

應用類神經網路建置瘋狗浪機率預警系統

蘇瑋琳¹ 陳盈智² 滕春慈³ 朱啟豪⁴ 董東璟⁵

國立成功大學 中央氣象局 國立成功大學
水利及海洋工程系^{1,2} 海象測報中心^{3,4} 水利及海洋工程系⁵

摘要

海岸瘋狗浪無預警的發生，使海岸區域活動的安全蒙上陰影。海岸瘋狗浪的發生機制相當複雜，何時何地發生很難以定律的方式預測，本研究採用統計的方法，利用類神經網路具有高度學習及處理非線性問題的能力，建置海岸瘋狗浪機率預警系統，預測瘋狗浪發生機率，作為海岸瘋狗浪警報發佈之依據。預警系統建置的資料來源有二，浮標實測資料與波浪模式預測資料，並參考往昔之文獻選取瘋狗浪發生之可能影響因子，作為模式訓練之輸入因子。使用過去瘋狗浪發生案例進行系統的訓練與驗證。以實際落海事件進行驗證結果顯示，使用浮標觀測資料進行預警系統之訓練，整體來說具有最佳的驗證結果，正確率達8成以上，顯示使用類神經網路建置預警系統的可行性。

關鍵字：海岸瘋狗浪、人工類神經網路、機率預測

一、前言

近二十年來，臺灣周遭水域海岸瘋狗浪事件頻傳，導致人員落海災害時有耳聞，每年造成死傷人數達近百人，造成民眾生命威脅並花費大量救災資源。海岸瘋狗浪常發生於幾秒鐘之內，突如其來的大浪挾帶驚人的破壞力，時常造成海岸邊的漁民、釣客、戲水民眾及海巡人員莫大的危害。

根據董(2016)之統計資料指出，台灣周遭海域自2000年至2017年6月間，瘋狗浪事件共計308件，合計484人落海，平均每年發生約17件、約26人受傷，因此本研究建立預警系統，期望能適時提供警告資訊，降低傷害機率，以保障民眾生命安全。瘋狗浪事件發生原因很多，目前為止，科學界還不是很瞭解其發生機制，因此很難判斷預測發生地點與時機。故本研究採用資料探勘 (data mining) 技術建置瘋狗浪預警系統，資料探勘技術有許多種，其中，人工類神經網路 (artificial neural network, ANN) 具有高度學習演算及非線性最佳化之優點，比傳統之統計迴歸方法更好，此類統計方法已被廣泛應用於各領域當中。在海洋工程領域，常應用於處理複雜的自然現象，例如潮汐預測及補遺、颱風暴潮之預測、颱風波浪推算、海平面變遷、海岸灘線變遷以及系集預報等。

近年來人工類神經網路普遍應用於自然災害預警的相關研究，Böse et al. (2008)提出以類神經網路建置近即時且高可信度的地震預警系統，當地震發

生於海底，因震波的動力會引起海水劇烈起伏形成海嘯，Romano et al. (2009)、Mase et al. (2011)利用倒傳遞類神經網路建置即時海嘯預警系統；因應氣象引致區域型的災害，Chang et al. (2007)、Kung et al. (2012)利用類神經網路建立土石流預警系統，以輸出值判斷土石流是否會發生；Thirumalaiah et al. (1998)、Sunkpho et al. (2011)、López et al. (2012)利用類神經網路預測水位高度進而建置城市淹水預警系統。此外，張憲國等人(2006)利用類神經網路建立花蓮港船隻異動指數的預警模式，以提供花蓮港內船隻在颱風來襲之時判定有無出港避湧之需要。

本研究將應用人工類神經網路於龍洞海域建置瘋狗浪預警模式，預期提供準確的瘋狗浪預警資訊，作為發佈警報、防災措施決策之參考，並將此預警作業落實於中央氣象局作業化流程中。

二、研究方法

類神經網路為仿照人類大腦組織及運作方式的資訊處理技術，其優點在於不需瞭解系統的數學模型為何，直接以神經網路取代系統的模式，就能獲得輸入與輸出之間的關係。為使類神經網路正確的運作，必須透過訓練 (training) 的方式，讓類神經網路反覆的學習，直到每個輸入都能對應到正確的輸出，因此必須建立訓練資料做為學習過程中的參考。神經元是類神經網路最基本的組成單位如圖1所示，輸

入值 X 與權重值 W 輸入至神經元後，神經元內部即開始計算，計算公式如式1 所示，計算結果 Y 為神經元之輸出值。

$$Y_j = f(\text{net}) = f(\sum_i W_{ij}X_i - \theta_j) \quad (1)$$

類神經網路架構由輸入層(input layer)、隱藏層(hidden layer)以及輸出層(output layer)所組成，首先資料由輸入層輸入，再傳遞至隱藏層的神經元進行運算，最後經由轉化函數獲得輸出值。轉化函數有三種函數，其一為S 型曲線函數(sigmoid function)，輸出值會介於0 至1 之間，其公式如2 式所示；雙曲線正切函數(hyperbolic tangent function)，輸出值會介於-1至1之間，其公式如3式所示；以及線性函數(pure linear)。對於發生機制尚未釐清的自然現象或是複雜的問題，通常會使用S型曲線函數或雙曲線正切函數，使類神經網路具有非線性計算能力，建立複雜的函數關係。

$$f(\text{net}) = \frac{1}{1+\exp^{-\text{net}}} \quad (2)$$

$$f(\text{net}) = \frac{1-\exp^{-\text{net}}}{1+\exp^{-\text{net}}} \quad (3)$$

本研究選用之類神經網路為Rumelhart et al. (1986) 提出的倒傳遞類神經網路，具有監督式學習的特性，即學習網路中有輸入值及學習目標值。當開始學習時，網路將建立輸出值與學習目標值間之關聯性，可視為一種輸入與輸出之間的映射過程，利用網路權重(weights)與門限值(bias)來表示其關係的強弱。本研究使用Matlab 程式來建置倒傳遞類神經網路，模式建置工作包含了學習演算法、隱藏層神經元數、隱藏層數、學習速率以及隱藏層與輸出層轉化函數等6 項。學習演算法使用Levenberg Marquardt 方法，隱藏層神經元數係以平均法求得(葉怡成, 2001)。隱藏層數、學習速率、隱藏層與輸出層轉化函數皆以試誤法求得最佳值。

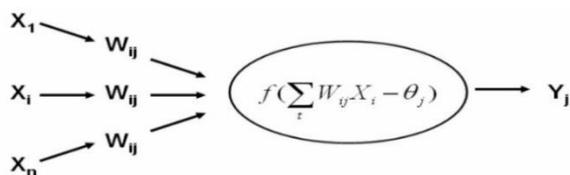


圖 1 類神經網路之基本架構

三、研究區域與使用資料

根據統計資料顯示，從2000 年至2017年6月之間所有發生案例中，台灣海岸地區因浪襲擊而落海的事件共308件，約7成左右發生在台灣東北角海岸地區(基隆市到宜蘭縣間)，其中76 件發生於龍洞附

近海域，為瘋狗浪最常發生的海域，故本研究以龍洞海域作為研究區域。

預警系統之建置使用浮標實測資料及模式預測資料，作為系統之輸入。本研究使用之浮標實測資料選用中央氣象局於龍洞海域布放的資料浮標，浮標離岸1公里，該處水深23米，逐時觀測海氣象之物理量。而波浪模式資料是使用Mike 21波浪模式裡SW模組(spectral wave)，重新計算過去16年龍洞海域之波浪場。Mike 21波浪裡的SW模組計算原理是使用Wave action density spectrum(Komen et al., 1994)來描述波浪場的生成與變化，計算結果即為方向波譜，從波譜中可以求得相關波浪參數，例如示性波高、尖峰週期、波向以及波普參數等。

四、預警系統建置

本研究使用之倒傳遞類神經網路採用監督式學習法，學習過程中所需的學習目標值採用實際落海事件之資料，而龍洞附近海域落海事件發生時，浮標實測資料無缺值者有63筆，使用全部資料的2/3數量合計40 筆作為模式學習案例，其餘23筆案例則作為模式之驗證。由於從過去至今累積之非發生瘋狗浪的海象資料過多，合計超過13萬筆，為避免模式在訓練過程中產生偏頗現象，本研究從所有非發生瘋狗浪事件的資料中，依相同比例隨機挑選非發生瘋狗浪之訓練及驗證資料。挑選原則包含波浪起伏小、風速不大以及週期很小，並計算全部資料的四分之一位數作為篩選門檻，小於門檻值才得以視為非發生瘋狗浪的資料。

考慮海象特徵的記憶性，模式建置使用事件發生前六小時之物理變化量作為輸入，再依不同預警時間(12小時及24小時)之模式分別選取各預報點前6小時內之資料作為建模資料。根據前人的研究與研究團隊前期的成果，近岸瘋狗浪之發生機制與海況、氣象、湧浪、方向、非線性、波浪群性及非線性因子有關，因此本研究將輸入因子區分為7大類並各別挑選合適的參數建模，說明如下：

(1) 海象類別參數

海象可以海面粗糙度、波高等物理參數來描述，考量資料蒐集的便利性，通常使用平均波高及最大波高描述波浪起伏的程度，故本研究使用前6 小時內最大波高作為輸入參數，以提供模式在預警期間的波浪變化資訊。

(2) 湧浪類別參數

Tamura et al. (2009)認為瘋狗浪的成因與湧浪有很大的關係，湧浪可透過波齡、平均週期、尖峰週期、

湧浪波高、湧浪週期等參數來判斷，然而考量預警模式輸入時之便利性，本研究使用前6小時內最大週期作為輸入參數，以提供模式在預警期間的湧浪資訊。

(3) 方向類別參數

當波浪向岸傳遞，風亦向岸吹送時，預期波浪於海岸邊的疊加效果將非常顯著，故本研究以波向風向差及波向做為輸入資料之方向資訊。

(4) 風類別參數

風垂直海岸向吹送，若風速愈強，預期所造成波浪於海岸邊的疊加效果將較為顯著，因此以前6小時內最大向岸風速作為輸入資料以提供因強勁向岸風造成波浪疊加的資訊。

(5) 非線性類別參數

Janssen (2003)認為瘋狗浪的發生是基於非線性波的交互作用，因此本研究使用峰度值(kurtosis)、譜寬參數與班傑明非線性指數(Benjamin Feir Index, BFI)以提供模式波浪非線性程度的資訊。一般而言，水位分布成均勻的高斯分布，而在非線性效應影響下水位分布會較為集中且會出現整體分布偏移的情形，峰度值可描述整體水位分布變化現象；BFI指數則是用以量化波浪不穩定現象的程度，可由波浪尖銳度以及譜寬參數計算得到。

(6) 波浪群性類別參數

Tsai et al. (2001; 2004), Chien et al. (2002) and Chen (2002)皆指出瘋狗浪的發生與波浪的群性有強的相關性存在，也認為波浪成群的效應是瘋狗浪發生的機制之一。本研究採用以前6小時群波因子(Groupiness Factor)作為模式輸入因子，以提供模式波浪成群與否的資訊。然而波浪模式中並無水位資料可分析群性，因此參考Goda(2000)提出之譜間參數(Qp)來替代，當譜間參數較大時表示能量越聚集，在群性明顯的波群中，其能量通常較為密集。

(7) 異常指數類別參數

本研究認為瘋狗浪可視為海岸邊的異常波浪，國際間對大洋中的異常波浪採用Kharif et al. (2009)定義之異常指數(Abnormal Index, AI)，作為判斷異常波浪之依據，即當異常指數大於2時，該波浪為異常波浪。本研究以前6小時最大異常指數能提供模式近岸波浪的異常程度，以預測瘋狗浪的發生。相同地因波浪模式沒有水位時序列資料，因此在波譜模式的輸入資料中省略異常指數類別參數的輸入。

綜合上述，本研究建置預警系統使用浮標實測資料及模式預測資料做為訓練及驗證，兩種資料均包括了各類別參數，其中浮標實測資料包含波高、週期、向岸風速、波向風向差、群波因子、峰度值、BFI值、AI值共8種因子；而波浪預測資料包含波高、週期、波向、譜間參數、峰度值、BFI值共6種因子。為建立準確性較佳之預警模式，本研究使用3種不同的資料組合，進行模式之訓練與驗證如表1所示，並提出以倒傳遞類神經網路建置預警模式，其類神經網路之架構如圖2所示(以資料集一為例)。

表 1 預警模式之訓練及驗證資料

資料集	使用資料
資料集一	實測資料
資料集二	模式資料
資料集三	實測資料、模式資料

建置模式之輸入因子在輸入倒傳遞類神經網路運算之前，必須將所有輸入因子數值轉換在0至1之間 (Chi, 2011)，以消弭因子本身的物理特性以及數值大小造成的誤差，並將資料正規化以提高模式準確性。另外，本預警模式之參數設定為一層隱藏層，包含3種不同網路神經元之S型曲線轉換函數的網路架構，學習演算法使用Levenberg Marquardt 演算法，學習速率為0.1，輸出層之轉換函數亦使用S型曲線轉換函數。

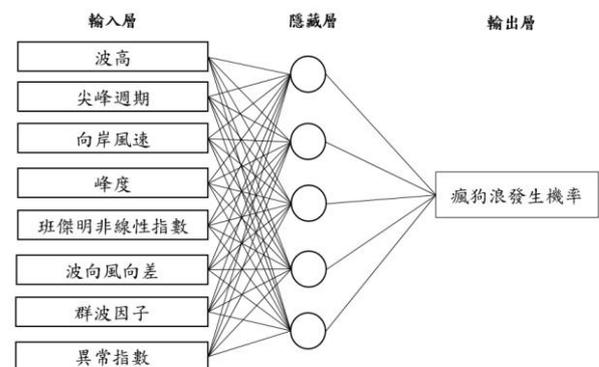


圖 2 預警模式之類神經網路架構(以資料集一為例)

五、分析結果

本研究完成瘋狗浪預警模式之建立，並使用正確率(accurate rate, ACR)、回應率(response rate, RSR)、反查率(recall rate, RCR)三指標評估模式之準確性，正確率係指模式預測的結果中，有多少比率是符合實際瘋狗浪引致落海事件與實際未發生瘋狗浪事件；回應率係指在預測為有落海事件發生集合中，多少比率是屬於真正的落海事件發生；反查率係指在所

有落海事件中，模式預測出多少比率為有發生，此三指標值越高表示模式之準確性越高。其定義如 (4)、(5)、(6)式所示。

$$ACR = (A+D)/(A+B+C+D) \quad (4)$$

$$RSR = D/(C+D) \quad (5)$$

$$RCR = D/(B+D) \quad (6)$$

根據預警模式建置時所設定之學習目標值，本研究定義預測機率值大於0.7 則歸類為高瘋狗浪發生機率；而預測機率值小於0.3 則歸類為低瘋狗浪發生機率。上式中，A 為模式預測低瘋狗浪發生機率，實際亦無瘋狗浪引致落海事件發生的事件個數；B 為模式預測低瘋狗浪發生機率，實際卻有瘋狗浪引致落海事件發生的事件個數；C 為模式預測高瘋狗浪發生機率，實際卻無瘋狗浪引致落海事件發生的事件個數；D 為模式預測高瘋狗浪發生機率，實際亦有瘋狗浪引致落海事件發生的事件個數。

資料集一預警時間12小時之模式訓練結果如圖3所示，圖中前40筆資料為有發生瘋狗浪之樣本，後40筆為無發生瘋狗浪之樣本，訓練十次後，模式已趨於穩定。接著使用另外23筆瘋狗浪資料與隨機挑選23無發生瘋狗浪資料進行驗證，如圖4所示。使用前述的三指標評估模式之準確性，結果如表2，模式之驗證結果正確率、反查率與回應率分別為83%、78%與91%，顯示大部分的海岸瘋狗浪事件皆可以被模式預測得到。因此本研究相同的方法使用不同資料分別建置預警時間9、12、18、24小時預警模式，驗證結果如表3。

以實際落海事件進行驗證結果顯示，預警時間9小時、12小時與24小時以實測浮標資料建置瘋狗浪預警系統具有最佳的預測正確率，正確率達93%、83%與82%，回應率與反查率分別有約8成以上；而預警時間18小時以實測浮標資料與波浪模式資料建置瘋狗浪預警系統具有最佳的預測正確率，正確率達83%，然而僅以浮標實測資料進行建置正確率相近達82%，回應率與反查率分別有約有8成左右。整體結果顯示，僅使用浮標實測資料(type I)建置具有最好之驗證結果，且回應率與反查率約有8成，顯示此預警模式在計算為高機率時，通常都有瘋狗浪案例；而瘋狗浪發生時，大多系統也能預測出高機率，顯示使用浮標觀測資料作為人工類神經網路之輸入資料，可以建置瘋狗浪預警系統，具有相當之預警能力。

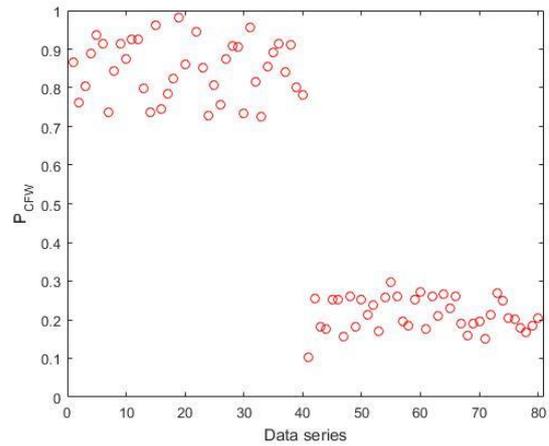


圖 3 以資料集一建立12小時預警模式之訓練結果

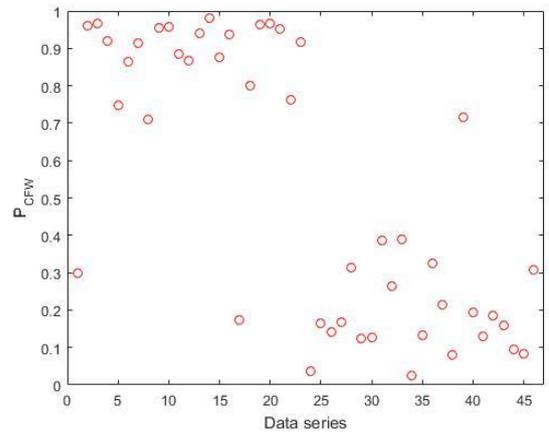


圖 4 以資料集一建立12小時預警模式之驗證結果

表 2 預警時間12小時式訓練與驗證結果 (訓練資料: 資料集一)

	訓練 (10 次)		驗證	
	成功預測	預測失敗	成功預測	預測失敗
瘋狗浪案例	39	1	21	2
非瘋狗浪案例	39	1	17	6
正確率 (ACR)	98 %		83 %	
反查率 (RCR)	98 %		78 %	
回應率 (RSR)	98 %		91 %	

表 3 以三種資料集分別建置預警模式之驗證結果

預警時間	資料	正確率 (ACR)	回應率 (RSR)	反查率 (RCR)
9 小時	Type I	93%	87%	85%
	Type II	70%	74%	61%
	Type III	78%	76%	83%
12 小時	Type I	87%	83%	91%
	Type II	74%	72%	78%
	Type III	80%	85%	74%
18 小時	Type I	82%	78%	86%
	Type II	78%	73%	91%
	Type III	83%	78%	91%
24 小時	Type I	82%	78%	84%
	Type II	78%	73%	91%
	Type III	78%	72%	91%

六、結論

海岸瘋狗浪的發生機制相當複雜，且發生地點與時機皆難以預測，故本研究採用具高度學習及處理非線性問題能力佳的類神經網路，完成建置海岸瘋狗浪機率預警系統，以提供準確的瘋狗浪資訊，得以提升海岸活動人們安全保障。本研究以實際發生案例資料做為模式訓練及驗證，並從各類別參數中挑選合適的輸入因子，為提高模式之準確性，使用不同資料組合及預警時間進行模式建置。由訓練結果顯示，各模式準確性皆達9成以上，顯示模式均有良好的訓練。模式訓練完成後也進行了驗證，由驗證結果顯示，模式準確性皆達8成以上，證明了模式之預測能力，同時也顯示出本研究在建模時所選用之輸入因子、轉化函數以及神經元個數，皆能提供模式很好的判斷依據。最後，本研究經由評估過後，選擇以資料集一所建立預警模式，其為所有模式中訓練及驗證結果較佳者，將做為未來研究之使用。

誌謝

本論文係交通部中央氣象局委託研究計畫「異常海象機率預警研究與作業試用」(編號MOTC-CWB-106-O-02)之研究成果，承蒙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] Böse, M., Wenzel, F., Erdik, M. (2008). PreSEIS: A Neural Network-Based Approach to Earthquake Early Warning for Finite Faults. *Bulletin of the Seismological*

Society of America, 98 (1), 366 – 382.

[2] Chang, F.J., Tseng, K. Y., Chaves, P. (2007). Shared near neighbours neural network model: a debris flow warning system. *Hydrological Processes*, 21, 1968 – 1976.

[3] Chen, W.B., Liu, W.C., Hsu, M.H. (2012). Predicting typhoon-induced storm surge tide with a two-dimensional hydrodynamic model and artificial neural network model. *Natural Hazards and Earth System Sciences*, 12, 3799 – 3809.

[4] Chi Q., Shu, J., Zhang, X. Zhou, Q. (2011). The Application of Improved BP Neural Network for Power Load Forecasting in the Island Microgrid System. *IEEE Electrical and Control Engineering*, 6138 – 6141.

[5] Kung, H.Y., Chen, C.H., Ku, H.H. (2012). Designing intelligent disaster prediction models and systems for debris-flow disasters in Taiwan. *Experts Systems with Application*, 39, 5838 – 5856.

[6] Janssen, P. A. (2003). Nonlinear four-wave interactions and freak waves. *Journal of Physical Oceanography*, 33(4), 863-884.

[7] López, V.F., Medina, S.L., Paz, J.F.d. (2012). Taranis: Neural networks and intelligent agents in the early warning against floods. *Experts Systems with Application*, 39, 10031 – 10037.

[8] Mase, H., Yasuda, T., Mori, N. (2011). Real-Time Prediction of Tsunami Magnitudes in Osaka Bay, Japan, Using an Artificial Neural Network, *Journal of Water, Port*, 137 (5), 263 – 268.

[9] Rumelhart, D.E., Hinton, G.E., Williams, R.J. (1986). Learning internal representations by back-propagating errors. *Nature*, 323, 533 – 536.

[10] Romano, M., Liong, S.Y., Vu, M.T., Zemskyy, P., Doan, C.D., Dao, M. H., Tkalich, P. (2009). Artificial neural network for tsunami forecasting. *Journal of Asian Earth Sciences*, 36, 29 – 37.

[11] Sunkpho, J., O otamakorn, C. (2011). Real-time flood monitoring and warning system. *Journal of Science and Technology*, 33(2), 227 – 235.

[12] Tamura, H. Waseda, T. Miyazawa, Y. (2009) Freakish sea state and well-windsea coupling: Numerical study of the Suwa-Marun incident. *Geographical Research Letter*, Vol.36, L01607.

[13] Thirumalaiah, K., Deo, M. C. (1998). Real-Time Flood Forecasting Using Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 13, 101 – 111.

[14] 張憲國、林立青、何良勝、李明璋(2006)「花蓮港船隻預警神經網路模式之研究」，第 28 屆海洋工程研討會論文集，第 923-928 頁。

[15] 葉怡成(2001)應用類神經網路，儒林圖書公司。