

行政院國家科學委員會專題研究計畫 成果報告

輻狀基底函數網路於水文系統之研究(3/3) 研究成果報告(完整版)

計畫類別：個別型
計畫編號：NSC 95-2221-E-002-257-
執行期間：95年08月01日至96年10月31日
執行單位：國立臺灣大學土木工程學系暨研究所

計畫主持人：林國峰

計畫參與人員：博士班研究生-兼任助理：陳儒賢、陳谷榕、吳明璋、黃珮瑜、王宗惇
碩士班研究生-兼任助理：蔡斐毓、許峰源、周揚敬、鄭家豪

報告附件：出席國際會議研究心得報告及發表論文

處理方式：本計畫可公開查詢

中華民國 97 年 02 月 01 日

目錄

目錄.....	I
中文摘要.....	II
英文摘要.....	III
第一章 水庫入流量預測之研究.....	1
1-1 前言.....	1
1-2 文獻回顧.....	1
1-3 研究方法.....	2
1-4 研究區域概述.....	6
1-5 模式建立與應用.....	8
1-6 結論.....	12
第二章 降雨量推估之研究.....	13
2-1 前言.....	13
2-2 研究方法.....	14
2-2-1 輻狀基底函數網路.....	14
2-2-2 IRBFN 模式.....	16
2-3 試驗設計.....	18
2-4 應用例.....	24
2-5 結論與建議.....	25
第三章 地下水位預測之研究.....	27
3-1 前言.....	27
3-2 研究方法.....	29
3-2-1 輻狀基底函數網路.....	29
3-2-2 自組織映射圖網路.....	31
3-3 試驗設計.....	33
3-4 應用例.....	35
3-4-1 研究資料.....	35
3-4-2 ARIMA 模式.....	35
3-4-3 SOM-RBFN 模式.....	38
3-4-4 結果與討論.....	39
3-5 結論與建議.....	40
參考文獻.....	41
計畫成果自評.....	45

中文摘要

本研究計畫為期三年，第一年應用全面監督式訓練法則來建立輻狀基底函數網路 (Radial Basis Function Network, RBFN) 之網路架構，作為流量之預報模式。全面監督式學習於訓練過程中，具有自動決定隱藏層神經元數目及訓練誤差隨著神經元增加而遞減之優點，避免了使用複合式訓練法則時，必須先設定隱藏層神經元個數之困擾。再者，本研究於網路訓練時加入了提早停止之條件，以避免產生網路過度配合 (over-fitting) 現象。最後，將其應用於翡翠水庫集水區之水庫入流量預測上，經由四種評鑑指標計算之結果發現，應用全面監督式訓練法則所建立之 RBFN 對於水庫入流量之預測具有相當良好之效果。由於此模式具有網路建構容易、學習速度快速以及對外在環境能快速適應等優點，因此在實際流量預測上具有相當優勢。

第二年結合輻狀基底函數網路與變異元理論而建立一個空間內插模式，稱之為 IRBFN 模式 (Improved RBFN Model)。首先，以三組不同變異元門檻值及尺度參數之等向性試驗資料加以測試，以驗證此模式內插之精確度，並與克利金法及標準 RBFN 模式之內差結果作比較。測試結果顯示 IRBFN 模式均較其他兩種方法擁有較高之估計準確度，另外，實際雨量內插估計之結果亦顯示，本研究所提出之模式可得到較為準確之內插降雨量。建議可將 IRBFN 模式應用於空間內插估計，因為此模式擁有簡單之網路架構及學習法則，並依據統計特性調節參數等多項優點。

第三年結合自組織映射圖網路 (Self-Organizing Map, SOM) 與 RBFN 於時間序列之預測，此模式稱之為 SOM-RBFN 模式。傳統上，輻狀基底函數網路隱藏層神經元數目及中心點之決定為一個亟待解決之問題。於本研究所提出之模式中，嘗試以 SOM 所得之二維密度圖決定神經元數目及中心點。再者，以三組模擬之時間序列資料測試 SOM-RBFN 模式之預測精確度，並與傳統之 ARIMA 模式比較。由結果發現，此模式較 ARIMA 模式有較佳之預測精確度。最後，以台灣南部地區秀林地下水位站之地下水位資料為應用例，分別以 SOM-RBFN 模式及 ARIMA 模式建立時間預測模式，預測月平均地下水位。結果顯示，SOM-RBFN 模式可準確的預測地下水位。由於 SOM-RBFN 模式擁有簡單之架構及簡易之學習法則，並擁有較佳之預測精確度，因此建議可以此模式於時間序列之預測上。

關鍵詞：類神經網路，流量預測，空間內插，輻狀基底函數網路，半變異元，自組織映射圖網路，時間序列分析

Abstract

This is a three-year project. In the first year, the radial basis function network (RBFN) is used to construct a rainfall-runoff model, and the fully supervised learning algorithm is presented for the parametric estimation of the network. The number of hidden layer neurons can be constructed automatically and the training error decreases with increasing number of neurons. The fully supervised learning algorithm has advantages over the hybrid-learning algorithm that has the trouble of setting up the number of hidden layer neurons. Furthermore, early stopping technique is used to cease training, which can avoid over-fitting during the process of network construction. Finally, the proposed methodology is applied to the Fei-tsui Reservoir watershed to forecast the one-hour-ahead inflow. The result shows that the RBFN can be applied to build the relation of rainfall and runoff successfully.

In the second year, based on the combination of the RBFN and the semivariogram, a spatial interpolation method, named improved RBFN, is proposed. First, the reference surfaces with prescribed semivariograms of different sills and scale parameters are generated in order to evaluate the interpolation accuracy of the proposed method. The proposed method as well as two existing methods (ordinary kriging and standard RBFN) is then used in the restoration of these reference surfaces. Among three interpolation methods, the proposed method has the highest interpolation accuracy regardless of the arrangement of sample points. The proposed method is performing well especially when the variance of the reference surface is large. An application of the proposed method to the estimation of the spatial distribution of rainfall also shows that the proposed method can estimate more precisely as compare to the other two existing methods. The proposed method is recommended as an alternative to the existing methods, because it has a clear principle and a simple structure. In addition, it provides more flexibility adjusted with stochastic property.

In the third year, a time-series forecasting model based on the combination of the self-organizing map (SOM) and the RBFN is proposed. Traditionally the positioning of the radial basis centers is a crucial problem for RBFN. In the proposed model, the SOM is used to construct the two-dimensional feature map from which the number of clusters (i.e. the number of hidden units in the RBFN) can be figured out directly by eyes, and then the radial basis centers can be determined easily. The proposed model is examined using the simulated time series data. The results demonstrate that the proposed RBFN is more competent in modeling and forecasting time series as compared to the ARIMA model. In addition, the proposed model is applied to actual groundwater head data. It is found that the proposed model can forecast more precisely than the ARIMA model. For time series forecasting, the proposed model is recommended as an alternative to the existing method, because it has a simple structure and can produce reasonable forecasts.

Keywords: artificial neural network, flow forecasting, spatial interpolation, semivariogram, radial basis function network; self-organizing map; time series analysis

第一章 水庫入流量預測之研究

1-1 前言

水庫於颱風豪雨期間，能蓄洪以消滅水庫下游地區可能之洪害，惟水庫之入流量過大時，必須進行洩洪操作，而水庫洩洪需考慮水庫本身的安全，以避免水庫下游河川溢淹以及儘可能儲蓄水資源。台灣每年夏秋之颱風頻仍，以近幾年的颱風為例，如瑞伯、象神等，水庫於颱風期間均需進行洩洪操作，若洩洪時間及洩洪量不當，可能危害水庫安全或導致下游河川溢淹。故倘能準確地預報水庫之入流量，將可作為水庫洩洪操作之重要依據。

類神經網路(artificial neural network; 簡稱 ANN)為晚近崛起之控制理論，他是一種模仿生物大腦與神經網路系統所建構出來之資訊處理系統，能夠對於外界輸入之訊號有儲存、學習及回想等一系列動作。由於類神經網路只是針對人腦作簡化之模擬，利用數學的方式建立模式，達到儲存、學習及回想之作用，其行為與統計之方式相當類似，因此可將其視為一種特殊之統計模式。當一個系統之機制複雜或是模式不易建置時，如何掌握此系統之轉換機制便相當重要。而類神經網路的最大優點即是不需事先了解系統之轉換機制，只要經過類神經元之學習訓練即可，且其脫離了依賴統計模型，具有理論簡明、結構單純，並具有快速計算、學習能力及容錯能力等優點。因此近來有許多類神經網路之模型被相繼提出。由於類神經網路之理論簡明、結構單純，可用來模擬物理方程式難以描述之複雜非線性關係，因此被大量應用在水文預測上。然而，倒傳遞類神經網路會有收斂到區域最小值、網路學習速度緩慢以及隱藏層結構不易訂定等缺點。輻狀基底函數網路(radial basis function network; 簡稱 RBFN)因為具有網路建構容易、學習速度快速及對外在環境具有快速之適應性等優點，目前此方法被廣泛應用於影像處理、語音辨識、圖形分類以及通訊系統傳輸等各種領域上，均有相當不錯之成果。而集水區之降雨-逕流關係可視為一極複雜之非線系系統，因此本研究嘗試以RBFN 建立洪水流量之預報模式，並以實際之降雨及逕流資料驗證所建立之模式。

1-2 文獻回顧

在流量預測方面，Zhu and Fujita (1994)利用倒傳遞類神經網路進行洪水小時流量預測，得到不錯的結果。但其輸入處理單元個數之決定為自定的方

式並無一客觀的準則，因此預測的時刻數將會有所限制，且輸入層資料均採歷史值，故模式為一預測應用之雛形。Marina et al. (1999)以及 Komda and Makarand (2000)均曾以倒傳遞類神經網路進行洪水位預測。國內方面，Hsu et al. (1995)利用類神經網路與時間序列建立降雨逕流模式進行流量預測。

RBFN 之概念最早是由 Hardy (1971)所提出，後來 Powell (1987)建立其網路架構，Moody and Darken (1989)則利用 RBFN 解決數學函數對應之問題，Broomhead and Lowe (1988)將其應用於數值逼近或內插之問題上。而後相繼有各種類似之網路結構之 RBFN 相繼被提出。隨著輻狀基底函數網路之快速發展，已有不同之訓練法則用以架構更有效率之輻狀基底函數網路，並利用於具有時間序列相關性之問題上。Mikko et al. (1996)曾以輻狀基底函數網路為基礎，結合自我迴歸(autoregressive)之觀念架構網路，並將之應用於時間序列模式之預測上，證實 RBFN 之準確性遠勝過 Autoregressive model (AR)、Threshold Autoregressive model (TAR) 及倒傳遞多層感知機 (back-propagating multiplayer perceptron, MLP)。

1-3 研究方法

輻狀基底函數網路(RBFN)屬於多層前饋式類神經網路，其輸入層與隱藏層間之神經元完全相互聯結，如圖 1-1 所示。




圖 1-1 RBFN 架構圖

此網路模式具有三個特性：

- (1)僅有三層結構
- (2)輸出層全由線性處理單元組成
- (3)隱藏層轉換函數之激發是由輸入資料與神經元中心之距離決定

RBFN 之主要優點為能將訓練樣本之資訊有系統性的儲存於隱藏層中，只要使用簡單之矩陣運算即可求得網路中之加權值，不需要於訓練階段設定許多參數值。此外，只要適當設定訓練停止條件即可，所以 RBFN 為相當有效率之非線性系統鑑別工具。

假設 RBFN 之結構中，輸入層為具有 I 個輸入變數之資料 X ，將其以向量 $X = [x_1, x_2, \dots, x_I]^T$ 傳輸至隱藏層中之神經元，以輸入向量與各神經元中心之距離作為神經元被激發與否之依據，每一隱藏層神經元之輸出 $h_j, j=1, 2, \dots, J$ 可以轉換函數表之：

$$h_j(x) = \phi(\|x - c_j\|) \quad (1-1)$$

其中， $\phi(\)$ 為反應函數(activation function)。反應函數包含有許多種之型態，如高斯函數(Gaussian function)、邏輯函數、multiquadric function (MQF)、thin-spline function (TSP)及指數函數(exponential function)等。本研究則使用最為普遍之高斯函數為隱藏層神經元之轉移函數，其型式如下所示：

$$\phi_j(x) = \exp\left[-\frac{\|x - c_j\|^2}{2\rho^2}\right] \quad (1-2)$$

其中， x 為測試樣本， c_j 為隱藏層神經元之中心點(center)， ρ 則為高斯函數之寬度值， $\| \ \|$ 為歐基里德範數(Euclidean Norm)。

在輻狀基底函數網路之訓練過程中，只要決定適當之隱藏層神經元之中心點、高斯函數之寬度值及輸出加權值，即可得到一個描述 $f: x \rightarrow y$ 函數映射之網路。就學習法則而言，大致可分為兩類：

1.複合式訓練法則：

Hecht-Nielsen (1987)提出一個結合非監督式學習及監督式學習之網路架構。Musavi et al. (1992)則利用 K-means 群集分析法求得基底函數之中心點及寬度值。

2.全面監督式訓練法則：

Chen et al. (1990) 提出 iterative orthogonal-forward-regression (OFR)的學習法則。Chen et al. (1991) 則提出 orthogonal least squares method (OLS)學習

法則。

上述兩類訓練法則中，複合式訓練法則雖有計算時間較為快速之優點，但由於若使用 K-means 群集分析法計算基底函數之中心點及寬度值，其分群的品質受到初始 seed 值很大之影響，造成分群結果不穩定，甚至可能因為分群數過多，造成群中間無訓練資料之情形發生。此外，對於分群數目該如何決定亦無明確之方法可供參考亦是其一項缺點。至於全面監督式訓練法則，其具有自動決定隱藏層神經元數目及訓練誤差隨著神經元增加而遞減之優點，雖然全面監督式訓練法則於計算所花費之時間較長，但由於流量資料通常並不多，且現今之電腦運算很快速，使得運算時間並不會造成太大之困擾。因此，本研究將嘗試應用全面監督式訓練法則之 RBFN 於洪水流量之預測上。

本研究採用全面監督式訓練法則，是先選定一訓練資料點為隱藏層第一個神經元之中心點並計算其寬度值，隱藏層中第 j 個神經元之寬度值 ρ 可表示如下：

$$\rho = \sqrt{\frac{d_{\max}^2}{j+1}} \quad (1-3)$$

其中， d_{\max} 為在訓練樣本中，輸入向量間之最大距離。計算所有輸入向量對神經元之輻狀基底函數輸出結果，並利用最小平方方法(least squares method) 求出隱藏層與輸出層間之權重值，進而將隱藏層輸出值乘以各個權重值，即可得到輸出層之輸出值，如下所示：

$$y_k = \sum_{j=1}^J w_{jk} \phi_j(x) \quad (1-4)$$

其中， y_k 為輸出層中第 k 個輸出值， w_{jk} 為隱藏層中第 j 個神經元至輸出層中第 k 個輸出值之權重值。當輸出層中之輸出值求得後，進而可推求得輸出值與實際值間之相關係數 r ，相關係數可以下式表示：

$$r = \frac{\sum_{k=1}^K (\hat{y}_k - \mu_{\hat{y}})(y_k - \mu_y)}{\sqrt{\sum_{k=1}^K (\hat{y}_k - \mu_{\hat{y}})^2 (y_k - \mu_y)^2}} \quad (1-5)$$

其中， \hat{y}_k 及 $\mu_{\hat{y}}$ 為輸出層之輸出值及其平均值， y_k 及 μ_y 為輸出層之目標值及其平均值。

當上述之步驟完成後，再選擇其他之訓練資料點當作此神經元中心點，

直到所有資料點都計算過後，逐一比對每筆訓練資料在成為中心點後之相關係數值，選擇具有最大相關係數值之資料點當作 RBFN 之第一個神經元之中心點。再依照前面之步驟，依序增加隱藏層之神經元數目，並分別計算求得各個神經元之中心點及寬度值，直到整個網路架構獲得滿意之相關係數或達到最大設定之神經元數目為止。在此，本研究採用相關係數為神經元中心點之選擇依據，主要是相關係數對於模式之精度較容易掌握及了解。

由於全面監督式訓練法則會自動增加神經元，並依據是否達到設定之相關係數或最大神經元數目而停止訓練。但是往往訓練誤差雖然減少了，但是驗證誤差卻有增加之現象，這是因為 RBFN 之隱藏層神經元數目過多所造成之過度訓練，雖然此時之 RBFN 具有較佳之訓練誤差，但其推廣能力 (generalization) 卻不佳。所謂之推廣能力是指網路對未曾見過之輸入資料能得到良好之輸出結果。此外，在網路之訓練過程中，往往對於網路之精度並無概念，無法定義容許誤差及神經元個數之上下限。基於上述原因，本研究嘗試使用交互驗證 (cross-validation) 之方法，先將所有資料分成訓練資料、驗證資料以及測試資料三部分。其中，以訓練資料建構網路之架構，再以驗證資料求出具有較佳推廣能力之網路，最後以測試資料來測試網路之預測效能，亦即當網路具有較佳之推廣能力時即提早停止網路之訓練。

本研究所採用提早停止訓練之原則是當網路訓練過程中，隨著神經元的增加，若連續有兩個神經元之驗證資料，其所求得之相關係數均小於前一個神經元時，便提早停止網路之訓練。採用連續兩個神經元之驗證相關係數，是為了避免驗證相關係數會有震盪之現象產生。關於 RBFN 之整個訓練流程圖繪製整理於圖 1-2。

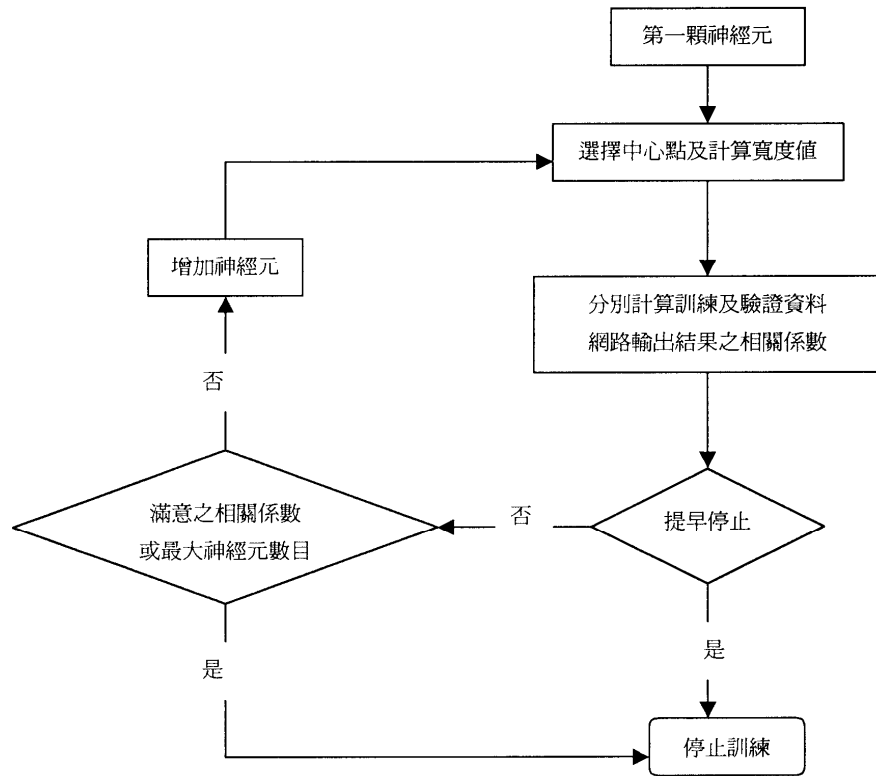


圖 1-2 RBFN 訓練流程圖

1-4 研究區域概述

本研究選擇位於臺灣北部的翡翠水庫集水區，使用在該流域蒐集之雨量及流量資料來作逕流預測。翡翠水庫壩址位於臺北縣新店市，屬於新店溪流域的上游支流北勢溪集水區，是供應大臺北地區民生用水的主要來源且附設七萬瓩發電廠。該集水區面積為 303 平方公里，由大壩至淹沒區上游，主流長度約為 21 公里，沿途有火燒樟溪、後坑子溪、石碇子溪、金瓜溪及魚溪等支流匯入。翡翠水庫集水區中，總共有六個雨量測站，分別是太平站、碧湖站、坪林站、九芎根站、十三股站及翡翠站。圖 1-3 是翡翠水庫集水區的示意圖。

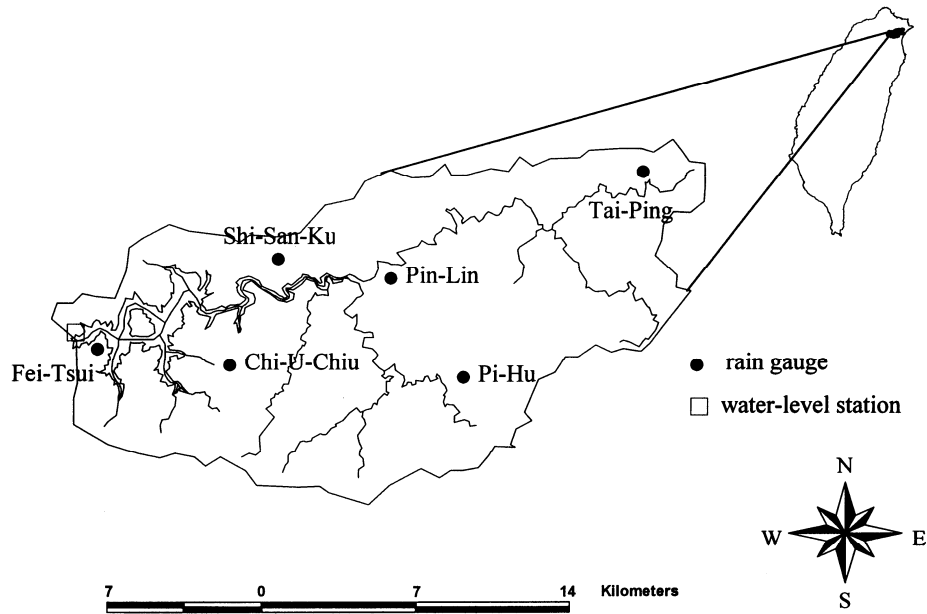


圖 1-3 翡翠水庫集水區示意圖

本研究以颱風事件作為降雨-逕流模擬的對象。本研究共選擇了九場颱風事件之時雨量資料，其中各事件之名稱、發生時間、尖峰流量及類別分別如表 1-1 所示。颱風事件中有三場事件用以檢定模式，另外三場用以驗證模式，其餘三場則做為測試模式之事件。颱風資料長度之決定則是以颱風警報發布至解除之時間為選取原則，經過整理後，總計有 290 筆訓練資料、245 筆驗證資料以及 314 筆測試資料。

表 1-1 颱風事件資料

編號	颱風名稱	發生時間	尖峰流量(m ³ /s)	類別
1	寶莉	1992/08/26	970.43	檢定
2	賀伯	1996/07/30	2586.39	檢定
3	葛拉絲	1994/08/31	1449.33	檢定
4	提姆	1994/07/09	673.61	驗證
5	弗雷特	1994/08/19	718.30	驗證
6	泰德	1992/09/20	922.00	驗證
7	露絲	1991/10/27	828.36	測試
8	席斯	1994/10/08	1456.78	測試
9	道格	1994/08/06	535.83	測試

1-5 模式建立與應用

本研究架構一個具有 21 個輸入值及 1 個輸出值之 RBFN 網路架構，輸入資料為六個雨量站前三小時之降雨資料及翡翠水庫流量站前三小時之入流資料，輸出資料則為翡翠水庫流量站現在之入流量。此外，本研究為了對於流量預報效果之優劣加以評鑑，因此分別採用下列四種評鑑指標判斷優劣：

1. 洪峰流量到達時間之誤差 (Error of Time to Peak, ET_p)

$$ET_p = \hat{T}_p - T_p \quad (1-6)$$

式中， \hat{T}_p ：推估之洪峰流量到達時刻， T_p ：觀測之洪峰流量到達時刻。

2. 洪峰流量誤差百分比 (Error of Peak Discharge, EQ_p)

$$EQ_p = \frac{\hat{Q}_p - Q_p}{Q_p} \times 100\% \quad (1-7)$$

式中， \hat{Q}_p ：推估之尖峰流量， Q_p ：觀測之尖峰流量。

3. 總流量誤差百分比 (Error of Runoff Volume, VER)

$$VER = \frac{\sum_{i=1}^n \hat{Q}_i - \sum_{i=1}^n Q_i}{\sum_{i=1}^n Q_i} \times 100\% \quad (1-8)$$

式中， \hat{Q}_i ：時間 i 之推估流量， Q_i ：時間 i 之觀測流量。

4. 效率係數 (Coefficient of Efficiency, CE)

$$CE = 1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \quad (1-9)$$

式中， \hat{Q}_i ：時間 i 之推估流量， \bar{Q} ：觀測流量之平均值。

本研究先以 290 筆訓練資料及 245 筆驗證資料建立 RBFN 網路架構，其訓練及驗證資料相關係數變化情形繪製於圖 1-4，由圖 1-4 顯示，當隱藏

層有一個神經元時，網路之輸出結果不論對於訓練資料或是驗證資料，其相關係數均高達 0.9 以上，當增加為四個神經元時，則可發現兩者之相關係數增加幅度均已經趨緩，當增加為五個神經元時，驗證資料之相關係數更是呈遞減情形，再增加至第六個神經元時亦呈現相同情形。因此，本研究所使用之網路隱藏層神經元取為 4 個。關於測試資料之估計結果繪於圖 1-5，驗證資料之估計結果則顯示於圖 1-6。此外，對於 314 筆測試資料之估計結果則如圖 1-7 所示。由圖 1-5 至圖 1-7 觀察可知，不論對於何種資料，對於整體之流量趨勢皆有相當不錯之模擬預測結果。




圖 1-4 訓練及驗證資料相關係數變化情形

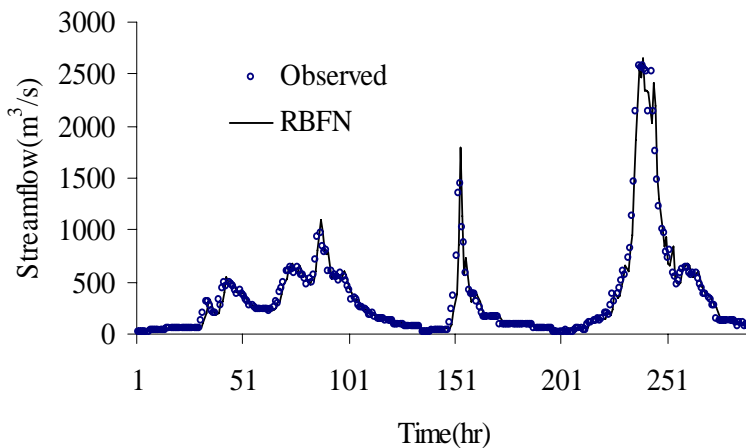


圖 1-5 訓練資料估計結果

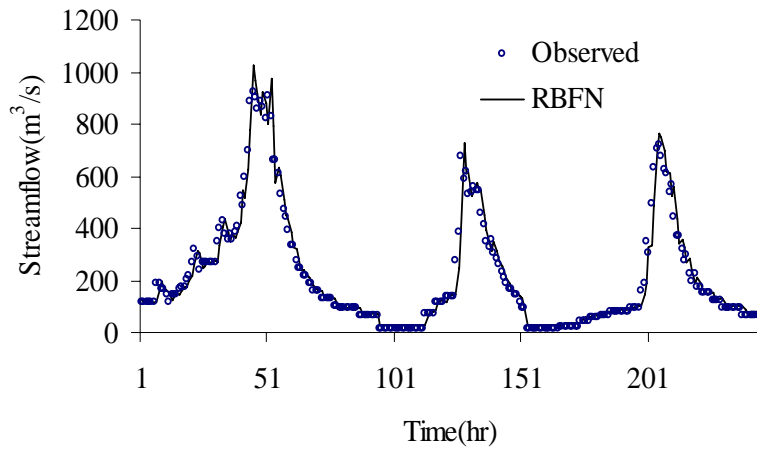


圖 1-6 驗證資料估計結果

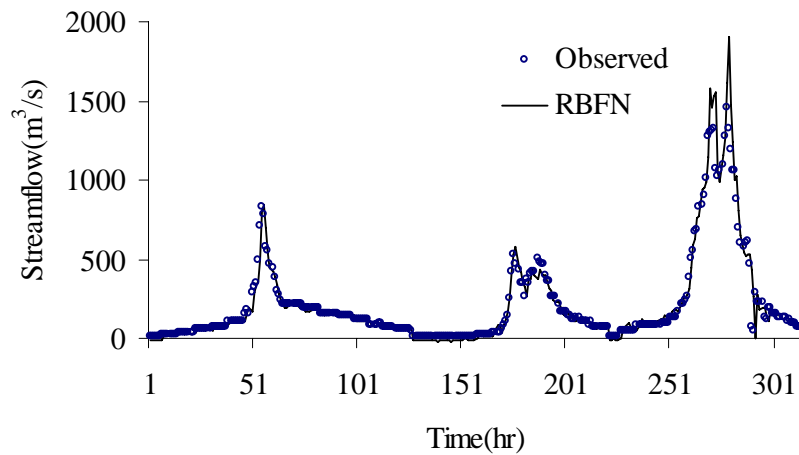


圖 1-7 測試資料估計結果

為了更加精確評鑑流量預報效果之優劣，關於九場颱風事件之四種評鑑指標計算結果整理列於表 1-2。由表 1-2 可得知，對於洪峰流量到達時間之預測上，訓練及驗證資料之預測尚稱良好，但對於測試資料則有延遲現象產生。關於洪峰流量誤差百分比方面，除了席斯颱風外，其餘 8 場颱風事件大約 10% 上下，總流量誤差百分比亦都低於 10%。再者，九場颱風事件之效率係數除席斯颱風外，均高達 0.95 以上，由此可知 RBFN 對於流量之估計上有相當良好之效果。

表 1-2 九場颱風事件之四種評鑑指標計算結果(全面監督式訓練法則)

編號	颱風名稱	評鑑指標			
		ETp (hr)	EQp (%)	VER (%)	CE
1	寶莉	0	13.8	1.8	0.959
2	賀伯	0	2.2	-0.6	0.981
3	葛拉絲	0	13.6	-2.9	0.981
4	提姆	1	8.1	2.6	0.958
5	弗雷特	0	5.9	4.9	0.972
6	泰德	0	11.1	1.4	0.966
7	露絲	1	2.0	-4.9	0.955
8	席斯	1	20.4	8.6	0.940
9	道格	1	7.1	-8.1	0.957

此外，為了比較複合式訓練法則與全面監督式訓練法則所架構網路間之差異，本研究另外建立一個隱藏層具有四個神經元之 RBFN，先以 k-means 群集分析法將資料分群，再分別計算基底函數之中心點及寬度值，最後以最小平方法求出隱藏層與輸出層間之權重值，進而得到輸出層之輸出值。其四種評鑑指標之計算結果列於表 1-3。由表 1-3 可得知，採用複合式訓練法則所架構之網路，對於洪峰流量到達時間之預測上，不論是訓練、驗證或測試資料皆有延遲 1 至 2 小時之情形。至於洪峰流量誤差百分比，大部分之颱風事件都大於 10%，賀伯颱風甚至接近 30%。總流量誤差百分比之結果亦較全面監督式訓練法則所架構之網路為差。此外，九場颱風事件之效率係數除弗雷特及泰德兩場颱風外，其餘均低於 0.90，葛拉絲颱風甚至只有 0.396。由上述之結果可知，不論是何種指標均顯示以複合式訓練法則所架構之網路，其預測之品質均較採用全面監督式訓練法則所架構之網路為差。探究其原因，主要是因為複合式訓練法則所架構之網路，其隱藏層之中心點為各分群之資料點平均值，若一分群之資料點中有一些離群值，則容易造成此神經元中心點之偏離，因而降低了模式整體之精確度，此情形在隱藏層之神經元數目較少時尤其容易發生。

表 1-3 九場颱風事件之四種評鑑指標計算結果(複合式訓練法則)

編號	颱風名稱	評鑑指標			
		ETp (hr)	EQp (%)	VER (%)	CE
1	寶莉	2	9.0	1.4	0.885
2	賀伯	1	29.8	-6.3	0.874
3	葛拉絲	2	19.4	22.0	0.396
4	提姆	1	-14.1	3.4	0.892
5	弗雷特	2	-17.6	-0.4	0.942
6	泰德	2	9.1	3.6	0.908
7	露絲	2	-14.6	0.5	0.870
8	席斯	2	20.9	18.2	0.778
9	道格	1	-7.6	12.3	0.862

1-6 結論

本研究嘗試應用全面監督式訓練法則來建立 RBFN 之網路架構，作為洪水流量之預報模式。將其應用於翡翠水庫集水區之水庫入流量預測，經由四種評鑑指標計算之結果發現，此模式在洪水流量之預測上具可行性。由於全面監督式訓練法則具有自動決定隱藏層神經元數目及訓練誤差隨著神經元增加而遞減之優點，雖然於計算所花費之時間較長，但由於流量資料通常並不多，且現今之電腦運算快速，因此運算時間並不會造成太大之困擾。相對的，複合式訓練法則雖有計算時間較為快速之優點，但其必須先設定隱藏層神經元之個數，且其分群的品質對網路估計之結果會有很大之影響，這些因素均會對網路之建構成造成困擾。為了增進網路之推廣能力並縮短網路之建構時間，本研究嘗試使用交互驗證之方法，先將資料分成訓練、驗證及測試三部分，以訓練資料建構網路之架構，再以驗證資料求出具有較佳推廣能力之網路，最後以測試資料來測試網路之預測效能，亦即當網路具有較佳之推廣能力時即提早停止網路之訓練。比較複合式訓練法則與全面監督式訓練法則所架構網路之估計結果，發現全面監督式訓練法則所架構網路之預測之品質均較採用複合式訓練法則所架構之網路為佳。此乃因為複合式訓練法則所架構之網路，其隱藏層之中心點易受分群資料點中之離群值影響，因而降低了模式整體之精確度。RBFN 因具有網路建構容易、學習速度快速及對外在環境具有快速之適應性等優點，因此在實際之應用上具有相當之優勢。

第二章 降雨量推估之研究.

2-1 前言

空間推估之應用非常廣泛，包括水文、地下水、礦脈、環境地質、大氣污染、環境監測等領域(Chirlin and Dagan, 1980; Bastin et al., 1984; Hill and Alexander, 1989; White et al., 1997; Duc et al., 2000)。其中，克利金(kriging)推估為空間推估之重要方法之一。在克利金推估之過程中，半變異元(semivariogram)扮演了一個極為重要的角色。於克利金系統建構完成前，必須選擇一個適用之半變異元模式，並計算其模式參數。因此，半變異元之計算對於克利金模式之精確度有著極大之影響。亦即若半變異元模式無法正確描述資料之空間結構時，則此模式將無法產生良好之空間估計值。再者，當資料數目眾多時，克利金會有運算速度緩慢之缺點。

類神經網路(artificial neural network)為晚近崛起之控制理論，他是一種模仿生物大腦與神經網路系統所建構出來之資訊處理系統，能夠對於外界輸入之訊號有儲存、學習及回想等一系列動作。由於類神經網路只是針對人腦作簡化之模擬，利用數學的方式建立模式，達到儲存、學習及回想之作用，其行為與統計之方式相當類似，因此可將其視為一種特殊之統計模式。當一個系統之機制複雜或是模式不易建置時，如何掌握此系統之轉換機制便相當重要。而類神經網路的最大優點即是不需事先了解系統之轉換機制，只要經過類神經元之學習訓練即可，且其脫離了依賴統計模型，具有理論簡明、結構單純，並具有快速計算、學習能力及容錯能力等優點。關於類神經網路之架構及學習法則，至今已有許多模式及方法被提出。其中，又以倒傳遞類神經網路(back-propagation neural network)最廣為被熟知及應用。然而，倒傳遞類神經網路於訓練過程中會有許多問題(Wasserman, 1993)。首先，它容易收斂到區域最小值。再者，它即使使用相同之訓練資料，亦會產生出不同之結果。此外，網路學習速度緩慢以及隱藏層結構不易訂定也是其主要缺點。輻狀基底函數網路(radial basis function network; 簡稱RBFN)因為具有網路建構容易、學習速度快及對外在環境具有快速之適應性等優點，因此本研究嘗試以此網路建立空間內插模式。

RBFN之概念最早於1960年代被提出(Aizerman et al., 1964; Bashkirov et al., 1964)。Powell(1987)則首先應用RBFN於實際多變量之內差問題上；Broomhead and Lowe(1988)則將其應用於數值逼近或內插之問題上；Moody and Darken(1989)利用RBFN解決數學函數對應之問題；Poggio and Girosi(1990)以RBFN之理論建立一個新的網路架構；Park and Sandberg(1991)則嘗試以RBFN解決一般之近似問題。近年來，RBFN已經廣泛被應用於各種領域上，例如雷達目標辨識(Zhao and Bao, 1996)、曲線擬合(Xu, 1998)、系

統整合(Sanchez et al., 1998)以及 X 光照片辨識(Tsujii et al., 1999)等。

然而，當 RBFN 應用於空間內插時，於網路架構學習過程中，往往忽略了空間相關性。因此本研究將建立一個結合 RBFN 及半變異元理論之空間內插模式，稱之為 IRBFN 模式 (Improved RBFN Model)。首先，為了驗證此模式內插之精確度，本研究建立了三組不同變異元門檻值及尺度參數之等向性試驗資料加以測試，並與克利金法及標準 RBFN 模式之內差結果作比較。最後，將此模式應用於實際空間降雨量之推估上。

2-2 研究方法

2-2-1 輻狀基底函數網路

輻狀基底函數網路(RBFN)屬於多層前饋式類神經網路，其輸入層與隱藏層間之神經元完全相互聯結，其網路架構如圖 2-1 所示。RBFN 具有三個特性：(1)僅有輸入、隱藏及輸出等三層結構；(2)輸出層完全由線性處理單元所組成；(3)隱藏層轉換函數之激發是由輸入資料與隱藏層神經元中心之距離決定。




圖 2-1 RBFN 架構圖

假設輸入資料 X 為 L 維度之向量， $X = [x_1, x_2, \dots, x_L]^T$ ，而隱藏層神經元之維度與輸入資料相同。以輸入向量與各神經元中心之距離作為神經元被激發與否之依據，第 i 個輸入資料於第 j 個隱藏層神經元之輸出可以轉換函

數表之：

$$\phi_j(z_i) = \phi(\|z_i - c_j\|) \quad j=1, 2, \dots, M \quad (2-1)$$

其中， $\| \cdot \|$ 為歐基里德範數 (Euclidean norm)； c_j 為隱藏層神經元之中心點 (center)； $\phi(\cdot)$ 為反應函數 (activation function)； M 為隱藏層神經元數目。在作空間內插估計時， c_j 可以視為第 j 個觀測點位置，而 $\|x_i - c_j\|$ 則可視為第 j 個觀測點與第 i 個預估計點之距離。

在網路架構中，隱藏層之維度與輸入層相同。至於反應函數之型態包含許多種類，如高斯函數 (Gaussian function)、邏輯函數、multiquadric function(MQF)、thin-spline function(TSP)及指數函數 (exponential function) 等。本研究則使用最為普遍之高斯函數為隱藏層神經元之轉移函數，其型式如下所示：

$$\phi(X) = \exp\left(-\frac{\|X - c_j\|^2}{2\sigma^2}\right) \quad (2-2)$$

其中， σ 為高斯函數之寬度值，可由下式求得：

$$\sigma = \frac{d_{\max}}{\sqrt{2N_h}} \quad (2-3)$$

其中， d_{\max} 為在訓練樣本中，輸入向量間之最大距離。計算所有輸入向量對神經元之輻狀基底函數輸出結果，並利用最小平方法 (least squares method) 求出隱藏層與輸出層間之權重值，進而將隱藏層輸出值乘以各個權重值，即可得到輸出層之輸出值 \hat{y}_r ，如下所示：

$$\hat{y}_r = w_0 + \sum_{q=1}^{N_h} w_{qr} \phi_q(Z) \quad r=1, 2, \dots, N_R \quad (2-4)$$

其中， $\phi_q(Z)$ 為第 q 個隱藏層神經元之輸出值； y_k 為輸出層中第 k 個輸出值；

w_{qr} 為隱藏層中第 q 個神經元至輸出層中第 r 個輸出值之權重值； w_0 為偏差

(bias)； N_R 為輸出值個數。若以矩陣表示，則方程式(2-4)可表為

$$Y = W\Phi \quad (2-5)$$

其中

$$W = \begin{bmatrix} w_{11} & w_{21} & \cdots & w_{M1} \\ w_{12} & w_{22} & \cdots & w_{M2} \\ \cdot & \cdot & \cdot & \cdot \\ w_{1N} & w_{2N} & \cdots & w_{MN} \end{bmatrix} \quad (2-6)$$

$$\Phi = [\phi_1 \quad \phi_2 \quad \cdots \quad \phi_M]^T \quad (2-7)$$

2-2-2 IRBFN 模式

於 RBFN 之架構中，隱藏層神經元之中心點 c 及寬度值 σ 兩個參數需要被決定。傳統上，隱藏層神經元之數目常被假設少於訓練樣本之數目。然而，對於空間推估而言，由於其隱藏層神經元之數目等於已知之測站個數，因此當 RBFN 應用於空間推估時，寬度值便成為一個極為重要之網路參數。寬度值 σ 將決定整個反應函數之平滑度，當 σ 較小時，其所相對涵蓋之區域也較小，所以隱藏層神經元之數目需要增加，然而此方式將有可能造成過度訓練之結果。相反的，當 σ 過大時，其所涵蓋之區域將會過於擴大，造成模式預估之準確度下降。以上兩種情形，均會造成模式衍生能力 (generalization capability) 表現欠佳 (Oukhellou and Akinin, 1999)。

由於方程式(2-3)為一個定率式，所以方程式(2-2)並無統計之性質。然而，空間上之變數於某個範圍內常彼此有些相關性存在。共變異分析 (covariation analysis) 常被用來分析空間資料間之相關性。其中，實驗半變異元 (experimental semivariogram) 是共變異分析時之一個重要工具。實驗半變異元代表資料之空間變異性，並被用來決定克利金法之適當權重值。本研究嘗試結合 RBFN 與變異元理論建立一個新的空間內插模式，稱為 IRBFN 模式 (Improved RBFN Model)，介紹如下：

於 IRBFN 模式中，其反應函數之型態為指數型，如下所示：

$$\phi_j(x) = \exp\left(-\frac{h}{\sigma_j}\right) \quad (2-8)$$

其中， $h = \|x - c_j\|$ ； σ_j 為第 j 個隱藏層神經元之寬度值。必須注意的是，於此模式中，其反應函數之寬度值並不相同，而於方程式(2-2)中之反應函數則擁有相同之寬度值。

指數型之半變異元常被應用於水文之領域上 (Kitanidis, 1993)：

$$C(h) = C(0) \exp\left(-\frac{h}{a}\right) \quad (2-9)$$

其中， $C(0)$ 為變異數 (variance)； a 為尺度參數 (scale parameter)； $C(h)$ 為距離 h 時之共變異函數。所以方程式(2-9)可被寫為

$$\frac{C(h)}{C(0)} = \exp\left(-\frac{h}{a}\right) \quad (2-10)$$

方程式(2-8)及方程式(2-10)有相同之型式，所以當共變異函數已之時，則 σ_j 則會可以被求得。必須注意的是，由上述方式所得之每個隱藏層神經元之寬度值均相同，因為整個空間只有一個共變異數。

在推求共變異數時，必須先知道資料之平均值。但實際上，由資料所求得之平均值往往會有偏差產生。因此，資料樣本之共變異數也會產生偏差且降低空間推估之精確度。為了避免上述問題，半變異元被用以計算隱藏層神經元之寬度值，因為它可以自動過濾掉平均值(Chiles and Delfiner, 1999)。半變異元之型式可表示如下：

$$\gamma(h) = C(0) - C(h) \quad (2-11)$$

將方程式(2-9)代入方程式(2-11)，可得到指數型之半變異元模式：

$$\gamma(h) = C(0)\left[1 - \exp\left(-\frac{h}{a}\right)\right] \quad (2-12)$$

其中， $C(0)$ 稱為門檻值 (sill)，其影響範圍可以 $\alpha \approx 3a$ 表之(Kitanidis, 1993)。方程式(2-8)與方程式(2-12)有相同之型式，所以當指數型半變異元已知時，我們便可由方程式(2-8)求得隱藏層神經元之寬度值。然而，因為只有一個半變異元值，因此對於所有的隱藏層神經元而言均只有一個固定之寬度值。此外，由於半變異元是利用所有資料點所求得，因此它無法顯示空間上小區域之變化情形。為了解決上述之問題，一個決定隱藏層神經元寬度值的方法被提出，簡述如下：

首先，對於第 j 個隱藏層神經元，令影響範圍 α 為鄰近區域 (neighborhood)，然後計算神經元中心點與其鄰近區域內資料點之平均距離 \bar{d}_n ；對於第 j 個神經元鄰近區域，其平均距離之一半 ($\bar{d}_n/2$) 即代表第 j 個神經元之寬度值。其中，有兩種極端情形必須注意，敘述如下：首先，如果鄰近區域小於第 j 個神經元與其最近資料點之距離時 (亦即鄰近區域內無資料點存在)，則令第 j 個隱藏層神經元之寬度值 σ_j 等於第 j 個神經元與其最近資料點距離之一半。再者，若鄰近區域大於資料點間最大距離之一半時，表示這些資料之空間相關性不高，因此令第 j 個隱藏層神經元之寬度值 σ_j 等

於資料點間平均距離之一半。

2-3 試驗設計

三種不同空間變異性之隨機場 (random field) 被用來測試本研究所提模式空間推估之精確性。這些隨機場是由 HYDRO_GEN 程式 (Bellin and Rubin, 1996) 所產生，此方法能快速且正確的產生大維度之隨機場，且優於傳統之 turning bands method 及 fast Fourier transform (Bellin and Rubin, 1996)。

一個隨機場為 10×10 之正方形網格，共計有 100 個網格點。然後隨機選出其中之 25 個網格點上之資料，再利用這些資料計算其餘 75 個網格點上之估計值，最後再計算這 75 個網格點上已知值與估計值間之差距，以評鑑空間推估方法之優劣。關於此三種不同空間變異性之隨機場測試結果敘述如下：

1. 試驗一： $C(0)=1, a=1$

圖 2-2 為利用方程式(2-12)所建立之隨機場，其 $C(0)$ 及 a 之值均為 1，圖 2-3 則是利用圖 2-2 中所有資料點所建立之試驗半變異圖。由圖 2-3 可知，其半變異圖符合預先設定之統計特性 ($C(0)=1, a=1$)。然後，分別從圖 2-2 之 100 個網格點中，隨機選擇 25 個網格點，總計作 10 次試驗。

3.95	3.36	4.04	3.76	2.66	1.47	2.18	2.75	2.42	1.94
3.41	3.99	5.85	4.14	3.03	2.87	3.46	3.10	2.70	2.57
3.45	3.74	4.10	4.40	3.49	3.48	3.14	3.52	3.00	2.79
4.27	4.86	2.88	3.91	3.28	2.81	2.18	2.84	3.01	2.98
4.95	4.57	2.18	3.04	3.40	1.51	3.22	4.23	3.34	4.35
2.50	1.88	2.57	2.78	3.07	1.92	2.63	2.69	2.84	3.13
1.18	1.70	1.90	2.90	1.88	0.80	2.02	1.58	3.02	3.44
2.77	1.26	3.69	3.36	3.01	4.01	1.84	2.26	2.34	3.49
3.44	2.51	4.98	4.46	3.24	4.07	2.61	5.18	3.12	3.10
3.18	3.81	2.58	2.64	4.83	3.87	2.16	1.19	2.24	4.11

圖 2-2 試驗一之隨機場 ($C(0)=1$ 及 $a=1$)




圖 2-3 試驗半變異圖(試驗一)

對於每次之試驗，以均方差（root mean square error, RMSE）為評鑑方法精確度之指標：

$$\text{RMSE} = \sqrt{\frac{1}{N_e} \sum_{p=1}^{N_e} \left[\frac{\hat{Z}_p - Z_p}{Z_p} \right]^2} \quad (2-13)$$

其中， N_e 為估計點之數目； \hat{Z}_p 為第 p 個網格點上之估計值； Z_p 為第 p 個網格點上之實際值。RMSE 最小之內差方法即是最佳之方法。

普通克利金法(Ordinary Kriging; 簡稱 OK)、標準 RBFN 模式(Standard RBFN; 簡稱 SRBFN)及 IRBFN 模式(Improved RBFN Model; 簡稱 IRBFN)等三種空間推估方法分別於 10 次試驗內插估計之 RMSE 值(估計點從圖 2-2 中隨機選取)整理於表 1 中。其中，關於 SRBFN 之網路參數計算是使用方程式(2-2)作為反映函數，並利用方程式(2-3)計算隱藏層神經元之寬度值。由表 2-1 之結果可發現，IRBFN 之 RMSE 值從 0.375 至 0.511，並且有最小之 RMSE 值。平均而言，其值分別比 OK 及 SRBFN 兩種方法降低約 19% 及 20%。對於 10 個試驗結果亦發現，IRBFN 除了有較小之 RMSE 值外，其 RMSE 值之變化亦較其他兩種方法為小，此結果驗證了 IRBFN 之穩定性。

表 2-1 三種方法於 10 次試驗內插估計之 RMSE 值(估計點從圖 2-2 中隨機選取)

Pattern	RMSE		
	IRBFN	OK	SRBFN
1	0.375	0.442	0.405
2	0.423	0.627	0.552
3	0.447	0.479	0.485
4	0.411	0.485	0.663
5	0.451	0.543	0.628
6	0.414	0.483	0.488
7	0.457	0.562	0.482
8	0.427	0.520	0.716
9	0.418	0.615	0.483
10	0.511	0.612	0.549
Mean	0.433	0.537	0.545

2. 試驗二： $C(0)=1, a=2$

變異性 $C(0)$ 等於 1、尺度參數 a 等於 2 之隨機場如圖 2-4 所示，圖 2-5 則是利用圖 2-4 中所有資料點所建立之試驗半變異圖。由圖 2-4 可知，其半變異圖符合預先設定之統計特性 ($C(0)=1$ 及 $a=2$)。與試驗一相同，從隨機場中隨機選擇 25 個網格點，總計作 10 次試驗，其結果如表 2-2 所示。由表 2-2 可知，IRBFN 之 RMSE 值均較另外兩個方法為小 (0.292 至 0.418)。此外，其平均值分別比 OK 及 SRBFN 兩種方法降低約 19% 及 26%。由上述結果再次驗證 IRBFN 之內差估計精確度較另外兩個方法為佳。

4.18	3.80	3.08	2.33	3.62	4.34	3.76	3.99	3.71	3.18
4.13	3.47	2.86	3.29	4.69	3.95	2.83	3.35	3.56	3.56
4.00	3.04	2.89	3.25	3.61	3.84	3.23	2.99	3.12	3.09
4.15	3.36	2.41	3.44	2.57	3.23	3.23	3.36	2.82	2.43
3.98	5.23	4.48	3.40	4.27	2.48	2.99	2.08	3.53	2.25
3.00	3.88	3.65	4.12	3.85	2.54	3.72	3.32	3.22	3.54
3.19	4.51	4.30	3.65	3.46	3.13	2.87	2.60	3.40	3.13
2.63	3.79	3.22	3.84	4.30	2.15	1.98	1.30	1.98	2.91
3.51	2.56	1.83	1.37	2.16	0.71	0.94	1.57	1.53	1.83
3.60	3.70	2.39	2.26	2.22	1.99	2.19	1.89	2.78	2.32

圖 2-4 試驗二之隨機場 ($C(0) = 1$ 及 $a = 2$)




圖 2-5 試驗半變異圖(試驗二)

表 2-2 三種方法於 10 次試驗內插估計之 RMSE 值(估計點從圖 2-4 中隨機選取)

Pattern	RMSE		
	IRBFN	OK	SRBFN
1	0.363	0.381	0.411
2	0.330	0.348	0.456
3	0.329	0.381	0.344
4	0.327	0.420	0.487
5	0.418	0.602	0.446
6	0.367	0.385	0.440
7	0.326	0.469	0.391
8	0.353	0.422	0.490
9	0.407	0.619	0.835
10	0.292	0.308	0.432
Mean	0.351	0.433	0.473

3. 試驗三： $C(0)=2, a=1$

於試驗三中，其隨機場 ($C(0)=2; a=1$) 如圖 2-6 所示，其所有資料點所建立之試驗半變異圖則繪製於圖 2-7，由圖 2-7 可知此隨機場符合原先之統計假設。關於 10 次試驗之結果則分別整理於表 2-3。其結果與前面兩個試驗相同，IRBFN 不論哪個試驗均有最小之 RMSE 值，且其平均值亦分別比 OK 及 SRBFN 兩種方法降低約 30% 及 33%。

由上述三種不同設計之試驗結果可知，相較於 OK 及 SRBFN 兩種方法，本研究所提之 IRBFN 擁有較佳之估計精確度。此外，亦可發現當隨機場之變異性對於估計之精確度影響極大。尤其當變異性越大時，IRBFN 之 RMSE 值相較於 OK 及 SRBFN 有較大之降低幅度，亦即 IRBFN 於變異性較大之隨機場，其表現遠較另外兩種內插方法為優。

4.35	3.51	4.48	4.08	2.51	0.84	1.83	2.64	2.19	1.50
3.58	4.40	7.02	4.62	3.05	2.82	3.65	3.14	2.57	2.40
3.63	4.05	4.56	4.97	3.70	3.67	3.20	3.73	3.01	2.71
4.79	5.63	2.83	4.28	3.39	2.02	1.84	2.77	3.02	2.97
5.76	5.21	1.85	3.06	3.57	0.89	3.31	4.74	3.48	4.91
2.29	1.41	2.39	2.68	3.10	1.47	2.48	2.56	2.78	3.18
0.43	1.16	1.45	2.86	1.42	-0.10	1.61	0.99	3.04	3.62
2.68	0.54	3.98	3.51	3.02	4.43	1.36	1.95	2.07	3.69
3.63	2.31	5.80	5.07	3.33	4.52	2.45	6.08	3.16	3.13
3.26	4.15	2.41	2.49	5.59	4.23	1.81	0.44	1.92	4.57

圖 2-6 試驗三之隨機場 ($C(0)=2$ 及 $a=1$)




圖 2-7 試驗半變異圖(試驗三)

表 2-3 三種方法於 10 次試驗內插估計之 RMSE 值(估計點從圖 2-6 中隨機選取)

試驗次數	RMSE		
	IRBFN	OK	SRBFN
1	0.898	1.150	1.356
2	2.667	3.024	3.655
3	0.545	1.001	0.741
4	0.837	1.136	1.193
5	0.697	1.226	1.329
6	0.553	0.950	1.240
7	0.594	0.949	1.256
8	1.734	2.734	2.088
9	1.584	2.858	1.814
10	1.576	2.393	1.911
Mean	1.168	1.742	1.658

2-4 應用例

本研究以台灣北部淡水河流域之降雨空間分布為研究對象，淡水河之平均坡度為 1/45，整個流域面積約為 2,726 平方公里，流域內共有 55 個中央氣象局之雨量測站，其位置分佈如圖 2-8 所示。總計有 64 筆小時雨量資料可供 OK、SRBFN 及 IRBFN 模式等三種方法進行空間降雨量推估。

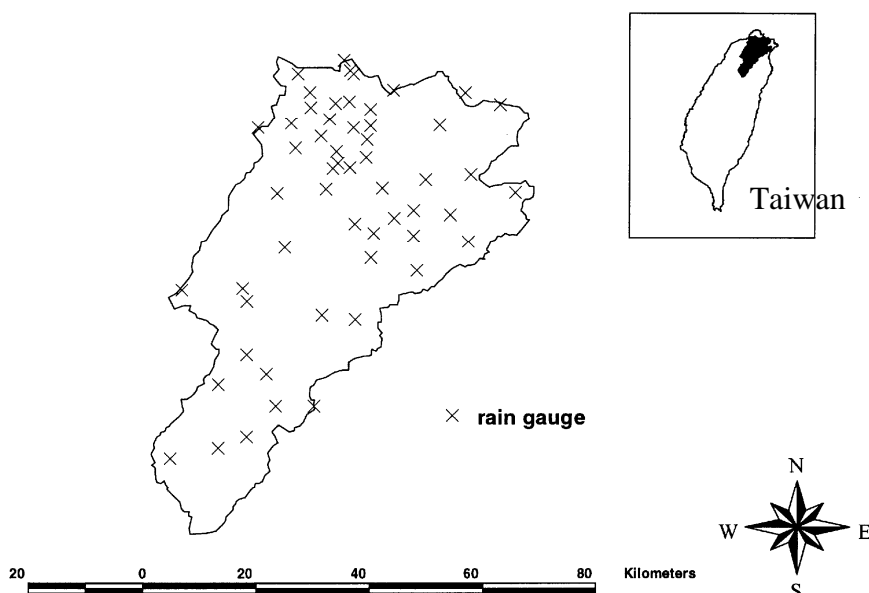


圖 2-8 淡水河流域雨量測站分佈示意圖

交叉驗證法 (Cross-validation) 被用以檢驗 OK、SRBFN 及 IRBFN 模式等

三種方法於此應用例中之表現。交叉驗證法是先選定一個欲估計之雨量測站，再利用其他雨量測站之觀測值推估此測站之降雨量，並由此雨量測站之觀測值計算其 RMSE 值，依序計算每個測站之 RMSE 值，最後再予以平均，擁有最小之 RMSE 值者即為最佳之空間推估方法。關於三種空間推估方法對 64 筆小時降雨內插估計所得之 RMSE 值整理於表 2-4。由表可知，IRBFN、OK 及 SRBFN 之平均 RMSE 值分別為 0.525、0.746 及 0.793。相較於 OK 及 SRBFN 兩種方法，IRBFN 之平均 RMSE 約降低了 30% 及 34%。雖然 IRBFN 於有些雨量資料內插估計之 RMSE 值並非最小，但整體而言，IRBFN 然有較佳之估計準確度。此應用結果更加印證本研究所提空間內插模式之可靠度。

2-5 結論與建議

於本研究中，一個結合輻狀基底函數網路與變異元理論之空間內插模式被建立，稱之為 IRBFN 模式(Improved RBFN Model)。此模式擁有簡單之網路架構及學習法則，並依據統計特性調節參數等多項優點。再者，此模式對於數目龐大之資料，較傳統柯利京法有較快之運算速度。為了驗證此模式內插之精確度，本研究建立了三組不同變異元門檻值及尺度參數之等向性試驗資料加以測試。三組測試之結果顯示，在三種內插模式(IRBFN 模式、柯利京法及標準 RBFN 模式)中，IRBFN 模式均較其他兩種方法擁有較高之估計準確度。此外，實際雨量內插估計之結果亦顯示，本研究所提出之模式可得到較為準確之內插降雨量。

表 2-4 三種空間推估方法對雨量資料內插估計之 RMSE 值

編號	RMSE			編號	RMSE		
	IRBFN	OK	SRBFN		IRBFN	OK	SRBFN
1	0.535	0.591	0.650	33	0.495	0.899	0.602
2	0.485	0.506	0.894	34	0.345	0.522	0.653
3	0.437	0.555	0.682	35	0.723	0.807	1.142
4	0.504	0.758	0.699	36	0.815	0.935	0.835
5	0.400	0.570	0.638	37	0.563	0.913	0.714
6	0.948	0.957	1.350	38	0.522	0.688	0.691
7	0.439	0.456	0.683	39	0.621	0.838	0.606
8	0.438	0.412	0.588	40	0.366	0.660	0.688
9	0.623	0.709	0.905	41	0.400	0.566	0.632
10	0.937	1.140	1.459	42	0.383	0.606	0.535
11	0.492	0.696	0.854	43	0.309	0.360	0.496
12	0.636	0.844	0.948	44	0.425	0.474	0.605
13	0.339	0.371	0.595	45	0.253	0.244	0.510
14	0.469	0.808	0.838	46	0.275	0.283	0.512
15	0.422	0.503	0.709	47	0.324	0.523	0.503
16	0.489	0.877	0.804	48	0.355	0.358	0.503
17	0.482	0.481	0.656	49	0.251	0.231	0.579
18	0.678	1.175	0.848	50	0.299	0.426	0.495
19	0.442	0.480	0.642	51	0.312	0.657	0.501
20	0.447	0.474	0.607	52	0.404	0.469	1.009
21	0.452	0.535	0.700	53	0.439	0.734	0.808
22	0.537	0.618	0.545	54	0.631	0.979	0.830
23	0.591	0.622	0.944	55	0.713	0.905	1.442
24	0.766	1.738	1.670	56	0.637	0.737	1.303
25	0.690	1.662	0.801	57	0.512	0.807	0.702
26	0.733	1.144	1.033	58	0.716	1.159	0.878
27	0.621	1.079	1.109	59	0.632	1.573	0.584
28	0.712	1.941	1.220	60	0.410	0.494	0.680
29	0.857	1.010	0.684	61	0.694	1.011	0.700
30	0.474	0.799	0.929	62	0.810	0.883	1.645
31	0.342	0.436	0.706	63	0.383	0.414	0.624
32	0.494	0.595	0.786	64	0.687	1.046	0.590
				Mean	0.525	0.746	0.793

第三章 地下水位預測之研究

3-1 前言

類神經網路 (artificial neural network) 為晚近崛起之控制理論，他是一種模仿生物大腦與神經網路系統所建構出來之資訊處理系統，能夠對於外界輸入之訊號有儲存、學習及回想等一系列動作。由於類神經網路只是針對人腦作簡化之模擬，利用數學的方式建立模式，達到儲存、學習及回想之作用，其行為與統計之方式相當類似，因此可將其視為一種特殊之統計模式。當一個系統之機制複雜或是模式不易建置時，如何掌握此系統之轉換機制便相當重要。而類神經網路的最大優點即是不需事先了解系統之轉換機制，只要經過類神經元之學習訓練即可，且其脫離了依賴統計模型，具有理論簡明、結構單純，並具有快速計算、學習能力及容錯能力等優點。因此，近年來，類神經網路逐漸被應用於時間序列之預測上，多個應用例也皆已說明其為一種實用之時間序列預測工具。理論上，類神經網路為一種能精確地模擬任一種非線性方程之模擬器(Cybenko, 1989; Hornik et al. 1989; Hornik, 1991)。也因為此優點使得類神經網路可以解決真實世界中許多非線性之問題(Granger, 1993)。此外，許多實驗亦證明類神經網路於非線性時間序列上之適用性及優勢(Kuan and Liu, 1995; Saxen, 1996; Kohzadi et al., 1996; Zhang et al., 1998)。

關於類神經網路之架構及學習法則，至今已有許多模式及方法被提出。其中，又以倒傳遞類神經網路 (back-propagation neural network) 最廣為被熟知及應用。然而，倒傳遞類神經網路於訓練過程中會有許多問題(Wasserman, 1993)。首先，它容易收斂到區域最小值。再者，它即使使用相同之訓練資料，亦會產生出不同之結果。此外，網路學習速度緩慢以及隱藏層結構不易訂定也是其主要缺點。輻狀基底函數網路 (radial basis function network; 簡稱 RBFN) 因為具有網路建構容易、學習速度快及對外在環境具有快速之適應性等優點，目前此方法已經被廣泛應用於影像處理、語音辨識、圖形分類以及通訊系統傳輸等各種領域上，均有相當不錯之成果。而水文上之時間序列可視為一極複雜之非線系系統，因此本研究嘗試以 RBFN 建立時間序列預測模式。

RBFN 之概念最早是由 Hardy (1971) 所提出，後來 Powell (1987) 建立其網路架構，Moody and Darken (1989) 則利用 RBFN 解決數學函數對應之問題，Broomhead and Lowe (1988) 將其應用於數值逼近或內插之問題上。而後相繼有各種類似之網路結構之 RBFN 相繼被提出。隨著輻狀基底函數網路之快速發展，已有不同之訓練法則用以架構更有效率之輻狀基底函數網路，並利用於具有時間序列相關性之問題上。Mikko et al. (1996) 曾以輻狀基底函

數網路為基礎，結合自我迴歸(*autogressive*)之觀念架構網路，並將之應用於時間序列模式之預測上，證實 RBFN 之準確性遠勝過 *autogressive model*、*threshold Autogressive model* 及倒傳遞多層感知機 (*back-propagating multiplayer perceptron*)。

整體而言，RBFN 之建構過程有兩個重要步驟。一個為設定隱藏層神經元之個數及其中心點，另一個為計算隱藏層至輸出層間之權重。在現有之學習法則中，最主要之差別即是在於第一個步驟，神經元中心點之決定為建構 RBFN 之一個極為重要之問題。最簡單的解決方式就是將每個訓練資料都當作神經元中心。然而，這是不切實際的做法，尤其是當訓練資料很多時。因此，過去群集分析(*cluster analysis*)常被用來決定 RBFN 之神經元中心點 (Moody and Darken, 1989)。

群集分析是一種能根據資料之相似性與相異性，進行分群的邏輯程序。其針對某種指定之特性，將欲進行分類之資料依此特性劃分為多個群集，使同一群集中具有高度之均一性 (*homogeneity*)，不同群集彼此具有明顯的異質性 (*heterogeneity*)。傳統的群集分析大致可分為階層式 (*hierarchical*) 的群集分析法如單一鏈結法 (*single linkage method*)、華德法 (*Ward's method*) 及非階層式 (*non-hierarchical*) 的群集分析法如 *K* 均值法 (*K-means method*)。然而，階層式的群集分析法進行分群之依據乃是根據分析後所得的樹狀圖，其幫助了瞭解資料間的相對距離，然並無客觀決定群集組數的方法，端視研究者的需要及經驗決定。非階層群集分析法通常需在進行分析之前決定群集的組數，然而不同的群集組數常會導致差異極大的分析結果。對於 RBFN 之建構來說，判定資料是否確實存在群集關係及如何決定適當的神經元數目乃是一重要的課題。有鑑於此，本研究嘗試利用自組織映射圖網路 (*self-organizing map*; 簡稱 *SOM*) 來解決這些問題。

SOM 網路是由 Kohonen (1990) 所提出，屬於非監督式及競爭式學習的網路模型。其功能是将高維度的資料映射至低維度的圖形中，並保存資料原本的拓撲結構及顯現資料內在的統計特徵，近來廣泛被應用於各種領域上 (Orwig et al., 1997; Tokutaka et al., 1999; Michaelides et al., 2001, Tennant and Hewitson, 2002)。Zhang and Li (1993) 提出了利用 *SOM* 網路找出資料的群集關係及群集邊界的方法，稱之為自組織映射圖網路分析。Mangiameli et al. (1996) 曾經比較 *SOM* 網路與傳統之群集分析法，結果均顯示 *SOM* 網路有較佳之群集分析結果。Vesanto and Alhoniemi (2000) 利用 *SOM* 網路進行了二步驟之群集分析。首先應用 *SOM* 網路分析原始資料，待原始資料被映射至低維度之圖形時，再以其他群集分析方法分析前一步驟所得的特徵圖 (*feature map*)，利用此二步驟分析所得之分群效果較傳統方法更佳，且可大幅減低群集分析所需之計算時間。Michaelides et al. (2001) 運用 *SOM* 網路分析降雨之變異性，並用以提供氣候模型使用，其結果亦顯示 *SOM* 網路較階層式群集分析法更能顯示出降雨變異性的細節。

綜合上面所述，本研究將建立一個結合 RBFN 及 SOM 之時間序列預測模式，稱之為 SOM-RBFN 模式。首先，本研究先針對 RBFN 及 SOM 之網路架構及學習法則作一一介紹。再以三組模擬之時間序列測試此模式之預測能力。最後，將此模式應用於實際地下水位時間序列之預測上，並與傳統之 ARIMA 模式作比較。

3-2 研究方法

3-2-1 輻狀基底函數網路

輻狀基底函數網路 (RBFN) 屬於多層前饋式類神經網路，其輸入層與隱藏層間之神經元完全相互聯結，其網路架構如圖 3-1 所示。RBFN 具有三個特性：(1)僅有輸入、隱藏及輸出等三層結構；(2)輸出層完全由線性處理單元所組成；(3)隱藏層轉換函數之激發是由輸入資料與隱藏層神經元中心之距離決定。RBFN 之主要優點為能將訓練樣本之資訊有系統性的儲存於隱藏層中，只要使用簡單之矩陣運算即可求得網路中之加權值，不需要於訓練階段時設定許多網路參數值。此外，只要適當設定訓練停止條件即可，所以 RBFN 為相當有效率之非線性系統鑑別工具。




圖 3-1RBFN 架構圖

假設 RBFN 之結構中，輸入層為具有 P 個輸入變數之資料 Z ，將其以向量 $Z = [z_1, z_2, \dots, z_p]^T$ 傳輸至隱藏層中之神經元，以輸入向量與各神經元中心之距離作為神經元被激發與否之依據，每一隱藏層神經元之輸出 $h_j, j=1, 2, \dots, J$ 可以轉換函數表之：

$$\phi_j(z_i) = \phi(\|z_i - c_j\|) \quad j=1, 2, \dots, N_h \quad (3-1)$$

其中， $\| \cdot \|$ 為歐基里德範數 (Euclidean norm)； c_j 為隱藏層神經元之中心點 (center)； $\phi(\cdot)$ 為反應函數 (activation function)； M 為隱藏層神經元數目。在作空間內插估計時， c_j 可以視為第 j 個觀測點位置，而 $\|x_i - c_j\|$ 則可視為第 j 個觀測點與第 i 個預估計點之距離。

在網路架構中，隱藏層之維度與輸入層相同。至於反應函數之型態包含許多種類，如高斯函數 (Gaussian function)、邏輯函數、multiquadric function (MQF)、thin-spline function (TSP) 及指數函數 (exponential function) 等。本研究則使用最為普遍之高斯函數為隱藏層神經元之轉移函數，其型式如下所示：

$$\phi(Z) = \exp\left[-\frac{\|Z - c\|^2}{2\beta^2}\right] \quad (3-2)$$

其中， σ 為高斯函數之寬度值，可由下式求得：

$$\beta = \frac{d_{\max}}{\sqrt{2N_h}} \quad (3-3)$$

其中， d_{\max} 為在訓練樣本中，輸入向量間之最大距離。計算所有輸入向量對神經元之輻狀基底函數輸出結果，並利用最小平方法 (least squares method) 求出隱藏層與輸出層間之權重值，進而將隱藏層輸出值乘以各個權重值，即可得到輸出層之輸出值 \hat{y}_r ，如下所示：

$$\hat{y}_r = w_0 + \sum_{q=1}^{N_h} w_{qr} \phi_q(Z) \quad r=1, 2, \dots, N_R \quad (3-4)$$

其中， $\phi_q(Z)$ 為第 q 個隱藏層神經元之輸出值； y_k 為輸出層中第 k 個輸出值； w_{qr} 為隱藏層中第 q 個神經元至輸出層中第 r 個輸出值之權重值； w_0 為偏差 (bias)； N_R 為輸出值個數。

於 RBFN 之架構中，若隱藏層神經元之中心點與寬度值被決定後，方程式(3-4)中之權重值可利用最小平方法求得。於本研究中，將使用 SOM 網路決定隱藏層神經元之數目及中心點，而此模式稱之為 SOM-RBFN 模式。關於 SOM 網路之架構及學習方法則敘述於下節。

3-2-2 自組織映射圖網路

自組織映射圖 (SOM) 網路在類神經網路領域中是一種知名的網路模型，其網路架構如圖 3-2 所示。SOM 網路屬於非監督式學習 (unsupervised learning) 網路，其網路可經由競爭式學習法架構。競爭式學習法之原理是輸出單元彼此競爭，唯一贏得勝利者則稱為優勝單元，成為唯一權重向量受刺激調整之單元，此過程稱之為贏者全拿 (winner-take-all)。然而，SOM 網路與傳統之競爭式學習法則並不相同，它加入了鄰近區域之概念，使得每次優勝單元之鄰近區域輸出單元亦會隨同優勝單元而被激發。




圖 3-2 SOM 網路架構圖

SOM 網路可將任意維度之輸入向量映射至特徵圖 (feature map) 上，如圖 3-2 所示。所以 SOM 網路可視為將輸入樣本以非線性法轉換至特徵圖上。其神經元會依輸入向量之特性，以具有意義之拓樸結構展現在輸出空間，而此拓樸結構可反應輸入樣本之特性。因此若原本輸入向量間存在著相關性，反映於特徵圖上之輸出單元也會表現出相似之關係。近年來，SOM 網路常被應用於辨識分類處理，而在許多領域也都使用它來做歸納分析，如影像圖樣處理、語言學家分析語言、商業管理對市場反應作分類處理等。

SOM 網路的學習過程包含競爭程序 (competitive process)、合作程序 (cooperative process) 以及調整程序 (adaptive process) 等三個重要的程序，其演算過程敘述如下：

1. 若原始資料空間有 p 個樣本輸入向量，而每個輸入向量維 m 維度，因此第 p 個樣本向量如下所示：

$$x_p = [x_{p,1}, x_{p,2}, x_{p,3}, \dots, x_{p,m}]^T \quad (3-5)$$

網路之神經元權重向量將會有相同之維度 m ，而第 j 個神經元之權重向量表示如下：

$$w_j = [w_{j,1}, w_{j,2}, w_{j,3}, \dots, w_{j,m}]^T \quad j=1, 2, 3, \dots, l \quad (3-6)$$

2. 因為輸入變數之間尺度不一致，因此輸入變數需要先經過標準化消除變數間對分群時不同之權重關係。第 p 個樣本標準化計算如下：

$$x'_p = \frac{x_p - \bar{x}_p}{s_p} \quad (3-7)$$

其中， \bar{x}_p 、 s_p 分別為第 p 個樣本之平均值及標準偏差。

3. 設定循環次數 n 、學習速率 η 及鄰近區域函數 $h_{j,i(x)}$ 。其中，學習速率是優勝單元權重向量之加權值。
4. 初始神經元權重向量 $w_j(0)$ 以隨機選取，因此所有神經元初始權重向量均不相同。
5. 循序從輸入樣本空間選取樣本向量 x_p ，並計算輸入向量 x_p 與權重向量

w_j 之歐式距離 $d_{p,j}$ ：

$$d_{p,j} = \left[\sum_{i=1}^m (x_{p,i} - w_{j,i})^2 \right]^{1/2} \quad (3-8)$$

其中， $x_{p,i}$ 為輸入向量 x_p 第 i 個分量； $w_{j,i}$ 為權重向量 w_j 第 i 個分量。

6. 找出歐式距離最小之神經元權重向量，則此神經元即是優勝單元，調整優勝單元和以其為中心鄰近區域內之權重向量：

$$w_j(n+1) = w_j(n) + \eta(n) h_{j,i(x)}(n) (x(n) - w_j(n)) \quad (3-9)$$

其中， $w_j(n+1)$ 為經調整後神經元 j 新的權重向量； $h_{j,i(x)}(n)$ 為鄰近區域

函數； $\eta(n)$ 為學習速率。

7. 重複步驟 3 至 6，當所有之輸入向量均與權重向量比較過，即完成一次循環。直至完成所有循環次數。
8. 輸入向量中所有樣本將分別映射至特徵圖上之網格點。在特徵圖中，一個輸入樣式只會擁有唯一的映像，但是一個映像卻可以同時是其他很多不同輸入樣式的映像。

計算每個映像所對應的輸入樣式數目並將其填入該網格中即可得到密度圖 (density map)，從中可以得知輸入樣式在密度圖散佈的情形。輸入樣式之間若具有相似的特性，其會有坐落在密度圖同一區域的傾向；而輸入樣式之間的差異較大時，其在密度圖上的位置則會較為分散。換句話說，當輸入樣式之間確實存在某些群集的情況時，其群集的情形會顯示在密度圖。此性質可被應用在高維度資料之群集分析上。

3-3 試驗設計

本研究所提出之類神經網路是否適用於時間序列之預測？與傳統 ARIMA 模式比較表現值如何？為了回答這些問題，本研究以 ARIMA(p, d, q) 模式(Box and Jenkins, 1976)模擬三組時間序列資料。三組測試之時間序列模式之型式如下所示：

1. The AR(1) process

$$y_t = y_{t-1} + \varepsilon_t \quad (3-10)$$

2. The AR(2) process

$$y_t = y_{t-1} - 0.6y_{t-2} + \varepsilon_t \quad (3-11)$$

3. The ARIMA(1, 1, 1) process

$$(1 - B)y_t = 0.5(1 - B)y_{t-1} + \varepsilon_t + 0.5\varepsilon_{t-1} \quad (3-12)$$

其中， ε_t 為白噪音 (white noise)。

上述三組時間序列常發生於水文過程中。每組時間序列各有 200 個訓練資料，100 個測試資料。訓練資料被用以建立 RBFN 之網路架構及計算 ARIMA 模式之參數；測試資料則被用以測試模式之預測能力。其中，本研究假設此三組試驗資料之 ARIMA 模式形式皆為已知，因此忽略模式檢定之動作。至於 ARIMA 模式之參數是以最小平方法計算。此外，本研究為了對於預報效果之優劣加以評鑑，因此分別採用下列兩種評鑑指標判斷優劣：

1. Mean square error (MSE)

$$\text{MSE} = \frac{1}{T} \sum_{t=1}^T [\hat{y}_t - y_t]^2 \quad (3-13)$$

其中， \hat{y}_t 為時間 t 之預測值； y_t 為時間 t 之觀測值； T 為預測之數目。

2. Median absolute percentage error (MdAPE)

$$\text{MdAPE} = \text{Median} \left(\left| \frac{\hat{y}_t - y_t}{y_t} \right| \times 100 \right) \quad (3-14)$$

其中，雖然 MSE 為最常被使用之評鑑指標。然而，它也常受到許多批評 (Clements and Hendry, 1993)。Gardner (1983) 曾針對以上兩種指標評鑑預測模式之原因加以說明。MdAPE 比 MSE 優越已經被討論證實 (Armstrong and Collopy, 1992; Fildes, 1992)。

關於 RBFN 及 ARIMA 模式對於三組時間序列試驗組之評鑑指標計算結果，分別被整理列表於表 3-1、表 3-1 以及表 3-3。由這些表之結果可發現，RBFN 之預測表現較 ARIMA 模式為佳。此外，對於此三組試驗資料，RBFN 皆能有效掌握其主要之變化趨勢，且不論以何種指標評鑑，皆擁有極佳之預測表現。

表 3-1 評鑑指標對於 AR(1)模式及 SOM-RBFN 模式之計算結果

預測模式	訓練資料		測試資料	
	MSE	MdAPE	MSE	MdAPE
AR(1)模式	1.084	0.762	1.009	0.601
SOM-RBFN 模式	1.026	0.749	0.965	0.528

表 3-2 評鑑指標對於 AR(2)模式及 SOM-RBFN 模式之計算結果

預測模式	訓練資料		測試資料	
	MSE	MdAPE	MSE	MdAPE
AR(2)模式	0.990	0.660	1.041	0.709
SOM-RBFN 模式	0.969	0.535	0.901	0.626

表 3-3 評鑑指標對於 ARIMA(1, 1, 1)模式及 SOM-RBFN 模式之計算結果

預測模式	訓練資料		測試資料	
	MSE	MdAPE	MSE	MdAPE
ARIMA(1, 1, 1)模式	0.228	0.298	0.259	0.387
SOM-RBFN 模式	0.220	0.302	0.260	0.384

3-4 應用例

3-4-1 研究資料

本研究以台灣南部地區之秀林地下水位測站為研究對象，其月平均地下水位如圖 3-3 所示。資料紀錄從 1982 年至 2001 年共 20 年資料，總計有 240 筆月平均地下水位資料。其中，192 筆資料作為訓練，另外 48 筆資料作為測試。

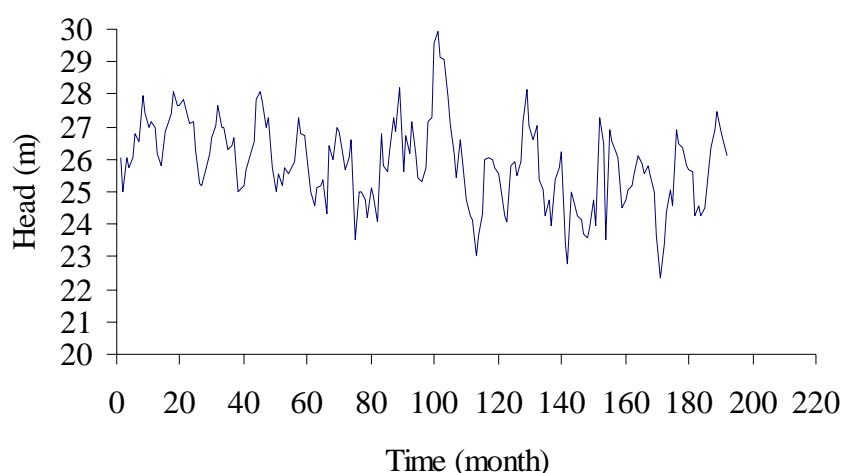


圖 3-3. 秀林測站月平均地下水時間序列

3-4-2 ARIMA 模式

首先，原始地下水時間序列之自我相關函數 (sample autocorrelation function; ACF) 及偏自我相關函數 (partial autocorrelation function; PACF) 分別被求出，整理如表 3-4 所示。由表中可知，ACF 在相隔 12 個月時較為顯著，因此需要取相隔 12 個月之差分值(季節性差分)，即 $(1-B^{12})Z_t$ 。

關於季節性差分時間序列之 ACF 及 PACF 則整理如表 3-5 所示。由表中可知，ACF 呈現一明顯之 sine-cosine 形式，而 PACF 於時間差一個月時顯著不為零，所以此時間序列模式可表示為：

$$(1-\Phi B)(1-B^{12})Z_t = \theta_0 + a_t \quad (3-15)$$

其中， Z_t 為時間 t 之地下水水位； B 為後移運算子 (backward shift operator; $B^k Z_t = Z_{t-k}$)； θ_0 為常數； a_t 為白噪音 (white noise)。計算式中各個係數後，可得到下式：

$$(1-0.69B)(1-B^{12})Z_t = -0.09 + a_t \quad (3-16)$$

再者，模式 $(1-0.69B)(1-B^{12})Z_t = -0.09 + a_t$ 之殘差 ACF 列於表 3-6。由表可知殘差 ACF 在相隔 12 個月時較為顯著，所以定義此模式為 ARIMA(1, 0, 0)×(0, 1, 1)₁₂：

$$(1-\Phi B)(1-B^{12})Z_t = \theta_0 + (1-\Theta B^{12})a_t \quad (3-17)$$

其中， Θ 為移動平均參數。經過參數計算後，模式可表示如下：

$$(1-0.68B)(1-B^{12})Z_t = -0.03 + (1-0.91B^{12})a_t \quad (3-18)$$

表 3-4 秀林測站原始地下水時間序列之 ACF 及 PACF

(a) ACF $\hat{\rho}_k$ for $\{Z_t\}$; ($\bar{Z} = 25.89$, $S_Z = 1.29$, $n = 192$)												
k	1	2	3	4	5	6	7	8	9	10	11	12
$\hat{\rho}_k$	0.73	0.55	0.40	0.22	0.08	0.00	-0.01	0.00	0.09	0.12	0.18	0.25
St.E.	0.10	0.12	0.12	0.13	0.13	0.13	0.13	0.13	0.13	0.13	0.13	0.13
k	13	14	15	16	17	18	19	20	21	22	23	24
$\hat{\rho}_k$	0.21	0.14	0.08	0.00	-0.08	-0.16	-0.14	-0.09	-0.04	0.00	0.10	0.18
St.E.	0.13	0.13	0.13	0.13	0.13	0.14	0.14	0.14	0.14	0.14	0.14	0.14
k	25	26	27	28	29	30	31	32	33	34	35	36
$\hat{\rho}_k$	0.16	0.18	0.17	0.19	0.15	0.09	0.08	0.06	0.05	0.07	0.10	0.13
St.E.	0.14	0.14	0.14	0.14	0.14	0.14	0.14	0.14	0.14	0.14	0.15	0.15
(b) PACF $\hat{\phi}_{kk}$												
k	1	2	3	4	5	6	7	8	9	10	11	12
$\hat{\phi}_{kk}$	0.73	0.05	-0.04	-0.14	-0.08	0.01	0.10	0.07	0.14	-0.02	0.07	0.08
St.E.	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07
k	13	14	15	16	17	18	19	20	21	22	23	24
$\hat{\phi}_{kk}$	-0.09	-0.09	-0.02	-0.04	-0.03	-0.10	0.10	0.08	-0.01	-0.04	0.13	0.07
St.E.	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07
k	25	26	27	28	29	30	31	32	33	34	35	36
$\hat{\phi}_{kk}$	-0.08	0.08	0.04	0.16	-0.04	-0.05	0.06	-0.06	0.00	0.08	0.00	0.00
St.E.	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07

表 3-5 秀林測站季節性差分時間序列之 ACF 及 PACF

(a) ACF $\hat{\rho}_k$ for $\{W_t = (1-B^{12})Z_t\}; (\bar{W} = -0.05, S_w = 1.59, n = 180)$												
k	1	2	3	4	5	6	7	8	9	10	11	12
$\hat{\rho}_k$	0.70	0.55	0.42	0.30	0.17	0.10	0.01	-0.11	-0.15	-0.24	-0.34	-0.50
St.E.	0.10	0.12	0.13	0.13	0.13	0.13	0.13	0.13	0.13	0.14	0.14	0.15
k	13	14	15	16	17	18	19	20	21	22	23	24
$\hat{\rho}_k$	-0.34	-0.32	-0.29	-0.29	-0.26	-0.27	-0.23	-0.15	-0.13	-0.11	-0.03	0.02
St.E.	0.16	0.16	0.16	0.16	0.17	0.17	0.17	0.17	0.17	0.17	0.17	0.17
k	25	26	27	28	29	30	31	32	33	34	35	36
$\hat{\rho}_k$	0.05	0.15	0.22	0.31	0.34	0.34	0.31	0.23	0.17	0.15	0.09	0.06
St.E.	0.17	0.17	0.17	0.18	0.18	0.19	0.19	0.19	0.19	0.19	0.19	0.19
(b) PACF $\hat{\phi}_{kk}$												
k	1	2	3	4	5	6	7	8	9	10	11	12
$\hat{\phi}_{kk}$	0.70	0.13	-0.01	-0.05	-0.10	0.01	-0.08	-0.15	0.00	-0.13	-0.18	-0.30
St.E.	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07
k	13	14	15	16	17	18	19	20	21	22	23	24
$\hat{\phi}_{kk}$	0.36	-0.03	-0.07	-0.18	-0.04	-0.04	-0.06	0.02	-0.02	-0.16	-0.02	-0.13
St.E.	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07
k	25	26	27	28	29	30	31	32	33	34	35	36
$\hat{\phi}_{kk}$	0.28	0.11	0.05	0.03	-0.05	-0.08	0.00	-0.03	-0.05	-0.03	-0.01	-0.04
St.E.	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07	0.07

表 3-6 $(1-0.69B)(1-B^{12})Z_t = -0.09 + a_t$ 之殘差 ACF

k	1	2	3	4	5	6	7	8	9	10	11	12
$\hat{\rho}_k$	-0.03	0.09	0.16	-0.09	-0.08	0.03	-0.09	-0.12	0.08	-0.04	-0.04	0.00
St.E.	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08
k	13	14	15	16	17	18	19	20	21	22	23	24
$\hat{\rho}_k$	0.07	0.01	0.05	0.04	0.03	-0.07	-0.03	0.02	-0.10	-0.11	0.02	-0.36
St.E.	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.09	0.09	0.09	0.09
k	25	26	27	28	29	30	31	32	33	34	35	36
$\hat{\rho}_k$	-0.09	0.11	-0.07	0.10	0.17	0.04	0.06	0.07	-0.15	0.00	-0.01	0.01
St.E.	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10

模式 $(1-0.68B)(1-B^{12})Z_t = -0.03 + (1-0.91B^{12})a_t$ 之殘差 ACF 則整理於表

3-7。殘差 ACF 值相當小，由此可知 ARIMA(1, 0, 0)×(0, 1, 1)₁₂ 模式相當適用於描述此時間序列。當模式參數計算完畢後，即可使用下式預測未來之地下水水位：

$$Z_{t+l} = 0.68Z_{t+l-1} + Z_{t+l-12} - 0.68Z_{t+l-13} + a_{t+l} - 0.91a_{t+l-12} - 0.03 \quad (3-19)$$

表 3-7 $(1-0.68B)(1-B^{12})Z_t = -0.03 + (1-0.91B^{12})a_t$ 之殘差 ACF

k	1	2	3	4	5	6	7	8	9	10	11	12
$\hat{\rho}_k$	-0.03	0.09	0.10	-0.09	-0.08	0.03	-0.09	-0.11	0.08	-0.04	-0.04	0.00
St.E.	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08
k	13	14	15	16	17	18	19	20	21	22	23	24
$\hat{\rho}_k$	0.07	0.01	0.05	0.04	0.03	-0.07	-0.03	0.02	-0.10	-0.11	0.02	-0.36
St.E.	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.09	0.09	0.09	0.09
k	25	26	27	28	29	30	31	32	33	34	35	36
$\hat{\rho}_k$	-0.09	0.11	-0.07	0.10	0.17	0.04	0.06	0.07	-0.15	0.00	-0.01	0.01
St.E.	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10	0.10

3-4-3 SOM-RBFN 模式

根據 ACF 及 PACF 之結果可知，秀林站之月平均地下水與前一個月、前 12 個月以及前 13 個月之紀錄有相關性，因此本研究以此三個紀錄資料作為 SOM-RBFN 模式之輸入值。首先，經由 98,000 次循環計算後，SOM 之 14×14 密度圖即被建立完成，如圖 3-4 所示。由 SOM 密度圖可知，其可被劃分為 15 個區域，亦即 192 筆訓練資料可被分成 15 個群集。因此，於網路模式中之隱藏層神經元數目為 15 個，而其各自之中心點隨即可被計算得到。




圖 3-4. SOM 二維密度圖

3-4-4 結果與討論

關於 ARIMA 及 SOM-RBFN 兩模式預測值與觀測值之比較結果分別如圖 3-5 及圖 3-6 所示。由圖 3-5 及圖 3-6 可知，SOM-RBFN 模式之預測結果相當良好，但是 ARIMA 模式之預測結果則相差甚多。再者，ARIMA 及 SOM-RBFN 兩模式對於地下水位預測之評鑑指標表現值則整理於表 3-8。對於訓練資料而言，SOM-RBFN 模式之 MSE 及 MdAPE 之值分別為 0.06 及 0.38，均小於 ARIMA 模式之 1.15 及 2.39。此外，於測試資料中，SOM-RBFN 模式之 MSE 及 MdAPE 之值分別為 0.26 及 0.91，亦均小於 ARIMA 模式之 0.42 及 1.46。由上述之結果可知，SOM-RBFN 模式的確擁有較好之時間序列預測能力。

表 3-8 ARIMA 及 RBFN 對於秀林站地下水位預測之評鑑指標表現值

Method	Training data		Testing data	
	MSE	MdAPE	MSE	MdAPE
ARIMA Model	1.15	2.39	0.42	1.46
RBFN	0.06	0.38	0.26	0.91




圖 3-5. ARIMA 模式預測值與觀測值之比較




圖 3-6. SOM-RBFN 模式預測值與觀測值之比較

3-5 結論與建議

於本研究中，一個結合輻狀基底函數網路與自組織映射圖網路之時間序列預測模式被建立，稱之為 SOM-RBFN 模式。由於傳統之輻狀基底函數網路架構中，其隱藏層神經元數目及中心點之決定為一個亟待解決之問題。因此本研究嘗試以自組織映射圖網路建立二維密度圖，用以決定神經元數目及中心點。為了測試此模式之預測能力，本研究以 ARIMA 模式模擬三組時間序列資料，並以這些資料測試 SOM-RBFN 模式與傳統 ARIMA 模式之預測精確度。結果證實此預測模式有較佳之預測精確度。此外，本研究將 SOM-RBFN 模式應用於台灣南部地區秀林地下水水位站之地下水水位時間序列預測，並與季節性 ARIMA 模式之預測結果作比較。結果顯示 SOM-RBFN 模式可準確預測地下水水位。

參考文獻

- Aizerman, M.A., Braverman, E.M., Rozonoer, L.I., 1964. Theoretical foundations of the potential function method in pattern recognition learning. *Automatic Remote Control* 25 (6), 821-837.
- Armstrong, J.S., Collopy, F., 1992. Error measures for generalizing about forecasting methods: empirical comparisons. *International Journal of Forecasting* 8 (1), 69-80.
- Bashkirov, O.K., Braverman, E.M., Muchnik, I.B., 1964. Potential function algorithms for pattern recognition learning machines. *Automatic Remote Control* 25 (5), 629-631.
- Bastin, G., Lorent, B., Duque, C., Gevers, M., 1984. Optimal estimation of the average rainfall and optimal selection of raingage locations. *Water Resources Research* 20 (4), 463-470.
- Bellin, A., Rubin, Y., 1996. HYDRO_GEN: A spatially distributed random field generator for correlated properties. *Stochastic Hydrology and Hydraulics* 10 (4), 253-278.
- Box, G.E.P., Jenkins, G.M., 1976. *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco.
- Broomhead, D.S., Lowe, D., 1988. Multivariable functional interpolation and adaptive networks. *Complex System* 2, 321-355.
- Chen, S.S., Billings, A., Grant, P.M., 1990. Recursive hybrid algorithm for non-linear system identification using radial basis function networks. *International Journal Control* 55 (5), 1051-1070.
- Chen, S.C., Cowan F.N., Grant, P.M., 1991. Orthogonal least squares learning algorithm for radial basis function networks. *IEEE Transactions on Neural Networks* 2 (2), 302-309.
- Chiles, J.P., Delfiner, P., 1999. *Geostatistics: Modeling Spatial Uncertainty*. Wiley, New York.
- Chirlin, G.R., Dagan, G., 1980. Theoretical head variogram for steady flow in statistically homogeneous aquifers. *Water Resources Research* 16 (6), 1001-1015.
- Clements, M.P., Hendry, D.F., 1993. On the limitations of comparing mean square forecast errors. *Journal of Forecasting* 12 (8), 615-637.
- Cybenko, G., 1989. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems* 2, 303-314.
- Duc, H., Shannon, I., Azzi, M., 2000. Spatial distribution characteristics of some air pollutants in Sydney. *Mathematics and Computers in Simulation* 54 (1-3), 1-21.
- Fildes, R., 1992. The evaluation of extrapolative forecasting methods. *International Journal of Forecasting* 8 (1), 81-98.

- Gardner, E.S., 1983. The trade-offs in choosing a time series method. *Journal of Forecasting* 2 (3), 263-267.
- Granger, C.W.J., 1993. Strategies for modeling nonlinear time-series relationships. *The Economic Record* 69 (206), 233-238.
- Hardy, R.L., 1971. Multiquadric equations of topography and other irregular surfaces. *Journal of Geophysical Research* 76 (8), 1905-1915.
- Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks* 2 (5), 359-366.
- Hornik, K., 1991. Approximation capability of multilayer feedforward networks. *Neural Networks* 4 (2), 251-257.
- Hecht-Nielsen, R., 1987. Counterpropagation networks. *Applied Optics* 26 (23), 4979-4984.
- Hill, M., Alexandar, F., 1989. Statistical methods used in assessing the risk of disease near a source of possible environmental pollution: a review. *Journal of Royal Statistical Society*. 152(3), 353-363.
- Hsu, G. L., Gupta, H. V., Sorooshian, S., 1995. Artificial Neural Network Modeling of the Rainfall-Runoff Process. *Water Resources Research* 31 (10), 2517-2530.
- Kitanidis, P.K., 1993. Geostatistics, In: Maidment D.R. (Ed.), *Handbook of Hydrology*, McGraw-Hill, New York, 20.1-20.39.
- Kohonen, T., 1990. The self-organizing map. *Proceedings of the Institute of Electrical and Electronics Engineers* 78 (9), 1464-1480.
- Kohzadi, N., Boyd, M.S., Kermanshahi, B., Kaastra, I., 1996. A comparison of artificial neural network and time series models for forecasting commodity prices. *Neurocomputing* 10 (2), 169-181.
- Komda, T., Makarand, C., Hydrological forecasting using neural networks. *Journal of Hydrologic Engineering* 5 (2), 180-189, 2000.
- Kuan, C.M., Liu, T., 1995. Forecasting exchange rates using feedforward and recurrent neural networks. *Journal of Applied Econometric* 10, 347-364.
- Lin, G.F., Chen, G.R., 2007. A systematic approach to the input determination for neural network rainfall-runoff models. *Hydrological Processes*, DOI: 10.1002/hyp.6849. (published online)
- Lin, G.F., Chen, L.H., 2004a. A non-linear rainfall-runoff model using radial basis function network. *Journal of Hydrology* 289 (1-4), 1-8.
- Lin, G.F., Chen, L.H., 2004b. A spatial interpolation method based on radial basis function networks incorporating a semivariogram model. *Journal of Hydrology* 288 (3-4), 288-298.
- Lin, G.F., Chen, L.H., 2005a. Time series forecasting by combining the radial basis function network and the self-organizing map. *Hydrological Processes* 19 (10),

1925-1937.

- Lin, G.F., Chen, L.H., 2005b. Application of an artificial neural network to typhoon rainfall forecasting. *Hydrological Processes* 19 (9), 1825-1837.
- Lin, G.F., Chen, L.H., 2006. Identification of homogeneous regions for regional frequency analysis using the self-organizing map. *Journal of Hydrology* 324 (1-4), 1-9.
- Lin, G.F., Wang, C.M., 2006. Performing cluster analysis and discrimination analysis of hydrological factors in one step. *Advances in Water Resources* 29 (11), 1573-1585.
- Lin, G.F., Wu, M.C., 2007. A SOM-based approach to estimating design hyetographs of ungauged sites. *Journal of Hydrology* 339 (3-4), 216-226.
- Mangiameli, P., Chen, S.K., West, D., 1996. A comparison of SOM neural network and hierarchical clustering methods. *European Journal of Operational Research* 93 (2), 402-417.
- Marina, C., Paolo, A., Alfredo, S., 1999. River flood forecasting with a neural network model. *Water Resources Research* 35 (4), 1191-1197.
- Michaelides, S.C., Pattichis, C.S., Kleovoulou, G., 2001. Classification of rainfall variability by using artificial neural networks. *International Journal of Climatology* 21 (11), 1401-1414.
- Mikko, L., Jukka, S., Pentti, H., Kimmo, K., 1996. A network of autoregressive processing units for time series modeling. *Applied Mathematics and Computation* 75 (2-3), 151-165.
- Moody, J., Darken C.J., 1989. Fast learning in networks of locally-tuned processing units. *Neural Computation*. 1, 289-303.
- Musavi, M.T., Ahmed, W., Chan, K.H., Faris, K.B., Hummels, D.M., 1992. On the training of radial basis function classifiers. *Neural Network* 5 (4), 595-603.
- Orwig, R.E., Chen, H., Nunamaker, J.F., 1997. A graphical, self-organizing approach to classifying electronic meeting output. *Journal of the American Society for Information Science* 48 (2), 157-170.
- Oukhellou, L., Aknin P., 1999. Hybrid training of radial basis function networks in a partitioning context of classification. *Neurocomputing* 28, 165-175.
- Park, J., Sandberg, I.W., 1991. Universal approximation using radial basis function network. *Neural Computation* 3 (2), 246-257.
- Poggio, T., Girosi, F., 1990. Networks for approximation and learning. *Proceedings of the IEEE* 78 (9), 1481-1497.
- Powell, M.J.D., 1987. Radial basis functions for multivariable interpolation: A review. *Algorithms for Approximation*. Clarendon Press, New York.
- Sanchez, V.D., Sloat, S., Guerrero, J., Shullo, D., Lefebvre, M., 1998. The design of a

- real-time neurocomputer based on RBF networks. *Neurocomputing* 20 (3), 111-114.
- Saxen, H., 1996. Nonlinear time series analysis by neural networks: a case study. *International Journal of Neural Systems* 7 (2), 195-201.
- Tennant, W.T., Hewitson, B.C., 2002. Intra-seasonal rainfall characteristics and their importance to the seasonal prediction problem. *International Journal of Climatology* 22 (9), 1033-1048.
- Tokutaka, H., Yoshihara, K., Fujimura, K., Iwamoto, K., Obu-Cann, K., 1999. Application of self-organizing maps (SOM) to auger electron spectroscopy. *Surface and Interface Analysis* 27 (8), 783-788.
- Tsuji, O., Freedman, M.T., Mun, S.K., 1999. Classification of microcalcifications in digital mammograms using trend-oriented radial basis function neural network. *Pattern Recognition* 32 (5), 891-903.
- Vesanto, J., Alhoniemi, E., 2000. Clustering of the self organizing map. *IEEE Transactions on Neural Networks* 11 (3), 586-600.
- Wasserman, P.D., 1993. *Advanced methods in neural computing*. Van Nostrand Reinhold, New York.
- White, J.G., Welch, R.M., Norvell, W.A., 1997. Soil zinc map of the USA using geostatistics and geographic information systems. *Soil Science Society of America Journal* 61 (1), 185-194.
- Xu, L., 1998. RBF nets, mixture experts, and Bayesian Ying-Yang learning. *Neurocomputing*. 19(1), 223-257.
- Zhang, X., Li, Y., 1993. Self-organizing map as a new method for clustering and data analysis. *Proceeding of 1993 International Joint Conference on Neural Networks* 3, 2448-2451.
- Zhang, G., Patuwo, B.E., Hu, M.Y., 1998. Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting* 14 (1), 35-62.
- Zhao, Q., Bao, Z., 1996. Radar target recognition using a radial basis function neural network. *Neural Networks* 9 (4), 709-720.
- Zhu, M.L., Fujita, M., 1994. Comparisons between fuzzy reasoning and neural network methods to forecast runoff discharge. *Journal of Hydroscience and Hydraulic Engineering* 12 (2), 131-141.

計畫成果自評

本研究計畫為期三年，第一年應用全面監督式訓練法建立 RBFN，並應用於翡翠水庫集水區之水庫入流量預測，且預測效果相當良好。第二年結合 RBFN 與變異元理論而建立一個空間內插模式，稱之為 IRBFN 模式(Improved RBFN Model)，並應用於雨量內插估計，測試結果顯示 IRBFN 模式均較其他兩種方法（克利金法及標準 RBFN 模式）擁有較高之估計準確度。第三年研究結合 SOM 與 RBFN 於時間序列之預測，此模式稱之為 SOM-RBFN 模式，並以台灣南部地區秀林地下水位站之地下水位資料進形測試，結果發現此模式較 ARIMA 模式有較佳之預測精確度。

在計畫期間，本人持續針對 ANN 進行一系列有系統的研究，逐步擴展 ANN 模式於水文領域應用的範圍，全部的研究內容均與原計畫相符，預期目標亦完全達成，計畫成果業已分別發表於知名期刊 *Journal of Hydrology* (Lin and Chen, 2004a; Lin and Chen, 2004b; Lin and Chen, 2006; Lin and Wu, 2007)、*Hydrological Processes* (Lin and Chen, 2005a; Lin and Chen, 2005b; Lin and Chen, 2007)與 *Advances in Water Resources* (Lin and Wang, 2006)，至目前為止共計已有八篇 SCI 之期刊論文發表。而論文一經發表，隨即獲得國際間相關學者的認同，部分學者立即跟進並從事相關研究，被引用次數亦甚多。另外，本計畫不但研究成果豐碩，更對於培育後起研究人才貢獻良多。在計畫期間，本人所領導之研究團隊，除原定研究內容之外，也不斷以最新研究成果為基礎，進行許多衍生的相關研究，足見本計畫深具學術價值，在未來必將引領更多突破性的相關研究，進而對全球性的水資源問題提供較佳的解答與協助。

亞洲大洋洲地球科學學會第四屆年會

林國峰

國立台灣大學土木工程學系

一、參加會議經過

亞洲大洋洲地球科學學會 (Asia Oceania Geosciences Society, AOGS) 的第四次年會於泰國曼谷舉行。該學會創立之主要目的為提升地球科學研究水準，並據以增進亞洲和大洋洲地區公共利益。每年均舉辦年會，供會員進行交流以促進知識流通。例行舉辦之年會主要的焦點在於與地球科學領域相關的科技，諸如水文科學、海洋科學、大氣科學、行星科學等重要科目以及各學科之跨領域整合研究。年會參與人數眾多，專業氣息濃厚，學術地位頗高。今年的大會在泰國曼谷 The Queen Sirikit National Convention Center (QSNCC) 舉行，會議日期自 2007 年 7 月 31 日至 8 月 4 日共計五天。

本次年會的主題包含七個不同領域之學科，而本人參與的以水文科學(Hydrological Science)為主，而其中再細分為若干子題。論文宣讀由 2006 年的十二個分組增為十八個平行分組，分別為：(1) GEOS (Global Earth Observation System of Systems), CEOP (Coordinated Enhanced Observing Period) and MAHASRI (Monsoon Asian Hydro-Atmosphere Scientific Research and Prediction Initiative)、(2) 氣

候變化動力學及水文學：弱點及改進(climatic change dynamics and hydrology: vulnerability and adaptation)、(3)氣候改變及河川流域經營 (climate change and river basin management)、(4)統計及序率水文學 (statistical and stochastic hydrology)、(5)地下水文學及經營 (groundwater hydrology and management)、(6)亞洲河川之水與泥沙變化(water and sediment discharge changes of Asian rivers)、(7)未設測站流域之預報(predictions in ungauged basins)、(8)東南亞地區季節性至長時間氣候變異性及水文學 (seasonal to inter-decadal climate variability and hydrology in the southeast Asia region)、(9)洪水及洪水預報：減輕災害並提昇效益(flood and flood forecasting: reduce miseries and enhance the benefits)、(10)雷達水文學(radar hydrology)、(11)地下水污染評估及預報 (assessment and prediction of groundwater contamination)、(12)受干擾下之生態水文學 (ecohydrology of disturbance)、(13)整合性水資源經營及都市流域之工具及應用之進展 (advances in tools and applications for integrated water resources management and urban watersheds)、(14)水文過程之統計模擬及分析 (statistical modeling and analysis of hydrologic processes)、(15)極端氣候及氣候變異性方案之研發 (development of scenarios of climate extremes and climate variability)、(16)整合性水資源經營(integrated water resources management)、(17)都市洪水水文學(urban flood

hydrology)、(18)地震水文學及水文地震學(earthquake hydrology and hydroseismology)。

此次會議發表之論文經篩選後共有 1424 篇，論文除會議前之初審外，若欲刊登於專書需再經一次審查，且第二次審查須經過二位學者審查通過方能出版，因此論文有相當高的學術水準。專書將交由 World Scientific 出版社出版，預定名稱為“Advances in Geosciences, Vol. 6”。

本人不僅於 2007 年 8 月 3 日於整合性水資源經營分組中宣讀論文「A nonlinear computational units cascaded model for flood forecasting」，亦於同日下午擔任 HS17 兩個分組討論的主席 (Session Chair)。會議進行時，雖同一時段有多個分組同時進行論文宣讀，但與會者可隨個人興趣自由進出各分組會場。另外亦有海報論文、學會及廠商展示攤位，與會者亦可於休息時段獲得相關資訊。

二、與會心得

此次會議探討主題極為廣泛，參與的學者亦非常眾多，因此只能就最有興趣的分組去聽講，所以難免有遺珠之憾，此為平行分組無法避免的缺點。本次會議中，除有來自亞太地區之學者外，亦有來自歐洲與美洲的學者，因此可說是世界型之會議。在此會議中，筆者除經由聆聽論文宣讀可獲得寶貴的訊息與啟發研究思想外，亦得以和世界

各國學者交換研究經驗、思索未來的研究方向及討論未來可能的合作研究，對筆者未來的研究與教學有極大的裨益。本次會議令筆者印象最深刻的為參與人數眾多，討論科目廣泛，所參與之論文數為歷來之最。讓筆者得有機會進一步瞭解水文科學之新技術，拓展個人的視野。整體而言，會場的討論非常熱絡，顯示出世界各地水文科學研究的蓬勃進展，也顯示出亞太地區在發展過程中對水文科學技術的需求。依筆者之見，隨著亞太地區的工業化、都市化，亞太地區將會面臨更多的水文科學問題，尤其是管理及生態方面的問題，未來此方面的研究將會更多。水文科學和水資源問題因地而異，其解決方法也常因地而異，此次會議提供了良好的場所讓與會人士去瞭解它國的問題與解決方法，可據以改善我國解決水文問題的方法，亦增進了水文科學的交流與發展，同時個人的視野也得以拓展。

以本人多次參加國外學會所舉辦的國際性會議經驗而言，透過參加國際性學術會議能與世界上之頂尖研究人才交流，獲知最新研究主題與方向。若有機會，我國也應要多舉辦國際性的學術會議，一方面可展現我國的研究成果，另一方面也可以增進我國在國際學術上的地位。

A NONLINEAR COMPUTATIONAL UNITS CASCADED MODEL FOR FLOOD FORECASTING

Gwo-Fong Lin, Chun-Ming Wang, Ming-Chang Wu, Guo-Rong Chen

Department of Civil Engineering, National Taiwan University, Taipei 10617, Taiwan

Abstract

To improve the forecasting of flood, a nonlinear computational units cascaded (NCUC) model is proposed in this paper. The NCUC model can overcome two traditional problems of the ANN (artificial neural networks)-based forecasting models. These two problems both result from the construction of the memory of the rainfall-runoff process. The proposed NCUC model is embedded with an automated calibration method. A popular and robust optimization technique, the simple genetic algorithm (SGA), is introduced as the basis of the automated calibration method for NCUC model. The NCUC model is quite flexible to meet the modelers' requirements. Modelers can freely choose the number of the cascaded NCUs and the configurations of the NCUs to build the NCUC model. An actual application of the NCUC model to forecast the one-hour-ahead flood is also presented in this paper. The results show that the performance of the NCUC model is outstanding. The NCUC model is expected to be a useful model for flood forecasting.

Keywords: flood forecasting; nonlinear computational units cascaded model; artificial neural networks

Introduction

Currently, two types of methods for flood forecasting (FF), which are respectively based on conventional rainfall-runoff (CRR) models, such as the TOPMODEL (Beven, 2001), and the artificial neural networks (ANN), have been applied for flood forecasting. However, problems that need to be solved exist in actual applications of these two types of methods.

Typically, methods for flood forecasting, which are accomplished based on the CRR models (abbreviated as the CRR-FF methods herein), as indicated by Beven (2001), involves two sequential phases, and the data requirements are different during the two phases. The two phases are the calibration phase and forecast phase, respectively. The kernel of the CRR-FF methods is a CRR model which is employed to represent the rainfall-runoff process. Therefore, the first phase (i.e., the calibration phase) of the CRR-FF methods is to adjust the CRR model, so that

the CRR model can appropriately model the rainfall-runoff process. It should be noted that the CRR model mentioned herein constructs the current-state relation of the rainfall and the runoff. For clarity, the following equation is used:

$$Q(t) = \text{CRR}(p_i(t)) \quad i = 1, 2, \dots, g \quad (1)$$

where $\text{CRR}(\)$ is the CRR model, $p_i(t)$ is the rainfall of gage i at time t , and g is the number of rain gages, $Q(t)$ is the runoff at time t . In this paper, $p_i(t)$ is treated as the input and $Q(t)$ is treated as the output of the CRR models, respectively.

For CRR-FF methods, flood forecasting is made at the forecast phase, and the data requirement is different from that at the calibration phase. At the forecast phase, it can be found from Eq. (1) that the CRR-FF methods require the rainfall forecast as their input so that the future runoff can then be forecasted. For clear explanation, the following equation is used:

$$Q(t+1) = \text{CRR}(p_i(t+1)) \quad i = 1, 2, \dots, g \quad (2)$$

where $p_i(t+1)$ is the rainfall of gage i at time $t+1$, $Q(t+1)$ is the runoff at time $t+1$ and others are as defined above. The CRR-FF methods need additional work to acquire the rainfall forecast to enable the forecast. This additional work increases the burden of the hydrologists who employ the CRR-FF methods. Furthermore, the precision of the rainfall forecast obviously influences the forecast accuracy of the CRR-FF methods.

The forecast accuracy of the CRR-FF methods is another notable matter and is influenced by two crucial factors. One, as aforementioned, is the precision of the rainfall forecast, and the other is the modeling accuracy of the CRR models. From the present viewpoint, the accuracy of the CRR models, which highly depends on the appropriateness of the model parameters, is perhaps not comparable to that of the methods for flood forecasting based on the artificial neural networks. The evidences regarding the accuracy of the CRR models can be found, for instance, in Todini (1996) and Franchini et al. (1996). The CRR-FF methods are difficult to be applied without an ACM, because the manual calibration of the parameters of the CRR model does require much time and can be done by experienced engineers only. Therefore an ideal CRR-FF method should have an ACM. Moreover, the accuracy of the CRR-FF methods is improved, if the CRR-FF methods had ACMs.

Artificial neural networks (ANN) nowadays are widely used for flood forecasting. Papers discussing the ANN-FF methods are quite numerous (Anctil et al., 2006; Aqil, 2007; Baratti, 2003; Bruen, 2005; Chang et al., 2002; Lin and Chen, 2004). The foundation of the ANN-FF methods is the relation between the future

runoff, and the current rainfall and runoff, and the previous rainfall and runoff. The future runoff is the output of the ANN-FF methods. The input of the ANN-FF methods is the current rainfall and runoff, and the previous rainfall and runoff. The ANN in the ANN-FF methods is the mapping of the input to the output. There are many categories of the ANN-FF methods, and their differences are the ANNs that are used to build the input-output mapping. In the ANN-FF methods, the ANNs employed evolve from the feed-forward networks (Anctil et al., 2006; Aqil, 2007; Baratti, 2003; Bruen, 2005; Lin and Chen, 2004) to recurrent networks (Aqil, 2007; Chang et al., 2002), etc. The strategy adopted by the various ANN-FF methods for flood forecasting is identical and hence they have common shortcomings. The strategy and shortcomings are explained using the following equation, which is also the general description of the ANN-FF methods:

$$Q(t+1) = \text{ANN}(p_i(t), p_i(t-1), \dots, p_i(t-k), Q(t), Q(t-1), \dots, Q(t-h)) \quad i = 1, 2, \dots, g \quad (3)$$

where $\text{ANN}(\)$ is the network used by the ANN-FF methods; $p_i(t)$ is the rainfall of gage i at time t , $p_i(t-1)$ is the rainfall of gage i at time $t-1$, and so on; $Q(t+1)$ is the runoff at time $t+1$, $Q(t)$ is the runoff at time t , $Q(t-1)$ is the runoff at time $t-1$, and so on; k and h are the numbers of time delays of the rainfall and runoff, respectively. From Eq. (3), it can be found that the strategy of the ANN-FF methods is to take all available rainfall and runoff records as their input.

Two shortcomings of the ANN-FF methods, which are caused by the required data, are the memory (i.e., the temporal dependency between the input and output) (Haykin, 1999) construction within the networks and the requirement of the runoff data. The first shortcoming results from the evaluation of the memory length (i.e., the degree of the temporal dependency between the input and output). That is the magnitudes of the variables k and h in Eq. (3) must be carefully determined. The procedure to evaluate the k and h in Eq. (3) is called the system identification. The system identification can be done by trial and error (Luk et al., 2000) cross-correlogram (Sajikumar and Thandaveswara, 1999) or the corner method (Lin and Chen, 2007). The second shortcoming is the requirement of the current runoff and the previous runoff as the input. As is well known, it is dangerous to measure the runoff during a severe flood. The requirement of the runoff data also results in the difficulty in applying the ANN-FF methods. These two shortcomings confine the usability of the ANN-FF methods.

The purpose of this paper is to propose a method for flood forecasting based on the nonlinear computational units cascaded (NCUC) model which is embedded with an automated calibration method (Lin and Wang, 2007a, b). The concept of the

proposed method is simple so that hydrologists can employ the proposed method without difficulty. Moreover, the aforementioned shortcomings of the CRR-RF methods and the ANN-RF methods are overcome by the proposed method. Actual applications of the proposed method are also given in this paper to demonstrate the capability of the proposed method.

The NCUC model

The NCUC model, which is firstly developed by Lin and Wang (2007a, b), is originally used for the rainfall-runoff modeling. The building block of the NCUC model is the NCUs (nonlinear computation units). There are four different types of the NCUs. The configurations of the NCUs can be selected arbitrarily by the modelers. The NCUC model is built by cascading several NCUs. A specific ACM which is based on the simple genetic algorithms (SGA) is also proposed to facilitate the modelers obtaining the parameters of the NCUC model. The modeling performance of the NCUC model is outstanding. It is concluded that the NCUC model is an effective and efficient tool for the rainfall-runoff modeling. For detailed explanations of the corresponding ACM and the modeling performance, please refer to Lin and Wang (2007a, b)

The method for flood forecasting based on the NCUC model

The method proposed herein is for flood forecasting and is based on the NCUC model. Therefore it is abbreviated as the NCUC-FF method in this paper. The flood at one hour ahead is forecasted. The data requirement of the NCUC-FF method is quite simple, and is unlike that of the CRR-FF and the ANN-FF methods. The following equation is used to explain the NCUC-FF method:

$$ED(t+1) = NCUC(P(t)) \quad (4)$$

where $P(t)$ is the areal average rainfall at time t , $NCUC(\)$ is the NCUC model, and $ED(t+1)$ is the equivalent depth at time $t+1$. The core of the NCUC-FF method is Eq. (4). $P(t)$ is the input and $ED(t+1)$ is the output of the NCUC model. Unlike the CRR-FF and the ANN-FF methods, the NCUC-FF method only takes the current rainfall as its input to produce the forecast of flood. Therefore, its usage is simpler than that of the CRR-FF and the ANN-FF methods.

For conforming to the common unit of the runoff (m^3/s or ft^3/s), the equivalent depth at time $t+1$ should be transformed into the proper unit using the following equation:

$$Q(t+1) = \frac{ED(t+1)A}{T} \quad t = 1, 2, \dots, q \quad (5)$$

where A is the watershed area, and T is the time interval for sampling the data. $Q(t+1)$ is the runoff at time $t+1$ and is the final output of the NCUC-FF method. The units of A and T should be carefully selected according to the unit of $Q(t+1)$ for the dimensional homogeneity.

The NCUC-FF method has an ACM, and therefore the model parameters can be easily obtained. The objective function used in this paper to calibrate the NCUC model within the NCUC-FF method is the simple least square (SLS):

$$\text{SLS} = \sum_{t=1}^n (Q(t) - \hat{Q}(t))^2 \quad (6)$$

where $\hat{Q}(t)$ and $Q(t)$ are respectively the forecasted and the observed runoff, \bar{Q} is the average observed runoff, and n is the number of data elements. A smaller value of the SLS implies the better performance.

Study area and data set

The study area of this paper is the Shih-Men Reservoir Watershed which is the third largest reservoir in Taiwan. The area of the study watershed is 763.4 km², and the total length of the streams in the watershed is 352.63 km. The annual average rainfall depth is 2,444.4 mm. Fig. 1 shows the study area and the locations of rain gauges and one water-level station. The original purposes of the water use of the Shih-Men Reservoir are to provide the water use in agriculture and are for flood control. However, due the transition of the society in Taiwan, the main purpose of the Shih-Men Reservoir is now changed to provide the municipal water use. In the area where the water is supplied by the Shih-Men Reservoir, the population grows rapidly and the demand of water increases consequently. For better operation of the reservoir, an accurate flood forecast is of great demand.

The information of the data set employed in this paper are four typhoon events. The data set is divided into two subsets which both have two typhoon events. One subset is used for the calibration of the NCUC model within the NCUC-FF method and is called the subset I. The other is to be forecasted and is called the subset II. The hyetographs of the areal average rainfall of the subsets I and II are depicted in Figs. 2 and 3. The observed hydrographs of the four events are drawn in Figs. 4 and 5.

Results and discussions

The optimal pattern of the NCUC model within the NCUC-FF method is determined by the strategy given in Lin and Wang (2007a, b). The optimal pattern selected in this paper is {D2, D2, D2, D2}. Regarding the notation of the model

pattern (i.e., {D2, D2, D2, D2}), please refer to Lin and Wang (2007a, b). The NCUC model of the optimal pattern is calibrated respectively using the objective functions SLS. The corresponding 1-hour-ahead forecasted hydrographs for the calibration and for the forecast are drawn in Figs. 4 and 5. From the figures, it can be found that the 1-hour-ahead forecasted hydrographs closely meet the observed ones.

For quantifying the performance of the NCUC-FF method, four frequently used performance criterion functions are used. They are (1) Error of peak runoff, (EQ_p), (2) Error of total runoff volume (EV), (3) Coefficient of determination (R^2), (4) Root mean square error (RMSE), and (5) Efficiency coefficient (EC).

The values of these performance criteria of the results derived from the NCUC-FF method which is calibrated using SLS are summarized in Table 1. It can be seen from the table that the performance of the NCUC-FF method is outstanding.

The hydrograph of the last typhoon event is a relative complex one, because it has two significant peaks. The other hydrographs are relative simpler to that of the last typhoon event. Though the NCUC model within the NCUC-FF method is calibrated using simpler events, it can be used to forecast more complex events. Furthermore, as indicated by Anctil et al. (2006), the ANN-FF methods require runoff records as their input to well produce the rising limb and recession of the hydrographs, because at that portions of the hydrographs there are many zeros of the rainfall depth records. However, the NCUC-FF method can excellently produce the rising limb and recession of the hydrograph with taking the rainfall depth records as its input only.

Conclusions

The shortcomings of the CRR-FF methods are the requirement of the rainfall forecast and the absence of an ACM. The shortcomings of the ANN-FF method are the requirement of the system identification and the current runoff as the input. The NCUC-FF method proposed in this paper does not need rainfall forecast as its input. The memory between the input and output is involved within the NCUC model and thus the job of the system identification can be seamlessly done. Since the memory is implicitly constructed within the NCUC model, the NCUC-FF method requires only the rainfall data as its input. Moreover, the NCUC-FF method provides the flexibility that allows hydrologists choosing the model patterns to meet the characteristics of watersheds and has an ACM to help hydrologists obtain appropriate model parameters. Actual applications for flood forecasting using the NCUC-FF method are conducted in this paper. The evaluation of the

forecasting performance is also given and the results show that the forecasting performance is outstanding. Especially, the rising limb and the recession of hydrographs forecasted by the NCUC-FF method are quite excellent even without employing the runoff records as its input. Therefore, it is concluded that the NCUC-FF is an alternative method of great potential for flood forecasting.

References

- Anctil, F., Lauzon, N., Andreassian, V., Oudin, L., Perrin, C., 2006. Improvement of rainfall-runoff forecasts through mean areal rainfall optimization. *Journal of Hydrology* 328(3-4), 717-725.
- Aqil, M., Kita, I., Yano, A. Nishiyama, S., 2007. Neural networks for real time catchment flow modeling and prediction. *Water Resources Management* 21(10), 1781-1796.
- Baratti, R., Cannas, B., Fanni, A., Pintus, M., Sechi, G.M., Toreno, N., 2003. River flow forecast for reservoir management through neural networks. *Neurocomputing* 55(3-4), 421-437.
- Beven, K.J., 2001. *Rainfall-runoff modelling : the primer*. John Wiley, New York.
- Bruen, M., Yang, J.Q., 2005. Functional networks in real-time flood forecasting - a novel application. *Advances in Water Resources* 28(9), 899-909.
- Chang, F.J., Chang, L.C., Huang, H.L., 2002. Real-time recurrent learning neural network for stream-flow forecasting. *Hydrological Processes* 16(13), 2577-2588.
- Chow V.T., Maidment D.R., Mays L.W., 1988. *Applied hydrology*. McGraw-Hill, New York.
- Franchini, M., Wendling, J., Obled, C., Todini, E., 1996. Physical interpretation and sensitivity analysis of the TOPMODEL. *Journal of Hydrology* 175(1-4), 293-338.
- Haykin S., 1999. *Neural Networks: a comprehensive foundation*. Prentice Hall, New Jersey.
- Lin G.F., Chen L.H., 2004. A non-linear rainfall-runoff model using radial basis function network. *Journal of Hydrology* 289(1-4), 1-8.
- Lin G.F., Chen G.R., 2007. A systematic approach to the input determination for neural network rainfall-runoff models. *Hydrological processes*. DOI: 10.1002/hyp.6849. (published online)
- Lin G.F., Wang C.M., 2007a. A nonlinear rainfall-runoff model embedded with an automated calibration method. Part 1. The model. *Journal of Hydrology* 341(3-4), 186-195.
- Lin G.F., Wang C.M., 2007b. A nonlinear rainfall-runoff model embedded with an automated calibration method. Part 2. The automated calibration method. *Journal*

of Hydrology 341 (3-4), 196-206.

Luk, K.C., Ball, J.E., Sharma, A., 2000. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *Journal of Hydrology* 227(1-4), 56-65.

Nash, J.E., Sutcliffe, J.V., 1970. River flow forecasting through conceptual models. Part 1: A discussion of principles. *Journal of Hydrology* 10(3), 282–290.

Sajikumar, N., Thandaveswara, B.S., 1999. A non-linear rainfall–runoff model using an artificial neural network. *Journal of Hydrology* 216(1-2), 32-55.

Todini E., 1996. The ARNO rainfall-runoff model. *Journal of Hydrology* 175(1-4), 339-382.

Table 1 Performance of the NCUC-FF method

	Subset Performance criterion function				
	EC	RMSE (m ³ /s)	EV (%)	EQ _p (%)	R ²
I	0.99	103.90	-0.63	-2.26	0.99
II	0.99	82.86	-0.82	-8.02	0.99

*The NCUC model within the NCUC-FF method is calibrated using the objective function SLS.

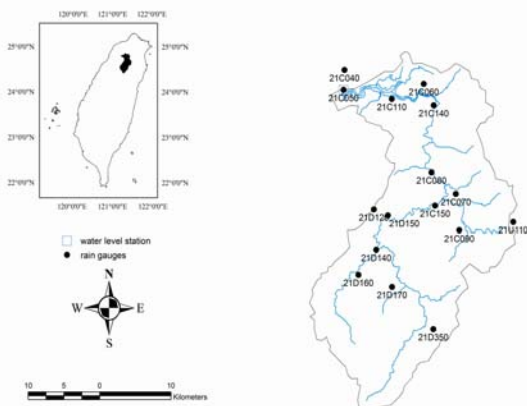


Fig. 1 The Shih-Men Reservoir Watershed in Taiwan.




Fig. 2 The hyetographs of the areal average rainfall for the subset I.




Fig. 3 The hyetographs of the areal average rainfall for the subset II.




Fig. 4 The observed and 1-hour-ahead forecasted hydrographs for the subset I. The NCUC model within the NCUC-FF method is calibrated using the objective function SLS.




Fig. 5 The observed and 1-hour-ahead forecasted hydrographs for the subset II. The NCUC model within the NCUC-FF method is calibrated using the objective function SLS.