

以倒傳遞類神經網路探討水庫水質與 集水區降雨之相關性

Using Back-Propagation Neural Network (BPNN) to Assess the Relationship between Reservoir Water Quality and Watershed Rainfall

逢甲大學
水利工程與資源保育學系
副教授

張嘉玲*
Chia-Ling Chang

逢甲大學
水利工程與資源保育學系
研究生

陳永堯
Yong-Shen Chen

逢甲大學
水利工程與資源保育學系
大專生

魏逸葳
Wei-Yi Wei

逢甲大學
水利工程與資源保育學系
大專生

鄭雅庭
Ya-Ting Zheng

逢甲大學
水利工程與資源保育學系
大專生

王文生
Wen-Sheng Wang

摘 要

台灣為海島型國家，雨量充沛，但因特殊地理條件常造成缺水問題，伴隨水庫區內非點源污染嚴重，對庫區之水資源運用造成嚴重的影響。因此若能建立預測水庫水體的模式，提供我們模擬預測水庫水質之變化，便能提供地方單位做決策。本研究使用倒傳遞類神經網路探討降雨與水庫水體水質之相關性，進而以降雨資料預測水庫水體水質，所選擇預測之水質項目為卡爾森指標中的總磷、透明度、葉綠素，並以當日降雨量，前五日平均降雨量，月平均降雨量進行水庫水體水質之預測。本研究結果顯示，月平均降雨與水庫水體水質存在較高之相關性，換言之，採用月平均降雨量來預測水庫水體水質能力佳，其中又以總磷、葉綠素 a 之預測結果較好。

關鍵詞：倒傳遞類神經網路，卡爾森指數，水庫水質。

*通訊作者，逢甲大學水利工程與資源保育學系副教授，40724 台中市西屯區文華路 100 號，clchang@fcu.edu.tw

ABSTRACT

Reservoir water quality protection is an important work in water resource management. Meteorological and hydrological properties can influence the water quality in a reservoir. This study applied the Back-Propagation Neural Network (BPNN) to predict reservoir water quality. According to rainfall data, the BPNN can learn and describe the relationship between rainfall data and reservoir water quality. The results show that the prediction efficiency of reservoir water quality is high according to average monthly precipitation. However, the prediction efficiency of reservoir water quality is poor according to the average precipitation for the five days prior to the water quality monitoring date or the precipitation on the water quality monitoring date.

Keywords: Back-Propagation Neural Network (BPNN), Carlson trophic state index (CTSI), reservoir water quality.

一、前言

台灣因地形變化劇烈，及降雨情況因季節性差異大，導致集水區不易涵蓄水分，且降雨在地表停留的時間短暫，使得水資源的有效利用相對困難。為了更有效的利用地表上的水資源，便在河谷內建立了許多的人工建築物，如水庫，攔河堰等以蓄水及引水，故台灣對水庫的依賴性極高，但水庫的興建對環境的影響相當巨大，且台灣經過數十年的開發，可興建水庫的集水區已經不多，而近年來保育觀念的提升，使得大型水庫的興建相當困難。因此，未來對水資源的需求勢必日漸增加，故現今的水資源問題已從如何興建水庫以擴充水源，轉而思考如何對現有的水資源做更有效的管理與利用，達成水資源永續利用的目標。

在水資源永續利用議題上，集水區保育與管理為相當重要的工作，集水區內包含點源污染及非點源污染，其中非點源污染因屬擴散性污染，在污染源的傳遞及擴散較不穩定，故較點源污染難以管控。若集水區污染源無法有效控制，則會流入河川水體或水庫，造成水體土砂淤積及優養化的情形，進而可能造成淨水場處理成本的負擔，及影響到正常供水的穩定度。由於降雨會誘發非點源污染，降雨特性與水體水質存在一定程

度之相關性，故本研究將應用倒傳遞類神經網路，探討降雨與水庫水體卡爾森優養指標中三個水質項目間的相關性，進而建立水庫水體水質預測模式。本研究主要目的是期望透過所建立的水庫水體水質預測模式，提供有關單位掌握水庫水體水質變化的趨勢，以作為水庫管理單位水質管理之重要參考依據。

二、文獻回顧

2.1 環境因子影響水質之相關研究

國際上常用許多指標來評估水體水質，用來評估水庫水體水質的指標很多，其中卡爾森優養化指標(CTSI)為台灣最常使用的指標。優養化是由於水庫中藻類的增生，而藻類的增生會造成水體的初級生產率增加，必須要評估水庫中的基礎生長率，來決定優養化的程度；CTSI 是利用理化參數評估水庫水質優養化程度，根據透明度、水中葉綠素 a 及總磷量含量等，CTSI 是採用以上所得各數值平均所得之綜合性指標。採用此指標來呈現水庫水體水質變化，可以增加水庫水質管理的便利性，因此，建立 CTSI 中三個水質項目的預測模式，則更顯重要。

過去的文獻中提到氣象條件與水質及卡爾森指標有一定的相關性。例如：何嘉華(2008)探討石門水庫集水區週遭人文環境變化資料與水

質監測結果間之相關性，發現降雨特性及土地利用均與水體水質存在極大之相關性；周展鵬(2012)觀察到微囊藻團在水體中粒徑分佈之情形，受到週遭環境因子的影響甚劇，其研究透過不同藻團之粒徑，進一步評估與水庫水體水質之相關性，發現藻團粒徑與卡爾森指數、葉綠素a和水中導電度有顯著之正相關。在眾多氣象水文因子中，因降雨沖擊地表會使非點源污染量增加，故本研究認為降雨特性與水庫水體水質間之相關性，應高於其他許多其他氣象因子，因此，在建立水庫水體水質預測模式時，降雨資料則必定是相當重要的資訊。

2.2 應用類神經網路之相關研究

類神經網路因需脫離複雜的物理或數學理論架構，其理論較為簡明，且容易透過演算法則建立不同條件下之特定模式，因此，近年來被應用在許多不同的領域中。而現今依不同領域及需求，類神經網路也可以結合不同的理論及方法，而形成各類型的類神經應用模式，例如：倒傳遞類神經網路則是一個廣泛被使用的類神經網路模式。在水環境相關研究的領域，類神經網路亦常被用來作為建立預測模式的工具。

在水文預測模式方面，例如：Anctil *et al.* (2004)曾應用類神經網路來預測流量，發現通常短期趨勢仰賴高頻度的輸入參數，包括即時雨量及流量資訊，而長期連續預測輔以氣溫或臨前條件可提升預測能力；Riad *et al.* (2004)亦曾應用類神經網路模式建立降雨-逕流域測模式，發現模式類神經網路輸入層神經元的調整，可以提高模擬結果的可信度。在地下水質預測方面，例如：高力山與張斐章(2011)曾應用類神經網路建立地下水砷濃度推估模式，以解決高度非線性砷污染傳輸問題，及提高砷濃度推估之準確性，其研究模式成功解決過去傳統模式不易推估區域地下水中砷污染問題。在水庫水質預測模式方面，例如：范正成等(2006)曾應用類神經網路，配合其他現地數位化水質自動記錄監測儀，建立完備的懸浮固體濃度即時監測系統，以快速準確的推估

預測懸浮固體濃度。

根據過去許多文獻指出降雨與水庫水體水質間具有相關性，而類神經網路的理論基礎，可應用歷史資料建立系統間的關聯性，其黑盒分析能力可克服傳統定率式模式的限制，因此，相當適合用來探討集水區內環境因子間的相關性。本研究則將應用類神經網路模式，建立水庫降雨與卡爾森指標中的總磷、透明度、葉綠素 a 的預測模式，探討各種降雨因子對於此三個水庫水體水質項目之預測能力。

三、研究方法

3.1 建立水庫水體預測模式

3.1.1 水庫水體水質項目選擇

在水庫水體水質指標中，卡爾森優養化指標(CTSI)為最廣泛被使用之指標，透過此指標有關單位及民眾均可以很清楚地評估及瞭解水庫水質水質狀態。CTSI 之計算係依據水中的總磷、透明度及葉綠素-a 等三項因子，因此，本研究根據優養化原始定義，選定總磷、透明度及葉綠素-a 三項因子，作為主要水庫水體預測模式之水質項目。

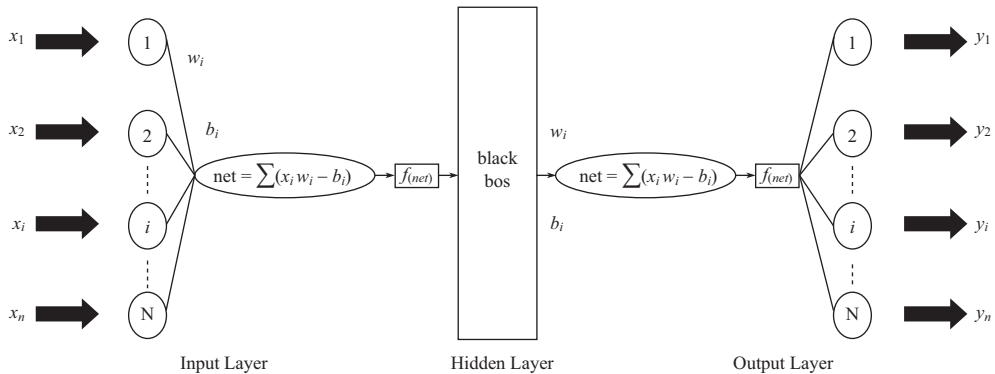
CTSI 之計算方法如式(1)，其中 TSI(TP)、TSI(SD)及 TSC(Chl)分別是由總磷、透明度及葉綠素-a 之監測數據，所轉換成之指標值，其轉換及計算方法如式(2)~式(4)所示。CTSI 值大小代表水質優養化的程度，當 CTSI 值大於 50，表示水體呈現優養狀態，CTSI 值介於 40~50 之間，表示水體為中養狀態，而 CTSI 小於 40，則表示水體為貧養狀態。式中 TP = 總磷濃度 (μg/l)；SD = 透明度(m)；Chl-a = 葉綠素 a (μg/l)。

$$CTSI = \frac{TSI(TP) + TSI(SD) + TSI(Chl)}{3} \dots\dots (1)$$

$$TSI(TP) = 14.42 \ln(TP) + 4.15 \dots\dots\dots (2)$$

$$TSI(SD) = 60 - 14.41 \ln(SD) \dots\dots\dots (3)$$

$$TSI(Chl) = 9.81 \ln(Chl - a) + 30.6 \dots\dots\dots (4)$$



資料來源：廖崇聖(2011)

圖 1 倒傳遞類神經網路示意圖

3.1.2 類神經網路建模

類神經網路有聯想速度快、網路架構容易維持、適於解決最佳化、非線性系統問題、具容錯特性與平行處理能力等優點，處理複雜的工作時，不需要針對問題定義複雜的解微分方程、積分方程其他的數學方程式，而是直接對大量資料進行分析與學習，來建構模式模擬非線性的複雜問題。

倒傳遞網路模式(Back-Propagation Network, BPN)是目前神經網路學習模式中最具代表性，應用最普遍的模式。一般常用的倒傳遞類神經網路架構由三層所構成，包含輸入層、隱藏層及輸出層，如圖 1 所示，隱藏層是在輸入層與輸出層之間，與外界資訊隔離，實際上輸入層如同單層感知器的輸入層，並不對輸入資訊作處理，只是當外界輸入訊息的傳遞介面，將輸入訊息直接往後傳遞，因此，實際有作用的神經元只有隱藏層及輸出層兩層(Jain *et al.*, 2003)。倒傳遞網路演算法屬多層前饋式網路，採用監督式學習法，監督式學習法常用以處理輸入輸出間之非線性映射關係，乃藉由網路輸出值與目標值間的誤差以修正模式，適合運用在分類、決策、相關性分析及預測分析(Rajurkar *et al.*, 2004)。

倒傳遞神經網路其學習過程是由訊息正向傳播與誤差修正負向傳播所組成。在正向傳播過程中，輸入訊息從輸入層經由隱藏層加權運算，透過轉化函數處理後，再傳向輸出層計算網路輸

出值；若在輸出層不能得到目標輸出值，則轉為反向傳播，將誤差訊號回傳修改各層神經元的權重與偏權值，使誤差值達到容忍誤差範圍之內而停止。其運算公式如下：

$$y_j^n = f(\text{net}_j^n) \quad \dots\dots\dots (5)$$

式(5)中， y_j^n 為神經元輸出值， f 為轉換函數， net_j^n 為第 $n-1$ 層輸出值的權重累加值，可表示為式(6)，其中 w_{ji}^n 為第 n 層第 j 個神經元與第 $n-1$ 層第 i 個神經元的連結權重、 b_j^n 為第 n 層第 j 個神經元的偏權值。

$$\text{net}_j^n = \sum_i w_{ji}^n y_i^{n-1} + b_j^n \quad \dots\dots\dots (6)$$

由於倒傳遞類神經網路屬監督式學習，其學習的目的在降低網路輸出值與目標輸出值間的差距，誤差函數 E 的公式為式(7)，其中 d_j 為目標輸出值， y_j 為網路計算輸出值。因此，倒傳遞網路的學習過程，即為使上述誤差函數最小化的過程，利用最陡坡降法來找出誤差函數 E 的最佳解，也就是最小誤差平方和(Philip and Joseph, 2003)。

$$E = \frac{1}{2} \sum_k (d_j - y_j)^2 \quad \dots\dots\dots (7)$$

網路的演算即在調整權重值使能函數往最大梯度方向下降，權重調整的幅度和誤差函數對其敏感度成正比，也就是和誤差函數對權重的偏

微分值大小成正比，故：

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} \quad \dots\dots\dots(8)$$

其中， η 為學習速率，其大小決定最陡坡降法修正幅度的大小，而 $\frac{\partial E}{\partial w_{ji}}$ 可以用微積分中的連鎖律

(Chain Rule) 得出式(9)，將式(9)中 δ_j^n 為將此式代入(8)式中可得式(10)。式(10)即倒傳遞網路演算法之關鍵公式，每輸入一組訓練範例，同時有輸入項目與目標輸入值，各連結的權重即可依此方式加以調整。式(11)中 p 為第 p 組訓練範例。

$$\frac{\partial E}{\partial w_{ji}} = \delta_j^n y_j^{n-1} \quad \dots\dots\dots(9)$$

$$\Delta w_{ji} = \eta \delta_j^n y_i^{n-1} \quad \dots\dots\dots(10)$$

$$w_{ji}(p) = w_{ji}(p-1) + \Delta w_{ji} \quad \dots\dots\dots(11)$$

目前倒傳遞網路已經有許多應用實例，在分類與預測等複雜問題分析上的表現，往往比傳統統計分析有更好的表現；因此，本研究中選擇倒傳遞類神經網路來模擬不同降雨模式－水庫水體水質因子之間的關係。本研究所建構之倒傳遞類神經網路架構，輸入層分別為 3 種不同時間的降雨型態，包括：當日降雨量、前五日平均降雨量及月平均降雨量，分別對輸出層的 3 種水質項目，總磷、透明度及葉綠素-a，建立 9 個預測模式。

本研究應用倒傳遞類神經網路所建立之降雨-水庫水體水質預測模式，輸入層神經元為氣象站之降雨資料，輸出層神經元為水質測站之監測資料，採用 2002~2009 年的資料進行模式訓練，2010~2011 年的資料進行模式驗證。

3.2 評鑑指標

3.2.1 相關係數(correlation coefficient; R^2)

指標為評估預測值與實測值之間的線性相關， R^2 越趨近 1，表示模擬趨勢的準確度越高。 R^2 的定義如式(12)所示，式中 n 為資料筆數， x_i 及 y_i 分別為第 i 個時刻的水質實測值及預測值，

\bar{x}_i 及 \bar{y}_i 分別為水質實測值的平均及預測值的平均。

$$R^2 = \frac{\sum_{i=1}^n (x_i - \bar{x}_i)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}_i)^2 \sum_{i=1}^n (y_i - \bar{y}_i)^2}} \quad \dots\dots\dots(12)$$

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

此指標表示預測值與實測值之間的誤差量化，並用平方後開根號的方式，相除相對誤差的盲點，最佳值為 0，指標越大代表誤差越大。RMSE 的定義如式(13)所示，式中 n 為資料筆數， x_i 及 y_i 分別為第 i 個時測的水質實測值及預測值。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad \dots\dots\dots(13)$$

3.3 研究區域

本次研究選定石門水庫做為研究區域，石門水庫集水區位於大漢溪中上游段，其庫區位於桃園縣境內，橫跨龍潭、大溪及復興三鄉鎮，集水區面積為 763.4 平方公里，滿水位標高為 245 公尺，在民國 86 年所量測到的水庫總容量為 2 億 5178 萬立方公尺。主要目的為灌溉、防洪、給水、發電與觀光等效益，目前石門水庫集水區主要的功能是調節供水與灌溉。其每日平均由水庫調蓄之供水量約 80 萬立方公尺，加下游未控流量及三峽河抽水站，總供水量最大可達 148 萬立方公尺，主要供應新北市、桃園縣及新竹縣之用水，石門水庫集水區以山谷地為主，由於集水區上游地區的水土保持工作不夠確實執行，加上這幾年來幾次颱風所帶來的破壞，已經嚴重危害到石門水庫的壽命以及水庫的水質，使得颱風時期的水質的濁度高，危害到飲用水供給。本研究所選定庫區內之氣象站--石門氣象站，降雨資料取自此氣象站之監測資料，而水質測站的部分，亦選用庫區內之水質測站，共計有六個水質測站，包括：石門水庫一、石門水庫二、石門水庫三、石門水庫四、石門水庫五、石門水庫六，測站分佈如圖 2 所示。



資料來源：全國水質監測資訊網

圖 2 研究區域及研究測站設置圖

四、結果與討論

4.1 倒傳遞類神經網路模式建置

透過模式訓練及驗證，隱藏層個數、轉換函數、訓練次數及訓練速度等參數逐步調整後，其結果如表 1 所示，在模式訓練剛開始期間，訓練數據集和驗證數據集的誤差正常地都將同時降低，然而當模式開始產生 Overfitting 的現象時，驗證數據集的誤差將開始上升，此時網路訓練就停止，此時模式即建模完成，建置後之倒傳遞類神經網路模式，即可進行水庫水體水質之預測。

4.2 以倒傳遞類神經網路預測水庫水質

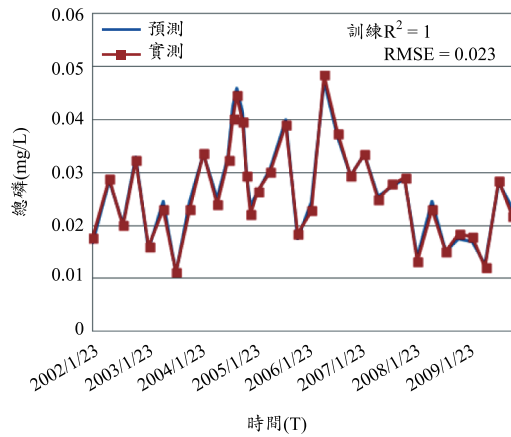
本研究以當日降雨資料預測水庫水體之總磷、透明度、葉綠素 a，模式訓練結果如圖 3(a)、3(b)、3(c)所示，驗證結果如圖 3(d)、3(e)、3(f)

所示。由結果可知模式訓練結果佳，對三個水質項目之預測結果 R^2 均為 1，但驗證結果則不佳，可以看出總磷、透明度、葉綠素 a 的預測值都明顯的偏低，最後在這三項水質的預測 R^2 都小於 0.5，即表示此模式在預測是不準確的。因此，以當日降雨資料預測總磷、透明度、葉綠素 a 的變化效果不佳。

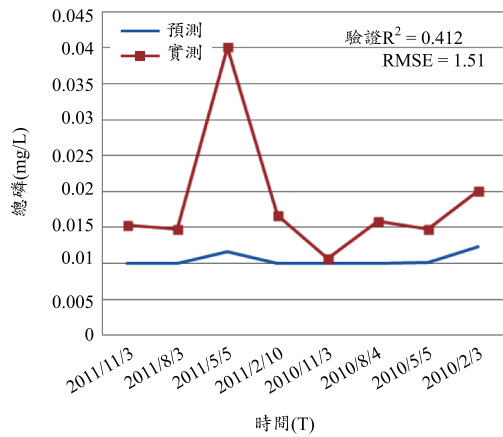
若以前五天降雨平均資料預測水庫水體之總磷、透明度、葉綠素 a，模式訓練結果如圖 4(a)、4(b)、4(c)，驗證結果如圖 4(d)、4(e)、4(f)所示。由結果可知模式訓練結果亦佳，對三個水質項目之預測結果 R^2 均為 1，但驗證結果亦不佳，固然總磷、透明度、葉綠素 a 的預測值有稍微提高的趨勢，但由於此三個水質項目預測在模式驗證時， R^2 值均小於 0.5，即表示此模式在預測是不準確的。因此，以前五天降雨平均資料預測總

表 1 轉換函數說明表

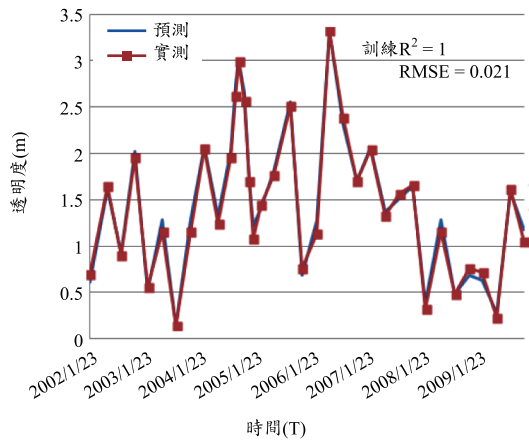
模式種類	神經元個數		轉換函數		訓練次數	學習速率
	隱藏層	輸出層	隱藏層	輸出層		
降雨-總磷	3	1	Logsig	Purelin	100	0.1
降雨-透明度	3	1	Logsig	Purelin	130	0.1
降雨-葉綠素 a	3	1	Logsig	Purelin	180	0.1




(a)總磷之訓練




(d)總磷之驗證



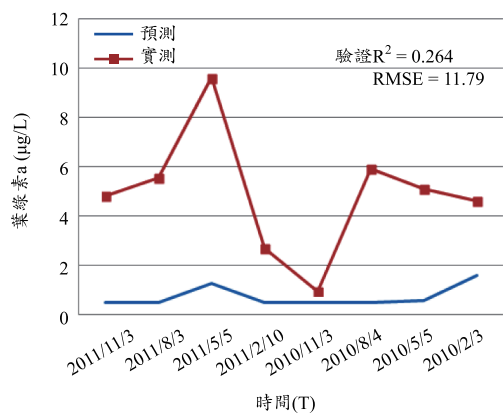
(b)透明度之訓練



(e)透明度之驗證




(c)葉綠素a之訓練




(f)葉綠素a之驗證


圖 3 當日降雨資料預測水庫水體水質




(a)總磷之訓練




(d)總磷之驗證




(b)透明度之訓練



(c)透明度之驗證




(e)葉綠素a之訓練

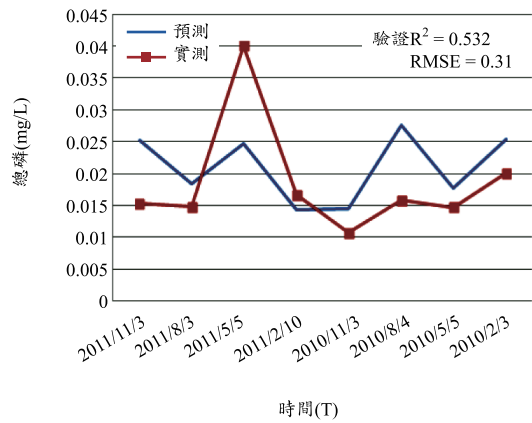


(f)葉綠素a之驗證


圖 4 前五日平均降雨資料預測水庫水體水質



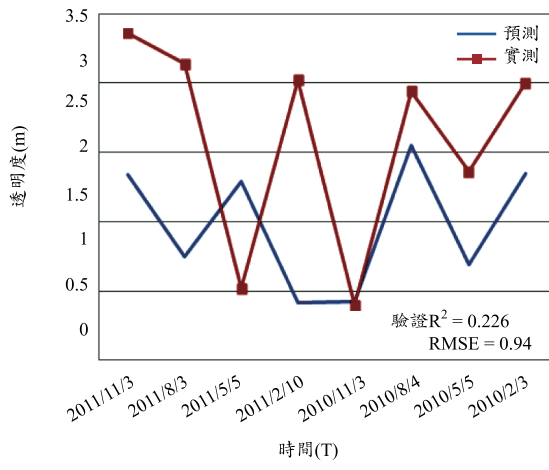
(a)總磷之訓練




(d)總磷之驗證




(b)透明度之訓練



(e)透明度之驗證



(c)葉綠素a之訓練



(f)葉綠素a之驗證

圖 5 月平均降雨資料預測水庫水體水質

磷、透明度、葉綠素 a 的變化效果亦不甚理想。

若以每月平均降雨資料預測水庫水體之總磷、透明度、葉綠素 a，模式訓練結果如圖 5(a)、5(b)、5(c)所示，驗證結果如圖 5(d)、5(e)、5(f)所示。由結果可知模式訓練結果亦佳，對三個水質項目之預測結果 R^2 均為 1，而從模式驗證結果來看，可以發現在預測總磷的驗證結果， R^2 大於 0.5 在趨勢的預測上是可被接受的，在預測透明度的驗證結果， R^2 小於 0.5，表示此模式對透明度的預測效果極為不準確，在預測葉綠素 a 的驗證結果，在趨勢上 R^2 為 0.8，表示此模式對於葉綠素 a 預測能力是相當不錯的。

由以上所建構的各種模式分析結果可知，以月平均降雨資料預測水質的能力是最好的，其中以葉綠素 a 的預測能力最強，其次為總磷，透明度的預測能力最差。

4.3 水質預測模式分析

本研究綜合分析當日降雨、前五天降雨平均、每月平均降雨等資料，對於水庫水體水質項目之預測結果。由數據圖中可知，採用當日降雨資料預測總磷、透明度、葉綠素 a，訓練結果佳，但驗證結果十分不理想；採用前五天降雨平均資料預測總磷、透明度、葉綠素 a，結果也是呈現訓練結果佳、驗證結果不佳的狀況。然而，若採用月平均降雨資料預測總磷、透明度、葉綠素 a，在總磷及葉綠素 a 的預測上，無論模式訓練或驗證，趨勢掌握度上均有顯著的提升。

以整體而言，這三種不同降雨模式的預測能力，以每月平均降雨的趨勢掌握最高，其次為前五天降雨平均模式，當日降雨模式的測能力則是最差的。李孟遠(2012)亦曾以降雨資料應用倒傳遞類神經預測河川水質，分別以當日降雨與前五天降雨量對河川水質進行預測，其前五天的預測能力優於當日降雨。由此結果推測，固然水體水質均會受到降雨特性的影響，但動態的河川水質與靜態的水庫水質所受到的影響仍是有所差異的，河川水質受到暴雨的影響較大，而水庫水體流況屬於靜態，其流動速度、混合、傳遞與交換較為緩慢，因此影響水庫水質之控制因子應為長

時距之降雨輸入，短期之降雨資料並不為主要之影響因子。

五、結論與建議

本研究採用倒傳遞類神經網路，探討降雨資料與水庫水體水質之相關性，未來即可依據此相關性分析結果，建立水庫水體水質之預測模式。主要結論與建議歸納如下：

1. 本研究採用三種不同降雨型態的預測模式，在這三種不同降雨模式的預測能力中，以每月降雨平均的趨勢掌握最高，其次為前五天降雨平均模式，當日降雨模式的測能力則是最差的。
2. 本研究採用三種不同降雨型態的預測模式，分別對卡爾森指數中三項水質項目進行預測，三項水質項目中以對透明度之預測效果最差，表示降雨資料與透明度間的相關性較不顯著；相對地，總磷及葉綠素 a 兩水質項目則與月平均降雨量有較高之相關性，因此，預測效果亦較佳。
3. 本研究單以降雨資料預測水庫水體水質的能力，其預測結果尚可，但與過去以降雨資料預測河川水質的結果相比，河川水質的預測能力比水庫水體水質的預測能力佳，推測水庫水體水質除受降雨影響外，亦受到許多其他氣象水文因子的影響。
4. 本研究初步建議水庫水體水質的預測模式，未來將加入氣象、水文資料進行預測，或是增加測站，加入不同的降雨型態，如：前 10 天、前 20 天的降雨資料，以提高各水質項目預測之準確度。

參考文獻

1. 何嘉華(2008)，石門水庫上游集水區水質與復興鄉人文環境之綜合研究，中央大學應用地質研究所學位論文。
2. 李孟遠(2012)，應用集水區模式於流量及水質預測-以台北水源特定區為例，逢甲大學水利工程研究所碩士論文。
3. 周展鵬(2012)，環境因子對微囊藻團粒化影響之研究-以新山水庫為例，臺灣大學環境工程

- 學研究所學位論文。
4. 范正成、張郁麟、楊文仁、劉哲欣(2006)，倒傳遞類神經網路應用於石門水庫懸浮固體濃度之即時分析與預測，中華水土保持學報，37卷4期，367-376頁。
 5. 高力山、張斐章(2011)，應用類神經網路推估區域地下水中砷污染之研究，農業工程學報，57卷3期，88-102。
 6. 廖崇聖(2011)，應用類神經網路預測颱風事件下之淨水場原水濁度，逢甲大學水利工程研究所碩士論文。
 7. Anctil, F., Michel, C., Perrin, C. and Andreassian, V. (2004), "A soil moisture index as an auxiliary ANN input for stream flow forecasting", Journal of Hydrology, Vol. 286 (1-4), 155-167.
 8. Jain, A. and Indurthy, S. (2003), "Comparative analysis of event-based rainfall-runoff modeling techniques-Deterministic, statistical, and artificial neural networks", Journal of Hydrologic Engineering, Vol.8(2), 93-98.
 9. Philip, N.S. and Joseph, K.B. (2003), "A neural network tool for analyzing trends in rainfall", Computers & Geosciences, Vol.29, 215-223.
 10. Raid, S. and Mania, J., Bouchaou, L. and Najjar, Y. (2004), "Rainfall-Runoff Model Using an Artificial Neural Network Approach", Mathematical and Computer Modelling, Vol.40, 839-846.
 11. Rajurkar, M.P., Kothyari, U.C. and Chaube, U.C. (2004), "Modeling of the daily rainfall-runoff relationship with artificial neural network", Journal of Hydrology, Vol.285, 96-113.

收稿日期：民國 102 年 1 月 24 日

修正日期：民國 102 年 7 月 5 日

接受日期：民國 102 年 7 月 5 日