

基于改进 BOA-ELM 的热轧带钢宽度预测

陈啸天, 张 帅, 杨培宏, 张 勇

(内蒙古科技大学 信息工程学院, 内蒙古 包头 014010)

摘要: 针对传统粗轧宽度预测模型参数强耦合、非线性等特点, 从数据驱动角度出发, 提出一种基于改进蝴蝶算法优化极限学习机 (IBOA-ELM) 的粗轧宽度预测模型。首先, 利用蝴蝶优化算法 (BOA) 对极限学习机 (ELM) 的随机权重和偏置进行参数寻优, 以提高 ELM 模型的预测精度。然后, 针对蝴蝶优化算法易陷入局部最优及收敛性差等问题, 引入 Fuch 混沌映射、非线性惯性权重和折射反向学习等策略改进蝴蝶优化算法, 进一步提高宽度预测模型的精度。最后, 通过某钢厂热轧生产现场数据对该模型进行仿真测试。结果表明: 基于数据驱动的 IBOA-ELM 模型在预测精度方面具有明显优势, 预测粗轧宽度误差在 ± 8 mm 以内的命中率为 93%, 明显优于对照模型, 可用于热轧带钢粗轧宽度预测且具有较强的适用性。

关键词: 粗轧宽度预测; 热轧带钢; 蝴蝶优化算法; Fuch 混沌映射; 非线性惯性权重; 折射反向学习

DOI: 10.13330/j.issn.1000-3940.2024.03.014

中图分类号: TG335.56; TP183

文献标志码: A

文章编号: 1000-3940 (2024) 03-0101-07

Prediction on hot rolled strip width based on improved BOA-ELM

Chen Xiaotian, Zhang Shuai, Yang Peihong, Zhang Yong

(School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China)

Abstract: For the characteristics of strong coupling and non-linearity of parameters in traditional rough rolling width prediction model, a new rough rolling width prediction model based on improved butterfly algorithm optimized extreme learning machine (IBOA-ELM) was proposed from the data-driven perspective. Firstly, the random weight and bias of the extreme learning machine (ELM) were optimized by butterfly optimization algorithm (BOA) to improve the prediction accuracy of ELM model. Then, for the problems that the butterfly optimization algorithm was easy to fall into local optimum and the convergence was poor, the butterfly optimization algorithm was improved by introducing the strategies of Fuch chaotic mapping, non-linearity inertia weights, refraction reverse learning and so on to further improve the accuracy of the width prediction model. Finally, the model was simulated and tested by the hot rolling production site data of a steel mill. The results show that the data-driven IBOA-ELM model has obvious advantages in prediction accuracy, and the hit rate of predicting the rough rolling width within ± 8 mm is 93%, which is significantly better than the comparison models, and can be used for predicting the rough rolling width of hot rolled strips with strong applicability.

Key words: prediction of rough rolling width; hot rolled strip; butterfly optimization algorithm; Fuch chaotic mapping; non-linearity inertia weights; refraction reverse learning

带钢宽度控制精度同厚度、板形等指标一样, 是产品质量的重要体现^[1]。热连轧粗轧阶段具有变量多、强耦合、非线性、时变性等特点, 且热轧机组生产现场情况非常复杂, 设备震动、磨损等随机不稳定因素极易产生控制系统的精度偏差, 导致基于数学、物理公式推导出的半机理模型在换规格和

新产品研发中难以达到预期效果。随着数字化时代的发展, 基于数据驱动的神经网络学习在众多领域已取得显著效果, 例如: 费庆等^[2]在研究中引入主成分分析-径向基函数 (Principal Components Analysis-Radial Basis Function, PCA-RBF) 神经网络建模, 实验证明, 经过训练的神经网络模型能够显著提升带钢宽度的预测精度; Deng J F 等^[3]将智能算法与人工神经网络 (Artificial Neural Networks, ANN) 相结合, 并将其应用于带钢热连轧板凸度预测, 证实了这种综合方法可以显著提高热轧产品预测的准确性; 杨金光等^[4]采用粒子群算法和差分进化算法相结合的方法, 对热轧带钢工作辊热形状进

收稿日期: 2023-07-12; 修订日期: 2023-10-13

基金项目: 国家自然科学基金资助项目 (62263026)

作者简介: 陈啸天 (1999-), 男, 硕士研究生

E-mail: 1571059802@qq.com

通信作者: 张 帅 (1986-), 男, 硕士, 工程师

E-mail: 364776437@qq.com

行分析,为实现高精度板形控制奠定了理论基础;梅文娟等^[5]将极限学习机(Extreme Learning Machine, ELM)模型应用于器件性能衰退趋势预报,与常规预报模型相比,其预报准确率有较大提高。

蝴蝶优化算法(Butterfly Optimization Algorithm, BOA)为 Arora S 等^[6]于 2019 年提出的一种新型启发式智能算法,通过模拟蝴蝶觅食和寻偶进行寻优。该方法对解决传统工程优化问题具有明显优势,但也同样面临着计算精度不高、收敛性差等问题。王永贵等^[7]在改进鲸鱼算法中引入 Fuch 混沌映射,有效地提高了算法执行过程中的搜索效率,产生了多样性良好的优质初始种群。段玉先等^[8]在麻雀搜索算法中加入非线性惯性权重,改善了算法在探索和开发之间的平衡。王光等^[9]在飞蛾扑火算法中将折射原理与反向学习相融合,使算法收敛速度得到明显提高。

综上所述,本文将某钢厂热轧生产实际生产数据作为样本,对热轧粗轧宽度预测模型展开研究,将蝴蝶优化算法改进,融入 Fuch 混沌映射、非线性惯性权重、折射反向学习等策略,由此建立基于改进蝴蝶算法优化极限学习机(Improved Butterfly Optimization Algorithm-Extreme Learning Machine, IBOA-ELM)的粗轧宽度预测模型,并通过平均绝对误差(Mean Absolute Error, MAE)、平均绝对百分误差(Mean Absolute Percentage Error, MAPE)和均方根误差(Root Mean Square error, RMSE)这 3 种性能指标验证该模型的可靠性。

1 极限学习机

极限学习机是一种单隐含层前馈神经网络^[10],无需调整输入权值与隐含阈值。与 RBF(Radial Basis Function)、BP(Back Propagation)等传统训练模型相比,ELM 模型具有结构简单、学习能力强等优点^[11],被广泛应用于物体识别、故障诊断以及温度、厚度和宽度预测等。

将在粗轧段采集到的 N 组样本数据表示为 $\{\mathbf{x}_i, \mathbf{t}_i\}$, 其中:

$$\begin{cases} \mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in}) \in \mathbf{R}^n \\ \mathbf{t}_i = (t_{i1}, t_{i2}, \dots, t_{im}) \in \mathbf{R}^m \end{cases} \quad (1)$$

则极限学习机的输出表示为:

$$\int_L = \sum_{l=1}^L \beta_l g_l(x) = \sum_{l=1}^L \beta_l g_l(\omega_l \times \mathbf{x}_i + \mathbf{b}_l) = \mathbf{t}_i \quad (2)$$

式中: \mathbf{x}_i 为第 i 组样本数据的输入向量; \mathbf{t}_i 为第 i 组样本数据的输出向量; n 为输入特征个数; m 为输

出特征个数; \mathbf{R} 为实数集; l 为隐藏节点序号, $l=1, 2, \dots, L$; L 为隐藏节点数量; β_l 为输出权值矩阵; ω_l 为输入权值矩阵; $g_l(x)$ 为激活函数; x 为任意变量; \mathbf{b}_l 为隐含层偏置矩阵。

式(2)可用矩阵表示为:

$$\mathbf{T} = \mathbf{H}\boldsymbol{\beta} \quad (3)$$

式中: \mathbf{T} 为极限学习机网络的输出矩阵; \mathbf{H} 为隐含层的输出矩阵; $\boldsymbol{\beta}$ 为输出权值矩阵。

训练单隐含层神经网络可化简为求解线性系统,则输出权值矩阵可以表示为:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \quad (4)$$

式中: \mathbf{H}^+ 为 \mathbf{H} 的广义逆矩阵; $\hat{\boldsymbol{\beta}}$ 为真实计算的输出权值矩阵。

ELM 的输入权值矩阵 ω_l 和隐含层偏置矩阵 \mathbf{b}_l 为随机产生,对模型预测精度影响较大。因此,本文利用改进蝴蝶优化算法(BOA)进行参数寻优。将 IBOA 对参数进行快速寻优的特点与 ELM 神经网络相结合,利用 IBOA 找到适合 ELM 神经网络的最佳参数,以提高 ELM 神经网络的预测精度。

2 蝴蝶优化算法

BOA 启发于蝴蝶捕食习性。蝴蝶利用空气中的气味来决定配偶和食物来源的可能方位。气味强弱由每只蝴蝶决定,同时也与它的适应度有关。当一只蝴蝶移动位置时,它的适应度也将随之改变。蝴蝶在一片区域捕捉到另一只蝴蝶散发的气味时,就会去靠近,这个阶段为全局搜索阶段。当蝴蝶不能捕捉到更强烈的气味时,它就会随机移动,这个阶段为局部搜索阶段。

蝴蝶气味浓度公式为:

$$f = cI^\alpha \quad (5)$$

式中: f 为气味浓度; I 为气味感知强度,与当前个体的适应度有关; c 为感官模态参数,一般取值为 0.01; α 为幂指数,通常取值为 0.1。

算法初始化种群,随机产生蝴蝶个体位置,并计算每只蝴蝶气味的大小,同时更新当前全局最优位置。

全局搜索阶段的位置更新公式为:

$$\mathbf{x}_h^{e+1} = \mathbf{x}_h^e + (r_1 s^* - \mathbf{x}_h^e) f_h \quad (6)$$

式中: \mathbf{x}_h^{e+1} 为第 h 只蝴蝶在第 $(e+1)$ 次迭代中的解向量; \mathbf{x}_h^e 为第 h 只蝴蝶在第 e 次迭代中的解向量; r_1 为 $[0, 1]$ 内的随机数; s^* 为当前最优解; f_h 为第 h 只蝴蝶发出的气味浓度。

局部搜索阶段的位置更新公式为:

$$\mathbf{x}_h^{e+1} = \mathbf{x}_h^e + (r_2^2 \mathbf{x}_u^e - \mathbf{x}_w^e) f_h \quad (7)$$

式中： \mathbf{x}_u^e 、 \mathbf{x}_w^e 为向量空间中选出的第 u 只和第 w 只蝴蝶； r_2 为 $[0, 1]$ 内的随机数。

蝴蝶寻找食物、求偶可以在全局和局部范围内发生。考虑到实际情况，在整个寻找食物或求偶的过程中，寻找食物的比例更大。因此，在 BOA 中使用切换概率 $p=0.8$ 与 $[0, 1]$ 内的随机数 r 进行对比：若 $p > r$ ，进行全局搜索；若 $p < r$ ，则进行局部搜索。

3 改进蝴蝶优化算法

3.1 Fuch 混沌映射

由于蝴蝶优化算法采用随机方法初始化种群个体，使种群初始化分布不均匀，易陷入局部最优。将混沌思想与自然启发式算法相结合，利用混沌序列的非线性、遍历性和长期不可预测性，替换服从标准概率分布的随机序列，从而搜寻整个解空间，使产生的个体分布均匀，提高种群初始化质量。

Fuch 相较于 Logistic、Tent 等传统混沌映射，具有对初值不敏感、遍历均衡和收敛较快等优点，因此，选用 Fuch 混沌映射初始化蝴蝶种群。Fuch 混沌映射的数学表达式为：

$$C_{z+1} = \cos\left(\frac{1}{C_z^2}\right) \quad (8)$$

式中： C_z 为 Fuch 映射的第 z 个种群的混沌变量， $C_z \neq 0$ ； $z=1, 2, \dots, N^*$ ； N^* 为种群设置数量。

3.2 非线性惯性权重

在蝴蝶优化算法中，发现最优解后，其他蝴蝶个体迅速靠向最优解，使算法全局搜索和局部搜索过程失衡，增加了陷入局部最优的概率。为此，引入非线性惯性权重 θ 来控制蝴蝶个体位置，从而避免算法过早陷入局部最优。惯性权重 θ 的计算公式为：

$$\theta = \exp\left(1 - \frac{e_{\max} + e}{e_{\max} - e}\right) \quad (9)$$

式中： e_{\max} 为最大迭代次数。

引入非线性惯性权重后，全局搜索阶段的位置更新公式为：

$$\mathbf{x}_h^{e+1} = \theta[\mathbf{x}_h^e + (r_1^2 \mathbf{s}^* - \mathbf{x}_h^e) f_h] \quad (10)$$

局部搜索阶段的位置更新为：

$$\mathbf{x}_h^{e+1} = \theta[\mathbf{x}_h^e + (r_2^2 \mathbf{x}_u^e - \mathbf{x}_w^e) f_h] \quad (11)$$

3.3 折射反向学习策略

传统蝴蝶优化算法存在易陷入局部最优及收敛速度慢等缺点，针对此问题，反向学习机制可有效改善。通过反向学习计算当前解的反向解，并比较

两个解的适应度值，选取更小的解作为当前最优解。将元启发式算法与反向学习相结合，能够有效避免算法陷入局部最优，并提高算法收敛速度。基于此思想，本文引入折射反向学习，其本质是在反向学习的基础上，结合光的折射定律寻找更优候选解。折射反向学习的基本原理如图 1 所示。

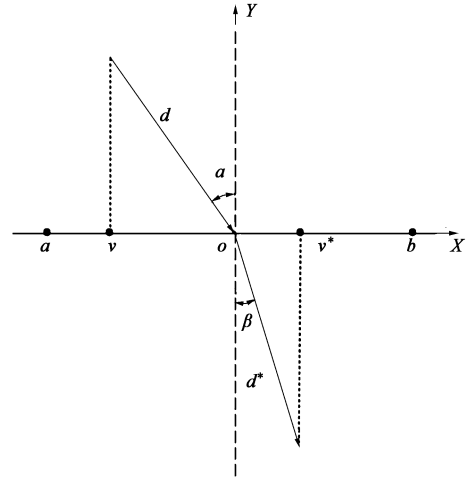


图 1 折射反向学习原理图

Fig. 1 Principle diagram of refraction reverse learning

在二维坐标中， X 轴搜索范围为 $[a, b]$ ， Y 轴为法线， α 和 β 分别为入射角和折射角， d 和 d^* 分别为入射光线和折射光线长度， v 和 v^* 分别为当前最优解和当前最优折射反向学习解， o 为搜索范围 $[a, b]$ 的中点。根据图 1 中的几何关系可得：

$$\sin\alpha = [(a+b)/2 - v]/d \quad (12)$$

$$\sin\beta = [v^* - (a+b)/2]/d^* \quad (13)$$

由式 (12)、式 (13) 及折射率的定义 $\eta = \sin\alpha/\sin\beta$ 可得：

$$\eta = \frac{d^* [(a+b)/2 - v]}{d [v^* - (a+b)/2]} \quad (14)$$

令 $k = d/d^*$ ，得：

$$k\eta = \frac{[(a+b)/2 - v]}{[v^* - (a+b)/2]} \quad (15)$$

对式 (15) 进行变换，得到基于折射原理的反向学习解的计算公式：

$$v^* = \frac{a+b}{2} + \frac{a+b}{2k\eta} - \frac{v}{k\eta} \quad (16)$$

当 $k=1$ 、 $\eta=1$ 时，式 (16) 可改写为标准式：

$$v^* = a + b - v \quad (17)$$

由于蝴蝶优化算法中个体是多维的，因此，将式 (16) 推广至多维空间，可改写为：

$$v_{q,j}^* = \frac{a_j + b_j}{2} + \frac{a_j + b_j}{2k} - \frac{v_{q,j}}{k} \quad (18)$$

式中： $v_{q,j}$ 为当前种群中第 q 个个体在第 j 维上的位置； $v_{q,j}^*$ 为 $v_{q,j}$ 的折射反向学习解； a_j 和 b_j 分别为搜索空间上第 j 维的最小值和最大值。

3.4 算法步骤

改进蝴蝶优化算法共有 8 个步骤，按顺序依次执行。

Setp 1: 初始化各项参数设置，利用式 (8) 初始化蝴蝶群体。

Setp 2: 计算每只蝴蝶个体的适应度值，并求出最优解。

Setp 3: 计算当前蝴蝶个体的气味浓度。

Setp 4: 若切换概率 $p > r$ ，则根据式 (10) 进行全局搜索。

Setp 5: 若切换概率 $p < r$ ，则根据式 (11) 进行局部搜索。

Setp 6: 按照式 (18) 对当前蝴蝶位置 $v_{q,j}$ 进行折射反向学习，生成折射反向学习解 $v_{q,j}^*$ ，并计算两个解的适应度值。

Setp 7: 比较 $v_{q,j}^*$ 和 $v_{q,j}$ 的适应度值，选取适应度值更小的为当前最优解进行迭代。

Setp 8: 重复 Step 3~Step 7，若达到规定迭代次数，则停止更新，输出全局最优解。

3.5 IBOA 性能测试

为验证本文提出的 IBOA 改进策略的有效性，将 IBOA 与灰狼算法 (Grey Wolf Optimization, GWO)^[12]、鲸鱼算法 (Whale Optimization Algorithm, WOA)^[13] 和基本蝴蝶优化算法 (BOA) 在 6 个标准测试函数中通过均值 Avg 与标准差 Std 进行对比分析。本次仿真环境为 Intel core i7, MATLAB R2020b。将算法统一设置为：函数维度 dim 为 30、迭代次数为 1000、种群数量为 30，为保证算法对比实验的准确性，各函数均独立运行 30 次^[14]。表 1 为测试函数信息，其中 $F1$ 、 $F2$ 、 $F3$ 为单峰函数， $F4$ 、 $F5$ 、 $F6$ 为多峰函数，表 2 为测试结果，图 2 为测试函数迭代曲线。

表 1 测试函数
Table 1 Test functions

函数	名称	范围	理论最优值
$F1$	Sphere	$[-100, 100]$	0
$F2$	Schwefel 2.22	$[-10, 10]$	0
$F3$	Schwefel 1.2	$[-100, 100]$	0
$F4$	Rastrigin	$[-5.12, 5.12]$	0
$F5$	Ackley	$[-32, 32]$	0
$F6$	Griewank	$[-600, 600]$	0

表 2 算法寻优结果比较 ($dim=30$)

Table 2 Comparison of algorithmic optimization results ($dim=30$)

函数	指标	算法			
		GWO	WOA	BOA	IBOA
$F1$	Avg	6.44×10^{-59}	6.85×10^{-151}	1.77×10^{-14}	0
	Std	9.92×10^{-59}	3.40×10^{-150}	9.29×10^{-16}	0
$F2$	Avg	1.52×10^{-34}	2.36×10^{-101}	1.01×10^{-11}	1.47×10^{-315}
	Std	1.38×10^{-34}	1.29×10^{-100}	2.30×10^{-12}	0
$F3$	Avg	2.95×10^{-15}	1.93×10^4	1.78×10^{-14}	0
	Std	8.80×10^{-15}	1.01×10^4	1.05×10^{-15}	0
$F4$	Avg	2.22×10^{-1}	0	1.46×10^1	0
	Std	9.09×10^{-1}	0	4.67×10^1	0
$F5$	Avg	1.61×10^{-14}	3.84×10^{-15}	1.16×10^{-11}	8.88×10^{-16}
	Std	3.11×10^{-15}	2.48×10^{-15}	2.16×10^{-12}	0
$F6$	Avg	3.59×10^{-3}	1.58×10^{-3}	1.67×10^{-15}	0
	Std	1.03×10^{-2}	1.10×10^{-2}	1.88×10^{-15}	0

由图 2 分析可知，本文提出的 IBOA 明显有更高的寻优精度和更快的收敛速度。BOA 在开始即陷入了局部最优，而使用混沌映射初始化后，形成了多样性更好的优质种群；非线性惯性权重的加入，增强了摆脱局部最优的能力；在寻优末期加入折射反向学习策略，提升了 IBOA 的收敛速度和跳出局部最优的概率，从而证明 IBOA 改进策略的有效性。

4 粗轧宽度预测模型

本文以某钢厂热连轧粗轧段为研究对象，通过对现场数据进行实地采集，将数据异常值剔除与归一化处理后，选取 600 组作为实验数据，其中 500 组用作训练，100 组用作测试。结合现场专家经验与 Pearson 相关性分析结果，最终选取入口带钢温度、粗轧入口厚度、粗轧入口宽度、穿带速度、侧压机 SSP (粗轧段入口侧压定宽机) 压下量、E1 (可逆立辊) 压下量、R2 (可逆平辊) 压下量、R2 轧制力、目标粗轧宽度作为预测输入，选取粗轧宽度作为输出，建立 IBOA-ELM 粗轧宽度预测模型。并将 IBOA-ELM 模型与 ELM、GWO-ELM、WOA-ELM、BOA-ELM 这 4 种模型比较分析。其中，ELM 神经网络隐含层节点数设置为 20。粗轧宽度预测模型如图 3 所示，Pearson 相关性分析公式如式 (19) 所示，Pearson 相关性分析结果如表 3 所示。

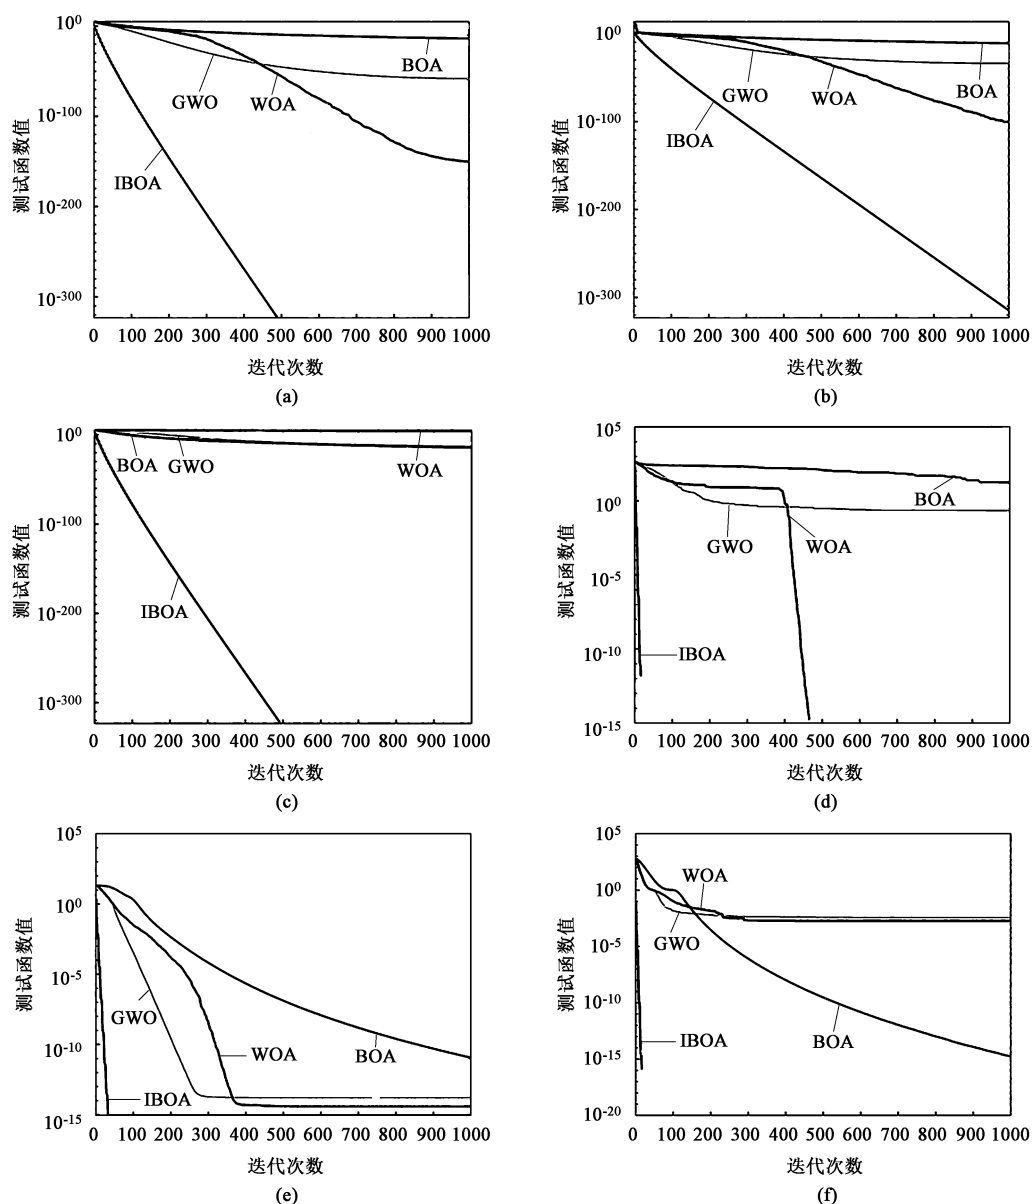


图2 测试函数迭代曲线

(a) F1 (b) F2 (c) F3 (d) F4 (e) F5 (f) F6

Fig. 2 Iteration curves for test functions

$$\rho = \frac{\sum (X' - \bar{X}') (Y' - \bar{Y}')}{\sqrt{\sum (X' - \bar{X}')^2 \sum (Y' - \bar{Y}')^2}} \quad (19)$$

式中： X' 、 Y' 为两组不同的变量； \bar{X}' 、 \bar{Y}' 为两组变量的平均值； ρ 为 X' 、 Y' 两组变量间的相关性系数。

为进一步比较各模型优劣性，本文采用平均绝对误差 MAE 、平均绝对百分比误差 $MAPE$ 和均方根误差 $RMSE$ ^[15] 这3种性能指标综合评价各模型预测精度，各性能指标计算公式为：

$$RMSE = \sqrt{\frac{1}{N} \sum_{o=1}^N (y'_o - y_o)^2} \quad (20)$$

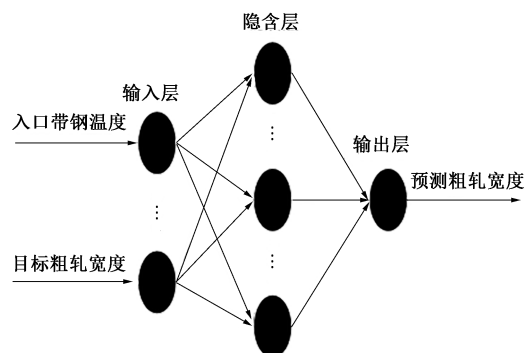


图3 粗轧宽度预测模型示意图

Fig. 3 Schematic diagram of rough rolling width prediction model

表 3 数据相关性分析

Table 3 Data correlation analysis

参数	实际粗轧宽度	
	Pearson 相关性系数	样本数
入口带钢温度	0.788 **	600
粗轧入口厚度	0.568 **	600
粗轧入口宽度	0.999 **	600
穿带速度	-0.671 **	600
侧压机 SSP 压下量	0.999 **	600
E1 压下量	0.456 **	600
R2 压下量	0.448 **	600
R2 轧制力	0.547 **	600
目标粗轧宽度	0.796 **	600

注：“**”在 0.01 级别（双尾），表示相关性显著。

$$MAE = \frac{1}{N} \sum_{o=1}^N |y'_o - y_o| \tag{21}$$

$$MAPE = \frac{100\%}{N} \sum_{o=1}^N \frac{|y'_o - y_o|}{y_o} \tag{22}$$

式中： y_o 为第 o 个样本的实际粗轧宽度； y'_o 为第 o 个样本的预测粗轧宽度； N 为样本个数， $o=1, \cdots, N$ 。

预测值与实际值对比如图 4 所示，预测误差对比如图 5 所示，模型评价结果如表 4 所示。

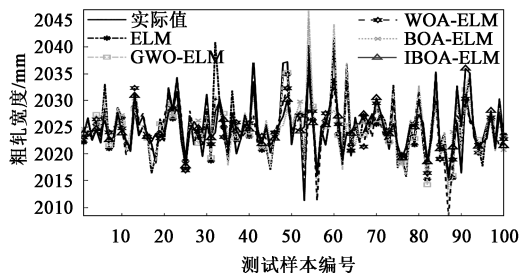


图 4 不同算法的粗轧宽度预测值与实际值对比

Fig. 4 Comparison of rough rolling width between predicted values by different algorithms and actual values

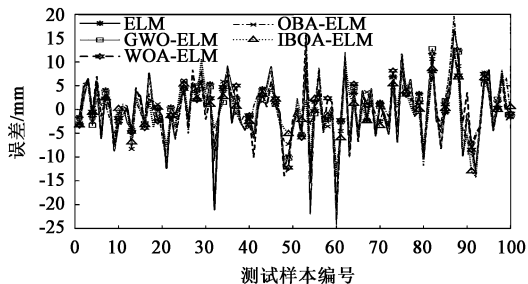


图 5 不同算法的预测误差比较

Fig. 5 Comparison of prediction errors by different algorithms

从表 4 分析可得，IBOA-ELM 模型的 MAE 、 $MAPE$ 和 $RMSE$ 均有明显降低，预测精度进一步提高，表明了模型的可靠性，同时证明了 IBOA-ELM 模型在粗轧宽度高精度预测中的可行性。

表 4 不同算法的模型评价结果

Table 4 Model evaluation results for different algorithms

指标	ELM	GWO-ELM	WOA-ELM	BOA-ELM	IBOA-ELM
MAE	4.9288	4.9875	4.4638	4.2107	3.7751
RMSE	6.5216	6.6913	5.9270	5.4431	4.9689
MAPE/%	0.24	0.25	0.22	0.21	0.19
测试误差					
在 ± 8 mm 以内的命中率/%	83	80	84	87	93

5 结论

(1) 本文在基础蝴蝶优化算法的基础上，提出了一种基于多策略改进蝴蝶优化算法（IBOA）。为提升初始种群质量，使其分布均匀，引入 Fuch 混沌映射；为平衡算法全局搜索能力与局部开发能力，融入非线性惯性权重；为提升跳出局部最优概率与收敛速度，引入折射反向学习策略。将 IBOA 与 GWO、WOA、BOA 对比测试，结果表明，本文改进的算法具有更高的预测精度。

(2) 以某钢厂热连轧粗轧生产过程数据为研究对象，选取合适的输入参数，建立 IBOA-ELM 粗轧预测模型。通过与 ELM、GWO-ELM、WOA-ELM、BOA-ELM 模型对比可得：IBOA-ELM 模型在 MAE 、 $MAPE$ 和 $RMSE$ 方面均得到不同程度的降低，预测误差在 ± 8 mm 以内的命中率为 93%，具有较高的命中精度。

参考文献：

[1] 李兴田. 提高热轧带钢宽度控制精度的综合措施 [J]. 轧钢, 2004, 21 (1): 49-51.
Li X T. Complex measures to improving the width control precision of hot rolled strip [J]. Steel Rolling, 2004, 21 (1): 49-51.
[2] 费庆, 战守义, 胡浩平, 等. 基于神经网络的热轧带钢宽度预报与设定 [J]. 北京理工大学学报, 2004, 24 (12): 1079-1083.
Fei Q, Zhan S Y, Hu H P, et al. Hot strip width prediction and setup with neural networks [J]. Journal of Beijing Institute of Technology, 2004, 24 (12): 1079-1083.
[3] Deng J F, Sun J, Peng W, et al. Application of neural networks for predicting hot-rolled strip crown [J]. Applied Soft Computing, 2019, 78: 119-131.
[4] 杨金光, 孙丽荣, 刘华强, 等. 基于 PSO 和 DE 优化算法的热轧工作辊热辊形的研究 [J]. 塑性工程学报, 2018, 25 (3): 289-296.
Yang J G, Sun L R, Liu H Q, et al. Study on thermal contour of work roll in hot rolling based on PSO and DE optimization algorithm [J]. Journal of Plasticity Engineering, 2018, 25 (3): 289-296.

(下转第 126 页)