

邓斌, 王玲, 何军, 等. 基于 SSA-CNN 模型的双排开孔圆筒防波堤透射系数预测[J]. 海洋学报, 2024, 46(4): 122–132, doi:10.12284/hyxb2024035

Deng Bin, Wang Ling, He Jun, et al. Prediction of transmission coefficient of double-row perforated cylinder breakwater based on SSA-CNN model[J]. Haiyang Xuebao, 2024, 46(4): 122–132, doi:10.12284/hyxb2024035

基于 SSA-CNN 模型的双排开孔圆筒 防波堤透射系数预测

邓斌^{1,2,4}, 王玲¹, 何军^{3*}, 尹龙斌¹, 蒋昌波^{1,2}, 陈杰^{1,2}, 伍志元^{1,2}

(1. 长沙理工大学 水利与环境工程学院, 湖南 长沙 410114; 2. 水沙科学与水灾害防治湖南省重点实验室, 湖南 长沙 410114; 3. 中交水运规划设计院有限公司, 北京 100007; 4. 水利工程智能建设与运维全国重点实验室, 天津 300072)

摘要: 双排开孔圆筒防波堤是一种新型环境友好型防波堤, 对其消浪特性的研究具有重要工程意义。随着人工智能的发展, 基于机器学习技术求解防波堤水动力学问题成了一种新的研究范式。本文提出基于麻雀搜索算法 (Sparrow Search Algorithm, SSA) 优化卷积神经网络 (Convolutional Neural Network, CNN) 模型, 实现对双排开孔圆筒防波堤透射系数的智能优化预测。结果表明: (1) 确定波高、波周期、波长、波速、排间距、开孔率、水深为影响透射系数的关键因子; (2) 当 SSA-CNN 模型的种群数量为 10 时, 对波浪透射系数预测的 R^2 值达到 0.990 9, 平均相对误差相比单一的 CNN 模型降低了 5.07%。研究成果为利用神经网络研究波浪透射问题提供了一种新的优化预测模型。

关键词: 双排开孔圆筒防波堤; 消浪特性; 麻雀搜索算法; 卷积神经网络; 透射系数

中图分类号: P753

文献标志码: A

文章编号: 0253-4193(2024)04-0122-11

1 引言

双排开孔圆筒防波堤因既满足防波堤的基本掩护效果, 又能促进水体交换, 具有很好的消浪性能和生态环保功能^[1], 具有广阔的应用前景。目前, 众多学者对于防波堤波浪透射问题的研究主要以理论分析、实验模拟及数值计算为主。Stoker 等^[2]、Suvarna 等^[3]、Liu 等^[4]分别从理论、实验、数值计算方面开展了透空式防波堤消浪特性相关研究。但是, 徐天宇^[5]指出研究对象中所涉及的复杂结构物的形状难以快速地通过数值模拟准确描述。而且, 当研究对象具有平面或空间结构时, 需要借助神经网络智能预测。但是, 传统深度神经网络需要人工有限次比选得到模型

的超参数, 其时效性得不到满足。因此, 如何准确快速找出透射系数预测模型的最优网络超参数极具挑战。

随着人工智能的发展, 单一的神经网络模型逐渐应用于水动力学参数求解, 而卷积神经网络因其具有降低网络的复杂度^[6], 以及强鲁棒性和容错能力的特点, 被广泛用于水动力学特征参数预测、湍流模拟等多种流体力学问题, 在数据驱动机制下推动了多个研究领域的突破。其中, 赵西增等^[7]基于深度学习网络模型, 搭建了适用于求解水动力学问题的卷积神经网络预测模型, 实现了透射系数及波形的快速预测求解。Montes-Atenas 等^[8]使用深度神经网络对纯水以及矿浆中的气泡形态运动过程进行了模拟, 研究表明深度神经网络模型可应用于求解复杂的流体力学

收稿日期: 2024-01-11; 修订日期: 2024-03-21。

基金项目: 国家重点研发项目 (2021YFB2601100); 国家自然科学基金项目 (51979015, 51839002); 水利工程仿真与安全国家重点实验室开放基金项目 (HESS-2114); 湖南省科技创新计划项目 (2020RC3037, 20hnpj019)。

作者简介: 邓斌 (1985—), 男, 湖南省衡南县人, 教授, 主要从事河流、海岸动力过程及其数值模拟研究。E-mail: dengbin07@csust.edu.cn

* **通信作者:** 何军 (1981—), 男, 安徽省和县人, 高级工程师, 主要从事水运工程管理与研究。E-mail: hejun@pdiwt.com.cn

问题,并能够对于其中的关键参数进行快速预测。Wei 和 Davison^[9]提出基于卷积神经网络(Convolutional Neural Network, CCN)模型预测近岸区的波浪和水动力,结果表明提出的 CNN 模型是预测包括离岸流在内的近岸过程的有效工具。综上所述, CNN 在预测水动力学问题上表现良好。但是在上述 CNN 模型中,卷积层的卷积核大小、学习率等超参数都是经过有限次数的对比实验后人工选择的,并非最优值^[10]。

在透射系数预测研究方面, Formentin 等^[11]基于 EurOtop 数据集,开发了透射系数预测模型,模型的均方根误差在 0.03~0.05 之间;赵沛泓等^[12]基于 216 组波浪与开孔沉箱物理试验结果,通过差分进化算法优化的支持向量机模型实现了对开孔沉箱防波堤反射系数预测,结果表明优化后的支持向量机模型能够描述各物理量之间的非线性关系; Zanuttigh 等^[13]基于单层人工神经网络模型,预测了浮式防波堤的透射系数;基于神经网络模型预测防波堤对波浪的反射、透射特征,其他学者也做了相关研究^[13-14]。目前,求解防波堤消浪问题的研究主要以单一的传统神经网络为主,仍存在训练成本高、求解精度低等局限性。随着优化算法的提出,越来越多的学者开始将自动迭代寻找最优网络参数的算法融入到传统网络求解模型中。其中, Li 等^[15]、Chen 等^[16]通过麻雀搜索算法(Sparrow Search Algorithm, SSA)^[17]对 LSTM 的超参数进行了寻优,建立了 SSA-LSTM 模型,解决了非线性风速预测问题,预测了最大海底油管点蚀深度,实现了水资源调度预测^[18]。结果表明,组合模型可解决 LSTM 模型手动选择参数的难题,不仅大幅缩短模型训练时间,还能找到最优网络超参数,从而发挥模型的最佳性能。由此可见, SSA 对传统网络模型的优化具有明显的效果。

近年来, SSA-CNN 模型因与单一的传统神经网络相比,预测精度更高^[19],学习和泛化能力更强,在短期电力负荷预测^[20]、轴承故障诊断^[21]和矿浆管道临界流速预测^[22]等方向得到初步应用。因此,本研究采用基于 SSA 优化 CNN 网络模型,以水动力学特征参数中的透射系数为预测目标,重点实现 SSA 对 CNN 模

型的批大小、学习率、两层卷积层的卷积核大小和数量、全连接层的神经元数量和正则化系数共 8 个超参数的优化,并搭建双排开孔圆筒防波堤透射系数 SSA-CNN 预测模型,重点探讨双排开孔圆筒防波堤中排间距和开孔率等结构参数对透射系数的影响。

2 数据和方法

2.1 研究数据

本文所采用的训练数据集是本课题组前期研究成果数据^[23],数值模拟工况如表 1 所示,共 176 组工况用于 SSA-CNN 模型对双排开孔圆筒防波堤消浪特性预测研究,模型计算参数设置如下:数值水槽长 30 m,宽 0.9 m,高 0.7 m,入射波采用规则波,波高变化区间为 [0.06, 0.11],波周期变化区间为 [1.4, 1.8],水深 0.5 m,第一排与第二排圆筒间的距离变化区间为 [1.0, 1.8],开孔率变化区间为 [0.231 1, 0.462 2],圆筒直径为 0.2 m,考虑到波浪能量主要集中在 1 倍波高范围之内,设置在静水面以下 0.3 m 至圆筒顶部之间开孔,开孔直径为 0.04 m,数值模型布置图如图 1 所示。

透射系数 (K_t) 相应计算公式为

$$K_t = \frac{H_t}{H_i}, \quad (1)$$

式中, H_i 为入射波高; H_t 为透射波高。

2.2 研究方法

2.2.1 互信息法特征选择

使用机器学习进行透射系数预测时,特征选择用

表 1 数值模拟工况

Table 1 Numerical simulation working condition

	工况			
波高, H/m	0.06	0.07	0.09	0.11
波周期, T/s	1.4	1.5	1.6	1.8
水深, d/m	0.5			
排间距, B/m	1.0	1.2	1.4	1.8
开孔率, e	23.11%	34.67%	46.22%	
圆筒直径, D/m	0.2			
开孔直径, D_f/m	0.04			




图 1 模型布置图

Fig. 1 Layout of the model

于提取数据关键特征,明确输入数据与透射系数的相关性。本文选择互信息法分析输入特征参数与透射系数之间的相关性,输入特征参数分别是波高(H)、周期(T)、波长(L)、波速(u)、第一排圆筒与第二排圆筒间的距离(B)、开孔率(e)、水深(d)、开孔直径(D_i)、圆筒直径(D),输入参数 $f(x)$ 和透射系数 K_i 的互信息值可通过式(2)计算。

$$MI(F(X), K_i) = \sum_{f(x) \in F(X)} \sum_{k_i \in K_i} p(f(x), k_i) \log_2 \frac{p(f(x), k_i)}{p(f(x))p(k_i)}, \quad (2)$$

式中, $MI(F(X), K_i)$ 为互信息; $p(f(x), k_i)$ 为联合概率分布函数; $p(f(x))$ 和 $p(k_i)$ 为边缘概率分布函数,对数以 2 为底,互信息的单位是 b(比特)。本研究通过预处理和分析,共选取 9 个输入特征参数与透射系数进行相关性分析,互信息值越大,表示特征对目标变量的贡献越大^[24],具有更强的预测能力。

2.2.2 麻雀搜索算法

麻雀搜索算法(SSA)是根据麻雀觅食并逃避捕食者的行为而提出的群智能优化算法^[19]。该算法利用麻雀种群模拟麻雀群体中个体的数量和分布情况,以增加搜索空间的探索能力,提高算法的收敛性和搜索效果。种群数量越多,表示参与搜索的个体越多,搜索空间的覆盖范围也就越广,从而增加发现全局最优解的可能性。麻雀种群主要由发现者、加入者和警戒者组成^[25],其中初始种群数量在迭代寻找最优解的过程中保持不变,发现者与加入者身份会互换,但两者数量之和的比例始终维持不变^[26]。麻雀位置更新方式及算法计算流程如图 2 所示。

2.2.3 卷积神经网络

CNN 网络结构主要由卷积层(Convolutional Layer, conv_x)、池化层(Pooling Layer)、随机断开层(Drop-out Layer)和全连接层(Fully-connected Layer, fc_x)组成^[27],其中卷积层和池化层是最核心的两个部分。卷积层通过卷积核实现输入数据的特征提取,池化层通常在卷积层之后,常被用来对卷积层提取的特征进行下采样^[28],即降维。最大池化方式因其极值点特征信息的捕捉更为有效而常被选为池化方式^[29]。经过卷积层对输入特征的抽取后,避免过拟合,增加随机断开层,并将随机断开层的所有神经元连接到全连接层,最终输出波浪透射系数的预测结果。

2.2.4 SSA-CNN 模型

在 CNN 模型中,根据卷积核大小实验和 CNN 网络结构共确定需要优化 CNN 网络模型的 8 个超参数,如表 2 所示,分别是卷积神经网络模型的批大小

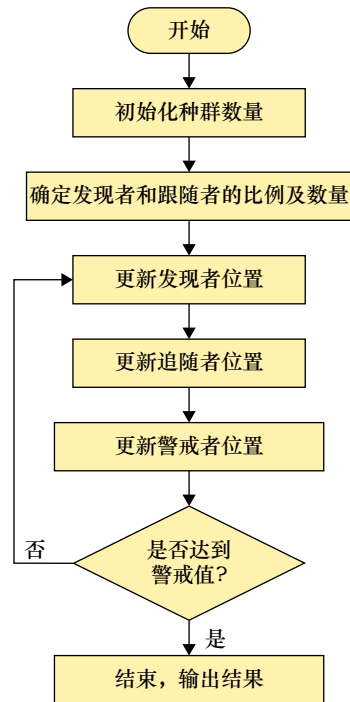


图 2 麻雀搜索算法计算流程

Fig. 2 SSA calculation process

(Batch Size)、学习率(Learning Rate)、两个卷积层的卷积核大小和数量、全连接层的神经元个数和正则化系数(Regularization)。卷积神经网络的批大小与数据规模相关,基于本研究的数据规模,设定批大小在 2^7 以内。参考张新生和贺凯璐^[22]及徐天宇^[5]的研究,学习率和正则化系数范围分别设定为 0.001~0.01 和 0.000 1~0.1,卷积核大小常设置为 3 或 5,并在此基础上适当扩大参数范围,以增加模型的泛化性。

表 2 SSA-CNN 算法中的超参数

Table 2 Hyperparameters in the SSA-CNN algorithm

参数	超参数	初始化范围
x_1	批大小	1~130
x_2	学习率	0.001~0.01
x_3	conv_1 核大小	1~5
x_4	conv_1 核数量	1~40
x_5	conv_2 核大小	1~5
x_6	conv_2 核数量	1~40
x_7	全连接层神经元数量	1~10
x_8	正则化系数	0.000 1~0.1

SSA-CNN 模型如图 3 所示。将 SSA 初始化参数输入到 SSA 模型中进行循环优化,然后根据输出结果改变 CNN 网络参数,从而得到 SSA-CNN 模型。

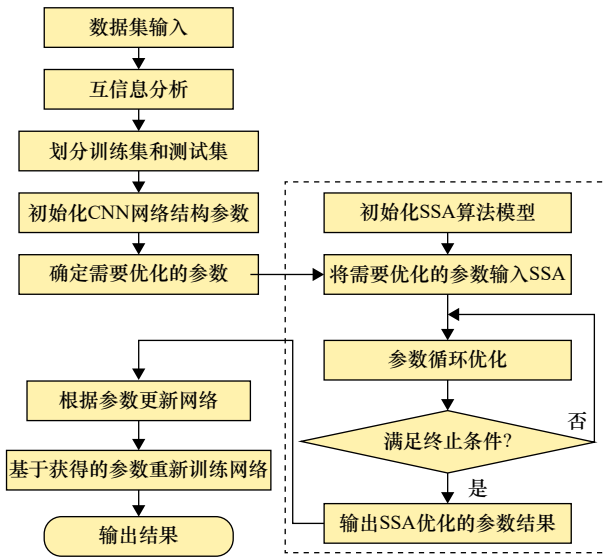


图3 SSA-CNN 模型
Fig. 3 SSA-CNN model

3 预测结果分析

3.1 透射系数预测模型超参数确定

首先搭建传统卷积神经网络模型^[9], 网络结构如图4所示, 层数为9层: 输入层、2个带有池化与激活的卷积层、随机断开层、全连接层。激活函数选择最常用的ReLU函数, 假设输入参数互相独立, 利用卷积网络自动抽取输入特征的优势, 对模型微调并加入一层丢弃层^[30-31], 设定随机断开比例为20%, 即随机选择20%的输出结果并将其置为0。




图4 CNN 网络结构
Fig. 4 Structure of the convolutional neural network

其次通过麻雀搜索算法对CNN模型的超参数自动迭代寻优, 初始化麻雀搜索算法的种群数量为10, 其中发现者占30%, 剩余70%为加入者, 根据图2进行自动迭代寻优, 输出CNN超参数的最优组合: 批大小为120, 学习率为0.0035, 卷积核大小均为3, 卷积核数量分别为16、32, 全连接层神经元数量为1, 正则化系数为0.0026。

最后将SSA输出结果放进CNN模型进行训练, 其中测试集占20%, 训练集占80%, 最终得到针对透

射系数预测的SSA-CNN模型。

3.2 互信息特征选择

基于文献[32]神经网络预测效果在一定程度上由输入参数与目标特征参数的相关性决定, 因此, 有必要在预处理时对数据的相关性进行排序, 选取相关性大的组合作为模型的输入参数, 本部分基于互信息法讨论模型输入特征 H 、 T 、 L 、 u 、 B 、 e 、 d 、 D_1 、 D 对模型预测透射系数重要程度进行排序。经式(2)计算, 输入特征参数与 K_t 的互信息值分别如表3所示, 数据相关性最高至最低的特征参数依次为 H 、 T 、 L 、 u 、 B 、 e 、 d 、 D_1 、 D , 其中 D_1 、 D 与透射系数的相关性最小, 然而, 水深作为影响透射系数的一个重要参数, 在相关性计算中结果为0, 因为在数据集中, 水深始终保持不变, 根据式(2)计算结果为0。综上所述, 选择 H 、 T 、 L 、 u 、 B 、 e 、 d 作为输入参数组合。

表3 互信息值

Table 3 Mutual information value

序号	参数	MI
1	H	1.194
2	T	0.592
3	L	0.592
4	u	0.592
5	d	0
6	B	0.586
7	e	0.473
8	D_1	0
9	D	0

3.3 不同模型预测透射系数对比分析

为了检验优化后模型的预测能力, 将CNN模型与SSA-CNN模型预测结果同透射系数对比分析, 结果见图5, 图中表明CNN模型与SSA-CNN模型均能学习到输入特征与透射系数之间的数据映射关系, 能够对不同工况下的透射系数进行预测, 特别是SSA-CNN模型在面对未知的输入数据时能够保持较好的预测能力。在波高 $H = 0.06\text{ m}$, 0.07 m , 0.09 m , 0.11 m , 圆筒直径 $D = 0.2\text{ m}$, $T = 1.6\text{ s}$ 的条件下, 图6、图7分别给出了 $e = 46.22\%$ 和 $H/D = 9$ 的工况下, 双排开孔圆筒防波堤的透射系数的预测值和真实值随相对排间距和开孔率的变化情况。不同波陡条件下, 透射系数整体均呈增大的趋势, 但增幅不大, 透射系数均在0.56以下。由图6可知, 当 $B/D = 6$ 时透射系数最低,

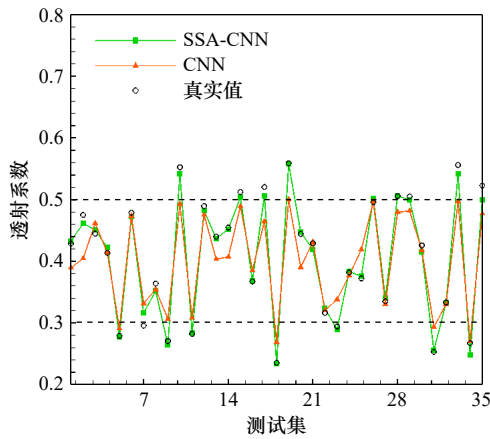


图5 SSA-CNN和CNN模型的预测值和真实值结果对比

Fig. 5 Comparison of predicted values and real values of SSA-CNN and CNN models

此时相较于最大透射系数可减小约 11.54%。由图 7 可知 $e = 23.11%$ 相较于 $e = 46.22%$ 工况下透射系数可降低 25.15%。由图 6、图 7 可知, SSA-CNN 预测的结果与计算流体力学 (Computational Fluid Dynamics, CFD) 数值模拟结果基本一致, 较好地反映了透射系数随相对排间距、开孔率的增大而增大的变化规律, 且具有较高的预测精度, 图 6 和图 7 中各工况的预测值和真实值的平均相对误差分别是 0.93% 和 1.54%。当波陡 $H/L = 0.0195$ 时产生了较为明显的误差, 其平

均相对误差分别为 2.10% 和 1.80%, 比同一工况不同波陡下的平均相对误差分别高 0.84% 和 1.16%, 此误差产生的主要原因是: SSA-CNN 模型以绝对误差作为训练指标, 因此在实际预测时, 较小的波高容易产生更大的相对误差; 而在波高较大的情况下, SSA-CNN 所预测的透射系数与真实值更加接近。

为了评估 SSA 算法的收敛性, 采用适应度进行算法的有效性验证。适应度值代表了模型在解决问题或者拟合数据时的有效性和优劣程度。适应度值下降得越快、降得越低表示在模型优化过程中找到最优解或靠近最优解越迅速, 适应度值在迭代过程中降得快意味着算法具有更好的收敛性。SSA-CNN 模型的适应度曲线见图 8, 由图 8 可知, 初始适应度值为 0.0272, 从第二次迭代开始, 适应度值开始下降, 随着迭代次数增加, 在第三次迭代适应度值逐渐趋于 0, 并在 0.025 附近保持不变, 表明 SSA 找到了该种群数量下的最优解, 可以看出 SSA 算法从第三次迭代逼近最优解, 说明 SSA 算法在给定种群数量下能够快速收敛, 并找到最优解, 充分说明了 SSA 算法的有效性和优越性。

为直观衡量模型预测值与波浪透射系数的误差, 采用绝对误差 (Absolute Error, AE) 作误差分布图, CNN 模型、SSA-CNN 模型误差分布图分别如图 9、图 10 所示, AE 计算式见式(3),

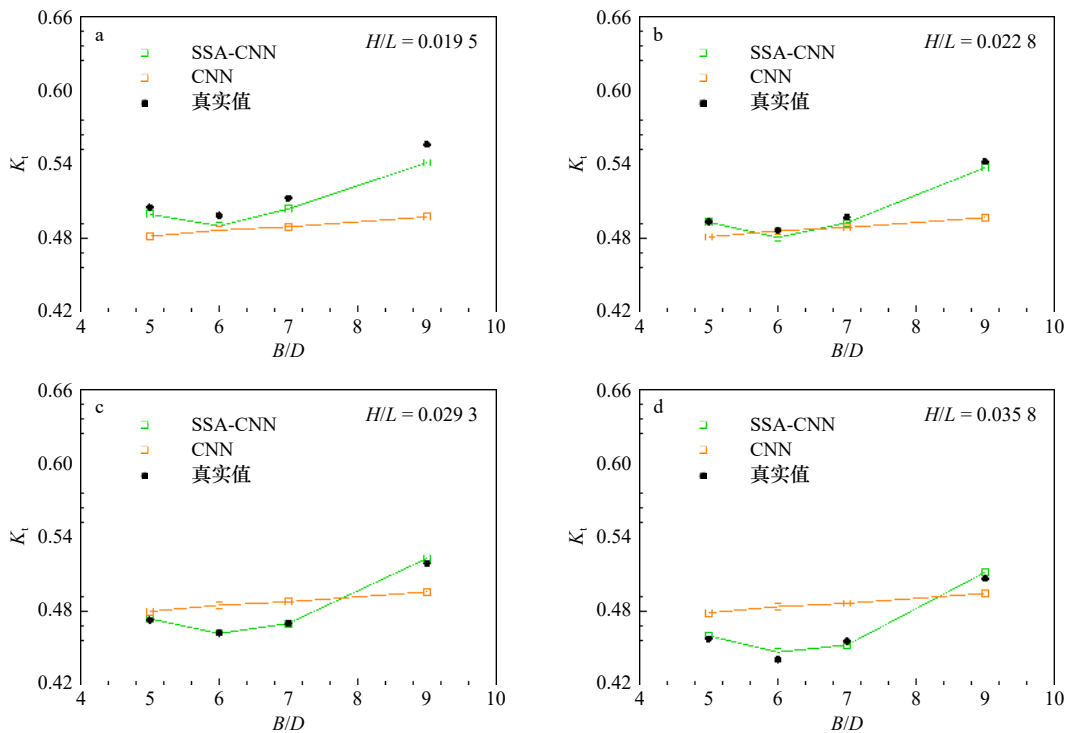


图6 透射系数随相对排间距的变化情况 ($e = 46.22%$)

Fig. 6 The change of K_t with B/D ($e = 46.22%$)

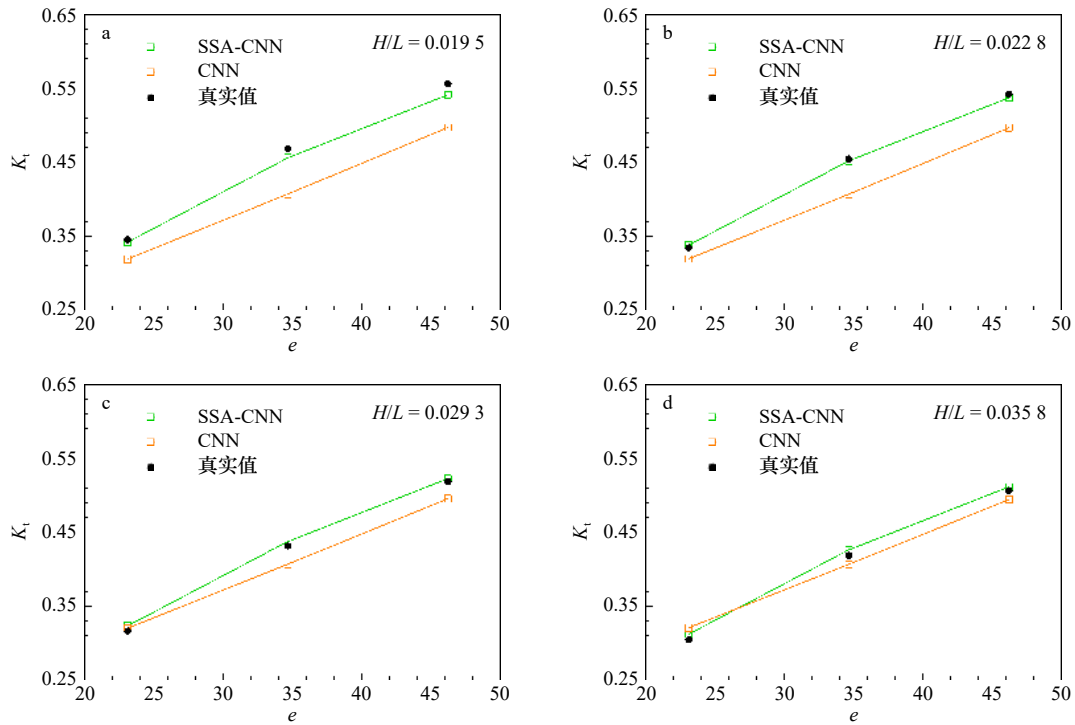


图7 透射系数随开孔率的变化情况 ($H/D = 9$)

Fig. 7 The change of K_t with e ($H/D = 9$)




图8 SSA-CNN 适应度曲线
Fig. 8 Fitness curve of SSA-CNN

$$AE = |y_i - \hat{y}_i|, \quad (3)$$

式中, y_i 为 CFD 计算值; \hat{y}_i 为模型预测值。

由图9、图10可知, SSA-CNN 模型预测值与真实值的误差最小, 假设 $AE \leq |0.02|$ 时, 模型对透射系数的预测更加可靠, 根据图9的35组测试集数据, SSA-CNN 模型的可靠性高达 97.14%, 仅有 1 条数据的绝对误差在 0.02~0.03 之间。而在 CNN 模型中, 有 15 条数据绝对误差满足假设要求, 在 CNN 模型上对透射系数的预测仅有 42.86% 的可靠性。对比可见, SSA-CNN 模型的预测可靠性远高于 CNN 模型。

为了更好地描述两种模型的性能, 采用以下 4 个统计学指标作为模型的评价指标: 平均绝对误差 (Mean Absolute Error, MAE)、均方误差 (Mean Squared




图9 SSA-CNN 模型预测误差分布
Fig. 9 Prediction error distribution of SSA-CNN model

Error, MSE)、均方根误差 (Root Mean Squared Error, RMSE) 和决定系数 (Coefficient of Determination, R^2) 对模型进行评估, 评价指标计算公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (4)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (6)$$




图 10 CNN 模型预测误差分布

Fig. 10 Prediction error distribution of CNN

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (7)$$

式中, n 为测试样本总数; y_i 为 CFD 计算值; \hat{y}_i 为模型预测值; \bar{y} 为 CFD 计算值的均值。

公式(4)至式(7)用于评估 SSA-CNN 模型和 CNN 模型的预测性能,式(4)至式(6)的计算结果值越小,且式(7)的计算结果越接近 1,则模型的预测精度越高。CNN 模型与 SSA-CNN 模型的评价指标计算结果如表 4 所示。由表 4 可知,SSA-CNN 模型的 R^2 值为 0.990 9, MAE、MSE、RMSE 值分别为 0.007 1、0、0.009 2,相对 CNN 模型, R^2 值提高了 13.58%, MAE、MSE、RMSE 值分别低 0.020 5、0.001 2、0.025 3。综上所述,SSA-CNN 模型在波浪透射系数预测上比传统 CNN 模型表现更好,精确性更高。

表 4 模型预测效果对比

Table 4 Comparison of model prediction effect

模型	R^2	MAE	MSE	RMSE	MRE
CNN	0.872 4	0.027 6	0.001 2	0.034 5	0.068 7
SSA-CNN	0.990 9	0.007 1	0	0.009 2	0.018 0

为了更好地描述两种模型的性能,采用以下 5 个统计学指标作为模型的评价指标:平均绝对误差 (Mean Absolute Error, MAE)、均方误差 (Mean Squared Error, MSE)、均方根误差 (Root Mean Squared Error, RMSE)、决定系数 (Coefficient of Determination, R^2) 和平均相对误差 (Mean Relative Error, MRE) 对模型进行评估,评价指标计算公式如下:

$$\text{MRE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (8)$$

3.4 不同种群数量对透射系数预测的影响

根据文献 [16] 使用麻雀搜索算法优化卷积神经网络模型时,需要考虑初始种群数量和发现者的比例对波浪透射系数预测的影响,初始种群数量过多,会增加计算复杂度和搜索成本,因此合适的种群数量对预测结果有着显著的影响。为探究初始化种群数量对模型预测能力的影响,本文设置了初始化种群数量分别为 5、10、15、20、25、30,研究了不同种群数量下模型预测值与 CFD 计算值之间的差异。模型的预测值与真实值的差异如图 11 所示,模型预测值与真实值的偏离程度,用绝对误差表示,如图 12 所示。

由图 11a 至图 11f、图 12a 至图 12f 可知,当稳定发现者的比例,初始种群数量为 10 时,模型对透射系数的预测值与 CFD 计算值的结果最为接近,模型绝对误差最小,预测值的误差维持在 ± 0.02 附近。不同初始种群数量的平均相对误差如表 5 所示,从表 5 看出种群数量对预测精度产生了不同的影响。当种群数量较小(例如 5)时,平均相对误差较高,达到了 3.19%。随着种群数量的增加,平均相对误差逐渐降低,当种群数量为 10、15、20、25 和 30 时,平均相对误差分别为 0.71%、1.33%、1.04%、0.82% 和 0.98%,误差主要来自以下两个方面:一是过少的初始种群数量限制了 SSA 算法的搜索空间,导致预测能力较差。此外,图 11b 的预测表现优于图 11a,导致该现象的原因在于,种群初始化数量较少,搜索空间受限。二是测试集中 R^2 值低于训练集,模型产生了过拟合,泛化能力较差。对此,考虑设置更加全面的工况,对不同组次分析,并在此基础上建立数据集。

从表 5 可以看出,随着种群数量的增加,预测模型的精度得到了改善。适当增加种群数量可以减小预测结果的相对误差,提高预测精度。然而,若种群数量过大,则根据文献 [11],可能陷入局部最优解,致使部分结果的预测值与 CFD 计算值偏离较大,需要根据研究内容进行权衡和选择。当种群数量为 10 时,平均相对误差最小,仅为 0.71%。综上所述,种群数量为 10 左右时,模型对透射系数预测的精确度最高。

4 结论

波浪透射系数受多种因素影响,本文将波浪特征参数与防波堤结构特征参数分别输入到 SSA-CNN 组

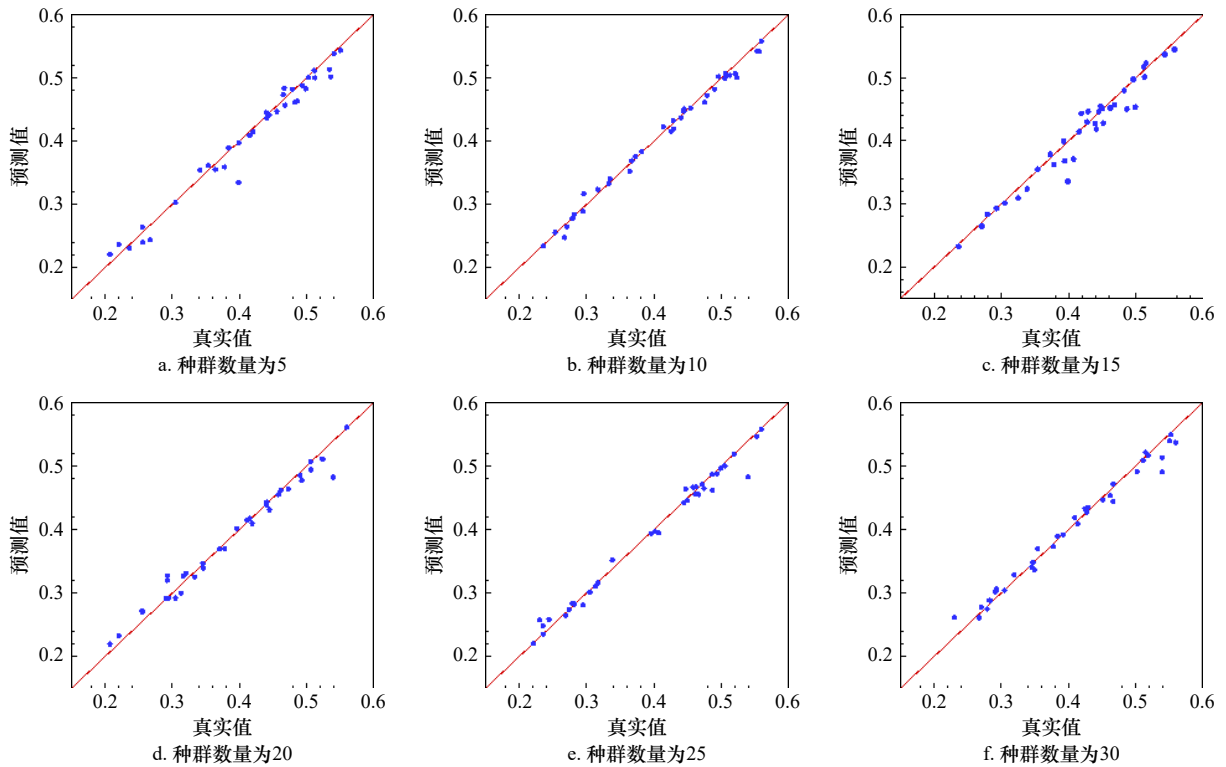


图 11 预测值与 CFD 计算值对比

Fig. 11 Comparison between predicted values and CFD calculation values

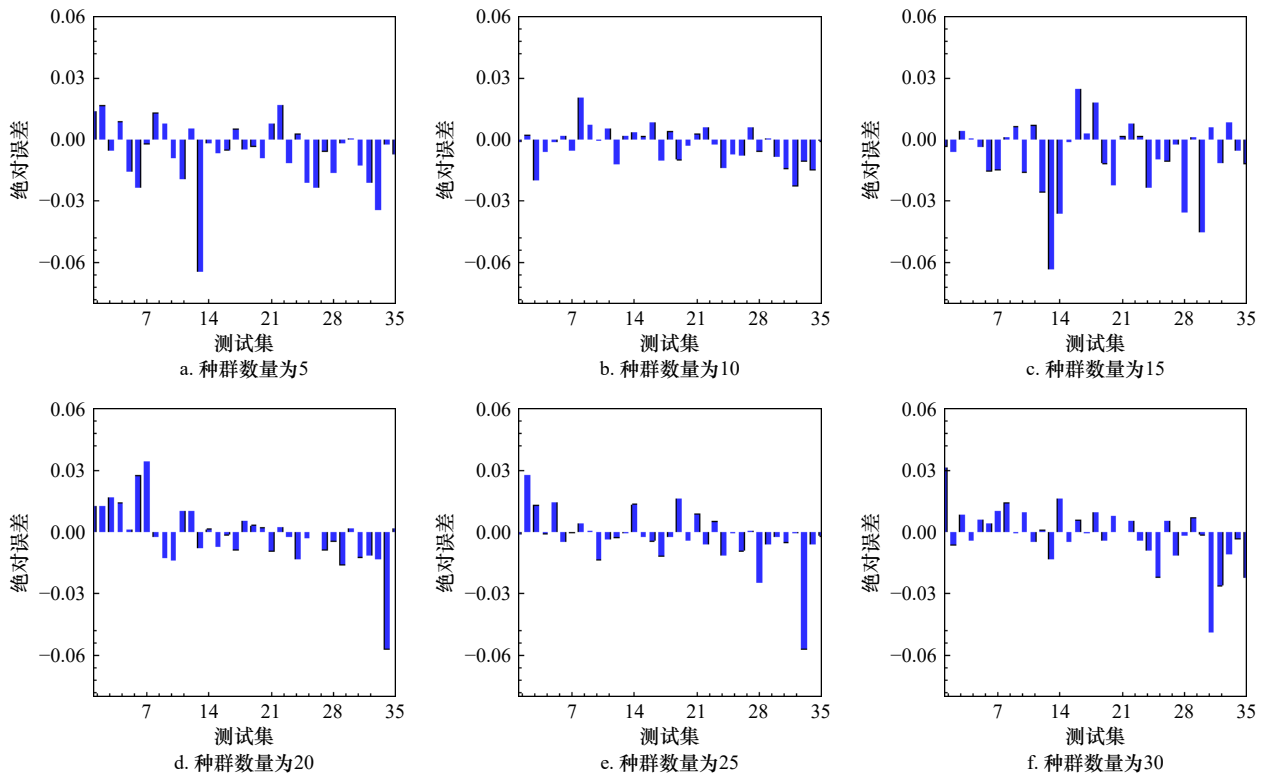


图 12 预测误差分布

Fig. 12 Prediction error distribution

合模型和传统单一的 CNN 模型, 同时将波浪透射系数作为预测结果。通过对模型的评估, 得出如下结论:

- (1) 基于 SSA 算法对 CNN 模型的超参数自动寻优, 超参数最优组合为: 批大小为 120, 学习率为 0.003 5,

表 5 平均相对误差结果分析
Table 5 Analysis of mean relative error results

序号	种群数量	平均相对误差
1	5	3.19%
2	10	0.71%
3	15	1.33%
4	20	1.04%
5	25	0.82%
6	30	0.98%

卷积核大小均为 3, 卷积核数量分别为 16、32, 全连接层神经元数量为 1, 正则化系数为 0.002 6。减少了人为试错时间, 消除人为设置参数的不确定性。

(2) 基于课题组所获成果数据集, 经互信息特征选择, 获得了对波浪透射系数影响的关键因子: H 、 T 、 L 、 u 、 B 、 e 、 d 。

(3) 提出 SSA-CNN 模型用于波浪透射系数预测, 并将该模型与传统单一 CNN 预测模型进行对比, 模

型拟合程度 R^2 值分别为 0.990 9、0.872 4, 相对于单一的 CNN 模型, SSA-CNN 模型的透射系数预测准确度提升了 13.58%, 平均相对误差降低了 5.07%。这表明 SSA-CNN 模型泛化能力更强, 从而丰富和发展了波浪透射系数预测的方法体系和研究理论。

(4) SSA 算法初始种群数量会影响模型运算时间, 不同的种群数量对应搜索空间不同, 当种群数量为 10 时, 能够找到模型对应搜索空间的最优解, 当种群数量较小时, 比如种群数量为 5, 搜索空间较小, 不足以找到最优解。对于实际情况, 需要根据研究内容进行权衡和选择。

本文利用 SSA 针对传统的卷积神经网络的超参数进行自动寻优, 减少了人为选参的不确定性, 加速了网络预测模型构建, 同时保证了模型的预测精度, 为波浪透射系数的预测、消浪特性研究和工程设计提供了更全面的技术支撑。但是, 也存在不足, 当问题规模较大时, 需要消耗更多的计算资源和时间, 在使用 SSA-CNN 模型时, 需要充分考虑初始化种群数量, 并根据具体情况权衡其优势和劣势, 以获得最佳的模型性能。

参考文献:

- [1] 季则舟, 吴波, 李超, 等. 双排圆筒透空式防波堤: 201920286464.1[P]. 2019-03-07.
Ji Zezhou, Wu Bo, Li Chao, et al. Double-row cylinder permeable breakwater: 201920286464.1[P]. 2019-03-07.
- [2] Stoker J J. Water Waves: The Mathematical Theory with Applications[M]. New York: Interscience Publishers, 1957, 83.
- [3] Suvarna P S, Sathyanarayana A H, Umesh P, et al. Laboratory investigation on hydraulic performance of enlarged pile head breakwater[J]. *Ocean Engineering*, 2020, 217: 107989.
- [4] Liu H.W., Ghidaoui M.S., Huang Z.H., et al. Numerical investigation of the interactions between solitary waves and pile breakwaters using BGK-based methods[J]. *Computers and Mathematics with Applications*, 2010, 61(12), 3668-3677.
- [5] 徐天宇. 基于卷积神经网络的近海工程水动力学特征预测 [D]. 杭州: 浙江大学, 2020.
Xu Tianyu. Prediction of hydrodynamic characteristics of offshore engineering based on convolutional neural network[D]. Hangzhou: Zhejiang University, 2020.
- [6] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述 [J]. *计算机学报*, 2017, 40(6): 1229-1251.
Zhou Feiyan, Jin Linpeng, Dong Jun. Review of convolutional neural network[J]. *Chinese Journal of Computers*, 2017, 40(6): 1229-1251.
- [7] 赵西增, 徐天宇, 谢玉林, 等. 基于卷积神经网络的涵洞式直立堤波浪透射预测 [J]. *力学学报*, 2021, 53(2): 330-338.
Zhao Xizeng, Xu Tianyu, Xie Yulin, et al. Prediction of wave transmission of culvertbreakwater based on CNN[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2021, 53(2): 330-338.
- [8] Montes-Atenas G, Seguel F, Valencia A, et al. Predicting bubble size and bubble rate data in water and in froth flotation-like slurry from computational fluid dynamics (CFD) by applying deep neural networks (DNN)[J]. *International Communications in Heat and Mass Transfer*, 2016, 76: 197-201.
- [9] Wei Zhangping, Davison A. A convolutional neural networkbased model to predict nearshore waves and hydrodynamics[J]. *Coastal Engineering*, 2022, 171: 104044.
- [10] Yao Z, Wang Z, Wang D, et al. An ensemble CNN-LSTM and GRU adaptive weighting model based improved sparrow search algorithm for predicting runoff using historical meteorological and runoff data as input[J]. *Journal of Hydrology*, 2023, 625: 129977.
- [11] Formentin S M, Zanuttigh B, van der Meer J W. A neural network tool for predicting wave reflection, overtopping and transmission[J]. *Coastal Engineering Journal*, 2017, 59(1): 1750006.
- [12] 赵沛泓, 孙大鹏, 吴浩. 采用 JADE-SVR 方法研究波浪和开孔沉箱相互作用 [J]. *水道港口*, 2021, 42(2): 166-173.
Zhao Peihong, Sun Dapeng, Wu Hao. Investigating on the wave interaction with perforated caisson based on JADE-SVR machine[J]. *Journal of Waterway and Harbor*, 2021, 42(2): 166-173.
- [13] Zanuttigh B, Formentin S M, van der Meer J W. Prediction of extreme and tolerable wave overtopping discharges through an advanced

- neural network[J]. *Ocean Engineering*, 2016, 127: 7–22.
- [14] Kim T, Lee W D, Kwon Y, et al. Prediction of wave transmission characteristics of low crested structures using artificial neural network[J]. *Journal of Ocean Engineering and Technology*, 2022, 36(5): 313–325.
- [15] Li Qi, Shi Yaru, Lin Ruiqi, et al. A novel oil pipeline leakage detection method based on the sparrow search algorithm and CNN[J]. *Measurement*, 2022, 204: 112122.
- [16] Chen Gonggui, Zhu Mengyuan, Huang Jing, et al. Short-term wind speed prediction with master-slave performance based on CNN-LSTM and improved POABP[J]. *Engineering Letters*, 2023, 31(2): 848–861.
- [17] Li Xinhong, Guo Mengmeng, Zhang Renren, et al. A data-driven prediction model for maximum pitting corrosion depth of subsea oil pipelines using SSA-LSTM approach[J]. *Ocean Engineering*, 2022, 261: 112062.
- [18] 王军, 马小越, 张宇航, 等. 基于 SSA-LSTM 模型的黄河水位预测研究 [J]. *人民黄河*, 2023, 45(9): 65–69.
Wang Jun, Ma Xiaoyue, Zhang Yuhang, et al. Research on the prediction of the Yellow River water level based on SSA-LSTM model[J]. *Yellow River*, 2023, 45(9): 65–69.
- [19] Xue Jiankai, Shen Bo. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22–34.
- [20] Fan Guofeng, Li Yun, Zhang Xinyan, et al. Short-term loadforecasting based on a generalized regression neural network optimized by an improved sparrow search algorithm using the empirical wavelet decomposition method[J]. *Energy Science & Engineering*, 2023, 11(7): 2444–2468.
- [21] Zhu Yucheng, Cao Xudong, Han Zhongting. An improved CNN employing SSA and its application in bearing fault diagnosis[C]//Proceedings of the IEEE 5th International Conference on Automation, Electronics and Electrical Engineering. Shenyang: IEEE, 2022: 714–718.
- [22] 张新生, 贺凯璐. 基于 SSA-CNN 的长距离矿浆管道临界流速预测 [J]. *安全与环境学报*, 2022, 22(5): 2524–2531.
Zhang Xinsheng, He Kailu. Prediction of critical velocity of long-distance slurry pipeline based on SSA-CNN[J]. *Journal of Safety and Environment*, 2022, 22(5): 2524–2531.
- [23] 邓斌, 尹龙斌, 黄姣凤, 等. 波浪与新型双排开孔圆筒防波堤相互作用三维数值模拟 [J]. *力学学报*, 2023, 55(4): 845–857.
Deng Bin, Yin Longbin, Huang Jiaofeng, et al. Three dimensional numerical simulation of wave interaction with a new type of double-row perforated cylinder breakwater[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2023, 55(4): 845–857.
- [24] Wang Ran, Zhao Jianhui, Yang Huijin, et al. Inversion of soil moisture on farmland areas based on SSA-CNN using multi-source remote sensing data[J]. *Remote Sensing*, 2023, 15(10): 2515.
- [25] Zhang R, Su J, Feng J. An extreme learning machine model based on adaptive multi-fusion chaotic sparrow search algorithm for regression and classification[J]. *Evolutionary Intelligence*, 2023: 1–20.
- [26] Fathy A, Alanazi T M, Rezk H, et al. Optimal energy management of micro-grid using sparrow search algorithm[J]. *Energy Reports*, 2022, 8: 758–773.
- [27] Liu Yang, Lu Yutong, Wang Yueqing, et al. A CNN-based shock detection method in flow visualization[J]. *Computers & Fluids*, 2019, 184: 1–9.
- [28] Yu Dingjun, Wang Hanli, Chen Peiqiu. Mixed pooling for convolutional neural networks[C]//Proceedings of the 9th International Conference. Shanghai: Springer, 2014: 364–375.
- [29] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing coadaptation of feature detectors[J]. *Comput. ENCE 2012*, 3: 212–223.
- [30] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. *The Journal of Machine Learning Research*, 2014, 15(1): 1929–1958.
- [31] Gal Y, Ghahramani Z. A theoretically grounded application of dropout in recurrent neural networks[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: Curran Associates Inc. , 2016: 1027–1035.
- [32] 周长春, 姜杰, 李谦, 等. 基于融合特征选择算法的钻速预测模型研究 [J]. *钻探工程*, 2022, 49(4): 31–40.
Zhou Changchun, Jiang Jie, Li Qian, et al. Research on drilling rate prediction model based on fusion feature selection algorithm[J]. *Drilling Engineering*, 2022, 49(4): 31–40.

Prediction of transmission coefficient of double-row perforated cylinder breakwater based on SSA-CNN model

Deng Bin^{1,2,4}, Wang Ling¹, He Jun³, Yin Longbin¹, Jiang Changbo^{1,2}, Chen Jie^{1,2}, Wu Zhiyuan^{1,2}

(1. School of Hydraulic and Environmental Engineering, Changsha University of Science & Technology, Changsha 410114, China; 2. Key Laboratory of Water-Sediment Sciences and Water Disaster Prevention of Hunan Province, Changsha 410114, China; 3. CCCC Water Transportation Consultants Co., Ltd., Beijing 100007, China; 4. State Key Laboratory of Hydraulic Engineering Intelligent Construction and Operation, Tianjin 300072, China)

Abstract: The double-row perforated cylinder breakwater is a new type of environment-friendly breakwater, and the research on its wave absorbing characteristics is of great engineering significance. With the development of artificial intelligence, solving the water dynamics problem of breakwater based on machine learning technology has become a new research paradigm. This paper proposes a Convolutional Neural Network (CNN) model based on Sparrow Search Algorithm (SSA) to achieve intelligent optimization prediction of transmission coefficient of double-row perforated cylindrical breakwater. The results show that: (1) wave height, wave period, wavelength, wave velocity, row spacing, hole rate and water depth are identified as the key factors affecting the transmission coefficient. (2) When the population size of the SSA-CNN model is 10, the R^2 value of the wave transmission coefficient prediction reaches 0.990 9, and the average relative error is reduced by 22.24% compared with the single CNN model. The research results provide a new optimal prediction model for the study of wave transmission by using neural networks.

Key words: double-row perforated cylinder breakwater; wave absorbing characteristic; sparrow search algorithm; convolutional neural network; transmission coefficient