

基于混合核支持向量机的带钢凸度预测

刘文广¹, 李子轩², 谢天伟³, 周亚罗², 张瑞成²

(1. 首钢京唐钢铁联合有限责任公司, 河北 唐山 063200; 2. 华北理工大学 电气工程学院, 河北 唐山 063210;
3. 北京首钢股份有限公司, 北京 064404)

摘要: 为了解决热轧带钢凸度预测精度低、泛化能力差的问题, 提出了高斯核和多项式核混合的支持向量机 (SVM) 预测模型。针对混合核支持向量机参数难以确定的问题, 提出了使用佳点集、不完全伽玛函数自适应权重和可选择反向学习策略改进的河马算法 (IHO) 对混合核参数进行寻优。仿真实验结果表明, 改进的河马算法的寻优速度快、收敛精度高。在凸度预测实验中, 与随机森林、核极限学习机、单一高斯核支持向量机、多项式核支持向量机预测模型相比, 混合核支持向量机预测模型的精度分别提高了 18.49%、15.75%、28.76% 和 10.27%, 对于实现轧制参数精准优化、有效改善板形边浪、楔形等缺陷具有重要意义。

关键词: 混合核支持向量机; 带钢凸度; 河马算法; 热轧; 预测精度

DOI: 10.13330/j.issn.1000-3940.2025.07.017

中图分类号: TP335.5

文献标志码: A

文章编号: 1000-3940 (2025) 07-0132-11

Strip convexity prediction based on hybrid kernel support vector machine

Liu Wenguang¹, Li Zixuan², Xie Tianwei³, Zhou Yaluo², Zhang Ruicheng²

(1. Shougang Jingtang Iron and Steel United Co., Ltd., Tangshan 063200, China; 2. College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China; 3. Beijing Shougang Co., Ltd., Beijing 064404, China)

Abstract: In order to solve the problems of low prediction accuracy and poor generalization ability of hot-rolled strip convexity, a support vector machine (SVM) prediction model with a mixture of Gaussian kernel and polynomial kernel was proposed. For the problem that the parameters of the hybrid kernel support vector machine were difficult to determine, an improved hippopotamus optimization algorithm (IHO) was proposed to optimize the hybrid kernel parameters by using good point sets, incomplete gamma function adaptive weights and optional reverse learning strategy. Simulation experiment results show that the IHO algorithm has a fast optimization speed and high convergence accuracy. In the convexity prediction experiment, compared with the random forest, kernel extreme learning machine, single Gaussian kernel support vector machine and polynomial kernel support vector machine prediction models, the accuracy of the hybrid kernel support vector machine prediction model is improved by 18.49%, 15.75%, 28.76% and 10.27%, respectively, which is of great significance for achieving the accurate optimization of rolling parameters and effectively improving the defects such as plate edge waves and wedges.

Key words: hybrid kernel support vector machine; strip convexity; hippopotamus algorithm; hot rolling; prediction accuracy

随着生活水平的提高, 市场对带钢板形的要求越来越严格。凸度和平直度是板形的两个重要指标^[1], 通过严格控制各机架的凸度, 可以减少边浪、中间浪等平直度缺陷, 提升带钢的质量与市场竞争力。

机器学习^[2]由于具有快速性和灵活性的特点而被广泛应用于凸度预测中, 主要有随机森林、极限

学习机、深度置信网络、深度神经网络和支持向量机等方法。汪龙军等^[3]提出了深度森林的热轧带钢凸度预测模型, 通过网格搜索的方法对模型的参数进行寻优, 预测结果的均方根误差为 2.56 μm 。曹建国等^[4]基于历史生产数据建立了宽厚板板凸度随机森林预测模型, 预测结果的均方根误差为 4.6 μm 。马红等^[5]对板凸度的影响因素进行分析, 采用极限学习机的方法建立了凸度预测模型, 凸度预测值的绝对误差小于 5 μm 。郝学斌^[6]提出了深度学习的板凸度预测方法, 设计了深度信念网络下的预测模型和建模流程, 预测结果的均方根误差为 3.07 μm , 预测值与真实值的绝对误差小于 5 μm 的比例达到了 93.1%。陈楠等^[7]提出将机理与深度神经网络 (Deep Neural Network, DNN) 相结合的热

收稿日期: 2024-07-28; 修订日期: 2024-11-10

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: 刘文广 (1978-), 男, 硕士, 高级工程师

E-mail: 464710757@qq.com

通信作者: 李子轩 (2000-), 男, 硕士研究生

E-mail: 2941512970@qq.com

轧凸度组合预测模型,其中,97%以上的预测数据的绝对误差小于 $20\text{ }\mu\text{m}$,82%以上的预测数据的绝对误差小于 $10\text{ }\mu\text{m}$ 。但随机森林、极限学习机、深度置信网络、深度神经网络预测模型的训练速度慢,计算复杂度高。王优龙等^[8]提出了集成特征选择和支持向量机回归的凸度预测模型,采用随机森林、极端梯度提升、梯度提升决策树等模型对特征重要性加权融合,减弱了人为选择参数的盲目性和随机性,并采用灰狼优化算法来优化支持向量机回归预测模型中的参数,实验结果表明,预测结果的绝对误差在 $15\text{ }\mu\text{m}$ 以内的比例超过 99%。刘元铭等^[9]提出了基于现场工业数据和智能算法的热轧带钢出口凸度预测模型,采用差分进化算法对支持向量机模型的惩罚因子和核函数宽度进行优化,平均绝对百分比误差、均方根误差分别为 4.56%、 $3.28\text{ }\mu\text{m}$,并且有 92.26%的凸度预测值的绝对误差在 $5\text{ }\mu\text{m}$ 以内,精准预测为热轧控制提供了技术支持。姬亚锋等^[10]建立了核偏最小二乘法结合粒子群算法优化的支持向量机的板凸度预测模型,仿真结果表明,有 96.86%的凸度预测值的绝对误差小于 $5.5\text{ }\mu\text{m}$ 。支持向量机具有训练时间短、收敛速度快的优点,而且在较小的数据样本预测中也能取得良好的性能,但是在使用支持向量机进行预测时,单一的核函数在寻求预测精度时难以平衡学习能力和泛化能力。另外,在对支持向量机参数寻优过程中,将灰狼算法、差分进化算法、粒子群算法等用于预测模型参数寻优过程中可能会陷入局部最优解,难以跳出局部最优解而找到全局最优解,影响算法的收敛性。针对算法易陷入局部最优的问题,郭云川等^[11]提出了凸型自适应控制因子、折射方向学习和定向重组与诱导突变策略改进秃鹰搜索算法,经基准函数测试,改进的秃鹰搜索算法的收敛速度快、求解精度高。于军琪等^[12]引入混沌序列机制初始化麻雀算法种群,将粒子群速度概念引入发现者位置更新公式,结合狼群算法猛狼跟随策略优化跟随者位置,经过半导体工厂实际案例测试,应用改进的麻雀算法最高可节能 23.97%。

本文针对单核支持向量机在寻求预测精度时难以平衡学习能力和泛化能力,无法充分发挥单一核函数功能、群智能算法,易陷入局部最优的问题,提出了混合核支持向量机预测模型对热轧带钢末机架出口凸度进行预测,并采用改进的河马算法对多项式核的幂数、高斯核核函数宽度、两种核的权重以及支持向量机的惩罚因子进行优化。

1 理论与方法

1.1 凸度

凸度^[13]为板材横截面的厚度分布情况,也表示带钢的凸起或者凹陷程度,常用 C_{40} 表示。凸度 C_{40} 经常作为热轧商品卷和冷轧原材料的控制指标,一般要求 C_{40} 在 $20\sim 70\text{ }\mu\text{m}$ 之间。凸度 C_{40} 的计算方法如式 (1) 所示,示意图如图 1 所示。

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

式中: h_c 为带钢中心点的厚度; h_l 和 h_r 分别为带钢左右两侧标志点分别离边部 40 mm 处的厚度。




图1 凸度计算示意图

Fig. 1 Schematic diagram of convexity calculation

1.2 支持向量机

支持向量机 (Support Vector Machine, SVM)^[14] 是基于结构风险最小化用于解决回归问题的常见机器学习算法,其基本思想为将线性不可分的原始数据经过核函数映射到高维空间使其变为线性可分,然后在高维空间中找到最优超平面进行回归预测。超平面由支持向量组成,支持向量是指距离超平面最近的数据点,这些数据点被用于确定超平面的位置和方向。超平面 $f(x)$ 的表达式^[15] 如式 (2) 所示:

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

式中: ω^T 为超平面法向量; $\phi(x)$ 为原始数据到高维特征空间的非线性映射; b 为超平面平移量。

传统的预测模型将输出和真实值的差值计算为损失,但硬间隔 SVM 在回归问题中引入不敏感损失函数 ε ,允许预测值与真实值之间最多有 ε 的误差,即当预测值位于真实值与 2ε 范围的区间内时,则认为预测正确。硬间隔 SVM 要求所有预测误差均在 2ε 内,硬间隔 SVM 最优超平面的目标函数^[16] 如式 (3) 所示。

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 \quad (3)$$

为了提高 SVM 的鲁棒性,降低噪声点、异常数据对 SVM 预测性能的影响,提出了软间隔 SVM,软间隔 SVM 允许少部分样本位于 2ε 之外,并且要求在边界之外的预测误差要尽量小。设 (x_{ij}, y_i) 为数据集中的训练集样本,其中, x_{ij} 为第 i 个样本中的第 j 个特征, y_i 为训练集中第 i 个样本的输出。引入惩罚因子 C 和松弛变量 ξ_i 、 $\dot{\xi}_i$ 后,目标函数如式 (4) ~ 式 (5) 所示。

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \dot{\xi}_i) \quad (4)$$

$$\begin{cases} f(x_{ij}) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_{ij}) \geq \varepsilon + \dot{\xi}_i \\ \xi_i \geq 0, \dot{\xi}_i \geq 0 \end{cases} \quad (5)$$

式中: n 为样本数量。

惩罚因子可以控制松弛变量对 SVM 回归模型的影响程度, C 越大,对误预测的惩罚越大, C 越小,对误预测的惩罚越小。松弛变量用于处理在边界外部分线性不可分的点或者噪声点,引入松弛变量后, SVM 回归模型在一定范围内容忍训练数据的预测误差,可以灵活调节模型的复杂度,有助于防止过拟合和提高模型的泛化能力。

1.3 混合核支持向量机

核函数通常分为全局核函数和局部核函数。常见的全局核函数有多项式核、线性核、感知机核等,其中,多项式核计算简单、高效,在处理大规模数据时具有一定的优势。局部核函数主要包括高斯核、拉普拉斯核、指数核等,拉普拉斯核、指数核是高斯核在某种参数下的特殊情况。高斯核可以将数据映射到一个无限维的特征空间,从而使 SVM 对非线性决策边界进行建模时边界更平滑,在处理噪声较多的数据时表现较好,具有较强的泛化能力。因此,本文选取常见的全局核函数多项式核和局部核函数高斯核两种类型的核函数进行加权,有效平衡 SVM 的泛化能力与学习能力。

1.3.1 多项式核

多项式核函数的表达式为:

$$K^{\text{poly}}(\mathbf{x}, \mathbf{x}') = [(\mathbf{x}, \mathbf{x}') + 1]^d \quad (6)$$

式中: $K^{\text{poly}}(\mathbf{x}, \mathbf{x}')$ 为多项式核函数; \mathbf{x} 、 \mathbf{x}' 分别为样本和样本的转置; d 为多项式核函数的幂数,选取 $d=2, 3, 4, 5$ 。

如图 2 可知,随着幂数 d 的增大,多项式核的学习能力增强。但是当幂数过大时,会导致模型的计算时间变长,模型的复杂度变高,使模型出现过拟合的现象。因此,幂数选取范围一般为 $1 \sim 5$ 。




图 2 多项式核映射曲线

Fig. 2 Mapping curves of polynomial kernel

1.3.2 高斯核

高斯核函数的表达式为:

$$K^{\text{rbf}}(\mathbf{x}, \mathbf{x}') = e^{-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\sigma^2}} \quad (7)$$

式中: $K^{\text{rbf}}(\mathbf{x}, \mathbf{x}')$ 为高斯核函数; σ 为高斯核函数的宽度,影响着高斯核作用范围的宽度,选取 $\sigma=0.1, 0.2, 0.3$ 和 0.4 。

如图 3 所示,随着 σ 的增大,高斯核的作用范围逐渐变宽,导致更多的远离决策边界的样本点被视为对 SVM 的贡献,从而使得决策边界变得更加平滑,但是会导致预测模型出现过拟合现象。




图 3 高斯核映射曲线

Fig. 3 Mapping curves of Gaussian kernel

1.3.3 混合核

选取高斯核和多项式核加权为新核,通过加权的方式平衡高斯核和多项式核的学习能力与泛化能力。选取 $d=2$, $\sigma=0.1$, 加权系数为 0.2 。混合核

核函数如式 (8) 所示, 映射曲线如图 4 所示。

$$K^{\text{mkernel}}(\mathbf{x}, \mathbf{x}') = \mu \times K^{\text{poly}}(\mathbf{x}, \mathbf{x}') + (1 - \mu) \times K^{\text{rbf}}(\mathbf{x}, \mathbf{x}') \quad (8)$$

式中: $K^{\text{mkernel}}(\mathbf{x}, \mathbf{x}')$ 为混合核 SVM 的核函数; μ 为多项式核权重。




图4 混合核映射曲线

Fig. 4 Mapping curve of hybrid kernel

综上所述, 惩罚因子 C 用来控制预测误差的权重, 惩罚因子 C 越大, SVM 预测超平面越严格, 容易过拟合; 相反, C 越小, 容易欠拟合。正确选择多项式核函数幂数 d 、高斯核核函数宽度 σ 和两种核的权重可以提高 SVM 模型的预测精度, 避免出现拟合或者欠拟合的现象。因此, 选取改进的河马算法对混合核 SVM 预测模型的参数进行寻优。

1.4 河马算法

Amiri M H 等^[17]提出了河马优化算法, 经过基准测试函数验证得出, 河马算法能有效平衡局部开发和全局开发的能力, 并且具有寻优速度快、精度高的优点。因此, 选取河马算法用于混合核支持向量机预测模型寻优, 能够有效避免随机选取混合核支持向量机预测模型超参数的盲目性。

河马种群聚集在主导河马周围, 主导河马来保护种群免受外来侵略。其他的雄性河马在雌性河马周围, 当雄性河马成年后, 会被驱逐出种群吸引雌性河马, 建立起自己的优势地位。河马种群和雄性河马种群位置的更新公式分别如式 (9) 和式 (10) 所示。

$$X_{e,f} = lb_f + rand \times (ub_f - lb_f) \quad (9)$$

$$X_{e,f}^{\text{mhippo}} = X_{e,f} + rand \times (Dhippo - I_1 \times X_{e,f}) \quad (10)$$

式中: $rand$ 为在 $[0, 1)$ 范围内的随机数字; $X_{e,f}$ 为河马种群的位置; ub_f 和 lb_f 为上、下限; $X_{e,f}^{\text{mhippo}}$ 为雄性河马位置; $Dhippo$ 为占主导地位河马的位置; I_1 为 $[1, 2]$ 之间的随机数; e 为河马种群的数量;

f 为变量的维度。

大部分幼小河马都会在雌性河马身边, 但是随着长大和好奇心的驱使, 一部分幼小河马会离开雌性河马。离开雌性河马的幼小河马一部分继续在河马种群周围徘徊, 另一部分直接与种群分离, 成为捕食者的目标。雌性河马和幼小河马的位置更新如式 (11) ~ 式 (14) 所示。

$$X_{e,f}^{\text{FB}} = \begin{cases} X_{e,f} + A \times (Dhippo - I_2 \times M_{xi}) & T > 0.6 \\ X_{e,f}^{\text{FB1}} & T \leq 0.6 \end{cases} \quad (11)$$

$$X_{e,f}^{\text{FB1}} = \begin{cases} X_{e,f} + B \times (M_{xi} - Dhippo) & r_6 > 0.5 \\ lb_f + rand \times (ub_f - lb_f) & r_6 \leq 0.5 \end{cases} \quad (12)$$

$$h = \begin{cases} I_2 \times r_1 + (\sim q_1) \\ 2 \times r_2 - 1 \\ r_3 \\ I_1 \times r_4 + (\sim q_2) \\ r_5 \end{cases} \quad (13)$$

$$T = \exp\left(-\frac{t}{T_1}\right) \quad (14)$$

式中: $X_{e,f}^{\text{FB}}$ 和 $X_{e,f}^{\text{FB1}}$ 分别为雌性河马和幼小河马的位置; M_{xi} 为随机选取的河马种群的平均值; A 、 B 分别为从 h 的 5 个场景中随机选取的数字或向量; I_2 为 $[1, 2]$ 之间的随机数; $r_1 \sim r_4$ 为 $0 \sim 1$ 的随机向量; r_5 和 r_6 为 $[0, 1]$ 的随机数; q_1 和 q_2 分别为 $[0, 1]$ 的随机整数; T 为迭代程度; t 为当前迭代次数; T_1 为最大迭代次数。

在防御阶段, 河马迅速转向捕食者并发出叫声, 也可能会接近捕食者诱导其撤退来抵御攻击。当捕食者离河马种群非常近时, 河马转向捕食者并进行移动; 当距离较远时, 河马也会转向捕食者, 示意捕食者已经闯入河马种群的领土。捕食者的位置如式 (15) 所示, 防御时河马位置如式 (16) 所示。

$$Predator_f = lb_f + r_8 \times (ub_f - lb_f) \quad (15)$$

$$X_{e,f}^{\text{HippoR}} = \begin{cases} R \times Predator_f + \frac{v}{[c - d \times \cos(L)] \times D} & F_t \geq F_{\text{HL}} \\ R \times Predator_f + \frac{v}{[c - d \times \cos(L)] \times (2D + r_9)} & F_t < F_{\text{HL}} \end{cases} \quad (16)$$

$$D = |Predator_f - X_{e,f}| \quad (17)$$

式中: $Predatir_f$ 为捕食者的位置; r_8 、 r_9 为 $[0, 1]$ 的随机向量; $X_{e,f}^{HippoR}$ 为防御时河马位置; R 为具有莱维分布的随机向量; v 为 $[2, 4]$ 的随机数; c 为 $[1, 1.5]$ 的随机数; L 为 $[-1, 1]$ 的随机数; D 表示河马到捕食者的距离; F_i 为最优适应度值; F_{HL} 为当前代数的适应度值。

当防御措施对捕食者不起作用时, 河马会跑向距离当前位置最近的安全区域来躲避捕食者的攻击。逃离捕食者阶段的河马位置更新如式 (18) 所示。

$$X_{e,f}^{p2} = lb_f^{local} + r_{10} \times lb_f^{local} + D \times (ub_f^{local} - lb_f^{local}) \quad (18)$$

$$lb_f^{local} = \frac{lb_f}{t}, \quad ub_f^{local} = \frac{ub_f}{t} \quad (19)$$

$$D = \begin{cases} 2 \times r_{11} - 1 \\ r_{12} \\ r_{13} \end{cases} \quad (20)$$

式中: $X_{e,f}^{p2}$ 为等待河马逃离的捕食者的位置; lb_f^{local}

和 ub_f^{local} 分别为逃离捕食者过程的下、上限; r_{10} 、 r_{13} 为 $[0, 1]$ 的随机数; r_{12} 为正态分布的随机数; r_{11} 为 $[0, 1]$ 的随机向量。

1.5 改进的河马算法

1.5.1 佳点集种群初始化

在原始河马算法中, 河马种群采用随机初始化的方式, 存在种群个体分布不均匀的现象, 从而增加了算法陷入局部最优解的风险。此外, 不同的初始化方法会影响算法的收敛速度, 随机初始化可能会降低算法寻优的速度, 增加了解决问题的时间成本。为提高河马算法初始种群的质量, 提出了佳点集理论^[18]用于种群初始化。使用佳点集后的河马位置更新如式 (21) 所示, 使用佳点集法的初始化种群如图 5 所示, 其中, X 、 Y 分别为 2 个维度。

$$X'_{e,f} = lb_f + (ub_f - lb_f) \times \{d_{e,f} \times e\} \quad (21)$$

式中: $X'_{e,f}$ 为使用佳点集的河马种群初始化位置; $d_{e,f}$ 为分圆域法在第 e 个佳点、 f 维分量的值。

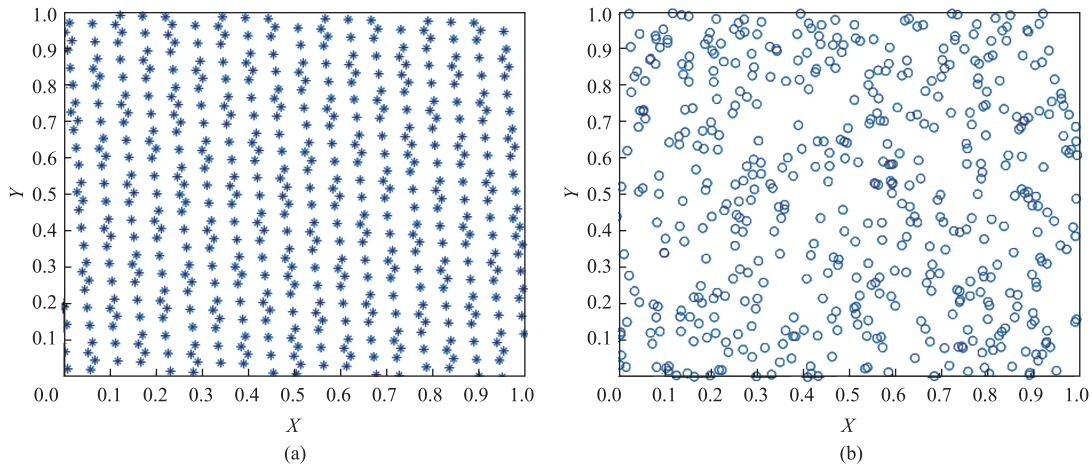


图 5 佳点集 (a) 与随机初始化种群 (b)

Fig. 5 Optimal point set (a) and randomly initialized population (b)

1.5.2 不完全伽玛函数自适应权重

自适应权重对平衡河马算法中的局部搜索能力和全局寻优能力有指导作用^[19]。当权重较大时, 算法的全局寻优能力较强; 当权重较小时, 算法的局部搜索能力强。为了更好地平衡算法的寻优能力, 选择不完全伽玛函数^[20]作为河马算法的自适应权重, 在算法前、中期进行局部搜索, 后期扩大全局搜索范围, 有效避免算法后期陷入局部最优。不完全伽玛函数还具有计算快捷的优点, 降低了算法寻优的时间。不完全伽玛函数如式 (22) 所示, 权重系数变化曲线如图 6 所示。

$$\text{gamma} = \Gamma(\lambda, 1 - t/T_1) \quad (22)$$

式中: $\Gamma(\lambda, 1 - t/T_1)$ 为不完全伽玛函数; λ 为 $[0, 1]$ 的随机变量。

1.5.3 可选择反向学习策略

为提高河马算法跳出局部最优的能力, 提出了可选择的透镜成像反向学习策略。当反向学习策略生成种群的适应度值优于全局最优解时, 将反向学习策略用于雄性河马位置更新公式中; 当反向学习策略生成的适应度值为劣质解时, 继续保持原来的位置更新公式。透镜成像反向学习策略^[21]根据平面镜成像原理得出, 其原理如图 7 所示。

在二维坐标 xoy 中, Q 在 x 轴上的投影为 X' , 在平面镜另一侧的图像为 Q^* 。通过位置变换得出




图6 权重系数变化图

Fig. 6 Variation diagram of weight coefficient




图7 平面镜成像原理图

Fig. 7 Principle diagram of plane mirror imaging

透镜成像的 Q^* 位置如式 (23) 所示。

$$Q^* = lb_f + ub_f - Dhippo \quad (23)$$

综上所述,改进河马算法的雄性河马位置的更新公式如式 (24) 所示。

$$X_{e,f}^{nhippo} = \begin{cases} \gamma \times X_{e,f} + rand \times [(Dhippo + Q^*)/2 - I_1 \times X_{e,f}], & F_t \leq F_b^t \\ X_{e,f} + rand \times (Dhippo - I_1 \times X_{e,f}), & F_t > F_b^t \end{cases} \quad (24)$$

式中: F_b^t 为 t 代及以前代数的最优适应度值。

2 预测模型的建立

2.1 数据预处理

在数据采集阶段,由于现场声音嘈杂、机器震动等问题,数据可能混入噪声或者存在测量误差较大的情况。为了提高预测模型的准确性,可以采取一些数据预处理的方法。首先,可以使用拉依达准则^[22]去除包含较大误差的样本。拉依达准则是一种常用的异常值检测方法,其可以通过计算数据点与平均值之间的偏差来判断是否为异常值。其次,为

了解决数据集中的量纲不一致的问题,可以采用归一化的方法。归一化可以使得不同特征之间的数值具有可比性,避免某些特征对模型的影响过大。拉依达准则如式 (25) 所示,归一化公式如式 (26) 所示。

$$|x_i - \bar{x}| > 3 \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (25)$$

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (26)$$

式中: x_i 为第 i 个样本数据; \bar{x} 为样本均值; x'_i 为归一化之后的样本数据; x_{\min} 和 x_{\max} 分别为样本数据中最小值与最大值; n 为样本数量。

2.2 混合核支持向量机预测模型的建立

传统单一核支持向量机在进行多特征、小样本数据预测时,存在过拟合、泛化能力差的问题,支持向量机的超参数惩罚因子 C 、高斯核核函数宽度 σ 、多项式核的幂数 d 、两种核的权重影响着预测精度,人为随机选取具有盲目性和随机性。针对以上问题,提出了改进河马算法优化多项式核和高斯核混合核的支持向量机超参数的预测模型。改进的河马算法优化支持向量机参数流程如图 8 所示,具体步骤如下。

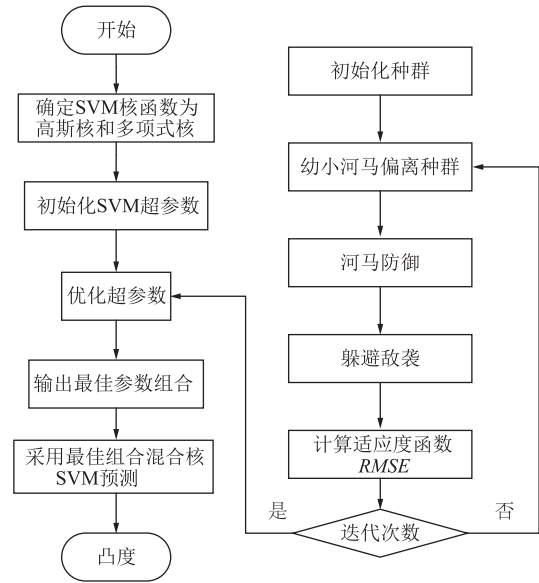


图8 改进河马算法优化混合核支持向量机的流程图

Fig. 8 Flow chart of optimization for hybrid kernel support vector machine by improved hippopotamus algorithm

(1) 步骤 1: 设置种群数量和最大迭代次数分别为 M 和 T_1 , 并初始化种群。

(2) 步骤 2: 河马的位置作为支持向量机的超参数, 根据适应度函数计算混合支持向量机的预测偏差, 将预测模型的均方根误差 $RMSE$ 作为河马算

法的适应度函数, 如式 (27) 所示。

(3) 步骤 3: 通过佳点集、不完全伽玛参数、可选择反向学习对攻击雄性河马进行位置变换, 计算不同位置的适应度函数。

(4) 步骤 4: 重复步骤 2 和步骤 3, 记录最优适应度函数对应的河马个体位置, 当满足最大迭代次数后结束运行。

(5) 步骤 5: 将最优河马个体位置带入支持向量机预测模型中, 通过寻优之后的混合核支持向量机计算精轧机组末机架出口板的凸度。

3 仿真实验

为了验证河马算法改进的有效性和热轧带钢末机架出口凸度预测模型的准确性, 进行 10 次算法改进有效性实验和 5 次热轧带钢末机架出口凸度预测模型的对比实验, 并取平均值作为指标进行对比分析。

3.1 改进算法有效性分析

为了验证改进河马算法寻优的性能, 在 CEC2005 测试函数中选取 4 个测试函数对改进的河马算法进行测试: 选取单峰函数 f_1 、 f_2 对算法的寻优速度进行测试; 选取多峰函数 f_5 、 f_7 对算法的局部搜索能力和全局搜索能力进行测试, f_5 和 f_7 函数具有多个局部最小值和一个全局极小值, 也能测验出算法跳出

局部最优的能力。具体测试函数如表 1 所示。其中, S_y 为关于 S 的自变量, 是维度为 y 的函数, 通过求解其最小值来测试算法寻优能力; S_{y+1} 为关于 S 自变量, 是维度为 $y+1$ 的函数。

表 1 测试函数
Table 1 Test functions

测试函数	定义域	最小值
$f_1(S) = \sum_{y=1}^{30} S_y^2$	$[-100, 100]$	0
$f_2(S) = \sum_{y=1}^{30} S_y + \prod_{y=1}^{30} S_y $	$[-10, 10]$	0
$f_5(S) = \sum_{y=1}^{30} [100(S_{y+1} - S_y^2)^2 + (S_y - 1)^2]$	$[-30, 30]$	0
$f_7(S) = \sum_{y=1}^{30} S_y^4 + rand$	$[-1.28, 1.28]$	0

选取改进的河马算法 (IHO)、河马算法 (HO)、麻雀算法 (SSA) 对 4 个测试函数进行测试, 并且为了改进算法有效性分析中的公平性, 在测试过程中, 将 3 种算法的种群大小均设置为 30, 最大迭代次数均设置为 1000。采用 3 种算法对测试函数进行 10 次试验, 迭代过程取任意一组迭代曲线, 如图 9 所示。迭代结果取 10 次测试结果的平均值进行比较, 如表 2 所示。

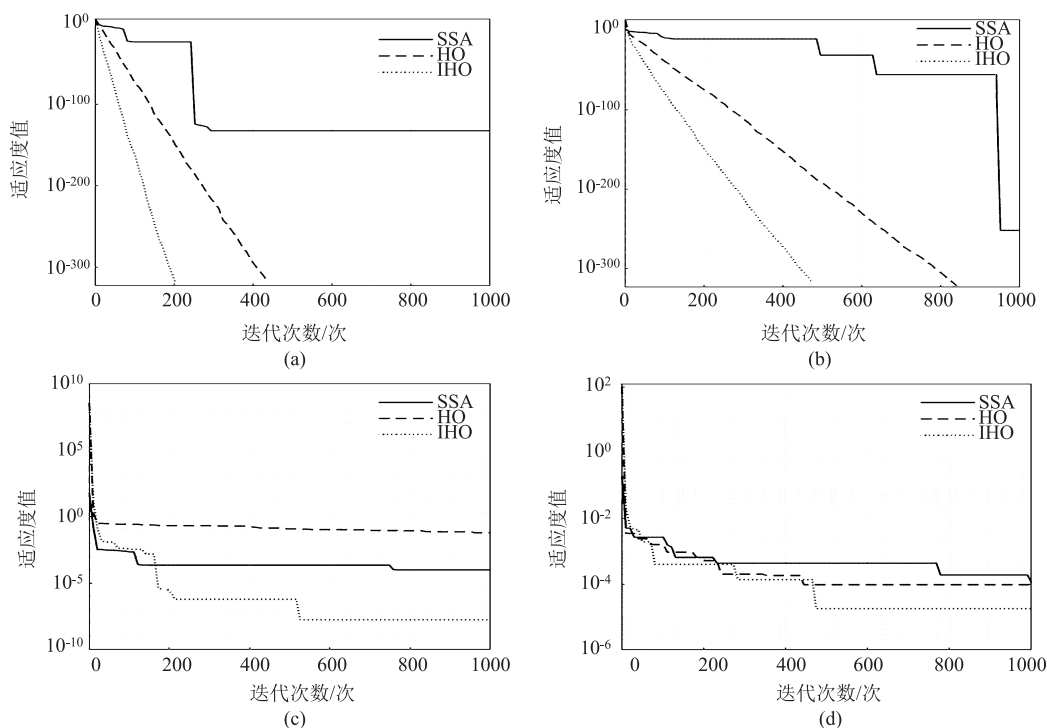


图 9 测试函数收敛曲线

(a) f_1 (b) f_2 (c) f_5 (d) f_7

Fig. 9 Convergence curves of test functions

表 2 测试函数求解极小值统计结果

Table 2 Statistical results of test functions for solving minimum values

函数	算法	平均值
f_1	SSA	2.26×10^{-54}
	HO	0
	IHO	0
f_2	SSA	3.60×10^{-49}
	HO	0
	IHO	0
f_5	SSA	2.60×10^{-5}
	HO	0.0029
	IHO	1.39×10^{-11}
f_7	SSA	5.06×10^{-4}
	HO	8.20×10^{-5}
	IHO	1.75×10^{-5}

由图 9a 和图 9b 可知，改进的河马算法的迭代速度优于原始河马算法和麻雀算法；由图 9c 和图 9d 可知，改进河马算法不断跳出局部最优。

从表 2 可知：改进的河马算法在单峰测试函数 f_1 、 f_2 中均能找到理论最小值，并且分别在迭代到 203、401 次时收敛，比河马算法和麻雀算法的寻优速度快，证明了改进河马算法在寻优速度方面的有效性；在多峰测试函数 f_5 、 f_7 中，3 种算法均未能寻找到理论最小值，但是改进河马算法多次实验的平均值远远低于河马算法和麻雀算法，说明了改进河马算法在平衡局部探索能力与全局开发能力、跳出局部最优的能力优于河马算法和麻雀算法，证明了改进河马算法在搜索具有多个局部极小值问题时的有效性。

3.2 热轧带钢凸度预测实验

以 1580 热轧带钢生产线为数据来源，该生产线在七机架四辊 CVC 轧机组末机架出口配备非接触式凸度仪，能准确、快速地识别带钢的凸度。在 1580 生产线上采集 S500GD 钢板的凸度，目标凸度为 40 μm 的数据有 199 组，根据拉依达准则将数据中 37 组异常点删除，最终选取了 162 组数据，其中，117 组数据作为训练集，45 组数据作为测试集。宽度、中间坯凸度、中间坯厚度和弯辊力等 28 种特征作为混合核支持向量机凸度预测模型的输入，末机架出口凸度作为输出，适应度函数为均方根误差。各输入、输出参数如表 3 所示。

3.2.1 预测模型中参数寻优

为了对比改进河马算法在混合核支持向量机预

表 3 预测模型输入参数与输出参数列表

Table 3 List of input and output parameters for prediction model

序号	特征参数
1~7	工作辊有效凸度（机架 1~机架 7）/mm
8~14	轧制力（机架 1~机架 7）/kN
15~18	弯辊力（机架 1、机架 5、机架 6、机架 7）/kN
19~25	窜辊量（机架 1~机架 7）/mm
26	宽度/mm
27	中间坯凸度/mm
28	中间坯厚度/mm
29	末机架出口凸度/ μm

测模型中的收敛速度与搜索全局极小值的能力，采用麻雀算法对混合核支持向量机的超参数进行寻优对比实验。算法参数设置如表 4 所示，其中，上、下限中分别为多项式核幂数、多项式核权重、高斯核核函数宽度及混合核支持向量机的惩罚因子。改进河马算法和麻雀算法在混合核支持向量机的寻优迭代过程如图 10 所示。

表 4 算法参数设置

Table 4 Setting of algorithm parameters

算法	种群大小	最大迭代次数	上限	下限
SSA	30	100	(4, 1, 10, 200)	(1, 0.01, 0.1, 30)
IHO	30	100	(4, 1, 10, 200)	(1, 0.01, 0.1, 30)




图 10 改进河马算法和麻雀算法优化混合核支持向量机迭代图

Fig. 10 Iteration diagram of optimization for hybrid kernel support vector machine by improved hippopotamus algorithm and sparrow search algorithm

由图 10 可知，迭代第 1 次时，改进河马算法的适应度值低于麻雀算法，表明在混合核预测模型中，

佳点集初始化种群能有效提高初始种群的质量,能有效避免算法陷入局部最优。在迭代到 100 次过程中,麻雀算法在迭代第 7 次时陷入局部最优,只能寻到局部极小值;改进河马算法在迭代过程中,不断跳出局部最优,寻找出全局极小值 $1.218 \mu\text{m}$ 。在混合核支持向量机寻优中,改进河马算法的适应度值优于麻雀算法,并且迭代速度快,表明改进的河马算法更适用于混合核支持向量机的热轧带钢凸度预测模型。

3.2.2 凸度预测模型对比

在热轧末机架出口凸度预测中,分别采用随机森林(Random Forest, RF)预测模型、核极限学习机(Kernel Extreme Learning Machine, KELM)预测模型、单一高斯核支持向量机(高斯核 SVM)预测模型、单一多项式核支持向量机(多项式核 SVM)预测模型、混合核支持向量机(混合核 SVM)预测模型共 5 种模型进行了预测仿真实验,每种模型分别进行 5 次实验,取实验平均值。预测模型的评价指标为均方根误差 $RMSE$ 和平均绝对百分比误差 $MAPE$,两者均是越小越好,误差越小,说明预测精度越高,效果越好。均方根误差为凸度预测值与凸度真实值之间的平均偏差程度,平均绝对百分比误差为凸度预测值与凸度实际值之间的平均绝对误差,其计算公式分别如式(27)和式(28)所示,随机森林和核极限学习机参数设置如表 5 所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (27)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (28)$$

式中: y_i 为第 i 个样本的预测值; \hat{y} 为第 i 个样本的真实值。

表 5 预测模型参数设置

Table 5 Parameter settings of prediction model

参数	模型				
	RF	KELM	高斯核 SVM	多项式核 SVM	混合核 SVM
决策树数量	49	—	—	—	—
最大叶子结点数	31	—	—	—	—
惩罚因子	—	10.36	10.31	13.28	14.41
高斯核核函数宽度	—	1.372	0.556	—	0.557
多项式核幂数	—	—	—	2.363	2.071
多项式核权重	—	—	—	—	0.227

热轧末机架出口凸度预测实验结果如图 11~图 12 所示,其中,图 11 为 5 种模型的凸度预测值,图 12 为 5 种模型的凸度预测误差。




图 11 5 种模型的凸度预测结果对比图

Fig. 11 Comparison diagram of convexity prediction results for five models




图 12 5 种模型的凸度预测误差对比图

Fig. 12 Comparison diagram of convexity prediction errors for five models

由图 11 可知,混合核支持向量机的预测结果更接近于真实值,随机森林、核极限学习机、高斯核支持向量机 SVM 和多项式核 SVM 的预测效果低于混合核 SVM 的预测结果。

由图 12 可知,随机森林、核极限学习机、高斯核 SVM、多项式核 SVM、混合核 SVM 的预测误差最大值分别为 6.3、6.3、3.4、5.3 和 2.3 μm ,去除误差最大值之后,5 种预测模型的预测误差分别落在 3、4、3、5 和 2 μm 之内。这表明混合核 SVM 预测模型的预测误差更小,泛化能力更强。

由表 6 的误差指标对比可知,混合核 SVM 热轧带钢精轧机组末机架出口凸度预测模型的均方根误差 $RMSE$ 为 $1.46 \mu\text{m}$ 、平均绝对百分比误差 $MAPE$ 为 2.61%,误差指标均低于多项式核 SVM、高斯核

表 6 5 种模型误差指标对比

Table 6 Comparison of error indicators for five models

误差指标	模型				
	RF	KELM	高斯核 SVM	多项式核 SVM	混合核 SVM
RMSE/ μm	1.73	1.68	1.88	1.61	1.46
MAPE/%	3.25	3.01	3.76	3.00	2.61

SVM、随机森林和和极限学习机预测模型。综上所述，改进的河马算法优化的混合核 SVM 模型的预测误差小，且均能保持在较小的误差内，在测试集中的预测效果表现良好，泛化能力强，有助于提升板材质量。

4 结论

- (1) 采用佳点集、不完全伽玛函数自适应权重、可选择反向学习策略对河马算法进行改进，并用改进的河马算法对混合核支持向量机模型的超参数和权重系数进行优化。经过 CEC2005 基准函数测试，改进的河马算法分别在第 203 和 401 代时寻找到理论最小值。
- (2) 采用改进的河马算法对多项式核和高斯核混合核支持向量机的各个超参数进行寻优，并且和麻雀算法在相同条件下进行比较。结果显示：麻雀算法在迭代第 7 次时陷入局部最优，而改进的河马算法不断进行搜索，从而寻到全局最优值 1.218 μm ，表明改进的河马算法更适用于凸度预测模型寻优。
- (3) 提出了多项式核和高斯核混合核支持向量机热轧带钢凸度预测模型，混合核 SVM 预测模型的预测误差最大值为 2.3 μm ，其余样本的预测误差均在 2 μm 之内。

参考文献：

[1] 宋君, 董广, 丁相阳, 等. UCMW 机组冷连轧过程板形形成机理及预报模型 [J]. 锻压技术, 2024, 49 (7): 243–250.
Song J, Dong G, Ding X Y, et al. Formation mechanism and prediction model of strip flatness in cold tandem rolling process of UCMW mill [J]. Forging & Stamping Technology, 2024, 49 (7): 243–250.

[2] 张振, 李欣, 刘颂, 等. 基于多类别生产状态的烧结矿转鼓指数预测模型 [J]. 中国冶金, 2022, 32 (1): 27–35.
Zhang Z, Li X, Liu S, et al. Predictive model of sinter drum index based on multi-category production status [J]. China Metallurgy, 2022, 32 (1): 27–35.

[3] 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.
Wang L J, Ding C Y, Fan Y C, et al. Hot rolled strip crown prediction model based on deep forest [J]. Steel Rolling, 2023, 40 (1): 90–96.

[4] 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.
Cao J G, Jiang J, Zhao Q F, et al. Wide and heavy plate crown control based on data mining [J]. Journal of Central South University, 2019, 50 (11): 2743–2752.

[5] 马红, 熊雯, 张雪荣. 基于极限学习机的热轧板凸度预测方法 [J]. 装备维修技术, 2023 (2): 74–77.
Ma H, Xiong W, Zhang X R. Prediction method of hot rolled plate crown based on limit learning machine [J]. Equipment Technology, 2023 (2): 74–77.

[6] 郝学斌. 深度信念网络算法下的热连轧板凸度预测模型 [J]. 材料与冶金学报, 2022, 21 (5): 364–370.
Hao X B. Prediction model of crown of hot rolling based on deep belief network algorithm [J]. Journal of Materials and Metallurgy, 2022, 21 (5): 364–370.

[7] 陈楠, 李旭, 栾峰, 等. 基于机理与数据驱动的热连轧板凸度组合预测 [J]. 哈尔滨工业大学学报, 2023, 55 (10): 74–81.
Chen N, Li X, Luan F, et al. Prediction of hot strip crowns of hot tandem rolling based on mechanism and data driving [J]. Journal of Harbin Institute of Technology, 2023, 55 (10): 74–81.

[8] 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.
Wang Y L, Li W G, Wang Y Q. Crown prediction of hot strip steel based on integrated feature selection and SVR [J]. Iron & Steel, 2024, 59 (1): 99–107.

[9] 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.
Liu Y M, Wang Z H, Wang T, et al. Data-driven modeling and intelligent prediction analysis for hot strip outlet crowns [J]. China Mechanical Engineering, 2020, 31 (22): 2728–2733.

[10] 姬亚锋, 宋乐宝, 原浩, 等. 基于 KPLS 与 SVM 的热连轧板凸度预测 [J]. 中国冶金, 2021, 31 (1): 20–24, 30.
Ji Y F, Song L B, Yuan H, et al. Strip crown prediction of hot-rolled strip based on KPLS integrate SVM [J]. China Metallurgy, 2021, 31 (1): 20–24, 30.

[11] 郭川川, 张长胜, 段青娜, 等. 融合多策略的改进秃鹰搜索算法 [J]. 控制与决策, 2024, 39 (1): 69–77.
Guo Y C, Zhang C S, Duan Q N, et al. Improved bald eagle search algorithm fused with multiple strategies [J]. Control and Decision, 2024, 39 (1): 69–77.

[12] 于军琪, 薛志璐, 赵安军, 等. 基于多策略改进麻雀搜索算法的并联冷机系统节能优化 [J]. 控制与决策, 2024, 39 (6): 1810–1818.
Yu J Q, Xue Z L, Zhao A J, et al. Optimization of parallel chill-

- ers system based on multi-strategy improved sparrow search algorithm for energy saving [J]. Control and Decision, 2024, 39 (6): 1810-1818.
- [13] 李硕, 于洋, 宋浩源, 等. 基于凸度转移理念的冷轧支撑辊辊型设计 [J]. 中国冶金, 2023, 33 (9): 112-117.
Li S, Yu Y, Song H Y, et al. Roll contour design of cold rolling backup roll based on crown transfer concept [J]. China Metallurgy, 2023, 33 (9): 112-117.
- [14] 江德文, 王振阳, 戴建华, 等. 基于支持向量机的高炉煤气利用率预测建模 [J]. 中国冶金, 2021, 31 (4): 55-63, 67.
Jiang D W, Wang Z Y, Dai J H, et al. Forecast modeling of gas utilization rate of blast furnace based on support vector machine [J]. China Metallurgy, 2021, 31 (4): 55-63, 67.
- [15] 梁盛楠, 刘文博, 李雅芝. 基于改进局部极化准则的多核 SVM 模型 [J]. 东北师大学报 (自然科学版), 2023, 55 (4): 32-38.
Liang S N, Liu W B, Li Y Z. Multiple kernel SVM model based on improved local polarization [J]. Journal of Northeast Normal University (Natural Science Edition), 2023, 55 (4): 32-38.
- [16] 崔兆亿, 耿秀丽. 基于随机森林和量子粒子群优化的 SVM 算法 [J]. 计算机集成制造系统, 2023, 29 (9): 2929-2936.
Cui Z Y, Geng X L. Support vector machine algorithm based on random forest and quantum particle swarm optimization [J]. Computer Integrated Manufacturing Systems, 2023, 29 (9): 2929-2936.
- [17] Amiri M H, Mehrabi Hash N, Montazeri M, et al. Hippopotamus optimization algorithm: A novel nature-inspired optimization algorithm [J]. Scientific Reports, 2024, 14 (1): 5032.
- [18] 包金山, 杨定坤, 张靖, 等. 基于特征提取与 INGO-SVM 的变压器故障诊断方法 [J]. 电力系统保护与控制, 2024, 52 (7): 24-32.
Bao J S, Yang D K, Zhang J, et al. Transformer fault diagnosis method based on feature extraction and INGO-SVM [J]. Power System Protection and Control, 2024, 52 (7): 24-32.
- [19] 黄鹤, 高永博, 茹锋, 等. 基于自适应黏菌算法优化的无人机三维路径规划 [J]. 上海交通大学学报, 2023, 57 (10): 1282-1291.
Huang H, Gao Y B, Ru F, et al. 3D Path planning of UAV based on adaptive slime mould algorithm optimization [J]. Journal of Shanghai Jiao Tong University, 2023, 57 (10): 1282-1291.
- [20] 蒋宇飞, 许贤泽, 徐逢秋, 等. 多策略融合改进的自适应蜉蝣算法 [J]. 北京航空航天大学学报, 2024, 50 (4): 1416-1426.
Jiang Y F, Xu X Z, Xu F Q, et al. Multi-strategy fusion improved adaptive mayfly algorithm [J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50 (4): 1416-1426.
- [21] 李得恺, 张长胜, 杨雪松. 融合多策略改进的黏菌优化算法 [J]. 模式识别与人工智能, 2023, 36 (7): 647-660.
Li D K, Zhang C S, Yang X S. Improved slime mould algorithm fused with multi-strategy [J]. Pattern Recognition and Artificial Intelligence, 2023, 36 (7): 647-660.
- [22] 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.
Zhang X L, Dai J H, Kang X N, et al. Plate data modeling based on multiple RBF neural networks [J]. Mining and Metallurgical Engineering, 2019, 39 (6): 124-128.

《锻压技术》全文获取通道全线开通!

方式1: 官方网站

1. 点击首页 2. 点击文章 3. 点击即可下载全文

方式2: 《锻压技术》杂志微信公众号

1. 点击“电子刊” 2. 点击封面进行阅读