

DOI:10.19651/j.cnki.emt.2312694

基于 CHHO 优化 LSTM 的火场环境预测模型研究<sup>\*</sup>

王永东 袁凯鑫 曹祥红

(郑州轻工业大学建筑环境工程学院 郑州 450000)

**摘要:** 准确预测火场环境变化有助于精准掌握火情的发展趋势,保障人员的安全。由于火场环境多参数并存、耦合关系复杂,且具有时序性和非线性,难以建立准确的预测模型,因此提出了一种基于改进哈里斯鹰算法的自注意机制长短期记忆网络模型,实现了对火场环境数据的精准预测。首先,将 Logistic 映射策略、余弦权重因子、高斯扰动策略引入哈里斯鹰优化算法,丰富算法的种群多样性、平衡其全局探索和局部开发能力、提高算法的收敛精度。然后,利用改进后的哈里斯鹰优化算法对自注意机制长短期记忆网络模型中的超参数进行优化,基于优化后的参数对火场环境进行预测。仿真结果表明,基于改进后的哈里斯鹰优化算法的自注意机制长短期记忆网络模型拟合效果更好,具有更高的预测精度。

**关键词:** 火场环境预测;长短期记忆网络;哈里斯鹰优化算法

**中图分类号:** TU998.12; TP181 **文献标识码:** A **国家标准学科分类代码:** 62030;52020

Research on fire environment prediction model based on  
CHHO optimized LSTM

Wang Yongdong Yuan Kaixin Cao Xianghong

(School of Building and Environmental Engineering, Zhengzhou University of Light Industry, Zhengzhou 450000, China)

**Abstract:** Accurately predicting changes in the fire environment helps to accurately grasp the development trend of the fire and ensure the safety of personnel. Due to the coexistence of multiple parameters of the fire scene environment, the complex coupling relationship, and the time series and nonlinearity, it is difficult to establish an accurate prediction model. Therefore, this paper proposes a long-term and short-term memory network model of self-attention mechanism based on the improved Harris Hawk algorithm, which realizes the accurate prediction of the fire scene environment data. Firstly, the logistic mapping strategy, cosine weighting factor, and Gaussian perturbation strategy are introduced into the Harris Hawk optimization algorithm to enrich its population diversity, balance its global exploration and local development capabilities, and improve its convergence accuracy. Then, the improved Harris Hawk optimization algorithm is used to optimize the hyperparameter in the self-attention mechanism short-term memory network model, and the fire environment is predicted based on the optimized parameters. The simulation results show that the self-attention mechanism based on the improved Harris Hawk optimization algorithm has better long-term memory network model fitting effect and higher prediction accuracy.

**Keywords:** fire site environment prediction; short and long-term memory network; Harris Hawk optimization algorithm

## 0 引言

火灾作为人们常遇灾害之一,每年要夺走成千上万人的生命,造成数以亿计的经济损失<sup>[1-2]</sup>。室内空间作为人们长期居住的场所,一旦发生火灾,火灾产生的高温和烟雾将会对人员应急疏散造成巨大威胁。因此,准确而快速的预测火场环境成为建筑火灾安全领域一项重要的研究课题对

指导火灾应急救援和人员疏散具有重要意义。

近年来,数值模拟技术已经广泛应用在火灾研究中<sup>[3-5]</sup>,但是其要求大量的计算时间和资源,建模过程较为复杂,难以快速的对火场环境进行预测。作为时间序列预测分析的自回归模型,例如自回归移动平均模型(arma/arima)、自回归条件异方差模型(arch)、自回归条件异方差模型(garch)等<sup>[6]</sup>,对描述复杂的火场环境显得太过简单,

收稿日期:2023-01-31

<sup>\*</sup> 基金项目:河南省科技攻关计划重点研发与推广专项(212102210020)、博士科研基金(13501050022)项目资助

没有考虑火场环境参数之间的耦合性。机器学习被广泛应用于各个行业,长短时记忆神经网络(long short-term memory, LSTM)作为一种改进后的循环神经网络,在处理时间序列数据有较好的表现<sup>[7-8]</sup>。Wu 等<sup>[9]</sup>通过构建大型隧道火灾数值模拟数据库训练 LSTM 预测火灾场景,结果表明训练好的模型可以准确预测隧道火灾的位置和大小。Kou 等<sup>[10]</sup>设计出了基于门控循环单元(gated recurrent unit, GRU)的模型预测火灾位置和强度,结果表明该模型性能良好,可以不受火灾模拟精度的影响达到较高的预测精度。尹云飞等<sup>[11]</sup>利用时间序列内在特征辅助深度学习的方法构建出具有先验知识的深度神经网络模型,提高了火灾烟气流动与温度分布预测的准确度。孟晓静等<sup>[12]</sup>利用卷积神经网络(convolutional neural networks, CNN)与 LSTM 的算法优势构建一种火灾源强实时预测模型,在预测火源位置及强度上准确率达到 99.18%。以上研究都证明了深度学习在火灾场景实时预测方面的应用前景,但是在训练过程中存在依靠人工经验手动调节参数、随机性较大、不确定性较高、在处理高维数据时收敛速度较慢且容易陷入局部最优的问题。

哈里斯鹰优化算法(Harris Hawk algorithm, HHO)是由 Heidari 等<sup>[13]</sup>提出,模拟哈里斯鹰独特的群体捕食行为,在收敛速度和寻优精度等方面有着明显优势。吴丁杰等<sup>[14]</sup>利用 HHO 对核极限学习机(kernel based extreme learning machine, KELM)的惩罚系数、宽度参数两个参数进行优化,建立了 HHO-KELM 模型。结果表明 HHO-KELM 相较于 KELM 提高了诊断的正确率。谢渊等<sup>[15]</sup>利用哈里斯鹰优化算法优选遗传规划的主要算法参数,预测钢筋混凝土的寿命。结果表明该寿命预测模型计算精度较高。展广涵等<sup>[16]</sup>利用精英混沌反向学习策略初始化种群,引入动态自适应权重的逃逸能量非线性递减策略替代哈里斯鹰算法的线性递减机制,利用拉普拉斯交叉算子策略生成适应度更高的新个体,提高了算法的抗停滞能力。在瓦斯涌出量预测上精度最高。李金颖等<sup>[17]</sup>利用 Tent 混沌映射初始化种群,使用贪婪策略生成新的种群,改进后的算法对核极限学习机进行优化,仿真结果表明相较于原始算法模型,该模型具有更高的预测精度。

本文提出一种基于改进的哈里斯鹰优化算法的火场环境预测模型(CHHO-SALSTM),通过将 Logistic 映射策略、余弦权重因子、高斯扰动策略引入 HHO 算法,丰富算法的种群多样性、平衡其全局探索和局部开发能力、提高收敛速度。相较于其他优化算法本文算法复杂度较低,收敛速度较快,能够快速寻优。通过软件模拟的火场环境数据,将室内火场环境数据按照时间序列构造输入矩阵,输入到 CHHO-SALSTM 模型进行训练,以实现火场多维环境数据的精准预测。

## 1 哈里斯鹰优化算法

当猎物的逃逸能量  $|E| \geq 1$ , 算法处在探索阶段,此时

哈里斯鹰个体以下面两种策略进行位置更新,来追踪猎物的位置。其公式如式(1)所示。

$$\mathbf{X}(t+1) = \begin{cases} \mathbf{X}_{rand}(t) - r_1 |\mathbf{X}_{rand}(t) - 2r_2 \mathbf{X}(t)|, & q > 0.5 \\ [\mathbf{X}_{rabbit}(t) - \mathbf{X}_m(t)] - r_3 [lb + r_4(ub - lb)], & q < 0.5 \end{cases} \quad (1)$$

式中:  $\mathbf{X}(t+1)$  和  $\mathbf{X}(t)$  分别为第  $t+1$  和  $t$  次迭代时哈里斯鹰的位置;  $\mathbf{X}_{rand}(t)$  为第  $t$  次迭代时哈里斯鹰的随机位置;  $\mathbf{X}_{rabbit}(t)$  为当前最优个体位置;  $r$  和  $q$  为  $[0, 1]$  间的随机数;  $ub$  与  $lb$  表示搜索空间上下限;  $N$  为种群数量。  $\bar{\mathbf{X}}(t)$  表示第  $t$  次迭代时种群中心位置, 计算公式为  $\bar{\mathbf{X}}(t) = 1/N \sum_{i=1}^N \mathbf{X}_i(t)$ 。  $E$  为猎物的逃逸能量, 猎物的逃逸能量随着哈里斯鹰的围攻而逐渐降低, 计算公式为  $E = 2 \times E_0(1 - t/T)$ 。  $E_0$  为  $[-1, 1]$  的随机数,  $t$  为当前迭代次数,  $T$  为最大迭代次数。

当  $|E| \leq 1$  时, 此时哈里斯鹰追踪到猎物的位置, 哈里斯鹰会根据逃逸能量  $E$  和逃脱概率  $r$  来决定使用那种策略进行更新。

当  $|E| \geq 0.5$  且  $r \geq 0.5$  时, 猎物有足够的逃逸能量, 但是逃脱概率较小。此时攻击猎物, 猎物可能通过随机的跳跃的方式逃出包围圈, 从而导致捕捉失败, 因此哈里斯鹰执行软包围策略进行位置更新, 逐渐消耗猎物的能量, 最终完成捕食, 其公式如式(2)所示。

$$\mathbf{X}(t+1) = \Delta \mathbf{X}(t) - E |J \times \mathbf{X}_{rabbit}(t) - \mathbf{X}(t)| \quad (2)$$

式中:  $\Delta \mathbf{X}(t) = \mathbf{X}_{rabbit}(t) - \mathbf{X}(t)$  表示为猎物的位置向量与迭代当前位置的差值,  $J$ : 猎物的跳跃强度, 可较好的模拟猎物的运动形式。计算公式为  $J = 2 \times (1 - r_s)$ 。其中  $r_s$  为  $[0, 1]$  之间的随机数。

当  $|E| \leq 0.5$  且  $r \geq 0.5$  时, 猎物没有足够的逃逸能量, 并且逃脱概率较小, 此时攻击猎物一定能成功, 因此哈里斯鹰采用硬包围的策略进行位置更新, 其公式如式(3)所示。

$$\mathbf{X}(t+1) = \mathbf{X}_{rabbit}(t) - E |\Delta \mathbf{X}(t)| \quad (3)$$

当  $|E| \geq 0.5$  且  $r \leq 0.5$  时, 猎物的逃逸能量足够, 但是逃脱概率较小。此时攻击猎物需要消耗其逃逸能量, 因此哈里斯鹰执行渐进式快速俯冲的软包围策略进行位置更新。通过以下两种方式进行位置的更新。当第 1 种方式如式(4)所示进行位置更新后, 其适应度没有改善, 则执行第 2 种方式如式(5)所示。

$$\mathbf{Y} = \mathbf{X}_{rabbit}(t) - E \times |J \times \mathbf{X}_{rabbit} - \mathbf{X}(t)| \quad (4)$$

第 2 种位置更新公式为:

$$\mathbf{Z} = \mathbf{Y} + \mathbf{S} + \mathbf{LF}(D) \quad (5)$$

式中:  $\mathbf{X}(t)$  为第  $t$  次迭代时哈里斯鹰的位置。  $D$  为问题维度,  $\mathbf{S}$  是一个  $D$  维的随机向量,  $\mathbf{LF}$  为 Levy 飞行函数。

当  $|E| < 0.5$  和  $r < 0.5$  时, 猎物逃脱概率较大, 但逃逸能量不足, 此时攻击猎物可能会很大机率导致猎物逃脱, 因此哈里斯鹰执行渐进式快速俯冲的硬包围进行位置更

新。当第1种方式如式(6)所示进行位置更新后,其适应度没有改善,则执行第2种方式如式(7)所示。

$$Y = X_{rabbit} - E \times |J \times X_{rabbit} - \bar{X}(t)| \quad (6)$$

$$Z = Y + S \times LF(D) \quad (7)$$

## 2 改进的哈里斯鹰优化算法

### 2.1 基于Logistic映射初始化种群方法

哈里斯鹰优化算法采用随机生成的方式对种群进行初始化,使得哈里斯种群分布不均匀,导致收敛效果不稳定,影响后期的迭代寻优。考虑到Logistic混沌映射具有随机性与规律性的特点,且能在一定范围内不重复遍历所有状态,因此采用Logistic混沌映射初始化种群<sup>[18]</sup>。如式(8)所示。

$$X_{i+1} = \mu X_i \times (1 - X_i) \quad (8)$$

式中: $X_i$ 为哈里斯鹰种群位置,首先随机初始化 $X_1$ 的位置,然后利用式(8)生成其余 $M-1$ 个哈里斯鹰的位置,从而实现整个哈里斯鹰种群初始化。控制参数 $\mu$ 决定Logistic映射的演变过程, $\mu$ 值越大则序列取值越大、映射分布更均匀,因此本文中 $\mu$ 取最大值4。

假设种群规模为30,在二维搜索空间中产生的初始化种群分布如图1、2所示,从图中可以看出,相比随机初始化种群,Logistic映射产生初始化种群分布更加均匀,遍历性更好。




图1 随机初始化种群




图2 Logistic映射初始化种群

### 2.2 逃逸能量递减机制的改进

猎物逃逸能量 $E$ 是HHO平衡全局探索与局部开发行为的重要参数。HHO中对猎物逃逸能量 $E$ 的描述是由最大值线性递减至最小值,这种线性能量递减策略导致算法的探索和开发不平衡,对哈里斯鹰围攻猎物过程描述较差。为了提高算法的收敛精度,在更新逃逸能量时加入余弦权重因子<sup>[19]</sup>,其公式如式(9)~(10)所示。

$$E = 2 \times \omega E_0 \left(1 - \frac{t}{T}\right) \quad (9)$$

$$\omega = \cos^2 \frac{\pi t}{2 \text{iter}_{\max}} \quad (10)$$

其中, $t$ 为当前迭代次数; $\text{iter}_{\max}$ 为最大迭代次数。按照式(9)生成的逃逸能量值,如图3所示。 $\omega$ 在迭代前期,取值偏大,算法搜索范围更大,增加其全局搜索能力,有利于跳出局部极值。随着迭代次数的增加, $\omega$ 逐渐变小,此时进入局部开发阶段,从而提高了算法的精度。




图3 逃逸能量分布

### 2.3 高斯扰动策略<sup>[20]</sup>

针对HHO在寻找最优解时可能陷入局部最优,从而导致寻优精度和收敛速度降低的问题。引入高斯扰动策略,其在局部空间搜索性能好,对每次迭代后对适应度值比平均适应度值低的个体进行扰动,增加了种群的多样性,有利于算法跳出局部极值点,同时也提高了算法全局搜索性能。使用高斯扰动策略生成新个体的公式如式(11)所示。

$$X'_G = X'_G (1 + \text{Gaussian}(\mu, \sigma^2)) \quad (11)$$

其中, $X'_G$ 为原来个体的位置, $X'_G$ 为高斯变异后得到的个体位置。对所得到的新个体进行判断,如果新个体比之前的个体更优,则用新个体对原个体进行更新,否则保持不变。 $\mu$ 和 $\sigma^2$ 为高斯分布的均值和方差,本研究中的 $\mu$ 取0, $\sigma^2$ 取1。

### 2.4 改进算法的性能评估

为了验证CHHO算法的寻优能力,本研究选取遗传算法(genetic algorithm, GA)、粒子群算法(particle swarm optimization, PSO)、HHO作为对比试验。使用表1中的8个具有不同特征的基准测试函数进行测试。其中, $F_1 \sim F_5$ 是单峰函数, $F_6 \sim F_8$ 是多峰函数,参数设置最大迭代次数

为 1 000,种群规模为 30。为了去除偶然性带来的误差,分别利用 4 种算法对 8 个测试函数进行 30 次独立的试验,选取 30 次最优值的平均值作为算法的寻优结果。测试结果如表 2 所示。

表 1 基准测试函数

函数名称	测试函数	维度	搜索范围	最优值
Sphere	$F_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
Schwefel 2.22	$F_2(x) = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	30	$[-10, 10]$	0
Schwefel 1.2	$F_3(x) = \sum_{i=1}^n (\sum_{j=1}^n x_j)^2$	30	$[-100, 100]$	0
Rosenbrock	$F_4(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	$[-30, 30]$	0
Step	$F_5(x) = \sum_{i=1}^n ( x_i + 0.5 )^2$	30	$[-100, 100]$	0
Rastrigin	$F_6(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
Ackley	$F_7(x) = -20\exp(0.2\sqrt{\frac{1}{n}\sum_{i=1}^n (x_i)^2}) - \exp(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$	30	$[-32, 32]$	0
Griewank	$F_8(x) = \frac{1}{4\ 000}\sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	$[-600, 600]$	0

表 2 测试函数寻优结果

函数	算法	平均值	标准差	函数	算法	平均值	标准差
$F_1$	GA	$1.36 \times 10^6$	$1.79 \times 10^5$	$F_5$	GA	$1.52 \times 10^6$	$1.88 \times 10^5$
	PSO	$1.36 \times 10^6$	$6.33 \times 10^4$		PSO	$1.38 \times 10^6$	$6.05 \times 10^4$
	HHO	$1.06 \times 10^{94}$	$4.97 \times 10^{94}$		HHO	$3.61 \times 10^3$	$5.38 \times 10^3$
	CHHO	$2.65 \times 10^{102}$	$3.54 \times 10^{101}$		CHHO	$5.84 \times 10^{14}$	$6.28 \times 10^{13}$
$F_2$	GA	$4.29 \times 10^3$	$8.86 \times 10^1$	$F_6$	GA	$8.02 \times 10^3$	$3.01 \times 10^2$
	PSO	$1.79 \times 10^{10}$	$1.79 \times 10^{10}$		PSO	$1.35 \times 10^4$	$1.83 \times 10^2$
	HHO	$2.52 \times 10^{-30}$	$5.02 \times 10^{-30}$		HHO	$0.00 \times 10^0$	$0.00 \times 10^0$
	CHHO	$1.37 \times 10^{-75}$	$4.21 \times 10^{-62}$		CHHO	$0.00 \times 10^0$	$0.00 \times 10^0$
$F_3$	GA	$2.29 \times 10^7$	$3.93 \times 10^6$	$F_7$	GA	$1.95 \times 10^1$	$2.55 \times 10^{-1}$
	PSO	$3.72 \times 10^7$	$1.16 \times 10^7$		PSO	$1.98 \times 10^1$	$1.24 \times 10^{-1}$
	HHO	$1.79 \times 10^{-17}$	$9.81 \times 10^{-17}$		HHO	$8.88 \times 10^{-16}$	$4.01 \times 10^{-31}$
	CHHO	$3.51 \times 10^{-23}$	$3.85 \times 10^{-24}$		CHHO	$6.44 \times 10^{-23}$	$5.41 \times 10^{-45}$
$F_4$	GA	$4.73 \times 10^9$	$9.63 \times 10^8$	$F_8$	GA	$1.26 \times 10^1$	$1.63 \times 10^3$
	PSO	$3.72 \times 10^9$	$2.76 \times 10^8$		PSO	$1.23 \times 10^1$	$5.18 \times 10^2$
	HHO	$5.73 \times 10^{-1}$	$1.40 \times 10^0$		HHO	$0.00 \times 10^0$	$0.00 \times 10^0$
	CHHO	$5.91 \times 10^{12}$	$1.6 \times 10^8$		CHHO	$0.00 \times 10^0$	$0.00 \times 10^0$

由表 2 所知在,CHHO 对于单峰函数  $F_1 \sim F_5$  的优化效果比较明显,寻优的指标值远超其他算法,对于多峰函数  $F_6 \sim F_8$ ,其中  $F_6$  和  $F_8$ ,CHHO 和 HHO 均能找到理论的极值 0,对于多峰函数  $F_7$ ,CHHO 也比 HHO 有着一定程度的提升。无论单峰函数还是多峰函数,CHHO 在多次寻优过程中,平均值和标准差均比其他算法更小,表明

CHHO 拥有更好的全局搜索能力。

通过绘制基准测试函数的迭代进化曲线,可以进一步对比分析各个算法的收敛能力,从而更加准确的评判其预测性能。图 4~11 为所有算法迭代 1 000 次后的进化曲线图。

从图 4~11 可知,相对于其他算法,CHHO 迭代更少




图4 Sphere函数迭代曲线




图8 Step函数迭代曲线




图5 Schwefel 2.22函数迭代曲线




图9 Rastrigin函数迭代曲线




图6 Schwefel 1.2函数迭代曲线




图10 Ackley函数迭代曲线




图7 Rosenbrock函数迭代曲线




图11 Griewank函数迭代曲线



的次数达到最优适应度,表明引入 Logistic 映射可以提高初始解的质量,使初始种群分布更加均匀,有利于提高算法的全局搜索能力,从而快速实现寻优。对于多峰函数,CHHO 在迭代初期可以迅速找到最优值,相对于 HHO 收敛速度更快,全局搜索能力更强。

### 3 CHHO-SALSTM 模型

#### 3.1 SALSTM 神经网络原理

LSTM 通过其内部复杂的门运算和引入细胞态,可以有效缓解递归神经网络中的长期依赖问题。LSTM 不仅可以从单个数据点,还可以从整个数据系列中提取、传递和表达长时间序列中时间记忆信息。同时 LSTM 可以解决 RNN 中的梯度消失和梯度爆炸的问题。其结构主要分为 3 种门:遗忘门、输入门和输出门。LSTM 神经网络的结构如图 12 所示。

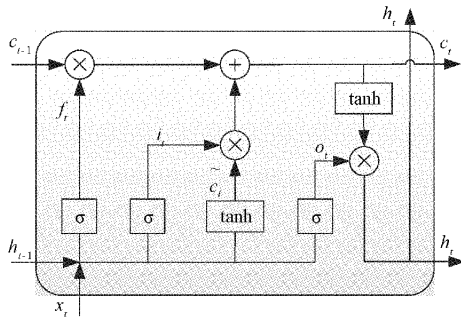


图 12 LSTM 网络结构

注意力机制是一种类似人类视觉所特有的大脑信号处理机制,可以对事物不同部分赋予不同的权重,从而降低其无关部分的作用<sup>[21]</sup>。通过输入参数内部的相关关系来决定应该关注哪些输入参数,对关注的参数设置的权重系数较大,从而快速筛选出关键的信息。其本身不需要其他参数,降低了对外部参数的依赖,更擅长捕捉输入参数的内部相关性。本文通过自注意力机制赋予 LSTM 神经网络输出的隐藏层向量不同的权重,突出一些重要特征,从而使整个模型(SALSTM)能表现出更好的性能。

#### 3.2 CHHO-SALSTM 模型原理

在 SALSTM 模型中,神经元个数,迭代次数、输入批量和学习率等超参数选择对模型拟合能力起着重要作用<sup>[22]</sup>,而火场环境预测模型中输入数据是多维的,传统的 SALSTM 靠人工经验进行调参,效率低且准确性差。CHHO-SALSTM 模型的主要思想是利用改进后的 Harris 鹰搜索算法对网络中的神经元个数,迭代次数、输入批量和学习率等超参数进行大范围搜索,通过适应度值的不断更新调整训练误差。本模型将测试集中的均方根误差作为适应度函数值。迭代完成后根据最优超参数值对 SALSTM 模型进行训练,最终得到预测性能更好的神经网络模型。CHHO 优化 SALSTM 模型的流程如图 13 所示。

1)定义初始化参数,包括 Harris 鹰种群大小,最大迭代次数,设置优化参数(神经元个数、迭代次数、输入批量和学习率),使用 Logistic 映射初始化种群

2)计算个体适应度,对适应度函数进行排序,选取最优适应度的 Harris 鹰位置作为猎物的初始位置。

3)更新初始能量  $E$  和跳跃强度  $J$ 。

4)根据逃逸能量  $E$  和  $r$  的取值, Harris 鹰采用不同的策略调整自身位置攻击猎物。

5)判断 Harris 鹰个体适应度值是否低于种群的平均适应度值。若符合,则利用高斯扰动策略对 Harris 鹰个体进行位置更新。

6)判断是否满足设定的达到最大迭代次数的停止条件。若符合,则将全局最优超参数组设为 SALSTM 的参数;若不符合,则返回步骤 2)。

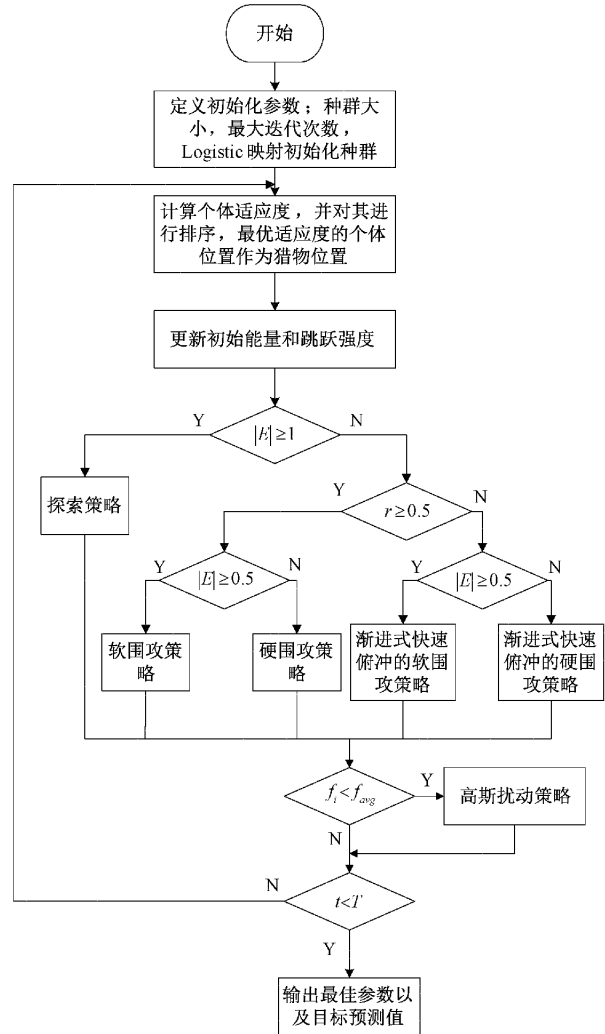


图 13 CHHO-SALSTM 模型流程

## 4 基于 CHHO-SALSTM 模型的火场温度预测

### 4.1 硬件平台设置

在计算在计算机硬件方面,本实验在 Windows10 专

业版 64 bit 的操作系统下进行深度学习的模型训练,配置为 Intel (R) Core (TM) i5-7300HQ CPU @ 2.50 GHz, 16 GB 的内存。在软件配置方面,本模型使用 Python 编程语言和 TensorFlow 框架进行实验。

#### 4.2 实验数据采集

参照 ISO9705 火灾标准实验间,设计的标准实验间尺寸为 3.6 m × 2.4 m × 2.5 m。标准实验房间的门设在 2.4 m × 2.5 m 的短墙的中心,门的尺寸为 0.8 m × 2 m。火灾反应设置为尼龙燃烧。燃烧物体积为 0.5 m × 0.5 m × 0.1 m 的立方体,设定燃烧物热释放速率为 5 000 kW/m<sup>2</sup>。设定输出结果参数为 10 000。为简化实验,房间内部没有放置家具等物品,房间门设置为畅通,默认顶部无排风口,风速默认设置为 0 m/s,仿真环境设置为采用自然排烟,初始环境温度为 22 °C,模拟时间为 600 s。采用 PyroSim 自带的矩形网格形式,进行空间网格划分,设定的单元网格尺寸为 0.25 m × 0.25 m × 0.25 m。整个网格区域总共有 3 840 个单元网格。将火场温度值达到 600 °C 设定为轰然发生的临界温度。在 SALSTM 模型训练前,先对原始的火场数据进行归一化处理,其公式如式(12)所示。

$$x_j = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (12)$$

式中: $x_j$  为第  $j$  个样本归一化后的值; $x_{\max}$ 、 $x_{\min}$  分别为数据集中最大值和最小值。

#### 4.3 CHHO-SALSTM 模型优化及训练

为了更加精准的建立火场温度预测模型,采用多组传感器的平均值作为模型的训练数据,为了检验 CHHO 算法的性能,本文将改进后与原始算法、粒子群算法,进行对比试验。设定神经单元数搜索范围[100, 300],迭代次数搜索范围[10, 200],输入批量搜索范围[32, 128],学习率搜索范围[0.01, 1],最大训练轮数为 50。训练过程中,利用 CHHO 不断地调整 SALSTM 中神经元个数、迭代次数、输入批量与自注意力机制神经元数量 4 个模型参数。

#### 4.4 评价指标

为了验证 CHHO-SALSTM 预测模型的性能,本研究采用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)和平均百分比误差(mean absolute percentage error, MAPE)用来评价各类模型的预测性能,公式如式(13)~(15)所示。

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{x}_i - x| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x)^2} \quad (14)$$

$$MAPE = \sum_{i=1}^n \left| \frac{\hat{x}_i - x}{x} \right| \times \frac{100}{n} \quad (15)$$

式中: $\hat{x}_i$  为火场温度实际值, $x$  为火场温度预测值。MAE、RMSE 和 MAPE 越低说明预测值越接近实际值,预测性能就越好。

#### 4.5 实验结果分析

本文实验结果以 RMSE、MAE、MAPE 作为评价指标,将 CHHO-SALSTM 模型分别与 HHO-SALSTM、PSO-SALSTM、LSTM 模型进行相同时间步的预测,模型的仿真预测结果如图 14~17 所示。




图 14 温度预测结果

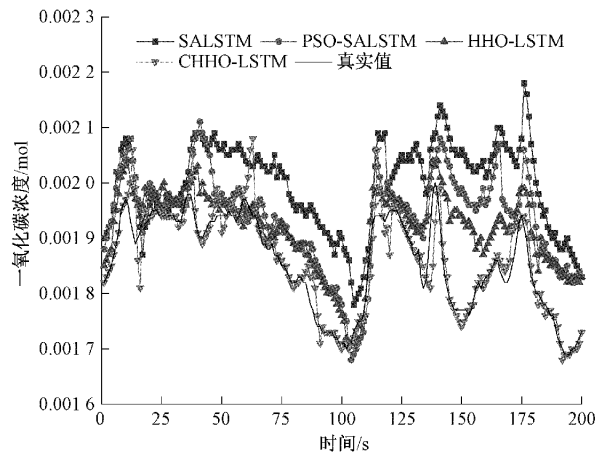


图 15 二氧化碳浓度预测结果

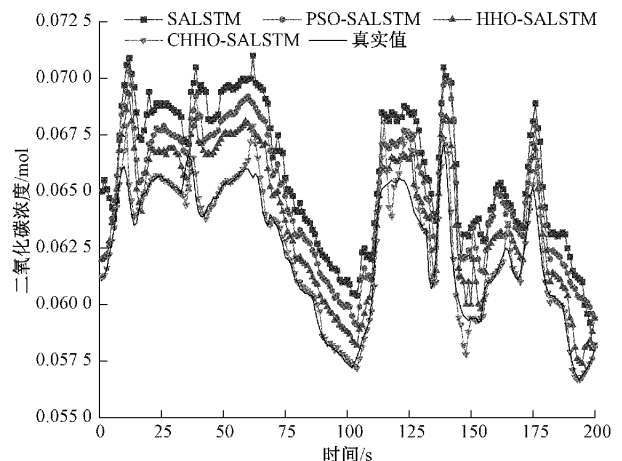


图 16 一氧化碳浓度预测结果




图 17 烟雾浓度预测结果

从图 14 温度预测结果可以清楚的看到 CHHO-SALSTM 模型预测曲线最接近真实值,可以能够描述温度的变化趋势,但是在某些时刻也会出现一定的误差。

从图 15 二氧化碳浓度预测结果可以看出 CHHO-SALSTM 模型预测曲线与 HHO-SALSTM 模型预测曲线比较接近,但是在前半段明显 CHHO-SALSTM 模型的预测效果更好。

从图 16 一氧化碳浓度预测结果可以看出所有的预测模型在某一段区间内均有较大的误差,原因一氧化碳浓度值变化缓慢,模型不容易进行预测,从而导致所有模型的预测结果误差较大。

从图 17 烟雾浓度预测结果可以看出, CHHO-SALSTM 模型的预测曲线的拟合程度高于其他 3 种模型,预测值更加接近真实值,可以较好的预测烟雾浓度的值。

不同火场参数预测模型仿真误差指标如表 3 所示,可以看出经过相关算法优化后的组合模型的预测效果明显优于单一的 SALSTM 神经网络模型。其中,在组合模型中,CHHO-SALSTM 在温度预测、二氧化碳浓度、一氧化碳浓度、烟雾浓度中预测中,相比于 SALSTM、PSO-SALSTM、HHO-SALSTM 模型误差值均是最低,预测精度最好,能够有效地应用于火场环境的预测中。

为了验证模型的效果,将仿真实验中尼龙燃烧换成乙醇燃烧,获取验证数据集。由于乙醇燃烧不产生一氧化碳气体,因此选择温度、烟雾浓度、二氧化碳浓度预测温度的变化。选取乙醇燃烧前期燃烧数据作为模型的测试集,进行未来 50 s 的预测,对温度的预测结果如图 18 所示,误差值如图 19 所示。

从图 18~19 可以看到模型在前期可以预测火场的温度变化趋势,随着时间的推移误差变大,但是误差值均控制在 7%之内,说明本模型可以有效预测室内火灾的环境信息。

表 3 不同火场参数预测模型仿真误差指标

预测内容	预测模型	RMSE	MAE	MAPE
温度	SALSTM	21.91	20.59	0.037
	PSO-SALSTM	14.80	13.87	0.028
	HHO-SALSTM	11.21	9.27	0.019
	CHHO-SALSTM	9.06	7.94	0.017
二氧化碳浓度	SALSTM	23.04	22.89	0.045
	PSO-SALSTM	15.63	16.71	0.038
	HHO-SALSTM	12.28	14.24	0.030
一氧化碳浓度	SALSTM	16.88	21.02	0.064
	PSO-SALSTM	10.38	14.72	0.051
	HHO-SALSTM	7.48	10.80	0.032
烟雾浓度	CHHO-SALSTM	6.37	8.41	0.029
	SALSTM	23.41	36.86	0.046
	PSO-SALSTM	16.74	28.33	0.029
	HHO-SALSTM	12.58	17.94	0.019
CHHO-SALSTM	11.04	15.38	0.015	




图 18 温度预测结果




图 19 温度误差值

### 5 结 论

针对火场环境预测,提出了基于 CHHO-SALSTM 火



场环境预测模型。通过对不同火场参数的仿真对比,发现该模型具有较高的精准度。针对哈里斯鹰优化种群多样性差、全局探索和局部开发能力不平衡的问题,采用 Logistic 映射的方法初始化种群和余弦权重因子对其进行改进,高斯扰动策略跳出局部最优。通过实验仿真对比发现其寻优能力有了较大的提升,对 SALSTM 火场环境预测能力起到了较好的作用。

### 参考文献

- [1] 柳浩,李淮江,房腊早.基于多传感器的火灾监测及小型灭火系统研究[J].电子测量技术,2021,44(5):11-15.
- [2] 程耀,谢华,朱长发,等.基于多路传感器室内火情报警系统的设计[J].国外电子测量技术,2019,38(10):137-140.
- [3] 王洪欣,查晓雄.建筑室内火灾温度的预测分析[J].建筑结构,2017,47(23):46-49.
- [4] 杨倩,杨瑞霞,徐小峰.基于FDS的中庭式教学楼火灾数值模拟[J].安全,2022,43(4):10-17.
- [5] 于洋,曹正罡,孙瑛,等.火灾条件下气承式膜结构内压FDS模拟[J].东北大学学报,2022,43(8):1176-1182.
- [6] 胡振圆,王路平,聂金龙.基于主成分分析法的火灾预测模型研究[J].科学技术创新,2021(22):171-173.
- [7] ZHANG T, WANG W, WONG H Y, et al. Real-time forecast of compartment fire and flashover based on deep learning [J]. Fire Safety Journal, 2022, 130(4): 103-126.
- [8] 许春芳,乔元健,李军.基于LSTM和RBF-BP深度学习模型的火灾预测方法[J].齐鲁工业大学学报,2020,34(3):53-59.
- [9] WU X Q, PARK Y, LI A, et al. Smart detection of fire source in tunnel based on the numerical database and artificial intelligence[J]. Fire Technology, 2020, 57(2): 657-682.
- [10] KOU L Y, WANG X Z, GUO X J, et al. Deep learning based inverse model for building fire source location and intensity estimation [J]. Fire Safety Journal, 2021,121:103310.
- [11] 尹云飞,林跃江,黄发良,等.基于趋势特征向量的火灾烟气流动与温度分布预测[J].计算机科学,2021,48(7):299-307.
- [12] 孟晓静,陈佳静.卷积与长短期记忆网络在火灾源强实时预测中的应用[J/OL].安全与环境学报:1-8[2023-03-19]. DOI: 10.13637/j.issn.1009-6094.2022.2429.
- [13] HEIDARI A, MIRJALILI S, FARIS H. Harris Hawks optimization: Algorithm and applications[J]. Future Generation Computer Systems, 2019,32(3):849-872.
- [14] 吴丁杰,温立书.一种基于哈里斯鹰算法优化的核极限学习机[J].长江信息通信,2021,34(11):45-46.
- [15] 谢渊,高玮,汪义伟,等.基于哈里斯鹰优化遗传规划的钢筋混凝土地下结构硫酸盐腐蚀寿命预测[J].土木工程学报,2022,55(4):33-41.
- [16] 展广涵,王雨虹,刘昊.混合策略改进的哈里斯鹰优化算法及其应用[J].传感技术学报,2022,35(10):1394-1403.
- [17] 李金颖,马天阳.基于改进哈里斯鹰算法优化核极限学习机的短期电网负荷预测研究[J].电力科学与工程,2023,39(1):52-60.
- [18] 徐武,汤弘毅,杨昊东,等.基于ISSA优化的Elman神经网络短期电力负荷预测[J].扬州大学学报,2022,25(1):37-42.
- [19] 张文帅,王占刚.基于改进麻雀算法优化深度极限学习机的缺失数据预测[J].电子测量技术,2022,45(15):63-67.
- [20] 胡青,龚世才,胡珍.基于改进麻雀搜索算法的空气量指数预测[J].广西科学,2022,29(4):642-651.
- [21] 张帅涛,蒋品群,宋树祥,等.基于注意力机制和CNN-LSTM融合模型的锂电池SOC预测[J].电源学报,2022,9(27):1-15.
- [22] 祖林禄,柳平增,赵妍平,等.基于SSA-LSTM的日光温室环境预测模型研究[J].农业机械学报,2023,1(4):1-14.

### 作者简介

王永东,博士,讲师,主要研究方向为时空大数据建模、火场温度预测。

E-mail: ydwang@zzuli.edu.cn

袁凯鑫,硕士研究生,主要研究方向为火场温度预测。

E-mail: 2603211978@qq.com

曹祥红(通信作者),硕士,教授,主要研究方向为建筑电气与智慧消防。

E-mail: caoxhong@zzuli.edu.cn