

結合EMD法之類神經網路長期風浪推算模式

林立青¹
環境變遷研究中心
中央研究院

張憲國²
土木工程學系
國立交通大學

摘要

本研究應用經驗模態分解法(Empirical Mode Decomposition method, EMD)，將風速分解成多個模態函數(Intrinsic Mode Functions, IMF)，以此作為類神經網路的輸入值，藉由各個風速IMF的變化來推算測站波高。本研究應用中央氣象局集狀網格數值天氣預測系統(NFS)之MC風場，並以實測波浪資料作為推估模式之輸出值。本模式並與張等(2006)所建構之WANF波浪模式進行比較。由比較結果，本模式與實測之誤差及相關性優於張和林(2006)所提之WANF模式。

關鍵字：類神經網路、經驗模態分解法(EMD)、波高

一、前言

台灣位於亞洲的季風區，季風的變化則會在波浪的成長及傳遞等有不同程度的影響，除了季風外，颱風所造成的湧浪亦對近岸造成結構物及人員甚大的危害。台灣東北季風發生時間長達半年以上；而西南季風盛行於六月到九月，歷時約三個月。而東北季風的強度不亞於颱風災害性天候氣象。颱風及東北季風所帶來的強風巨浪對海上作業、港灣工程作業及施工的影響甚鉅。因此，如何建立風與波浪的特性來進行波浪預測為本研究重要之課題。

目前相關之波浪模式有波譜法(wave spectrum method)及示性波法(significant wave method)二種，前者是應用波浪能量平衡方程式為其控制方程式，並配合波浪傳遞後各種物理特性來加以推算。現今的波浪預報方式系統有NOAA WAVE WATCH-III、WAM及SWAN等三種模式系統，上述預報模式需較長時間資料運算及模式參數適應性不易調整等缺點。至於後者，示性波法(significant wave method)則是將波浪大小與風速、吹風歷時與吹送距離等參數關係加以定量分析。在示性波法中，最早採用系統化來進行波浪推算則為SMB法(Sverdrup and Munk, 1947; Bretschneider, 1976)，並根據不同水域(開放水域JONSWAP)或主風向及主波向不一致(Donelan-JONSWAP)則有不同的推算方法。因此傳統的SMB及Donelan-JONSWAP較適用於季風波浪推算。

另外，往昔學者利用類神經網路進行預測波浪，有Deo和Naidu (1999)以即時實測波浪資料作為類神經網路之輸入值，而以倒傳遞類神經網路架構來推算波浪，並以此建立短期波浪推算模式。Deo等人(2001,2003)則建構以風速及示性波高與週期之類神經網路，來預測風浪。Bhattacharya等人(2003)利用實測波浪資料、風向、延時作為類神經之輸入值，來追算遺失之波浪資料。Makarynsky (2004)為修正短期

波浪之預測，分析不同延時之測試對預測風浪正確性之關係，並建立輸入值為48小時與輸出值為24小時之波高及週期之類神經學習網路，以此進行較長時間且可獲得較正確之波浪預測。Kalra等人(2005)則以衛星量測之外海波浪特性及風場資料，進行類神經網路近岸風浪之推算。Chang和Chien (2006a、2006b)針對不同風場參數分析其對波浪特性之關係，建立多個轉換函數之類神經網路模式，以進行颱風波浪之推算。張和林(2006)應用適應性類神經模糊網路將模式之風速及風向與實測波浪進行網路的建構以推算長期波浪，其推算誤差優於NOAA Wave Watch III模式，但是相關性則略低於NWW III模式。Özger and Sen(2007)應用模糊系統，以實測風速及前一個延時的波高及週期推算下一個延時的示性波高與週期值。Browne等人(2007)應用9個NOAA Wave Watch III模式之輸出參數，以類神經網路進行實測波高學之習與預測，其平均誤差結果較SWAN模式小。Kalra 和Deo (2007)以TOPEX衛星量測之波高及風速，應用徑向基底類神經網路(RBF)進行近岸測站之波高及週期的推算。

由於類神經或模糊網路在波浪推算上使用廣泛，在計算量及推算誤差與經驗公式及數值模式比較下，類神經或模糊的網路的推算結果則略優於上述兩者。因此，本研究利用經驗模態分解法(EMD)及類神經網路，簡稱EMD_NN，以架構具不同模態之風浪推算模式，該架構具有非線性最佳化及學習快速演算等優點，進而達到即時且快速預測波浪之能力。以提供港灣工程施工及船隻作業之參考，並期望此模式未來可在工程設計與防災上提供即時及較精確的波浪推算與預報。

二、經驗模態分解法(EMD)

經驗模態分解法(Empirical Mode Decomposition method, EMD)是Huang (1998,1999)所提Hilbert

Huang Transform (HHT) 過程中的一個部份，在進行HHT的過程先以EMD法對非線性(nonlinear)及非常態(non-stationary)的數據進行處理，而求得各模態函數(Intrinsic Mode Functions, IMF)，各分量代表各個不同能量及頻率，各分量的總和則等於原始數據。各IMF個模態訊號須滿足兩個條件：1).IMF訊號的極值數目與跨越零點(zero-crossing)的數目相等或最多相差一個。2).訊號中極大與極小值得包絡線的平均包絡線須為零。這樣的分解過程可將載波消除及使波形具有對稱性。以下詳述EMD分解的步驟：

首先，求得訊號 $X(t)$ 中各局部極大及極小值，以內插法(Cubic spline)求出上、下包絡線(envelope)，而上下包絡線的平均值為平均包絡線 m_1 ，兩者個差值為第一個分量 h_1 可表示為式(1)

$$X(t) - m_1 = h_1 \quad (1)$$

而此時第一個的成分含有許的不同能量的擾動及數據未全都跨越零點，且平均包絡線之值亦非為零的，因此從 h_1 再重複進行上述的平均包絡線的計算示如下式

$$h_1 - m_{11} = h_{11} \quad (2)$$

並重複計算直到第 k 次式(3)滿足IMF的條件式(4)

$$h_{1(k-1)} - m_{1k} = h_{1k} \quad (3)$$

$$SD = \sum_0^T \frac{|h_{1(k-1)} - h_{1k}|^2}{h_{1(k-1)}^2} \quad (4)$$

根據Huang (1998)建議 SD 值的範圍約在0.2-0.3間，當 SD 滿足0.2-0.3時，IMF的第一個分量 C_1 即等於 h_{1k} 。因此，訊號可被分解成數個IMF模態，其表示式為式(5)

$$X(t) = \sum_{i=1}^n C_i + r_n \quad (5)$$

其中 r_n 為各個IMF之殘差值，其值成單調趨勢或接近零。

另外，本文採用之風場資料為中央氣象局巢狀網格數值天氣預測系統(NFS)，所提供之區域性大氣模式輸出的海面風場，依解析度大小分別為RC(45km×45km)、MC(15km×15km)及HC(5km×5km)，本文應用解析度為RC之風場資料，且輸出時間間隔為6小時。本研究將花蓮測站之RC模式風速(U與V分量)進行EMD分解，共可分解出11個IMF，第10個為殘差值，如圖1及2。

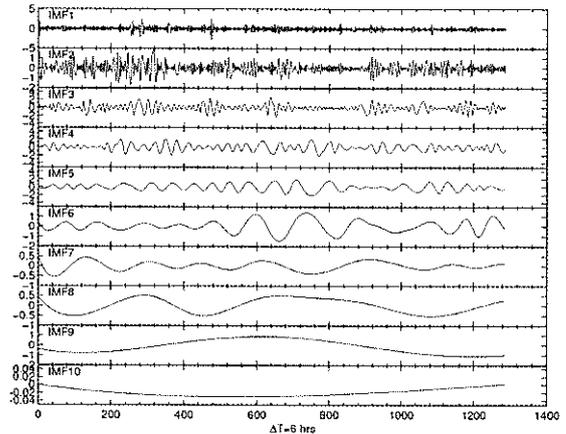


圖 1 花蓮測站模式風速U分量之EMD分解

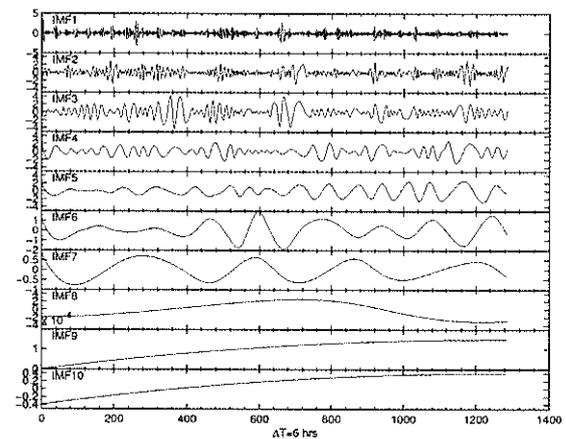


圖 2 花蓮測站模式風速V分量之EMD分解

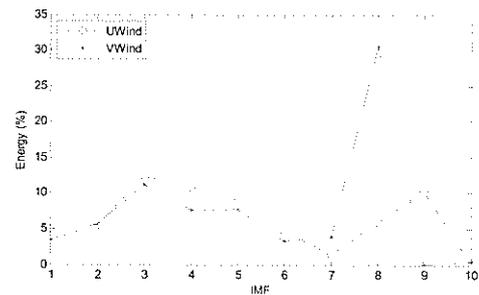


圖 3 U及V分量之各IMF能量百分比

圖3則為RC模式之風速U及V分量之各IMF能量分布，U分量最大能量在IMF3，V分量最大能量在IMF8。由於由模式風速分解出的各個IMF所包含的能量及頻率代表該IMF的重要程度。風速的變化影響波高的大小，吹風延時亦會影響波浪的成長，因此波高

受到風速大小及吹風延時的影響，本文將風速分解成各個吹風頻率及能量之IMF，以此建構不同吹風能量及頻率特性的波浪推散類神經網路。

三、類神經模糊網路模式

本文所使用的類神經網路為傳遞網路(Back propagation)，傳遞學習演算法是被廣泛使用的一種學習演算法，因其具有學習及回想的機能，故可在回想過程中以相同於學習過程的方式來進行預測。一般倒傳遞網路可分為三部份，輸入層用以接受外在環境的訊息，輸出層用以輸出訊息給外在環境，隱藏層則表現輸入與輸出層各處理單元間的相互關係，並以權重和閾值來闡述該相關性。倒傳遞網路學習方式是由輸入相當數量之學習樣本，應用向前餽入與誤差向後推導兩步驟，推求輸入變數與輸出變數的內在對映規則，再應用回想功能，進行新案例之輸出變數值推估。

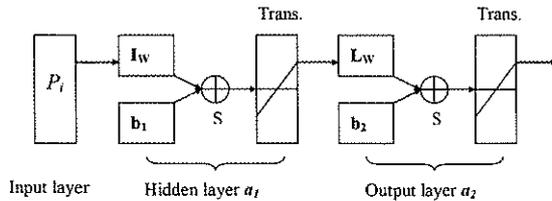


圖 4 類神經網路架構示意圖

圖 4 所架構之網路為一層隱藏層及一層輸出層，Trans. 為轉換函數，S 為神經元個數，P 為輸入變數矩陣， I_w 和 b_1 為輸入層與隱藏層間的權重和閾值矩陣， L_w 和 b_2 為輸出層與隱藏層間的權重和閾值矩陣。經由網路學習誤差最佳化的過程，神經網路將輸入值及學習目標值的關係紀錄在閾值與權重上，以此表示輸入值與學習目標值間的關係強弱。其中，神經網路使用轉換函數使隱藏層模仿生物神經元處理非線性的機能，以輸入值之加權乘積和轉換成處理單元之輸出值。整個倒傳遞網路模式由隱藏層與輸入參數及輸出層的關係可用方程式表示為

$$a_1 = f(I_w P + b_1) \quad (6)$$

$$a_2 = f(L_w a_1 + b_2) \quad (7)$$

其中 a_1 為隱藏層之輸出值矩陣， a_2 為倒傳遞網路輸出值矩陣， f 為轉換函數。藉由上式之運算後求出網路輸出值，其與學習目標值 Y 間之誤差平方定義為誤差函數 E ，示如下式

$$E = \frac{\|a_2 - Y\|^2}{N} \quad (8)$$

因此，整個網路學習的過程為了最佳化各神經元間之權重與閾值使誤差函數達到最小值，即使網路輸出值趨近學習目標值。當網路完成學習過程，建立最合適的權重和閾值後即可以此網路的回想過程來進行預測分析。

本研究選定花蓮(Hua-Lien)波浪觀測站，該測站分別隸屬花蓮沿海沿海之預報區域。測量波浪的儀器為中央氣象局長期發展之資料浮標(data buoy)，波浪資料的時間間隔為一小時。本文所收集的2002-2003波高，其資料浮標位置分別為花蓮—花蓮縣新城鄉花蓮七星潭外海0.5公里，水深約30公尺。

依據SPM法之風浪成長經驗公式，描述深水波示性波高與延時關係，若風吹延時固定，在不同風速對應波高有所不同，風速越大波高越高，但在相同之風速，若風吹延時越久則波浪越發展成熟。張和林(2006)分析RC模式風速及實測波高延時之相關性，得知在延時為2個資料點(每六小時為一個資料點)時，其具有最高約0.6的相關係數。因此，本研究以RC模式風速之各IMF分量及其延時作為輸入值，以類神經網路建構風波特性的長期推算模式(EMD_NN)。

四、EMD_NN模式分析結果

本研究以 MATLAB 軟體之 NeuroNetwork Toolbox 所提供之倒傳遞網路模式，進行風浪模式 EMD_NN 之建構。並以花蓮之 RC 模式風場的風速(U 及 V 分量)、延時做為模式之輸入值，輸出資料則為對應之測站波高，學習時間為 2002 年，預測時間則為 2003 年，資料間隔為 6 小時。

本模式之學習及推算結果與花蓮實測數據進行比較，如圖 5 及圖 6。由圖 5 可知在學習階段，模式模擬的數據與實測數據相近，於預測階段則在 7-9 月的波浪推算與實測值有較大的誤差，該時間為颱風發生頻繁的季節，2003 年之颱風發生於花蓮海域共有六個依次為柯吉拉、蘇迪勒、尹布都、莫拉克、杜鵑及米勒等。

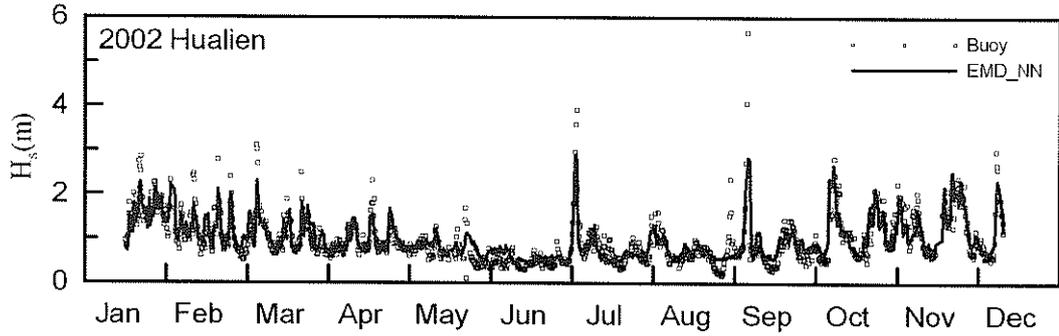


圖5 花蓮2002 EMD_NN模式推算值與實測值之比較

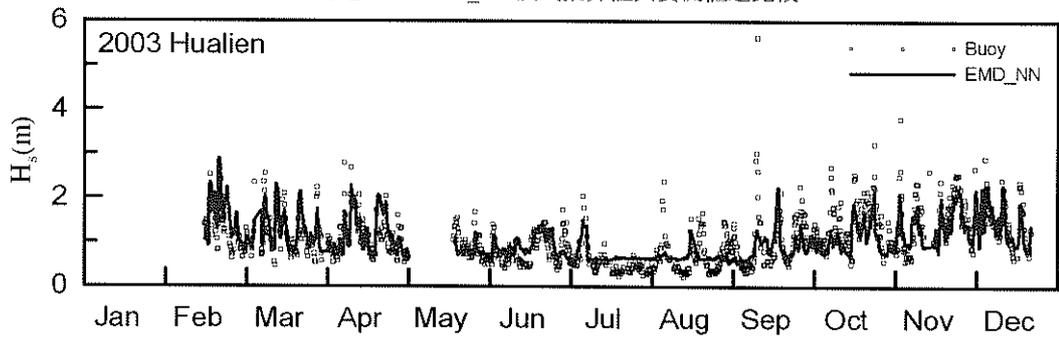


圖6 花蓮2003 EMD_NN模式推算值與實測值之比較

本研究亦分析2002-2003年不同季節之推算結果，示如表1及2。為了能客觀表示模式推算結果之優劣程度，本研究利用了三個統計參數作為模擬結果之評斷。

(1) 相關係數 r (correlation coefficient)：示如式(1)，可表現出預測值與實測值之間之趨勢，其之間之相關程度介於-1與1之間，假若預測值與實測值之間之相關性較高，則 r 會趨近為1。其定義為

$$r = \frac{\sum_{i=1}^N [(P_i - \bar{P})(O_i - \bar{O})]}{\left[\sum_{i=1}^N (P_i - \bar{P})^2 \sum_{i=1}^N (O_i - \bar{O})^2 \right]^{1/2}} \quad (9)$$

其中， P_i 與 O_i 分別表示為預測值與實測值，則 \bar{P} 與 \bar{O} 分別表示在預測時間內之預測平均值與實測資料平均值， N 為資料總數。

(2) 平均絕對誤差 ε (mean absolute error)：示如式(2)， ε 值可表現出預測值與實測值之間之平均預測誤差， ε 越大則表示偏差量越多而誤差大。

$$\varepsilon = \frac{\sum_{i=1}^N |P_i - O_i|}{N} \quad (10)$$

(3) 平均偏態誤差 β ：示如式(3)， β 可表現出預測值與實測值偏差量之大小，若實測值與預測值均相同，則 β 值為0，如果 β 值大於0則表示預測值高估於實際值。反之則 β 值小於0則表示實際值高估於預測值。

$$\beta = \frac{\sum_{i=1}^N (P_i - O_i)}{N} \quad (11)$$

本研究之推算結果將與張和林(2006)所提之WANF模式結果比較，示如表1。WANF模式使用自適應模糊類神經網路，其網路輸入值為RC模式之風速及風向及延時，EMD_NN則是以RC模式風速之 U 及 V 分量之EMD分解的IMF分量(各10個分量)及其延時，作為類神經網路的輸入值。

由表1可知，2002年之學習結果，本模式與實測波高相關性及誤差皆優於WANF模式，並於2003年之推算結果可看出春夏兩季的相關性本模式略優於WANF之結果，其中夏季本模式的相關性約為0.57遠高於WANF模式。秋冬兩季本模式則略劣於WANF模式。

於2002年學習階段本模式之平均絕對誤差約為0.15-0.21m，WANF則為0.21-0.34m。於2003年之推算階段本模式之平均絕對誤差約為0.21-0.33m，WANF模式則為0.24-0.40m。2003年除了秋季外，本

模式平均絕對誤差皆小於WANF之結果。但是兩者之平均絕對誤差皆約為0.33。2002年學習階段的平均偏態，本模式則為-0.05-0.01m，WANF模式則為-0.29-0.12；2003年的推算階段本模式約為-0.08-0.16m，WANF模式則為-0.35-0.02m。由此可知，本模式之學習及推算誤差優於WANF模式之推算結果。

本研究將2002年及2003年EMD_NN及WANF模式與花蓮實測波高分別繪制散佈圖，示如圖7至圖10。由圖7及8中可看出本模式之學習及推算階段結果，其相關性約為0.86及0.72。但兩者之線性回歸線之斜率皆約為0.72及0.56。圖9及10兩者之線性回歸線之斜率皆約為0.52及0.46。因此，由此可知EMD_NN的相關性結果較優於WANF模式，且與實測之結果較接近，WANF模式之推算波高與實測波高的分布較本模式散亂，且實測波高在0~2m範圍，大部份的WANF模式波高則約為0.7~1m。顯示WANF在波高0~2m時的推算較無法完全的模擬風浪的特性。

表1 花蓮EMD_NN模式與WANF模式推算能力評估

		EMD NN			WANF		
		γ	ε (m)	β (m)	γ	ε (m)	β (m)
2002	春	0.86	0.18	0.01	0.73	0.34	-0.29
	夏	0.77	0.15	-0.05	0.58	0.21	0.10
	秋	0.78	0.20	0.00	0.71	0.27	0.12
	冬	0.87	0.21	-0.01	0.77	0.32	-0.20
	平均	0.86	0.18	0.00	0.67	0.28	-0.05
2003	春	0.75	0.25	-0.08	0.72	0.29	-0.19
	夏	0.57	0.21	-0.03	0.37	0.24	0.00
	秋	0.51	0.33	0.04	0.65	0.33	0.02
	冬	0.70	0.32	0.16	0.75	0.40	-0.35
	平均	0.72	0.28	-0.02	0.73	0.32	-0.14
兩年平均		0.79	0.23	0.01	0.69	0.30	-0.09

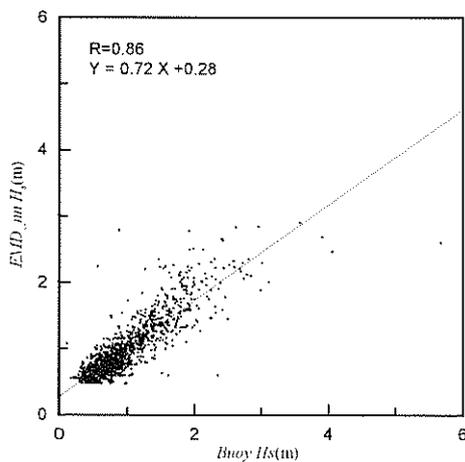


圖7 2002 EMD_NN模式與實測值之散佈圖

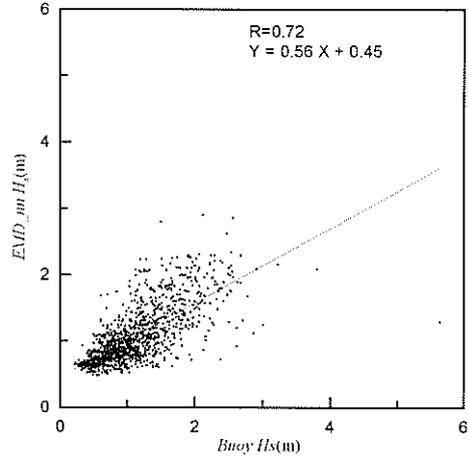


圖8 2003 EMD_NN模式與實測值之散佈圖

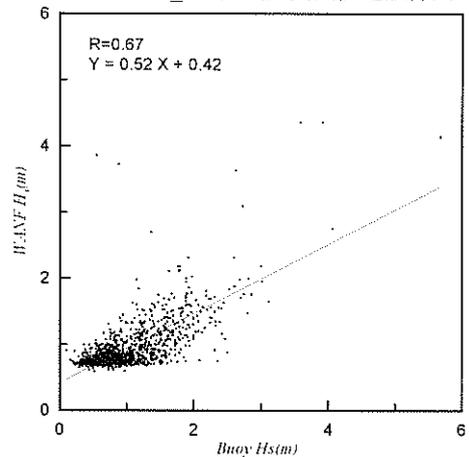


圖9 2002 WANF模式與實測值之散佈圖

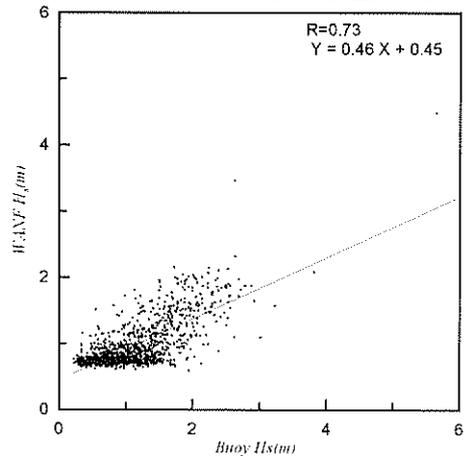


圖10 2003 WANF模式與實測值之散佈圖

五、結論

本研究以EMD法分解RC模式之風速，並將分解之IMF作為類神經網路之輸入值。該方法將不同能量及頻率的風速分解，藉由類神經網路建立風浪特性關係。本模式(EMD_NN)之風浪模式，以花蓮測站學習資料時間為2002年，預測時間則為2003年，本文架構花蓮之風浪長期推測模式，其與2003年實測值之相關係數約0.72、平均絕對誤差約0.28公尺。由此顯示本模式之推算結果，可建立區域性的風浪關係，並實際應用於長期風浪之推算與預警，藉由不同能量之風速分解，可讓類神經網路建構不同風能分量所造成的波浪結果。此法與僅使用風速及波高及其延時作為模糊類神經網路(WANF)輸入值更能描述風浪地特性。

謝誌

本研究RC模式風場及花蓮波高數據由中央氣象局海象測報中心提供，使本研究得以順利完成，謹誌謝忱。

參考文獻

1. 張憲國、林立青、蔡獲光、徐月娟、林芳如, 2006: “類神經模糊網路之風浪推算模式”, 天氣分析與預報研討會論文集, 7-61-7-66。
2. Bhattacharya, B., Shrestha, D.L., Solomatine, D.P., 2003: “Neural Networks in Reconstructing Missing Wave Data in Sedimentation Modelling”, Proceedings of the XXXth IAHR Congress, Thessaloniki, Greece.
3. Bretschneider, C. L., Tamaye, E. E., 1976: “Hurricane Wind and Wave Forecasting Techniques”, Proceedings of 15th Conference on Coastal Eng., Hawaii, 1, 202-237.
4. Browne, M., Castelle, B. Strauss, D., Tomlinson, R., Blumenstein, M., Lane, C., 2007: “Near-shore swell estimation from a global wind-wave model: Spectral process, linear, and artificial neural network models,” Coastal Eng., Vol. 54, pp. 445-460.
5. Chang, H.K., Chien, W.A., 2006a: “Neural network typhoon wave models using multi trend simulating transfer functions”, Adv. Eng. Softw., 37, 184-194.
6. Chang, H.K., Chien, W.A., 2006b: “A fuzzy-neural hybrid system of simulating typhoon waves”, Coastal Eng., 53, 737-748.
7. Deo, M.C., Sridhar Naidu, C., 1999: “Real time wave forecasting using neural networks”, Ocean Eng., 26, 191-203.
8. Deo, M.C., Jha, A., Chaphekar, A.S., Ravikant, K., 2001: “Neural networks for wave forecasting”, Ocean Eng., 28, 889-898.
9. Deo, M.C., Jagdale, S.S., 2003: “Prediction of breaking waves with neural networks”, Ocean Eng., 30, 1163-1178.
10. Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shin, H. S., Zheng, Q., Yuen, Y., Tung, C. C. and Liu, H. H., 1998: “The empirical mode decomposition and Hilbert spectrum for nonlinear and non-stationary time series analysis”, Proc. Roy. Soc. Lond, 454, 903-995.
11. Huang, N. E., Shen, Z., Long, S. R., 1999: “A new view of nonlinear water waves: The Hilbert spectrum”, Ann. Rev. Fluid Mech. 31, 417-457.
12. Jang, R., 1993: “ANFIS: Adaptive-network-based fuzzy inference systems”, IEEE Trans. On Systems, Man, and Cybernetics, 23(3), 665-685.
13. Kalra, R., Deo, M.C., Kumar, R., Agarwal, V. K., 2005: “Artificial neural network to translate offshore satellite wave data to coastal locations”, Ocean Eng., 32, 1917-1932.
14. Kalra, R., Deo, M.C., 2007: “Derivation of coastal wind and wave parameters from offshore measurements of Topex satellite using ANN,” Coastal Eng., 54, 187-196.
15. Makarynsky, O., 2004: “Improving wave predictions with artificial neural networks”, Ocean Eng., 31, 709-724.
16. Özger, M., Sen, Z., 2007: “Prediction of wave parameters by using fuzzy logic approach,” Ocean Eng., 34, 460-469.
17. Sverdrup, H. U., Munk W. H., 1947: Wind, Sea and Swell, Theory of Relation for Forecasting, U. S. Navy Hydrographic Office, Pub. 601, 44.