

· 综 合 ·



## 基于最大差异选择算法的代表性海况选取\*

王潇晨<sup>1</sup>, 郑振钧<sup>1</sup>, 董华伟<sup>1</sup>, 李鹏达<sup>2</sup>, 吴宇飞<sup>2</sup>, 郑艳娜<sup>3</sup>, 马小舟<sup>1</sup>, 董国海<sup>1</sup>

(1. 大连理工大学海岸和近海工程国家重点实验室, 辽宁 大连 116024;

2. 深圳大学 广东省滨海土木工程耐久性重点实验室, 广东 深圳 518060;

3. 大连海洋大学 海洋与土木工程学院, 辽宁 大连 116023)

**摘要:** 数值模拟及物理模型试验是研究近岸波浪的重要方法。在实施数值模拟和物理模型试验前, 需要根据近岸波浪特征确定入射波浪要素。近岸波浪往往是由混合浪主导的, 包含多个独立的波浪系统, 每个波系都需用多个波浪特征参数进行描述, 因此实现多波浪系统的代表性海况的选取具有重要意义。首先介绍了数据挖掘算法, 随后根据汉班托塔港的实测波浪数据, 运用最大差异选择算法(MDA)分别选取了二维、三维以及多维特征参数描述下的代表性波浪条件。结果表明, 对于可进入行为筛选的二维波浪特征参数, MDA 算法的筛选结果优于人工筛选结果。在三维及多维波浪特征参数条件下, MDA 算法选取的代表性海况在数据空间上分布均匀, 具有较高的代表性, 证实了 MDA 算法适用于选取混合海况下的代表性波浪特征参数。

**关键词:** 最大差异选择算法; 波浪观测; 代表性海况; 混合浪; 多波浪系统

中图分类号: U652; O353.2

文献标志码: A

文章编号: 1002-4972(2024)01-0001-07

### Selection of representative sea states based on maximum dissimilarity algorithm

WANG Xiaochen<sup>1</sup>, ZHENG Zhenjun<sup>1</sup>, DONG Huawei<sup>1</sup>, LI Pengda<sup>2</sup>, WU Yufei<sup>2</sup>, ZHENG Yanna<sup>3</sup>,  
MA Xiaozhou<sup>1</sup>, DONG Guohai<sup>1</sup>

(1. The State Key Laboratory of Coastal and Offshore Engineering, Dalian University of Technology, Dalian 116024, China;

2. Guangdong Provincial Key Laboratory of Durability for Marine Civil Engineering, Shenzhen University, Shenzhen 518060, China;

3. School of Ocean and Civil Engineering, Dalian Ocean University, Dalian 116023, China)

**Abstract:** Numerical simulation and physical model experiment are important methods for studying nearshore wave. Before implementing numerical simulation and physical experiments, it is necessary to determine the incident waves elements based on the characteristics of nearshore waves. Nearshore waves are typically dominated by mixed waves, which contain multimodal independent wave systems, each of which requires several wave characteristic parameters for complete description. It is of great significance to realize the selection of representative sea states for multimodal wave systems. Firstly, this paper introduces popular data mining algorithms, and then according to the measured wave data of Hambantota Port, it selects the representative wave conditions defined by two-dimensional, three-dimensional and multi-dimensional wave characteristic parameters respectively using maximum dissimilarity algorithm(MDA). The results show that the outcome of the MDA is better than the manual results for the two-dimensional wave parameters that can be artificially selected. If the wave conditions are defined by three-dimensional or even multidimensional wave characteristic parameters, the representative sea states selected by MDA

收稿日期: 2023-04-20

\*基金项目: 深圳市科技计划项目(KQTD20200820113004005), 国家自然科学基金面上项目(52071060); 中央高校基本科研业务费资助项目(DUT22LAB101, DUT22RC(6)006); 辽宁省教育厅资助项目(LJKZ0717)

作者简介: 王潇晨(1998—), 女, 硕士研究生, 从事近岸波候研究。

通讯作者: 郑振钧(1994—), 男, 博士, 助理研究员, 从事港湾振荡致灾机理及防灾减灾的研究。E-mail: zjzheng@dlut.edu.cn

algorithm are even distribution in data space and have high representativeness, which proves the MDA algorithm is suitable for selecting representative wave characteristic parameters under mixed sea conditions.

**Keywords:** maximum dissimilarity algorithm; wave measurement; representative sea state; mixed wave; multimodal wave system

现场观测、数值模拟和物理模型试验是研究波浪问题的重要方法。近岸波候的表征需要长时间的波浪特征参数序列。当观测数据或大尺度波浪模型数据位于深水区时,需采用波浪数值模型将重要的波浪信息推算到浅水区。为了减少模拟工况的数量,通常用少量代表性海况作为整体海况的近似。

当基于全谱的波浪特征参数(有效波高、谱峰周期和平均波向等)表征海况时,一般可人为挑选代表性海况。而面对高维特征参数描述的海况时,人工方式存在局限性。此外,基于全谱的表征方法忽略了海浪的内部组成,将海浪视为单一波系,只适用于纯风浪或纯涌浪海况。自然界中海浪通常以风浪和涌浪混合的形式存在。为了更加真实、准确地描述混合浪,需利用谱分割技术将海浪划分为不同的波浪系统并分别进行参数化表征。由于波浪描述的精细化,波浪特征参数也成倍增加,导致混合浪海况下代表性波要素的选取变得异常复杂,因此需要设计、开发和应用一些计算机算法,实现复杂海况下代表性波浪特征参数的选取。

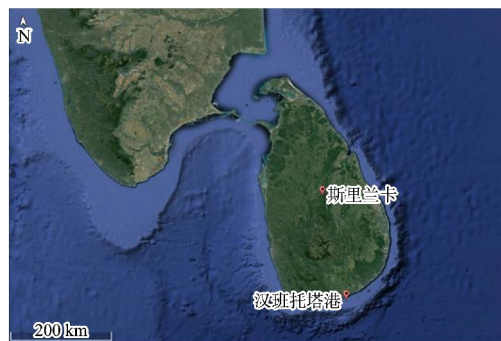
$K$ -means( $K$ -means clustering algorithm)算法<sup>[1]</sup>和 SOM(self-organizing maps)算法<sup>[2]</sup>是目前比较流行的两种聚类技术,已经被应用到土木工程、化学、生物学、气象学等多个领域<sup>[3-8]</sup>。MDA(maximum dissimilarity algorithm)算法是特征选择算法的一种,在 1969 年由 Kennard 等<sup>[9]</sup>提出,而后被应用于化学、生物学和海洋学等多个领域<sup>[10-12]</sup>。相较于聚类算法,MDA 算法可以自动识别数据空间边界上的元素,选择的向量在数据样本上分布更加均匀,更具代表性。

本文首先对  $K$ -means 算法和 SOM 算法等聚类

技术进行简要介绍,随后详细介绍 MDA 算法的实现过程以及算法中质心(文中为代表性海况)数量的设定依据,最后结合汉班托塔港口的实测资料,探索 MDA 算法在海洋工程中的应用。

## 1 实测数据

研究海域和测点信息见图 1。汉班托塔港面向北印度洋,没有岛礁和陆架的掩护,受外海涌浪影响显著<sup>[13]</sup>。在西南季风期间,印度洋的涌浪达到最大值<sup>[14-15]</sup>,并且由于风速增大,风浪、涌浪混合情况加剧。本文选取 2019 年汉班托塔海域实测的 1 800 组波浪数据进行分析。波浪采集设备为 Nortek AWAC 传感器,每小时观测一次,每次记录 20 min,采样频率为 2 Hz。



a) 汉班托塔港地理位置



b) 汉班托塔港近岸波浪测点位置

图 1 研究海域及测点位置

风涌浪的分离可根据海浪谱的维数分为一维谱方法和二维谱方法<sup>[16]</sup>。一维谱方法通过求解分割频率<sup>[17]</sup>或运用谱拟合的方法<sup>[18]</sup>对频谱进行高低频划分, 实现风涌浪的分离。这类方法操作相对简单, 但对多涌浪的复杂海况难以给出准确的分离结果。二维谱方法利用分水岭算法将海浪谱划分为独立的波浪系统, 然后对各个波浪系统进行风涌浪成分的识别, 这类方法考虑的信息较为全面, 理论上能够给出更为准确的分离结果。研究选用由 Portilla 等<sup>[19]</sup>改进的分水岭算法对二维谱进行波系分离。根据分离结果, 汉班托塔海域实测谱中至多存在 4 个波浪系统, 每个波系均通过有效波高  $H_s$ 、谱峰周期  $T_p$ 、平均波向  $D_m$ 、谱峰升高因子  $\gamma$  及方向分布参数  $\sigma$  5 个波浪特征参数进行表征, 对于不存在的波系用空值描述, 每个海浪谱由 20 个波浪特征参数表征。

## 2 数据挖掘技术方法

### 2.1 K-means 算法

K-means 算法中的  $K$  表示数据集中的质心个数, means 代表均值, 即质心为其所代表的数据的平均值。数据集  $X = \{x_1, x_2, \dots, x_N\}$  由  $N$  个  $n$  维向量组成, 其中  $x_i = \{x_{1i}, x_{2i}, \dots, x_{ni}\}$ 。从数据集中随机选择  $K$  个向量  $\{v_1, v_2, \dots, v_K\}$  作为初始质心, 其中  $v_j = \{v_{1j}, v_{2j}, \dots, v_{nj}\}$ 。按公式(1)计算数据集中每个向量与  $K$  个质心的欧式距离  $d$ , 将向量聚类到距离最近的质心的簇内, 最终划分为  $K$  个簇 ( $C_1, C_2, \dots, C_K$ )。

$$d = \|x_i - v_j\| \quad (i = 1, \dots, N; j = 1, \dots, K) \quad (1)$$

所有向量归好相应的簇后, 按公式重新计算每个簇的质心, 直到实现最小平方误差停止迭代, 最小平方误差按照公式计算。经过迭代得到代表性子集  $v = \{v_1, v_2, \dots, v_K\}$ 。

$$v_j = \sum_{x_i \in C_j} \frac{x_i}{n_j} \quad (i = 1, \dots, N; j = 1, \dots, K) \quad (2)$$

$$E = \sum_{j=1}^K \sum_{x_i \in C_j} \|x_i - v_j\|^2 \quad (i = 1, \dots, N; j = 1, \dots, K) \quad (3)$$

式中:  $n_j$  为  $C_j$  包含向量的个数;  $v_j$  是  $C_j$  的均值向量, 也称之为质心。

K-means 算法所定义的代表性子集为数据样本的平均值, 能够综合最具代表性的海况来定义平均波候, 可用于对代表性波候敏感而对极端波候不敏感的港口作业分析等近岸应用。

### 2.2 SOM 算法

SOM 算法是一种无监督的人工神经网络, 在 K-means 的基础上加以改进, 通过学习输入空间中的数据, 生成一个低维、离散的映射, 将高维空间分布转移到二维空间上的概率密度函数, 使得分类效果更加直观。SOM 算法不同于 K-means 算法的是需要运用公式(4)在每次迭代中计算“获胜”质心  $v_{g(i)}$ ,  $v_{g(i)}$  是最接近向量  $x_i$  的质心。

$$\|v_{g(i)} - x_i\| = \min_j \{\|v_j - x_i\|\} \quad (i = 1, \dots, N; j = 1, \dots, K) \quad (4)$$

在迭代训练过程中, 不仅“获胜”质心向数据向量移动, 邻近的质心也向着数据向量移动, 运用公式将高维空间的拓扑关系映射到低维空间:

$$v_j = v_j + \alpha h(g(i), j)(x_i - v_j) \quad (i = 1, \dots, N; j = 1, \dots, K) \quad (5)$$

式中:  $\alpha$  为学习率, 可控制自适应过程的速度;  $h(g(i), j)$  决定了“获胜”质心周围的变化率。

与 K-means 算法相同, SOM 算法所选取的代表性子集是聚类均值, 不是向量本身, 其对多维数据提供了简单概率分析, 是对多维数据进行可视化的最佳算法。

### 2.3 MDA 算法

#### 2.3.1 MDA 算法的实现

MDA 算法基于向量间的最大差异来选择数据库中的代表性子集。该算法从向量  $v_1$  对代表性子集进行初始化, 剩余的  $M-1$  个向量需迭代选择。

当算法迭代  $M$  次时, 筛选过程完成, 计算流程如下:

1) 向量的归一化。以  $N$  个三维向量组成的数据集为例说明, 初始数据集为  $\mathbf{x}_i^* = \{H_{s,i}, T_{p,i}, D_{m,i}\} (i=1, \dots, N)$ 。将  $H_{s,i}$ 、 $T_{p,i}$  和  $\theta_{m,i}$  分别按照式(6)~(8)进行归一化处理, 得到归一化后的数据集为  $\mathbf{x}_i = \{H_i, T_i, D_i\} (i=1, \dots, N)$ 。

$$H = \frac{H_s - \min(H_s)}{\max(H_s) - \min(H_s)} \quad (6)$$

$$T = \frac{T_p - \min(T_p)}{\max(T_p) - \min(T_p)} \quad (7)$$

$$D = \frac{D_m}{\pi} \quad (8)$$

2)  $\mathbf{v}_1$  的选取。由公式计算数据集中的每个向量  $\mathbf{x}_i$  与剩余  $N-1$  个向量  $\mathbf{x}_k (k \neq i)$  的欧式距离之和  $d_i$ ,  $d_i$  最大时表明向量  $\mathbf{x}_i$  与数据集中的剩余向量具有最大相异性, 故取该向量为代表性子集的第一个向量  $\mathbf{v}_1$ 。

$$d_i = \text{sum}$$

$$(\sqrt{(H_i - H_k)^2 + (T_i - T_k)^2 + (\min(|\theta_i - \theta_k|, 2 - |\theta_i - \theta_k|))^2}) \quad (i=1, \dots, N; k=1, \dots, i-1, i+1, \dots, N) \quad (9)$$

3)  $\{\mathbf{v}_2, \dots, \mathbf{v}_M\}$  的确定。若代表性子集已确定  $R$  个向量 ( $R \leq M$ ), 在选择第  $R+1$  个向量时, 需按式计算数据集 (包含  $N-R$  个向量) 中每个剩余向量  $\mathbf{x}_i$  与代表性子集之间的相异性  $d_{i, \text{subset}(R)}^{\min}$ ,  $N-R$  个剩余向量对应  $N-R$  个  $d_{i, \text{subset}(R)}^{\min}$ 。最大  $d_{i, \text{subset}(R)}^{\min}$  对应的向量为代表性子集中第  $R+1$  个向量  $\mathbf{v}_{R+1}$ 。 $d_{i,R}$  表示数据集中向量  $\mathbf{x}_i$  与转移到代表性子集的最后—个向量  $\mathbf{v}_R$  之间的相异性, 其中向量之间的相异性可按式(11)计算, 向量与在上一代表性子集 (包含  $R-1$  个向量) 之间的相异性可按(12)计算。

$$d_{i, \text{subset}(R)}^{\min} = \min [d_{i,R}, d_{i, \text{subset}(R-1)}^{\min}] \quad (10)$$

$$d_{i,j} = \|\mathbf{x}_i - \mathbf{v}_j\| \quad (i=1, \dots, N-R; j=1, \dots, R) \quad (11)$$

$$d_{i, \text{subset}(R-1)} = \min \left\{ \|\mathbf{x}_i - \mathbf{v}_j\| \right\} \quad (i=1, \dots, N-R; j=1, \dots, R) \quad (12)$$

4) 向量的反归一化。将代表性子集中的向量按式(13)~(15)进行反归一化处理:

$$H_{s,j} = H_j \cdot (\max(H_s) - \min(H_s)) + \min(H_s) \quad (13)$$

$$T_{p,j} = T_j \cdot (\max(T_p) - \min(T_p)) + \min(T_p) \quad (14)$$

$$D_{m,j} = D_j \pi \quad (15)$$

最终得到反归一化后的代表性子集  $\mathbf{v}^* = \{\mathbf{v}_1^*, \mathbf{v}_2^*, \dots, \mathbf{v}_M^*\}$ 。 $\mathbf{v}_1^*$  是与其余数据最不相似的向量, 表示位于数据空间边缘的一个点。 $\mathbf{v}_2^*$  表示与  $\mathbf{v}_1^*$  最不相似的向量,  $\{\mathbf{v}_3^*, \mathbf{v}_4^*, \dots, \mathbf{v}_M^*\}$  是按照最大相异性迭代选择的代表性数据。MDA 算法从数据样本所有域 (包括数据外围) 中选择代表性子集, 使得子集分布非常均匀。

### 2.3.2 质心 $M$ 的确定

通过 MDA 算法筛选出代表性子集  $\mathbf{v}^*$  后, 利用式(16)计算数据样本中的  $\mathbf{x}_i$  与代表性数据  $\mathbf{v}_j^*$  之间的欧氏距离, 向量  $\mathbf{x}_i$  的类别与距离该向量最小的  $\mathbf{v}_j^*$  的类别相同, 最终将所有数据样本划分为  $M$  簇 ( $C_1, C_2, \dots, C_M$ )。按公式通过计算每个数据样本与相应质心的欧氏距离之和来定义误差  $E$ , 进而确定  $M$  的取值,  $E$  随  $M$  的增大不断减小, 当  $E$  趋于稳定时,  $M$  的取值较为合理。

$$\begin{aligned} \|\mathbf{x}_i - \mathbf{v}_j\| &= \sqrt{(H_i - H_j)^2 + (T_i - T_j)^2 + (\min(|D_i - D_j|, 2 - |D_i - D_j|))^2} \\ &\quad (i=1, \dots, N; j=1, \dots, M) \end{aligned} \quad (16)$$

$$E = \sum_{j=1}^M \sum_{\mathbf{x}_i \in C_j} \|\mathbf{x}_i - \mathbf{v}_j\| \quad (i=1, \dots, N; j=1, \dots, M) \quad (17)$$

## 3 代表性海况的选取

### 3.1 人为筛选二维代表性海况

基于 2019 年汉班托塔港二维实测资料 ( $H_s, T_p$ ), 人工筛选代表性子集, 实测数据数量  $N=1\,800$  组, 从中选取的代表性海况数量  $M=25$  组。筛选结果如图 2 所示, 选取的代表性子集整齐地排列分布于数据样本空间上, 包含部分数据边缘的向量。








图 2 人工筛选二维代表性海况结果  
( $N=1\ 800$ ,  $M=25$ )



a)  $M=10$



b)  $M=25$

图 3 不同质心数下 MDA 算法选取二维代表性海况结果 ( $N=1\ 800$ )




图 4 不同质心数下的误差

### 3.2.2 MDA 算法筛选三维代表性海况


面对三维以及多维数据, 人工筛选十分困难, 需借助 MDA 算法选取代表性海况。基于 2019 年

## 3.2 MDA 算法筛选代表性海况


### 3.2.1 MDA 算法筛选二维代表性海况

不同于人为筛选, 运用 MDA 算法筛选代表性子集前首先要确定代表性海况的数量  $M$ 。为了直观理解  $M$  对筛选结果的影响, 图 3 展示了 MDA 算法在不同质心数下对二维实测波浪数据的选取结果, 可见随着  $M$  的增加, 选取的数据向量在数据空间上分布更加均匀, 更具代表性。根据图 4 不同质心数下的误差, 观察到  $M \geq 25$  时,  $E$  趋于稳定, 故取  $M=25$ 。相较人工筛选结果, MDA 算法选取的代表性数据在样本空间上分布更加均匀, 并且可自动识别数据空间边界上的元素。

汉班托塔港的三维实测波浪数据 ( $H_s$ 、 $T_p$ 、 $D_m$ ) 分析误差曲线, 取  $M=25$ 。运用 MDA 算法筛选代表性海况结果如图 5 所示, 代表性子集在数据空间上分布十分均匀。





a) 三维数据筛选结果可视化

b) 三维数据筛选结果二维( $H_s$ 、 $T_p$ )可视化图5 MDA 算法选取三维代表性海况结果 ( $N=1\,800, M=25$ )



### 3.2.3 MDA 算法筛选多维代表性海况

基于 2019 年汉班托塔港的实测波浪数据, 运用改进的分水岭算法<sup>[20]</sup>将海浪谱划分为 4 个波浪系统, 每个波浪系统由 5 个波浪特征参数( $H_s$ 、 $T_p$ 、 $D_m$ 、 $\gamma$ 、 $\sigma$ )描述, 每个海浪谱由 20 个波浪特征参数描述。经过分析误差曲线, 取  $M=40$ 。主要从同一波浪系统下不同参数的筛选结果以及不同波浪系统下不同参数的筛选结果两方面检验 MDA 算法在多维数据下的性能。

1) 同一波浪系统下不同参数。 $M=40$  时, 基于多维的实测波浪数据, 筛选结果如图 6 所示, 其中  $H_{s1}$ 、 $T_{p1}$ 、 $D_{m1}$  分别代表第一个波浪系统的有效波高、峰值周期和平均方向。MDA 算法所选取的代表性子集不仅分布于数据密集区域, 而且也分布于数据边缘区域, 可自动选择代表性深水海况。此外, 在多维数据可视化的过程中, 由于部分数据特征不能完全显示, 故可能出现代表性数据分布不均匀的情况。

a) 多维数据筛选结果三维 ( $H_{s1}$ 、 $H_{p1}$ 、 $H_{m1}$ ) 可视化b) 多维数据筛选结果二维( $H_{s1}$ 、 $D_{m1}$ )可视化图6 MDA 算法选取多维代表性海况结果 ( $N=1\,800, M=40$ )

2) 不同波浪系统下不同参数。 $M=40$  时, 基于多维的实测波浪数据, 筛选结果如图 7 所示, 其中  $\gamma_1$  代表第一个波浪系统的谱峰升高因子,  $T_{p2}$  代表第二个波浪系统的谱峰周期。可见代表性子集在整个数据集上分布十分均匀。

a) 多维数据筛选结果三维 ( $H_{s1}$ 、 $H_{p2}$ 、 $\gamma_1$ ) 可视化b) 多维数据筛选结果二维( $H_{s1}$ 、 $\gamma_1$ )可视化图7 MDA 算法选取多维代表性海况结果 ( $N=1\,800, M=40$ )

## 4 结论

1) 基于汉班托塔港口单波浪系统的二维实测

波浪数据,MDA算法选取的代表性子集较人工筛选结果而言,其在样本空间上分布更加均匀,更具代表性,并且可以自动识别数据空间边界上的元素。

2) 基于汉班托塔港口单波浪系统的三维实测波浪数据,MDA算法在选取代表性子集方面表现良好,不仅从数据密集区域,而是从数据内部以及数据外围选择代表性子集,使得所选取的代表性子集在数据样本所有域上分布十分均匀。

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

#### 参考文献:

- [1] HASTIE T, TIBSHIRANI R, FRIEDMAN J. The elements of statistical learning[M]. New York: Springer, 2001.
- [2] KOHONEN T. Fast evolutionary learning with batch-type self-organizing maps[J]. Neural processing letters, 1999, 9(2): 153-162.
- [3] PARK Y S, VERDONSCHOT P, CHON T S, et al. Patterning and predicting aquatic macroinvertebrate diversities using artificial neural network [J]. Water research, 2003, 37(8): 1749-1758.
- [4] HONG Y, HSU K L, SOROOSHIAN S, et al. Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system [J]. Journal of applied meteorology, 2004, 43(12): 1834-1852.
- [5] HONG Y, HSU K L, SOROOSHIAN S, et al. Self-organizing nonlinear output (SONO): A neural network suitable for cloud patch-based rainfall estimation at small scales [J]. Water resources research, 2005, 41(3): W03008. 1-W03008. 15.
- [6] BROSSE S, GIRAUDÉL J L, LEK S. Utilisation of non-supervised neural networks and principal component analysis to study fish assemblages [J]. Ecological modelling, 2001, 146(1-3): 159-166.
- [7] 孟海东, 孙家驹, 殷跃, 等. 基于聚类分析的地球化学数据分布特征研究[J]. 有色矿冶, 2012, 28(2): 1-3.
- [8] 沙鹏, 倪吉吉, 汪自学, 等. 基于优化的 K 均值算法对岩体结构面产状聚类分析[J]. 绍兴文理学院学报(自然科学), 2023, 43(1): 16-21.
- [9] KENNARD R W, STONE L A. Computer Aided Design of Experiments[J]. Technometrics, 1969, 11(1): 137-148.
- [10] CAMUS P, MENDEZ F J, MEDINA R, et al. Analysis of clustering and selection algorithms for the study of multivariate wave climate [J]. Coastal engineering, 2011, 58(6): 453-462.
- [11] SNAREY M, TERRETT N K, WILLETT P, et al. Comparison of algorithms for dissimilarity-based compound selection [J]. Journal of molecular graphics & modelling. 1997, 15(6): 372-385.
- [12] WILLETT P. Dissimilarity-based algorithms for selecting structurally diverse sets of compounds [J]. Journal of computational biology, 1999, 6(3-4): 447-457.
- [13] DONG G H, ZHENG Z J, MA X Z, et al. Characteristics of low-frequency oscillations in the Hambantota Port during the southwest monsoon [J]. Ocean engineering, 2020, 208(Jul. 15): 107408. 1-107408. 10.
- [14] 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.
- [15] 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.
- [16] 林伊楠, 陶爱峰, 李雪丁, 等. 台湾海峡风涌浪分离方法研究[J]. 海洋学报, 2019, 41(11): 25-34.
- [17] WANG D W, HWANG P A. An operational method for separating wind sea and swell from ocean wave spectra[J]. Journal of atmospheric and oceanic technology, 2001, 18(12): 2052-2062.
- [18] 朱绍华, 于文太, 李广帅, 等. 基于双峰海浪谱的风浪和涌浪分离应用研究[J]. 中国造船, 2017, 58(4): 160-167.
- [19] PORTILLA J, OCAMPO-TORRES F J, MONBALIU J. Spectral partitioning and identification of wind sea and swell [J]. Journal of atmospheric and oceanic technology, 2009, 26(1): 107-122.

(本文编辑 王传瑜)