

結合自組織映射圖網路與輻狀基底函數網路 於地下水位預測之研究

Study on Groundwater Level Forecasting by Combining the Self-Organizing Map and the Radial Basis Function Network

致遠管理學院
觀光資源與環境學系
助理教授

陳 儒 賢*

Lu-Hsien Chen

國立嘉義大學
土木與水資源工程學系
副教授

陳 濟 田

Ching-Tien Chen

國立嘉義大學
土木與水資源工程學系
碩士班研究生

潘 汧 谷

Yan-Gu Pan

國立嘉義大學
土木與水資源工程學系
碩士班研究生

林 典 蔚

Dian-Wei Lin

摘 要

台灣受全球持續暖化所引發氣候變遷之衝擊，致水文環境有重大改變，且氣候變異現象亦加劇北澇南旱之趨勢，更凸顯水資源經營管理之重要性；而台灣於短期內難以開發新地表水資源。於有限水資源前提下，如何利用地下水資源實乃一重要課題。本研究結合自組織映射圖網路與輻狀基底函數網路之理論，建置一地下水位預測模式稱為 SOM-RBFN 模式，並將此模式應用於雲林斗六地區六個地下水水位站(自 1997 年 8 月至 2003 年 12 月)之月平均地下水水位預測上。首先，先以 SOM 所得之二維密度圖解決傳統 RBFN 網路於訂定隱藏層神經元數目及中心點之不確定性問題，再者，利用 RBFN 之原理運算隱藏層至輸出層間神經元之權重值。而經本研究結果顯示，應用多站預測單站之月平均地下水水位結果較單站預測單站之精確度為高，然而多站之數量並非越多越好，其與模擬結果之精度並非成完全正比。此外，由於 SOM-RBFN 模式擁有較簡單之網路架構及簡易之學習演算法則，且多站預測模式相對地擁有更佳之精確度，因此建議可應用多站 SOM-RBFN 模式於地下水位之預測上。

關鍵詞：地下水，輻狀基底函數網路，自組織映射圖。

ABSTRACT

Taiwan is subjected to correlation influence of global warming and climatic changes

*通訊作者，致遠管理學院觀光資源與環境學系助理教授，72153 台南縣麻豆鎮南勢里 87 之 1 號，lhchen@dwu.edu.tw

causes the significant changing of hydrology environment. The warming current of Taiwan is the same as global's, and intensifies the tendency of north waterlogging and south drought. Thus, it demonstrates the importance of water resource management. However, it is difficult to search new surface water resource in the short term in Taiwan. Therefore, the groundwater use plays a decisive role under using the premise of limited water resource. In this paper, a groundwater level forecasting model is proposed by combing the theory of self-organizing map (SOM) and radial basis function network (RBFN). It is examined by simulated six groundwater stations's data in Douliou city, Yunlin county. Traditionally, the number of hidden units and the positioning of the radial basis centers are crucial problems for establishing RBFN. The result shows that proposed model can decide the number of RBFN's hidden units with using the two-dimensional feature map which is constructed by SOM, and then it can determine the positioning of the radial basis centers easily. Finally, the proposed model is applied to actual groundwater head data. It is found that the proposed model which with mult-stations' data can forecast more precisely than single. For groundwater level forecasting, the proposed model which with mult-stations' data is recommended as an alternative to the other method, because it has a simple structure and can produce more reasonable forecasts.

Keywords: Groundwater, Radial Basis Function Network, Self-Organizing Map.

一、前言

1.1 研究動機

近年全球暖化現象日趨嚴重,2007年4月聯合國跨國氣候變遷委員會(Intergovernmental Panel on Climate Change, IPCC)公佈之最新研究,再度對全球暖化問題發出警訊並指出氣候變遷的問題越來越迫近,應著手改進人類排放溫室氣體的情況。就台灣而言,從1990年至2004年二氧化碳總排放量倍速成長111%,為全球成長值的四倍,每人平均年排放量超過十二噸,是全球平均值的三倍(蕭富元,2007)。由1940年至2003年之長期氣象資料得知降雨僅北部有增加之趨勢,西南部及東部則逐漸降低,南北區域性的水文差異亦正逐漸擴大中,北澇南旱趨勢顯著;且南北降雨天數逐年降低,使得降雨集中,強度更強(汪中和,2004)。

臺灣本島年降雨量925.92億噸,其中無法利用之年蒸發量占26.31%,且年逕流入海水量占年逕流量55.02%,而可供利用之年引用河水量、水庫調節水量及抽用地下水量僅佔18.67%,

其中地表與地下水資源之年總供應量之比例約為7比3(經濟部水利署,2005),顯示台灣可供利用之水資源實屬相當有限。而台灣因尚須考慮符合環境生態等因素影響之下,於短期內難以開發新地表水資源;因此,地下水資源管理與利用之相關研究,便日益彰顯其重要性。

綜合上述,可知台灣地區之水文環境正持續改變中,進而導致水資源的重新分配亦將影響並挑戰水資源利用與管理。因此,於有限水資源的前提下,當地表水資源開發不易之時,倘若能更加掌握地下水資源之動態,將對水資源之有效利用與永續發展提供實質裨益。

1.2 研究目的

水文推估模式一般可分為定率式與序率式,前為應用數理方程式構成水文模式以模擬自然界水文的物理現象;然而,數值方法之地下水模型往往需有簡化之假設以利分析之用,且模式中地文與水文參數之區域性更須因時間進行校正調整,使得概念模式實際應用上受到限制;後則以統計方法,依過去實測水文記錄,歸納其特

性與關係，藉此推估未來之水文狀況，且近年加上計算機能力提升及觀測資料自動化，已累積相當之水文觀測紀錄資料。而與相關預測理論結合，蔚為研究趨勢；然而，地下水水位預測之相關研究多以時間序列分析模式(ARIMA 法)及灰色理論見常，少有類神經網路之預測模式。故本研究結合自組織映射圖(Self-Organizing Map; SOM)與輻狀基底函數(Radial Basis Function Network; RBFN)之類神經網路架構地下水水位預測模型，並進而探討運用單站地下水水位資料模式與多站地下水水位資料模式之模擬結果，期望能建構更準確預測地下水水位變化之模型，冀以有效提昇水資源之調配與利用。

二、文獻回顧

地下水資源為重要供應水資源之一，因此若能掌握地下水水位之變化，將可供水資源調配與規劃之用，且亦可供地層下陷等相關研究之參考。然地下水水位之變動量呈現週期性地隨機變動，且受無法控制的因素影響而預估不易，而近年地下水水位預測相關研究盛行。其中，Lallahem 等(2005)指出地下水水位模式之物理機制過於複雜使得數學式建構不易，故藉類神經網路建構多層感知機之預測模式，並以 RMSE 及 CE 評估結果，結果顯示模式預估之效果良好。陳儒賢等(2006)以雲林地區秀林水位站之地下水水位資料，分別以 SOM-RBFN 模式與 ARIMA 模式建立時間預測模式，研究結果顯示 SOM-RBFN 模式較 ARIMA 模式之預測精確度佳。Lin and Chen (2005)，亦結合 SOM 與 RBFN 之類神經網路模式於時間序列預測之研究中，結果顯示其模式架構簡單且具較佳之預測精準度。由前人研究可知以輻狀基底函數網路為基礎，應用於時間序列預測上效果頗佳，故以輻狀基底函數網路為基礎架構，並輔以自組特徵映射確立其隱藏層神經元數量及中心位置，以建構類神經網路之地下水水位預測模式。

三、分析理論

3.1 類神經網路(Artificial Neural Network)

傳統數學模式在面對複雜及非線性之自然




圖 1 類神經元模型

現象時，常需經由些許假設簡化後才得以建構物理模式或數學方程式，而類神經網路為近年所發展出之模擬器，其為一仿生物大腦與神經網路之資訊處理系統，僅需藉由學習訓練便可面對複雜問題與不確定性環境，而隨著計算機科技之發展與進步以及資料記錄儀器技術之發達，使得類神經網路迅速發展。直至今日已有眾多研究提出各式各樣類神經網路。主要優點為：高度平行化處理能力、非線性近似能力佳、良好學習與記憶能力、具容錯能力等。

類神經元(如圖 1)為神經系統中最小之訊息處理單元，亦為類神經網路系統之運作基礎，可接受外界訊號之輸入，再經活化函數整合後輸出至下一層，而由多個平行結構之類神經元組成一網路層，再由數個網路層架構一類神經網路系統。而基本架構包含：(1)鍵結權重值(Synaptic Weight)：仿不同生物神經元間觸突連結強弱，權重值為正表示增強而為負則為抑制，鍵結強弱與絕對值大小成正比。(2)輸入訊號疊加器(Summation Function)：仿生物神經元受多方刺激時膜電位之總變化量，即輸入訊號經加權後由疊加器線性疊加後輸出供後續運算。(3)轉換函數(Transfer Function)：原為仿生物神經元動作電位之門檻值，然目前大多作為正規化之用，而轉換函數一般採用非線性函數可避免漏失輸入資料(Input Data)之非線性特性。

3.2 輻狀基底函數網路(RBFN)

輻狀基底函數網路(Radial Basis Function Network)最早概念由 Hardy (1971)提出，而 Powell (1987)以不規則位置之資料點，求得相對應之輻




圖 2 RBFN 網路架構示意圖

基底函數並建立其網路架構，Broomhead and Lowe (1988)將之應用於數值逼近以及內插問題，而後類似網路結構之 RBFN 相繼提出。RBFN 屬多層前饋式網路架構，其藉由建構眾多輻狀基底函數於隱藏層各神經元中，再藉函數逼近方式求得輸入與輸出訊息間之映射關係，其網路架構如圖 2 所示。一般 RBFN 具有三特點：(1)網路架構與多層感知機相同，僅為輸入、隱藏及輸出三層結構；(2)輸出層完全由線性處理單元組成；(3)隱藏層中神經元之激發乃藉由輸入資料與隱藏層神經元中心之歐基里德範數(Euclidean norm)決定。主要優點乃能將訓練樣本之隱含資訊，有系統地儲存於隱藏層各神經元中，且僅需使用簡單矩陣運算即可求得隱藏層與輸出層間之鍵結權重值，無需於訓練階段時設定許多網路參數值，亦因此 RBFN 於鑑別非線性系統是具有相當效率之工具，只須適當設定訓練停止條件即可完成模式訓練。

RBFN 架構之中，若於輸入層接收到具有 n 個輸入變數之資料 X ，則輸入向量 $X = [x_1, x_2, x_3, \dots, x_n]^T$ ，其藉輸入層傳遞至隱藏層神經元中，並以輸入向量與隱藏層各神經元中心位置向量之歐式距離最小者，作為欲激發之隱藏層神經元。而隱藏層各神經元之輸出值 $z_j(x)$ ，可表示成下式：

$$z_j(x) = \phi(\|x - c_j\|) \quad j = 1, 2, 3, \dots, m \quad \dots\dots\dots (1)$$

其中， $\phi(\)$ ：輻狀基底函數。 $\| \ \|$ ：歐基里德範數(Euclidean Norm)。 c_j ：隱藏層第 j 個神經元之

中心位置向量。 m ：隱藏層神經元之數目。輻狀基底函數之型態有很多，如高斯函數(Gaussian Function)、薄平面曲線函數(Thin-Plate-Spline Function)、二次多變數函數(Multiquadric Function)及二次多變倒數函數(Inverse Multiquadric Function)等型態。本研究中乃採用地下水領域中廣泛運用之高斯函數，以其為 RBFN 隱藏層神經元之輻狀基底函數，而其數學式如下所示：

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

其中， σ 為高斯函數之寬度值，可由下式求得 (Haykin, 1994)。

$$\sigma = \frac{d_{\max}}{\sqrt{2m}} \quad \dots\dots\dots (3)$$

其中， d_{\max} ：訓練樣本資料中，輸入向量間之最大距離； m ：隱藏層神經元之數目。隨後乃計算所有輸入向量傳遞至隱藏層後，經各神經元之輻狀基底函數輸出結果，再利用最小平方法(Least Squares Method)求得隱藏層與輸出層間之鍵結權重值，並將隱藏層各神經元輸出值乘上各鍵結權重值即進行加權，而後可得輸出層之輸出值 y ，如下式所示：

$$y = w_0 + \sum_{j=1}^m z_j(x) \cdot w_j \quad \dots\dots\dots (4)$$

其中， y ：輸出層之輸出值。 w_0 ：偏差(bias)。 $z_j(x)$ ：第 j 個隱藏層神經元之輸出值。 w_j ：隱藏層中第 j 個神經元至輸出層間之鍵結權重值。

傳統 RBFN 之建構過程有兩大重要步驟。首先乃是訂定隱藏層神經元之個數與中心位置，而後為求解隱藏層至輸出層間之鍵結權重。最主要之差異乃是第一步驟隱藏層神經元中心位置之決定，其為建構 RBFN 之極為重要因素；過去常用群集分析(Cluster Analysis)以決定 RBFN 隱藏層神經元之中心位置及數目。群集分析可分階層式(Hierarchical)及非階層式(Non-Hierarchical)群集分析。其中，階層式之群集分析法乃依據分析後所得之樹狀圖，以瞭解資料間之相對距離，但




圖 3 SOM 網路架構示意圖

無客觀決定群集組數之方式，端賴研究者之需求及經驗訂定。非階層式則需於分析前決定群集組數，然不同之群集組數常會使得分析結果有顯著差異。因此，本研究則採用自組織映射圖網路 (Self-Organizing Map, SOM) 以克服上述之缺憾；有關 SOM 網路之架構及學習方法則敘述於下節。

3.3 自組織映射圖網路(SOM)

自組織映射圖網路主要用於架構本研究 SOM-RBFN 模式中輸入層至隱藏層神經元間之拓樸映射關係，故稱之為 SOM 階段，屬前饋式、非監督式學習網路，係由 Kohonen 於 1982 年所提出，其網路架構如圖 3 所示。其主要功用乃將高維度輸入樣本資料(Input Pattern)轉換至其它維度，常用於高維度輸入樣本映射至低維度空間以得到輸出資料；而本模式中隱藏層各神經元之排列方式可為一維線線性式(Linear)排列、二維網格式(Lattice)排列或者更高維度之排列方式等等，而本文則以較為常用之二維網格式排列來輸出拓樸映射圖。

SOM 之學習過程中包含三個重要的程序，分別是競爭程序(competitive process)、合作程序(cooperative process)及調整程序(adaptive process)，其演算過程敘述如下。

3.3.1 競爭程序(competitive process)

若輸入樣本資料具 m 維度如(5)式，則輸入層與隱藏層中各神經元間鍵結權重向量亦具相同維度 m ，而各神經元鍵結權重之初始值乃以隨

機變數產生，其中優勝神經元之權重則如(6)式。

$$X = [x_1, x_2, x_3, \dots, x_m]^T \dots\dots\dots(5)$$

$$i(x) = \arg \min_j \|x - w_j\| \quad j = 1, 2, \dots, l \dots\dots(6)$$

其中， $i(x)$ ：輸入樣本與各神經元鍵結權重之最短距離。

於此程序中每筆輸入樣本資料輸入網路後，緊接為評估此輸入樣本資料與網路中各神經元之相似程度，而後挑出與該輸入樣本資料相似度最高之神經元，令其受到激發並進入後續程序。而相似度之評估乃依據輸入樣本資料與其所對應神經元之歐氏距離，距離越小者代表相似度越高；亦可藉輸入樣本資料與各神經元鍵結權重之內積(inner product)評估，即以內積值最小者之神經元為優勝神經元。

3.3.2 合作程序(cooperative process)

輸入樣本資料歷經競爭程序後便可得一個優勝神經元，而該神經元則作為拓樸鄰域之中心。然而，神經元間存在側向地交互作用之影響，且其與神經元間之距離成反比，距離愈遠則影響相對愈小；關於拓樸鄰域之概念可以高斯函數表示如下。

$$h_{j,i(x)} = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2}\right) \dots\dots\dots(7)$$

其中， $h_{j,i(x)}$ ：優勝神經元 i 及鄰近神經元 j 之鄰近關係值。 $d_{j,i}^2$ ：拓樸圖上神經元 j 與優勝神經元 i 之歐氏距離。其趨近無限大則拓樸鄰域將趨近於零，為 SOM 網路收斂之必要條件。 β ：拓樸鄰域有效寬度(effective width)亦即鄰域半徑。

拓樸鄰域另一特徵為隨時間增加(疊代次數，the number of iterations)而縮小可利用(8)式。

$$\beta(t) = \beta_0 \left(-\frac{t}{\tau_1}\right) \quad t = 0, 1, 2, \dots\dots\dots(8)$$

其中， β_0 為 β 之起始值， t 為疊代次數， τ_1 為常數，故可將拓樸鄰域以鄰域函數(neighborhood function)如下式。

$$h_{j,i(x)}(t) = \exp\left(-\frac{d_{j,i}^2}{2\beta^2(t)}\right) \dots\dots\dots (9)$$

3.3.3 調適程序(adaptive process)

於神經元鍵結權重之調適過程中，鍵結權重值往靠近輸入樣本資料之方向進行調整，調適方法以原始 Hebbian (1949) 假設為本並引入一失憶項(forgetting term)即調適前後之神經元鍵結權重差值，可由下式得知。

$$\Delta W_j = \eta h_{j,i(x)}(X - W_j) \dots\dots\dots (10)$$

$$W_j(t+1) = W_j(t) + \eta(t)h_{j,i(x)}(t)(X - W_j(t)) \dots\dots\dots (11)$$

其中， η 為學習率。

經調適程序後各神經元之新鍵結權重值將可由(11)式求得，僅拓樸鄰域內之神經元鍵結權重會受調適程序作用。於網路收斂後，相鄰神經元將具相近鍵結權重，而相距較遠者則差異較大。鍵結權重調適過程包含排序階段(自組階段)及收斂階段。前者各神經元鍵結權重將進行其拓樸結構排序，其學習率需維持接近於 0.1，然不得低於 0.01 且疊代次數則大概需 1000 次以上。後者，初始時網路將進行微調以供更精確描述有關輸入樣本資料之統計量，此階段學習率應於 0.01 左右需經數千次疊代。

反覆進行此三程序至網路收斂為止，以二維網格紀錄輸入樣本與其所對應激發之神經元，並將編號或名稱標示於網格內以求得特徵圖(feature map)。受標示之網格元素代表網路中神經元受某特定之輸入樣本資料所激發，此網格元素則稱為該特定輸入樣本資料之映像(image)。於特徵圖中計算各映像所對應之輸入樣本數目且將之填入該網格即得密度圖(density map)，從其可知輸入樣本之分佈情況。倘若輸入樣本間具相似之特性，於密度圖中將趨於同一區位，而差異性較大則位置便較分散。異言之，若輸入樣本間存在某些群集情況，其群集關係將顯現於密度圖上。輸入樣本較密集區則密度圖會顯示出高原(plateau)表示群集存在，而較稀疏區域則顯示出山谷(valley)亦即群集間之界線，因此可用於高維

度資料之群集分析。

3.4 模式評估準則

為探討模式間之差異及效能，本研究藉由客觀之統計指標作為模式評估指標，以評估各模式於地下水水位預測之適合性，分述如下。

3.4.1 均方根誤差(Root Mean Square Error; RMSE)

$$RMSE = \sqrt{\frac{\sum_{s=1}^n [L_{est}(s) - L_{obs}(s)]^2}{n}} \dots\dots\dots (12)$$

其中， $L_{est}(s)$ ：第 s 筆模式預估之地下水水位(m)；

$L_{obs}(s)$ ：第 s 筆觀測地下水水位(m)；

n ：資料總數量。

RMSE 值愈接近零則預測精確度愈高，表預測值與實際觀測值間相對誤差越小，可描述預測值與實際觀測值間差異性。

3.4.2 效率係數(Coefficient of Efficiency; CE)

$$CE = 1 - \frac{\sum_{s=1}^n [L_{est}(s) - L_{obs}(s)]^2}{\sum_{s=1}^n [L_{obs}(s) - \bar{L}_{obs}(s)]^2} \dots\dots\dots (13)$$

其中， $\bar{L}_{obs}(s)$ ： s 筆觀測地下水水位之平均值(m)。

CE 值範圍介於負無窮大至 1 之間，若 CE 愈趨近 1 時，則代表模式適合度愈佳，反之則越差，其可提供模式偏態情形之參考。

四、模式應用

4.1 研究區域概述

濁水溪沖積扇位於台灣之中西部之間，北至烏溪，南以北港溪為界，東鄰八卦山脈、斗六丘陵區，西瀕台灣海峽。總面積約為 1800 平方公里，為台灣之地下水的主要蘊藏地區。雲林縣地下水資源年使用量約 12.79 億噸，而斗六市之地下水水權則占有 1.398 億噸約 10.9% 之鉅(經濟部水利署, 2005)故本文以濁水溪沖積扇頂區域之斗六地區為研究對象，以流域範圍而言，其境內隸屬北港溪流域上游之虎尾溪系統，與濁水溪、

表 1 地下水位觀測站基本資料

井名	電腦編號	二度分帶 座標 X	二度分帶 座標 Y	井址(斗六市)	井頂高 (m)	井管深 (m)	濾水管位置 (m)	資料起訖
虎溪 1	09010112	199331	2624542	興農路 600 號(雲林科技工業區)	36.64	24.00	15~21	1997/07~
虎溪 2	09010122	199331	2624542	興農路 601 號(雲林科技工業區)	36.70	129.00	96~123	1997/07~
虎溪 3	09010132	199331	2624542	興農路 602 號(雲林科技工業區)	36.64	230.00	212~224	1997/07~
虎溪 4	09010142	199331	2624542	興農路 603 號(雲林科技工業區)	36.70	300.00	282~294	1997/07~
石榴 1	09010212	206944	2624360	南仁路 51 號(石榴國小)	67.60	20.00	8~14	1997/08~
石榴 2	09010221	206944	2624360	南仁路 52 號(石榴國小)	66.32	120.40	66~84 ; 90~96 ; 108~114 。	1992/12~

資料來源：經濟部水利署，2001

新虎尾溪、舊虎尾溪及北港溪等河流相連接；而此地下水分區中含水層主要由瓣狀河道環境所沉積之礫石和粗中砂層，與濱岸環境沉積之細砂層所組成；阻水層則由沿岸沼澤或淺海環境之泥層所組成，且 300 公尺內之地層由上而下可劃分為四層含水層及四層阻水層。

斗六地區中原有石榴、虎溪及斗六等三處設有地下水位觀測站，而其中斗六地下水位觀測站屬於早期建立之觀測站，其觀測資料為逐月記錄且精度較低，因而經濟部水利署於民國 81 年起於地下水觀測網計畫所設立之觀測站為逐時記錄，其觀測連續性及精度較高，且各含水層間之相互影響與關係亦有較良好之展示。因此，本研究以石榴及虎溪兩處共 6 個地下水位觀測站所記錄之地下水位資料作為模式模擬之用，而地下水位觀測資料皆採用 1997 年至 2003 年間之地下水位資料，各地下水位觀測站之相關基本資料如表 1。

4.2 模式參數簡述

本研究輸入資料部份，據陳儒賢等(2006)依原始地下水時間序列之自我相關函數(Autocorrelation Function, ACF)及偏自我相關函數(Partial Autocorrelation Function, PACF)分析，指出輸入參數乃以各地下水觀測站之前 13、12 以及 1 個月等三個月份之月平均地下水位，而本研究曾以前 13、12、2 以及 1 個月等四個月份之月平均地下水位為輸入參數進行比較，結果顯示前 13、12 以及 1 個月為輸入參數有較顯著相關，

故本文以此為模式輸入參數。自 1997 年 8 月至 2003 年 12 月間歷經 77 個月份，而採用前 13、12 及 1 個月份之月地下水位為輸入資料時，可知原始地下水位資料共有 63 筆輸入資料可為模式之用，其中前 50 筆月平均地下水位資料為訓練樣本資料，而以另 13 筆為驗證之資料。

SOM 階段中輸入層至隱層間之初始鍵結權重值，以隨機變數產生且介於 0 至 1 之間；學習速率初始值為 0.1 而至最後為 0.01，經疊代 3200 次後映射至 8 乘 8 之二維密度圖上輸出資料，藉可視化原則得知資料之群集關係後，即能得知群數及各群平均值，便能客觀決定 RBFN 中隱藏層神經元之個數及中心點位置向量。

RBFN 中隱藏層至輸出層間，亦以隨機變數產生且介於 0 至 1 間之初始鍵結權重值；網路之偏差值為 1，而其與輸出層間之初始鍵結權重值亦為介於 0 至 1 間之隨機變數。而由於僅調整隱藏層至輸出層間之鍵結權重，可視為線性系統參數之集合即可利用最小方法求得最佳鍵結權重，進而得到網路輸出值。

本研究中所用之月平均地下水位資料分別屬於虎溪 1、虎溪 2、虎溪 3、虎溪 4、石榴 1 及石榴 2 等六個地下水位觀測站，而分別以單站地下水位資料模式及多站地下水位資料模式，以預測各單站之月平均地下水位；而多站模式中經挑選其中較具代表性之虎溪 2、虎溪 4、石榴 1 及石榴 2 等站，故多站模式又可分为六站模式與四站模式兩種。

五、應用分析及結果討論

5.1 觀測站模擬結果

5.1.1 虎溪 2 站

圖 4 為各模式訓練樣本資料(50 筆)經 SOM 網路拓樸映射至 8 乘 8 之二維密度圖後，其單站模式之訓練資料可分為 6 群，亦即 RBFN 中隱藏層神經元數目將為 6 個，六站模式為 7 群，而四站模式則有 8 群。

圖 5 可知各模式模擬訓練資料之狀況，配合表 2 及表 4 可瞭解各模式之效能。其中，訓練樣本資料中各效能評估指標皆顯示多站模式中四站模式相對地最佳；然此站中屬多站之六站模式卻為最差，其可能原因為較大預測誤差發生時期時，六站模式中虎溪 2 站為較近地表觀測站其水

位較易受環境及人為因素之速效性影響產生變化，可知若有較多雜訊輸入將使得網路預測模擬能力下降。圖 6 為驗證資料單站與多站模式之月地下水水位模擬情形，配合表 3 及表 5 可瞭解各模式之效能，而評估指標值雖無訓練樣本資料來得佳，然亦以四站模式顯示模擬效能表現相對地為最佳。

5.1.2 虎溪 4 站

各模式以 50 筆訓練樣本資料經 SOM 網路拓樸映射至 8 乘 8 之二維密度圖上(如圖 7)，其中單站模式訓練樣本資料可分為 6 群即決定 RBFN 隱藏層中神經元數目及中心位置，六站模式訓練資料可分為 8 群，而四站模式則有 9 群。

圖 8 可知單站和多站模式模擬訓練資料之情況，其中表 2 及表 4 顯示各模式訓練效能之評估




圖 4 虎溪 2 站各模式訓練樣本之拓樸映射密度圖




圖 5 虎溪 2 站各模式之訓練地下水水位歷線圖




圖 6 虎溪 2 站各模式之驗證地下水位歷線圖

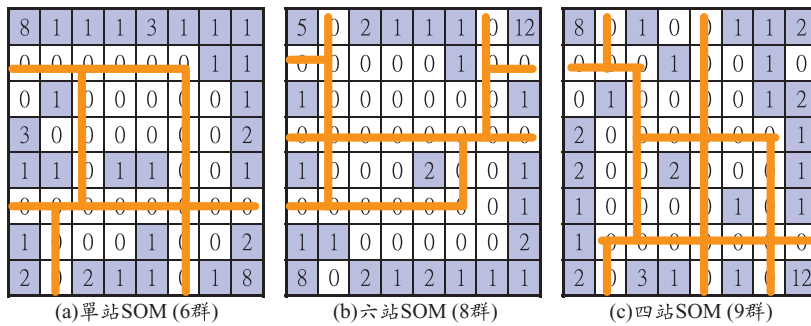


圖 7 虎溪 4 站各模式訓練樣本之拓樸映射密度圖




圖 8 虎溪 4 站各模式之訓練地下水位歷線圖

表。其中，各指標皆顯示多站模式之四站模式相對地最佳，且多站模式皆較單站模式為佳。其原因可能位於較深含水層之地下水觀測井，其較不易受氣候及環境因素之速效性影響而發生地下水位之波動，且與其它地下水觀測站變動趨

勢較為一致，故就其整體預測結果而言多站模式較單站模式良好。圖 9 則顯示單站和多站模式驗證樣本資料之月平均地下水位歷線模擬情況，其中表 3 及表 5 為各模式驗證效能之評估值。於驗證樣本資料中，各指標皆顯示四站模式模擬結果




圖 9 虎溪 4 站各模式之驗證地下水位歷線圖




圖 10 石榴 1 站各模式訓練樣本之拓樸映射密度圖

相對地最為優異，且整體而言，多站模式又較單站模式良好。其中四站模式相對地擁有最佳指標值，其 RMSE 值為 0.731 而 CE 值為 0.400。

5.1.3 石榴 1 站

訓練樣本資料共有 50 筆，經 SOM 網路映射至 8 乘 8 之二維密度圖上，如圖 10 所示。其中，單站模式訓練樣本資料可被分為 4 群，用以 RBFN 隱藏層神經元數目之決定，六站模式則可分 8 群，而四站模式則有 10 群，各模式間群數分析差異頗大。

從圖 11 可知單站和多站模式模擬訓練資料之月平均地下水位歷線，其中表 2 及表 4 顯示各模式之效能評估值。此站之各項指標皆顯示多站模式之四站模式相對地最佳，然其模擬預測結果顯示較虎溪 2 及 4 站差。其原因可能石榴 1 站為位於較靠近地表含水層之地下水位觀測井，且此區域屬於濁水機沖積扇頂頂位置亦為地下水補

助旺盛之區域，故其地下水變動之差距甚大於其他地下水位觀測站，故其模擬結果誤差亦會較大。而由圖 12 中，可清楚看出各模式驗證樣本資料模擬之月平均地下水位歷線，且由表 3 及表 5 可知各模式效能評估情況。於驗證樣本資料中，各指標顯示四站模式之模擬結果相對地最佳，然其較另三個地下水位觀測站之模擬精確度良好甚多，其可能原因為驗證時期恰為地下水位變化波動較小之時期。其中，多站模式又較單站模式良好，而四站模式擁有相對地最佳指標值，其 RMSE 值為 0.248 而 CE 值則高達 0.784。

5.1.4 石榴 2 站

圖 13 即以 50 筆之訓練樣本資料經 SOM 網路映射至 8 乘 8 之二維密度圖上。其中，單站模式訓練樣本資料可被分為 6 群用以 RBFN 隱藏層中神經元數目之決定，六站模式則為 9 群，而四站模式則有 6 群。




圖 11 石榴 1 站各模式之訓練地下水水位歷線圖




圖 12 石榴 1 站各模式之驗證地下水水位歷線圖




圖 13 石榴 2 站各模式訓練樣本之拓樸映射密度圖

從圖 14 可知單站和多站模式預測訓練資料之月平均地下水水位歷線，其中表 2 及表 4 顯示各模式訓練效能之評估值。於訓練階段中，各指標亦皆顯示多站模式之四站模式相對地最佳，且其

中多站模式又較單站模式良好。其模擬預測結果顯示亦較虎溪 2 及 4 站差但優於石榴 1 站，其原因乃石榴 2 站亦屬於濁水機沖積扇頂位置亦為地下水補注旺盛之區域，然其為位於較深含水層




圖 14 石榴 2 站各模式之訓練地下水水位歷線圖




圖 15 石榴 2 站各模式之驗證地下水水位歷線圖

之地下水水位觀測站，故其地下水變動之差距僅居第二位，故與其模擬結果之誤差得以相呼應。而由圖 15 中，可知其各模式驗證樣本資料之月平均地下水水位模擬情形，且自表 3 及表 5 可知各模式之驗證效能概況。其中，多站模式又較單站模式良好，而四站模式相對地亦為多站模式中較佳之模擬模式，模式評估準則中其 RMSE 值為 0.789 而 CE 值則為 0.592。

5.2 模式效能評估值

本文為瞭解 SOM-RBFN 模式於預測地下水水位之合適性，藉以均方根誤差(RMSE)及效率係數(CE)評估之，其評估結果則分述如下：

5.2.1 RMSE 評估值

RMSE 評估指標為正值且值愈趨近於零則

代表模式預測精確度愈佳，而下表 2 及表 3 可清楚看出各地下水水位觀測站於不同模式模擬結果之 RMSE 值。訓練樣本資料中，虎溪 2 單站較六站模式佳，而此評估指標值顯示四站模式相對地為最佳，可知多站站數與預測精度並非完全成正比；而驗證資料中四站模式亦相對地最佳，其中虎溪 2 站為 0.918、虎溪 4 站為 0.731、石榴 2 站為 0.789 且石榴 1 站更達 0.248。

5.2.2 CE 評估值

CE 評估指標介於負無窮大至 1 之間，其值愈趨近於 1 表是模式模擬之適合度越高，而下表 4 及表 5 可瞭解各地下水水位觀測站其模式偏態之情況。依舊可分訓練及驗證樣本資料來看；前者，此評估指標值顯示四站模式較六站模式適合度高，而六站模式又較單站模式良好，然而虎

表 2 各站訓練資料模擬結果之 RMSE 評估表

指標 \ 模式	單站模式	六站模式	四站模式
虎溪 2	0.675	0.798	0.669
虎溪 4	0.935	0.773	0.647
石榴 1	1.548	1.455	1.141
石榴 2	1.203	1.196	1.028

表 3 各站驗證資料模擬結果之 RMSE 評估表

指標 \ 模式	單站模式	六站模式	四站模式
虎溪 2	0.947	0.947	0.918
虎溪 4	0.871	0.748	0.731
石榴 1	0.644	0.327	0.248
石榴 2	1.442	1.008	0.789

溪 2 站中之六站模式較單站模式表現不佳；後者，多站模式均較單站模式佳，而多站模式之四站模式相對地有最佳適合度，其中虎溪 2 站為 -0.183、虎溪 4 站為 0.400、石榴 1 站為 0.784 而石榴 2 站則為 0.592。

綜合上述兩項指標之評估結果，可清楚瞭解 SOM-RBFN 中之多站模式結果較單站模式預測之精確度及適合度皆佳。然而，六站模式之預測結果卻未必比四站模式為佳，亦即多站模式並非越多測站預測效果越好，探究原因可能是因為輸入太多訓練因子反而增加模式之干擾(noise)，使網路預估之效能降低。

六、結論與建議

6.1 結論

1. 由虎溪 2、虎溪 4、石榴 1 及石榴 2 等站之模擬結果，藉 RMSE 評估表可知模式預測值與觀測值之差異程度，而訓練資料中其模擬預測精度之整體趨勢以四站模式最佳、六站模式居中而單站模式相較下較為遜色；而驗證資料部份亦為多站模式優於單站模式，而多站模式中相對地又以四站模式為最佳。
2. 經 CE 指標評估表呈現各模式模擬預測之適合度，而虎溪 2、虎溪 4、石榴 1 及石榴 2 等站其訓練樣本資料之適合度，整體而言四站模式

表 4 各站訓練資料模擬結果之 CE 評估表

指標 \ 模式	單站模式	六站模式	四站模式
虎溪 2	0.768	0.676	0.772
虎溪 4	0.744	0.825	0.878
石榴 1	0.560	0.611	0.761
石榴 2	0.782	0.785	0.841

表 5 各站驗證資料模擬結果之 CE 評估表

指標 \ 模式	單站模式	六站模式	四站模式
虎溪 2	-0.260	-0.259	-0.183
虎溪 4	0.149	0.371	0.400
石榴 1	-0.451	0.627	0.784
石榴 2	-0.362	0.335	0.592

亦為最佳而單站模式則表現較差；而驗證資料部份更可清楚看出多站模式之優異性，而多站模式中亦為四站模式相對地擁有最佳之適合度。

6.2 建議

1. 由於本研究挑選之觀測站均屬濁水溪沖積扇之扇頂區域，因此後續研究可針對扇央及扇尾地區之觀測站進行預測比較，且石榴觀測站恰好位於中央地質調查所繪製之地質水文剖面圖邊緣部份，故倘若有不合理情形時難以物理機制加以分析解釋，因此可供後續研究者選擇觀測站參考之用。
2. 有關於本研究中多站模式四站之部份，乃欲突顯觀測站需再經挑選較具代表性之站別資料以為模式所用，然本研究中僅以剔除地下水位歷線較相近之原則下進行挑選流程，因此，建議後續之研究者可就擬定更客觀之多站模式挑選機制作更詳盡之探討，亦可逐一比較單站、兩站、三站、四站、五站及六站等模式之不同排列組合以探討最佳站數之機制。
3. 本文中地下水位觀測站所謂之多站模式乃是基於重直縱剖面上之多站而非空間中之多站，因此空間中平面上測站位置之選擇亦可藉由區域化變數理論等方向進行探討與研究，進而訂定出更為更客觀且有助於提升預測精確

度之選站機制。

4. 有關於地下水位模擬方面，一般慣用乃以各含水層來進行分析探討，因此建議後續研究者可選用同一含水層之觀測站進行預測模擬之研究，期以提升模式之實用性。
5. 本研究中所採用地下水位資料之時間尺度為 77 個月份(自 1997 年 8 月至 2003 年 12 月)，故亦需相當長度之歷史地下水位資料。因此，後續研究可就地下水位資料之時間尺度上進行探究，以尋求最佳效率之時間尺度以供模式之用。
6. 本研究中曾提及台灣地區水文環境北澗南旱趨勢顯著，因而後續研究者亦可探討豐枯水期之地下水位資料，其與預測模擬結果之相關性，且可對評估指標值進行卡方檢定 (Chi-Square Test)等統計分析以決定相對可接受之評估指標值。

七、參考文獻

1. 汪中和(2004)，「臺灣降雨的長期變化及對環境的衝擊」，自然與文化研討會，pp.50-54。
2. 張斐章、張麗秋(2005)，「類神經網路」，東華書局。
3. 陳儒賢、王育民、王豪辛、張國璋(2006)，「結合輻狀基底函數網路與自組織映射圖網路於時間序列之預測」，第十二屆資訊管理暨實務研討會論文集。
4. 蕭富元(2007)，「全球暖化 台灣發燒」，天下雜誌，第 369 期，pp.106-117。
5. Broomhead, D.S., Lowe, D. (1988), "Multivariable functional interpolation and adaptive networks." *Complex System* 2, pp. 321-355.
6. Gwo-Fong Lin, Lu-Hsien Chen (2005), "Time series forecasting by combining the radial basis function network and the self-organizing map." *Hydrological Processes* 19(10), pp. 1925-1937.
7. Hardy, R.L. (1971), "Multiquadric equations of topography and other irregular surfaces." *Journal of Geophysical Research* 76, pp. 1905-1915.
8. Kohonen, T. (1982), "Self-organized formation of topologically correct feature maps." *Biological Cybernetics* 43, pp. 59-69.
9. Lallahem, S., Mania, J., Hani, A., and Najjar, Y. (2005), "Groundwater level forecasting using artificial neural networks." *Journal of Hydrology*, 307, pp. 92-111。
10. Mikko, L., Jukka, S., Pentti, H., Kimmo, K. (1996), "A Network of Autogressive Processing Units for Time Series Modeling." *Applied Mathematics and Computation*, 75, pp. 151-165.
11. Powell, M.J.D. (1987), Radial basis functions for multivariable interpolation: A review, In *Algorithms for Approximation*, Mason JC, Cox MG (Eds.), Carendon Press: Oxford, pp. 143-167.
12. Wasserman, P.D. (1993), "Advanced methods in neural computing." Van Nostrand Reinhold, New York.

收稿日期：民國 97 年 11 月 10 日

修正日期：民國 97 年 11 月 24 日

接受日期：民國 97 年 11 月 28 日