

適應性網路模糊推論系統在洪水演算之研究

A Study of Adaptive-Network-Based Fuzzy Inference System for River Flood Routing

中國技術學院土木系講師

國家災害防救科技中心博士後研究

段 鏞

傅 金 城

Yong Duann

Jin-Cheng Fu

摘要

本文將複合式學習的適應性網路模糊推論系統應用於河川洪水演算，由複合式學習方式，建構規則庫及優選分佈之歸屬函數，應用於求解河川之洪水演算問題。在複合式學習的過程中，適應性網路模糊推論系統可以利用模糊規則建構輸入與輸出間的對應關係，可適用於非線性函數與非線性向量之系統。本文利用四場颱洪事件，以新海橋、中正橋和河口之即時水位觀測值為邊界條件預測台北橋水位，經由模擬結果顯示以即時水位及第 1 小時預報結果較佳。

關鍵詞：適應性網路模糊推論系統，洪水演算，複合式學習。

ABSTRACT

This study presents the application of hybrid-learning Adaptive-Network-Based Fuzzy Inference System (ANFIS) in river flood routing. By using the hybrid-learning algorithm in ANFIS model, the rule database and optimal distribution of membership functions have been constructed to solve the river flood routing problems. Based on the fuzzy rules, the ANFIS model establishes a mapping relationship between input and output in the processes of the hybrid-learning algorithm. The algorithm can be applied to nonlinear functions or nonlinear components. Four typhoon flood events are simulated to predict the water stage of Taipei Bridge using the real-time observed stages of the Hsinhai Bridge, Chungcheng Bridge and river mouth. The results show that the ANFIS model has good accuracy for real-time and 1-hour stage forecasting in the Tanshui River.

Keywords: Adaptive-Network-Based fuzzy inference system, Flood routing, Hybrid-learning.

一、前 言

臺灣之河川長度短促，且坡度陡，每於颱風季節來臨時，往往因為集中且強度大之暴雨造成嚴重洪災，使得人民之生命與財產嚴重受到威脅。若能建立一套快速又準確之預測洪水演算模式，對洪水來臨之前提出預警，將可減少洪水災害，使得人民之生命與財產更有保障。

過去對於河川洪水演算模式可以分為兩種類型，一為水文演算法，模式所依據的基本方程式為水文方程式，利用水文方程式發展出來的方法甚多，如波爾斯法、係數法、馬斯金更法…等[1]。另一為水力演算法，演算模式的基本方程式為連續方程式與運動方程式，但是，它們是偏微分方程式所建構的非線性控制方程式，無法得到真解，往往必須利用數值分析方法，如有限差分法[2]等，將方程式改寫為可以利用電腦程式求解之型式，最後再以電腦做大量之計算得到演算結果。

然而，因為水文現象往往是具有隨機性、不均勻性與非線性的，故可建立一個刺激(輸入)與反應(輸出)間相互關係之黑盒系統(Black-box system)，以做為水文演算之工具。本文主要建立適應性網路模糊推論系統(ANFIS)[24]，並應用於河川洪水之模擬、驗證與預測，達到建立一個簡單快速之預測模式的目的。

二、文獻回顧

雖然近代電腦發展快速，已經能夠進行大量且快速的運算。但是，電腦仍然無法達到與人腦具有相同的辨識能力及學習能力之境界。故希望藉由人工神經元模仿生物神經元的方式，由外界獲取資訊後經過簡單的計算，將結果輸出至其他之人工神經元或外界，達到以曾經發生過的事件為學習對象，經由適度的學習訓練使其具有辨識與預測之能力。

最早提出神經元模型的研究是在 1943 年由 McCulloch 與 Pitts 建構的感知機基本原理之神經元數學模型[16]，以其發明者之名命名為 MP 模型。其後在 1957 年 Rosenblatt 提出了感知機模型

(Perceptron)[14]，它是最古老的類神經網路模式。然而在 1969 年 Minsky 發表專書說明，感知機缺乏隱藏層的學習運算[18]，故其學習能力受到相當大的限制，並且無法解決互斥問題，使其發展受到停滯。

1974 年 Werbos 在其博士論文中提出了具有隱藏層的學習運算法[19]，這是最早的倒傳遞神經網路(Back-Propagation Network，BPN)，1982 年 Parker 再次提出一篇有關倒傳遞神經網路之文章[20]，1986 年 Rumelhart、Hinton 發表一篇倒傳遞神經網路之論文[22]，此後再度引發了世人對神經網路的重視。

倒傳遞神經網路增加了隱藏層，表現出處理單元間之關係，並且改用可微分之平滑轉換函數，使其可以利用最陡梯度法導出修正加權值之公式。1996 年陳昶憲、楊朝仲、王益文就以倒傳遞神經網路對烏溪之洪流預報加以研究[4]。1997 年張斐章、孫建平亦以倒傳遞網路模式對降雨與逕流之關係加以研究[5]。

繼倒傳遞神經網路後，在 1987 年 Robert, Hecht-Nielsen 發展出反傳遞神經網路 (Counter-Propagation Network，CPN) [23]，該網路系統結合了無監督式學習的自組織映射圖網路 (Self-Organizing Map, SOM) 與監督式學習的感知機，在輸入層與隱藏層間使用無監督式學習，在隱藏層與輸出層間使用監督式學習，其優點是學習速度較倒傳遞神經網路快，但是，其缺點是精確度較倒傳遞神經網路差。2001 年陳昶憲、黃尹龍、吳青俊、蔡曜隆曾以反傳遞神經網路對洪流量之預測加以研究及比較[8]。

至於模糊理論，最早是在 1965 年由 Zedach 提出[17]，到了 1974 年 Mamdah 更加入了邏輯條件敘述句將模糊理論加以推展。1990 年張斐章、徐國麟利用模糊理論推估河川流量[3]；1998 年張良正、楊朝仲、陳昶憲以模糊理論對洪流加以預測[6]。1999 年張斐章、梁晉銘以類神經模糊推論模式對大甲溪流域內德基水庫上游集水區旬流量加以驗證[7]。

1993 年由張智星發展出適應性網路模糊推論系統(Adaptive-Network-Based Fuzzy Inference

System, ANFIS)[24]，它能解決傳統模糊控制系統中，須要靠人類的思考一次又一次地調整歸屬函數方能達到減小誤差之缺點，故可以避免過多之人為試誤後方能達到準確演算結果的煩瑣過程。使其在有限筆數之訓練資料狀況下，達到學習速度快與預測準確之目的，同時具有相對誤差較小的優點。

適應性網路模糊推論系統曾經由不同領域之學者應用於實務的研究，2001 年廖宏彬、蘇仲鵬、吳慧敏[9]以適應性網路模糊推論系統建立教師人力需求的預測模式。2003 年謝維廷以適應性網路模糊推論系統建立禪定腦電波頻帶判讀系統，完成禪定者與非禪定者腦電波資料之差異性[12]。2001 年藍武王、葉信宏亦以適應性網路模糊推論系統研究不同冒險度駕駛人之跟車行爲[10]。2002 年盧永華等對機械材料之破口形成以 ANFIS 模式與有限元素法相互比較及探討，得到以 ANFIS 模式有非常良好的結果[27]。良忠儀科技公司由 1997 年開始所發展的 FK2.1 套裝軟體，是針對台股(Technical Assistance Information Exchange Unit, Taiex)所開發的另一期貨決策軟體，以 ANFIS 模式參數風險控管機制，找出小波段的高低點及大波段的起漲點及起跌點。

由以上不同領域學者的研究結果說明採用分散式的網路架構，將可以有效且快速的對於具有非線性與時間序列之有限數量的樣本空間，達到準確預測之目的。

三、模式理論

本文利用適應性網路模糊推論系統所設計之模糊邏輯控制器可以解決複雜的非線性、時變性且不易準確量測系統之問題。該模式將會對輸入資料與輸出資料經由複合式學習(hybrid-learning)之方式，使其耦合而得到最佳化分佈之歸屬函數(membership functions)，此後即可以對未來發生之事件予以快速準確的預測。

所謂複合式學習(hybrid-learning)之過程，在前半部為利用前向學習(forward pass)得到前半部參數，後半部則利用最小平方估算法(least

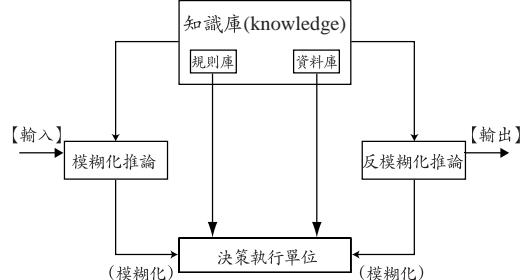


圖 1 模糊邏輯控制器結構圖

square estimate)求得後半部參數，再經由倒傳遞法(backward pass)中的最陡梯度法(gradient steepest descent approach)，將誤差率傳回前半部以更新前半部參數。當前半部參數與後半部參數在改變的過程中，其各個歸屬函數亦隨之發生變化，最後當前半部參數與後半部參數耦合時，就出現了各個配合適當之歸屬函數。

基本上，模糊邏輯控制器包括了五個部份，如圖 1 所示，五個部份如下列所述：

- 規則庫(rule base)：

內含許多人為訂定之模糊邏輯規則(If-then rules)。

- 資料庫(database)：

內含許多人為訂定範圍與型式之歸屬函數(Membership functions)。

- 決策執行單位(decision-making unit)：

執行人為訂定模糊規則之推論(inference)。

- 模糊化推論(fuzzification inference)：

將明確之輸入資料(Crisp input data)轉為適當之對應歸屬函數模糊狀態的語言值(linguistic value)。

- 反模糊化推論(defuzzification inference)：

將執行模糊規則推論的演算結果，利用反模糊化之程序轉變為明確之輸出資料(Crisp output data)。

模糊邏輯規則之型式為”If A is a , then B is b ”，為能簡單明瞭地說明 ANFIS 之計算過程，我們利用三個輸入資料 x 、 y 、 z 及一個輸出 f 之模糊推論系統來說明，利用 Sugeno's[21]之一階模糊規則，產生三個模糊規則，如下列三式所示：

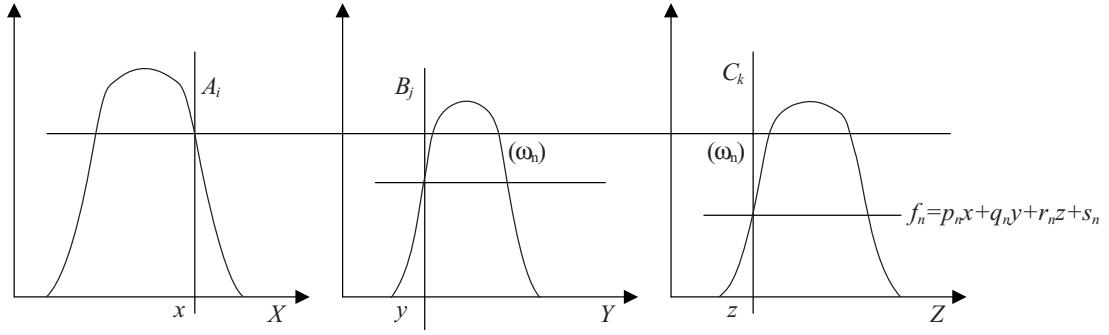


圖 2 適應性網路模糊推論示意圖

規則 1 : If x is A_1 and y is B_1 and z is C_1 , then $f_1 = p_1x + q_1y + r_1z + s_1$

規則 2 : If x is A_2 and y is B_2 and z is C_2 , then $f_2 = p_2x + q_2y + r_2z + s_2$

規則 3 : If x is A_3 and y is B_3 and z is C_3 , then $f_3 = p_3x + q_3y + r_3z + s_3$

式中 A_1, A_2, A_3 為設定之 x 的鐘形歸屬函數； B_1, B_2, B_3 為設定之 y 的鐘形歸屬函數， C_1, C_2, C_3 為設定之 z 的鐘形歸屬函數，其個數可自定； f_1, f_2, f_3 為輸出； $p_1, q_1, r_1, s_1, p_2, q_2, r_2, s_2, p_3, q_3, r_3, s_3$ 為參數。適應性網路模糊推論系統(ANFIS)之推論，如圖 2 所示。

適應性網路模糊推論系統之架構，如圖 3 所示，分為五層。圖中圓形標誌為固定節點(fixed nodes)，採用固定的參數組。而矩形標誌為適應性節點(adaptive nodes)，其參數為可以調整的。有關各層之節點函數如下列所述：

1. 第一層：

各節點為可以調整的，標示為矩形標誌，其節點函數如(1)、(2)、(3)三式。

$$O_i^1 = \mu_{A_i}(x) \quad i=1, 2, 3 \dots \quad (1)$$

$$O_j^1 = \mu_{B_{j-3}}(y) \quad j=4, 5, 6 \dots \quad (2)$$

$$O_k^1 = \mu_{C_{k-6}}(z) \quad k=7, 8, 9 \dots \quad (3)$$

式中 x, y, z 為節點之輸入； A_i, B_{j-3}, C_{k-6} 為語言變數(linguistic variable)，例如：in1mf1、in1mf2； in2mf2、in2mf2； large、small。 O_i^1, O_j^1, O_k^1 為歸屬函數(membership functions)； $\mu_{A_i}, \mu_{B_{j-2}}$ 、

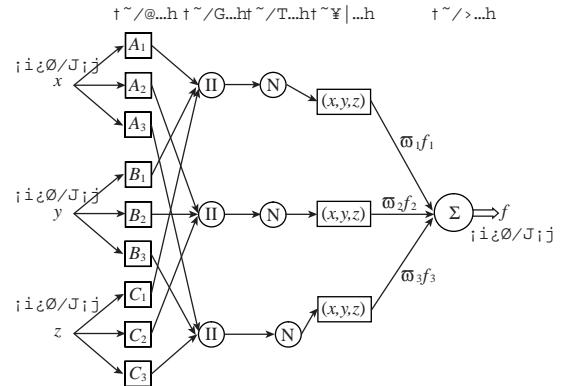


圖 3 適應性網路模糊推論系統架構圖

$\mu_{C_{k-6}}$ 通常為鐘形(bell-shaped)，其值介於 0 與 1 之間，以 $\mu(x)$ 表示之，如下列(4)式、(5)式所示。

$$\mu(x) = \frac{1}{1 + \left(\frac{x-c}{a}\right)^{2b}} \quad \dots \dots \dots \quad (4)$$

或

$$\mu(x) = \exp\left[-\left(\frac{x-c}{a}\right)^2\right] \quad \dots \dots \dots \quad (5)$$

式中之 a, b, c 為參數，當它們改變時鐘形函數亦隨之而變，其圖形如圖 4 所示。在圖 4 中

$$\mu(x) = \frac{1}{1 + \left(\frac{x-c}{a}\right)^{2b}} \quad \dots \dots \dots \quad (6)$$

2. 第二層：

各節點為固定的，標示為圓形標誌，此處由兩個以上之輸入訊號產生相乘結果後再送出，其

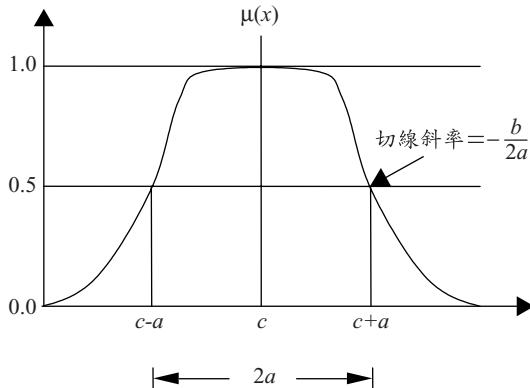


圖 4 鐘形歸屬函數圖形

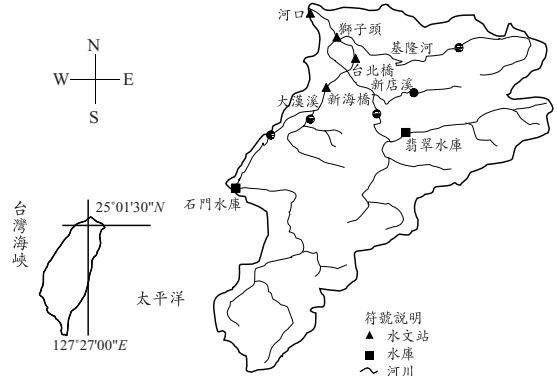


圖 5 淡水河流域

相乘結果如(7)式所示

$$O_n^2 = w_n = \mu_{A_n}(x) \times \mu_{B_n}(y) \times \mu_{C_n}(z) \dots \dots \dots (7)$$

式中 w_n 為經由 T-norm 之過程，對每一個模糊規則取得最小之觸發強度(firing strength)，又稱為權重(weighting)， $n=1, 2, 3$ 。

3. 第三層：

各節點為固定的，標示為圓形標誌，計算第 i 個模糊規則的觸發強度對所有模糊規則的觸發強度的比值，如(8)式所示。

$$O_n^3 = \overline{w_n} = \frac{w_n}{w_1 + w_2 + w_3} \dots \dots \dots (8)$$

式中 $\overline{w_i}$ 為常態觸發強度 (normalized firing strength)， $n=1, 2, 3$ 。

4. 第四層：

各節點為可以調整的，標示為矩形標誌，該層之節點函數如(9)式所示。

$$O_n^4 = \overline{w_n} f_n = \overline{w_n} (p_n x + q_n y + r_n z + s_n) \dots \dots \dots (9)$$

式中 p_n, q_n, r_n, s_n 為參數， $n=1, 2, 3$ 。

5. 第五層：

各節點為固定的節點，標示為圓形標誌，此處計算整體之輸出值，節點函數如(10)式所示。

$$O_n^5 = \sum_n \overline{w_n} f_n = \frac{\sum_n \overline{w_n} f_n}{\sum_n \overline{w_n}} \dots \dots \dots (10)$$

式中 O_n^5 為整體之輸出值(overall output)， $n=1, 2, 3$ 。

在學習訓練過程中，由第一層利用前向學習(forward pass)至第四層，以最小平方估算法(least square estimate)求得參數 p_n, q_n, r_n, s_n 。另一方面，同時利用倒傳遞法(backward pass)中的最陡梯度法(gradiant steepest descent approach)，將誤差率傳回以更新參數 p_n, q_n, r_n, s_n ，則其各所對應之歸屬函數亦隨之而變，直到最後前半部參數與後半部參數耦合後，就出現了各個適當分佈之歸屬函數。未來即可以利用訓練完成之適當分佈歸屬函數，對未來的事件加以預測，得到具有一定可以信任程度之預測結果，本模式對訓練資料數量少的事件往往可以獲得快速且準確性高得結果。

四、模式之學習訓練

本文之研究區域以位於台灣北部的第三大河川淡水河流域。淡水河流域發源於標高 3,529 公尺之品田山，流域內有大漢溪、新店溪、景美溪及基隆河等主要支流。大漢溪在江子翠與新店溪會合後，成為淡水河本流，如圖 5 所示。本流再與基隆河匯集於台灣首善都會區台北盆地，台北盆地約有 500 萬人口，最後本流至淡水鎮油車口附近，注入台灣海峽。淡水河全長 159 公里、流域面積廣達 2,726 平方公里，河道坡度範圍由 0.15 ‰ 至 27 ‰。流域之平均年降雨量約 3,001 公釐。但是，有大約 62% 的降雨集中於夏、秋兩季，使得台北盆地經常發生洪水災害，尤其在颱風來襲時，強度大且集中之降雨往往形成低窪地區洪水氾濫成災。

表 1 颱洪分組

發生年份	颱洪英文名稱	颱洪中文名稱	組別
1969	Alsi	艾爾西	訓練組
1969	Flossic	芙勞西	
1971	Basi	貝絲	
1972	Betty	貝蒂	
1977	Wila	薇拉	
1978	Ela	婀拉	
1985	Nelson	尼爾森	
1992	Ted	泰德	
1996	Herb	賀伯	
1998	Zeb	瑞伯	
2000	Bilis	碧利斯	
2001	Nani	納莉	
1992	Polly	寶莉	預報組
1997	Winnie	溫妮	
2000	Prapiroo	巴比侖	
2000	Xangsane	象神	

本文在經由台北橋與其附近各水文站之水位記錄分析後，發現颱洪期間新海橋、中正橋及河口之間的水位最為完整。故以新海橋、中正橋及河口的觀測水位資料進行台北橋水位的預測。

本文所採用的訓練組與預測組之颱洪事件列如表 1 所示，以訓練組中 12 場颱洪事件共 438 筆之觀測水位為訓練樣本，經訓練後輸入、輸出參數之變化範圍如下所列：

x ：新海橋水位範圍為 -0.86m 至 6.59m

y ：中正橋水位範圍為 -1.0m 至 8.59m

z ：河口水位範圍為 -1.53m 至 2.9m

O_i^5 ：台北橋水位範圍為 -1.13m 至 4.85m

在獲得較佳的參數值後，再個別對預報組之颱洪事件進行台北橋水位即時預報、第 1 小時預報、第 2 小時預報及第 3 小時預報。

本文在以 ANFIS 模式預測前，先以訓練組颱洪事件對不同數量之歸屬函數與訓練之訓練疊代次數對預測結果的影響加以分析，並以預報水位與觀測水位的均方差 (Root-Mean-Square Errors, RMSE)，作為決定最佳數量之歸屬函數及訓練疊代次數之判定依據，以免因過度訓練而產生預測結果不良之虞。其中 RMSE 的定義如(11)式所示。

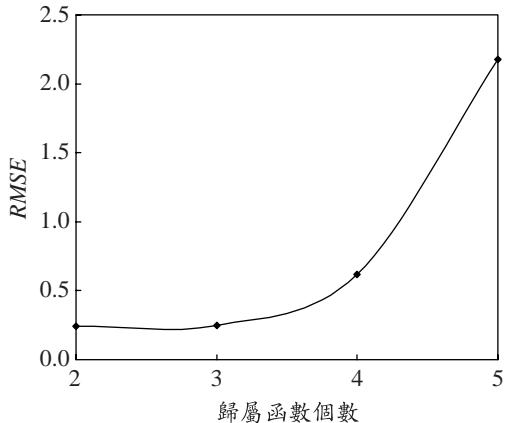


圖 6 歸屬函數個數與 RMSE 之關係圖

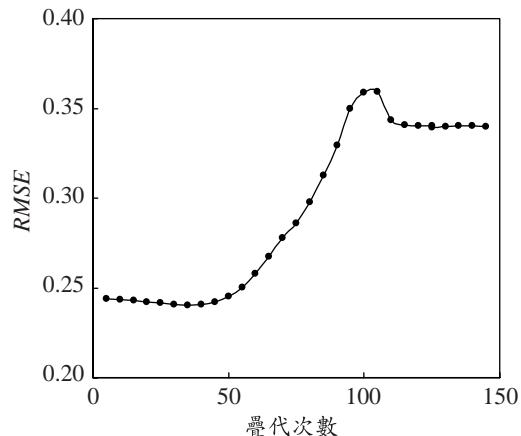


圖 7 疊代次數與 RMSE 之關係圖

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\bar{Y}_i - Y_i)^2}{N}} \quad \dots \dots \dots (11)$$

式中 \bar{Y}_i 為預報水位值； Y_i 為觀測水位值； N 為觀測值總數量。

由不同數量之歸屬函數的測試結果，發現以兩個歸屬函數做為訓練的結果，可以得到最小的 RMSE，且其水位的預測結果是最好的，如圖 6 所示。至於在疊代次數對預測結果影響分析下，則如圖 7 所示，圖中顯示以疊代次數為 35 次時，所產生的 RMSE 為最小，且其預測的結果是最佳的。經由以上的測試結果顯示，本文以兩個歸屬函數和 35 次疊代次數所建立的 ANFIS 模式較適合應用於洪水演算。

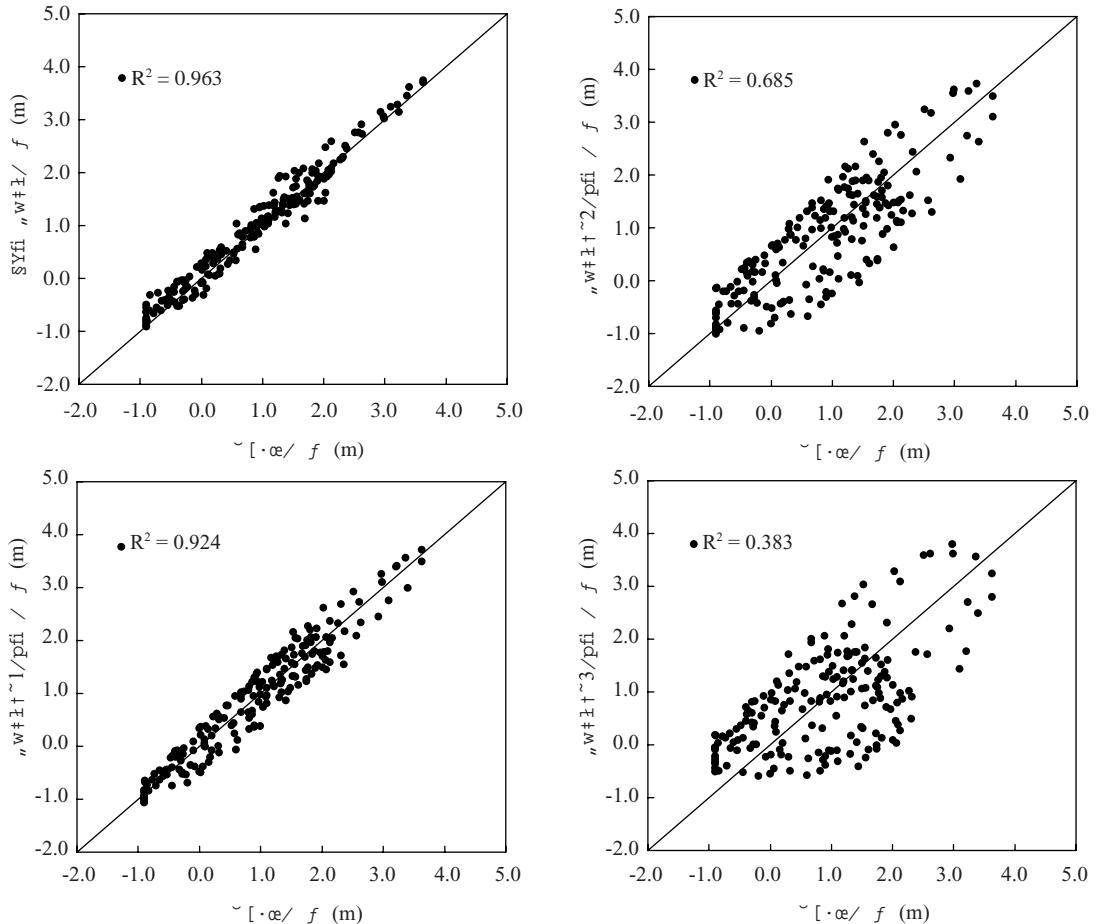


圖 8 各颱洪事件之台北橋觀測值與即時預報水位關係

五、預報結果與討論

本文以象神(2000)、巴比侖(2000)、溫妮(1997)及寶莉(1992)等四場颱洪的新海橋、中正橋、河口之水位觀測值為邊界條件，進行台北橋水位的即時預報、第 1 小時預報、第 2 小時預報與第 3 小時預報，以探討 ANFIS 模式之實用性(颱洪事件之分組詳見表 1)。

首先，本文將台北橋於四場颱洪事件的即時預報、第 1 小時預報、第 2 小時預報和第 3 小時預報之預報水位與觀測水位繪製如圖 8 所示，並將其確定係數(coefficient of determination, R^2)之結果列於圖中。一般而言，若預報水位愈接近於觀測水位，則資料點將會愈接近於圖中之 45

度實線，其確定係數將會接近於 1.0。由結果顯示 ANFIS 模式在即時預報及預報第 1 小時的水位較接近於 45 度實線，其 R^2 分別為 0.963 和 0.924。但在預報第 2 小時時，因為洪水波傳遞的因素而使得此時的 R^2 降低至 0.685，部份預報值偏離了 45 度實線，而在預報第 3 小時的水位分佈則是偏離 45 度實線，此時的 R^2 為偏低的 0.383，由此可以明顯的發現若以即時水位預測較長時間的水位將會出現預測的失真及不準確的結果，使得預報值會逐漸的遠離 45 度實線而降低其預報合理性。

圖 9 為台北橋在象神(2000)、巴比侖(2000)、溫妮(1997)及寶莉(1992)等四場颱洪事件的即時預報、預報第 1 小時、第 2 小時及第 3 小時的水

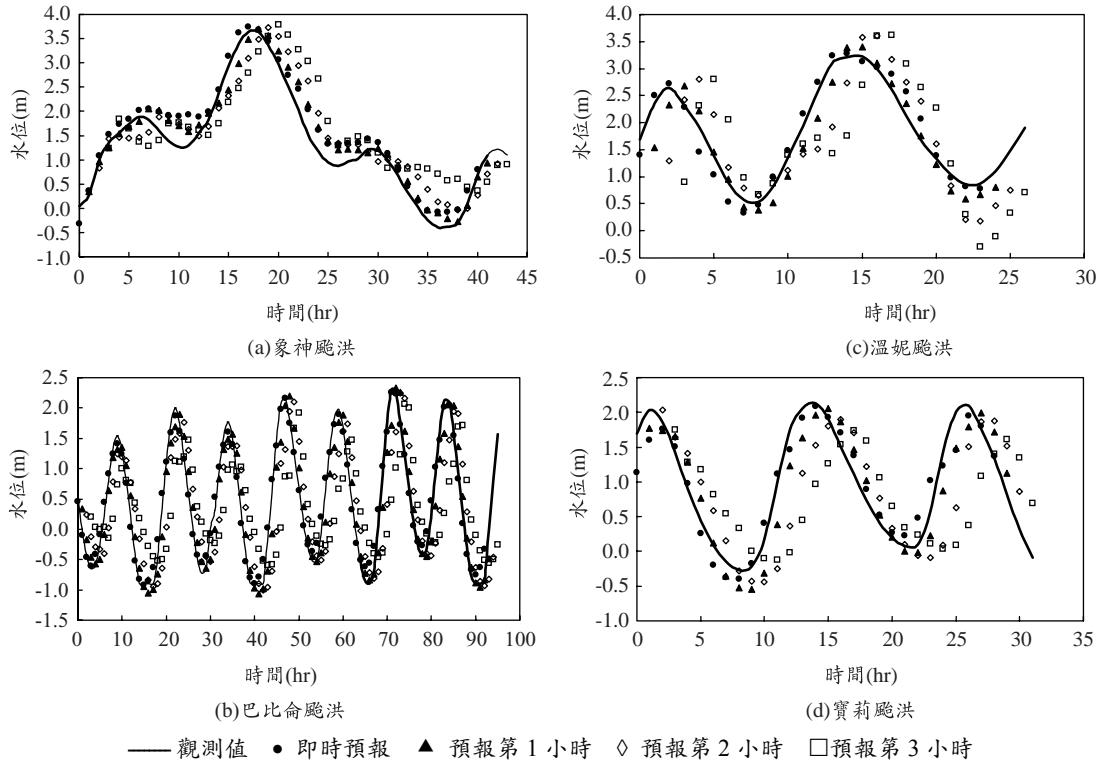


圖 9 各颱洪事件之台北橋水位歷線

表 2 ANFIS 模式各預報時間之 RMSE

颱洪	時間	即時預報	第 1 小時預報	第 2 小時預報	第 3 小時預報
象 神		0.283	0.271	0.457	0.457
巴 比 倫		0.167	0.312	0.694	0.982
溫 妮		0.217	0.313	0.660	0.952
寶 莉		0.240	0.322	0.652	0.918

位歷線。以圖 9(a)象神颱洪的預報水位歷線為例說明，在即時預報及預報第 1 小時的水位歷線較能掌握觀測水位的變化趨勢且較貼近於觀測水位。而預報第 2 小時的預報水位歷線則開始偏離了觀測水位歷線，當預報至第 3 小時時，則可以明顯的發現預報第 3 小時的水位歷線，已有時間平移的偏離觀測水位歷線之現象，尤其是尖峰水位與洪峰時間的稽延狀況更為顯著。

此外，表 2 為四場颱洪事件在各預報時間之預報水位均方差。由表中顯示四場颱洪事件，其水位預報的誤差大約可以維持在即時預報及預

報第 1 小時，之後即隨著時間的增加而遞增。從此水位預報誤差現象，說明了不論颱洪事件的大小，以 ANFIS 模式配合即時觀測水位能夠對即時預報及預報第 1 小時的精度提昇較為有效，在第 2 小時後的洪水預報誤差將會隨著之增加。

由以上的預報結果顯示，ANFIS 模式在即時預報及第 1 小時的水位預報結果較第 2 小時與第 3 小時為佳，分析其原因可能是洪水波在短促的河川中迅速地向下游傳遞，由圖 10 四場颱洪的觀測水位顯示新海橋、中正橋及台北橋的洪峰時間差約 1 個小時左右，此一現象說明由新海橋及

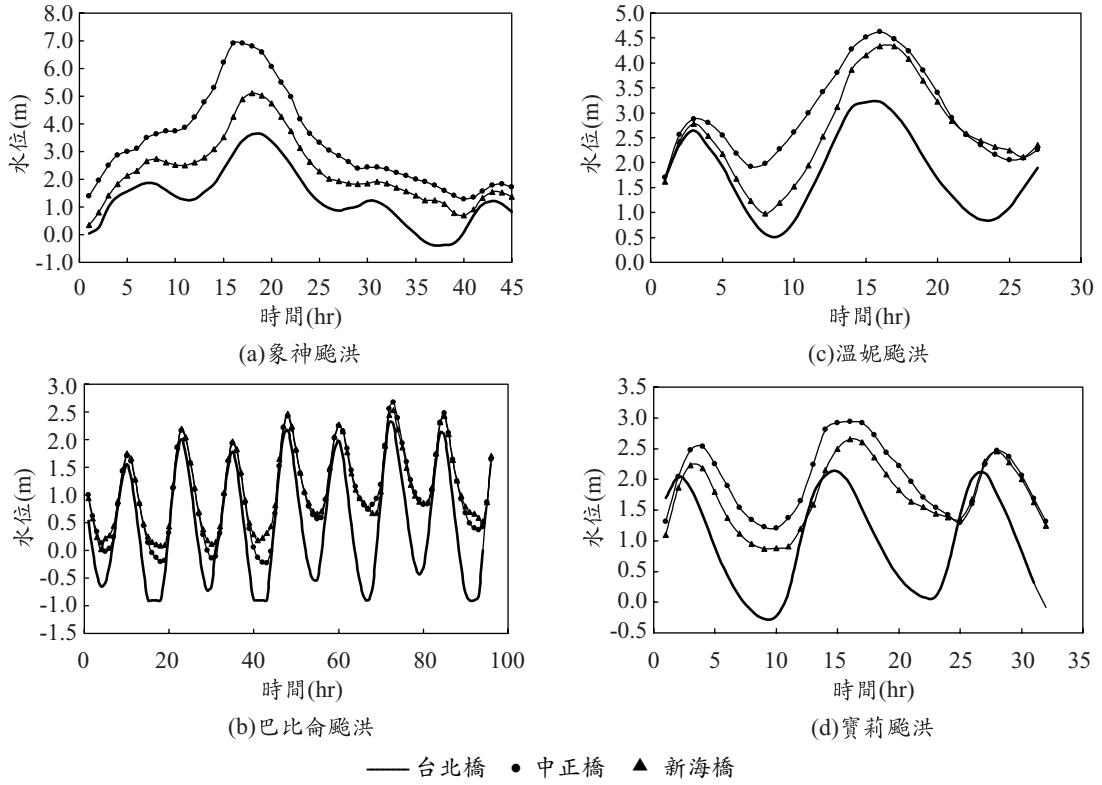


圖 10 各颱洪事件之新海橋、中正橋及台北橋水位歷線

中正橋的洪水波在經過 1 個小時後即已通過了台北橋，故若以即時水位預測超過 1 小時以上之預報水位將會出現預報值時間之稽延，結果不甚理想。

然後本文藉由學習而能夠處理輸入與輸出間之非線性映射關係的類神經網路(Artificial Neural Network, ANN)中之倒傳遞網路(Back Propagation Neural Network)方法[25,26,27]，配合 ANFIS 模式以相同的颱洪事件進行訓練，再分別對預報組的四場颱洪進行台北橋水位的即時預報與第 1 小時預報、第 2 小時預報。所謂的倒傳遞類神經網路演算法(Back Propagation)的學習過程，是由正向傳播與負向傳播所組成，在正向傳播過程中，輸入訊息從輸入層經由隱藏層加權運算、透過轉換函數處理後，再傳向輸出層運算輸出，每一層神經元的狀態只影響下一層神經元的狀態。若在輸出層不能得到期望的輸出值時，則轉入反向傳播，將誤差訊號沿原來的連接通路

表 3 ANFIS 與 ANN 模式水位預報之 RMSE 比較表

預報時間 颱洪事件	即時預報		第 1 小時預報	
	ANFIS	ANN	ANFIS	ANN
象 神	0.283	0.296	0.271	0.396
巴 比 倫	0.167	0.215	0.312	0.388
溫 妮	0.217	0.282	0.313	0.320
寶 莉	0.240	0.302	0.322	0.370

返回，透過修改各層神經元的連結加權值與偏權值，期能使誤差函數值達到容忍誤差範圍之內而停止。經由訓練結果顯示，本文以三層網路、隱藏層節點數目 2 個、學習速率 0.001 和慣性因子為 0.80 的類神經網路為最佳。

首先，將 ANFIS 及 ANN[15]模式對四場颱洪的即時預報及第 1 小時預報結果彙整如表 3 所示，由結果顯示 ANFIS 模式在象神、巴比倫、溫妮及寶莉颱洪在即時預報的 RMSE 值分別為 0.283、0.167、0.217 和 0.240，其結果均比 ANN

表 4 ANFIS 與 ANN 模式之洪峰水位、絕對誤差與相對誤差比較

颱洪事件	觀測水位 (m)	即時預報		第1小時預報	
		ANFIS	ANN	ANFIS	ANN
		AE (m) / RE (%)			
象 神	3.63	0.06 / 1.63	0.34 / 9.34	0.08 / 2.07	0.16 / 4.38
巴比倫	2.31	0.04 / 2.08	0.78 / 31.34	0.59 / 24.18	0.67 / 28.87
溫 妮	3.23	0.10 / 2.97	0.16 / 4.83	0.18 / 5.48	0.40 / 12.35
寶 莉	2.13	0.04 / 2.07	0.13 / 6.34	0.17 / 8.028	0.21 / 9.81

模式的 0.296、0.215、0.282 和 0.302 為小。而從四場颱洪的台北橋在第 1 小時水位的預報結果亦顯示 ANFIS 模式的水位預測誤差較 ANN 模式為低，且較接近於觀測值。故經由此結果顯示，ANFIS 模式對於應用於洪水演算具有良好的預測結果。

本文並以颱洪洪峰水位之絕對誤差、相對誤差進行兩模式的模擬結果比較，並將即時與第1小時的水位預報結果彙整如表4所示。

$$AE = \left| \bar{Y}_i - Y_i \right| \quad \dots \dots \dots \quad (12)$$

$$RE = \frac{|\bar{Y}_i - Y_i|}{Y_i} \times 100\% \quad \dots \dots \dots (13)$$

以表 4 中的象神颱洪洪峰水位 3.63 m 為例，ANFIS 模式的即時預報的水位絕對誤差(AE)及相對誤差(RE)分別為 0.06 m 及 1.63%，而第 1 小時的 AE 及 RE 分別為 0.08 m 及 2.07%。至於 ANN 模式即時預報的 AE 及 RE 分別為 0.34 m 及 9.34%，而預報第 1 小時的 AE 及 RE 分別為 0.16 m 及 4.38%。由此結果顯示 ANFIS 模式在預報洪峰到達時間與觀測洪峰到達時間的可信度均較 ANN 模式為高。

六、結論與建議

本文的結果係以新海橋、中正橋、河口之水位觀測值為邊界條件，利用 ANFIS 模式預測台北橋水位，結果顯示以即時預報及第 1 小時預報水位的結果較佳，而第 2 小時與第 3 小時的預報並不理想，分析其原因可能是洪水波在短促的河川中迅速地向下游傳遞，在經過 1 個小時後由新海

橋及中正橋所傳遞的洪水波已通過台北橋而沒有產生影響，故若以即時水位預測較長時間的預報水位將會出現預測值時間稽延及不準確的結果。故若是要達到準確的長時間預報水位，則可能要找到降雨量、時間與水位站的水位的關係後，方能準確地做更長時間的預報。此外本文亦以類神經網路模式的預測結果與 ANFIS 模式進行探討，由結果顯示 ANFIS 模式除了可以應用於洪水預測外，對於預報洪峰到達時間與洪峰值亦有良好的可信度。

參考文獻

- 王如意、易任(1982)，「應用水文學」。
 - 段鏞(1984)，「二重疏洪道完成後淡水河系洪水演算模式之研究」，國立台灣大學土木工程研究所碩士論文。
 - 張斐章、徐國麟(1990)，「利用模糊集理論推估河川流量之研究」，中國農業工程學報，第 36 卷第 4 期，pp 1~12。
 - 陳昶憲、楊朝仲、王益文(1996)，「類神經網路於烏溪流域洪流預報之應用」，中華水土保持學報，第 27 卷第 4 期，pp 267~274。
 - 張斐章、孫建平(1997)，「類神經網路及其應用於降雨-逕流過程之研究」，中國農業工程學報，第 43 卷第 1 期，pp 9~25。
 - 張良正、楊朝仲、陳昶憲(1998)，「模糊理論在洪流預測之應用」，第九屆水利工程研討會論文集，pp I-95~I-104。
 - 張斐章、梁晉銘(1999)，「類神經模糊推論模式在水文系統之研究」，臺灣水利，第 47 卷第 2 期，pp 1~12。

8. 陳昶憲、黃尹龍、吳青俊、蔡曜隆(2001),「應用倒傳遞與反傳遞神經網路模式於洪流量之預測」,臺灣水利,第 49 卷第 3 期,pp 65~77。
9. 廖宏彬、蘇仲鵬、吳慧敏(2001),「ANFIS 理論應用於教師人力需求預測模式之建構」,教育與心理研究,第 24 卷第 1 期,pp 1~17。
10. 藍武王、葉信宏(2001),「不同冒險度駕駛人之跟車行爲:適應性類神經模糊推論系統」,中國土木水利工程學刊,第 13 卷第 2 期,pp 427~434。
11. 王文俊(2002),「認識 Fuzzy」,全華科技圖書公司。
12. 謝維廷(2003),「禪定腦電波頻帶判讀系統設計」,交通大學電機與控制工程研究所碩士論文。
13. 李宜達(2003),「控制系統設計與模擬」,全華科技圖書公司。
14. 葉怡成(2003),「類神經網路模式應用與實作」,儒林圖書公司。
15. 傅金城(2003),「即時回饋演算之河川洪水預報模式」,國立臺灣大學生物環境系統工程學研究所博士論文。
16. McCulloch & Pitts (1943), "Logical Calculus of Ideas Immanent in Nervous Activity", Bulletin Mathematical Biophysics 5, pp. 115~133.
17. Zedach, L. A. (1965), "Fuzzy sets", Inform. And Contr., Vol. 8., pp. 338~353.
18. Minsky, M. L. and Papert, S. S. (1969), "Perceptrons", MIT Press., Cambridge, MA.
19. Werbos, P. (1974), "New tools for prediction and analysis in the behavioral science", PHD Thesis, Harvard University.
20. Parker, D. B. (1982), "Learning logic", Technical Report TR47, Center for Computational Research in Economics and Management Science, MIT, Cambridge, MA.
21. Takagi, T. and Sugeno, M. (1983), "Derivation of fuzzy control rules from human operator's control action", in Proc. IFAC Symp. Fuzzy Information, Knowledge Representation and Decision Analysis, pp. 55~62.
22. Rumelhart, D. E., Hinton, G. E., 1986. "Learning representations by back-propagation error", Nature, Vol. 323, pp. 533-536.
23. Robert, Hecht-Nielsen, R. (1987), "Counter-propagation networks", ICNN-87, II, pp. 19-32.
24. Jang, J. S. R. (1993) "ANFIS: Adaptive – Network – Based Fuzzy Inference System", IEEE Transactions on Systems, Man. and Cybernetics, Vol. 23, No. 3, pp. 665~685.
25. Simon, H., 1999. "Neural network: a comprehensive foundation", Second Edition. Prentice Hall.
26. Marier, H. R., and Dandy, G. C., 2000. "Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and application", Environmental Modeling and Software, Vol. 15, pp. 101-124.
27. Lu, Y. H., Yeh, F. H., Li, C. L., Wu M. T. and Lin C., (2003) "Study of ductile fracture and perform design of upsetting process using adaptive network fuzzy inference system", Journal of materials, Vol. 140, pp. 576~582.

收稿日期：民國 93 年 5 月 18 日

修正日期：民國 93 年 7 月 20 日

接受日期：民國 93 年 7 月 30 日