

DOI:10.19651/j.cnki.emt.2212454

# 基于 NMWOA-LSTM 的卷取温度预测模型<sup>\*</sup>

周建新 霍彤明

(华北理工大学电气工程学院 唐山 063210)

**摘要:** 由于热连轧带钢卷取温度控制过程存在强非线性和时变性等因素影响,导致卷取温度控制精度和卷取命中率低。提出一种基于改进鲸鱼算法优化长短期记忆神经网络的方法,加入自适应参数优化和混合变异策略并融合小生境技术得到小生境技术混合变异策略的改进鲸鱼优化算法,建立改进鲸鱼算法优化 LSTM 的卷取温度预测模型,并与其它模型进行对比。仿真实验表明,在 10 个测试函数中,同其他先进算法相比,NMWOA 算法具有更好的搜索能力和寻优精度;在卷取温度模型预测中,NMWOA-LSTM 模型同其他 4 种模型相比,卷取温度高精度命中率达到 97.50%,提高了卷取温度的预测精度。

**关键词:** 鲸鱼优化算法;小生境技术;混合变异策略;长短期记忆神经网络;预测

中国分类号: TP183 文献标识码: A 国家标准学科分类代码: 510.4

## Prediction model of coiling temperature based on NMWOA-LSTM

Zhou Jianxin Huo Tongming

(College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China)

**Abstract:** The coiling temperature control accuracy and coiling hit rate of hot strip rolling are low due to the influence of strong nonlinearity and time variation. This paper proposes a method to optimize long short-term memory (LSTM) neural network based on improved whale algorithm. The improved Whale optimization algorithm of niche technology-mixed mutation strategy (NMWOA) was obtained by combining adaptive parameter optimization and hybrid mutation strategy with niche technology. The coiling temperature prediction model of LSTM optimized by improved whale algorithm was established and compared with other models. Simulation results show that the NMWOA algorithm has better search ability and optimization accuracy among the 10 test functions compared with other advanced algorithms. In the prediction of the coiling temperature model, compared with the other four models, the NMWOA-LSTM model has a high precision hit rate of 97.50%, which improves the prediction accuracy of the coiling temperature.

**Keywords:** whale optimization algorithm;niche technology;mixed mutation strategy;long short-term memory;forecast

## 0 引言

卷取温度控制是热轧带钢生产中最后一个温度控制环节,是决定带钢性能的重要工艺参数之一。过高的卷取温度会使力学性能变坏,并产生坚硬的氧化铁皮,影响带钢质量;过低的卷取温度不仅卷取困难,还影响轧材性能<sup>[1]</sup>。因此,对卷取温度进行实时准确预测有利于提高板带卷取命中率,提升温度控制精度,有效提高板带品质性能。

近年来,随着人工智能的不断发展,相关技术相继应用到卷取温度控制领域。王旌鉴<sup>[2]</sup>设计一款温度计算模型,在实际卷取温度控制过程中,实现了带钢卷取温度高精度的稳定控制,但该模型温度控制精度不够完善,在应对带钢

轧制速度突变的情况时,易产生较大误差。孙铁军等<sup>[3]</sup>利用改进遗传算法结合神经网络建立卷取温度预报模型,提高了卷取温度预测精度,但需要大量数据进行训练,难以建立精确数据对温度模型进行准确预测,控制策略繁琐导致控制精度降低。

本文设计一种小生境技术混合变异策略的改进鲸鱼优化算法(niche technology-mixed mutation strategy-whale optimization algorithm, NMWOA)并与长短期记忆神经网络(long short-term memory, LSTM)相结合的卷取温度预测模型。长短期记忆神经网络自提出以来,因其选择记忆特性,广泛应用于时间序列等预测领域,但网络自身仍存在训练复杂、梯度消失等问题。Xu 等<sup>[4]</sup>基于残差修正模型构

收稿日期:2022-12-22

\*基金项目:河北省自然科学基金(F2018209201)项目资助

建IWOA-LSTM-CEEMDAN模型预测煤矿瓦斯浓度,仿真实验表明,该模型的预测精度得到有效提升。Rajamoorthy等<sup>[5]</sup>设计混合旗鱼算法与鲸鱼算法并结合深度长短期记忆网络(SWO-DLSTM)的模型,该混合模型在一定程度上提升了模型的训练精度和收敛速度,取得了较好的预测效果,但其改进算法仅是两种算法的融合,在均衡算法的收敛速度和寻优精度上存在欠缺。为解决鲸鱼算法与LSTM结合预测精度低等问题,在算法初期和迭代过程中分别对鲸鱼算法做了进一步优化提升。

首先优化非线性收敛因子 $a$ 以提升迭代过程中算法局部开发能力和全局寻优能力;随后加入混合变异策略,提升鲸鱼种群在位置更新过程中跳出局部最优解和全局探索能力;为保证种群多样性提升算法初期的全局搜寻性能,最后融合小生境技术初始化鲸鱼种群,并将改进鲸鱼算法结合长短期记忆神经网络优化其隐藏神经元个数和学习率以提升模型预测精度。采用文献[6]的卷取温度相关数据应用于本文提出的NMWOA-LSTM神经网络模型,进行温度精度预测。

## 1 改进鲸鱼优化算法

标准鲸鱼优化算法同其他启发式智能算法一样容易陷入局部最优解<sup>[7]</sup>,为解决这一问题,Chakraborty等<sup>[8]</sup>设计SHEDE-WOA混合算法结合,提升整体算法跳出局部最优解和全局搜索能力。Heidari等<sup>[9]</sup>设计BHC与鲸鱼算法结合改善算法局部收敛和开发探索能力。本文针对算法迭代过程中早熟收敛、寻优精度低<sup>[10]</sup>等问题,提出自适应参数优化鲸鱼位置更新公式,提升算法的寻优能力和收敛速度。鲸鱼种群搜寻猎物具有随机性,在搜寻位置更新后加入混合变异策略,提升搜寻范围,提高种群多样性。并确定一种小生境初始种群的包围机制,通过小生境划分初始种群,有效地提升了初始种群精英个体数量、增强了算法前期跳出局部最优的能力。

### 1.1 自适应参数优化

在鲸鱼优化算法中,位置更新均涉及到非线性收敛因子 $a$ 的取值。根据文献[11]可知,算法前期,增加收敛因子权重提升WOA的全局搜索能力;算法后期,减小收敛因子权重提升WOA的局部开发能力。

为了提升算法的跳出局部最有能力和全局搜寻能力,本文在原有改进的基础上重新设计了非线性收敛因子,通过引入正弦函数,进一步保证非线性收敛因子 $a$ 随迭代从迅速到缓慢的递减过程,公式如下:

$$a = 2 \cdot [1 - \sin(\frac{\pi}{2} \cdot \sqrt{\frac{t}{T_{\max}}})] \quad (1)$$

其中, $t$ 为当前迭代次数, $T_{\max}$ 为最大迭代次数。

### 1.2 混合变异策略

鲸鱼种群在搜寻阶段,当 $|A| < 1$ 时,位置更新采用收缩包围机制,当 $|A| > 1$ 时,鲸鱼种群向外延伸扩大搜寻范

围,位置更新具有随机性。本文引入混合变异策略<sup>[12]</sup>更新位置,在包围、捕食和搜寻阶段位置更新时采用标准柯西分布函数和标准高斯分布函数,选择适应度最好个体进行变异并进行下一步迭代运算,数学模型如下:

$$X'_{best}(t) = X_{best}(t)[1 + \lambda_1 Cauchy(0, 1) + Gauss(0, 1)] \quad (2)$$

$$\lambda_1 = 1 - \frac{t^2}{T_{\max}^2} \quad (3)$$

$$\lambda_2 = \frac{t^2}{T_{\max}^2} \quad (4)$$

其中, $X'_{best}(t)$ 为变异后的个体, $\lambda_1, \lambda_2$ 为自适应变化的动态参数,在迭代过程中, $\lambda_1$ 逐渐减小, $\lambda_2$ 逐渐增大。算法前期逐步增大柯西策略增强权重影响,缓慢增加最优个体占比提升算法寻优范围;中期柯西-高斯策略混合作用,快速提升权重影响,提高算法收敛速度;后期增大高斯策略权重,逐渐减小权重影响,避免算法陷入局部最优解。提升算法迭代过程中跳出局部最优并进行全局探索能力。

### 1.3 小生境技术

为进一步提高鲸鱼算法的全局搜索能力,对初始鲸鱼种群划分小生境距离,重新调整适应度值更新最优鲸鱼个体。对适应度值高的个体最大化适应度值,保证个体的优良性,对适应度值低的个体降低其适应度值并重新迭代,使其搜寻更大范围区域寻找潜在的全局最优,具体公式如下:

$$d_{ij} = |X_i - X_j| \quad (5)$$

$$sh(d_{ij}) \begin{cases} 1 - \frac{d_{ij}}{\delta_s}, & d_{ij} < \delta_s \\ 0, & d_{ij} > \delta_s \end{cases} \quad (6)$$

$$f_{si} = \frac{f_i}{sh} i = 1, 2, \dots, m \quad (7)$$

其中, $d_{ij}$ 为新的小生境距离, $sh(d_{ij})$ 为共享函数, $f_{si}$ 为更新后的适应度值, $d_{ij} < \delta_s$ 保证种群个体在小生境环境中。

## 2 长短期记忆神经网络

长短期记忆神经网络是循环神经网络(recurrent neural network, RNN)的一种特殊类型,通过引入遗忘门、输入门和输出门更新细胞状态,可有效消除循环神经网络的梯度爆炸和梯度消失问题。LSTM神经网络结构如图1所示。

LSTM结构如图1所示,包含输入 $X_t$ 、上一次隐含层输出 $h_{t-1}$ 、细胞状态 $C_{t-1}$ 、遗忘门输出 $f_t$ 、输入门 $i_t$ 、新候选向量 $\hat{C}_t$ 、输出门 $o_t$ 、隐含层输出 $h_t$ 和新的细胞状态 $C_t$ ,其计算公式如式(8)~(13)所示。

$$f_t = \sigma(W_f X_t + W_f h_{t-1} + b_f) \quad (8)$$

$$i_t = \sigma(W_i X_t + W_i h_{t-1} + b_i) \quad (9)$$

$$\hat{C}_t = \tanh(W_c X_t + W_c h_{t-1} + b_c) \quad (10)$$

$$o_t = \sigma(W_o X_t + W_o h_{t-1} + b_o) \quad (11)$$

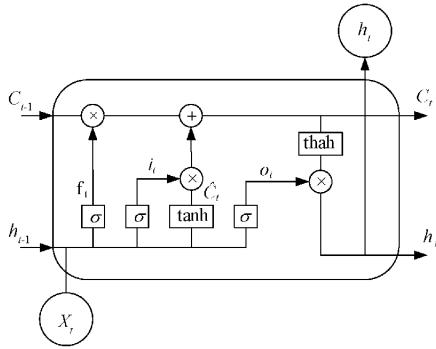


图 1 LSTM 神经网络结构

$$C_t = f_t \odot C_{t-1} + i_t \odot \hat{C}_t \quad (12)$$

$$h_t = o_t \odot \tanh(C_t) \quad (13)$$

其中,  $\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_c, \mathbf{W}_o$  分别是遗忘门、输入门、当前细胞状态和输出门的权重系数矩阵;  $\odot$  为向量对应元素相乘;  $\sigma$  为 sigmoid 激活函数,  $\tanh$  为正切激活函数。

### 3 NMWOA-LSTM 混合预测算法

NMWOA-LSTM 模型是将改进鲸鱼算法与 LSTM 神经网结合。调节隐藏神经元个数和学习率两个超参数确定 LSTM 神经网络预测精度<sup>[13]</sup>。其中, 隐藏神经元个数影响模型的最终拟合效果, 过多神经元易导致过拟合, 过少神经元易导致欠拟合; 合适的学习率在保证训练模型收敛速度的同时也提升了寻优精度。

采用小生境技术初始化鲸鱼算法种群, 加入自适应参数更新位置公式, 利用混合变异策略优化最优个体后得到的改进鲸鱼优化算法训练 LSTM 神经网络的隐藏神经元个数和学习率。训练模型流程如图 2 所示。

其中,  $\mathbf{X}_n(t)$  和  $\mathbf{X}_{best}'(t)$  分别为基本 WOA 算法和优化后的 NMWOA 算法中包围阶段和捕食阶段的最优位置向量;  $\mathbf{X}_{rand}(t)$  和  $\mathbf{X}_{best}''(t)$  分别为基本 WOA 算法和优化后的 NMWOA 算法中搜寻阶段的随机位置向量;  $D$  为包围、搜寻阶段个体间距离,  $D'$  为捕食阶段个体间距离;  $A$ 、 $C$  为系数;  $b$  为对数螺线形状的常数;  $l$  为  $[-1, 1]$  的随机数。

具体步骤如下:

- 1) 确定小生境范围并初始化鲸鱼种群参数; 初始化 LSTM 结构, 设定优化目标为隐藏神经元个数和学习率;
- 2) 根据适应度函数计算鲸鱼个体适应度值并进行位置更新计算;
- 3) 优化非线性收敛因子  $a$ , 提升算法的寻优能力;
- 4) 分别在包围、捕食和搜寻阶段的位置更新中加入混合变异策略, 将最优个体变异后更新鲸鱼位置;
- 5) 判断是否达到最大迭代次数或得到最优解; 若否, 返回步骤 2);
- 6) 输入 LSTM 最优隐藏神经元个数和学习率, 完成

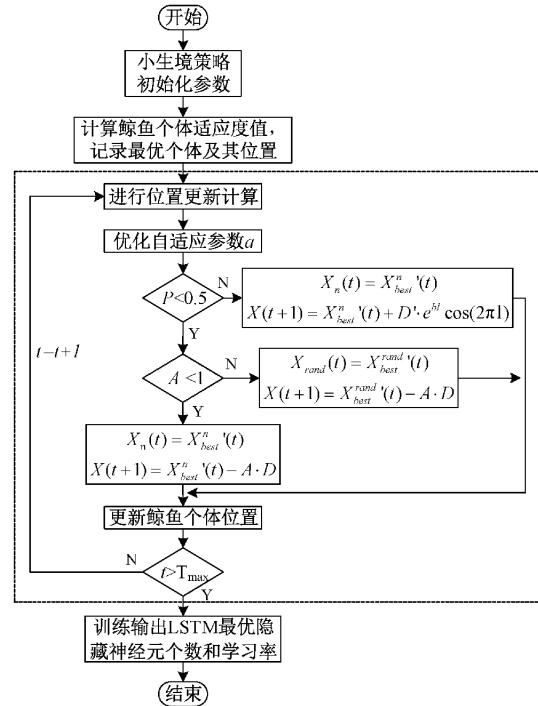


图 2 NMWOA-LSTM 训练流程

NMWOA-LSTM 训练模型。

### 4 NMWOA-LSTM 模型性能测试

#### 4.1 算法对比实验

为了测试 NMWOA 算法的优化性能, 与 CWOA<sup>[14]</sup>、标准 WOA<sup>[15]</sup>、ICSSOA<sup>[16]</sup>、GWO<sup>[17]</sup> 算法进行比较。选取 10 个不同类型的函数进行仿真实验, 其中  $F_1 \sim F_4$  为单峰函数、 $F_5 \sim F_6$  为多峰函数、 $F_7 \sim F_{10}$  为固定维度多峰函数。函数名称、表达式、维度、搜索区间和最小值如表 1 所示。

为验证算法测试的准确性, 设置相同种群规模 ( $N = 35$ ), 最大迭代次数为 900, 5 种算法分别在测试函数中进行 30 次独立仿真实验, 分析算法优化性能。记录并比较算法在测试函数中的平均精度值和标准差值如表 2 所示, 最佳仿真结果用黑色字体加粗, 实验结果保留 4 位小数。

由表 2 可知, NMWOA 在大部分测试函数中较于其他四种先进算法均取得最优平均精度值和标准差值。NMWOA 在  $F_1, F_2, F_4, F_5, F_6$  这 5 个函数 ( $dim = 50/500$ ) 和 3 个固定维度  $F_7$  ( $dim = 2$ )、 $F_8$  ( $dim = 4$ )、 $F_{10}$  ( $dim = 4$ ) 函数中均取得最优平均精度值和标准差值, 只有在函数  $F_3$  和  $F_9$  中平均精度值和标准差值略低但极为接近于 CWOA 和 ICSSOA, 表明 NMWOA 在单峰函数、多峰函数和固定维度多峰函数中均具有较强的寻优性能。充分说明 NMWOA 具有更高的寻优精度和收敛速度并具有更好的稳定性。

#### 4.2 温度预测评价指标实验

在本节中, 采用文献[6]中层流冷却系统中的终轧温

表1 基准测试函数

函数名称	表达式	维度	搜索区间	最小值
Schwefel2.22	$F_1(x) = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	50/500	[-10,10]	0
Schwefel2.21	$F_2(x) = \max_i\{ x_i , 1 \leq i \leq n\}$	50/500	[-100,100]	0
Rosenbrock	$F_3(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	50/500	[-30,30]	0
Quartic	$F_4(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0,1)$	50/500	[-1.28,1.28]	0
Ackley	$F_5(x) = -20\exp(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)) + 20 + e^{-50/500} [-32,32]$	50/500	[-32,32]	0
	$F_6(x) = \frac{\pi}{n} \{10\sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10\sin^2(\pi y_{i+1})] + (y_n - 1)^2\} + \sum_{i=1}^n u(x_i, 10, 100, 4)$			
Penalized1	$y_i = 1 + \frac{x_{i+1}}{4}u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m, & x_i > a \\ 0, & -a < x_i < a \\ k(-x_i - a)^m, & x_i < -a \end{cases}$	50/500	[-50,50]	0
Shekel's Foxholes	$F_7(x) = (\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6})^{-1}$	2	[-65,65]	1
Kowalik	$F_8(x) = \sum_{i=1}^{11} [a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4}]^2$	4	[-5,5]	0.0003
Branin	$F_9(x) = (x_2 - \frac{5.1}{4\pi^2}x_1^2 + \frac{5}{\pi}x_1 - 6)^2 + 10(1 - \frac{1}{8\pi})\cos x_1 + 10$	2	[-5,5]	0.398
Goldstein Price	$F_{10}(x) = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \times [30 + (2x_1 - 3x_2)^2 \times (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$	2	[-2,2]	3

表2 算法优化性能比较

函数	Dim	NMWOA	CWOA	WOA	ICSSOA	GWO
F1	50	平均值	<b>0</b>	0	$7.2315 \times 10^{-93}$	$6.0209 \times 10^{-230}$
		标准差	<b>0</b>	0	$3.1159 \times 10^{-92}$	0
	500	平均值	<b>0</b>	$3.7661 \times 10^{-281}$	$1.2667 \times 10^{-60}$	$8.9217 \times 10^{-211}$
		标准差	<b>0</b>	0	$5.8937 \times 10^{-60}$	0
F2	50	平均值	<b>0</b>	$3.7318 \times 10^{-291}$	$5.9976 \times 10^1$	$3.9482 \times 10^{-217}$
		标准差	<b>0</b>	0	$2.8456 \times 10^1$	0
	500	平均值	<b>0</b>	$1.3927 \times 10^{-282}$	$8.5353 \times 10^1$	$8.1104 \times 10^{-198}$
		标准差	<b>0</b>	0	$1.2866 \times 10^1$	0
F3	50	平均值	<b>4.7700 × 10<sup>1</sup></b>	$4.7857 \times 10^1$	$4.7782 \times 10^1$	$4.8300 \times 10^1$
		标准差	$3.1685 \times 10^{-1}$	$4.7125 \times 10^{-1}$	$4.6738 \times 10^{-1}$	$3.1619 \times 10^{-1}$
	500	平均值	$4.9423 \times 10^2$	<b>4.9411 × 10<sup>-2</sup></b>	$4.9555 \times 10^2$	$4.9459 \times 10^2$
		标准差	$8.7733 \times 10^{-2}$	<b>2.9318 × 10<sup>-2</sup></b>	$5.2181 \times 10^{-1}$	$5.6963 \times 10^{-1}$

表 2(续)

函数	Dim	NMWOA	CWOA	WOA	ICSSOA	GWO
F4	50	平均值 <b>2.536 0 × 10<sup>-5</sup></b>	5.996 5 × 10 <sup>-5</sup>	1.902 2 × 10 <sup>-3</sup>	4.616 3 × 10 <sup>-5</sup>	3.928 5 × 10 <sup>-5</sup>
	500	标准差 <b>2.493 5 × 10<sup>-5</sup></b>	5.058 4 × 10 <sup>-5</sup>	2.185 9 × 10 <sup>-3</sup>	4.464 9 × 10 <sup>-5</sup>	3.089 5 × 10 <sup>-5</sup>
	50	平均值 <b>1.503 8 × 10<sup>-5</sup></b>	6.651 9 × 10 <sup>-5</sup>	3.737 0 × 10 <sup>-3</sup>	5.911 4 × 10 <sup>-5</sup>	4.717 2 × 10 <sup>-5</sup>
	500	标准差 <b>1.199 0 × 10<sup>-5</sup></b>	4.368 6 × 10 <sup>-5</sup>	4.122 7 × 10 <sup>-3</sup>	4.993 8 × 10 <sup>-5</sup>	3.754 4 × 10 <sup>-5</sup>
F5	50	平均值 <b>8.881 8 × 10<sup>-16</sup></b>	8.881 8 × 10 <sup>-16</sup>	5.269 9 × 10 <sup>-15</sup>	8.881 8 × 10 <sup>-16</sup>	3.967 2 × 10 <sup>-15</sup>
	500	标准差 <b>3.944 3 × 10<sup>-31</sup></b>	3.944 3 × 10 <sup>-31</sup>	3.515 0 × 10 <sup>-15</sup>	3.944 3 × 10 <sup>-31</sup>	1.207 7 × 10 <sup>-15</sup>
	50	平均值 <b>8.881 8 × 10<sup>-16</sup></b>	8.881 8 × 10 <sup>-16</sup>	4.559 3 × 10 <sup>-15</sup>	8.881 8 × 10 <sup>-16</sup>	4.440 9 × 10 <sup>-15</sup>
	500	标准差 <b>3.944 3 × 10<sup>-31</sup></b>	3.944 3 × 10 <sup>-31</sup>	2.671 8 × 10 <sup>-15</sup>	3.944 3 × 10 <sup>-31</sup>	3.944 3 × 10 <sup>-30</sup>
F6	50	平均值 <b>4.891 1 × 10<sup>-2</sup></b>	1.668 1 × 10 <sup>-1</sup>	1.281 4	2.876 6 × 10 <sup>-1</sup>	4.951 1 × 10 <sup>-1</sup>
	500	标准差 <b>2.994 1 × 10<sup>-2</sup></b>	1.072 9 × 10 <sup>-1</sup>	2.867 4 × 10 <sup>-1</sup>	1.883 6 × 10 <sup>-1</sup>	2.750 3 × 10 <sup>-1</sup>
	50	平均值 <b>1.743 6 × 10<sup>-2</sup></b>	9.483 4 × 10 <sup>-2</sup>	1.189 5	8.136 2 × 10 <sup>-2</sup>	1.105 7 × 10 <sup>-1</sup>
	500	标准差 <b>1.121 6 × 10<sup>-2</sup></b>	6.154 4 × 10 <sup>-2</sup>	1.158 4 × 10 <sup>-2</sup>	5.330 8 × 10 <sup>-2</sup>	7.787 9 × 10 <sup>-2</sup>
F7	2	平均值 <b>1.198 1</b>	2.061 9	3.024 4	1.522 0	2.625 8
		标准差 <b>5.369 5 × 10<sup>-1</sup></b>	1.550 0	3.393 9	1.816 0	3.058 0
F8	4	平均值 <b>3.304 2 × 10<sup>-4</sup></b>	3.591 7 × 10 <sup>-4</sup>	8.690 2 × 10 <sup>-4</sup>	3.728 2 × 10 <sup>-4</sup>	3.500 9 × 10 <sup>-4</sup>
		标准差 <b>6.680 9 × 10<sup>-5</sup></b>	7.018 3 × 10 <sup>-5</sup>	4.835 3 × 10 <sup>-4</sup>	1.032 6 × 10 <sup>-4</sup>	7.869 8 × 10 <sup>-5</sup>
F9	2	平均值 3.983 5 × 10 <sup>-1</sup>	<b>3.978 9 × 10<sup>-1</sup></b>	3.993 2 × 10 <sup>-1</sup>	3.979 1 × 10 <sup>-1</sup>	3.978 9 × 10 <sup>-1</sup>
		标准差 8.112 5 × 10 <sup>-16</sup>	<b>1.665 3 × 10<sup>-16</sup></b>	6.794 6 × 10 <sup>-3</sup>	5.283 5 × 10 <sup>-5</sup>	1.665 3 × 10 <sup>-16</sup>
F10	4	平均值 <b>3.000 2</b>	3.001 9	3.004 4	3.001 5	3.001 0
		标准差 <b>6.354 7 × 10<sup>-4</sup></b>	2.788 7 × 10 <sup>-3</sup>	6.240 3 × 10 <sup>-3</sup>	2.146 3 × 10 <sup>-3</sup>	2.838 4 × 10 <sup>-3</sup>

度、实际卷取温度、板带厚度、板带速度、开水口数量 6 组数据作为输入对 NMWOA-LSTM 进行预测处理。为了验证和评估结果, 将 NMWOA-LSTM 模型与 CWOA-LSTM、GA-BP 神经网络<sup>[18]</sup>、随机森林 (random forest, RF)<sup>[19]</sup>、和极限学习机 (extreme learning machine, ELM)<sup>[20]</sup> 模型进行比较。采用平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 和决定系数 ( $R_{sq}$ ) 作为评价指标, 评价标准如下:

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (14)$$

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

$$R_{sq} = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2} \quad (16)$$

其中,  $\hat{y}_i$  为预测温度值,  $y_i$  为实际温度值,  $\bar{y}$  为实际温度的平均值,  $N$  为样本总数。

为实现 NMWOA 对 LSTM 神经网络结构的优化, 设定评价指标寻找最优超参数。首先进行初始参数设定, 为保证实验公平性, 将涉及到的所有智能算法种群规模和迭代次数进行统一, 将 NMWOA 和 CWOA 的基本参数设置

为: 种群规模为 35, 迭代次数为 30, 隐含层神经元个数和学习率范围设置为 [1, 100]、[0.000 1, 0.1], 对模型进行 1 000 次迭代实验; GA 的基本参数设置为: 种群规模为 35, 迭代次数为 30, 交叉概率为 0.3, 变异概率为 0.2。

#### 4.3 实验结果分析

根据上述实验参数设置, 对文献[6]中的 120 个样本数据进行测试实验, 涉及神经元预测模型参数结果如表 3 所示。

表 3 模型参数寻优结果

模型	参数名称	最优参数
NMWOA-LSTM	隐藏神经元个数	72
	学习率	0.001 75
CWOA-LSTM	隐藏神经元个数	98
	学习率	0.001 89

根据所选测试数据, 采用 NMWOA-LSTM、CWOA-LSTM、GA-BP 神经网络、RF 和 ELM 模型对卷取温度进行预测。预测结果如图 3 所示。

图 3 为上述 5 种模型对卷取温度进行预测的效果图。图 3(a) 中 NMWOA-LSTM 模型在温度偏差区间和温度密集采样点区间的预测精度要优于其他 4 种模型, 说明该模型预测效果更佳; 图 3(b)、(c) 中 CWOA-LSTM 模型和 GA-BP 模型在大温度变化区间误差相对有所缓解, 但在温

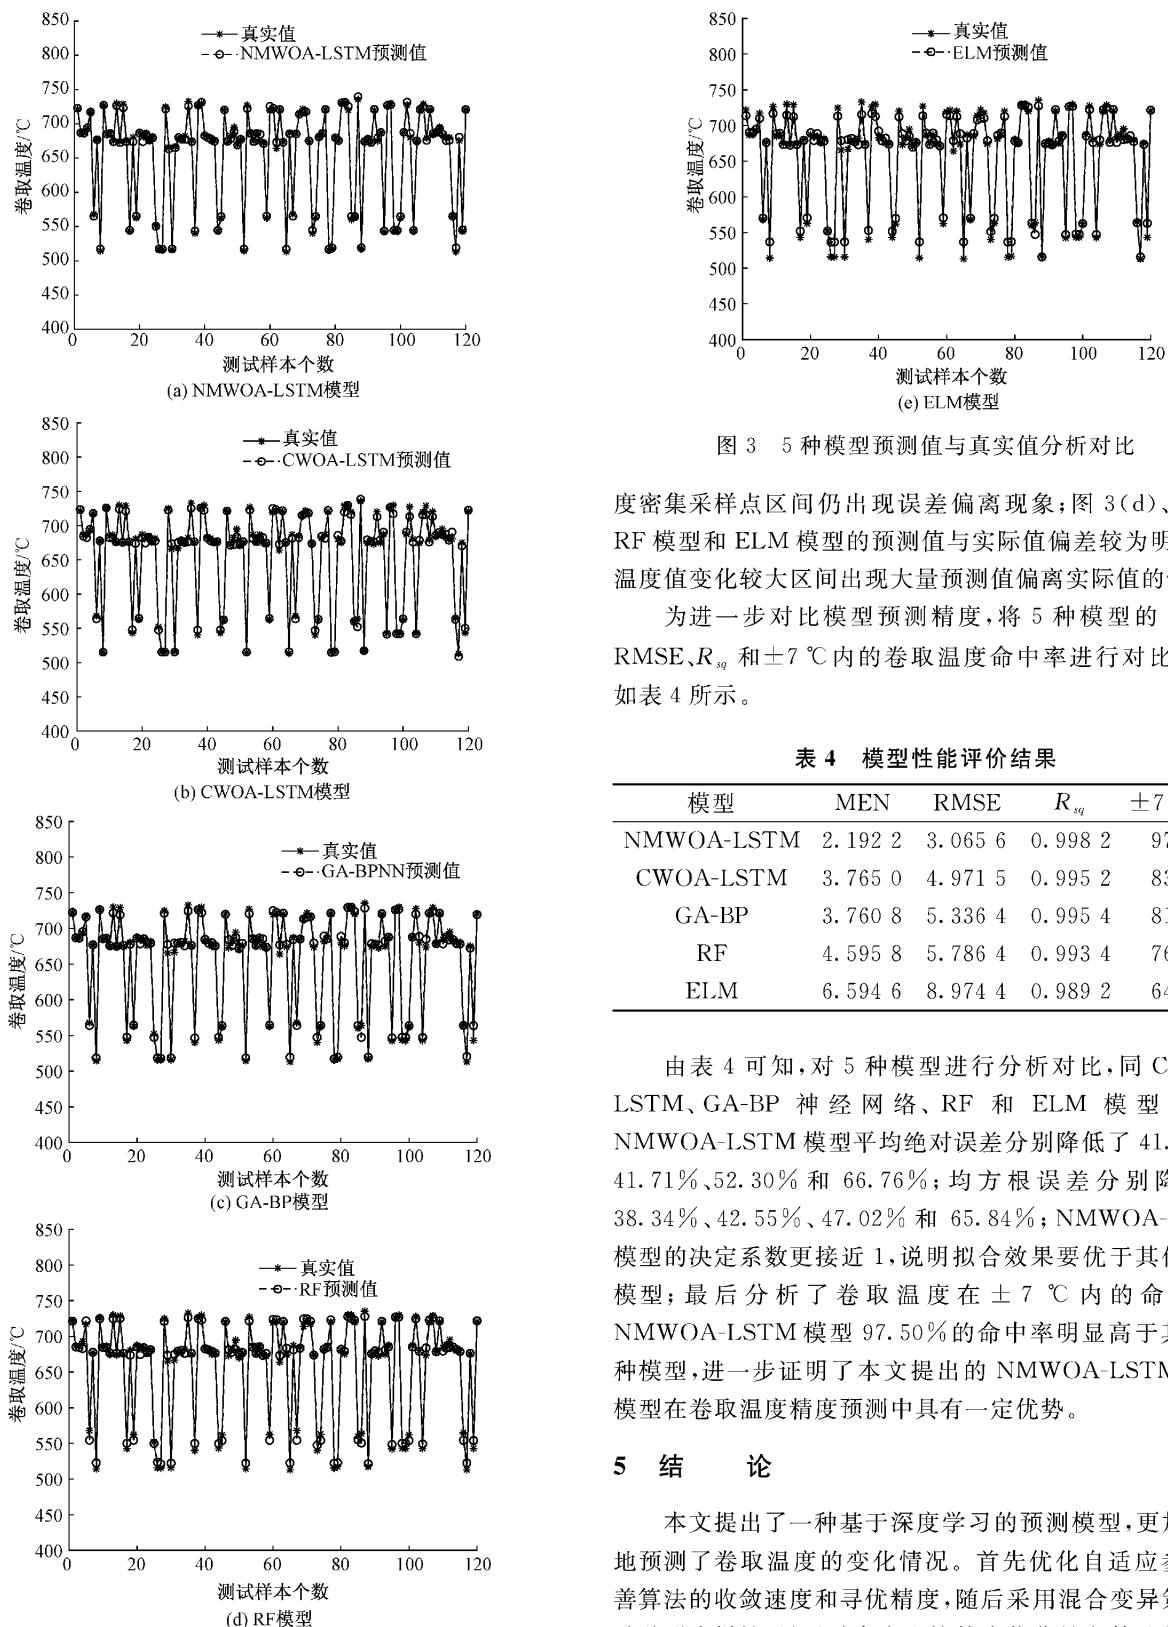


图 3 5 种模型预测值与真实值分析对比

度密集采样点区间仍出现误差偏离现象; 图 3(d)、(e) 中 RF 模型和 ELM 模型的预测值与实际值偏差较为明显, 在温度值变化较大区间出现大量预测值偏离实际值的情况。

为进一步对比模型预测精度, 将 5 种模型的 MAE、RMSE、 $R_{sq}$  和  $\pm 7^{\circ}\text{C}$  内的卷取温度命中率进行对比, 结果如表 4 所示。

表 4 模型性能评价结果

模型	MEN	RMSE	$R_{sq}$	$\pm 7^{\circ}\text{C} / \%$
NMWOA-LSTM	2.192 2	3.065 6	0.998 2	97.50
CWOA-LSTM	3.765 0	4.971 5	0.995 2	83.33
GA-BP	3.760 8	5.336 4	0.995 4	81.67
RF	4.595 8	5.786 4	0.993 4	76.66
ELM	6.594 6	8.974 4	0.989 2	64.17

由表 4 可知, 对 5 种模型进行分析对比, 同 CWOA-LSTM、GA-BP 神经网络、RF 和 ELM 模型相比, NMWOA-LSTM 模型平均绝对误差分别降低了 41.77%、41.71%、52.30% 和 66.76%; 均方根误差分别降低了 38.34%、42.55%、47.02% 和 65.84%; NMWOA-LSTM 模型的决定系数更接近 1, 说明拟合效果要优于其他 4 种模型; 最后分析了卷取温度在  $\pm 7^{\circ}\text{C}$  内的命中率, NMWOA-LSTM 模型 97.50% 的命中率明显高于其他四种模型, 进一步证明了本文提出的 NMWOA-LSTM 预测模型在卷取温度精度预测中具有一定优势。

## 5 结 论

本文提出了一种基于深度学习的预测模型, 更加准确地预测了卷取温度的变化情况。首先优化自适应参数改善算法的收敛速度和寻优精度, 随后采用混合变异策略提升种群多样性, 最后融合小生境技术优化鲸鱼算法初始种群, 进一步提升算法前期寻优能力。实验结果表明, 同其他四种先进算法相比, NMWOA 算法在 10 个基准测试函数中具有更好的寻优精度和搜索能力。

将改进的鲸鱼算法应用于 LSTM 神经网络模型进行参数优化,得到 NMWOA-LSTM 模型。在热连轧卷取温度预测实验中,NMWOA-LSTM 模型的 3 个评价指标明显优于其他四种模型,均方根误差和平均绝对误差更小,说明 NMWOA-LSTM 模型有极高的预测精度和稳定性,并且在采集±7 °C 内的卷取温度命中率中,NMWOA-LSTM 模型的命中率达到 97.50%,进一步体现了该模型在小温度偏差的预测稳定性更具优势。在未来的计划工作中,将重点研究 LSTM 神经网络最优参数的体系、结构的建立,并与更高效的智能算法结合,将其应用到卷取温度的预测、控制等相关研究中。

## 参考文献

- [1] 李研,李铁军,滕华湘,等.卷取温度对合金元素在氧化铁皮与基体间界面富集的影响[J].热加工工艺,2022(1):86-89.
- [2] 王旌鉴.热轧带钢层流冷却控制系统设计与应用[D].大连:大连理工大学,2018.
- [3] 孙铁军,杨卫东,程艳明,等.用改进遗传算法优化的带钢卷取温度预报模型[J].控制理论与应用,2015,32(8):1106-1113.
- [4] XU N K, WANG X Q, MENG X R, et al. Gas concentration prediction based on IWOA-LSTM-CEEMDAN residual correction model[J]. Sensors, 2022,22(12):4412.
- [5] RAJAMOORTHY R, SARASWATHI H V, DEVARAJ J, et al. A hybrid sailfish whale optimization and deep long short-term memory(SWO-DLSTM) model for energy efficient autonomy in india by 2048[J]. Sustainability, 2022, 14(3):1355.
- [6] 孙铁军.带钢卷取温度高精度预报及多目标优化控制策略研究[D].北京:北京科技大学,2016.
- [7] BOZORGI S M, YAZDANI S. IWOA: An improved whale optimization algorithm for optimization problems[J]. Journal of Computational Design and Engineering, 2019, 6(3):243-259.
- [8] CHAKRABORTY S, SHARMA S, SAHA A K, et al. SHADE-WOA: A metaheuristic algorithm for global optimization [J]. Applied Soft Computing, 2021,113(A):107866.
- [9] HEIDARI A A, ALJARAH I, FARIS H, et al. An enhanced associative learning-based exploratory whale optimizer for global optimization [J]. Neural Computing & Applications, 2020,32(9):5185-5211.
- [10] 刘亮,何庆.一种求解函数优化问题的改进鲸鱼优化算法[J].计算机应用研究, 2020, 37(4):1004-1009.
- [11] 王延峰,廖荣航,梁恩豪,等.基于围攻机制的改进鲸鱼优化算法[J].控制与决策,2023,38(10):2773-2782.
- [12] 付华,刘昊.多策略融合的改进麻雀搜索算法及其应用[J].控制与决策,2022,37(1):87-96.
- [13] SHERSTINSKY A. Fundamentals of recurrent neural network(RNN) and long short-term memory(LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404:132306.
- [14] 王坚浩,张亮,史超,等.基于混沌搜索策略的鲸鱼优化算法[J].控制与决策,2019,34(9):1893-1900.
- [15] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016,95(5):51-67.
- [16] XUE J K, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1):22-34.
- [17] XU L W, YU X, GULLIVER T A. Intelligent outage probability prediction for mobile IoT networks based on an IGWO-Elman neural network [J]. IEEE Transactions on Vehicular Technology, 2021, 70(2): 1365-1375.
- [18] 蒋磊,孙蕊,刘正午,等.基于 GA-BP 的中欧 GNSS 电离层误差建模与精度分析[J].北京航空航天大学学报,2023,49(6):1533-1542.
- [19] 周满国,黄艳国,段锦锋.基于 GRU-RF 模型的太阳辐射度短时预测[J].太阳能学报,2022,43(7):166-173.
- [20] 董庆,李本威,闫思齐,等.基于 BSO-ELM 的涡轴发动机加速过程性能参数预测[J].系统工程与电子技术, 2021,43(8):2181-2188.

## 作者简介

周建新,博士,副教授,主要研究方向为复杂系统的建模分析与控制。

E-mail:zhoujianxin1977@126.com

霍彤明,硕士研究生,主要研究方向为复杂系统的建模分析与控制。

E-mail:tm\_HUO1995@126.com