

# 類神經網路和支撐向量機建立瘋狗浪預警系統之校驗與比較

陳威成<sup>1</sup> (Chen W.-C.) 陳盈智<sup>1</sup> (Chen Y.-C.) 滕春慈<sup>2</sup> (Teng C.-T.) 林芳如<sup>2</sup> (Lin F.-R.) 董東環<sup>1</sup> (Doong D.-J.)  
蔡政翰<sup>3</sup> (Tsai C.-H.)

<sup>1</sup>國立成功大學 水利及海洋工程學系 <sup>2</sup>交通部中央氣象局 海象測報中心  
<sup>3</sup>國立臺灣海洋大學 海洋環境資訊系

## 摘要

海洋變化萬千，發生在近岸區域的異常波浪頻繁地造成民眾危害，亟需建立預警機制，保障民眾海域遊憩活動的安全，近年來中央氣象局致力於環島異常波浪預警系統之建置，提升對於異常海象預警能力。本研究為精進異常波浪預警技術，以類神經網路和支撐向量機方法嘗試建立，以新北市龍洞海岸進行測試，選用示性波高、平均週期、波向、平均風速、風向、波浪尖銳度、尖峰週期、湧浪波高、湧浪週期、班傑明非線性指數(BFI)、水位變化峰度係數、窄度係數(narrowness)、譜尖參數(peakness)等13個因子建立預測模式，透過瘋狗浪發生時之實測資料訓練，獲得預測模式最佳的相關參數，並比較兩種不同的方法，初步分析在各項驗證指標顯示，以類神經網路方法預測近岸異常波浪發生機率之正確性可達9成以上，而以支撐向量機方法預測近岸異常波浪發生或未發生機率之正確性皆可達7成以上，顯示兩種預警系統皆具有很高之參考性。

**關鍵字：**近岸異常波浪、類神經網路、支撐向量機、機器學習、機率預警

## 一、前言

台灣四面環海，海岸遊憩活動興盛，而海岸瘋狗浪(coastal freak wave)常將海岸邊的遊客或是釣客捲入海中，常見於如礁岩、消波塊及近海面的平台等區域，瘋狗浪一詞為一種俗稱，尚未有明確的定義，只要是在岸邊激起可能傷害到人員的大浪就可以稱之為瘋狗浪，且瘋狗浪發生機制未明且複雜，至今仍未有完整理論可以說明，綜合目前的研究，瘋狗浪的發生可能與當地的地形條件以及海氣象條件有關。台灣周遭海域常有釣客或是遊客遭到海岸瘋狗浪襲擊的事件發生，因此在每年造成不少死傷人數，以及耗費大量救災資源。據中央氣象局(2019)統計2000至2019年間在台灣地區的發生海岸瘋狗浪事件有360件合計589人落海，平均每一年會發生約18件瘋狗浪事件、約29人落海，因此若能對瘋狗浪發生時機有所掌握，即可提前發布預警，也能使民眾的生命安全有更多保障。

近年因電腦計算能力增強，對於利用資料探勘和機器學習方法預測自然現象的研究層出不窮，其中機器學習方法包含類神經網路(artificial neural network)、支撐向量機(support vector machine)、隨機森林(random forest)等，主要透過對輸入資料進行分析，從資料中找出規律或特徵進而對新的資料進行準

確的預測，其中類神經網路和支撐向量機即為本研究使用的方法。類神經網路是透過讓電腦學習與人腦結構相同的神經傳遞訊息與反應動作的過程，類神經網路為監督式學習方法，給予類神經網路輸入值和學習目標值來讓其能建立輸入值和學習目標值之間的關係，類神經網路的學習能力強，擁有較高的強健性(robustness)，能有效處理非線性的關係，應用在如瘋狗浪機制目前尚未明確發生機制的自然現象上，類神經網路都能訓練出不錯的效果。支撐向量機是一種以嚴謹數學理論為基礎的機器學習方法，由資料中的少數資料來決定分類函式，得到對資料分布的結構化敘述，減低了對資料規模和分布的要求，因此支撐向量機對於小樣本資料的訓練上能得到比其他機器學習方法更好的結果，能避免過擬合問題(overfitting)且泛化能力(generalization ability)好；對非線性特徵資料則能透過核函數(kernel function)映射資料至高維空間找出分類函式，有效處理高維度數據問題。

而本研究目的為建置瘋狗浪機率預警系統，並比較不同機器學習方法，如瘋狗浪目前發生機制尚未明確且發生案例並不多的自然現象，擁有非線性的特性，因此對於預測瘋狗浪的訓練，可採用對於非線性資料較有效的機器學習方法。類神經網路和支撐向量機擁有有效處理非線性資料的能力，預期能有效針對瘋狗浪事件建置瘋狗浪預警系統。

## 二、研究區域與資料

### (一)研究區域

本研究的主要研究區域為位於新北市貢寮區的龍洞海岸，其中又專注於研究該區域的龍洞灣岬發生的瘋狗浪事件，同時結合鄰近於該區域的龍洞浮標以利研究。龍洞灣岬左側面山、右側面海，有因海蝕作用造成懸崖峭壁的地形，且因為位於台灣海岸東北部的關係，容易受到東北季風影響而常有湧浪，但長年以來仍有不少釣客和遊客冒著風險前往此地進行遊憩活動，也因此累積不少岸邊人員落海事件。因應當地的瘋狗浪事件較多和鄰近浮標可提供海氣象數據等特性，本研究選定在該區域進行瘋狗浪的研究。

因此中央氣象局(2019)自 2016 年至今在龍洞海岸的建築物上架設攝影機拍攝龍洞灣岬，影像經過王(2017)分析後得到瘋狗浪發生的時間並且透過鄰近的龍洞浮標得到瘋狗浪發生當下的海氣象數據，以提供瘋狗浪資料，圖 1 標示出本研究為收集瘋狗浪事件設置的光學監視站和其拍攝的地點，以及鄰近的龍洞浮標位置。圖 2 則為光學監視站拍攝瘋狗浪發生時之原始全彩影像。



圖 1 本研究的主要研究區域，圖中標示出光學監視站、近岸浮標以及龍洞灣岬的位置



圖 2 光學監視站拍攝瘋狗浪發生時之原始全彩影像(中央氣象局，2019)

### (二)潛在因子

瘋狗浪發生的機制雖目前仍尚未明確，但已有不少的前人文獻探討可能有關於瘋狗浪發生的潛在因子(White and Fornberg, 1998; Chien et al., 2002; Janssen, 2003; Tsai et al., 2004; Dyachenko and Zakharov, 2005; Mori and Janssen, 2006; Zakharov et al., 2006; Tamura et al., 2009)，因此除了有關於波浪的基本海氣象因子外，本研究也參考前人文獻的研究結果來決定輸入訓練過程的影響瘋狗浪發生之潛在

因子，如表 1 所示，本研究選取了 6 種不同類別因子，一共 13 個因子來訓練。

表 1 影響瘋狗浪發生的潛在因子

海象類別因子	示性波高
	平均週期
氣象類別因子	平均風速
方向類別因子	波向
	風向
湧浪類別因子	尖峰週期
	湧浪波高
	湧浪週期
	波浪尖銳度
非線性類別因子	峰度
	BFI 值
波浪群性因子	窄度係數
	譜尖參數

### (三)研究資料

本研究透過光學監視站得到瘋狗浪發生的時間，以一個小時為間隔，該小時內發生一個或一個以上的瘋狗浪事件即視為一筆瘋狗浪資料，將 2016~2018 年的瘋狗浪事件整理成以一個小時為單位並且同樣以該時間結合同個區域的龍洞浮標量測到的海氣象數據，最終得到共 717 筆瘋狗浪資料。

而為了避免訓練不平衡(imbalanced training)，從 2016~2018 年間的龍洞浮標海氣象數據中，隨機選取同瘋狗浪資料數量的資料，因應目前光學監視站無法拍攝到夜晚的瘋狗浪影像，因此捨去所有在夜晚的海氣象數據後，再從中隨機選取無瘋狗浪資料。

當在分析擁有不同因子的資料時，因為因子之間的單位不同，其數值大小的代表性也各不相同，影響機器學習訓練的結果。因此為有效地訓練，可對資料進行正規化(normalization)，藉由將原始資料轉換成無因次的純量後，再進行機器學習的訓練。本研究設定資料正規化的上下限範圍為 0~1 之間，如下式所示：

$$y' = lower + (upper - lower) * \frac{y - min}{max - min} \quad (1)$$

式中  $y$  為縮放前的數據、 $y'$  為縮放後的數據； $lower$  為指定的縮放下限、 $upper$  為指定的縮放上限； $min$  為原始數據的最小值、 $max$  為原始數據的最大值。

如下表 2 所示，將已資料正規化的瘋狗浪資料與無瘋狗浪資料各取出 70% 的資料作為機器學習的訓練資料，剩餘的 30% 作為驗證預測效果的驗證資料。

表 2 訓練與驗證資料數量

訓練資料	瘋狗浪資料	1004	502
	無瘋狗浪資料		502
驗證資料	瘋狗浪資料	430	215
	無瘋狗浪資料		215
總資料數			1434

## 參、研究方法

### (一)類神經網路

#### 1.類神經網路理論

類神經網路為模仿人類大腦組織及運作方式的資訊處理技術，由 Rumelhart et al. (1986)研究出倒傳遞類神經網路(back propagation neural network, BPNN)加上電腦技術日新月異，使得類神經網路開始突出於人工智慧領域。類神經網路透過讓電腦學習與人腦結構相同的神經傳遞訊息的過程，應用在如瘋狗浪機制目前尚未明確的自然現象上，從中找出自然現象的發生徵兆、機制等。

神經元(neuron)為類神經網路最基本的組成單位，如圖 3 所示，輸入值  $X$  與權重值  $W$  輸入至神經元後，神經元內部即開始進行運算，而運算結果  $Y$  即為神經元的輸出值，運算公式如下式所示

$$Y_j = f(\text{net}) = f(\sum_i W_{ij} X_i - \theta_j) \quad (2)$$

其中  $Y_j$  為類神經網路神經元的輸出值， $f(\text{net})$  為集成函數， $W_{ij}$  為類神經網路各神經元間的連結權重值， $X_i$  輸入變數， $\theta_j$  類神經網路處理單元的門檻值。

類神經網路架構如圖 4 所示包含了輸入層(input layer)、隱藏層(hidden layer)以及輸出層(output layer)，類神經網路的輸入資料由輸入層輸入，傳遞至隱藏層的神經元進行運算，根據要解決的問題之複雜度，神經元的數量可以是一個或是多個，最後經由轉換函數得出輸出值。

對於發生機制尚未明確的自然現象預測問題，通常會使用如雙曲線正切函數(hyperbolic tangent function)和 Sigmoid 函數(Sigmoid function)，使類神經網路具有非線性計算能力，建立複雜的函數關係，以描述整個物理現象。

倒傳遞類神經網路的訓練過程，分成正向傳遞和反向傳遞兩部分，正向傳遞指的是輸入值從輸入層神經元進入到隱藏層再傳遞至輸出層的過程，每個神經元負責將資訊傳至下游的神經元，以產生最終結果。反向傳遞則是當輸出值與學習目標值有落差時，計算出該筆資料的誤差，將此誤差傳遞回隱藏層中，依照誤差重新分配權重至隱藏層神經元。




圖 3 類神經網路之神經元概念圖




圖 4 類神經網路之架構概念圖

#### 2.預測模型之建置

本研究選用的類神經網路為 Rumelhart et al. (1986)提出的倒傳遞神經網路，為監督式學習，學習過程中有輸入值和學習目標，透過訓練而建立出輸入值與學習目標值之間的關係，利用權重(weight)與偏差值(bias)來表示其關係的強弱。訓練過程中透過不斷調整建置參數，以達到最佳訓練結果，訓練過程中的參數包含了隱藏層、神經元數目、隱藏層數目、學習速率以及隱藏層與輸出層轉移函數等。

預測模型訓練過程中，參考 Cybenko(1989)採用一層隱藏層，設定隱藏神經元數、學習速率、隱藏層與輸出層轉移函數皆以試誤法選取，其中學習速率測試如表 3 所示，範圍取 0.5 到 5 之間的初始學習速率進行測試，找出訓練結果最佳的學習速率。隱藏層與輸出層轉移函數測試則經由交叉測試雙彎曲函數(Logsig)和雙彎曲正切函數(Tansig)後，找出最佳的隱藏層與輸出層轉移函數。隱藏層神經元數可以平均法求得，因此範圍以 1 至 10 測試，找出最佳的隱藏層神經元數目。

### (二)支撐向量機

#### 1.支撐向量機理論

本研究運用機器學習方法中的支撐向量機來分析瘋狗浪案例，支撐向量機具有以嚴謹的數學演算和利用核函數(kernel function)處理高維度數據等特點，且支撐向量機為監督式機器學習方法，給定一組訓練資料，從已標籤化(labeled)的資料中分析，透過計算後即可得到預測模型。

如圖 5 所示，支撐向量機的基本概念即透過在資料中找出最合適的幾筆資料，並劃分出一線性可分函式(linearly separable function)使兩組資料間の間隔(margin)最大化，以最佳區分出兩組資料，而在支撐向量機領域劃分出來的線性可分函式稱為超平面(hyperplane)，而決定超平面的資料稱為支撐向量(support vector)，當輸入新的資料時，即能直接進行分類並透過轉換函數(transition function)預測每個新輸入的資料在各組的分類。

而對於無法線性可分的資料，如圖 6 和圖 7 所示，可將資料透過核函數投射到更高維度的向量空間中，再同樣透過找出間隔最大，也就是最佳的超平面來分類出兩組資料。而核函數有許多類型，根據不同

需求可選擇不同的核函數來映射資料至更高維度，在機器學習領域常見如線性核函數(linear kernel function)、多項式核函數(polynomial kernel function)、Sigmoid 核函數(sigmoid kernel function)、RBF 核函數(radial basis function)。




圖 5 支撐向量機基本概念，圖中標示出兩組資料間間距、支撐向量和超平面




圖 6 從非線性可分資料找出超平面示意圖




圖 7 利用核函數投射資料至高維空間找出超平面示意圖

## 2. 預測模型之建置

支撐向量機在建置預測模型的訓練過程中，使用核函數來對非線性可分資料投射至高維空間找出超平面，訓練過程所需要選定的參數包含了影響訓練過程中允許誤差程度的參數  $C$  和影響資料投射在高維空間的分布情形之參數  $\gamma$ ，以下分別論述兩者參數所代表的定義。

參數  $C$  的定義為允許在計算超平面時容許被分類錯誤的資料存在的程度，藉由參數  $C$  能給予被分類錯誤的資料懲罰程度，控制用來決定最佳超平面的支撐向量之影響力，當參數  $C$  越大，代表訓練過程中容許錯誤的程度就越小，反之參數  $C$  越小，代表容許錯誤的程度就越大；參數  $\gamma$  影響了資料在高維空間的分布情形，當參數  $\gamma$  越大，支撐向量的數目就越少，資料點的影響範圍較近，越接近超平面的資料點的權重就越大，容易勾勒出擬合較近資料點的超平

面，但也容易造成有過度擬合(overfitting)的問題，反之當參數  $\gamma$  越小，支撐向量的數目就越多，資料點的影響範圍就較遠，離超平面較遠的資料點對超平面能有所影響，容易勾勒出較直且平滑的超平面。

為了利用已建立好的訓練資料來建置最佳瘋狗浪預測模型，因此需要擬定出最佳的訓練參數  $\gamma$  和  $C$  輸入訓練過程，本研究為求出最佳訓練參數所採取的方法為網格搜尋法(grid search)，如圖 8 所示，利用在指定的範圍內測試所有不同的參數組合並比較，選出訓練結果最佳的訓練參數組合，而比較的依據是藉由  $k$ -fold 交叉驗證( $k$ -fold cross-validation)輸出訓練結果，如圖 9 所示， $k$ -fold 交叉驗證將訓練資料分成  $k$  等份， $k-1$  等份的資料建置預測模型，其餘的資料用來測試該模型的正確率，此過程將會重複進行直至每一等份的資料都曾作為測試資料後，最後將每一次的測試結果平均加總起來，即為  $k$ -fold 交叉驗證的輸出結果，亦為本研究預測模型的訓練結果。本研究參考 Chang(2015)的建議，將使用網格搜尋法時，兩個參數的範圍設定介於  $2^{-8}$  到  $2^8$  之間以及  $k$ -fold 交叉驗證的  $k$  值設定為 10，比較不同參數組合下的訓練結果並找出最佳的訓練參數來建置最佳預測模型。




圖 8 利用網格搜尋法找出最佳訓練參數。圖中橫坐標為訓練參數  $C$ ，縱坐標為訓練參數  $\gamma$ ，顏色的深淺代表正確率的高低




圖 9  $k$ -fold 交叉驗證示意圖(假設  $k=4$ )

## 四、研究結果

### (一) 模型建置結果

#### 1. 類神經網路預測模型

預測模型訓練過程中，參考 Cybenko(1989)採用一層隱藏層，設定隱藏神經元數、學習速率、隱藏層

與輸出層轉移函數皆以試誤法選取，其中學習速率測試如表 3 所示，範圍取 0.5 到 5 之間進行測試，發現當學習速率為 0.5 時有最好的訓練結果。隱藏層與輸出層轉移函數測試由表 4 所示，經由交叉測試後，證實當使用雙彎曲函數(Logsig)作為隱藏層轉移函數，以及使用雙彎曲正切函數(Tansig)作為輸出層轉移函數具有最好的訓練結果。隱藏層神經元數則以範圍以 1 至 10 測試，如圖 5 所示，當隱藏層神經元數為 4、5、6 時有較佳的訓練結果，正確率均達九成以上，其中隱藏層神經元數為 5 時有最好的訓練結果。

本研究透過試誤法找出訓練結果最佳的參數，選定學習速率為 0.5、隱藏層與輸出層轉移函數分別為 Logsig 和 Tansig 以及隱藏層神經元數為 5 來建置模型，並將驗證資料輸入模型輸出正確率(accuracy rate)、反查率(recall rate)、回應率(response rate)以及真陰性率(true negative rate)等評估指標。表 4 為類神經網路建置模型之驗證結果，其正確率表現良好，可達 72% 上下，在實際有瘋狗浪發生時模型的預測能力準確，反查率可達 99%，但在模型預測有瘋狗浪發生時的準確能力不高，回應率僅達 45%，最後在無瘋狗浪發生時的預測能力較不理想，真陰性率 64.5%。綜以上所述，類神經網路預測模型在實際瘋狗浪發生時預測的準確能力較佳。

表 3 類神經網路模型學習速率參數測試

學習速率	0.1	0.2	0.3	0.4	0.5
正確率	72%	90%	62%	84%	96%
學習速率	1	2	3	4	5
正確率	87%	92%	84%	70%	91%

表 4 類神經網路模型轉移函數參數測試

隱藏層	輸出層	正確率
Logsig	Logsig	42%
Tansig	Tansig	82%
Logsig	Tansig	96%
Tansig	Logsig	37%

表 5 類神經網路建置模型之驗證結果

驗證結果	正確率	72.3%
	反查率	99.0%
	回應率	45.4%
	真陰性率	64.5%




圖 10 類神經網路隱藏層神經元數測試

## 2. 支撐向量機預測模型

本研究分別利用上一小節所提到的四種常見的核函數：線性核函數、多項式核函數、Sigmoid核函數以及RBF核函數建置預測模型，輸入相同的訓練資料並且利用k-fold交叉驗證輸出的訓練結果以及輸入相同的驗證資料得出的驗證結果之正確率，來比較出效果最佳的核函數。

圖11顯示不同核函數建置模型的結果，發現以RBF核函數建置模型的訓練與驗證正確率最高，其中多項式核函數建置模型的表現雖僅略低於RBF核函數的結果，但其訓練結果之正確率比驗證結果高，當訓練結果比驗證結果好時可能有過度擬合的問題，而RBF核函數並無此趨勢且表現良好。因此，本研究選擇RBF核函數來建置瘋狗浪預測模型，再根據網格搜尋法擬定訓練參數，最終以訓練參數C為16和參數 $\gamma$ 為1.414來建置支撐向量機瘋狗浪預測模型。

本研究選定建置效果最佳的核函數並利用網格搜尋法和k-fold交叉驗證擬定最佳訓練參數(參數C和參數 $\gamma$ )建置支撐向量機瘋狗浪預測模型，將驗證資料輸入模型輸出正確率、反查率、回應率以及真陰性率等評估指標。表6為支撐向量機瘋狗浪預測模型的建置結果，其模型的驗證結果之正確率均表現良好，達 74% 上下；從反查率可知，預測模型在實際有瘋狗浪發生時的預測能力表現良好；從真陰性率可知，模型在實際沒有瘋狗浪發生時的預測能力也表現良好；從回應率可知，預測模型預測有瘋狗浪發生時且實際亦有瘋狗浪發生的比率高，代表沒有高估預測瘋狗浪的傾向。綜以上結果顯示支撐向量機瘋狗浪預測模型無論實際瘋狗浪會發生或未發生，模型均能預測表現良好。

表 6 支撐向量機建置模型之驗證結果

驗證結果	正確率	74.4%
	反查率	74.0%
	回應率	74.7%
	真陰性率	75.0%

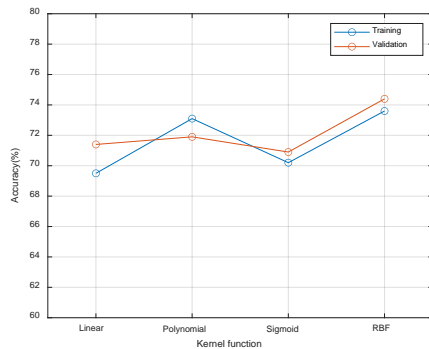


圖 11 不同核函數建置的訓練與驗證正確率

### 3.比較不同機器學習預測模型

本研究分別利用機器學習方法中的類神經網路以及支撐向量機建置瘋狗浪預測模型並進行比較，以正確率、反查率、回應率以及真陰性率等評估指標作為比較的依據。

表7即列出兩者不同方法各自的評估指標，由兩種方法的正確率發現無論類神經網路或是支撐向量機建置的瘋狗浪預測模型，兩者的正確率均表現良好。而單就類神經網路預測模型，其反查率高於真陰性率且回應率不高，反查率可反映出模型在實際有瘋狗浪發生時的預測能力，真陰性率則是反映出模型在實際沒有瘋狗浪發生時模型的預測能力，而回應率為模型預測有瘋狗浪發生的結果中，實際真的有發生瘋狗浪的比率，代表類神經網路方法在有瘋狗浪發生時預測的效果較好，而支撐向量機的反查率雖比類神經網路方法低，但其各項評估指標均保持良好，代表支撐向量機方法整體的預測能力較佳。

表 7 類神經網路與支撐向量機瘋狗浪預測模型比較

	類神經網路	支撐向量機
正確率	72.3%	74.4%
反查率	99.0%	74.0%
回應率	45.4%	75.0%
真陰性率	64.5%	74.7%

## 伍、結論

本研究以類神經網路和支撐向量機方法來建置瘋狗浪預測系統，擬定好各自最佳的參數來建置模型並比較這兩種不同的機器學習方法。無論類神經網路或是支撐向量機建置的瘋狗浪預測模型，兩者的正確率均表現良好，從兩者的反查率與回應率發現，類神經網路方法在有瘋狗浪發生時預測的效果較好，而支撐向量機方法的反查率雖比類神經網路方法低，但其各項評估指標均保持良好，代表支撐向量機方法整體的預測能力較佳，皆顯示兩種預警系統皆具有很高之參考性。

## 謝誌

本論文係中央氣象局研究計畫「沿岸異常波浪預警系統之建置(1/3)」之研究成果，承蒙中央氣象局經費之補助使本研究得以順利完成，謹致謝忱。

## 參考文獻

- [1] 中央氣象局, 2019: “異常海象機率預警研究與作業試用”, 研究計畫報告
- [2] 王敘民、陳盈智、董東璟、滕春慈. 2017: “海岸瘋狗浪光學影像分析之研究”, 第39屆海洋工程研討會, 第555-560頁
- [3] Cybenko, G., Approximation by Superpositions of a Sigmoidal Function. *Mathematical Control Signal Systems*, 2, 303-314, 1989
- [4] Cortes, C., & Vapnik, V., 1995: “Support-Vector Networks”, *Machine Learning* 20(3), 273-297
- [5] Chien, H., Kao, C.C., and Chuang, Z.H., 2002: “On the characteristics of observation coastal freak waves”, *Coastal Engineering Journal* Vol. 44 No. 4, 301-319
- [6] David E. Rumelhart, Geoffrey E. Hinton & Ronald J. Williams, 1986: “Learning representations by back-propagating errors”, *Nature* 323, 533-536
- [7] Dyachenko, A. I., & Zakharov, V. E., 2005: “Modulation instability of Stokes wave -> freak wave” *Jetp Letters* 81(6), 255-259
- [8] Doong, D. J., Chen, S. T., Chen, Y. C., & Tsai, C. H. (2020). Operational Probabilistic Forecasting of Coastal Freak Waves by Using an Artificial Neural Network. *Journal of Marine Science and Engineering*, 8(3).
- [9] Janssen, P. A. E. M., 2003: “Nonlinear four-wave interactions and freak waves”, *Journal of Physical Oceanography* 33(4), 863-884
- [10] Mori, N., & Janssen, P. A. E. M., 2006: “On kurtosis and occurrence probability of freak waves” *Journal of Physical Oceanography* 36(7), 1471-1483
- [11] Tsai, C.H., Su, M.Y., and Huang, S.J. (2004). Observations and Conditions for Occurrence of Dangerous Coastal Waves, *Ocean Engineering*, Vol. 31, 745-760.
- [12] White, B. S., & Fornberg, B., 1998: “On the chance of freak waves at sea” *Journal of Fluid Mechanics* 355, 113-138.
- [13] Zakharov, V. E., Dyachenko, A. I., & Prokofiev, A. O., 2006: “Freak waves as nonlinear stage of Stokes wave modulation instability” *European Journal of Mechanics B-Fluids* 25(5), 677-692