

DOI: 10.13382/j.jemi.B2508429

参数优化 CNN-BiLSTM-Attention 的 船舶火灾辨识方法*

刘林凡^{1,2} 周丽芸³

(1. 华东交通大学电气与自动化工程学院 南昌 330000; 2. 华东交通大学控制科学与工程流动站 南昌 330000;
3. 江西工业贸易职业技术学院信息工程系 南昌 330000)

摘要:针对现有船舶火灾辨识准确率不高问题,提出了一种融合注意力机制、卷积神经网络(convolutional neural network, CNN)和双向长短期记忆网络(bidirectional long short term memory, BiLSTM)的船舶火灾辨识方法。使用火灾动力学模拟工具(fire dynamics simulator, FDS)建立了3层甲板渡轮火灾仿真模型,利用传感器采集了船舶火灾过程的温度、一氧化碳浓度和能见度数据。随后采用CNN提取火灾数据的纵向特征,并通过降维压缩数据长度,减少模型的训练参数;搭建基于BiLSTM的级联深度学习神经网络,提取火灾数据横向特征,并在输出层融合注意力机制。此外,为了提升灰狼优化算法的收敛速度,将混沌博弈算法引入该算法,提出了改进的灰狼优化算法。最后,采用改进的灰狼优化算法优化CNN-BiLSTM-Attention模型,并利用该模型进行了两个场景的船舶火灾辨识实验。结果表明,相比于其他火灾分类方法,在船舶火灾数据样本不均衡情况下,所提方法火灾辨识的准确率达到100%,能够满足工程实际需求。

关键词: 火灾辨识; 船舶; 注意力机制; 双向长短期记忆网络; 灰狼优化算法

中图分类号: TN60; U674.11 **文献标识码:** A **国家标准学科分类代码:** 520.2010

Parameter-optimized CNN-BiLSTM-Attention approach for ship fire identification

Liu Linfan^{1,2} Zhou Liyun³

(1. School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330000, China;
2. Postdoctoral Research Station of Control Science and Engineering, East China Jiaotong University, Nanchang 330000, China;
3. Department of Information Engineering, Jiangxi Industry & Trade Vocational and Technical College, Nanchang 330000, China)

Abstract: This study proposed a ship fire identification approach that integrates an attention mechanism, a convolutional neural network (CNN) and a bidirectional long short term memory network (BiLSTM) to address the low accuracy of existing methods. A three-deck ferry fire simulation model was constructed using the fire dynamics simulator (FDS), and sensors were used to collect temperature, carbon monoxide, and visibility data from the simulated ship fire process. A CNN was employed to extract longitudinal features from fire data, while dimensionality reduction was used to compress data length and to reduce the number of model training parameters. A cascaded deep learning neural network based on BiLSTM was established to extract transverse features from fire data, where an attention mechanism was incorporated at the output layer. Furthermore, to accelerate convergence, an improved grey wolf optimization algorithm was developed by integrating the chaotic game algorithm. The improved algorithm was applied to optimize the CNN-BiLSTM-Attention model, which was subsequently utilized to perform ship fire identification experiments under two scenarios. The experimental results indicated that, despite the imbalance in ship fire data samples, the proposed approach outperformed other fire classification methods, achieving 100% fire identification accuracy and satisfying practical engineering requirements.

Keywords: fire identification; ship; attention mechanism; bidirectional long short-term memory; grey wolf optimization

0 引言

海洋运输是世界贸易和运输网络的重要组成部分,现代船舶机电系统密集、危险品运输频繁容易出现火灾事故^[1]。研究发现船舶火灾一旦发生,将会造成人员伤亡和财产损失,船舶火灾事故约占海难事故的11%。船舶火灾发生时产生的浓烟,将会降低船舶水平通道和垂直通道的能见度,释放的有毒物质严重影响人身安全。船舶结构越来越复杂,火灾事故发生的概率也逐渐增加。然而,现有的船舶火灾辨识技术不能满足要求,为了提升船舶安全管理水平,急需研究船舶火灾辨识方法^[2]。

近年来,国内外学者对船舶火灾问题进行了深入研究。Lee等^[3]设计了船舶消防安全评估系统,能够提供火势进展和疏散时间的实时数据。Ergasheva等^[4]创建了船舶数据集,提出基于实时目标检测算法的船舶火灾检测模型。Xie等^[5]为了有效评估船舶火灾疏散性能,采用结合火灾数据和多智能体疏散仿真模型的方法,研究了火灾产物对船舶乘客疏散的影响。Liu等^[6]采用FDS模拟邮轮的单源和多源火灾场景,提出了时变等效权重迪杰斯特拉算法为乘客规划最佳疏散路线。Yar等^[7]研究基于双注意网络的火灾探测方法,实现了多种火灾数据的准确分类。Li等^[8]构建结合文本挖掘技术和K均值聚类算法的船舶火灾辨识方法,为船舶火灾风险管理做出贡献。Kim等^[9]研究了基于深度学习和卷积神经网络的火灾检测模型,实现了火灾的精确探测。这些船舶火灾研究方法为开展船舶火灾辨识提供技术借鉴。

实际上在船舶火灾辨识方面,相关研究成果已在学术界获得广泛认可。传统的火灾辨识方法包括基于模型的方法^[10-11]和基于信号分析的方法^[12-13],此类方法需要专业的知识,具有一定的局限性。随着人工智能技术的

发展,机器学习和深度学习方法在风险评估方面取得了长足发展。Sun等^[14]提出了结合决策树和相关性测量的改进随机森林算法,提高了分类准确率。Hasan等^[15]构建了卷积神经网络的分类模型,该方法在手写数字数据集上的分类准确率高达98%。Wu等^[16]研究了卷积神经网络的多模态遥感数据分类方法。Touvron等^[17]设计了多层感知器的前馈网络模型,该模型在大型可视化数据库上取得了更高的分类准确率。杨春雨等^[18]为了解决船舶火灾早期预报的漏报问题,提出了一种模糊奖惩机制的多源信息融合方法。由于船舶火灾受多变环境及火情快速发展的影响,传感器获取的火灾数据表现出较强的非线性特性。但现有方法在火灾特征提取方面不够深入,未能有效捕捉数据中的关键信息,限制了火灾辨识的准确性。

针对上述问题,本文提出了一种融合注意力机制(Attention)、CNN和BiLSTM的船舶火灾辨识方法。建立CNN-BiLSTM-Attention模型,实现了船舶火灾特征的提取和分类。引入混沌博弈算法(chaos game optimization, CGO)改进传统的灰狼算法(grey wolf optimization, GWO),并优化了CNN-BiLSTM-Attention模型的相关参数,提升了模型的火灾辨识准确率。

1 船舶火灾仿真模型

1.1 渡轮

FDS能够模拟复杂场景下烟气的扩散轨迹、温度的动态变化过程,以及有毒气体分布情况。本研究以一艘拥有3层甲板的渡轮为研究对象,建立火灾仿真模型。该船舶第1层甲板的火源位置设置如图1所示。设置了13组传感器,每组传感器包括一氧化碳(carbon monoxide, CO)浓度传感器、温度传感器和能见度传感器,火源点分别为图2中小方块处。




图1 渡轮的1层甲板平面布局

Fig. 1 Layout of the first deck of the ferry




图2 传感器的位置

Fig. 2 Location of sensors

网格是 FDS 的最小计算单位,网格划分精度直接影响计算时间和计算结果的精度。火源直径如式(1)、(2)所示。

$$d^* = \left(\frac{Q}{\rho_0 c_p T_0 \sqrt{g}} \right)^{2/5} \quad (1)$$

$$4 \leq \frac{d^*}{\psi_x} \leq 16 \quad (2)$$

表 1 船舶舱内危险等级分类

Table 1 Critical values of fire products

	危险等级 1	危险等级 2	危险等级 3	危险等级 4
温度/°C	0~40	40~60	60~90	>90
CO 浓度/(mol/mol)	5×10^{-4}	$5 \times 10^{-4} \sim 8 \times 10^{-4}$	$8 \times 10^{-4} \sim 1.2 \times 10^{-3}$	1.2×10^{-3}
能见度/m	≥ 15	10~15	5~10	≤ 5

本文在 FDS 中建立了船舶火灾仿真模型,火灾热释放速率为 5 000 kW。最初网格大小设置为 0.8 m × 0.8 m × 0.8 m,然后逐渐细化,最终网格大小设置为 0.5 m × 0.5 m × 0.5 m。渡轮火灾仿真中主要使用的材料属性如表 2 所示。通常,船舶火灾的燃烧模型为非稳态模型。该模型的数学表达式为:

$$\dot{Q} = \theta t^2 \quad (3)$$

式中: \dot{Q} 为单位时间内的火灾热释放速率; θ 为增长系数; t 为时间。

表 2 主要材料的属性

Table 2 Properties of key materials

参数	铁	铝	木材	石膏
辐射率(-)	0.8	0.55	0.92	0.8
密度/(kg·m ⁻³)	7 850	2 670	500	1 050
比热容/(kJ·kg ⁻¹ ·K ⁻¹)	0.48	0.8	2.5	1.0
热导率/(W·m ⁻¹ ·K ⁻¹)	58.2	237	0.35	330

渡轮火灾烟气扩散情况如图 3 所示,由于火灾产生的浓烟迅速向上扩散,烟气触及顶部后形成顶棚射流效应,并开始向水平方向扩散。随着火灾的发展,烟气逐渐向下沉积形成浓烟。




图 3 渡轮火灾烟气扩散情况

Fig. 3 Smoke dispersion characteristics in the ferry fire

火灾不同时刻 CO 浓度变化如图 4 所示。火灾发生 120 s 时,除火源附近的 CO 浓度达到 5×10^{-4} mol/mol,渡轮第 1 层甲板其他区域的 CO 浓度都没有超过

式中: d^* 为火源的直径; ψ_x 为网格单元的尺寸; Q 为火灾释放的总热量; ρ_0 为空气密度; c_p 为空气的比热容; T_0 为环境温度; g 为重力加速度。

为了降低船舶火灾对人员生命的威胁,将船舶舱内危险等级分类划分如表 1 所示^[19]。

3×10^{-4} mol/mol;火灾发生 240 s 时,渡轮的酒吧区、综合区、集合区 A、B 和 C 的 CO 浓度均高于 4.5×10^{-4} mol/mol,超市区的 CO 浓度低于 3×10^{-4} mol/mol;在火灾发生 360 s 时,酒吧区域的 CO 浓度达到 1.05×10^{-4} mol/mol。




图 4 渡轮火灾不同时刻的 CO 浓度

Fig. 4 CO concentration at different stages of the ferry fire

火灾不同时刻能见度如图 5 所示。火灾发生 120 s 时,渡轮第 1 层甲板的酒吧区、综合区的能见度低于 10 m;火灾发生 240 s 时,渡轮第 1 层甲板的酒吧区、综合区和集合区 A 的能见度低于 10 m,其他区域的能见度高于 10 m;火灾发生 360 s 时,渡轮第 1 层甲板的各个区域能见度均低于 10 m。




图 5 渡轮火灾不同时刻能见度

Fig. 5 Visibility at different stages of the ferry fire

火灾不同时刻温度变化如图 6 所示。火灾发生 120 s 时,火源点的温度迅速高于 100 °C,酒吧区、综合区和集合区 A 的温度高于 36 °C;火灾发生 240 s 时,渡轮第 1 层甲板的酒吧区和综合区的温度高于 52 °C,其他区域的温度低于 44 °C;火灾发生 360 s 时,渡轮第 1 层甲板的酒吧区的温度高于 84 °C。火灾实验中,在渡轮火源点设置 CO 浓度、温度和能见度探测器,记录的 CO 浓度数据、温度数据、能见度数据分别如图 7~9 所示。设置的传感器组之间的距离为 10 m。




图 6 火灾不同时刻温度

Fig. 6 Temperature at different stages of the ferry fire

如图 7 所示,火灾发生 38 s 时,火源点的 CO 浓度超过 5×10^{-4} mol/mol。如图 8 所示,火源点的温度在 25 s 超过 60 °C,如图 9 所示,渡轮火源点的能见度在 10 s 下降到 10 m 以下。




图 7 渡轮火源点 CO 浓度

Fig. 7 CO concentration at the fire source of the ferry

如图 10~12 所示,传感器组 5 距离火源点较远,所以 CO 浓度、温度和能见度没有变化,传感器组 5 距离船舶的距离为 50 m。火灾发生时,乘客受到烟气的影响最大,导致船舶内部 CO 浓度升高,环境能见度显著下降。

2 深度神经网络的火灾辨识模型

CNN-BiLSTM-Attention 的船舶火灾辨识模型采用以




图 8 渡轮火源点温度

Fig. 8 Temperature at the fire source of the ferry




图 9 渡轮火源点能见度

Fig. 9 Visibility at the fire source of the ferry




图 10 不同位置的 CO 浓度

Fig. 10 CO concentration at different locations

两个卷积层为核心的纵向特征提取模块,对输入数据进行特征挖掘;使用以 BiLSTM 模型为核心的横向特征提取模块,对经过纵向特征提取后的数据进一步处理。这两个模块前后级联,分别从纵向特征和横向特征两个维度,充分挖掘数据中隐藏的特征信息,模型输出层添加了




图 11 不同位置的温度

Fig. 11 Temperature at different locations




图 12 不同位置的能见度

Fig. 12 Visibility at different locations

注意力机制。相较于复杂的深度学习网络结构,该模型更为简洁,能够在火灾发生时对渡轮火灾程度进行辨识。

2.1 卷积神经网络模型

纵向特征提取模块的核心是 CNN, CNN 能够自动提取火灾数据内部特征,依托局部连接和权重共享机制,降低模型计算复杂度,提升火灾数据特征的提取效率。通过多次卷积与池化操作, CNN 能够逐步提取关键的局部特征。以当前时刻传感器组监测的温度、能见度和 CO 浓度数据作为输入,本文 CNN 模型结构如图 13 所示,卷积层用于从原始输入中提取高维局部特征。在卷积层后加入分段线性函数(rectified linear unit, ReLU),提升模型的非线性表达能力。通过最大池化进行特征降维,同时保留关键信息。在池化层后引入批量归一化操作,规范化特征分布至标准正态形式,加快模型收敛速度。

2.2 BiLSTM 模型

横向特征提取模块的核心为 BiLSTM,该模型由分别沿正向与反向处理序列的两组 LSTM 单元构成,能够同

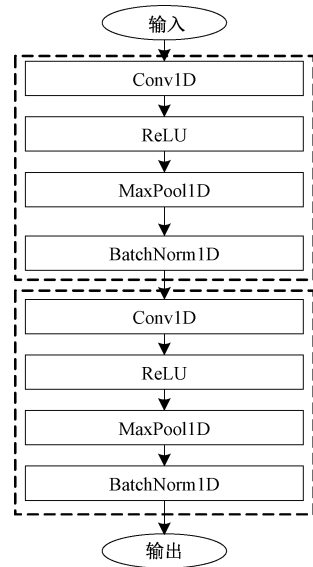


图 13 CNN 模型

Fig. 13 CNN model

时捕捉时间序列中前后状态的特征信息。横向特征提取的主要是历史时刻传感器组监测的温度、能见度和 CO 浓度数据。通过挖掘当前数据与历史时刻之间的潜在关联, BiLSTM 有效提升了特征表达能力。BiLSTM 模型网络结构如图 14 所示。




图 14 BiLSTM 模型

Fig. 14 BiLSTM model

本文使用 BiLSTM 作为编码器。BiLSTM 模型使用两个隐藏层从火灾特征数据提取信息,并且两者都连接在同一输出层中,可以通过两个相互连接的隐藏层同时处理不同方向的顺序数据:前者处理使用 t 从 $1 \sim T$ 的前向隐藏层;后者使用 t 从 $T \sim 1$ 的后向隐藏层。BiLSTM 的相关计算如下:

$$\vec{h}_t = LSTM(x_t, \vec{h}_{t-1}) \quad (4)$$

$$\overleftarrow{h}_t = LSTM(x_t, \overleftarrow{h}_{t-1}) \quad (5)$$

$$y_t = \sigma(W_y \cdot [\vec{h}_t, \overleftarrow{h}_t] + b_y) \quad (6)$$

式中:箭头表示处理方向; y_t 为最终输出; b_y 为输出层的偏置; x_t 为输入; h_t 表示 BiLSTM 的最终隐藏状态,由前向隐藏层状态 \vec{h}_t 和后向隐藏层状态 \overleftarrow{h}_t 拼接而成,因此,

最终的隐藏状态 h_t 计算如下:

$$h_t = u_t \cdot \vec{h}_t + v_t \cdot \overleftarrow{h}_t + b_t \quad (7)$$

式中: u_t 和 v_t 分别是前向隐藏层和后向隐藏层对应的权值; b_t 表示在 t 时刻隐藏状态的偏置。

2.3 Attention 模型

Attention 模型为输入序列中各位置的信息分配差异化权重,促使模型聚焦于有效信息,有效提升模型性能。Attention 模型的实现通常包含以下步骤:对输入序列 $y = [y_1, y_2, \dots, y_n]$ 进行编码,得到 1 组查询向量 q 。通过打分之间的相似度 $[s_1, s_2, \dots, s_n]$, 打分函数定义如下:

$$s(y_i, q) = V^T \tanh(Wy_i + Uq) \quad (8)$$

式中: V, W, U 均为参数待学习的矩阵。利用 Softmax 函数进行归一化,得到每组输入向量的权重 a_i , 计算式如下:

$$a_i = \text{Softmax}[s(y_i, q)] = \frac{\exp[s(y_i, q)]}{\sum_{i=1}^n \exp[s(y_i, q)]} \quad (9)$$

根据权重和对应的值向量计算加权和,计算得到火灾风险分类输出 a 。

$$a = \sum_{i=1}^n a_i \quad (10)$$

3 参数寻优

3.1 改进的灰狼优化算法

GWO 是模拟灰狼捕食行为的群体智能优化算法, GWO 和 CGO 都是发展较为成熟的优化算法^[20-21]。在全局搜索能力方面,CGO 优于 GWO。在迭代后期,灰狼种群会趋向于领导狼聚集,而 CGO 则具有随机扰动特性,并引入了混沌分形理论。在两者融合的过程中,混沌分形理论使每只灰狼个体在后期搜索过程中朝向领导狼聚集。本文提出了融合 GWO 和 CGO 的 GWCG 算法,通过该算法获取最优初始学习率、最优 L2 正则化系数和最优自注意力机制中的头数。

1) 动态权重机制

每只狼更新后的位置 $\vec{X}(t+1)$, 取决于 α 狼、 β 狼和 δ 狼的平均值,并未给予 α 狼作为领导者应有的重要地位,如式(11)所示^[22]。

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (11)$$

式中: $\vec{X}_1, \vec{X}_2, \vec{X}_3$ 分别表示 3 只领导狼的位置。

为了解决此种跟随行为导致算法收敛速度慢问题,本文提出引入动态权重机制,以增强狼在引导个体狼位置更新过程中的领导作用。权重的计算方法如式(12)~

(16)所示。

当 $f(\vec{X}_\beta) = \infty$ 时,计算式如下:

$$(Weight_\alpha, Weight_\beta, Weight_\delta) = \left(\frac{1}{3}, \frac{1}{3}, \frac{1}{3}\right) \quad (12)$$

当 $f(\vec{X}_\alpha) \neq \infty$ 和 $f(\vec{X}_\beta) = \infty$ 时,计算式如下:

$$(Weight_\alpha, Weight_\beta, Weight_\delta) = (1, 0, 0) \quad (13)$$

当 $f(\vec{X}_\alpha) \neq \infty$ 且 $f(\vec{X}_\beta) \neq \infty$ 且 $f(\vec{X}_\delta) \neq \infty$ 时,计算式如下:

$$(Weight_\alpha, Weight_\beta, Weight_\delta) = (f(\vec{X}_\alpha) + f(\vec{X}_\beta)) \times \left(\frac{1}{f(\vec{X}_\alpha)}, \frac{1}{f(\vec{X}_\beta)}, 0\right) \quad (14)$$

其他,计算式如下:

$$(Weight_\alpha, Weight_\beta, Weight_\delta) = (f(\vec{X}_\alpha) + f(\vec{X}_\beta)) \times \left(\frac{1}{f(\vec{X}_\alpha)}, \frac{1}{f(\vec{X}_\beta)}, \frac{1}{f(\vec{X}_\delta)}\right) \quad (15)$$

$$\vec{X}(t+1) = \frac{Weight_\alpha \times \vec{X}_1 + Weight_\beta \times \vec{X}_2 + Weight_\delta \times \vec{X}_3}{Weight_\alpha + Weight_\beta + Weight_\delta} \quad (16)$$

式中: $f(\vec{X}_\alpha), f(\vec{X}_\beta), f(\vec{X}_\delta)$ 分别是第 α, β, δ 只狼的适应度值; $Weight_\alpha, Weight_\beta, Weight_\delta$ 分别对应的权重。

本文引入收敛因子 a_0 , 增强算法的局部搜索功能,实现更高搜索精度。

$$a_0 = 2 - 2 \times \log\left(\frac{1 + (\exp(1) - 1) \times \frac{it}{Maxit}}{Maxit}\right) \quad (17)$$

式中: it 为当前迭代次数; $Maxit$ 为最大迭代次数。

2) 混沌博弈机制

CGO 算法使用 3 个种群个体构建临时三角形形成候选个体集合,该方法增强了算法局部搜索能力。在搜索空间内利用个体狼 $\vec{X}_i, \vec{X}_\alpha$ 以及 \vec{X}_{mean} (代表随机选定个体种群的均值) 构建临时三角形。在此阶段,选定个体狼 $\vec{X}_i, \vec{X}_\alpha$ 和 \vec{X}_{mean} 进行信息交互,并生成新的个体狼后代。

同时,对 \vec{X}_α 和 \vec{X}_{mean} 执行相同的操作。相关的计算过程如下:

$$\vec{X}_i^1 = \vec{X}_i + \alpha_i \times (\beta_i \times \vec{X}_\alpha - \gamma_i \times \vec{X}_{mean}) \quad (18)$$

$$\vec{X}_i^2 = \vec{X}_\alpha + \alpha_i \times (\beta_i \times \vec{X}_i - \gamma_i \times \vec{X}_{mean}) \quad (19)$$

$$\vec{X}_i^3 = \vec{X}_{mean} + \alpha_i \times (\beta_i \times \vec{X}_i - \gamma_i \times \vec{X}_\alpha) \quad (20)$$

式中: 变量 α_i 表示一个随机值,用于模拟狼群运动的限制条件; 而变量 β_i 和 γ_i 则是随机整数,取值为 2。

$$\vec{X}_i^4 = \vec{X}_{\min} + rand(\vec{X}_{\max} - \vec{X}_{\min}) \quad (21)$$

式中: \vec{X}_{\max} 和 \vec{X}_{\min} 分别表示搜索空间中允许的最大值和最小值; $rand$ 是 $[0, 1]$ 的随机数。

4 船舶火灾辨识框架

参数优化 CNN-BiLSTM-Attention 的船舶火灾辨识方法实现过程如下:

- 1) 采用 FDS 建立渡轮的火灾仿真模型, 设置火源位置和传感器位置, 进行船舶火灾仿真, 采用传感器采集温度、能见度和 CO 浓度数据;
- 2) 将传感器采集的温度、能见度和 CO 浓度数据进行归一化, 将处理后的火灾数据输入到 CNN-BiLSTM-Attention 模型;
- 3) 提出 GWCG 算法, 采用该算法对 CNN-BiLSTM-Attention 模型的初始学习率、L2 正则化系数和自注意力机制中的头数进行优化, 提高船舶火灾辨识的准确率。

5 仿真结果与分析

5.1 算法寻优结果对比

从标准测试函数库中选择 4 个典型测试函数进行寻优性能测试, 函数选择 CEC2020 中的 $f_1(x)$ 、 $f_2(x)$ 、 $f_4(x)$ 和 $f_8(x)$, 包括单峰函数和多峰函数。为了对比 GWCG 与其他算法的差异, 采用粒子群优化算法 (particle swarm optimization, PSO)、哈里斯鹰优化算法 (harris hawks optimization, HHO)、GWO、GWCG、海马优化算法 (seahorse optimization, SHO) 对 4 个测试函数进行寻优测试, 所有群智能优化算法的设置群个体为 30, 最大迭代次数为 500。寻优结果如表 3 所示, 寻优迭代过程如图 15 所示。实验结果表明, 在函数 $f_1(x)$ 上, GWCG 算法取得的最优值为 110.68, 比其他算法接近最优值。在函数 $f_2(x)$ 和 $f_4(x)$ 上, GWCG 算法在较少的迭代次数获得了最优解。在函数 $f_8(x)$ 上, GWCG 比 GWO 寻优收敛慢, 寻优效果次优。GWCG 算法在 4 个测试函数中均表现出较好的寻优能力, 其结果更接近理论最优值。

表 3 不同优化算法的寻优结果

Table 3 Comparative optimization results of various algorithms

函数	理论值	PSO	HHO	GWO	GWCG	SHO
$f_1(x)$	100	6.3896×10^8	9.4242×10^6	3.8030×10^3	1.1068×10^2	5.0723×10^9
$f_2(x)$	1100	2.1890×10^3	3.3469×10^3	3.1551×10^3	1.1194×10^3	3.0297×10^3
$f_4(x)$	1900	1.9121×10^3	1.9295×10^3	1.9262×10^3	1.9110×10^3	2.2554×10^3
$f_8(x)$	2200	2.3020×10^3	2.3142×10^3	2.3016×10^3	2.3019×10^3	4.1724×10^3

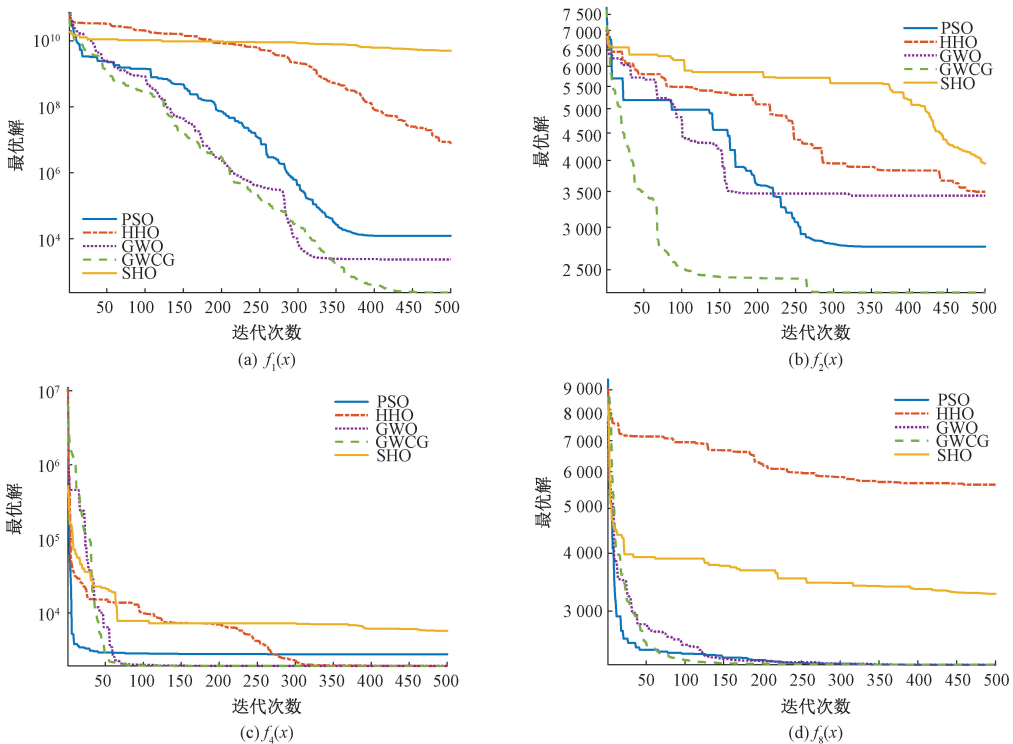


图 15 不同优化算法的迭代过程

Fig. 15 Convergence curves of different optimization algorithms

5.2 消融实验

CNN-BiLSTM-Attention 模型的超参数设置如下:两个二维卷积层卷积核大小分别为 $[1, 1]$ 和 $[1, 1]$,输出通道数依次为32和64。模型采用Adam优化器,设置最大训练轮数为500,初始学习率设为best_lr,L2正则化系数设为best_l2。学习率调整策略采用分段下降,在第400轮训练周期后按0.5的因子进行衰减。GWCG的参数设置如下:搜索个体数量设为10,最大迭代次数为30,待优化参数维度为3,分别为学习率、自注意力机制中的头数以及正则化系数。各参数的取值范围如下:学习率取值范围为 $[10^{-3}, 10^{-2}]$,注意力头数为 $[4, 8]$,正则化系数范围为 $[10^{-4}, 10^{-1}]$ 。

为验证 CNN-BiLSTM-Attention 模型的有效性,设计消融对比实验,采用 CNN、BiLSTM、CNN-BiLSTM、BiLSTM-Attention 4种模型与本文提出模型对船舶火灾进行辨识。消融实验结果及评价指标如表4所示。表4中最大准确率是使用模型进行10次实验得到最佳分类结果,最小准确率是使用模型进行10次实验得到的最差分类结果。平均准确率为10次实验得到的平均值。采用不同模型进行火灾辨识是根据温度、能见度和CO浓度判断当前区域所属的“危险等级”,便于船员制定应急疏散优先级和乘客引导策略。BiLSTM-Attention引入注意力机制提高了船舶火灾辨识精度,CNN-BiLSTM通过考虑火灾数据之间的关联关系同样提高了火灾辨识的精度。本文所提 CNN-BiLSTM-Attention 模型的综合平均准确率最高,比 BiLSTM 高 11.20%。

表4 消融实验评价指标

Table 4 Comparative optimization results of various algorithms (%)

模型	最大准确率	最小准确率	平均准确率
CNN	92.84	87.55	90.36
BiLSTM	88.61	84.63	86.72
CNN-BiLSTM	95.42	91.17	94.25
BiLSTM-Attention	96.39	90.16	93.47
CNN-BiLSTM-Attention	97.62	93.21	96.43

5.3 对比实验

为验证所提模型对船舶火灾辨识效果,将本文模型与常用的蜣螂优化算法(dung beetle optimizer, DBO)优化的径向基函数神经网络(radial basis function network, RBF) DBO-RBF模型、GWO优化的最小二乘支持向量机(least squares support vector machine, LS-SVM) GWO-LSSVM模型和GWO-Transformer模型进行对比。选取火灾发生300s内,传感器组1、2、3、4、5采集的数据进行火灾辨识。DBO-RBF模型的参数设置为:设置种群规模为30,最大迭代次数为30次,优化参数的范围为 $[1, 1000]$ 。GWO-LSSVM模型的参数设置为:设置种群规模

为30,最大迭代次数为30次,优化参数的范围为 $[1, 1000]$ 。如图16所示,GWCG在进化到第5代收敛。如图17和18所示,GWCG-CNN-BiLSTM-Attention模型在不均衡数据的情况下,各个类别的分类准确率均达到了100%。




图16 GWCG的适应度曲线

Fig. 16 Fitness curve of the GWCG

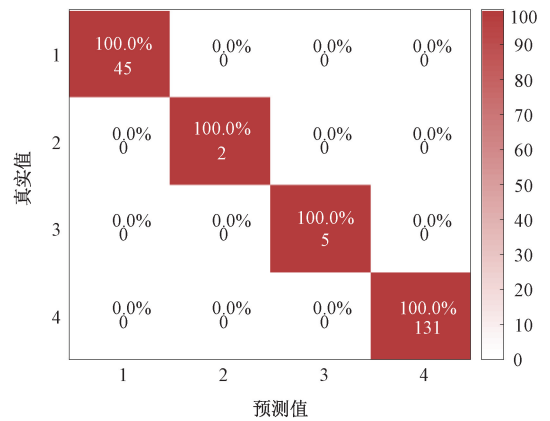


图17 模型的混淆矩阵

Fig. 17 Confusion matrix of the model




图18 模型的分类结果

Fig. 18 Classification results of the model

表 5 为 4 种模型在船舶火灾辨识方面的结果。GWCG-CNN-BiLSTM-Attention 模型在所有指标上均达到 100%，表明该模型稳定性好、鲁棒性强。相比之下，DBO-RBF 模型和 GWO-Transformer 模型的精确率较低，分别为 98.68% 和 98.27%。GWO-LSSVM 方法的精确率、召回率和 F1 分别为 96.48%、97.23%、96.86%，整体表现比较差。

表 5 不同模型分类结果对比

Table 5 Comparison of classification results for different models (%)

模型	精确率	召回率	F1
DBO-RBF	98.68	96.34	97.50
GWO-LSSVM	96.48	97.23	96.86
GWO-Transformer	98.27	98.40	98.34
GWCG-CNN-BiLSTM Attention	100	100	100

5.4 不同场景的火灾辨识结果

为了验证参数优化 CNN-BiLSTM-Attention 模型的有效性，将火源设置在渡轮第 1 层甲板的超市区域（火源点 2）。采用的是火灾发生 300 s 时的数据，由于传感器组 1、2 和 3 等距离火源较远，本文采用传感器组 9、10、11、12、13 采集的火灾数据进行火灾辨识，得到的结果如表 6 所示。

表 6 不同模型分类结果对比

Table 6 Comparison of classification results for different models (%)

模型	精确率	召回率	F1
DBO-RBF	96.67	99.54	98.09
GWO-LSSVM	97.05	98.33	97.46
GWO-Transformer	96.84	95.83	96.48
GWCG-CNN-BiLSTM-Attention	100	100	100

在这 4 种模型中，参数优化 CNN-BiLSTM-Attention 模型在所有评估指标中均表现最佳，精确率、召回率和 F1 均为 100%。DBO-RBF 模型的精确率、召回率和 F1 分别为 96.67%、99.54% 和 98.09%。GWO-LSSVM 模型和 GWO-Transformer 模型的 F1 分数分别为 97.46% 和 96.48%，比前两者效果要差。经实验结果分析可知，参数优化 CNN-BiLSTM-Attention 模型能够完成船舶火灾辨识，该方法具有更高的分类精度。

6 结论

为解决现有船舶火灾辨识方法存在的准确率不高问题，本文提出参数优化 CNN-BiLSTM-Attention 的船舶火灾分类方法。引入 CGO 使每只灰狼个体在后期搜索过程中朝向领导狼聚集，提出了 GWCO。采用 GWCO 优化

CNN-BiLSTM-Attention 模型的学习率、自注意力机制中的头数和正则化系数，提升模型的分类准确率。将 DBO-RBF 模型、GWO-LSSVM 模型和 GWO-Transformer 模型分别与本文提出的模型进行火灾辨识结果对比。结果表明，该模型的精确率、召回率和 F1 值均为 100%。通过该模型船员能够准确识别火灾等级，制定人员疏散措施。然而，该方法还存在不足之处，在应用于不同的船舶极端火灾时，还需要解决数据缺乏问题和模型的泛化能力测试。未来可通过微调网络权重使火灾辨识方法适用于新型船舶的火灾分类，并使用更有效的深度学习模型来优化改进。

参考文献

- [1] TAO R, ZHANG X, REN H, et al. A unified particle method for fluid simulation in ship fire scenario [J]. Ocean Engineering, 2024, 312: 119266.
- [2] LIU J, CHEN H, LI D, et al. Quantitative risk assessment of a spill fire caused by the continuously leaked fuel in a sealed ship engine room [J]. Ocean Engineering, 2024, 303: 117664.
- [3] LEE S M, NAM J H. Performance-based fire and evacuation analysis for real-time response to shipboard fire incidents [J]. Ocean Engineering, 2025, 318: 120166.
- [4] ERGASHEVA A, AKHMEDOV F, ABDUSALOMOV A, et al. Advancing maritime safety: Early detection of ship fires through computer vision, deep learning approaches, and histogram equalization techniques [J]. Fire, 2024, 7(3): 84.
- [5] XIE Q, GUO S, ZHANG Y, et al. An integrated method for assessing passenger evacuation performance in ship fires [J]. Ocean Engineering, 2022, 262: 112256.
- [6] LIU L, ZHANG H, SHI J, et al. Real-time evacuation route optimization in the fire scenarios of cruise ships [J]. Simulation Modelling Practice and Theory, 2023, 129: 102843.
- [7] YAR H, HUSSAIN T, AGARWAL M, et al. Optimized dual fire attention network and medium-scale fire classification benchmark [J]. IEEE Transactions on Image Processing, 2022, 31: 6331-6343.
- [8] LI K, MAO Y, TANG F, et al. Risks identification and fire scenarios determination of ship fires based on improved text mining and K-means algorithm [J]. Fire and Materials, 2025, 49(6): 904-917.
- [9] KIM D H, RUY W S. CNN-based fire detection method on autonomous ships using composite channels composed of RGB and IR data [J]. International Journal of Naval Architecture and Ocean Engineering, 2022, 14: 100489.

- [10] ZIO E, MIQUELES L. Digital twins in safety analysis, risk assessment and emergency management [J]. Reliability Engineering & System Safety, 2024, 246: 110040.
- [11] 陈晓霖, 黄采伦, 赵延明, 等. 基于 PCA 特征优选和 AdaBoost 集成学习的齿轮箱油品状态识别方法[J]. 电子测量与仪器学报, 2024, 38(10): 58-68.
CHEN X B, HUANG C L, ZHAO Y M, et al. Gearbox oil status recognition method based on PCA feature optimization and adaboost ensemble learning[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(10): 58-68.
- [12] 陈万志, 任鹏江, 王天元. 因素空间背景基的流量异常检测基点分类方法[J]. 电子测量与仪器学报, 2024, 38(6): 84-94.
CHEN W ZH, REN P J, WANG T Y. Traffic anomaly detection base on fundamental point classification by factor space background basis[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(6): 84-94.
- [13] MA M, ZHAO G, HE B, et al. XGBoost-based method for flash flood risk assessment[J]. Journal of Hydrology, 2021, 598: 126382.
- [14] SUN Z, WANG G, LI P, et al. An improved random forest based on the classification accuracy and correlation measurement of decision trees[J]. Expert Systems with Applications, 2024, 237: 121549.
- [15] HASAN M D A, BHARGAV T, SANDEEP V, et al. Image classification using convolutional neural networks [J]. International Journal of Mechanical Engineering Research and Technology, 2024, 16(2): 173-181.
- [16] WU X, HONG D, CHANUSSOT J. Convolutional neural networks for multimodal remote sensing data classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 1-10.
- [17] TOUVRON H, BOJANOWSKI P, CARON M, et al. Resmlp: Feedforward networks for image classification with data-efficient training [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(4): 5314-5321.
- [18] 杨春雨, 张闯, 张晓凡. 基于模糊奖惩机制证据理论的船舶火灾预测方法[J]. 系统仿真学报, 2025, 37(8): 2152-2162.
- YANG CH Y, ZHANG CH, ZHANG X F. Ship fire prediction method based on evidence theory with fuzzy reward[J]. Journal of System Simulation, 2025, 37(8): 2152-2162.
- [19] GUAN W, ZHANG C, DONG C, et al. Ship fire and explosion accident statistical analysis based on fault tree and Bayesian network [J]. Fire Safety Journal, 2025, 153: 104358.
- [20] NADIMI-SHAHRAKI M H, TAGHIAN S, MIRJALILI S. An improved grey wolf optimizer for solving engineering problems [J]. Expert Systems with Applications, 2021, 166: 113917.
- [21] TALATAHARI S, AZIZI M. Chaos game optimization: A novel metaheuristic algorithm [J]. Artificial Intelligence Review, 2021, 54(2): 917-1004.
- [22] YANG J, YAN F, ZHANG J, et al. Hybrid chaos game and grey wolf optimization algorithms for unmanned aerial vehicle path planning [J]. Applied Mathematical Modelling, 2025, 142: 115979.

作者简介



刘林凡, 2018 年于湖南工业大学获得硕士学位, 2024 年于武汉理工大学获得博士学位, 现为华东交通大学讲师, 主要研究方向为人员疏散建模和路径优化。

E-mail: 3593@ecjtu.edu.cn

Liu linfan received his M. Sc. degree from Hunan University of Technology in 2018 and Ph. D. degree from Wuhan University of Technology in 2024, respectively. Now he is a lecturer in East China Jiaotong University. His main research interests include occupant evacuation modeling and path optimization.



周丽芸(通信作者), 2015 年于湖南工业大学获得学士学位, 2018 年于湖南工业大学获得硕士学位, 现为江西工业贸易职业技术学院助教, 主要研究方向为人群安全管理。

E-mail: zoliyun@126.com

Zhou liyun (Corresponding author) received her B. Sc. degree from Hunan University of Technology in 2015, M. Sc. degree from Hunan University of Technology in 2018, respectively. Now she is a teaching assistant in Jiangxi Vocational and Technical College of Industry and Trade. Her main research interest includes crowd safety management.