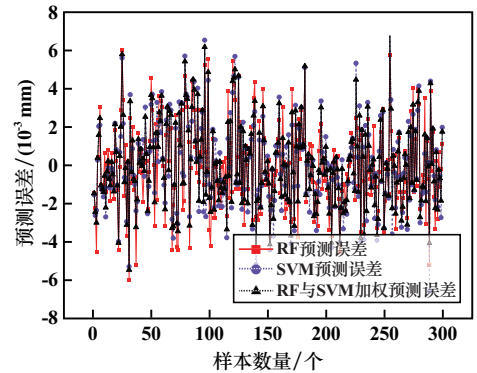


图 10 预测误差对比

由图 9 可知,RF 与 SVM 加权预测模型的精度最高,预测结果和真实值更接近。由图 10 可以得出,

ICOA优化的RF与SVM加权预测模型的预测误差全部在 $6\ \mu\text{m}$ 以内,而ICOA-SVM预测模型和ICOA-RF预测模型分别有1个和2个样本预测结果在 $6\ \mu\text{m}$ 以外,表明ICOA优化的RF与SVM加权预测模型预测误差小,且精度更高。

各预测模型误差指标计算结果见表5。从表5可以得出,基于改进长鼻浣熊算法优化的RF和SVM加权预测模型均方根误差和平均绝对百分比误差分别为 $2.23\ \mu\text{m}$ 和 $4.43\%$ ,RF预测模型的均方根误差为 $2.40\ \mu\text{m}$ ,SVM预测模型的均方根误差为 $2.29\ \mu\text{m}$ 。与随机森林模型、支持向量机模型预测精度进行比较,加权预测模型的精度分别提高了 $7.08\%$ 、 $2.62\%$ 。

表5 误差指标计算结果

预测模型	误差指标	
	MSE/ $\text{mm}^2$	MAPE/%
RF	$5.76 \times 10^{-6}$	4.83
SVM	$5.24 \times 10^{-6}$	4.53
RF-SVM	$4.98 \times 10^{-6}$	4.43

为了验证RF与SVM加权预测模型的稳定性,选取预测值和真实值绝对误差在 $\pm 5\ \mu\text{m}$ 范围内的样本与全体样本的比率进行比较,结果如表6所示。

表6 不同误差凸度命中率

预测模型	命中率( $\pm 5\ \mu\text{m}$ )/%
RF	96.3
SVM	96.7
RF-SVM	97.3

RF与SVM加权预测模型预测误差在 $\pm 5\ \mu\text{m}$ 以内的凸度命中率为 $97.3\%$ ,分别大于RF、SVM的 $96.3\%$ 和 $96.7\%$ ,表明RF与SVM加权预测模型对于大部分样本,预测误差都能保持在较小的误差内,并且在凸度预测过程中稳定性和可靠性较高,有助于提升板形质量。

## 4 结语

1) 利用黄金正弦和莱维飞行策略对长鼻浣熊算法进行改进,平衡了算法的全局寻优和局部搜索能力,增强了算法跳出局部最优的能力。

2) 采用改进长鼻浣熊算法对随机森林、支持向量机模型的超参数和加权系数进行优化,可加快寻优速度、提高收敛精度。

3) 随机森林与支持向量机加权预测模型有助于减少边降、卷曲、楔形、局部高点等板形不良问题,对热轧带钢生产具有现实意义。

## 参考文献:

- [1] 王贵成,贺振,高俊丽. 基于灰色系统理论的我国钢铁产业与GDP关系研究[J]. 矿冶工程, 2019,39(2):128-132.
- [2] 田宝亮,牛培峰. 基于GA-BP神经网络的弯辊力预设定模型研究与应用[J]. 矿冶工程, 2018,38(1):111-114.
- [3] 周莲莲,白振华,李亮亮,等. UCM冷连轧机组基于机理模型的板形与板凸度在线综合控制技术[J]. 轧钢, 2009,26(6):29-32.
- [4] 陈胜利,何安瑞,徐致让,等. 一个轧制单元内实时辊系综合凸度预测及应用[J]. 机械工程学报, 2017,53(2):61-66.
- [5] 汪龙军,丁成砚,范宇超,等. 基于深度森林的热轧带钢凸度预测模型[J]. 轧钢, 2023,40(1):90-96.
- [6] 曹建国,江军,赵秋芳,等. 基于数据挖掘的宽厚板板凸度控制[J]. 中南大学学报, 2019,50(11):2743-2752.
- [7] 王优龙,李维刚,王永强. 基于集成特征选择和SVR的热连轧板凸度预测[J]. 钢铁, 2024,59(1):99-107.
- [8] 刘元铭,王振华,王涛,等. 热轧带钢出口凸度数据驱动建模及智能化预测分析[J]. 中国机械工程, 2020,31(22):2728-2733.
- [9] 郝学斌. 深度信念网络算法下的热轧板凸度预测模型[J]. 材料与冶金学报, 2022,21(5):364-370.
- [10] 姬亚锋,宋乐宝,孙杰,等. 基于SVM和PCA-CS算法的热轧带钢板凸度预测[J]. 中南大学学报, 2021,28(8):2333-2344.
- [11] 马志强,魏立新,孙浩,等. 考虑辊缝摩擦及张力影响的冷轧机非线性振动特性研究[J]. 矿冶工程, 2019,39(2):102-107.
- [12] 王鑫瑞,曹鹏飞,肖一清,等. 基于WOA-SVM模型的爆破振动预测研究[J]. 矿冶工程, 2023,43(4):48-51.
- [13] BREIMAN L. Random forests[J]. Machine Learning, 2001,45(1):5-32.
- [14] DEGHANI M, MONTAZER Z, TROJOVSKA E, et al. Coati optimization algorithm: a new bio-inspired metaheuristic algorithm for solving optimization problems[J]. Knowledge-Based Systems, 2023, 259:110011.
- [15] TANYILDIZI E, DEMIR G. Golden sine algorithm: a novel math-inspired algorithm[J]. Advances in Electrical and Computer Engineering, 2017,17(2):71-79.
- [16] 周亚罗,张少川,刘文广,等. 基于IHPO-KELM的冷轧带钢板形模式识别[J]. 矿冶工程, 2023,43(6):162-168.
- [17] 张秀玲,代景欢,康学楠,等. 基于多RBF神经网络的板形数据建模[J]. 矿冶工程, 2019,39(6):124-128.
- [18] 阳俊,曾维伟. 基于GA-BP神经网络的采空区地表沉降预测模型[J]. 矿冶工程, 2022,42(2):42-45.

引用本文: 周亚罗,李子轩,张少川,等. 基于随机森林与支持向量机的热轧带钢凸度加权预测模型研究[J]. 矿冶工程, 2024,44(6):144-150.