

類神經網路結合半變異圖模式於地下水 水位預測之研究

A Study on Ground Water Level Forecasting by Combining Neural Networks and Semi-variogram Model

國立嘉義大學
土木與水資源工程學系
副教授

陳清田

Ching-Tien Chen

台灣首府大學
休閒管理學系
副教授

陳儒賢*

Lu-Hsien Chen

國立嘉義大學
土木與水資源
工程學研究所
碩士

黃建演

Jian-Yen Huang

國立嘉義大學
土木與水資源
工程學研究所
碩士班研究生

黃上竹

Shang-Jhu Huang

摘 要

本研究嘗試結合倒傳遞神經網路(back-propagation neural network; BPN)、克利金法(kriging technique)之半變異圖(semi-variogram)模式與試誤法(try and error)，建立一地下水水位預測模式，並將此模式應用於台南地區二十個地下水水位測站之月平均地下水水位預測上。研究結果顯示，資料若先經過克利金法所計算出之影響範圍(influence range)篩選後，的確有助於 BPN 模式之地下水水位預測，然本研究地區之影響範圍並不明顯，故本研究再經由試誤的方式篩選影響範圍內之地下水水位資料。由研究結果得知，經過試誤法篩選後，有十八個測站 BPN 模式之效率係數(coefficient of efficiency; CE)值大於 0.7，且有九個測站之 CE 值提高 10%以上。此外，輸入 BPN 模式之相關測站數目也由原本平均 8 站減少到平均 2 站。上述結果顯示，經由半變異圖模式所計算出之影響範圍內之測站資料，若再經由試誤法篩選後，不僅可以去掉影響模式精確度之干擾項，提高預測結果之精確度，且可以有效地減少模式訓練時間以及資料成本的使用。

關鍵詞：地下水預測，倒傳遞類神經網路，半變異圖模式，試誤法。

ABSTRACT

In this study, based on the combination of the the back-propagation neural network

*通訊作者，台灣首府大學休閒管理學系副教授，72153 台南市麻豆區南勢里 168 號，lhchen@tsu.edu.tw

(BPN), semi-variogram model and try and error method to propose a groundwater level forecasting model. The proposed model is applied to actual groundwater data from 20 groundwater stations of the Tainan area. The study results show that data of selected stations within influence range obtained by kriging method is indeed helpful to improve performance of BPN model in forecasting groundwater level. However, the influence range in the study area is unobvious. Try and error method is used to select groundwater level data within the influence range. The results show that there are 18 stations achieve the coefficient efficiency, CE, of over 0.7. Moreover, the 9 stations yield an average CE upgradation 10%. In addition, the average number of related stations is reduced eight to two. The results show that the proposed method can not only delete noise to the network and produce reasonable forecasts, but also can save training time of model and decrease costs of data collection and management.

Keywords: groundwater level forecasting, back-propagation neural network, semi-variogram model, try and error.

一、前 言

台灣地區降雨多來自於每年五、六月之梅雨及夏季之颱風，造成豐、枯水期的降雨量差異非常懸殊，加上近年來受到氣候變遷之影響，導致台灣地區每人每年所分配的用水量約為世界平均值的五分之一，聯合國 2005 年統計指出，台灣名列全球第 18 位缺水的國家，屬於水資源利用潛能不高之地區(聯合國統計，2005)。根據經濟部水利署統計，台灣地區之年平均用水量約為 180 億噸，其中地表水約占 120 億噸，地下水約占 60 億噸(經濟部水利署網站，2009)。根據調查結果得知，台灣地區天然地下水之總蘊含量約為 176 億立方公尺(經濟部水資源局，2001)，屬相當豐富之水資源，但因取用相當方便且開發成本過低，因此成為各標用水競相開發的目標。然而，地下水資源若過度不當的開發，日後將造成國家水土資源嚴重之傷害。

近年來，許多地下水水位預測模式已相繼被提出，這些模式一般可分為定率式與序率式兩種。其中，定率式是應用數理方程式建構水文模式來預測地下水水位；序率式則是利用實測所得之地水記錄，以統計方法歸納其特性，藉以推估未來之水文狀況。然而，由於地下水

本身之機制相當複雜且其影響因子眾多，導致很難以定率式模式直接模擬其水文現象。再者，很多預測模式在應用上皆有其限制條件與適用範圍，造成使用上極不方便。因此，本研究嘗試建立一個地下水水位預測模式，期望利用簡單的計算方法與少量之地下水水位資料，即可獲得精準度較高之預測值。

Chen *et al.* (2011)嘗試結合自組織映射圖網路(self-organizing map; SOM)與倒傳遞類神經網路(back-propagation neural network; BPN)之理論建立一個地下水水位之預測模式，稱為 SOM-BPN 模式。該模式與一般傳統自回歸-積分-移動平均法(autoregressive-integrated-moving average model; ARIMA)模式與 BPN 模式比較，結果顯示 SOM-BPN 模式預測之精確度較傳統之 ARIMA 模式及 BPN 模式為佳，但因多站預測單站之精度並不一定比單站預測單站之精確度為高，該研究認為是因為干擾項(noise)太多所致。基於上述理由，該研究再應用克利金(kriging)之半變異圖(semi-variogram)理論求得影響範圍(influence range)，以選定影響範圍內之水位觀測站資料作為模式之輸入項，研究結果顯示結合克利金之 SOM-BPN 模式可得到更精確之地下水水位預測值。

理論上，BPN 是一種能精確模擬任一種非線性方程之模擬器，更是一種實用之時間序列預測工具，若能結合其他篩選資料之方法，將可有效提高 BPN 模式之預測精確度，如上述 Chen *et al.* (2011) 結合半變異圖理論，將欲推估之地下水水位測站的影響範圍求出，藉此得知可納入周遭哪些測站資料，進而提升 BPN 模式之預測精確度。然而，若該地區內測站之地下水水位資料無明顯之線性相關時，將造成其影響範圍並不明顯，並導致其影響距離過大，此時若將此影響範圍內之測站資料輸入模式內，將會造成過多干擾項，以致於影響 BPN 模式預測之精確度。有鑑於此，本研究將嘗試加入試誤(try and error)的方式篩選影響範圍內之測站資料，再結合 BPN 模式進行地下水水位預測，最後並將與以單站自身資料作為模式輸入項之 BPN 模式、直接以自身及其他所有測站之資料作為模式輸入項之 BPN 模式，以及結合半變異圖理論之 BPN 模式等三種模式之結果做比較，期望本研究所提出之模式能達到以少量之地下水水位資料，即可快速方便獲得精確地下水水位預測值之目的。

近年來，關於地下水水位預測之相關模式、方法與研究相當多，黃浚瑋(2006)以 Modflow 產生資料訓練 ANN 模式，並以 ANN 模式在定量抽水情況下，進行長期預測地下水水位變化之可行性。由研究結果可知，本模式兼具線性規劃之高計算效率與遺傳演算法可以涵蓋線性與非線性之彈性。Karamouz *et al.* (2004) 利用地下水數值模式 Modflow 軟體產生資料供給類神經網路(artificial neural networks; ANN)作為訓練資料之用，並在研究過程中以 ANN 充當地下水水位之響應函數，對德黑蘭平原之水資源優選調度做最佳化分析。Chen *et al.* (2011) 結合 SOM 與 BPN 之理論建立一個地下水水位之預測模式，稱為 SOM-BPN 模式，並將此模式應用於彰化地區十個地下水水位測站之月平均地下水水位之預測上。結果顯示，SOM-BPN 模式確實能較客觀地確立網路之隱藏層神經元數目，且預測之精確度較傳統之 ARIMA 模式及 BPN 模式為佳。此外，該研究並利用半變異圖理論篩選影響範圍內之測站資料作為模式

輸入項，結果顯示結合克利金之 SOM-BPN 模式可得到更精確之預測值。

在各種 ANN 模式中，BPN 是最為普遍且具代表性的一種網路，它能精確地模擬任一種非線性方程之模擬器，因此可以解決真實世界中許多非線性之問題。此外，許多文獻亦證明 BPN 於非線性問題上之適用性及優勢，吳國儒等人(2008) 使用 BPN、SOM 及調適性網路模糊推論系統等三種 ANN 理論架構建立三種蒸發量推估模式，並與 Modified Penman 經驗式及 Penman-Monteith 經驗式的推估結果進行比較。該研究以中央氣象局恆春站 2002 至 2004 年的日氣象觀測資料，作為模式訓練與測試用，結果顯示此三種 ANN 模式推估日蒸發量之結果皆相當準確，且較傳統之經驗公式表現為佳。鄭鈞璋(2012) 結合經驗模態分解方法、SOM 與 BPN，嘗試以此複合模式預測地下水水位，並採用較切合實際預測情境之「預報」方法，應用於雲林麥寮地區地下水水位之預測，研究結果顯示，此複合模式較傳統模式在預測值準確性之改善與分析效率之提升上具有明顯之優勢。張庭瑞(2012) 利用 BPN 進行海堤堤趾沖刷深度之預測。該研究採用前人實驗數據，先將資料依照其底床坡度分為陡坡與緩坡兩種情況，再經由 ANN 訓練及測試，透過探討其輸入參數之過程求得各情況最佳預測模式。最後得到輸入堤前相對水深、入射波波浪尖銳度、底床坡度及堤面坡度等四項輸入因子來建立堤趾沖刷深度的最佳預測模式，其相關係數皆達 0.95 以上。最後並嘗試將陡坡緩坡數據混合進行預測，發現預測結果之相關係數亦可達 0.896。

二、研究方法

2.1 倒傳遞類神經網路

BPN 係由 Rumelhart *et al.* (1986) 所提出，它是以多層感知機(multilayer perceptron)為架構，一般使用誤差倒傳遞演算法(error back propagation)，故又稱為 BP (back propagation) 演算法。BPN 為目前 ANN 學習模式中最具代表性且應用最普遍的模式，其網路架構及學習過程簡介如下：

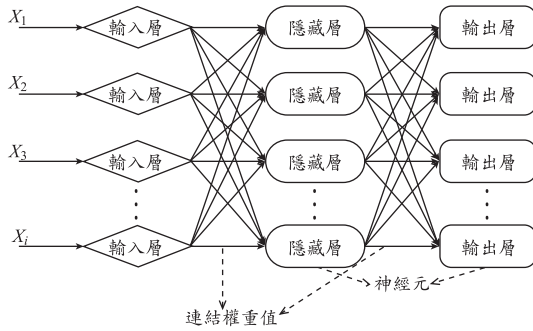


圖 1 倒傳遞類神經網路架構圖

2.1.1 網路架構

BPN 屬監督式多層前饋式網路架構，其架構包含輸入層(input layer)、輸出層(output layer)及隱藏層(hidden layer)等三層。BPN 之架構如圖 1 所示。

其中，輸入層負責網路的輸入變數，但此層並沒有計算能力，網路之訊號即由此輸入；輸出層使用非線性轉換函數，並表達網路的輸出變數，網路最終結果由此輸出；隱藏層用以表現輸入與輸出單元間的交互影響，其隱藏層神經元數目並無標準方法可以決定，神經元數目太少不足以反映輸出與輸入單元間的交互作用，但當神經元數目超過一定數目後，增加神經元數目反而會增加模式結果之誤差，徒增執行時間。

BPN 模式在訓練過程中，其每個神經元彼此間並不相連，只與前後層神經元相連接，訓練 BPN 模式之目的即在求出這些相互連結權重最佳值，以使 BPN 模式的輸入和輸出能形成特定之函數關係。

2.1.2 學習過程

BPN 是目前 ANN 學習模式中應用最普遍的模式，其基本原理是利用最陡坡降法(the gradient steepest descent method)來讓誤差函數最小化，並使用平滑可微分的轉換函數來修正網路權重值，以降低輸出單元與目標輸出值及推論輸出值之差距，其學習過程詳細說明如下：

1. 設定網路參數：BPN 之網路參數包括輸入及輸出單元數、隱藏層層數及隱藏層神經元、學習速率(learning rate)與慣性因子 α (momentum

factor)，並以均勻分布之隨機亂數設定層與層間之連結權重值 $W_{x,h}$ 、 $W_{x,y}$ 與門檻值 $\theta_{x,h}$ 、 $\theta_{x,y}$ 。

2. 輸入一訓練範例之輸入值 X 與目標輸出值 T 。
3. 計算網路之輸出向量 Y ，其中 F 為非線性轉換函數。

計算隱藏層之輸出向量

$$H : H = F(\sum W_{x,h}H - \theta_{x,h}) \dots \dots \dots (1)$$

計算網路輸出向量

$$Y : Y = F(\sum W_{x,y}H - \theta_{x,y}) \dots \dots \dots (2)$$

4. 計算誤差量

計算隱藏層誤差量

$$\delta_{x,h} : H(1-H)\sum W_{h,y}\delta_{h,y} \dots \dots \dots (3)$$

計算輸出層誤差量

$$\delta_{h,y} : Y(1-Y)(T-Y) \dots \dots \dots (4)$$

以上皆為向前傳遞之階段，若未達到誤差量之要求，則進行向後傳遞之階段，修正連結權重值。

5. 計算連結權重修正量及門檻值修正量

計算隱藏層之連結權重修正量 $\Delta W_{x,h}$ 、門檻值修正量 $\Delta \theta_{x,h}$ ：

$$\Delta W_{x,h} = \eta \delta_{x,h} X \dots \dots \dots (5)$$

$$\Delta \theta_{x,h} = -\eta \delta_{x,h} \dots \dots \dots (6)$$

連結權重修正量 $\Delta W_{h,y}$ 及門檻值修正量 $\Delta \theta_{h,y}$ 為計算輸出層：

$$\Delta W_{h,y} = \eta \delta_{h,y} H + \alpha \Delta W_{h,y} \dots \dots \dots (7)$$

$$\Delta \theta_{h,y} = \eta \delta_{h,y} \dots \dots \dots (8)$$

6. 若要更新各層之連結權重值 $W_{x,h}$ 及門檻值 $\theta_{x,h}$

$$\begin{aligned} W_{x,h} &= W_{x,h} + \Delta W_{x,h} & W_{x,h} &= W_{x,h} + \Delta W_{x,h} \\ \theta_{x,h} &= \theta_{x,h} + \Delta \theta_{x,h} & \theta_{x,h} &= \theta_{x,h} + \Delta \theta_{x,h} \end{aligned} \dots \dots (9)$$

需重複步驟 3 至步驟 6，直到誤差量 $\Delta W_{x,h}$ 收斂或達到所設定之學習循環次數為止。

2.2 克利金法

克利金法是根據資料在空間中分布的統計特性，決定線性內插係數的一種技術，它可分為

分析與估計兩部分，分述整理如下：

1. 結構分析(structural analysis)：其變異圖(variogram)或半變異圖(semi-variogram)的函數是經由歷年之水文資料，經由回歸統計協變異數隨距離變化的情形所決定的。
2. 最佳線性不偏估估計(best linear unbiased estimation)：假設估計值為已知值的線性權重平均，根據不偏估和最小估計誤差變異數兩項原則，根據變異圖或半變異圖導出權重係數值。

2.2.1 區域化變數理論

在區域化變數理論中，其變數須滿足定常性假設及內在假設，其原理分述如下：

1. 定常性假設(stationarity)

- (1) 區域化變數之期望值為常數(constant)，不隨空間位置而改變。如下式所示：

$$E[Z(u)] = m \quad \dots\dots\dots(10)$$

其中， E 為期望值； $Z(u)$ 為區域化變數； m 為常數(constant)。

- (2) 區域化變數 $Z(u)$ 在空間上之協變異數，是兩地之間的相對距離，與位置無關。如下式所示：

$$\begin{aligned} E[(Z(u_1) - m)(Z(u_2) - m)] & \dots\dots\dots(11) \\ = \text{cov}(u_1 - u_2) = C(h) \end{aligned}$$

其中， h 為 $|u_1 - u_2|$ ； $C(0) = E[(Z(u) - m)^2] = \sigma^2 = \text{constant}$

2. 內在假設(intrinsic)

在某些情況下，其空間資料中若不具定常性，但資料可滿足以下之內在模式(intrinsic model)，即：

$$E[Z(u_1) - Z(u_2)] = 0 \quad \dots\dots\dots(12)$$

$$\gamma(d) = \frac{1}{2} E[(Z(u_1) - Z(u_2))^2] \quad \dots\dots\dots(13)$$

其中， $2\gamma(d)$ 稱為變異圖； $\gamma(d)$ 稱為半變異圖。內在假設並不嚴格要求 $E[Z(u_1) - Z(u_2)] = 0$ 在所有的距離必須成立，僅要求在比較接近的距離內

必需成立，若定常性假設成立，則內在假設必然成立，反之則不必然。至於何為較接近的距離內，則須由半變異圖隨距離變化的情形而定。

2.2.2 半變異圖分析與模式配套

1. 半變異圖分析

半變異圖之定義如方程式(13)所示，表示在距離等於 d 時，所有距離為 d 的兩點變異差異平方的期望值，亦即需要有許多個距離為 d 的組合來決定 $\gamma(d)$ ，同時 d 由 0 變化到 ∞ 。實際觀測若有 m 個觀測點，兩兩組合共有 $\binom{m}{2} = \frac{m!}{(m-2)!2!} = \frac{m(m-1)}{2}$ 種組合，將這 $\frac{m(m-1)}{2}$ 個組合按距離長短分為 n 個區間，則每個區間內有 $\frac{m(m-1)}{2n}$ 個資料，第 k 個間距的 $\frac{m(m-1)}{2n}$ 個組合距離的平均作為平均距離 \bar{d}_k ，得到變異圖如下式所示：

$$2\gamma(\bar{d}_k) = \sum_1^{\frac{m(m-1)}{2n}} \left\{ [z(u_1) - z(u_2)]^2 \left(\frac{2n}{m(m-1)} \right) \right\} \quad \dots\dots\dots(14)$$

其中， $d_{k-1} \leq \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \leq d_k$ ， $k = 1, \dots, n$ ， d_{k-1} 與 d_k 是第 k 個距離間距的距離上、下限； z 為隨機變數 Z 的實現值。將所有間距之平均距離和半變異圖資料點 $(\bar{d}_k, \gamma(\bar{d}_k))$ 繪出，並選用某個變異圖的函數作回歸，便可得到變異圖的模式。

2. 模式配套

克利金之半變異圖的模式配套種類眾多，其影響範圍之計算方法不一，以下為三種較常用之半變異圖模式：

(1) 高斯模式(gaussian model)

$$\gamma(d) = \sigma^2 \left[1 - \exp\left(-\frac{d^2}{L^2}\right) \right] \quad \dots\dots\dots(15)$$

其中， $\sigma^2 > 0$ 且 $L > 0$ ；而影響範圍約為 $\sqrt{3}L$ 。




圖 2 各模式之半變異圖

(2) 指數模式(exponential model)

$$\gamma(d) = \sigma^2 \left[1 - \exp\left(-\frac{d}{L}\right) \right] \dots\dots\dots (16)$$

其中， $\sigma^2 > 0$ 且 $L > 0$ ；而影響範圍約為 L 至 $3L$ 。指數模式為一簡單的解析形式且具多變性，故水文資料之分析常使用本模式，本研究亦將選擇此模式進行半變異圖之配套。

(3) 球形模式(spherical model)

$$\gamma(d) = \begin{cases} \sigma^2 \left[\frac{3d}{2\alpha} - \frac{1}{2} \left(\frac{d}{\alpha} \right)^3 \right] & \text{if } d \leq \alpha \\ \sigma^2 & \text{if } d > \alpha \end{cases} \dots\dots\dots (17)$$

其中，參數 σ^2 為變異數， α 為影響範圍。

上述三種半變異圖之模式配套，繪製如圖 2 所示。

三、模型應用

3.1 研究區域與資料蒐集

本研究所採用的地下水位觀測站係依據經部水利署於民國 81 年起，分別於地下水觀測網計畫中所設立之觀測站中挑選而出，選擇這些觀測站是因為水利署所建立之地下水位觀測連續性與觀測精度較高，且具有逐時記錄之優點。本研究所選用之測站係依照下列原則挑選：1. 地質、空間分布均勻；2. 分布於同一含水層；3. 近十年內地下水紀錄完整。經過上述原則篩選後，本研究擬以台南地區第一含水層之二十個地下水位觀測站作為模式模擬驗證之用，各測站之相對位置如圖 3 所示。




圖 3 研究區域之二十個地下水位測站相對位置圖

3.2 評估指標

為探討模型間之差異及效能，本研究藉由客觀之統計指標作為模型評估指標。本文以常用之效率係數 CE (coefficient of efficiency)及均方根誤差(Root Mean Square Error; RMSE)兩個指標，評估類神經網路模型於地下水位預測之適合性，分述如下：

3.2.1 效率係數 CE：

$$CE = 1 - \frac{\sum_{t=1}^n [\hat{R}_t - R_t]^2}{\sum_{t=1}^n [R_t - \bar{R}]^2} \dots\dots\dots (18)$$

其中， R_t 為第 t 個月之觀測地下水位， \hat{R}_t 為第 t 個月之預測地下水位， \bar{R} 為平均觀測地下水位， n 為地下水位資料筆數。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。

3.2.2 均方根誤差 RMSE：

$$RMSE = \sqrt{\frac{\sum_{t=1}^n [(\hat{R}_t - R_t)]^2}{n}} \dots\dots\dots (19)$$

由上式可知，RMSE 值愈接近零表示預測值與實際觀測值間相對誤差越小，亦即預測精確度越高。




圖 4 指數型半變異圖模式回歸配套結果表

3.3 半變異圖分析

在利用類神經網路進行地下水位之預測前，必須先決定模式之輸入項，本研究嘗試利用半變異圖，先將欲推估之地下水位測站的影響範圍求出，藉此得知可納入哪些附近測站之資料，作為類神經網路預測時模式之輸入項。本研究利用水文資料分析最常使用之指數模式，針對台南地區二十個地下水位測站之資料進行半變異圖之迴歸配套，其配套結果繪製如圖 4。由方程式 (16) 可知，若使用指數模式進行半變異圖分析，其影響範圍約為 L 至 $3L$ 。由圖 4 之結果可發現，台南地區地下水位間之影響範圍 L 約為 14.72 公里，換言之，其三倍影響範圍 ($3L$) 之距離約為 44.16 公里。接著，本研究將台南地區二十個地下水位測站之相對距離求出，將影響範圍之距離設為 $3L$ ，則站與站間之相對距離大於 44.16 公里之站數只剩三站。換言之，其餘地下水位測站於此影響範圍內所選取之周遭測站將囊括所有測站，此結果將造成模式之輸入項目將與使用全部測站做為模式輸入項之情形相同。有鑑於此，本研究考慮將影響範圍訂為 14.72 公里。研究地區內二十個地下水位測站於影響範圍內之測站名稱整理如表 1 所示。

3.4 預測模式之分類

若欲預測時間為 t 時之地下水位，本研究先以時間為 $t-1$ 時之自站地下水位資料當作 BPN 模式輸入項並進行預測，並計算其 CE 值。接著，

表 1 各地下水位測站影響範圍內之測站

測站名稱	影響範圍內之地下水位測站名稱
白河	新東、柳營
柳營	下營、新東、總爺、港尾、白河
新東	柳營、白河、下營
紀安	總爺、港尾、後港、南科、台南、南興、大文、下營、新市、安慶、頂山、三股、永康
總爺	下營、紀安、港尾、台南、南科、後港、柳營、新市、大文、南興
港尾	後港、下營、總爺、紀安、大文、頂山、錦湖、柳營、南興、南科、台南、三股
下營	總爺、港尾、柳營、紀安、錦湖、後港、新東、大文、台南
大文	後港、頂山、三股、港尾、紀安、南興、總爺、安慶、南科、下營、台南
三股	大文、後港、頂山、安慶、南興、紀安、港尾
頂山	大文、後港、三股、港尾、紀安、錦湖
後港	大文、港尾、頂山、紀安、三股、南興、總爺、下營、南科、台南、安慶
錦湖	港尾、下營、頂山
新市	台南、南科、永康、南興、紀安、安慶、總爺、五甲
南科	台南、新市、南興、紀安、永康、總爺、安慶、後港、大文、港尾
南興	安慶、南科、台南、永康、新市、紀安、大文、後港、三股、總爺、仁和、港尾
仁和	永康、安慶、五甲、南興
五甲	永康、仁和、新市
永康	安慶、新市、南興、仁和、南科、台南、五甲、紀安
安慶	南興、永康、仁和、三股、南科、台南、新市、大文、紀安、後港
台南	南科、新市、南興、紀安、永康、總爺、安慶、後港、港尾、大文、下營

再以時間為 $t-1$ 及 $t-2$ 時之地下水位資料作為模式輸入項進行預測，依照上述方式以此類推，直到模式輸入項之時間為 $t-1$ 、 $t-2$ 、 \dots 、 $t-12$ 。換言之，若欲預測時間為 t 時之地下水位，將會有 12 組預測結果，本研究將分別求得各自驗證資料之 CE 值，最後找出當中 CE 值最大者為最佳 CE 值，稱為最佳時間序列，並以該時間序列之地下水位資料作為 BPN 模式之輸入項。接著，依據 BPN 模式之輸入項決定方式，將預測模式分為下列四類：

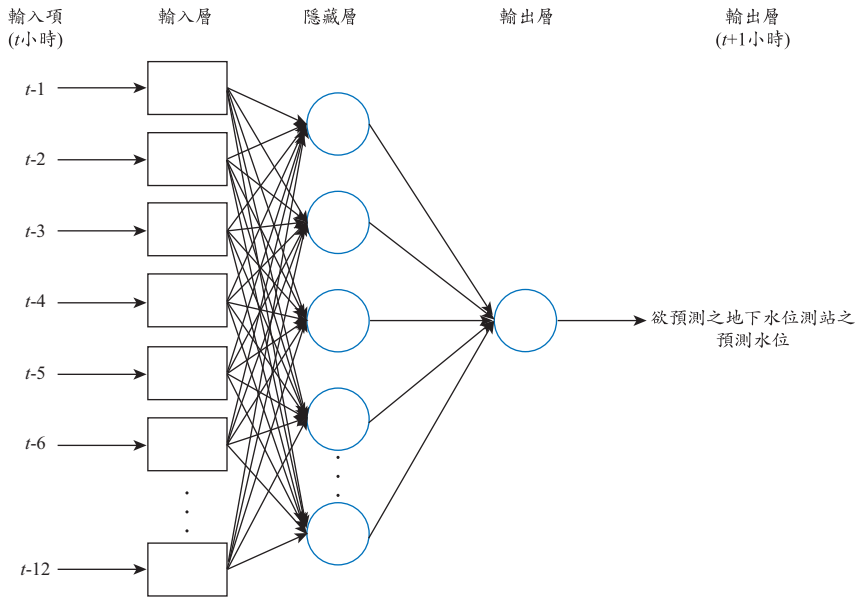


圖 5 BPN1 模式輸入輸出示意圖

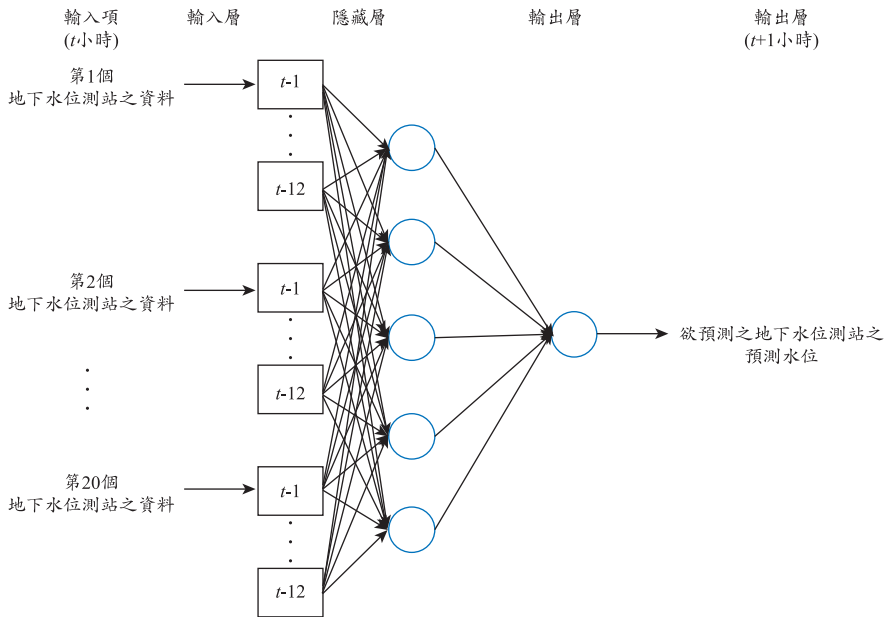


圖 6 BPN2 模式輸入輸出示意圖

1. 直接以單站自身地下水水位資料作為 BPN 模式輸入項，進行地下水水位之預測，簡稱為 BPN1。其輸出輸入示意圖繪製如圖 5；
2. 直接以自身及其他 19 個測站之地下水水位資料，作為 BPN 模式之輸入項，進行地下水水位之預測，簡稱為 BPN2。其輸出輸入示意圖繪製如圖 6；
3. 直接以影響範圍內之地下水水位測站資料，作為 BPN 模式之輸入項，進行地下水水位之預測，簡稱為 BPN3。其輸出輸入示意圖繪製如圖 7；

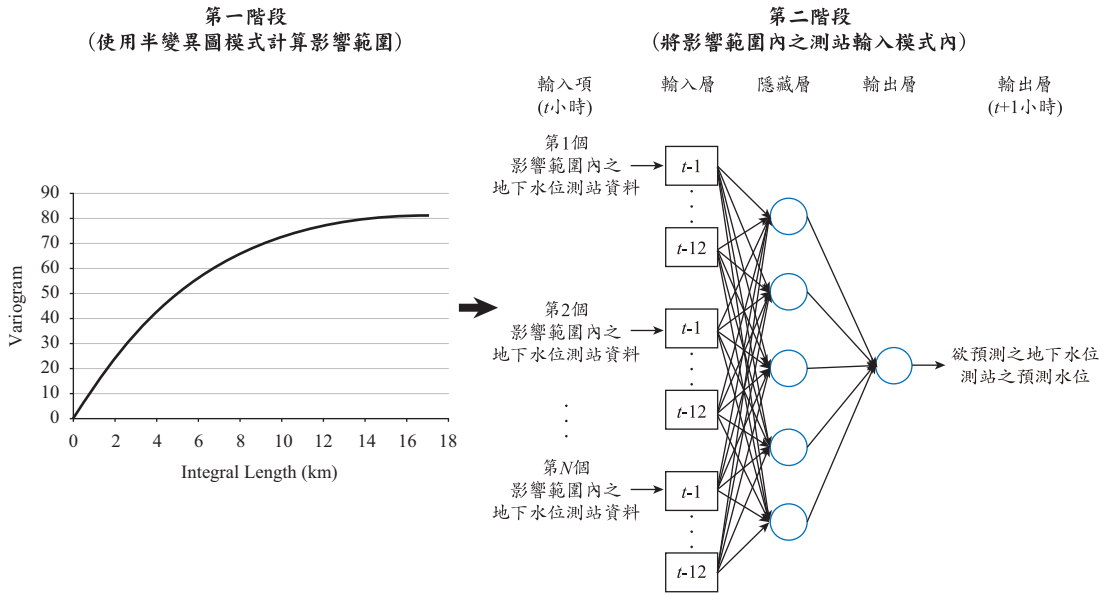


圖 7 BPN3 模式輸入輸出示意圖

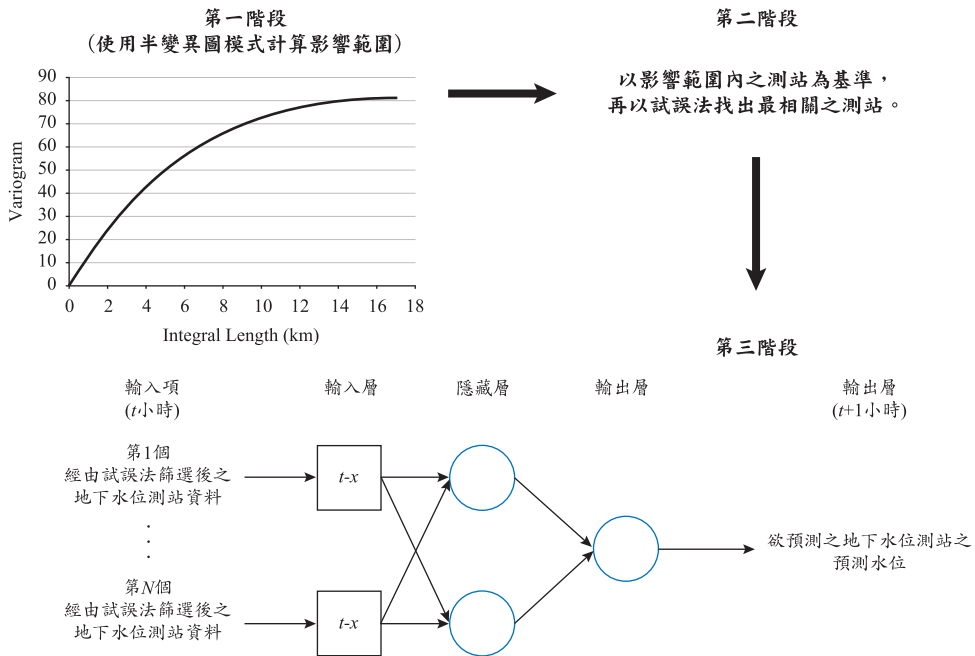


圖 8 BPN4 模式輸入輸出示意圖

4. 先找出影響範圍內之地下水位測站，再以試誤法找出最佳 BPN 模式之輸入項，簡稱為 BPN4。其輸出輸入示意圖繪製如圖 8。其中，BPN4 模式所使用之試誤法詳細原則如下：

首先，先依據欲預測地下水水位之測站，其單站(即 BPN1)模式輸入資料之最佳時間序列為主，再以半變異圖模式分析出影響範圍內之地下水位測站，將各種組合分別輸入模式內預測地下

表 2 試誤法篩選後地下水位測站與相關測站名稱

測站名稱	試誤法篩選後地下水位測站與相關測站名稱
白河	新東
柳營	新東
新東	白河
紀安	港尾
總爺	紀安
港尾	下營
下營	總爺、港尾
大文	後港、頂山、三股
三股	大文、頂山
頂山	大文、三股
後港	大文、港尾
錦湖	港尾、下營
新市	台南、南科
南科	台南、新市
南興	安慶、南科、台南
仁和	永康、安慶
五甲	永康
永康	新市
安慶	南興、仁和、永康
台南	南科

水位，找出具有最大 CE 值之測站組合。例如：白河站在 BPN1 模式之輸入資料最佳時間序列為 $t-10$ ，因白河站之影響範圍內之地下水位測站為新東站及柳營站兩個測站，故將白河搭配新東、白河搭配柳營、白河搭配新東及柳營等三種組合之 $t-10$ 時之資料予以試誤，從中找出最大 CE 值之組合，此組合之測站資料即為 BPN4 模式之輸入資料。本研究經由上述步驟篩選後之各地下水位測站與其相關測站名稱整理於表 2。

3.5 模式輸入參數之決定

不論是 BPN 或其他類型之神經網路模式，皆需事先決定許多重要的參數，俾使該模式能夠有效運作及演算，本研究中各項參數設定之方法分述如下：

3.5.1 訓練及驗證資料比例

BPN 模式之輸入單元資料可以分為訓練及驗證資料，訓練資料之分佈對於整個網路學習效果有很大的影響，當訓練資料分佈不均勻時，

BPN 模式的學習能力將會跟著降低，反之當訓練資料分佈均勻時，BPN 模式之學習能力則會表現較佳。為了使訓練資料分佈均勻且客觀，過去研究採取之方式有以 7:3 (葉怡成, 2003) 或 4:1 (林明宏等, 2004) 比例分成訓練與驗證資料筆數。本研究中經過多次測試後，採取 7:3 比例分配訓練與驗證資料筆數。

本研究各測站所蒐集之月平均地下水位資料期間是從 2001 年 1 月至 2011 年 12 月，單一測站之資料共計有 11 年 132 筆，故將前 8 年之資料(共計 96 筆)作為 BPN1 模式之訓練資料；後 3 年之資料(共計 36 筆)作為 BPN1 模式之驗證資料。BPN2 模式由於是以 20 個測站之地下水位資料進行預測，因此共有 2,640 個月(132 個月*20 站=2,640 個月)之月平均地下水位資料。換言之，共有 2,640 筆地下水位資料可供模式使用。其中，本研究將前 1,920 筆作為訓練資料；另 720 筆資料作為驗證資料。BPN3 模式則是以影響範圍內之測站資料進行地下水位預測，由於各測站於此範圍內之鄰近測站數目並不相同，因此各站之模式訓練與驗證資料數目也不一樣，但訓練及驗證資料之比例仍維持 7:3。BPN4 模式則是以試誤法找出影響範圍內相互影響較高的測站，其訓練及驗證資料之比例以 7:3 為標準，由於各測站所篩選出之測站數目並不相同，因此各站之訓練與驗證資料數目也不盡相同。

3.5.2 循環次數及隱藏層神經元數目

在 BPN 模式中，若不固定終止循環次數而讓程式自行收斂，其結果之標準差雖然會較趨於一致，但是要達到收斂條件所需之時間可能無法估計，故本研究經由反覆測試後，依據不同模式給予不同之最佳循環次數。此外，在 BPN 模式中，如果隱藏層神經元數目過少時，BPN 模式將無法有效模擬輸入與輸出間之正確關係，至於隱藏層神經元數目需要多少個，一般而言並無一定標準。學者葉怡成(2003)曾建議下面兩個公式決定隱藏層的神經元數目：

$$\text{隱藏層神經元數目} = (\text{輸入層數量} + \text{輸出層數量}) / 2 \dots\dots\dots (20)$$




圖 9 大文站之各模式驗證資料預測結果

表 3 大文站驗證資料模擬結果評估表

大文站	BPN1	BPN2	BPN3	BPN4
隱藏層神經元	2	10	10	10
循環次數	10000	1000	20000	20000
RMSE_Test	0.340	0.423	0.292	0.240
CE_Test	0.488	0.162	0.603	0.742

$$\text{隱藏層神經元數目} = (\text{輸入層數量} \times \text{輸出層數量})^{0.5} \dots\dots (21)$$

本研究依據上面二式之結果為試誤起始值，經由反覆測試後依據不同模式給予不同之最佳隱藏層神經元數目。

3.6 地下水位測站預測結果

本研究共使用 20 個地下水位測站資料進行預測，在此僅以大文站之預測結果為例加以說明。由表 1 可知，大文站之影響範圍內共計有 11 個測站，分別為後港、頂山、三股、港尾、紀安、南興、總爺、安慶、南科、下營及台南，故 BPN3 模式之輸入資料為上述 11 站之地下水位資料。由於各站分別有 132 筆資料，本研究將各站之前 96 筆作為訓練資料，後 36 筆作為驗證資料，因此 BPN3 模式之訓練資料共有 1152 筆，驗證資料共有 432 筆。此外，BPN3 模式之隱藏層設定為 1 層；隱藏層神經元數目設定為 10 個；循環次數設定為 20,000 次。

於 BPN4 模式中，本研究先將影響範圍內 11

個測站之地下水位資料輸入 BPN4 模式進行測試，結果發現若輸入後港、頂山、三股三站之資料將會有較佳之預測結果，故本研究將大文、後港、頂山及三股站之前 96 筆資料作為訓練資料；後 36 筆資料作為驗證資料，亦即訓練資料共計有 384 筆，驗證資料共計有 144 筆。此外，BPN4 模式之隱藏層設定為 1 層；隱藏層神經元數目設定為 10 個；循環次數設定為 20,000 次。

大文站經由 BPN1、BPN2、BPN3 及 BPN4 四種模式所預測之地下水位結果，與實際觀測值分別繪製於圖 9。此外，本研究再分別計算出 BPN1、BPN2、BPN3 及 BPN4 等四個模式預測結果之 CE 值與 RMSE 值，大文站四個模式驗證資料之 CE 值與 RMSE 值分別整理於表 3。由表 3 結果顯示，驗證資料於四個模式之 CE 值分別為 0.488、0.162、0.603 及 0.742；而四模式驗證資料之 RMSE 值分別為 0.340、0.423、0.292 及 0.240。由上述結果可知，BPN4 模式之預測結果較佳；BPN1 及 BPN3 模式之預測結果較次佳；BPN2 模式之預測結果最差。

表 4 四個模式驗證資料之 CE 值

測站名稱	CE 值			
	BPN1	BPN2	BPN3	BPN4
白河站	0.762	0.555	0.796	0.873
柳營站	0.792	0.664	0.798	0.834
新東站	0.714	0.503	0.750	0.804
紀安站	0.617	0.319	0.697	0.818
總爺站	0.722	0.488	0.729	0.813
港尾站	0.632	0.458	0.709	0.792
下營站	0.853	0.673	0.896	0.912
大文站	0.488	0.162	0.603	0.742
三股站	0.634	0.495	0.717	0.814
頂山站	0.686	0.519	0.802	0.831
後港站	0.614	0.469	0.712	0.770
錦湖站	0.685	0.573	0.743	0.790
新市站	0.581	0.519	0.669	0.715
南科站	0.504	0.415	0.640	0.788
南興站	0.796	0.619	0.850	0.853
仁和站	0.635	0.239	0.720	0.739
五甲站	0.394	0.403	0.520	0.678
永康站	0.682	0.593	0.780	0.798
安慶站	0.353	0.366	0.547	0.637
台南站	0.683	-1.910	0.724	0.759
平均值	0.623	0.356	0.720	0.788
標準差	0.123	0.549	0.093	0.065

3.7 小結

綜合上述二十個地下水位觀測站之預測結果，本研究將四種模式驗證資料之 CE 值彙整於表 4，其相關討論如下：

首先，根據表 4 之結果可知，BPN1 模式有六個測站之效率係數 CE 值大於 0.7，為預測結果較佳之測站，CE 值介於 0.5 至 0.7 的測站數則有 11 個，另外有四個測站之 CE 值低於 0.5 以下，為預測結果較差之測站。BPN2 模式雖然有兩個測站之 CE 值較 BPN1 模式為佳，但其差異並不大。再者，BPN2 模式並無任何測站之效率係數 CE 值大於 0.7，研判可能是輸入過多之地下水位資料導致過多干擾項，以至於 BPN2 模式之預測結果較 BPN1 模式差；BPN3 模式則有十四個測站之效率係數 CE 值大於 0.7，顯見經由克利金法計算出影響範圍後，再依據此影

響範圍篩選出相關之地下水位測站資料，的確能將較無相關之測站去除，藉以提升 BPN 模式之預測精確度；BPN4 模式其效率係數 CE 值大於 0.7 以上者則高達八個測站，可見經過再篩選之地下水位測站資料，的確更能良好地模擬地下水水位間之非線性變化。

接著，將四種模式驗證資料 CE 值之平均值與標準差計算出，如表 4 所示。由表 4 之結果可發現，BPN4 模式之 CE 平均值最高；BPN3 模式 CE 之平均值次高；BPN1 模式 CE 之平均值較低；BPN2 模式 CE 之平均值最低。換言之，在此四種模式中，BPN4 模式之表現最佳；BPN3 及 BPN1 模式次之；BPN2 模式表現最差。若以 CE 之標準差觀察可發現，BPN4 模式之 CE 標準差最小；BPN3 模式之 CE 標準差次小；BPN1 模式 CE 之標準差較大；BPN2 模式 CE 之標準差最

表 5 測站之相關站數與驗證資料 CE 值增加幅度

測站名稱	BPN3	BPN4	驗證資料 CE 值增加幅度	驗證資料 CE 值增加百分比
	相關站數	相關站數		
白河站	2	1	0.077	10%
柳營站	5	1	0.036	5%
新東站	3	1	0.054	7%
紀安站	13	1	0.121	17%
總爺站	10	1	0.084	12%
港尾站	12	1	0.083	12%
下營站	9	2	0.016	2%
大文站	11	3	0.139	23%
三股站	7	2	0.097	14%
頂山站	6	2	0.029	4%
後港站	11	2	0.058	8%
錦湖站	3	2	0.047	6%
新市站	8	2	0.046	7%
南科站	10	2	0.148	23%
南興站	12	3	0.003	0%
仁和站	4	2	0.019	3%
五甲站	3	1	0.158	30%
永康站	8	1	0.018	2%
安慶站	10	3	0.090	16%
台南站	11	1	0.035	5%

大。由上述結果可知，BPN4 模式不但預測之準確度較高，且其精確度高，至於 BPN2 模式不論在 CE 之平均值或標準差上，皆表現最差。

由表 4 之結果亦可發現，相較於 BPN1 與 BPN2 兩個模式，BPN3 模式驗證資料之 CE 值的確有所提升，顯見經過影響範圍再篩選後之資料，的確對於地下水位之預測有所幫助。然而，由克利金半變異圖模式回歸配套結果發現(詳見圖 4)，本研究地區之影響範圍並不明顯，故若一測站其附近有較多地下水位測站時，將會把許多並不相關之測站資料也輸入模式內，造成 BPN3 模式之預測結果並無明顯之提升(例如：總爺站、南興站、台南站)，故本研究以人工試誤的方式篩選影響範圍內之地下水位資料，作為 BPN4 模式之輸入項。

最後，本研究將 20 個地下水位測站之相關站數與驗證資料 CE 值增加幅度，整理如表 5 所示。由表 5 之結果可發現，白河、紀安、總爺、港尾、大文、三股、南科、五甲、安慶等九站，

其 BPN4 模式之驗證資料 CE 值皆較 BPN3 模式提高 10%以上，且能大大減少相關站數之使用量；再觀察表 5 發現，雖然柳營、新東、下營、頂山、後港、錦湖、新市、南興、仁和、永康、台南等 11 站，其 BPN4 模式較 BPN3 模式之驗證資料 CE 值提高幅度並不大(0~8%)，但資料經由人工試誤法篩選後，能將影響模式精確度之干擾項去除，將原本平均約 8 站之相關測站減少平均 2 站，亦即表示 BPN4 模式不僅可以有效地提高預測結果之精確度，並且可以減少模式所需輸入之相關地下水位資料，進而減少模式訓練時間以及資料成本的使用。

四、結論與建議

4.1 結論

本研究之目的是希望以較少量之地下水位資料，即能有效提高 BPN 模式於地下水位之預測效果，因此本研究除了以單站自身地下水位資料作為 BPN 模式輸入項(稱為 BPN1 模式)，以及直

接以自身及其他 19 個測站之地下水位資料作為 BPN 模式輸入項(稱為 BPN2 模式)外,另外亦嘗試 BPN 模式結合克利金法之半變異圖理論(稱為 BPN3 模式),以及先經由半變異圖找出影響範圍後,再以人工試誤法篩選出周遭測站,並以 BPN 模式進行地下水位之預測(稱為 BPN4 模式)。本研究將上述四種模式應用於台南地區同一含水層的 20 個地下水位測站,其所得之結論整理分述如下:

1. 由本研究之結果可知,單站(BPN1)模式驗證資料之效率係數 CE 值有五個測站大於 0.7,而 CE 值介於 0.5 至 0.7 的測站數則有 11 個,另外有四個測站之 CE 值低於 0.5 以下,這些結果代表單站模式仍未具有足夠之能力來描述地下水位時間序列之非線性問題,亦即各測站之地下水位預測精確度仍有提升之空間。
2. 由 BPN2 模式在 20 個測站之地下水位預測結果發現,除了安慶及五甲兩個測站外,BPN2 模式之預測結果的表現皆較 BPN1 模式為差,且並無任何測站之效率係數 CE 值大於 0.7,研判可能是因為輸入過多之地下水位資料導致過多干擾項,因而造成 BPN2 模式之預測結果表現不佳。
3. 由 BPN3 模式之預測結果可發現,在本研究所使用的 20 個測站中,有 14 個測站驗證資料之效率係數 CE 值大於 0.7;有 4 個測站驗證資料之 CE 值介於 0.6~0.7;僅有 2 站之 CE 值介於 0.5~0.6。顯見經由半變異圖模式計算出影響範圍後,再依據此影響範圍篩選出相關之地下水位測站資料,的確能將較無關聯之測站資料去除,藉以提升 BPN 模式之預測精確度。
4. 由於本研究地區之影響範圍並不明顯,故若一測站其附近有較多地下水位測站時,將會把許多並不相關之測站資料也輸入 BPN3 模式內,進而造成 BPN3 模式之預測結果並無明顯之提升(例如:總爺站、南興站、台南站),因此本研究嘗試以試誤法篩選出影響範圍內之測站資料,藉以提升模式預測之精確度,稱為 BPN4 模式。
5. 由 BPN4 模式應用於 20 個測站之地下水位預

測結果得知,效率係數 CE 值大於 0.7 者高達 18 個測站,另外 2 個測站則介於 0.6~0.7,且其 CE 值較 BPN3 模式提高 10%以上者有 9 站,而另 11 站則提高約 0~8%。由上述結果可見經過再篩選之地下水位測站資料,不但能將影響模式精確度之干擾項去除,並能將原本平均約 8 站之相關測站減少到平均 2 站。換言之,BPN4 模式不僅可以有效地提高預測結果之精確度,並可以大幅減少所需輸入之相關地下水位資料,進而減少模式訓練時間以及資料成本的使用。

4.2 建議

1. 由於本研究地區經由半變異圖模式配套所得之影響範圍並不明顯,建議日後之研究可考慮使用非等向性的半變異圖模式進行影響範圍的估算,以求得較為明確之影響範圍。
2. 本研究只將各站影響範圍內之相關測站地下水位資料納入模式之輸入因子中,建議後續研究亦可將影響地下水位變化之因子(例如:降雨量、地質...等)納入考量,相信對於模式預測之精確度將會有所提升。
3. 本研究使用 RMSE 與 CE 兩種指標來評估模式之優劣,建議未來可再加入一些針對地下水位之評估指標來評估模式之適用性。

參考文獻

1. 吳國儒、高慧珊、鍾昌翰、何宜樺、張斐章, 2008, 「以類神經網路推估蒸發量」, 農業工程學報, 第 54 卷, 第 3 期, 第 1-13 頁。
2. 吳嘉文, 2001, 「利用集水區水位記錄改善分佈型水筒模式之探討」, 國立成功大學水利及海洋工程學系碩士論文。
3. 林承賢, 2012, 「以類神經網路建構濁水溪流流域地下水位推估模式」, 國立臺灣大學生物環境系統工程學研究所碩士論文。
4. 林明宏、張順孔、李德河、方世杰, 2004, 「類神經網路應用在阿里山公路崩壞潛能評估之研究」, 全國災害危機處理學術研討會論文集, 2-102-2-109。

5. 林俊慶，2010，「應用類神經網路及降雨資料於地下水位補遺之研究-以雲林縣北港站為例」，逢甲大學環境資訊科技碩士論文。
6. 施文豪，2007，「類神經網路在颱風暴潮預測之研究」，立德管理學院資源環境研究所碩士論文。
7. 張庭瑞，2012，「類神經網路在堤趾沖刷深度預測之研究」，國立中興大學土木工程學系所碩士論文。
8. 陳奕任，2011，「結合支撐向量機與倒傳遞神經網路於颱風降雨預測之研究」，國立嘉義大學土木與水資源系碩士論文。
9. 傅怡釧，2006，「多湖區系統最佳地表地下聯合操作之研究」，國立交通大學土木工程系所碩士論文。
10. 游智宇，2007，「以類神經網路預測淡水河口暴潮偏差之研究」，國立中興大學土木工程學系所碩士論文。
11. 黃浚瑋，2006，「應用遺傳演算法與類神經網路於地表地下聯合營運」，國立交通大學土木工程系所碩士論文。
12. 經濟部水資源局，2001，臺灣地區地下水文圖繪製工作。
13. 葉怡成，2003，「應用類神經網路」第八版，儒林圖書公司，台北市。
14. 詹明修、徐名顯，2011，「以倒傳遞類神經網路進行水庫入流量預報」，第二十屆水利工程研討會。
15. 劉家蓉，2012，「以支撐向量分類與倒傳遞神經網路為基礎的地下水水位預測模式」，國立嘉義大學土木與水資源系碩士論文。
16. 鄭鈞瑋，2012，「結合經驗模態分解與類神經網路於地下水位預測之研究」，淡江大學水資源及環境工程學系碩士論文。
17. 聯合國統計，2005，http://en.wikipedia.org/wiki/UN_Food_%26_Agriculture_Organisation
18. Chen C.S., Chen B.P.T., Chou F.N.F., Yang C.C., (2010), "Development and application of a decision group back-propagation neural network for flood forecasting." *Journal of Hydrology*, 385, 173-182.
19. Chen L.H., Chen C.T., Lin D.W., (2011), "Application of integrated back-propagation network and self organizing map for groundwater level forecasting," *Journal of Water Resources Planning and Management, ASCE*, 137(4), 352-365.
20. Chang T.C., Chao R.J., (2006), "Application of back-propagation networks in debris flow prediction." *Engineering Geology*, 85, 270-280.
21. Ioannis N.D., Paulin C., Ioannis K.T., (2005), "Groundwater level forecasting using artificial neural network." *Journal of Hydrology* 309, 229-240.
22. Karamouz M., ASCE F., Mohammad M., Tabari Rezapour, Kerachian R., (2004), "Conjunctive use of surface and groundwater resources: application of genetic algorithms and neural networks." *Critical Transitions in Water and Environmental Resources Management*, 1-10.
23. Lee T.L., (2008), "Back-propagation neural network for the prediction of the short-term storm surge in Taichung harbor, Taiwan." *Engineering Applications of Artificial Intelligence*, 21, 63-72.
24. Matheron, G., (1971), "The theory of regionalized variables and its applications." *Ecol de Mines, Fontainebleau, France*.
25. Nayak P.C., SATYAJI R.Y.R., Sudheer K.P., (2006), "Groundwater forecasting in a shallow aquifer using artificial neural network approach", *Water Resources Management*, 20, 77-90.
26. Rumelhart D.E., McClelland J.L., (1986), "Parallel distributed processing, explorations in the microstructure of cognition." vol. 1. Cambridge, MA, MIT Press.

收稿日期：民國 103 年 6 月 4 日
 修正日期：民國 103 年 7 月 9 日
 接受日期：民國 103 年 9 月 19 日