

類神經網路及其應用於降雨—逕流過程之研究

A Study of the Artificial Neural Network for Rainfall-Runoff Process

臺灣大學農工所教授兼水工所主任

張斐章

Fi-John Chang

臺灣大學農工所碩士

孫建平

Jian-Ping Suen

摘要

類神經網路(ANN)為人們在研究生物腦的過程中發現生物腦的特性，並將此特性運用至現代的科技，進而發展出對非線性系統能夠自我學習、架構的網路。由於其具有柔性結構與組織簡潔之特性，並且學習精度高、回憶速度快，輸出值亦可為連續值，可解決複雜映射之問題；藉此特性，對水文事件中所具有之高度不確定、不均勻及隨機等特質提供一新的方法做分析研究，初步結果令人滿意。

本研究所使用的倒傳遞類神經網路演算法(BP演算法)為一具輸入、隱藏及輸出之三層神經網路；將其應用於降雨—逕流過程之模擬與預測，並探討降雨—逕流過程中前期輸入個數對訓練與預測之影響；其結果顯示：類神經網路具有學習描述如水文事件複雜關係之能力，並於預測時獲致良好的成效。

關鍵詞：類神經網路，非線性系統，降雨—逕流過程。

ABSTRACT

With the improvement of science, the characters of biological brains were investigated and implemented to modern technology. The artificial neural network (ANN) has been developed through the conceptual of biological brain characters and shown to be capable of self-organization and self-learning to describe non-linear systems. Due to the flexible structure and simplex organization of the ANN, it could approximately simulate any complex continuous input-output mapping. Consequently, the method is used to investigate the hydrological events which have the characters of highly uncertainty, non-uniform, and randomness.

In this study, the back-propagation neural network with three learning network layers, i.e. input, hidden, and output, is utilized to forecast the hourly rainfall and to simulate the rainfall-runoff process. Meanwhile the effect of input number of the rainfall-runoff process is also investigate. The results indicate that the neural network is capable to describe the complex hydrological events and has great forecasting efficiency.

Keywords : ANN, Non-linear system, Rainfall-runoff process.

一、前 言

現今的數位電腦已發展出可以迅速且正確地執行算術及邏輯運算之能力，但對於像是分辨各種含糊難辨的聲音、手寫的文字等對生物腦而言是輕而易舉的事，數位電腦則有待加強；因此我們嘗試模擬生物腦的特性，運用現代的科技發展出所謂的類神經網路(ANN, Artificial Neural Network)，試著來處理以往數位電腦無法有效解決的一些問題。而本文所使用的類神經網路架構為倒傳遞類神經網路(Back Propagation Neural Network)。

倒傳遞類神經網路是把一組樣本的 I/O 問題變成一個非線性最佳化的問題，使用了最佳化中最普遍的最陡坡降法，藉疊代運算的方式求解最佳值，並加入隱藏層處理單元，使得可調參數增加，從而可得到更精確的解。且倒傳遞類神經網路學習精度高、回憶速度快，輸出值亦可為連續值，可處理複雜的樣本識別問題與高度非線性的函數合成問題，其適用於樣本識別、分類問題、函數合成、適應控制、雜訊過濾、資料壓縮、專家系統等應用。

集水區之降雨—逕流過程，其受到集水區內之臨前條件、人為開發、地文因子及暴雨集水區內時間之變化、空間分佈不均勻性所影響，致使整個過程更為複雜。本文將介紹倒傳遞類神經網路演算法及其在降雨—逕流過程之研究，並與同為前向式類神經網路之 GMDH 演算法(Group Method of Data Handling)結果作比較。以探討類神經網路於解決複雜映射關係之能力。

二、理論分析

(一) 類神經網路簡介

神經網路這個名詞，在神經生理學、神經解剖學的範疇內，指的是生物神經網路(Biological Neural Network，簡稱 BNN)，在訊息處理、電腦科學等領域內，指的則是向生命學習而構造的類神經網路或稱人工神經網路(Artificial Neural network，簡稱 ANN)；基本上類神經網路是一種來自生物結構的靈感，因此它是模仿生物神經網路的資訊處理系統運作，並希望其能達到生物腦的工作特性，有效地處理欲解決之問題。

類神經網路定義

在近代科學技術的發展過程中，人們透過生物模仿學習的方法，獲取很多的科學技術概念；同樣地，向生物神經網路(BNN)學習的類神經網路(ANN)，也是在瞭解生物神經網路的結構、機制和功能的基礎上，學習和實現那些人們所需要的智慧。而類神經網路較精確的定義為：[5]

「類神經網路是一種計算系統，包括軟體與硬體，它使用大量簡單的相連人工神經元來模仿生物神經網路的能力。人工神經元是生物神經元的簡單模擬，它從外界環境或其它神經元取得資訊，並以簡單的運算程序後輸出其結果到外界或其它神經元。」

網路基本架構

類神經網路則是由許多的人工神經細胞(artificial neuron)所組成，用此來模擬生物神經網路；人工神經細胞又稱人工神經元、處理單元(processing element)，一般可用輸入值的加權乘積和之函數 $Y=f(\sum_i w_i x_i - \theta)$ 來表示。

網路特性

由於類神經網路是類似生物腦神經系統以大量神經元連成網路的形式工作，所產生的連接機制呈現下面幾種特徵：(1)處理訊號的高度平行性(巨量平行)；(2)訊息處理與訊息儲存合而為一；(3)能接受和處理類比的、模糊的和隨機的訊號；(4)求滿意而不是求精確解；(5)具有自我組織、自我學習的能力。

根據以上神經網路的特性，可以發現神經網路由輸入—輸出資料所建立的網路模型可用於處理許多傳統方法無法有效解決的問題，如樣本識別、自我學習等問題。本文乃嘗試以神經網路來分析降雨—逕流過程，期能得到較好之結果。

(二) 倒傳遞類神經網路(BP)

倒傳遞類神經網路演算法，簡稱為 BP(Back Propagation) 演算法，是屬於多層前授網路所使用的一種監督式學習法，常用於處理輸入輸出間之非線性映射關係。由於早期 Rosenblatt(1958) 發展之認知器(Perceptron)[10] 僅為兩層網路，無隱藏層之存在，無法解決許多問題，使得倒傳遞類神經

網路之發展有了很長的一段停滯期，1982年由Rumelhart、McClelland和他們同事成立一個PDP(Parallel Distributed Processing)小組[17]，研究平行分散式訊息處理方法，探索人類認知的微結構，並於1986年提出了著名的BP學習法[18]，實現了多層網路的構想。

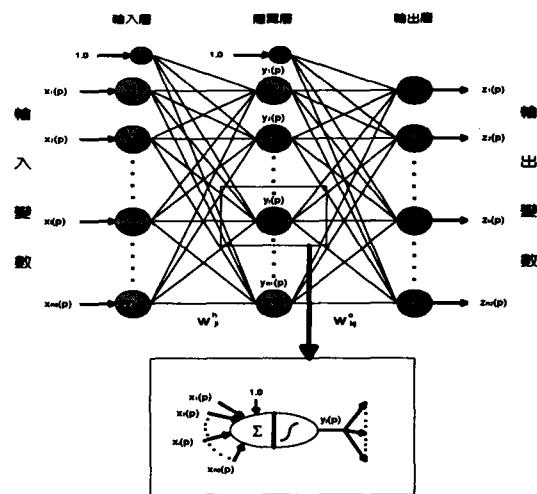


圖 1. 倒傳遞類神經網路架構圖

網路架構

倒傳遞類神經網路為含輸入層、隱藏層及輸出層結構之神經網路。其中輸入層與輸出層分別用以表現輸入及輸出變數，其單元數目依問題的型式而定；隱藏層則用以表現輸入處理單元間之交互影響，其往往需以試驗的方式決定其最佳單元數目。倒傳遞類神經網路架構如圖1所示。

基本原理

網路中靠相關權重連結各層間之單元，各輸入單元輸入值經由加權累加後到達隱藏層，並透過轉換函數可得一值，同理再傳至輸出層。其中常使用的轉換函數型式如(式1)，由於轉換函數為一平滑曲線，故可以微分，使得我們可以利用最陡坡降法(Gradient Steepest Descent Method)之觀念，在學習中改變權重與偏權值，使誤差函數之值逐次減小，達到學習之目的。

$$f(x) = \frac{1}{1 + \exp(-w(x - \theta))} \quad (1)$$

BP演算法的學習過程，是由正向傳播與負向傳播所組成(如圖2)，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

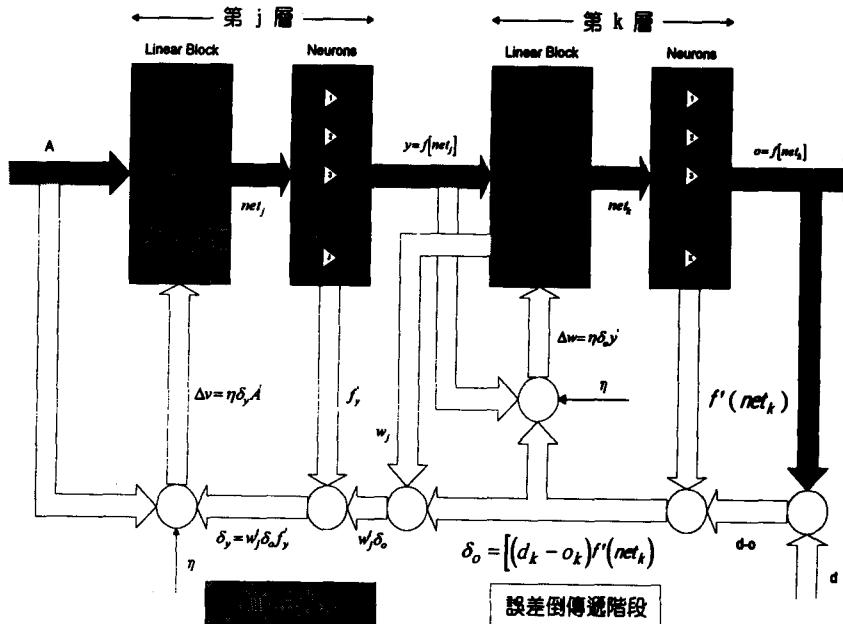


圖 2. BP 演算法之正向傳播與負向傳播圖

不能得到期望的輸出，則轉入反向傳播，將誤差訊號沿原來的連接通路返回，透過修改各層神經元的權重與偏權值，期能使誤差函數達到容忍誤差範圍之內而停止。以下就權重與偏權值修改之公式作一說明：

在倒傳遞類神經網路中，第 n 層的第 j 個單元輸入值為第 n - 1 層單元輸出值的非線性函數：

$$A_j^n = f(ne_{j^n}) \quad (2)$$

$$\text{其中 } ne_{j^n} = \text{集成函數} = \sum_i W_{ji} A_i^{n-1} - \theta_j \quad (3)$$

f = 轉換函數 (Transfer Function)

由於倒傳遞類神經網路屬監督式學習，其學習的目的在降低網路輸出單元中，目標輸出值與推論輸出值之差距，給定一能量函數（或稱誤差函數）表示學習的品質：

$$E = (1/2) \sum_j (T_j - A_j)^2 \quad (4)$$

其中 T_j = 輸出層目標輸出值， A_j = 輸出層推論輸出值

因此網路的學習過程，即為使上述能量函數最小化過程，在此我們以最陡坡降法來使能量函數最小化，即每當輸入一個訓練範例，網路即小幅調整加權值的大小，調整的幅度和誤差函數對加權值的敏感程度成正比，即與誤差函數度對加權值的偏微分值大小成正比：

$$\Delta W_{ji} = -\eta \cdot \frac{\partial E}{\partial W_{ji}} \quad (5)$$

其中 W_{ji} = 介於第 n - 1 層的第 i 個處理單元，與第 n 層的第 j 個處理單元間的連結加權值。

η = 學習速率 (learning rate)，控制每次以最陡坡降法最小誤差函數的步幅。

而 $\frac{\partial E}{\partial W_{ji}}$ 可用微積分學的鏈鎖律 (chain rule) 求得，不論 W_{ji} 處於隱藏層與隱藏層之間，或 W_{ji} 處於輸出層與隱藏層之間，均可寫成通式：

$$\frac{\partial E}{\partial W_{ji}} = -\delta_j^n \cdot A_i^{n-1} \quad (6)$$

其中 $A_i^{n-1} = W_{ji}$ 所連接第 n - 1 層的處理單元值

$\delta_j^n = W_{ji}$ 所連接第 n 層的處理單元之差距量

可得 $\Delta W_{ji} = \eta \cdot \delta_j^n \cdot A_i^{n-1}$ 此式即傳遞演算法之關鍵公式。

BP 演算法之程序

1. 設定網路參數，包含隱藏層數目、各層單元數目、學習速率、容忍誤差等；
2. 以亂數產生初始權重 (weight) 及偏權值 (bias)；
3. 計算隱藏層與輸出層之輸出；
4. 計算誤差值；
5. 計算加權修正量；
6. 調整各層加權值及偏權值；
7. 跳回步驟 3.，重複計算誤差至容忍誤差內或達到預設訓練次數時，網路即停止運算。

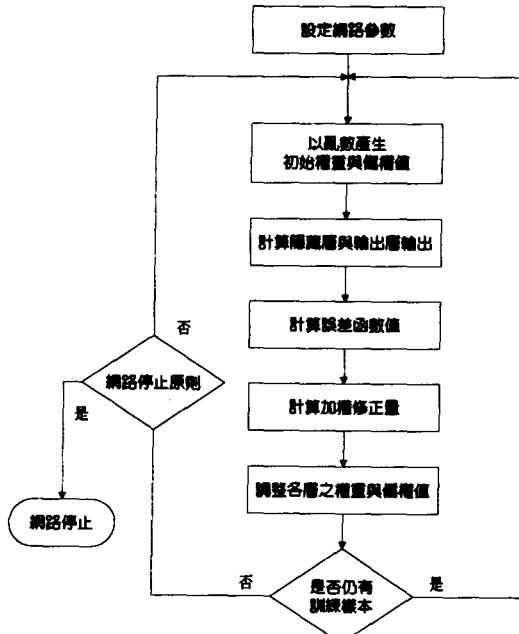


圖 3. BP 演算法運算流程

參數之決定

1. 隱藏層層數：

一般來說，隱藏層的層數通常為一層到兩層時會有較好的收斂性，隱藏層過多則會導致收斂性逐漸減低，且會產生許多的局部最小值，並且當錯誤訊息回傳時，經過隱藏層會有退化的現象，使得收斂時間要更長。另有研究 [25] 指出隱藏層為一層或兩層時在各方面的表現皆類似，唯兩層隱藏層較易落入局部最小值，故吾人撰寫程式時僅考量一層隱藏層，來架構此模式。

2. 隱藏層處理單元數目：

一般而言，隱藏層處理單元數目若過少易導

致無法有效描述問題型態，過多則可能造成過度描述(Over-fitting)而無法有效應用，且會使得收斂速度減慢。致於選取多少處理單元數目並無一定標準，常用的調整隱藏層單元數目的方式有二，其一為網路修剪法[20]，即從一大數目的隱藏層單元數開始訓練，再對網路逐漸修剪，如此會消耗較大量的時間，較不經濟；另一則是網路增長法[21]，即由一小數目的隱藏層單元數開始訓練，再一個一個逐漸增加，直到誤差達容忍範圍而停止。

3.學習速率(η)：

學習速率太大或太小對網路的收斂性質均不利，太小時容易浪費時間，且有可能掉入局部最小值而無法跳出；太小則容易產生振盪網路不易收斂。但學習速率的大小往往需藉不斷的嘗試，依各輸入資料而有所不同，所幸學習速率在相當程度的範圍內均有不錯的收斂性，即於此範圍內，學習的結果對學習速率並不敏感，一般取0.05~1.0皆有不錯的收斂性。

4.輸入資料之處理：

吾人在處理輸入資料時，採Smith[19]的建議，將資料正規化(normalize)至[0.1,0.9]的範圍間，其目的在避免輸出訊號值的飽和(saturation)現象，即避免因轉換函數微分值趨近於零，造成差距量 δ_j 亦趨近於零的現象，使得該處理單元無法有效修正與其相連之連結加權值。

倒傳遞類神經網路之困難

BP網路雖然自我學習能力強，但目前仍有諸多問題無法克服，茲分述如下：

1. BP網路是由許多的隱藏層及神經元所架構而成的，基本上對於不同的問題會有不同的架構；至於何者為優、何者為劣並沒有一定的規則可言，因此使用者必須不斷的試驗，才能找到適合的神經元個數及隱藏層的層數。
2. BP網路包含大量的空間切割，因此在訓練各神經元的權重與偏權值時，通常需要相當長之訓練時間。
3. 就訓練過程而言，由於空間中分佈許多的局部最小值(local minimize)，常使網路落入局部收斂值，無法跳出，使得收斂不完善，而無法達到真正的總體最小值(global minimize)。

為改善訓練情形，一般而言有下列方法：1.慣性項的加入(momentum term)；2.加權值累積式更新(批次學習)；3.自動調整學習速率與慣性因子；4.不同的之轉換函數；5.不同的誤差函數；6.範例重要性因子；7.加一隨機擾動量以跳出局部最小值；8.網路修剪(net pruning)。

(三) GMDH (Group Method of Data Handling)

GMDH演算法為一特殊型式之類神經網路，為比較BP演算法之應用，本文僅做一簡介並摘錄其結果[3]。

GMDH演算法為俄國學者 Ivakhnenko 於1970年所提出多層次輸入一輸出關係之自組性(self-organization)前向式特殊神經網路架構。結構建立的概念與生物進化、優選過程十分相似，其程序即在模擬一般生物的進化過程；如生物在自然競爭中，首先由數量繁多品種中的第一代相互交配而繁衍產生第二代，經由自然環境競爭後(e.g. 對環境的適應能力等)，始能決定有多少比例的第二代可被保留並用於繁衍更新的品種(第三代)，即經由前一代任兩種品種之所有組合中，優選出在標準以上較佳之結果，以作為傳遞下一代(層)繼續競爭之新品種；此一程序重複幾次後(第N代)可得最佳的品種。如上述植物配種之類似程序，GMDH演算法可自行架構衍生組成高階非線性之輸入一輸出函數關係，使吾人能在該系統絲毫無了解之下，由系統可能之輸入經由變數組合、競爭優選過程，層層推展直到最後誤差收斂為止，然後再由最後輸出層之最佳輸出單元往回溯源至最初之輸入層，即自動形成了輸入一輸出間之網路架構，而部份不重要輸入將從網路中被消除。在GMDH之高度非線性系統中，包含了許多不敏感之參數及變數間之高線性相關，其增加系統之複雜性卻未對系統有明顯有效的改善，因此需減少這些參數、變數之出現，而逐步迴歸(stepwise regression)可明顯有效的改善此現象[3]，故本研究採用此一方式，亦即為(SGMDH)。

三、實例操作

(一) 清水溪流域桶頭流量站之降雨—逕流過程建立 資料來源

清水溪為濁水溪上游支流，設有桶頭流量

站，在上游有阿里山和草嶺兩個自記雨量站，其平面位置關係及兩雨量站控制面積權重如圖 4 所示。桶頭流量站為臺灣省水利局所執行「全省主要流量站單位歷線之推求」研究計畫中選定之流量站，其水文資料檔案齊全，故本文擬以此流量站作為研究之對象。

採用分析之洪水事件為民國 59 年至 77 年間之 11 場颱風與暴雨事件，如表 1 所示。其中選定代表集水區的單峰高流量（洪峰流量大於 2500cms）之 1 號洪水事件、單峰普通流量之 2 號洪水事件及多峰流量（具兩個以上之洪峰，且洪峰流量相差在 20% 以內）之 4 號洪水事件等不同流量狀況用來檢定欲架構之 BP 模式，另選出具相似流量狀況之編號 9，3，6 之洪水事件，用以驗證模式，並由驗證所得之結果選出較適切之模式，用以推估預測其餘五場之洪水事件。表 2 所示為洪水事件功用分類表。



$$\text{集水區面積: } A = 259.2 \text{ km}^2$$

$$\text{雨量站權重: 草嶺 } 0.7102$$

$$\text{阿里山 } 0.2898$$

圖 4. 桶頭流量站平面位置關係及雨量站控制面積權重圖 [1]

架構過程

本研究選用檢定三場洪水事件之降雨一逕流資料，於架構本 BP 模式時，設定輸入層節點為 10 個，分別選取前期 5 個小時內之直接逕流量： $Q(t-1)$ 、 $Q(t-2)$ 、 $Q(t-3)$ 、 $Q(t-4)$ 、 $Q(t-5)$ 及前期 5 個小時內之有效雨量： $R(t-1)$ 、 $R(t-2)$ 、 $R(t-3)$ 、 $R(t-4)$ 、 $R(t-5)$ 做為輸入；隱

表 1. 桶頭流量站選用洪水事件一覽表 [1]

編號	名稱	日期	洪峰流量 (CMS)
1	莫安	59年 9/6~9/8	2680
2	艾妮絲	60年 9/18~9/19	1270
3	貝絲	60年 9/22~9/24	1390
4		61年 6/5~6/7	1110
5	莉泰	61年 7/25~7/26	1160
6	鸞瑪	63年 6/18~6/19	1610
7	妮娜	64年 8/3~8/4	3170
8		66年 6/1~6/3	1340
9		69年 8/27~8/28	3400
10		70年 7/22~7/27	1010
11		77年 8/12~8/16	2810

表 2. 各編號洪水事件功用分類表 [3]

事件編號 流分量類	模式進展階段		檢定	驗證	預測
	1	9			
單峰 高流量	1	9			7
單峰 普通流量	2	3			5~8~10
多峰 流量	4	6			11

藏層之層數定為 1 層，節點數於模式中皆定為 5 個；輸出層皆為 1 個節點，故第 t 小時的直接逕流量 Q(t) 如下所示：

$$\begin{aligned} Q(t) &= f(Q(t-5), Q(t-4), \dots, Q(t-1)), \\ R(t-5), R(t-4), \dots, R(t-1) \end{aligned} \quad (7)$$

架構網路參數如下：

隱藏層層數：1 層

隱藏層單元數目：5 個

學習速率：從 0.01 ~ 1.0 皆有使用

慣性因子： α 為 0.95

為比較各場檢定事件訓練之結果，以下三項做為比較標準，其定義分別如下：[3]

1. 效益係數 (coefficient of efficiency)

$$CE = 1 - \frac{\sum (Q_{OBS} - Q_{EST})^2}{\sum (Q_{OBS} - \bar{Q}_{OBS})^2} \times 100 \% \quad (8)$$

式中 Q_{OBS} 為觀測流量

Q_{EST} 為推估流量

\bar{Q}_{OBS} 為觀測流量之平均值

2. 洪峰流量誤差百分比

$$EQ_P = \frac{Q_{P,EST} - Q_{P,OBS}}{Q_{P,OBS}} \times 100 \% \quad (9)$$

式中 $Q_{P,OBS}$ 為觀測洪峰流量

$Q_{P,EST}$ 為推估洪峰流量

3. 洪峰到達時刻誤差：

$$ET_P(hr) = T_{P,EST} - T_{P,OBS} \quad (10)$$

式中 $T_{P,OBS}$ 為觀測值之洪峰到達時刻

$T_{P,EST}$ 為推估值之洪峰到達時刻

訓練過程中，為同時考量驗證三場事件的結果，將三場事件的（1 - 效益係數）與洪峰誤差百分比絕對值相加定為指標值，並以其值做為 BP 網路停止的依據，即當此指標值最小時，讓檢定事件停止訓練，並觀察此時檢定事件的能量函數值改變量是否已達容忍範圍內，若達容忍範圍內，則令此時檢定事件訓練之結果作為本降雨一逕流過程之架構模式。

結果與討論

在嘗試多組不同之初始值後，比較上述指標值，以指標值最小者做為各檢定事件之最終結果，表 3 為三場檢定事件訓練完成後，再推估三場驗證事件之結果。圖 5、圖 6、圖 7 分別為 1、2、4 號洪水之檢定與驗證圖。

由表 3 看出：事件編號為 2 之艾妮絲颱風在效益係數（皆大於 83.5 %）、洪峰誤差百分比（皆小於 14 %）及洪峰到達時刻誤差之整體表現為最佳，其型式為普通單峰流量之事件，可較有效推估驗證之三場洪水事件，故將其定為預測桶頭流量站降雨一逕流過程之檢定洪水事件，並將其參數做為預測桶頭流量站降雨一逕流過程之最終模式，再以此模式預測編號為 5、7、8、10、11 之各洪水事件，表 4 則為檢定事件架構完成後，再推估三場驗證事件及五場預測事件之結果。由表 4 可看出 BP 模式於五場的預測事件中，各場效益係數都高達 90 % 以上，事件編號 10 與 11 之洪水事件更高達 95 % 以上，而洪峰誤差百分比中，事件編號 8、10 與 11 都在 5 % 以內，較大的兩場亦在 16 % 以內，惟洪峰到達時刻皆較觀測值來的晚 1 到 2 小時，整體看來，五場洪水事件的預測結果非常優良。圖 8~12 則分別為以 2 號洪水事件做檢定之 5、7、8、10 及 11 號洪水預測圖。

表 3. BP 演算法對各洪水之模式檢定及驗證表

模式進 展階段	事 件	洪峰誤差 (%)	效益係數 (%)	洪峰時間差 (hr)
檢定	1	-4.18	96.57	-1
	3	0.06	96.01	-2
	6	4.97	82.47	0
驗 證	9	-25.38	80.29	2
	2	-0.96	99.90	0
	3	-3.18	98.15	-1
驗 證	6	3.00	83.96	-1
	9	-13.91	96.22	-4
	4	-4.69	97.01	-1
檢定	3	-0.69	98.74	0
	6	0.00	85.46	-1
	9	-32.92	78.01	-4

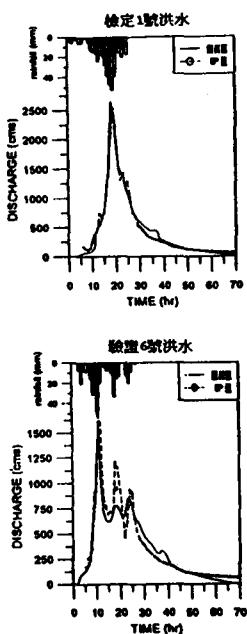


圖 5. 桶頭流量站 BP 模式 1 號洪水之檢定及驗證
圖

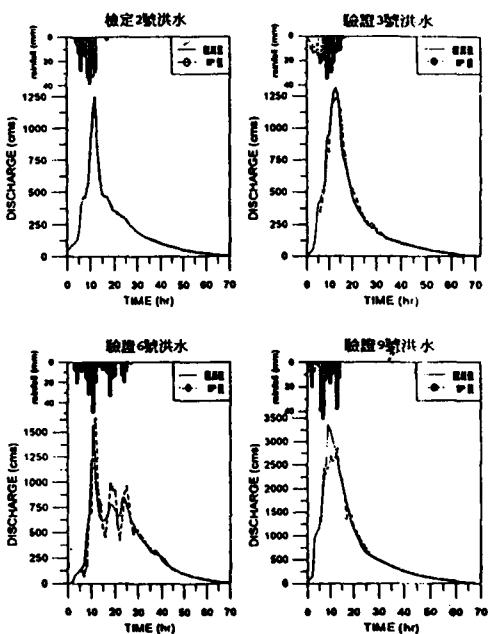
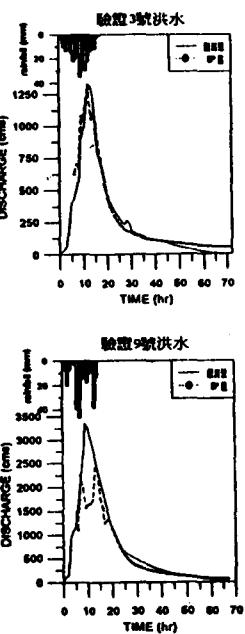


圖 6. 桶頭流量站 BP 模式 2 號洪水之檢定及驗證
圖

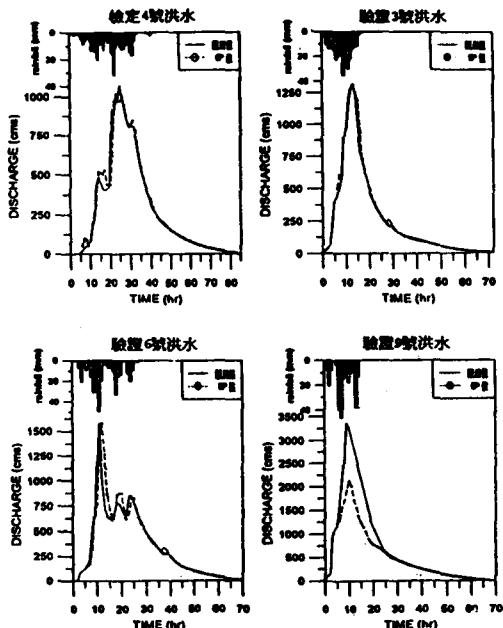


圖 7. 桶頭流量站 BP 模式 4 號洪水之檢定及驗證
圖

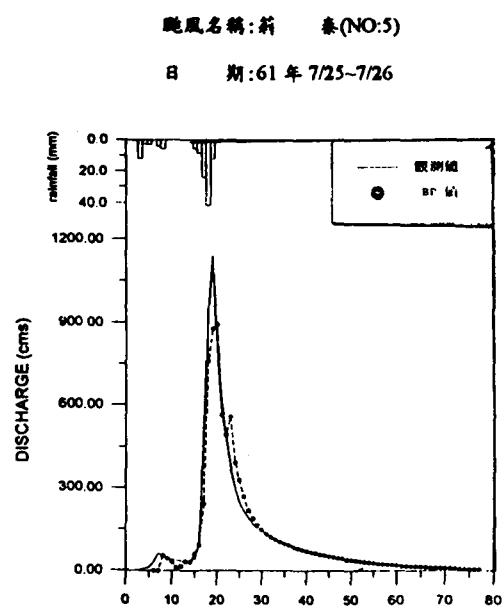


圖 8. 桶頭流量站 BP 模式 5 號洪水預測圖

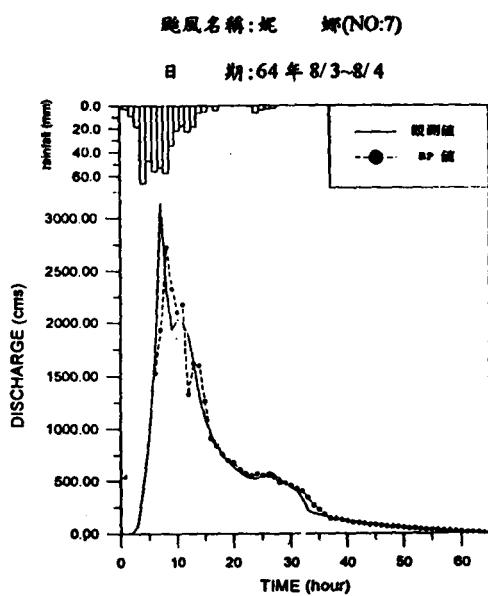


圖 9. 桶頭流量站 BP 模式 7 號洪水預測圖

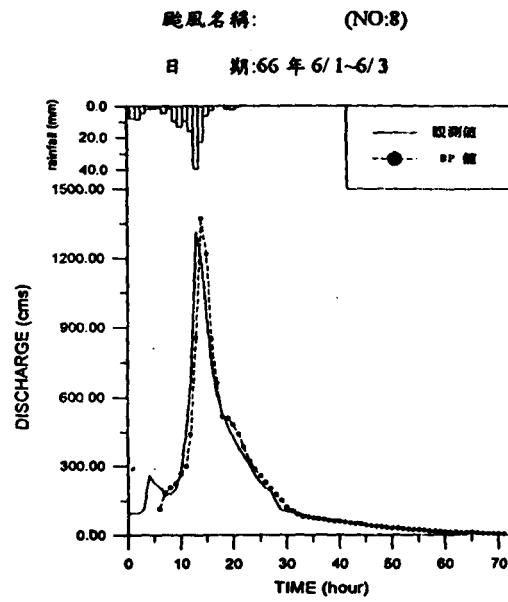


圖 10. 桶頭流量站 BP 模式 8 號洪水預測圖

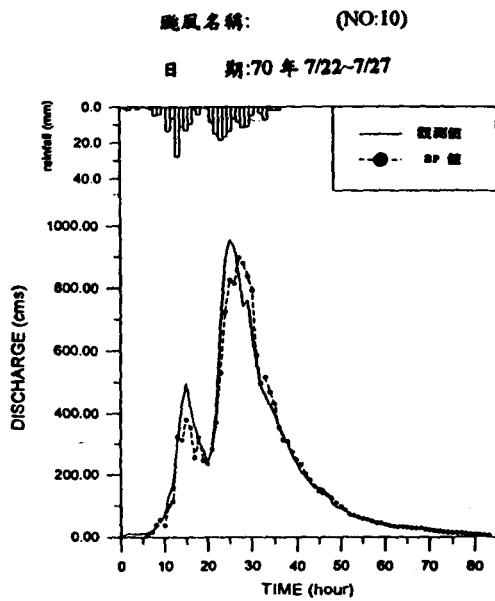


圖 11. 桶頭流量站 BP 模式 10 號洪水預測圖

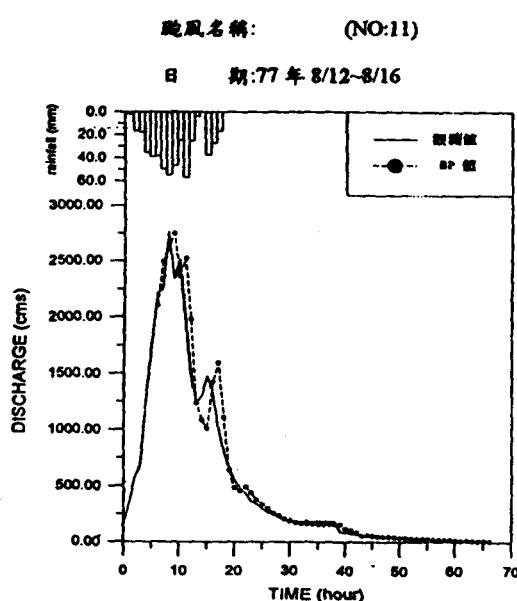


圖 12. 桶頭流量站 BP 模式 11 號洪水預測圖

表 4. BP 系統最終之檢定、驗證及預測表 (Q(t))

模式進 展階段	事 件	洪峰誤差 (%)	效益係數 (%)	洪峰時間差 (hr)
檢定	2	-0.96	99.90	0
驗 證	3	-3.18	98.15	-1
	6	3.00	83.96	-1
	9	-13.91	96.22	-4
預 測	5	-15.65	92.59	-1
	7	-11.95	92.00	-1
	8	3.24	91.22	-1
	10	-4.17	95.92	-2
	11	-0.67	95.14	-1

比較表 3 與表 5 之結果，可看出 BP 演算法所推估求得之效益係數比 SGMDH 法為佳，但 BP 演算法較易出現低估之現象；三檢定洪水事件之洪峰時間差中，兩法相距不大，但在驗證的三場事件中，洪峰到達時刻常較觀測值來的晚，尤其 BP 演算法在第 9 號事件晚 4 小時到達洪峰，差距頗大；再由圖 5、圖 6 及圖 7 看出 BP 訓練值與觀測值往往在峰值時差異較大，且於多峰事件更為明顯。

觀察圖 5 ~ 12 之各 BP 演算法推估值與觀測值的比較中，發現 BP 演算法推估值會較觀測值變動來得大，即在自然現象觀測值中的流量值較平滑，但 BP 演算法推估值會在流量上有明顯起伏轉折之現象，此一現象可能係流量歷線受降雨量影響頗大，即降雨量增加時會立刻反應在流量歷線中。

比較表 4 與表 6，在檢定事件與驗證事件中，BP 演算法求得之值在效益係數方面略佳於 SGMDH 演算法，SGMDH 演算法在驗證事件洪峰推估上有高估的現象，而 BP 演算法則高低估皆有；SGMDH 演算法在洪峰到達時刻表現上較 BP 演算法來得佳。於五場的預測事件中，可看出 BP 演算法的效益係數都高達 90 % 以上，明顯的比 SGMDH 演算法好許多；而洪峰誤差百分比方面，BP 演算法亦較 SGMDH 演算法結果好，但容易產生低估的現象；僅於洪峰到達時刻方面，BP 演算法略差於 SGMDH 演算法之結果。

表 5. SGMDH 法對各洪水之模式檢定及驗證表 [3]

模式進 展階段	事 件	洪峰誤差 (%)	效益係數 (%)	洪峰時間差 (hr)
檢定	1	-0.03	98.28	-1
	3	1.27	93.24	4
	6	48.96	80.64	0
驗 證	9	-32.54	75.82	2
	2	-0.15	99.25	0
	3	8.44	95.05	-1
預 測	6	9.86	83.82	-1
	9	7.20	84.96	0
	4	-0.31	93.09	-2
驗 證	3	-9.43	90.46	-2
	6	-40.02	39.48	-4
	9	-49.27	9.44	-4

表 6. SGMDH 系統最終之檢定、驗證及預測表 (Q(t))[3]

模式進 展階段	事 件	洪峰誤差 (%)	效益係數 (%)	洪峰時間差 (hr)
檢定	2	-0.15	99.25	0
	3	8.44	95.05	-1
	6	9.86	83.82	-1
驗 證	9	7.20	84.96	0
	5	3.49	72.34	-1
	7	-42.91	40.06	0
預 測	8	10.03	86.15	-1
	10	10.86	88.94	-1
	11	-32.52	35.01	1

由各場均方根值、效益係數及洪峰差值結果與洪峰關係圖(圖13)中可看出：均方根值以2號檢定事件為最低，驗證之三場均較同類型洪水之均方根質為低；同為單峰普通流量之3、5、8、10之事件由於2號事件亦為單峰普通流量，均方根質皆相近，另兩組單峰高流量與多峰流量事件均方根值均偏高，且兩組各場之均方根值接近。效益係數方面，除6號因其為多峰流量驗證事件低於85%外，其餘驗證事件與預測事件均高於90%以上，2號檢定事件則更接近100%。洪峰差值部份可看出除6號及8號事件有高估洪峰外，其餘各場多為低估，5號事件為單峰普通流量洪峰差值較大者，單峰高流量之兩事件洪峰差值均高達500 cms左右，可看出以單峰普通流量事件來推估單峰高流量之事件雖在效益係數有不錯之表現，但洪峰量仍不易達到。

(二) 輸入節點數之影響

改變輸入節點數

由於在架構前項模式時，把前期5個小時內之直接逕流量及有效雨量當作10個輸入做為考量，但如黃[3]在架構石門水庫之GMDH預測模式時，10個輸入中僅考量3個流量及2個雨量值，故吾人欲將輸入個數之多寡對均方根收斂值作一研究、討論，並希望能減少輸入個數，以期能在訓練過程中掌握流量增加之歷線上升段資訊，進一步能預測下一小時及下兩小時的流量。

吾人將直接逕流量及有效雨量各0~5個輸入加以組合，可得35種組合方式(兩輸入不可同時為0個)，將此35種組合作為輸入，隱藏層之節點數定為5個，輸出層之節點數則仍為1個，即此小時的流量Q(t)或下一小時及下兩小時的流量Q(t+1)、Q(t+2)。

為做說明，以ANN(n_a, n_b, n_h, n_o)做為各種輸入之表示方式：

其中 n_a 表流量輸入個數 n_b 表雨量輸入個數

n_h 表隱藏層單元個數 n_o 表流量輸出個數

為比較何種組合方式為最佳，吾人以均方根值(RMSE)、AIC(Akaike's information criterion)及BIC(Bayesian information criterion)做為評比考量，AIC及BIC之定義如下：[14,15,29]

$$AIC = m \ln(RMSE) + 2n_{par} \quad (1)$$

$$BIC = m \ln(RMSE) + n_{par} \ln(m) \quad (2)$$

其中m為輸入一輸出資料之組數、n_{par}為各組網路內之參數個數(即權重與偏權值個數和)。一般來說，RMSE值會隨著輸入參數個數之增加而逐漸改善，但會使網路更加複雜，而AIC及BIC值的目的則是要使輸入參數之個數降低，用以減低網路之複雜性。

結果與討論

吾人以編號2之洪水事件作為研究對象，分別做35組輸入組合之輸入，以各組輸出RMSE值作比較，當各網路輸出結果低於吾人給定之容忍範圍時，訓練即告停止；每組以不同初始值求取10次，並去除各組最大及最小RMSE值，確定其標準偏差小於1.5cms，平均後定為達收斂時之RMSE平均值。表7為各網路達收斂時之RMSE平均值。

由表7可以看出：當輸入僅為前期有效雨量時，RMSE收斂值皆大於119cms，加入1個流量輸入值時，可看到RMSE收斂值明顯的下降許多，隨著輸入流量個數的增加，RMSE收斂值隨之漸緩下降。而當輸入若僅有前期之直接逕流量時，RMSE收斂值亦皆大於37，加入前期有效雨量後，其RMSE收斂值隨之亦漸降，但是前期有效雨量個數增加至5個時，有幾組RMSE收斂值反而上升。

表7. 各網路達收斂時之RMSE平均值(單位：
CMS)

RMS E 均 方 根 值	0	1	2	3	4	5
0	187.049	150.467	130.501	124.602	119.914	
1	78.427	27.913	23.237	22.808	17.244	14.816
2	44.702	23.695	25.703	24.090	16.527	15.721
3	41.130	23.328	24.713	15.418	16.256	20.520
4	39.177	21.188	21.143	13.328	14.039	21.827
5	37.949	21.689	22.737	17.465	14.307	14.505

將表7中各網路的RMSE收斂值代入式(1)及式

將表 7 中各網路的 RMSE 收斂值代入式(1)及式(2)中，求出各模式 AIC 及 BIC 之值，而在同時考量 RMSE 收斂值、AIC 及 BIC 值三個因素對網路之影響下，決定採用 ANN(4,4,5,1)、ANN(1,5,5,1) 及 ANN(1,2,5,1) 之組合作為模式架構所需，並與先前之 ANN(5,5,5,1) 做比較，如此可同時考量較低之 RMSE 收斂值及降低結構之複雜性。

表 8 為 $Q(t)$ 模擬值於四模式所求得檢定、驗證

表 8. 四模式最終之檢定、驗證及預測表 ($Q(t)$)

模 式 及 風 雨 事 件 類 別 及 序 號	評 比 標 準	ANN			
		(5,5,5,1)	(4,4,5,1)	(1,5,5,1)	(1,2,5,1)
檢 定	CE (%)	99.90	99.01	96.00	95.62
	EQ_p (%)	-0.96	-4.16	-3.80	-0.04
	ET_p (%)	0	0	0	0
	CE (%)	98.15	96.97	96.56	97.38
	EQ_p (%)	-3.18	2.41	0.69	0.61
	ET_p (%)	-1	0	0	-1
	CE (%)	83.96	85.81	85.89	87.32
	EQ_p (%)	3.00	-0.03	-0.59	0.51
	ET_p (%)	-1	-1	-1	-1
	CE (%)	96.22	95.90	96.60	97.39
	EQ_p (%)	-13.91	-16.45	-13.38	-8.84
	ET_p (%)	-4	-4	-2	-1
驗 證	CE (%)	92.59	93.62	92.01	91.67
	EQ_p (%)	-15.65	-14.60	-12.77	-11.26
	ET_p (%)	-1	0	0	-1
	CE (%)	92.00	89.00	90.44	91.56
	EQ_p (%)	-11.95	-7.24	-5.22	-3.93
	ET_p (%)	-1	-1	-1	-1
	CE (%)	91.22	91.78	90.76	93.63
	EQ_p (%)	3.24	8.13	8.68	3.22
	ET_p (%)	-1	-1	-1	-1
	CE (%)	95.92	95.61	93.72	94.60
	EQ_p (%)	-4.17	-5.92	-5.22	-6.70
	ET_p (%)	-2	-3	0	0
預 測	CE (%)	95.14	92.71	93.90	94.70
	EQ_p (%)	-0.67	0.64	0.34	0.71
	ET_p (%)	-1	-1	-1	-3
	CE (%)	95.14	92.71	93.90	94.70

及預測各事件之結果，由表中可看出；在檢定事件停止訓練時，效益係數以 ANN(5,5,5,1) 為最佳，依次是 ANN(4,4,5,1)、ANN(1,5,5,1)、ANN(1,2,5,1)，即輸入個數較多時，檢定事件效益係數的結果會較好；驗證事件結果較相近，整體來說，ANN(1,2,5,1) 較佳，洪峰誤差百分比較小且洪峰到達時刻較接近；預測之五事件結果亦相近，ANN(1,2,5,1) 之洪峰誤差百分比仍較小一些。圖 14 為四

表 9. 四模式最終之檢定、驗證及預測表 ($Q(t+1)$)

模 式 及 風 雨 事 件 類 別 及 序 號	評 比 標 準	ANN			
		(5,5,5,1)	(4,4,5,1)	(1,5,5,1)	(1,2,5,1)
檢 定	CE (%)	99.24	96.21	96.21	91.65
	EQ_p (%)	-4.81	-7.11	-8.67	-6.39
	ET_p (%)	0	0	1	-1
	CE (%)	93.96	92.13	93.21	92.15
	EQ_p (%)	-10.80	-15.78	-3.60	-9.41
	ET_p (%)	1	-1	1	1
	CE (%)	64.30	71.60	62.39	66.98
	EQ_p (%)	-2.82	-16.46	7.71	0.04
	ET_p (%)	-1	-1	-1	-1
	CE (%)	82.07	74.85	91.01	80.39
	EQ_p (%)	-18.17	-29.59	-15.66	-24.53
	ET_p (%)	-5	-5	-5	-5
驗 證	CE (%)	76.17	80.19	84.77	83.46
	EQ_p (%)	-17.07	-14.10	0.65	-7.29
	ET_p (%)	-1	0	0	0
	CE (%)	75.28	81.34	76.74	83.06
	EQ_p (%)	-35.36	-37.20	-18.22	-27.07
	ET_p (%)	-3	-2	-2	-2
	CE (%)	77.40	78.48	76.20	81.89
	EQ_p (%)	-0.93	-13.69	12.20	-9.88
	ET_p (%)	-2	-2	-2	-1
	CE (%)	88.93	87.52	92.05	89.13
	EQ_p (%)	-2.33	-7.79	-6.64	-11.90
	ET_p (%)	-5	-5	-4	-1
預 測	CE (%)	85.94	84.61	86.97	86.20
	EQ_p (%)	-12.14	-20.65	-12.69	-16.22
	ET_p (%)	1	-2	-2	-4
測 試	CE (%)	85.94	84.61	86.97	86.20
	EQ_p (%)	-12.14	-20.65	-12.69	-16.22
	ET_p (%)	1	-2	-2	-4

模式及 SGMDH 模式觀測值與模擬值的比較圖，由圖中可看出檢定事件以 ANN(5,5,5,1) 結果為最佳，低流量時（小於 250cms）：ANN(5,5,5,1)、ANN(4,4,5,1) 及 SGMDH 三模式模擬值較接近觀測值，ANN(1,5,5,1) 及 ANN(1,2,5,1) 則會有小於約 150cms 時高估、大於 150cms 低估的情形；中流量時則高低估皆有發生，以 ANN(1,2,5,1) 及 SGMDH 差值較大；高流量（大於 1000cms）時則大多為低估。驗證各場的結果較相近，以 SGMDH 偏差較大。預測各場的結果亦較相近，仍以 SGMDH 偏差較大，明顯的在

中高流量時會產生低估。

表 9 為 $Q(t+1)$ 模擬值於四模式所求得檢定、驗證及預測各事件之結果，由表中可看出：在檢定事件停止訓練時有與 $Q(t)$ 模擬值相類似的結果，即效益係數以 ANN(5,5,5,1) 為最佳；驗證三事件中各項比較則互有高低，結果相近；預測之五事件結果則以 ANN(1,2,5,1) 為最佳，效益係數都在 81% 以上，洪峰到達時刻亦較接近。

表 10 為 $Q(t+2)$ 模擬值於四模式所求得檢定、驗證及預測各事件之結果，由表中可看出：

表 10. 四模式最終之檢定、驗證及預測表 ($Q(t+2)$)

模式進 展階段	颱風事 件編號	評比 標準	ANN (5,5,5,1)	ANN (4,4,5,1)	ANN (1,5,5,1)	ANN (1,2,5,1)
檢 定	2	CE (%)	91.29	90.86	95.47	87.29
		EQ_p (%)	-7.56	-6.41	-7.46	-13.80
		ET_p (hr)	0	0	0	1
驗 證	3	CE (%)	87.38	87.47	89.44	87.13
		EQ_p (%)	-18.83	-17.45	-9.86	-8.30
		ET_p (hr)	2	2	-4	0
	6	CE (%)	67.02	65.68	61.76	60.85
		EQ_p (%)	-13.85	-13.58	0.03	-1.07
		ET_p (hr)	-2	-2	-2	-2
	9	CE (%)	56.62	60.01	77.34	64.51
		EQ_p (%)	-38.90	-34.85	-17.01	-31.80
		ET_p (hr)	-6	-6	-6	-6
預 測	5	CE (%)	59.84	59.56	50.80	68.28
		EQ_p (%)	-2.11	-5.66	10.74	-2.54
		ET_p (hr)	-1	-1	-1	-1
	7	CE (%)	70.02	69.83	43.73	64.08
		EQ_p (%)	-40.48	-46.99	-28.35	-40.17
		ET_p (hr)	-2	-7	-7	-3
	8	CE (%)	67.14	67.07	63.97	70.71
		EQ_p (%)	-9.50	-11.30	5.84	-3.61
		ET_p (hr)	-2	-2	-2	-2
	10	CE (%)	82.08	81.19	78.40	83.54
		EQ_p (%)	-15.24	-10.75	0.94	-9.14
		ET_p (hr)	-5	-5	-5	10
	11	CE (%)	72.03	76.15	60.72	71.71
		EQ_p (%)	-37.59	-28.20	-27.71	-26.17
		ET_p (hr)	-3	-3	-9	-5

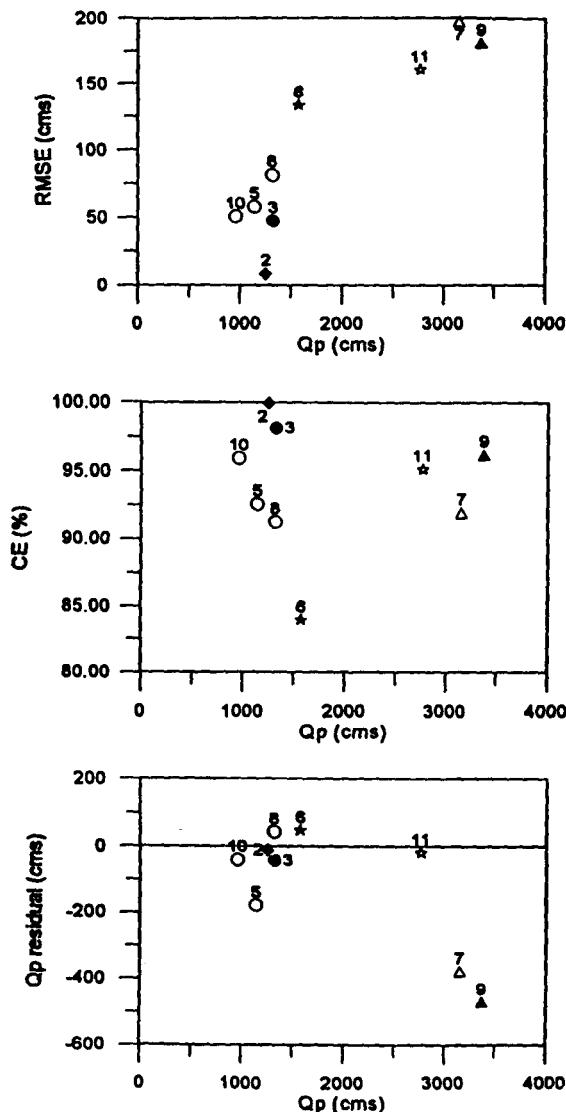


圖 13. 各場結果與洪峰關係。上：均方根值；中：效益係數；下：洪峰差值

ANN(1,5,5,1) 在訓練過程中應有過度描述的現象，因其在檢定事件之結果最好，驗證三事件亦比其它三模式要好一些，但在預測五事件中之結果明顯的較差。而另三模式之檢定事件亦有與 $Q(t)$ 模擬值相類似的結果，即輸入個數較多時，檢定事件效益係數的結果會較好；驗證三事件中各項比較亦互有高低，結果相近；預測之五事件結果仍以 ANN(1,2,5,1) 為最佳，同為單峰普通流量之 5、

8、10 號洪水之效益係數皆在 68 % 以上，其餘二場結果亦不差，其中 10 號事件之洪峰到達時刻相差甚遠，其因可能是降雨延時長達近 40 小時，降雨量不大且有起伏，造成誤差。

就表 8、表 9、表 10 中，四模式的結果以 ANN(1,2,5,1) 為最佳，其在檢定事件中效益係數雖較另三模式為低，但在驗證事件中結果已相近，預測事件之結果普遍較佳，且以 $Q(t+2)$ 模擬值最為明顯；輸入個數減少，於推估 $Q(t+2)$ 可增加上升段之資訊，提高推估之準確性。

四、結論與建議

結論部份

倒傳遞類神經網路可對複雜系統中輸入與輸出之映射關係做一很好之模擬。輸入值經由輸入層、隱藏層到輸出層，透過最陡坡降法之方式調整權重，使輸出值與目標值可漸次逼近，達容忍範圍而停止。唯在運算過程中，有掉入局部最小值之虞，吾人以加入慣性及加權值採累積式更新（批次學習）等方式做改良，並多次嘗試不同之權重初始值，情形已獲改善。

集水區之降雨一逕流過程中，由於資料本身包含了許多之不規則與不確定性，造成模擬與預測上十分困難；BP 演算法則對此一非線性系統提供了一種新的方法來做分析，亦獲得不錯之成果。

在降雨一逕流過程方面，同時考量三場驗證事件來做檢定事件之訓練時，在效益係數及洪峰誤差百分比之比較中，BP 演算法較 GMDH 演算法為佳，惟有易低估洪峰值及洪峰到達時刻會延後之現象。而 BP 演算法在五場的預測事件中皆有不錯之結果。

在探討輸入個數對架構降雨一逕流過程之影響中，檢定事件之效益係數以前期輸入個數較多之模式為較佳，但於驗證事件中，各模式之結果相近，於預測五事件中，前期輸入個數較少之模式則較佳。預測下一小時及下二小時之逕流量時，ANN(1,2,5,1) 模式因增加明顯上升段資訊，對結果較有助益，唯愈後期逕流效益係數之呈現較差且洪峰值明顯低估，需再收集更多資訊才能改

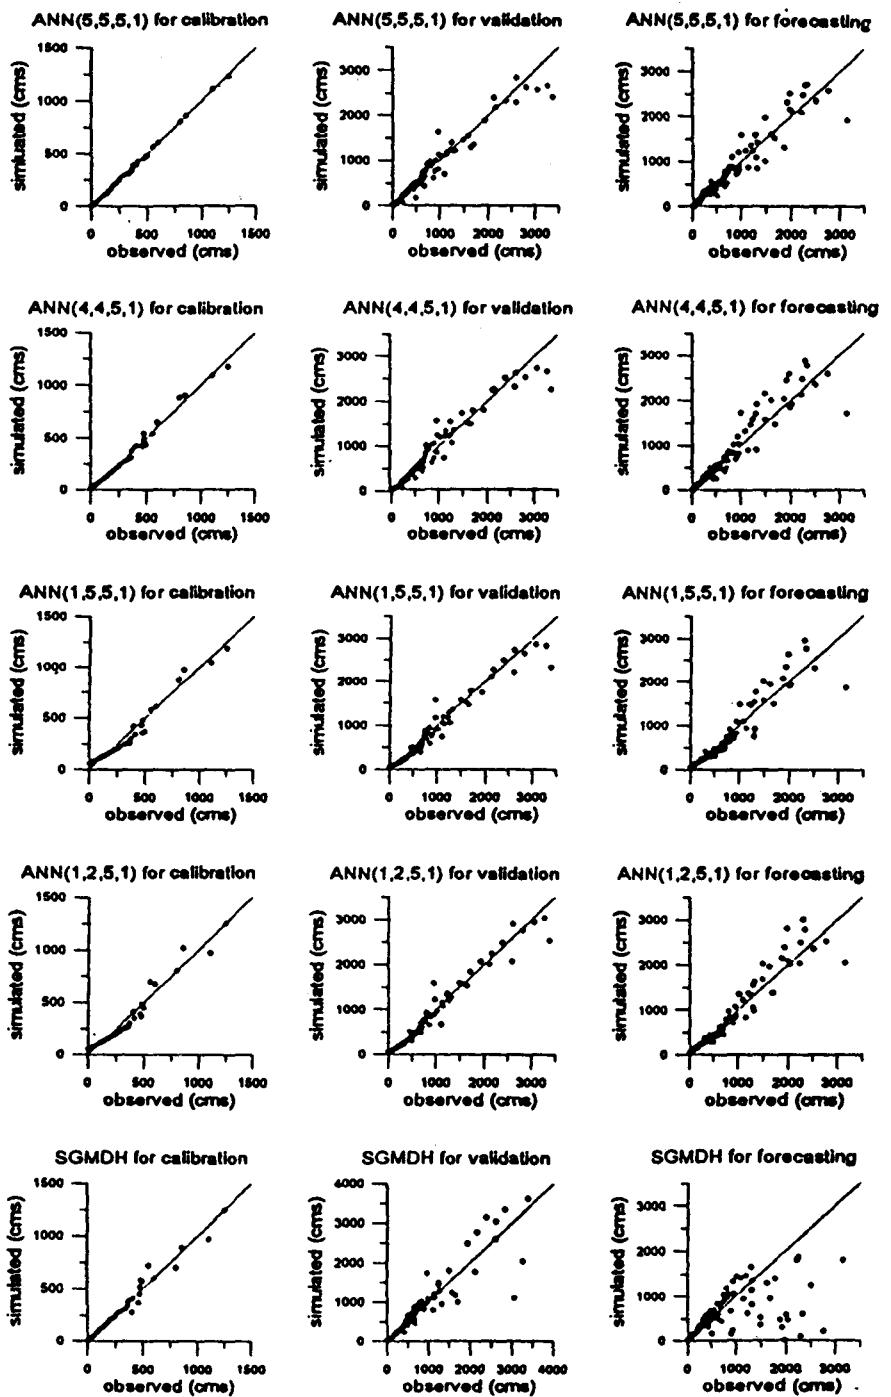


圖 14. 各模式觀測值與模擬值比較圖

善推估結果。

建議部份

就網路架構而言：可考量以不同的隱藏層單元數目做比較。因隱藏層單元數目之多寡影響了模式的複雜程度，故可探討隱藏層單元數目為多少時會有較佳之結果。

就降雨—逕流過程而言，洪峰值的低估與洪峰到達時刻之延後，可考量增加不同之輸入因子改善，如雨量站控制面積中心到流量站之距離，或是BP在演算法推估流量值後，在加入修正方式修正，以期獲得更好之推估值。

五、誌謝

本文研究期間，承蒙台大農工所博士班研究生黃源義、梁晉銘于意見提供與文稿撰寫多所協助，特此致謝。

六、參考文獻

中文部份

- 1.臺灣省水文資料電腦檔應用之研究—全省主要流量站單位歷線之推求(二)，臺灣省水利局(1991)。
- 2.中國科學技術大學生物醫學工程跨系委員會，神經網路及其應用，儒林圖書有限公司，台北(1992)。
- 3.張斐章、黃源義、徐國麟，「自組性演算法及其應用於降雨—逕流模式建立之研究」，台灣大學農學院研究報告，Vol32, No.4.(1992)
- 4.焦李成，神經網路系統理論，儒林圖書有限公司，台北(1993)。
- 5.葉怡成，類神經網路模式應用與實作，儒林圖書有限公司，台北(1993)。
- 6.遙測技術在淹水預警系統上之應用(3/6)，臺灣省水利局(1994)。
- 7.李心平，「智慧型控制理論於土石流預警系統之研究」，碩士論文，國立台灣大學農業工程研究所，台北(1995)。
- 8.郭勝豐，「神經網路應用於預測高粱產量」，農業工程學報，第41卷第2期，台北(1995)。
- 9.楊道昌、游保彬，「應用雨量機率預報模式於逕流預報之研究」，農業工程研討會論文集，

台北(1995)。

英文部份

10. Rosenblatt, F., "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain", Psych. Rev., Vol.65, pp.386-408(1958)。
11. Nelder, J. A. J. and R. Mead, "A Simplex Method for Function Minimization", Comput. J., Vol.7(4), pp.308-313(1965)。
12. Ivakhnenko A.G., "Heuristic Self-organization in Problem of Engineer Cybernetics", Automatica, Vol.6, pp.207-219(1970)。
13. Ivakhnenko, A.G., "Polynomial Theory of Complex System", IEEE Trans. System, Man, Cybern., Vol.SMC -1, NO.4, pp.364-378(1971)。
14. Akaike, H., "A New Look at the Statistical Model Identification", IEEE Trans. Autom. control, Vol.AC 19, pp.716-723(1974)。
15. Rissanen, J., "Modeling by Short Data Description", Automation, Vol.14, pp.465-471(1978)。
16. Farlow, J.S., "Self-Organizing Methods in Modeling GMDH Type Algorithms", Marcel Dekker, New York. (1984)。
17. McClelland, T.L., and Rumelhart, D.E., "Parallel Distributed Processing", MIT Press and the PDP Research Group, Cambridge(1986)。
18. Rumelhart, D.E., Hinton G.E., and Williams, R.J., "Learning Internal Representation by Error Propagation", Parallel Distributed Processing, Vol.1, pp.318-362(1986)。
19. Robert A. Jacobs, "Increased Rates of Convergence Through Learning Rate Adaptation", Neural Network, Vol.1, pp.295-307(1988)。
20. Karnin, E.D., "A Simple Procedure for Pruning Back-Propagation Neural Network", IEEE Trans. Neural Networks, Vol.1, pp.239-242(1990)。
21. Chang, T. and K.A.S. Abdel-Ghaffer, "A Universal Neural Net with Guaranteed Convergence to Zero System Error", IEEE Trans. Signal Process., Vol.40(12), pp.3022-3031(1992)。
22. Duan, Q., S. Sorooishian, and V.K. Gupta, "Effective

- and Efficient Global Optimization for Conceptual Rainfall-Runoff Models", Water Resour. Res., Vol.28 (4), pp.1015-1031(1992) .
- 23 Hamid Bacha and Walter Meyer, "A Neural Network Architecture for Load forecasting", IJCNN, Vol.2, pp. 442-447(1992) .
- 24 Jacques de Villiers and Etienne Barnard, "Back-Propagation Neural Nets with One and Two Hidden Layers", IEEE Trans. on Neural Network, Vol.4, No.1, pp.136-141(1992) .
- 25 Jacek M. Zurada, "Introduction to Artificial Neural Systems", Info Access Distribution Pte Ltd., Singapore, pp.1-250(1992) .
- 26 Mark N. French, Witold F. Krajewski and Robert R. Cuykendall, "Rainfall Forecasting in Space and Time Using a Neural Network", Journal of Hydrology, Vol. 137, pp.1-31(1992) .
- 27 Van Ooyen and Nienhuis, "Improving the Convergence of the Back-Propagation Algorithm", Neural Network, Vol.5, pp.465-471(1992) .
- 28 Smith, M., "Neural Networks for Statistical Modeling ", Van Norstrand Reinhold, New York(1993) .
- 29 Kuo-lin Hsu, Hoshin Vijai Gupta and Soroosh Sorooshian, "Artificial Neural Network Modeling of the Rainfall-Runoff process", Water Resour. Res., Vol. 31,pp.2517-2530(1995) .

收稿日期：民國 86 年 1 月 9 日

接受日期：民國 86 年 2 月 25 日

 專營土木、水利、建築等工程
義繼營造有限公司

地 址：台南縣永康市中華路 196-16 號 12 樓
 電 話：(06)2750602

 專營土木、水利、建築等工程
寶元營造有限公司

地 址：雲林縣台西鄉山寮村 53 號
 電 話：(05)6982032