



# 基于卷积神经网络的混合浪海域港口波浪预报\*

刘二利<sup>1</sup>, 马小舟<sup>2</sup>

(1. 招商局港口集团股份有限公司, 广东 深圳 518067; 2. 大连理工大学, 辽宁 大连 116024)

**摘要:** 港湾振荡是最常见的波浪灾害形式, 危害巨大。准确高效地预测港内波浪有助于降低港口损失, 避免人员伤亡。基于 Boussinesq 方程的数值模拟是研究港湾振荡的重要方法, 计算成本较高, 为应对港湾振荡业务化的预报, 以斯里兰卡汉班托塔港为例, 建立港湾振荡参数化模型, 实现了港内波高的快速预测。将港外实测海浪谱划分为独立的波浪系统, 对各个波系分别进行参数化表征, 运用最大差异选择算法(MDA)选取计算工况, 输入 FUNWAVE-TVD 模型模拟港内波浪在不同入射波浪参数组合下的响应, 生成数据集, 并分为泛化集和测试集两部分。泛化集用于训练和挑选卷积神经网络(CNN), 测试集用于测试神经网络对于未知工况的性能。神经网络的输出是港内整个计算域上的有效波高和低频波高。结果表明: 该模型在测试集上表现良好, 能够准确地估计未知工况下的全场波高。随后, 根据现场实测数据成功地验证了该模型, 证明了波浪数值模型和 CNN 的可靠性。一旦获取了港外波浪参数, 可以快速估计港口内的波浪状况。

**关键词:** 港湾振荡; 波浪估计; FUNWAVE-TVD; CNN; 混合降尺度波浪预报模型; 风涌浪分离

中图分类号: U655; O353.2

文献标志码: A

文章编号: 1002-4972(2025)04-0032-07

## Port wave forecasting in mixed wave sea area based on CNN method

LIU Erli<sup>1</sup>, MA Xiaozhou<sup>2</sup>

(1. China Merchants Port Group Co., Ltd., Shenzhen 518067, China; 2. Dalian University of Technology, Dalian 116024, China)

**Abstract:** Harbor oscillations is the most common form of wave disaster, which is very harmful. Accurate and efficient prediction of waves in the port is helpful to reduce economic losses and avoid casualties. The numerical simulation based on Boussinesq equation is an important method to study the harbor oscillation, and the calculation cost is high. To cope with the business oriented prediction of harbor oscillations, this paper proposes a parametric model of harbor oscillation and achieves rapid prediction of wave heights in the port, taking the Hambantota Port in Sri Lanka as an example. Based on the measured data of Hambantota port, the wave spectrum is divided into independent wave systems, each wave system is parameterized, the maximum difference selection algorithm (MDA) is used to select the calculation conditions, and the FUNWAVE-TVD numerical model is input to simulate the response of waves in the port under different incident wave parameter combinations, and the dataset is generated. The dataset is divided into generalization set and test set. The former is used to train and select the convolutional neural network (CNN), while the latter is utilized to measure the network performance on unknown cases. The output of the network is significant wave height and low-frequency wave height over the whole computing domain within the port. The results show that the model performs well on the test set and can accurately estimate the full-field wave height under unknown conditions. Then, the model is successfully verified according to the field measurement data, which proves the reliability of the wave numerical model and CNN. Once the wave parameters outside the port are obtained, the wave conditions inside the port can be quickly estimated.

**Keywords:** harbor oscillation; wave estimation; FUNWAVE-TVD; CNN; hybrid downscale wave prediction model; separation of wind sea and swell

收稿日期: 2024-05-29

\*基金项目: 国家自然科学基金面上项目(52071060)

作者简介: 刘二利(1978—), 男, 高级工程师, 从事港口建设管理、水动力研究。

港口是位于江、海、湖沿岸,具有水陆联运条件和设备以供船舶安全进出和停泊的交通枢纽。港湾水体在外部扰动下,发生与其固有频率有关的可以影响到人类社会经济活动的振荡现象,称为港湾振荡<sup>[1]</sup>。准确高效的波浪预测有助于规避港湾振荡带来的危害,降低港口经济损失,避免人员伤亡。

近年来人工神经网络在近海工程中得到了广泛应用。例如海浪条件的预报<sup>[2]</sup>、网箱结构应力和变形预测<sup>[3]</sup>、港内装卸规划的优化<sup>[4]</sup>和海滩剖面季节性变化预测<sup>[5]</sup>。卷积神经网络(convolutional neural network, CNN)是深度学习的代表算法之一,被广泛应用于计算机视觉、图像识别<sup>[6-7]</sup>等,具有较强的数据挖掘能力和泛化能力,对于部分神经网络所不能处理的大规模和图像数据集都可轻松应对。基于人工神经网络的波浪预测方法在近年来已较为成熟,例如 Demetriou et al.<sup>[8]</sup>利用风场数据训练人工神经网络对近岸波高进行实时预测; Wei et al.<sup>[9]</sup>将非静压波浪模型(Simulating Waves Till Shore, SWASH)和 CNN 结合用于预测近岸波浪和水动力。

大尺度海域水波模拟技术大多基于第三代相位平均海浪模型,如 WAM(海浪模型 Wave Model)<sup>[10]</sup>、SWAN(近岸波浪模拟, Simulating Waves Nearshore)<sup>[11]</sup>和 WW3(风浪模拟模型, WAVEWATCH III)<sup>[12]</sup>。这些模型的有效性和效率已经获得了充分验证,但它们主要关注短波,没有考虑低频波浪及其引发的港湾振荡。相位识别 Boussinesq 方程模型较好地考虑了港口及港内波浪的折射、绕射、反射、破碎等现象,可以应对近岸数公里海域波浪模拟的需求,其计算成本较高。FUNWAVE-TVD 是基于 Boussinesq 方程的开源软件,已广泛应用于许多工程<sup>[13-16]</sup>。本研究试图开发一种基于 FUNWAVE-TVD 和 CNN 的港内波浪参数化模型,以减少港内波浪业务化预报中的高计算成本。

近岸波浪往往由混合浪(风浪和涌浪)所构成,一组波浪特征参数(有效波高  $H_s$ 、谱峰周期  $T_p$  和平均波向  $D_m$ )不足以精确描述多个波系共存的复

杂海况,需借助谱分割技术将海浪谱划分为不同波系,运用多组波浪特征参数描述不同波系,将各波系进行参数化输出。基于港外实测波浪数据,运用 FUNWAVE-TVD 模型模拟汉班托塔港在不同代表性海况波浪特征参数条件下的响应,从而输出港内整个计算域波高分布,形成数据集训练 CNN,确保可以有效预测与预先计算工况相似的未知工况。

本文首先介绍实测数据、最大差异选择算法(maximum difference selection algorithm, MDA)和代表性海况的选取结果;然后详细描述 FUNWAVE-TVD 波浪数值模型和 CNN 模型的设置;最后结合汉班托塔港口的实测资料评估港内波浪参数化模型的性能。

## 1 数据观测

汉班托塔港位于斯里兰卡的东南部,面向北印度洋,港口海域的地理位置如图 1 所示,没有岛礁和陆架的掩护,受外海涌浪影响显著。在西南季风期间,印度洋的涌浪达到最大值<sup>[17-18]</sup>,并且由于风速增大,风浪、涌浪混合情况加剧,存在港湾振荡问题,曾多次因系泊船运动量过大而停止作业<sup>[19]</sup>。2 个 Nortek AWAC 传感器的位置如图 2 所示,2019-07-10—2019-09-25 对汉班托塔海域测点位置进行实时观测,  $G_1$  测点传感器每小时观测 20 min,采样频率为 4 Hz,  $G_2$  测点传感器每小时观测 34 min,采样频率为 2 Hz,最终得到港内外波浪观测数据共 1 715 组。




图 1 汉班托塔港地理位置

Fig. 1 Geographical location of Hambantota Port




图2 汉班托塔港口近岸波浪测点位置

Fig. 2 Locations of near-shore wave measuring points at Hambantota Port

## 2 工况选取

近年来,数据挖掘技术不断改进和完善,广泛应用于各个领域。 $K$ -均值算法( $K$ -means)、自组织映射神经网络(self-organizing map, SOM)、MDA算法是较为流行的数据挖掘技术,前两者通常用于近岸波候分析<sup>[20]</sup>以及简单概率分析,MDA算法则适用于挑选混合浪海域条件下的代表性海况。

### 2.1 向量的归一化

以 $N$ 个三维向量组成的数据集 $\{x_1^*, x_2^*, \dots, x_N^*\}$ 中挑选含 $M$ 个代表向量的代表性子集 $v^* = \{v_1^*, v_2^*, \dots, v_M^*\}$ 为例说明。其中 $x_i^* = \{H_{s,i}, T_{p,i}, D_{m,i}\}$  ( $i=1, \dots, N$ )。将 $H_{s,i}$ 、 $T_{p,i}$ 和 $D_{m,i}$ 分别按照式(1)~(3)进行归一化处理,得到归一化后的数据集为 $x_i = \{H_i, T_i, D_i\}$  ( $i=1, \dots, N$ )。

$$H = \frac{H_s - \min(H_s)}{\max(H_s) - \min(H_s)} \quad (1)$$

$$T = \frac{T_p - \min(T_p)}{\max(T_p) - \min(T_p)} \quad (2)$$

$$D = \frac{D_m}{\pi} \quad (3)$$

式中: $H_{s,i}$ 、 $T_{p,i}$ 和 $D_{m,i}$ 为向量 $x_i^*$ 的有效波高、谱峰周期和平均波向; $\min(H_s)$ 和 $\max(H_s)$ 为初始数据集中所有向量的有效波高最小值和最大值; $\min(T_p)$ 和 $\max(T_p)$ 为初始数据集中所有向量谱峰周期的最小值和最大值; $H_i$ 、 $T_i$ 和 $D_i$ 表示归一化后的波高、周期和波向。

### 2.2 代表性子集中向量 $v_1$ 的选取

由公式(4)计算数据集中的每个向量 $x_i$ 与剩

余 $N-1$ 个向量 $x_k$  ( $k \neq i$ ) 的欧式距离之和 $d_i$ ,  $d_i$ 最大时表明向量 $x_i$ 与数据集中的剩余向量具有最大相异性,因此取该向量为代表性子集的第1个向量 $v_1$ 。

$$d_i = \sum \|x_i - x_k\| \quad (4)$$

$(i=1, \dots, N; k=1, \dots, i-1, i+1, \dots, N)$

其中,  $\|x_i - x_k\|$  为向量 $x_i$ 与 $x_k$ 之间的欧式距离,计算式为:

$$\|x_i - x_k\| = \sqrt{(H_i - H_k)^2 + (T_i - T_k)^2 + [\min(|D_i - D_k|, 2 - |D_i - D_k|)]^2} \quad (5)$$

### 2.3 代表性子集中向量 $\{v_2, \dots, v_M\}$ 的确定

若代表性子集已包含 $R$ 个向量( $R \leq M$ ),在选择第 $R+1$ 个向量时,按式(6)计算归一化后的数据集(剩余 $N-R$ 个向量)中各向量 $x_i$ 与当前代表性子集的相异性,记为 $d_{i, \text{subset}(R)}^{\min}$ ,剩余的 $N-R$ 个向量可计算得到 $N-R$ 个 $d_{i, \text{subset}(R)}^{\min}$ 。将令 $d_{i, \text{subset}(R)}^{\min}$ 值最大的向量作为代表性子集的第 $R+1$ 个元素 $v_{R+1}$ 。

$$d_{i, \text{subset}(R)}^{\min} = \min(d_{i,R}, d_{i, \text{subset}(R-1)}^{\min}) \quad (6)$$

式中: $d_{i, \text{subset}(R-1)}^{\min}$ 为向量 $x_i$ 与之前代表性子集(包含 $R-1$ 个向量)的相异性,按式(7)计算; $d_{i,R}$ 为向量 $x_i$ 与转移到代表性子集的前一个向量 $v_R$ 的欧式距离,如式(8)所示。

$$d_{i, \text{subset}(R-1)}^{\min} = \min\{\|x_i - v_j\|\} \quad (7)$$

$(i=1, \dots, N-R+1; j=1, \dots, R-1)$

$$d_{i,R} = \|x_i - v_R\| \quad (8)$$

### 2.4 向量的反归一化

挑选完成后,将代表性子集中的各向量 $v_j = \{H_j, T_j, D_j\}$  ( $j=1, \dots, M$ )按式(9)~(11)进行反归一化,处理后的向量表示为 $v_j^* = \{H_{s,j}, T_{p,j}, D_{m,j}\}$  ( $j=1, \dots, M$ )。

$$H_{s,j} = H_j \cdot [\max(H_s) - \min(H_s)] + \min(H_s) \quad (9)$$

$$T_{p,j} = T_j \cdot [\max(T_p) - \min(T_p)] + \min(T_p) \quad (10)$$

$$D_{m,j} = D_j \cdot \pi \quad (11)$$

式中: $H_j$ 、 $T_j$ 和 $D_j$ 为代表性子集中向量 $v_j$ 的波高、周期和波向; $H_{s,j}$ 、 $T_{p,j}$ 和 $D_{m,j}$ 为反归一化后的有效波高,谱峰周期和平均波向。

### 2.5 代表向量数目 $M$ 的确定

选择合适的  $M$  值对于挑选结果至关重要。筛选出代表性子集  $\mathbf{v}^*$  后, 利用公式(5)计算归一化后的数据集中向量  $\mathbf{x}_i$  与代表性子集中  $\mathbf{v}_j$  之间的欧氏距离  $\|\mathbf{x}_i - \mathbf{v}_j\|$ 。向量  $\mathbf{x}_i$  的类别与距离该向量最近的  $\mathbf{v}_j$  类别相同, 最终将所有数据样本划分为  $M$  簇 ( $C_1, C_2, \dots, C_M$ )。按式(12)计算的各数据样本与相应质心 ( $\mathbf{v}_j$ ) 的欧氏距离之和来定义挑选误差  $E$ 。随着  $M$  值的增大,  $E$  通常会下降, 然后在某一点后下降速度降低, 并趋向平稳。这个点可认为是最优  $M$  值。

$$E = \sum_{j=1}^M \sum_{\mathbf{x}_i \in C_j} \|\mathbf{x}_i - \mathbf{v}_j\| \quad (i = 1, \dots, N; j = 1, \dots, M) \quad (12)$$

式中:  $\mathbf{x}_i$  和  $\mathbf{v}_j$  分别代表归一化后数据集中第  $i$  个向量和反归一化前的代表性子集中的第  $j$  个向量;  $E$  为将数据集划分为  $M$  簇的挑选误差。

采用由 Portilla et al. [21] 改进的分水岭算法对波浪系统进行划分, 采用多波系表征法表征近岸波浪。经过划分将海浪谱划分为 1~4 个波浪系统, 对于每个波浪系统制定有效波高、谱峰周期、平均波向、谱峰升高因子 ( $\gamma$ )、方向分布参数 ( $\sigma$ ) 5 个波浪特征参数, 即 1 个海况由 20 个波浪特征参数描述。

根据图 3 不同工况数目下的误差  $E$ , 观察到  $M \geq 70$  时,  $E$  趋于稳定。取  $M=72$ , 运用 MDA 算法得到代表性工况  $\mathbf{v} = \{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{72}\}$ , 计算工况在实测数据中的分布如图 4 所示, 观察到计算工况在数据空间上分布十分均匀, 具有较好的代表性。




图 3 不同质心数目下的误差

Fig. 3 Errors under different numbers of centroids




图 4 选取计算工况结果 ( $N=1715, M=72$ )

Fig. 4 Results of calculated conditions ( $N=1715, M=72$ )

### 3 FUNWAVE-TVD 波浪数值模型设置

#### 3.1 计算域和数值设置

汉班托塔港的 FUNWAVE-TVD 数值模型设置如图 5 所示。计算域的大小为  $3.76 \text{ km} \times 3.84 \text{ km}$ , 网格尺寸为  $d_x = d_y = 4 \text{ m}$ 。采用 Wei et al. [22] 的内域造波理论生成不规则波, 造波区布置于计算域的南部, 在图 5 中由虚线标记。在离岸和模型侧向边界处设置海绵层吸收波浪。

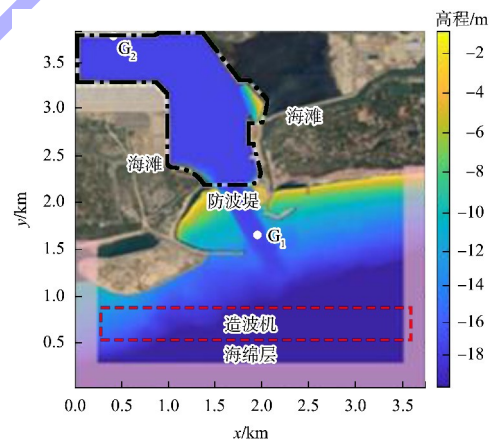


图 5 汉班托塔港 FUNWAVE-TVD 数值模型计算域

Fig. 5 FUNWAVE-TVD computational domain of Hambantota Port

#### 3.2 模型的输出

利用 FUNWAVE-TVD 模型将  $G_1$  测点计算工况的波浪信息 ( $H_s, T_p, D_m, g, s$ ) 推算到港内整个计算域, 构成数据集。短波风浪波高和长波涌浪波高是影响泊稳和安全的重要因素, 因此, 模型的输出为港内全场有效波高和低频波高。全场波高由  $511 \times 421$  的矩阵构成, 在图 5 中由点划线标记。

## 4 CNN 的设置

### 4.1 概述

近年来，机器学习在近岸工程中得到广泛应用，深度学习是实现机器学习的技术，通常使用

神经网络实现深度学习，CNN 是被广泛使用的深度学习工具。与其他神经网络相似，CNN 由输入层、输出层以及多个隐藏层组成。CNN 的基本架构如图 6 所示。

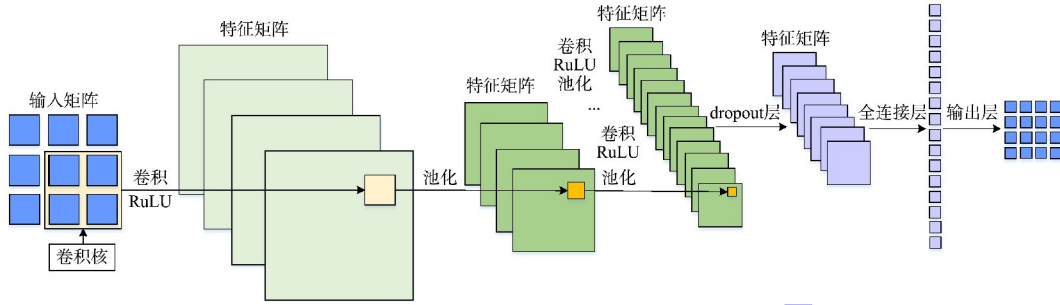


图 6 CNN 的基本架构

Fig. 6 Basic architecture of CNN

### 4.2 数据集的划分

卷积层的数量以及卷积核的个数对神经网络的性能具有重要影响，过少会导致模型拟合效果差精度较低，过大则会导致模型过拟合，不能准确估计港内波浪。因此，需比较各种具有不同卷积层、卷积核数量的 CNN，以确定网络的最优架构。本文利用  $k$ -fold 交叉验证的方法确定网络最优架构。

基于  $k$ -fold 交叉验证方法，如图 7 所示将数据集分为 3 部分，分别为训练集、验证集和测试集，其中，训练集和测试集统称为泛化集。按照随机分配的原则将 72 个计算工况分为 68 个泛化集和 4 个测试集。如图 7 所示，运用  $k=10$  的  $k$  次交叉验证方法，泛化集被随机分成大小近似相等的  $k$  个子集， $k-1$  个子集为训练集，剩余 1 个集合为验证集，基于验证集的均方误差确定网络的最优架构。




图 7  $k=10$  的  $k$  次交叉验证法

Fig. 7  $k$ -fold cross-validation method for  $k=10$

对于每个体系结构，网络被分别训练  $k$  次，使得每个子集都被用于 1 次验证。最后得到  $k$  个

验证误差，根据式 (13) 计算  $k$  次训练的  $k$  个验证误差。其均值  $\bar{E}_V$  用于表示特定架构的泛化能力。通过比较所有架构的  $\bar{E}_V$  选择最佳架构。

$$E_V = \frac{1}{nm} \sum_{i=1}^n \sum_{j=1}^m [(x_{ij}^{out})^* - (x_{ij}^{real})^*]^2 \quad (13)$$


式中： $x_{ij}^{out}$  为将验证集中第  $j$  个计算工况的波浪特征参数输入 CNN 得到的包含  $n$  个数据点的港内全场波高中第  $i$  个数据点的波高数据； $x_{ij}^{real}$  为第  $j$  个计算工况的港内全场波高数据中第  $i$  个数据点的 FUNWAVE-TVD 模拟值。

## 5 结果讨论

### 5.1 最优架构的挑选

运用  $k=10$  的  $k$  次交叉验证的方法，确定 CNN 的最优架构，对具有 2 个卷积层、3 个卷积层以及 4 个卷积层的不同体系结构进行比较。图 8 为不同 CNN 结构的平均验证误差  $\bar{E}_V$ ， $\bar{E}_V$  越小，网络架构的泛化能力越好，因此选取 [91][61][31] 为网络的最优架构，最优网络架构如图 9 所示。

以网络最优架构为例，图 10 为此架构的训练过程曲线。观察到均方误差  $E_{MS}$  和损失函数随迭代次数的增加不断降低，当网络达到最大训练次数时停止训练。训练轮数和训练样本的数目也需不断尝试，以寻求最优解。



注: [ ] 的数目代表 CNN 中卷积层数, 其中元素表示卷积核的大小。如 [31][31] 表示 2 个卷积层的网络架构, 每层卷积核大小为 3×3。

图 8 不同神经网络结构的平均验证误差  
Fig. 8 Average validation errors for different neural network structures

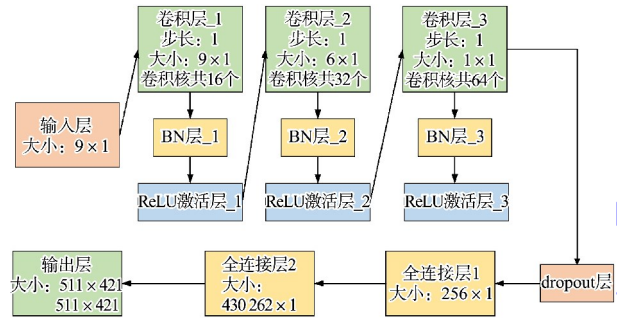


图 9 CNN 最优架构  
Fig. 9 Optimal architecture of CNN




图 10 CNN 最优架构在训练集上的均方误差随训练次数的变化曲线

Fig. 10 Curves of MSE for CNN optimal architecture at training set during training process


5.2 最优架构泛化能力的评估

测试集用于评估该网络架构在未知工况下的表现, 如表 1 所示, 为 4 个测试集对应的均方误差  $\bar{E}_v$ , 选取其中 1 个测试集展示网络预测港内全场有效波高的结果, 如图 11 所示, 观察到 CNN 在测试集上表现良好, 能够准确地估计未知情况下的全场波高, 证明了 FUNWAVE-TVD 和 CNN 模型的可靠性。

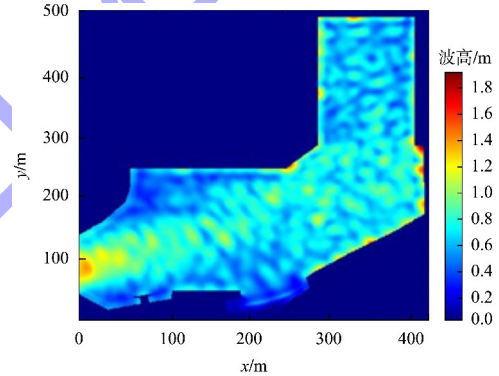
表 1 测试集对应的均方误差  $\bar{E}_v$

Tab. 1 Errors  $\bar{E}_v$  for test set

$\bar{E}_{v1}$	$\bar{E}_{v2}$	$\bar{E}_{v3}$	$\bar{E}_{v4}$
0.003 7	0.006 2	0.007 9	0.005 6



a) 预测全场低频波高



b) 目标全场低频波高

图 11 CNN 在测试集上的表现

Fig. 11 Performance of CNN on test set

6 结论

1) 基于汉班托塔港口多波浪系统的多维实测波浪数据, 采用 MDA 算法筛选的代表性子集在数据空间上分布十分均匀, 自动选择的代表性深水海况, 适用于挑选混合浪条件下的代表性波浪特征参数。

2) 基于验证集误差, 运用 k-fold 交叉验证方法在多种网络架构中确定出了最优架构。该网络结构在测试集上表现良好, 证明了该网络良好的泛化能力。

## 参考文献:

- 1 王岗,高俊亮,王培涛,等. 港湾共振研究综述 [J]. 海洋学报, 2017, 39(11): 1-13.  
WANG G, GAO J L, WANG P T, et al. Review on harbor resonance [J]. Acta oceanologica sinica, 2017, 39(11): 1-13.
- [2] BROWNE M, CASTELLE B, STRAUSS D, et al. Near-shore swell estimation from a global wind-wave model: spectral process, linear, and artificial neural network models [J]. Coastal engineering, 2006, 54(5): 445-460.
- [3] ZHAO Y P, BI C W, SUN X X, et al. A prediction on structural stress and deformation offish cage in waves using machine-learning method [J]. Aquacultural engineering, 2019, 85: 15-21.
- [4] LOPEZ I, LOPEZ M, IGLESIAS G. Artificial neural network applied to port operability assessment [J]. Ocean engineering, 2015, 109: 298-308.
- [5] HASHEMI M R, GHADAMPOUR Z, NEILL S P. Using an artificial neural network to model seasonal changes in beach profiles [J]. Ocean engineering, 2010, 37(14/15): 1345-1356.
- 6 李鸣,张鸿. 基于卷积神经网络迭代优化的图像分类算法 [J]. 计算机工程与设计, 2017, 38(1): 198-202, 214.  
LI M, ZHANG H. Image classification based on convolution neural network of iterative optimization [J]. Computer engineering and design, 2017, 38(1): 198-202, 214.
- [7] CAO Z M, YIN Q, TANG X O, et al. Face recognition with learning-based descriptor [C]// 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: Institute of Electrical and Electronics Engineers, 2010: 2707-2714.
- [8] DEMETRIOU D, MICHAILEDIS C, PAPANASTASIOU G, et al. Coastal zone significant wave height prediction by supervised machine learning classification algorithms [J]. Ocean engineering, 2021, 221: 108592.
- [9] WEI Z P, DAVISON A. A convolutional neural network base model to predict nearshore waves and hydrodynamics [J]. Coastal engineering, 2022, 171: 104044.
- [10] MONBALIU J, PADILLA-HERNANDEZ R, HARGREAVES J C, et al. The spectral wave model, WAM, adapted for applications with high spatial resolution [J]. Coastal engineering, 2000, 41(1): 41-62.
- [11] BOOIJ N, RIS R C, HOLTHUIJSEN L H. A third-generation wave model for coastal regions 1. model description and validation [J]. Journal of geophysical research(oceans), 1999, 104(C4): 7649-7666.
- [12] ABDOLALI A, ROLAND A, VAN DER WESTHUYSEN A, et al. Large-scale hurricane modeling using domain decomposition parallelization and implicit scheme implemented in WAVEWATCHIII wave model [J]. Coastal engineering, 2020, 157: 103656.
- [13] SHI F, KIRBY J T, HARRIS J C, et al. A high-order adaptive time-stepping TVD solver for Boussinesq modeling of breaking waves and coastal inundation [J]. Ocean modelling, 2012, 43/44: 36-51.
- [14] GRILLI S T, SHELBY M, KIMMOUN O, et al. Modeling coastal tsunami hazard from submarine mass failures: effect of slide rheology: experimental validation and case studies off the US East Coast [J]. Natural hazards, 2017, 86(1): 353-391.
- [15] GAO J L, JI C Y, GAIDAI O, et al. Numerical investigation of transient harbor oscillations induced by N-waves [J]. Coastal engineering, 2017, 125: 119-131.
- [16] CHOI Y K, SEO S N, CHOI J Y, et al. Wave prediction in a port using a fully nonlinear Boussinesq wave model [J]. Acta oceanologica sinica, 2019, 38(7): 36-47.
- [17] 郑崇伟,李崇银,李训强. 印度洋的风浪、涌浪和混合浪的时空特征 [J]. 解放军理工大学学报(自然科学版), 2016, 17(4): 379-385.  
ZHENG C W, LI C Y, LI X Q. Temporal and spatial distribution of wind sea, swell and mixed wave in India Ocean [J]. Journal of Army Engineering University of PLA(natural science edition), 2016, 17(4): 379-385.
- [18] ZHENG C W, LI C Y. Analysis of temporal and spatial characteristics of waves in the Indian Ocean based on ERA-40 wave reanalysis [J]. Applied ocean research, 2017, 63: 217-228.