

類神經網路流量系集預報模式之應用

The Application of Ensemble Flood Forecasting Using Artificial Neural Network

逢甲大學 水利工程與資源保育學系 碩士	逢甲大學 水利工程與資源保育學系 教授	逢甲大學 營建及防災研究中心 研究助理	逢甲大學 營建及防災研究中心 研究助理教授
林欣平	陳昶憲	唐偉倫	鍾侑達*
Hsin-Ping Lin	Chang-Shian Chen	Wei-Lun Tang	You-Da Jhong

摘 要

近年來，人工智慧方法常應用於水文流量預測上，本研究是以倒傳遞類神經網路為洪水預測模式之主要架構，即以倒傳遞類神經網路建構集水區系統特性，然而建模時，類神經網路之權重與閾值透過隨機選取，可取得無限多組滿足某一模式評鑑指標精度的參數組。本研究嘗試以自組織映射圖網路，聚類出具代表性的參數權重組，進行流量預測、區間預測及機率預測，由結果可知在同類參數的類神經網路模式具有高準確性之流量預測。

關鍵詞：倒傳遞類神經網路，自組織映射圖網路，系集洪流量預測。

ABSTRACT

In recent years, artificial intelligence methods predicted the hydrologic flood forecasting universally. This study employed a Back-Propagation Network (BPN) as the main structure in flood forecasting to learn the characteristic of catchment system. When the modeling, it could obtain the infinite set of parameters to satisfy the efficiency coefficient with stochastic initiate parameters. This paper attempted to combine Self-Organizing Map (SOM) to cluster representative weights and biases. A SOM network with classification ability was applied to classify the BPN parameter rules and to obtain the winning parameters. Finally, it will provide the point prediction, interval prediction and probability prediction. It can see that the artificial neural network has a high accuracy of the flood forecasting.

Keywords: Back-Propagation Network, Self-Organizing Map, Ensemble Flood Forecasting.

*通訊作者，逢甲大學營建及防災研究中心研究助理教授，40724 台中市西屯區文華路 100 號，m0403095@mail.fcu.edu.tw

一、前言

1.1 研究動機與目的

臺灣地理位置位於西太平洋颱風移動範圍內，平均年降雨量約為 2,500 毫米，多集中於每年 5~10 月的梅雨季及颱風，加上臺灣自然地形陡峭，使河川流域底床坡陡流急、洪水湍急與集流時間短，容易引起嚴重的洪水災害，每逢颱風或暴雨來臨時，迅速造成大量洪水對下游居民造成嚴重的生命財產損失及傷亡，近年來隨著氣候變異日趨顯著，極端水文事件愈趨頻繁，為期能降低洪水災害，因此發展洪水量之預測模式實有其必要性。然而水文現象在時間與空間變異性造成高度非線性現象，尤以颱風所造成之洪水更不易掌握，類神經網路為人工智慧方法之一，具有多變化的數學結構，可用於模擬水文複雜現象之非線性關係。

近年來許多學者將人工智慧方法應用在水文量之預測上，Islam (2010)利用類神經網路模式進行水位預報，其預報時間達十天，且有高度的準確性；陳昶憲等(2011)以時間序列模式預測颱風洪水位，嘗試加入調適性網路模糊推論系統對一階延遲現象進行修正；M.P. Rajurkara (2004)利用類神經網路建立降雨-逕流模式，從結果可看出其能準確地建立降雨-逕流關係；Yang *et al.* 等(2009)以倒傳遞類神經網路建構颱風洪流量預測模式，並建立出多組模式之網路參數，作為自組織映射圖網路之訓練聚類樣本進行聚類分析，找出最佳參數範圍進行颱風區間預測；陳昶憲等(2011)以遺傳規劃法建立烏溪之洪水預報模式，利用自適應網路模糊推論系統對可能發生之誤差加以修正；張嘉玲等(2012)以倒傳遞類神經網路分析集水區降雨-逕流的相關性，在輸入資料中加入前 1 時刻流量，能提升模式的精確度。前述各位學者其研究成果中顯示出人工智慧方法具有良好的預測效果，類神經網路所建立之模式具有良好之精度。

本研究以倒傳遞類神經網路為洪流量預測模式之主要架構，以隨機設定權重及閾值，訓練多組倒傳遞類神經網路，針對倒傳遞類神經網路

之權重及閾值，利用自組織映射圖網路進行分類，選出前三多聚類相似之倒傳遞類神經網路，期待在同一類相似之倒傳遞類神經，能有相當程度精度的預測結果，並計算流量預測、區間預測與機率預測，其結果可提供決策者於流量預測時，提供多方面之預測結果。

二、研究區域與資料蒐集

2.1 研究區域

本研究以烏溪流域進行實例演算，烏溪流域位於臺灣西海岸中部，發源於中央山脈合歡山西麓，東以中央山脈為界，東西長約 84 公里，南北寬約 52 公里，略似桐葉狀。地勢為東北向西南走向，幹線全長 119.13 公里，流域面積 2,025.6 平方公里，山地面積佔 2/3，平地包括埔里盆地、臺中盆地及濱海地區一部份，其主要水系可劃分為北港溪、南港溪、筏子溪、大里溪、貓羅溪及烏溪主流。烏溪流域水文測站分佈如圖 1 所示。

2.2 水文資料蒐集

本研究利用烏溪流域上游之流量測站(大里溪水系：溪南橋流量站、貓羅溪水系：南崗大橋流量站、烏溪主流上游：烏溪橋流量站)之時流量資料，預測烏溪下游流量測站(大肚橋流量站)之時流量。烏溪橋流量站受到 921 地震的影響，造成自記水位計受損，使其 1999 年至 2002 年之資料缺漏，大肚橋流量站於 2005 年至 2009 年期間廢站，其間資料缺漏，資料選取主要考量各水文測站於颱風事件中資料的完整性，故選取民國 85 年至 102 年發生之 8 場資料完整的颱風事件為研究資料，以 5 場颱風事件進行模式之訓練，再對驗證組之颱風事件進行模擬。學習組與驗證組之颱風事件如表 1 所示。

三、理論概述與模式建置

本研究主要以倒傳遞類神經網路與自組織映射圖網路為理論基礎所發展出來的，研究中所提及理論概述分別如下。

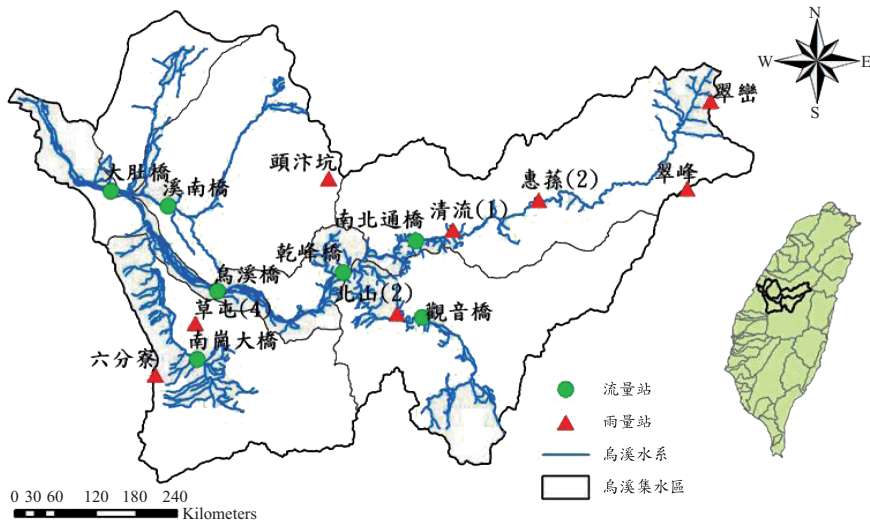


圖 1 烏溪流域水文測站分佈圖。

表 1 流量站預測模式使用之颱風事件資料

編號	時間(年/月/日)	颱風名稱	洪峰值(cms)	侵臺路徑分類	類別
1	1996/7/31	賀伯	5630	2	學習；檢定
2	1997/8/29	安珀	990	3	學習；檢定
3	1998/8/4	奧托	1440	3	學習；檢定
4	1998/10/16	瑞伯	1420	6	學習；檢定
5	2012/7/30	蘇拉	7199.62	2	學習；檢定
6	2013/7/11	蘇力	11004.73	2	驗證
7	2013/8/20	潭美	2011.4	1	驗證
8	2013/8/27	康芮	1786.04	6	驗證

3.1 線性轉換函數(Linear Transfer Function, LTF)

線性轉換函數為 Liu and Hanssens (1982)所提出的，可應用於一個以上投入數列的模式鑑定，係利用最小平方法直接估計衝擊反應權重，其線性轉換函數式如下：

$$Y_t = C + (v_0 + v_1 B + v_2 B^2 + \dots + v_l B^l) X_t + a_t \quad (1)$$

式中， Y_t 為 t 時刻的輸出量(大肚橋流量)

C 為常數項

B 為後移運算子(Backward Shift Operator)

X_t 為投入變數向量(大肚橋、溪南橋、南崗大橋、烏溪橋)

$(v_0, v_1, v_2, \dots, v_l)$ 為衝擊反應權重

a_t 為白噪音數列 ($a_t \sim NID(0, \sigma_a^2)$)

當衝擊反應權重求出後，進行各權重值的 t 值顯著性檢定， t 值為一統計參數，指統計假設之接受或拒絕全視特定統計量 \bar{X}_0 與母數 μ_0 之間是否有顯著性差異而定。利用 t 值相對大小，以決定集水區各流量站流量對出口流量站流量最適當的影響階數，大於 $| \pm 1.96 |$ 即表示其參數落在 95% 信賴區間內，其顯著性可以接受。

3.2 倒傳遞類神經網路(Back Propagation Network, BPN)

類神經網路具有將輸入變數與輸出變數間，

呈現複雜的對映關係之功能，解決非線性問題的工具之一。倒傳遞類神經網路為應用最為普遍的類神經網路，其一般包含三層，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-將輸入與輸出層各處理單元間的相互關係充分的表現出來。倒傳遞類神經網路模式之學習訓練為監督式學習網路，其係從所探討問題中取得訓練案例，並從案例中推求輸入變數與輸出變數的內在對映規則，之後可應用回想功能，以訓練所得的內在對映規則，進行新案例之輸出變數值預測。陳昶憲等(2011)以傳統倒傳遞類神經網路建構流量預測模式，由遺傳規劃法重新建構模式之轉換函數，解決低流量高估及高流量低估的問題，其轉換函數較近似於直線，本文中倒傳遞類神經網路之轉換函數以此作為參考。

本研究是以烏溪上游各主、支流入流量為輸入變數，以下游大肚橋出流量為輸出變數，選用歷史颱風資料作為模式學習及驗證。在建立模式時，需先將資料前處理，採用極值正規化方法將原始值壓縮在 0~0.8 之間，以預防模式在驗證時模擬出高於學習範圍之值，極值正規化公式如下：

$$X_{new} = [(X - \min(X)) / (\max(X) - \min(X))] \times 0.78 \quad (2)$$

式中， X_{new} 為正規化後之值

X 為原始資料

$\min(X)$ 為原始資料範圍內的最小值

$\max(X)$ 為原始資料範圍內的最大值

3.3 自組織映射圖網路(Self-Organize maps, SOM)

自組織映射圖網路係 T. Kohonen 在 1980 年所提出之競爭式的非監督式學習網路模式，不需給定輸出而是透過類神經競爭的方式尋求答案，其基本原理係仿效大腦將相似功能之腦細胞聚集，形成較佳運作效率之腦神經群，此亦類似「物以類聚」觀念，自問題領域內所有的訓練範圍(所有輸入變數值)，從中學習並分類，將訓練範圍聚類為幾種規則。網路學習完畢後，其輸出處理單元會相互影響，使相鄰近者會具有相似的功能，

亦是具有相似的連結加權值。

3.4 評鑑指標

為了評估模擬結果之準確度，本研究採用下列五種指標進行模式評鑑，說明如下：

(1) 效率係數(Coefficient of efficiency, CE)

$$CE = 1 - \frac{\sum (Q_t - \hat{Q}_t)^2}{\sum (Q_t - \bar{Q}_t)^2} \quad (3)$$

式中： \hat{Q}_t 為模式預測之流量(cms)

Q_t 為觀測之流量(cms)

\bar{Q}_t 為觀測流量之平均值(cms)

若 CE 值愈趨近 1，則表示模擬結果與實際資料愈密合，即精確度愈高。

(2) 洪峰誤差(Error of peak Discharge, EQ_p)

$$EQ_p = \frac{Q_{pest} - Q_{pobs}}{Q_{pobs}} \quad (4)$$

式中： Q_{pest} 為模式預測之洪峰流量(cms)

Q_{pobs} 為觀測之洪峰流量(cms)

若 $EQ_p > 0$ ，表示模式預測之洪峰值大於觀測之洪峰值。

若 $EQ_p < 0$ ，表示模式預測之洪峰值小於觀測之洪峰值。

(3) 洪峰到達時刻誤差(Error of time to peak, ET_p)

$$ET_p = T_{pest} - T_{pobs} \quad (5)$$

式中： T_{pest} 為模式預測之洪峰到達時刻

T_{pobs} 為觀測之洪峰流量到達時刻

若 $|ET_p|$ 愈小，表示模式所預測之洪峰到達時刻愈準確。

(4) 平均絕對值誤差(Mean Absolute Error, MAE)

$$MAE = \frac{1}{M} \sum_{l=1}^M |Q_{t+l} - \hat{Q}_{t+l}| \quad (6)$$

式中： M 為觀測值數目

Q_{t+l} 為第 l 時刻之觀測值

\hat{Q}_{t+l} 為第 l 時刻之預測值。

(5) 平均絕對誤差百分比 (Mean Absolute Percentage Error, $MAPE$)

$$MAPE = \left(\frac{1}{M} \sum_{t=1}^M \left| \frac{Q_{t+1} - \hat{Q}_{t+1}}{Q_{t+1}} \right| \right) \times 100\% \dots(7)$$

式中：M 為觀測值數目

Q_{t+1} 為第 t 時刻之觀測值

\hat{Q}_{t+1} 為第 t 時刻之預測值

(6) 準確率(Rate of Accuracy, ROA)

$$ROA = \frac{N}{M} \times 100\% \dots\dots\dots(8)$$

式中：M 為單場颱風流量值總個數

N 為單場颱風實際流量介於區間範圍內總個數

3.5 模式建置

本研究利用 LTF 決定烏溪流域上游各流量測站資料對下游出流量影響時間階數分析，並配合流量站間洪水波傳遞時間研判，可得各流量測站對大肚橋流量測站 t 時刻流量影響最為顯著之影響時間，如表 2 所示，表中 t 值大於 |±1.96| 皆為明顯影響之時間階次，選取大肚橋 Q_{t-1} 、溪南橋 Q_{t-1} 、南崗大橋 Q_{t-1} 、烏溪橋 Q_{t-1} 時刻流量作為模式輸入值，以大肚橋 Q_t 時刻流量為輸出值，進行模式訓練。

表 2 各流量測站各階權重 t 值檢定結果表

階數/測站	大肚橋	溪南橋	南崗大橋	烏溪橋
Q_{t-1}	22.51	4.03	6.96	4.44
Q_{t-2}	-4.37	-0.87	-2.78	-1.09
Q_{t-3}	-0.19	1.74	2.11	-0.14
Q_{t-4}	-0.15	-0.94	-1.17	0.98

本研究以烏溪流域進行集水區洪水流量預測，選用民國 85 年至 102 年發生之 8 場颱風事件為研究資料，並使用 BPN 為洪流量預測模式之主要架構，對 BPN 模式可行解之參數值利用 SOM 進行聚類分析進行流量預測，其模式建置步驟如下，模式建置流程圖如圖 2 所示：

1. 將研究區域內之水文流量測站資料以極值正規化方法進行資料正規化。
2. 進行上游各流量測站資料對下游出流量影

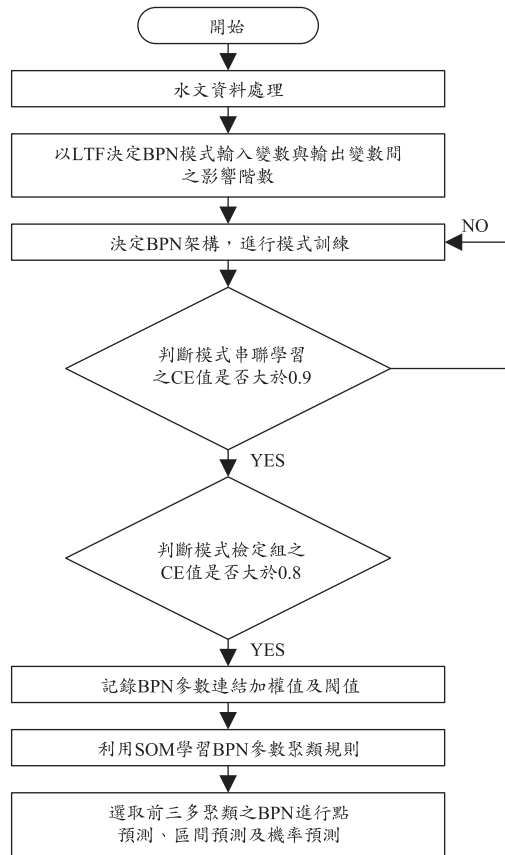


圖 2 模式建置流程圖。

響時間階數的 LTF 分析，得各流量測站對大肚橋流量測站 t 時刻流量影響最為顯著之影響時間。

3. 由步驟 2 可得，選取大肚橋 Q_{t-1} 、溪南橋 Q_{t-1} 、南崗大橋 Q_{t-1} 、烏溪橋 Q_{t-1} 時刻流量為模式訓練之輸入值，輸出值則為大肚橋 Q_t 時刻流量，BPN 之隱藏層單元數為(輸入層處理單元數+輸出層處理單元數)/2，故隱藏層單元數取 3 個。BPN 各層處理單元個數決定後，即可進行網路學習訓練。轉換函數選擇 Linear function，其型式為 $f(x) = x$ 。訓練過程則採用最陡坡降法(Gradient Steepest Descent Method)來調整權重參數值的增幅 (ΔW_{ij})。BPN 模式架構如圖 3 所示。
4. 紀錄 300 組串聯資料學習 CE 值大於 0.9 之




圖 3 倒傳遞類神經網路架構圖。




圖 4 自組織映射圖網路學習。

BPN 模式，再篩選出 142 組達到各單場檢定 CE 值皆大於 0.8 之 BPN 模式，紀錄其 BPN 模式之連結加權值及閾值(連結加權值及閾值一組共 19 個參數)。

5. 由步驟 4 所紀錄之 142 組 BPN 模式之連結加權值及閾值為訓練 SOM 聚類樣本，設定 9×9 大小的拓圖網格，進行 SOM 網路學習聚類分析，可得多個相同性質之 BPN 聚類模式，選取前三多的 SOM 聚類之模式，分別定義為 A、B、C 類模式，進行檢定及驗證。SOM 模式架構如圖 4 所示。SOM 聚類結果如圖 5 所示。

3.6 模式應用

A、B、C 類模式分別有 10 組、9 組及 8 組 BPN 模式之聚類，應用各類 BPN 模式進行流量預測、區間預測及機率預測。

- (1) 流量預測：本研究流量預測方法有兩種

- i. 方法 1：於 A、B、C 類模式中，分別

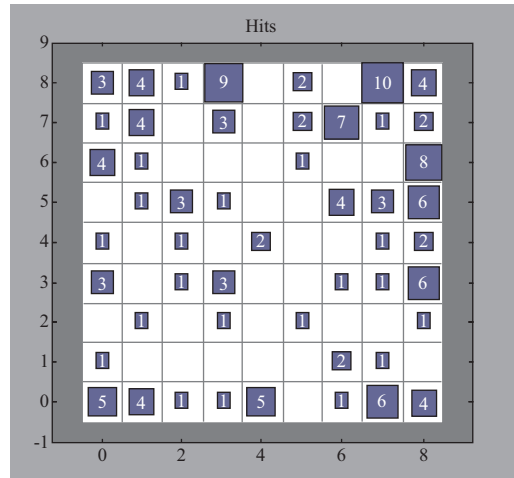


圖 5 SOM 學習聚類結果。

以學習資料評鑑指標 EQ_p 最小值之 BPN 模式，為流量最佳預測結果。

- ii. 方法 2：於 A、B、C 類模式，依不同類組可分別預測出 10 筆、9 筆、8 筆流量預測值，再依各類組之流量預測值計算其平均值，為流量系集平均預測結果。

- (2) 區間預測：於 A、B、C 類模式，3 個類組分別預測出各類流量預測值，依各類模式之最大及最小值，為流量預測之上下區間，為流量區間預測結果。

- (3) 機率預測：由流量預測方法 2 中，求得 A、B、C 類模式流量預測結果之平均值與標準偏差，假設預測範圍為常態分佈，即可訂定出 95%信賴區間，得流量機率預測結果。

四、結果與討論

4.1 檢定結果

A、B、C 類最佳模式分別為該類第 5、第 1 及第 3 筆模式，由這 3 個模式分別畫出各颱風最佳模式預測值，各颱風流量預測結果如圖 6 至圖 20 所示，表 3、表 4 為模式各評鑑指標結果，表 3 兩種流量預測結果中，整體預測皆有不錯的表




圖 6 A 組聚類預測結果-檢定組賀伯颱風。




圖 7 B 組聚類預測結果-檢定組賀伯颱風。




圖 8 C 組聚類預測結果-檢定組賀伯颱風。




圖 9 A 組聚類預測結果-檢定組安珀颱風。




圖 10 B 組聚類預測結果-檢定組安珀颱風。




圖 11 C 組聚類預測結果-檢定組安珀颱風。




圖 12 A 組聚類預測結果-檢定組奧托颱風。




圖 13 B 組聚類預測結果-檢定組奧托颱風。




圖 14 C 組聚類預測結果-檢定組奧托颱風。




圖 15 A 組聚類預測結果-檢定組瑞伯颱風。




圖 16 B 組聚類預測結果-檢定組瑞伯颱風。




圖 17 C 組聚類預測結果-檢定組瑞伯颱風。




圖 18 A 組聚類預測結果-檢定組蘇拉颱風。




圖 19 B 組聚類預測結果-檢定組蘇拉颱風。




圖 20 C 組聚類預測結果-檢定組蘇拉颱風。

現及結果，A、B、C 類中最佳模式及系集平均皆以蘇拉颱風預測結果最佳，CE 達 0.98 以上，安珀颱風為所有檢定及驗證場次中之颱風流量最小，A、B 類中最佳模式及系集平均預測結果較差，CE 值亦有 0.84 以上；區間預測的上下界都比機率預測較寬，故表 4 評鑑指標結果中，以區間預測結果較佳。

因類神經網路模式在訓練模式時，模式以流

表 3 檢定組流量預測評鑑指標結果

颱風場次	聚類規則	預測方法	評鑑指標				
			CE	MAPE (%)	MAE (cms)	EQ_p	ET_p (hr)
賀伯	A 組	最佳模式	0.943	15.913	280.729	0.041	1
		系集平均	0.961	11.690	220.254	-0.035	1
	B 組	最佳模式	0.942	14.959	283.833	0.056	1
		系集平均	0.955	13.500	246.913	0.000	1
	C 組	最佳模式	0.958	12.513	235.9	0.007	1
		系集平均	0.955	12.179	233.295	-0.028	1
安珀	A 組	最佳模式	0.848	32.260	84.259	0.105	1
		系集平均	0.910	23.360	64.608	-0.071	1
	B 組	最佳模式	0.893	23.397	66.552	0.094	1
		系集平均	0.889	27.440	73.968	-0.072	1
	C 組	最佳模式	0.913	22.213	62.948	0.069	1
		系集平均	0.919	22.449	63.776	-0.037	1
奧托	A 組	最佳模式	0.881	42.195	98.322	0.170	1
		系集平均	0.896	35.663	96.573	-0.072	1
	B 組	最佳模式	0.902	32.884	88.335	0.112	1
		系集平均	0.893	35.715	92.318	-0.130	1
	C 組	最佳模式	0.900	31.794	89.442	0.087	1
		系集平均	0.895	29.185	87.518	-0.095	1
瑞伯	A 組	最佳模式	0.919	41.099	111.388	0.073	0
		系集平均	0.939	30.573	95.063	-0.048	0
	B 組	最佳模式	0.944	29.550	89.994	0.039	0
		系集平均	0.927	35.775	104.956	-0.074	0
	C 組	最佳模式	0.940	29.157	93.073	0.052	0
		系集平均	0.930	30.079	99.323	-0.075	0
蘇拉	A 組	最佳模式	0.982	20.057	194.250	0.008	-1
		系集平均	0.988	16.473	143.133	0.030	0
	B 組	最佳模式	0.987	14.949	147.045	0.008	0
		系集平均	0.986	16.789	170.523	0.036	-1
	C 組	最佳模式	0.988	14.430	138.092	0.019	0
		系集平均	0.986	13.022	151.584	0.050	-1

表 2 檢定組區間預測評鑑指標結果

颱風場次	聚類規則	評鑑指標 ROA (%)	
		區間預測	機率預測
賀伯	A 組	59.57%	27.66%
	B 組	53.19%	21.28%
	C 組	63.83%	40.43%
安珀	A 組	40.43%	6.38%
	B 組	27.66%	12.77%
	C 組	21.28%	8.51%
奧托	A 組	22.58%	12.90%
	B 組	45.16%	12.90%
	C 組	67.74%	12.90%
瑞伯	A 組	21.21%	6.06%
	B 組	15.15%	3.03%
	C 組	12.12%	3.03%
蘇拉	A 組	64.29%	41.07%
	B 組	82.14%	32.14%
	C 組	85.71%	51.79%

量較大的範圍修正模式之權重及閾值較為明顯，所以在各類的流量預測在低流量時誤差百分比比較大。

4.2 驗證結果

驗證組各颱風預測結果如圖 21 至圖 29 所示，表 5、表 6 為模式各評鑑指標結果，A、B、C 類中最佳模式以潭美颱風預測最佳，CE 皆達 0.93 以上，A、B、C 類中系集平均 3 場颱風整體效率係數有 0.96 以上，而蘇力颱風是所有檢定及

驗證中颱風流量最大，而各類模式之最佳模式預測結果明顯不佳，因其降雨多集中於烏溪流域的中游且颱風移動速度快，使預測效果不佳，而系集平均預測擇優於最佳模式預測。

區間及機率預測中，評鑑指標皆比訓練時表現較佳，主要是因為類神經網路在驗證時其區間上下界差異更大，所以更容易涵蓋到觀測值，所以區間及機率預測也提供使用者預測範圍而不是單一值。




圖 21 A 組聚類預測結果-檢定組蘇力颱風。




圖 22 B 組聚類預測結果-檢定組蘇力颱風。




圖 23 C 組聚類預測結果-檢定組蘇力颱風。




圖 24 A 組聚類預測結果-檢定組潭美颱風。




圖 25 B 組聚類預測結果-檢定組潭美颱風。




圖 26 C 組聚類預測結果-檢定組潭美颱風。




圖 27 A 組聚類預測結果-檢定組康芮颱風。




圖 28 B 組聚類預測結果-檢定組康芮颱風。




圖 29 C 組聚類預測結果-檢定組康芮颱風。

表 5 驗證組流量預測評鑑指標結果

颱風場次	聚類規則	預測方法	評鑑指標				
			CE	MAPE (%)	MAE (cms)	EQ_p	ET_p (hr)
蘇力	A 組	最佳模式	0.806	46.067	917.919	0.204	0
		系集平均	0.980	26.865	327.413	-0.111	0
	B 組	最佳模式	0.764	45.704	1003.971	0.148	0
		系集平均	0.969	28.138	367.265	-0.151	0
	C 組	最佳模式	0.787	38.066	909.984	0.115	0
		系集平均	0.984	17.758	243.260	-0.102	0
潭美	A 組	最佳模式	0.949	16.233	103.267	0.041	-1
		系集平均	0.965	12.027	78.680	0.061	0
	B 組	最佳模式	0.931	16.531	120.433	0.058	-2
		系集平均	0.973	11.672	68.883	0.039	0
	C 組	最佳模式	0.946	14.439	103.298	0.046	0
		系集平均	0.986	8.432	48.556	0.032	0
康芮	A 組	最佳模式	0.936	21.594	109.319	0.060	0
		系集平均	0.964	17.074	70.789	0.093	0
	B 組	最佳模式	0.927	19.012	112.161	0.010	0
		系集平均	0.960	17.542	76.235	0.095	0
	C 組	最佳模式	0.922	18.043	112.261	0.047	0
		系集平均	0.970	12.635	59.983	0.113	0

表 6 驗證組區間預測評鑑指標結果

颱風場次	聚類規則	評鑑指標 ROA(%)	
		區間預測	機率預測
蘇力	A 組	69.57%	13.04%
	B 組	52.17%	39.13%
	C 組	56.52%	52.17%
潭美	A 組	75%	25%
	B 組	88.64%	56.82%
	C 組	86.36%	65.91%
康芮	A 組	61.54%	26.92%
	B 組	80.77%	30.77%
	C 組	88.46%	42.31%

五、結論與建議

5.1 結論

綜合上述內容，以下列點說明結論與建議：

1. 類神經網路結合自組織映射圖網路，使流量預測具有流量預測、區間預測及信賴區間機率預測，於流量預測應用面上更為廣泛與實用。
2. A、B、C 類模式共 27 個模式，於驗證組其整體預測之平均 CE 值皆有達到 0.93 以上；但於最佳模式流量預測中，蘇力颱風，因為其降雨異於大部分颱風事件，降雨多集中於烏溪流域的中游且颱風移動快速，使預測結果不佳，但 CE 值亦有 0.78。
3. 檢定及驗證組中，最佳值並無全優於系集平均值，檢定組各颱風場次最佳值與平均值整體預測結果皆不錯，在驗證組時整體則是平均值優於最佳值，而潭美、康芮最佳模式預測值之 CE 值有達 0.9 以上，驗證組中仍有良好表現。
4. 區間預測驗證組 A、B、C 類模式中，各類模式預測結果良好，平均 ROA 達到 68% 以上；機率預測中，以 C 類模式預測結果較佳，平均 ROA 為 53% 以上。

5.2 建議

1. 研究中常採用效率係數 CE 值為模式學習之性能指標，未來能考慮結合綜合性性能指標，在洪峰值的預測上更能掌握。

2. SOM 將類神經網路模式進行分類，未來可針對每一類適用之流量情形進行分析，以挑選出在不同流量情況下適用之 SOM 分類。
3. 侵臺颱風路徑主要分成十類，每一類路徑因降雨型態、時空分布的不同，對河川流量影響亦不同，未來可考量依不同路徑蒐集水文資料，使模式建立能更趨一致性。
4. 未來，可以考慮進一步應用預測前三小時、前六小時預報，測試與分析其預報能力。

參考文獻

1. Chao-Chung Yang and Chang-Shian Chen, "Application of integrated back-propagation network and self organizing map for flood forecasting", Hydrological Processes, Wiley InterScience, 23, pp. 1313-1323, 2009.
2. Liu, L.-M. and Hanssens, D. M., "Identification of multiple input transfer function models", Communications in Statistics, Part A—Theory and Models, 11, pp. 297-314, 1982.
3. Islam, A. S., "Improving flood forecasting in Bangladesh using an artificial neural network", Journal of Hydroinformatics, 12(3), pp. 351-364, 2010.
4. Kohonen, T., "The self-organizing map," Proc. IEEE, 78(9), pp. 1464-1480, 1980.
5. Rajurkara, M.P., Kothyarib, U.C. and Chaubec

- U.C., "Modeling of the daily rainfall-runoff relationship with artificial neural network", *Journal of Hydrology*, 285, pp. 96-113, 2004.
6. 陳志寬、陳思璋、鍾侑達、陳昶憲，「以遺傳規劃法建構類神經網路之轉換函數於降雨-逕流模式」，第二十屆水利工程研討會，K005，2011-12。
 7. 陳昶憲、鍾侑達、方唯鈞、葉昭憲，「以遺傳規劃建構智慧型洪水預報機制」，中國土木水利工程學刊，第 23 卷第 3 期，317-327 頁，2011。
 8. 張嘉玲、李孟遠、王傳益，「應用倒傳遞類神經網路於集水區流量預測-以台北水源特定區為例」，臺灣水利，第 60 卷第 2 期，98-104 頁，2012。
 9. 鍾侑達、黃晉華、陳昶憲、蘇惠珍，「以類神經模糊推理修正水位預測之一階延遲現象」，農業工程學報，第 57 卷第 3 期，1-16 頁，2011。

收稿日期：民國 105 年 11 月 6 日

修正日期：民國 106 年 9 月 14 日

接受日期：民國 106 年 9 月 25 日