

結合類神經網路與遺傳演算法於翡翠水庫 最佳控制優養化之研究

A Study of Combining the Neural Networks with Genetic Algorithms to the Optimal Control of Eutrophication in Feitsui Reservoir

財團法人中興工程顧問社
大地工程研究中心
研究員
中華大學
土木與工程資訊研究所
碩士

梁惠儀
Wai-Yi Leung

中華大學
土木與工程資訊研究所
教授

陳莉*
Li Chen

中華大學
土木與工程資訊研究所
博士生

王泰盛
Tai-Sheng Wang

中華大學
土木與工程資訊研究所
研究生

蔡祐竹
Yu-Chu Tsai

摘要

近來水庫優養化已成為嚴重的水質污染問題，影響水庫優養有許多因素，包括水庫的大小、深度和形狀，以及日照的強度、氣溫和營養鹽等。本研究考量污染源之時變性，企圖以類神經網路建立水質預測模式。此模式是根據六個重要關係因子來預測翡翠水庫之水質，其中包括北勢溪總磷濃度($\mu\text{g/L}$)、兩條支流鯉魚窟溪總磷濃度($\mu\text{g/L}$)、金瓜寮溪總磷濃度($\mu\text{g/L}$)、日最高降雨量(mm)、月平均降雨量(mm)、與水庫的淨入流量(CMSD) (入與出流量之差值)等。由於這些因子存在非線性關係，因此本研究利用類神經網路結合遺傳演算法來探討降低磷自支流進入水庫中的可行性，以維持水庫良好之水質狀態。

關鍵詞：優養化，類神經網路，遺傳演算法。

ABSTRACT

Eutrophication has been a serious problem which results in the pollution of water quality in reservoirs recently. A lot of factors including the size, depth and shape of a reservoir

*通訊作者，中華大學土木與工程資訊系教授，30067 新竹市五福路二段 707 號，lichen@chu.edu.tw

as well as the intensity of sun light, could affect nutrients concentration in reservoirs. In this study, we consider that the source pollution is unstable and attempt to use artificial neural networks (ANNs) to construct the water quality forecast models. This model is based on data from nutrient loads (which include the inflows from a main creek and two tributaries), average and maximum rainfall in the watershed, and net inflow (difference between inflow and outflow) to forecast the water quality in Feitsui Reservoir. These models use variant factors to predict the dynamic nutrient concentration. Owing to these factors exist non-linear relationships; ANNs were hybridized with genetic algorithms (GAs) to explore the feasibility of controlling phosphorus loads into the reservoir and maintaining a satisfied situation of water quality.

Keywords: Eutrophication, Artificial neural networks, Genetic algorithms.

一、前言

台灣地區降雨量分配不均，水庫蓄水往往為農業、民生和工業用水的主要來源，倘若水庫優養導致水質惡化，因而降低水源的有效供應，將會對未來的社會及生活影響甚鉅，因此水庫優養之控制是不可或缺之重要環節，若無善加保護水庫上游之集水區，容易發生土石流，使得泥沙淤積增加，因而降低水庫水源功能，同時也增加進入水庫營養鹽濃度。

水庫優養化的程度與水文有很大關係，在許多淡水中總磷是極為重要的限制因子，因此本研究將以翡翠水庫為研究對象。由圖 1 可以發現民國 90 年之後翡翠水庫有逐漸優養的趨勢，在民國 93 年的時候特別的嚴重，倘若營養鹽含量繼續升高，將會發生優養化的情況，翡翠水庫將不能供應大台北地區用水，對未來將會產生許多負面的影響，因此本研究將探討如何控制優養化情形。

本研究蒐集翡翠水庫自民國 85 年 1 月至民國 94 年 12 月共 10 年的水質監測資料，透過統計分析找出重要影響因子，如水庫上游支流之總磷濃度、水庫雨量與水庫流量等，並以類神經網路(Artificial Neural Networks, ANNs)建立水庫優養化訓練及測試之預測模型。然後利用遺傳演算法(Genetic Algorithms, GAs)建置營養鹽含量最佳控制模式，透過對支流入流總磷濃度的控制，

來降低水庫優養化程度，以供水庫經營者作為未來相關水質維護之參考。

二、文獻回顧

2.1 水體水質預測之相關文獻

國內近年來有前人對於水體水質預測有相關之研究，如郭益銘(1999)應用倒傳遞類神經網路來預測地下水質變化，探討隱藏層神經元數目改變對水質預測的影響；謝明翰(2002)利用倒傳遞類神經網路對水庫水質進行時間上連續的預測；王英義(2005)建立類神經網路水質(總磷與葉綠素)模式。

而國外學者亦有相關之水體水質預測之研究，如 French 和 Recknagel (1994)是第一位將類神經網路應用於進行藻華現象預測，他是以前饋式神經網路(feed-forward ANN)對德國 Saidenbach 水庫的浮游植物物種進行預測；Yabunaka 等學者(1997)利用類神經網路以葉綠素和五種浮游植物來模擬預測未來藻華現象的發生；Karul 等學者(2000)以三層式類神經進行來探討水庫優養化分析；Kuo 等學者(2007)用類神經預測水庫之營養鹽(溶氧、總磷、葉綠素、透明度)，其結果說明類神經在台灣水庫管理是相當有價值的工具。

2.2 水體優養控制之相關文獻

目前優養化問題大都以總磷(TP)為主要控

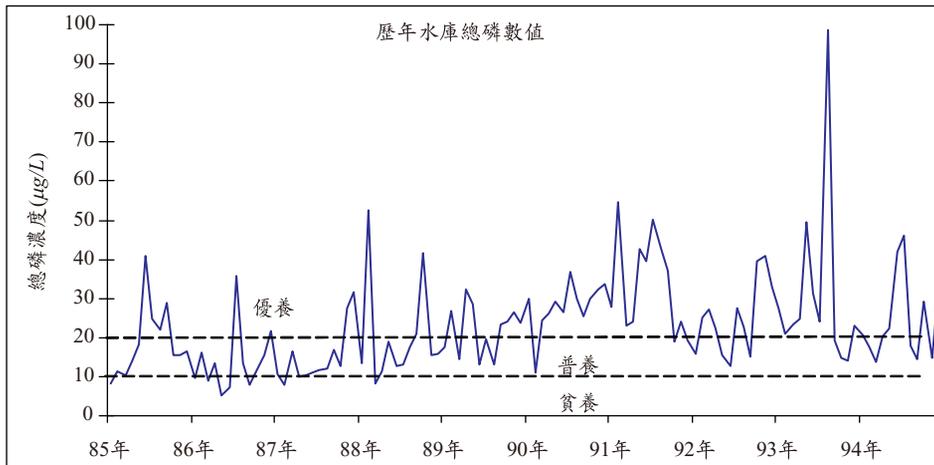


圖 1 翡翠水庫歷年總磷變化圖

制因素，其國內相關研究，如郭明棠(1988)應用線性規劃來探討降低磷自農場載入翡翠水庫中的經濟可行性，使水庫達到不致造成優養的適當養份狀態，該模式使用萬用土壤損失公式及磷緩衝曲線來估算磷的損失係數；蔡政賢(1993)應用多目標線性規劃來推估非點源污染量，進行總磷總量管制的多目標決策分析，該研究以 AGNPS 模式推估集水區的泥砂及總磷輸出量；並藉由淤砂的質量平衡探討模式之適用性後，進而推估水庫底泥的總磷釋放量；黃建源(2000)以多變量統計法分析民國 82 至 87 年日月潭水庫水質監測資料，分析日月潭水庫水質變異之主成份因子與研判污染源，建立適用於推估日月潭水庫總磷負荷量模式。並由土地利用型態分析氮與磷營養鹽來源，研擬水庫水質管理策略。但上述三篇文章對於污染量的推估皆為非時變性，無法表示出污染量在時間上的變化趨勢；王英義(2005)將類神經網路模式取代一般常用的水質模式，與遺傳演算法做結合，進行水庫水質的優養管理，對水庫集水區所需削減的磷負荷量提出建議方案。

而國外對於水體優養控制亦有相關之研究，如 Nurnberg (1987)的研究指出，增加水庫的放流量可以降低水庫內總磷濃度的 35-50%，雖然這個方案可以控制水庫的優養狀態，但是在現實台灣翡翠水庫的適用性並不高，可能會影響到水庫的正常運轉和大台北地區供水情況；

Srivastava 等學者(2002)結合類神經與遺傳演算法來進行水庫水質最佳管理之分析；Kuo 等學者(2006)同樣以類神經結合遺傳演算法來探討水庫水質最佳管理策略，其中類神經模型用來預測水質時間上的變化趨勢，遺傳演算法則用來優選翡翠水庫磷濃度的管制，其成果不錯，故本研究將參考 Kuo (2006)改進影響因子的選取，探討水質預測成效，最後結合遺傳演算法進行最佳管理控制之優選。

三、研究方法

3.1 類神經網路(Artificial Neural Networks, ANNs)

本研究於預測水質資料時採用目前應用於預測方面已經非常有經驗而且有良好的倒傳遞類神經網路 (Back-propagation Network, BPN)，以下是其基本介紹。“神經網路”原是指研究神經生理學、神經解剖學的“生物神經網路”(Biological Neural Networks, BNNs)；“類神經網路”則是一門在電腦科學、資訊工程、資料處理…等領域內，模擬動物神經結構的一種平行計算模式，用來資訊處理技術。類神經網路是由許多的人工神經細胞所組成，人工神經細胞又稱為神經元、人工神經元或處理單元(Processing element)，其輸入值與輸出值的關係式，可用輸入值的加權乘積和函數如式(1)表示：

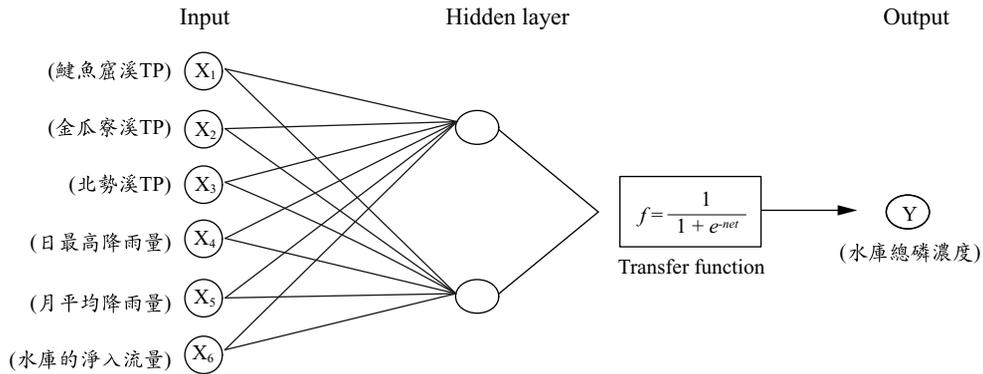


圖 2 類神經網路架構圖

$$Y_j = f\left(\sum_{i=1}^n W_{ij} X_i - \theta_j\right) \dots\dots\dots (1)$$

其中：

- Y_j ：模仿生物神經元的模型的輸出訊號。
- f ：模仿生物神經元的模型的轉換函數 (transfer function)。
- W_{ij} ：模仿生物神經元的模型的神經強度，又稱連結加權值。
- x_i ：模仿生物神經元的模型的輸入訊號。
- θ_j ：模仿生物神經元的模型的閾值。

其中本研究輸入層與隱藏層之間的轉換函數如式(2)所示：

$$f = \frac{1}{1 + e^{-net}} \dots\dots\dots (2)$$

介於處理各單元間訊號的傳遞路徑稱為連結 (links)。每一個連結上有一個加權的數值 W_{ij} ，表示第 i 個處理單元對第 j 個處理單元影響程度。整個類神經網路的聚集形式就如同人類的大腦一般，可透過樣本或資料的訓練來展現出學習 (learn)、回想 (recall)、歸納推演 (generalize) 的能力 (張斐章，2003)。

倒傳遞類神經網路模式，是一種 ANN 的監督式學習演算法，有輸入層 (input) 節點，輸出層 (output) 節點，而且有隱藏層 (hidden layer) 節點 (可一層或多層)，如圖 2 所示。對於輸入訊號，要先向前傳播到隱藏層節點，經過激發函數作用後，再把隱藏層節點的輸出訊號傳播到輸出點，

再經由激發作用，最後由輸出層輸出結果。即是從問題領域中取得訓練資料 (含有輸入變數值以及輸出變數值)，並在之中學習輸入變數與輸出變數的內在對應規則，以應用於新的輸出 (應用在只有輸入變數值，而需推論出輸出變數值的情況)。在學習過程中，是由正、反傳播所組成。在正向傳播過程中，輸入訊號由輸入層，經隱藏層單元逐層處理，並傳向輸出層，每一層神經元的狀態只影響下一個神經元的狀態。如果在輸出層節點所計算輸出值不能得到期望的數值，則進行反向傳遞步驟，將誤差訊號沿原來的連接通路，返回透過修改各層神經元的權值，使得整體系統誤差最小。

倒傳遞類神經網路仍引用梯度下降演算法 (Gradient descent Algorithm)：就每一個神經元來說，可接收連結之輸入訊號，並經轉換函數與閾值計算，輸出其反應值，以第 n 層的第 j 個單元得輸出值 A_j^n 為例，其為第 $n-1$ 層單元輸出值的轉換函數值如式(3)：

$$A_j^n = f(net_j^n) \dots\dots\dots (3)$$

式中： f ：轉換函數

其中集成函數 net_j^n 定義如式(4)

$$net_j^n = \sum_j W_{ij} A_j^{n-1} - \theta \dots\dots\dots (4)$$

式中： W_{ij} ：神經元 i 與神經元 j 間的連結強度，即連結加權值

θ_j ：神經元 j 的閾值

根據神經元連結的關係，以最陡坡降法來調整神經元間的連結加權值，期望達到誤差函数的最小值。誤差函数定義如式(5)。

$$E = \frac{1}{2} \sum_j (T_j - A_j)^2 \dots\dots\dots (5)$$

式中： T_j ：目標輸出值

A_j ：推論輸出值

若未達到設定之誤差量則網路權值需要修正方式如式(6)

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E}{\partial W_{ij}} \dots\dots\dots (6)$$

式中： ΔW_{ij} ：神經元 i 與神經元 j 間的連結加權值修正量

η ：學習速率(Learning Rate)

另外為避免網路收斂時產生震盪情形，可增加慣性量(Momentum)的設計，如式(7)

$$\Delta W_{ij} = \alpha \Delta W_{ij} + \eta \cdot \frac{\partial E}{\partial W_{ij}} \dots\dots\dots (7)$$

式中： α ：慣性量

3.2 遺傳演算法(Genetic Algorithms, GAs)

遺傳演算法(GAs)，在解決最佳化問題上已經有相當的地位及基礎，尤其是解決複雜的非線性問題之最佳化，所以本研究中對於水庫優養之最佳控制採用 GAs 結合預測模式進行控制。最早遺傳演算法的基本理論是由 John Holland 於 1975 年在其“Adaptation in Natural and Artificial Systems”著作中所提出，其觀念源自達爾文(Darwin)演化論中「物競天擇，適者生存，不適者淘汰」，以符合自然系統中調適與革新現象，模擬生物間相互競爭，惟有適合環境條件的個體，才有較大的機會獲得生存與繁衍；天擇不僅將不良的子代淘汰、生存者繼續藉由繁殖將優良的基因延續，建構出適合生存的群體，還可能使下一代擁有更好的基因。

遺傳演算法基本的運算元有群集大小(population size)、字串長度(bit length)其中字串

中的位元相當於染色體的基因(gene)、適合度函数(fitness function)以及三大運算元—複製(reproduction)、交換(crossover)及突變(mutation)，以下為主要三大運算元之介紹：

(1)複製(reproduction)或選擇(selection)

複製的目的是使適合度佳的母代保留到子代，使下一代更能適應環境，本研究中的複製法採取競爭選取法(tournament selection method)：

這類的方法是模仿自然界生物相互競爭，適合度較高的個體經競爭選取後存活下來的機率會比較高，此選取法的優點為個體被複製的機率和個體本身的適合度並無絕對的關係，而是取決於個體間適合度的相對大小，如此，更可避免因適合度過大而過早收斂，故競爭選取法適用於適合度值變化很大的問題上，且運算量較少。其程序如下：

- A、從母體中隨機選出數個個體彼此競爭。
- B、選擇適合度最高的個體進行複製。
- C、重複步驟 B 直到個體數與母體數相同。

(2)交換(crossover)

所謂的交換是將經過複製完成的染色體兩兩配對作部份資訊的交換，目的是為了產生更多組合的搜尋空間，繁殖出更優秀的個體。一般來說，交換率越高，則新物種進入群集的速度越快、搜尋最佳解的速度也越快(蔡宗志，2000)。但是交換率過高會導致物種基因劇烈變化而無法適度保存親代優良的基因；太低則會造成停滯在區域最佳解(黃証國，2002)。本研究的交換方法是屬於均勻交換(Uniform Crossover)：

這種方法即每個點都是交配點，其交配機率是獨立而且均等，由各點的交配率決定是否該進行交配。應用均勻交換法前要亂數產生一組模具(mask)和染色體基因長度相等的二位元一維矩陣，讓每一個基因都有交換的機會，模具中基因為 1 時，則進行交換；反之則不進行交換。這種方法不會有位置偏心和端點效應，並可以造成高度擾亂，產生多樣性的搜尋空間，圖 3 為均勻交換示意圖。

(3)突變(mutation)

單純靠複製、交換二個運算元，無法在演化

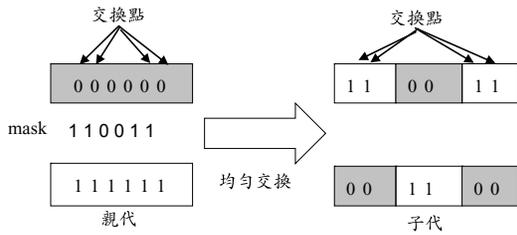


圖 3 均勻交換示意圖

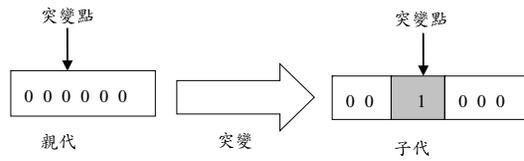


圖 4 突變示意圖

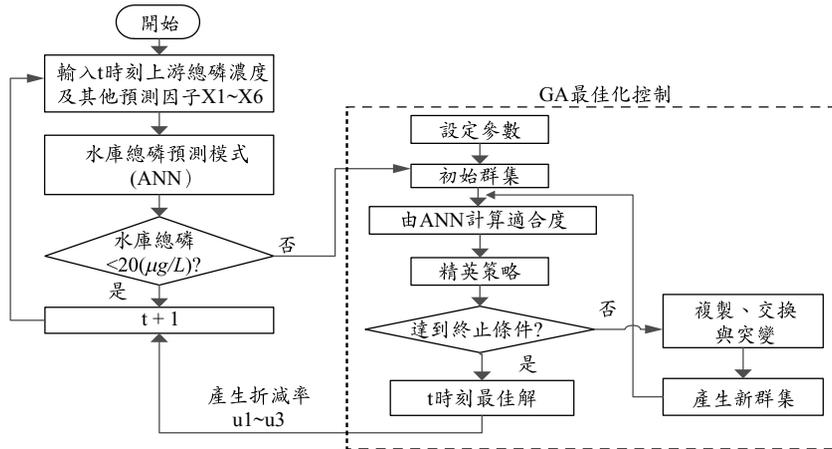


圖 5 水質預測模式(ANN)結合 GA 最佳控制流程圖

的過程中造出一個具有新特性的個體，故需藉由突變造出新物種增加搜尋空間的多樣性。遺傳演算法的突變為隨機選取一條交換後的染色體，再隨機選取一突變點改變，以二位元編碼來說，突變會強制的把 0 換成 1，把 1 換成 0，如圖 4 所示。

四、研究案例

本研究以翡翠水庫為研究區域，水質及水庫運轉之相關資料是由中央研究院-環境變遷研究中心與翡翠水庫管理局所提供。水庫水質監測資料為民國 85 年 1 月至民國 94 年 12 月共 10 年，參考 Kuo *et al.* (2006) 中之六個因子，包含北勢溪總磷濃度 ($\mu\text{g/L}$) 及兩條支流鯉魚窟溪總磷濃度 ($\mu\text{g/L}$)、金瓜寮溪總磷濃度 ($\mu\text{g/L}$)、日最高降雨量 (mm)、月平均降雨量 (mm) 與月合計放流量 (CMSD)，我們改進此文獻中的預測因子，將原本單純的放流量改成水庫的淨入流量(入流量減

去放流量) (CMSD) 進行分析，並以複迴歸模式及類神經網路建立預測模式。預測模式分訓練和測試兩種階段，其中訓練資料採民國 85 年到民國 90 年共 6 年資料；測試資料採民國 91 年到民國 94 年共 4 年資料。兩種預測模式之結果將以常用的兩種形式表示：平均絕對誤差(MAE)與均方根誤差(RMSE)，其中 RMSE 比較容易受高誤差的影響，因計算誤差的平方；而 MAE 為不偏推估的衡量，其計算誤差的絕對值，MAE 及 RMSE 分別如式(8)及式(9)所示。本研究進行預測及控制之流程如圖 5 所示，先採用類神經網路利用六個變數(包括三個上游支流的總磷濃度 $x_1 \sim x_3$ ，以及另外三個水文變數)來建立水庫中平均總磷濃度的預測模型，然後以遺傳演算法控制水庫中總磷濃度在設定標準之下，即優選出上游最低入磷濃度(x_1 、 x_2 、 x_3)之折減率(u_1 、 u_2 、 u_3)，達成水庫總磷濃度降低，使其維持在不發生優養的狀態($20 \mu\text{g/L}$)。

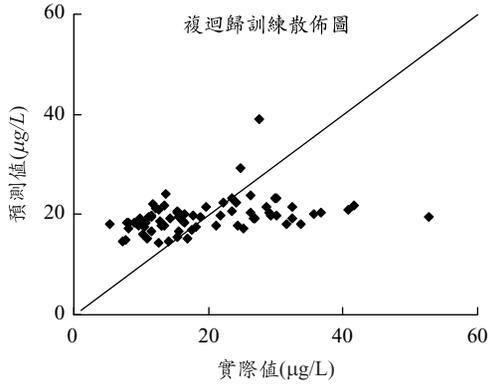


圖 6 複迴歸訓練散佈圖

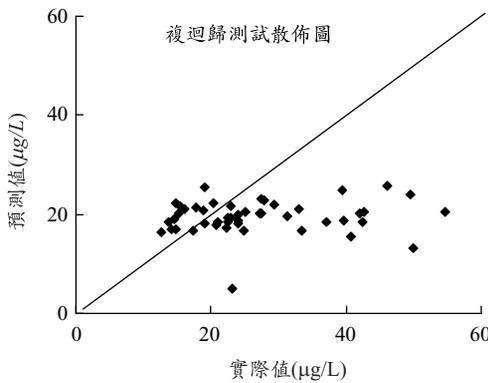


圖 7 複迴歸測試散佈圖

$$MAE = \frac{1}{N} \sum_{t=1}^N |\hat{Q}_t - Q_t| \dots\dots\dots (8)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (\hat{Q}_t - Q_t)^2}{N}} \dots\dots\dots (9)$$

式中 Q_t = 實際水庫總磷濃度($\mu g/L$) ; \hat{Q}_t = 預測水庫總磷濃度($\mu g/L$) ; N = 資料數

4.1 複迴歸模式(MLR)

本研究先以 MLR 方法進行分析，兩種評鑑指標結果如表 1 所示。訓練案例的 MAE 與 RMSE 的表現分別為 7.14 及 9.00；測試案例的 MAE 與 RMSE 的表現分別為 11.01 及 16.37。複迴歸模式散佈圖分別如圖 6 (訓練)、圖 7 (測試) 所示，由圖可知訓練與測試案例之推估結果偏

表 1 複迴歸、類神經之 MAE 與 RMSE 之結果表

	訓練	測試
複迴歸 MAE	7.14	11.01
複迴歸 RMSE	9.00	16.37
類神經 MAE	5.65	7.76
類神經 RMSE	7.83	10.37

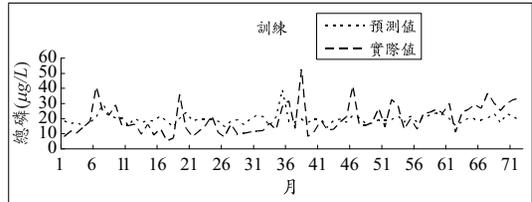


圖 8 複迴歸訓練之總磷濃度時序圖

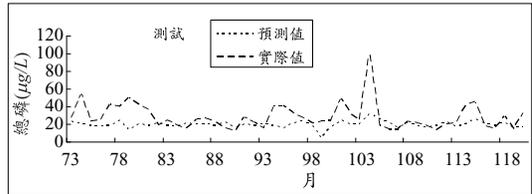


圖 9 複迴歸測試之總磷濃度時序圖

低，尤以測試結果大多為低估，實際值越大，推估之偏差越大。由圖 8 可知訓練案例之實際值變化趨勢較大與預測值變化趨勢差異甚大，顯示訓練案例極為不準確；而圖 9 可知測試案例之預測結果則多有低估之現象，可見 MLR 對於翡翠水庫之總磷預測效果不佳，訓練階段得到之總磷(TP)之複迴歸方程式為：

$$TP = 16.932 + 0.010x_1 - 0.057x_1 + 0.093x_3 + 0.044x_4 - 0.003x_5 - 0.252x_6 \dots\dots\dots (10)$$

式中 x_1 = 鯉魚窟溪 TP ($\mu g/L$)
 x_2 = 金瓜寮溪 TP ($\mu g/L$)
 x_3 = 北勢溪 TP ($\mu g/L$)
 x_4 = 日最高降雨量(mm)
 x_5 = 月平均降雨量(mm)
 x_6 = 水庫的淨入流量(入流量-放流量) (CMSD)

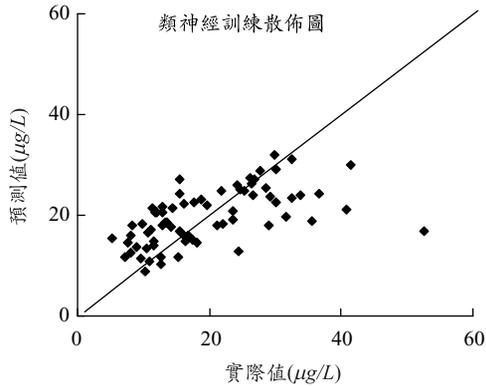


圖 10 類神經訓練案例散佈圖

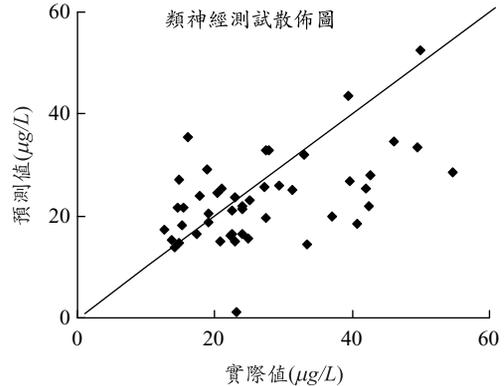


圖 11 類神經測試案例散佈圖

4.2 類神經模式(ANNs)

本研究的類神經是以 MATLAB 所建構，參數的設定經多次試驗而決定，其中學習速率及訓練循環數之參數的改變較不影響結果，故在此僅列出不同節點數結果，經類神經模擬結果是以 8 個節點模式的結果最佳，其實際值與預測值於平均絕對誤差(MAE)與均方根誤差(RMSE)之兩種評鑑指標比較結果如表 1 所示，訓練案例的 MAE 與 RMSE 的表現分別為 5.65 及 7.83；測試案例的 MAE 與 RMSE 的表現分別為 7.76 及 10.37，顯示類神經模式之結果優於複迴歸方法(如表 1)。圖 10(訓練)、圖 11(測試)為兩者之散佈圖，由圖可知類神經模式相對於複迴歸方法較無明顯高估或低估的情況發生，且分佈較貼近理想的 45 度線。由圖 12 可知在訓練案例中，實際值之高低值變化仍較大於預測值，但大致有較為類似的趨勢變化；而圖 13 可知測試案例之實際值與預測值趨勢很相近，可見類神經於翡翠水庫之水質預測較複迴歸分析有更滿意的結果。

4.3 遺傳演算法(GAs)之最佳控制

由上述二者方法分析得知，類神經分別於 MAE 與 RMSE 兩種評鑑指標中的表現程度均優於複迴歸，顯示有較佳的預測能力，因此本研究選取此組預測模型結合遺傳演算法進行水庫優養化控制。

目標函數之設定為在最少花費下達到水庫水質的預期目標，即達到不發生優養狀態。為使

表 2 遺傳運算元參數之設定

項目	值
群集大小	100
疊代次數	400
交換率	0.6
突變率	0.01
精英策略	yes

整治費達到最少花費，則必須使支流之總磷消減率達到最小，因此目標函數可表示如下：

$$\text{Min} \sum_{i=1}^3 (u_{p,i}^2 + r * \phi(P)) \dots\dots\dots(11)$$

其中 u_p 為支流總磷之消減率， $i = 1\sim 3$ 分別表示上游主流北勢溪及兩條支流鯉魚窟溪和金瓜寮溪之總磷濃度 $\Phi(P)$ 為當水庫總磷濃度超出預期標準時之懲罰函數。

本研究設定：若水庫總磷濃度(P)低於預期目標(20 $\mu\text{g/L}$)，則 $\Phi(P) = 0$ ；若水庫總磷濃度(P)高於預期目標(20 $\mu\text{g/L}$)，則 $\Phi(P) = P - 20$ 。r 為懲罰函數，若為最小化問題，則 $r > 0$ ，若為最大化問題，則 $r < 0$ ，本研究設定為 10000。

控制變數為北勢溪總磷濃度、鯉魚窟溪總磷濃度和金瓜寮溪總磷濃度，採用二位元編碼，每個變數分別為 12-bit，故每條染色體為 36-bit；其中複製採用競爭選取法，交配採用均勻交換法；收斂條件設定為至少疊代 400 代且需連續 200 代之最佳解不變；其它參數之設定如表 2 所示。

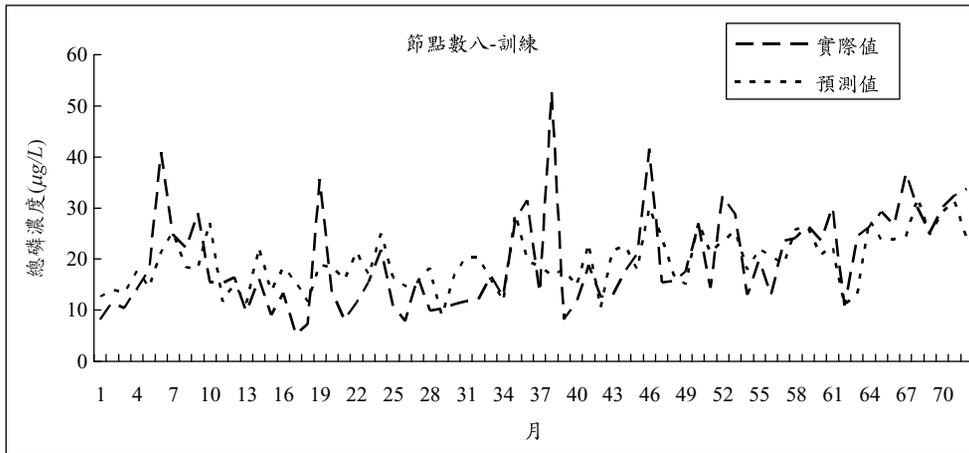


圖 12 類神經訓練之總磷濃度時序圖

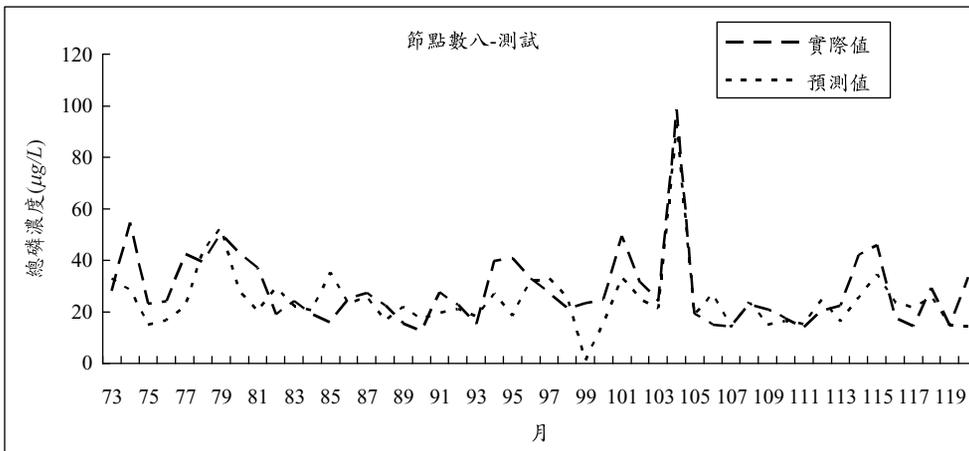


圖 13 類神經測試之總磷濃度時序圖

遺傳演算法的控制內容為主流及兩條支流之水庫入磷濃度(x_1 、 x_2 、 x_3)，決策變數為此三條溪流總磷濃度的折減率(u_1 、 u_2 、 u_3)，控制目標是使水庫總磷濃度低於優養化指標 $20 \mu\text{g/L}$ 。圖 14 為主流及支流於不同時刻的折減率(決策變數 u_1 、 u_2 、 u_3)，可以看出磷濃度遞減率主要控制於主流北勢溪和其中一條支流鱸魚窟溪，至於金瓜寮溪的影響比較小。圖 15 顯示本研究所優選之最佳控制下，可使水庫總磷將低至接近所設定之水質標準，所以本研究所提出之方法確實可以有效控制水庫之優養化。

五、結論與建議

本研究以類神經(ANNs)與複迴歸(MLR)來建立翡翠水庫之總磷預測模式，由分析結果得知，複迴歸分析有明顯的低估情況發生，類神經模式則較無此情況發生，類神經於平均絕對誤差(MAE)與均方根誤差(RMSE)之兩種評鑑指標的表現結果均優於複迴歸，顯示其有較佳的預測能力。

將類神經模式應用於遺傳演算法建立水質最佳控制模型，模擬結果可以成功的使翡翠水

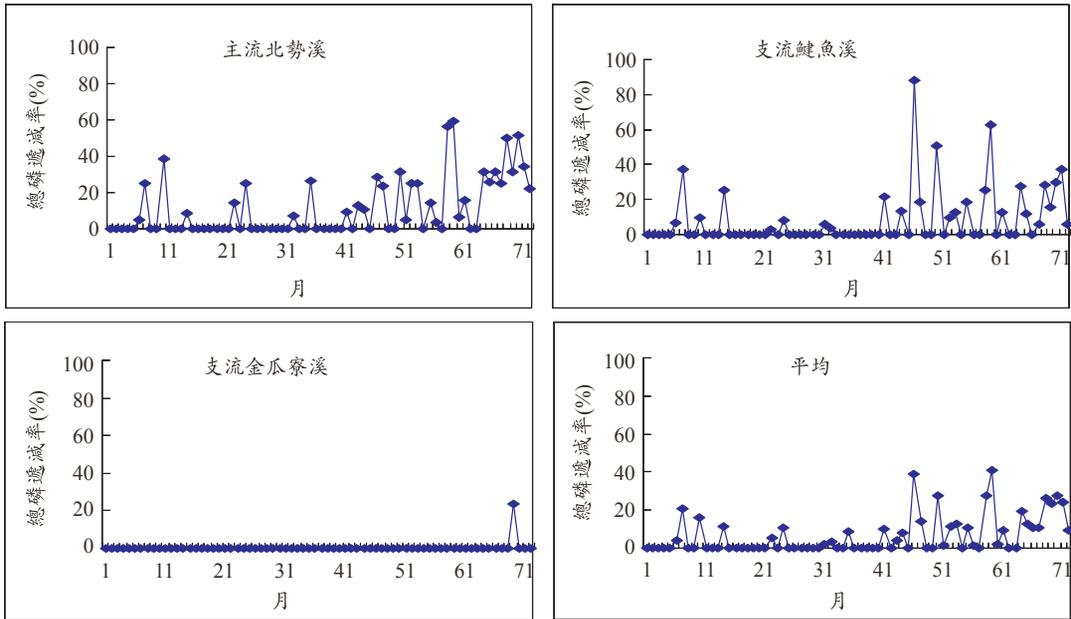


圖 14 各時刻上游入流之總磷折減率

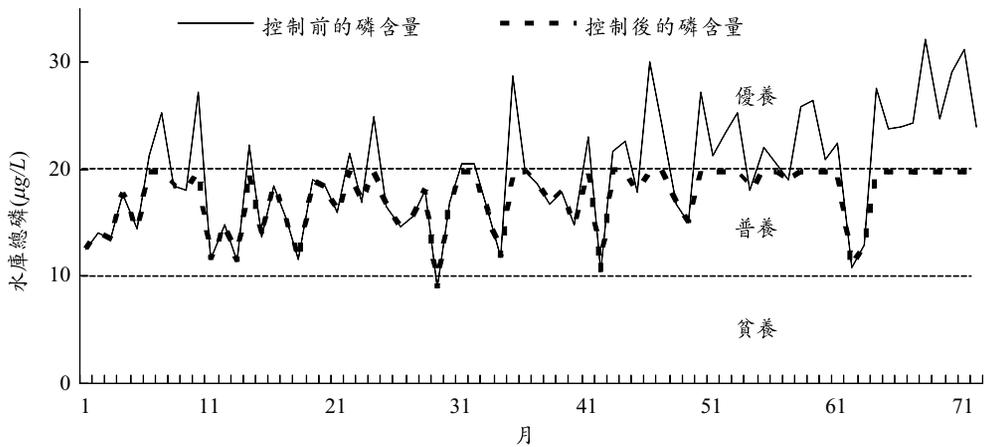


圖 15 翡翠水庫總磷控制前後之濃度變化圖

庫各時刻總磷濃度皆符合所設定的水質標準 (20 $\mu\text{g/L}$)，對於水庫優養化的控制確有不錯之成效，可提供決策者作為控制水庫優養之參考。

本研究水質預測模型僅限於預測水庫表水總磷濃度，並無法考量不同深度之濃度變化，未來可朝向蒐集不同分層之水質資料，並嘗試選取其它預測模型與各種因子，以進行水庫季節翻轉預測之研究，並加強其預測精度。

誌謝

本研究承蒙行政院國科會提供研究經費補助 (水庫營養源濃度預測與監控之最佳策略研究—NSC 97-2221-E-216-022-MY2)，以及中央研究院環境變遷中心高樹基副研究員提供相關資料與建議，謹此致謝。

參考文獻

1. French, M., Recknagel, F., "Modeling algal blooms in freshwaters using artificial neural networks," In: Zanetti, P. (Ed.), *Computer Techniques in Environmental Studies V*, vol. II: Environment Systems. Computational Mechanics Publications, Boston, pp. 87-94, 1994.
2. Karul, C., Soyupak, S., Cilesiz, A.F., Akbay, N., Germen, E., "Case studies on the use of neural networks in eutrophication modeling," *Ecol. Model*, 134, pp.145-152, 2000.
3. Kuo J. T., Wang, Y. Y., Lung, W. S., "A hybrid Neural-Genetic Algorithm for reservoir water quality management," *Water Research*, 40, pp. 1367-1376, 2006.
4. Kuo, J. T., Hsien, M. H., Lung, W. S., and She. N., "Using artificial neural network for reservoir eutrophication prediction." *Ecological Modelling*, Vol. 200, pp. 171-177, 2007.
5. Nurnberg, G. K., "Hypolimnetic withdrawal as lake restoration technique." *Environ. Eng.-ASCE* 113 (5), pp. 1006-1017, 1987.
6. Srivastava, P., Hamlett, J. M., Robillard, P. D., Day, R. L., "Watershed optimization of best management practices using AnnAGNPS and a genetic algorithm." *Water Resour. Res.* 38 (3), 2002.
7. Yabunaka, K.-I., Hosomi, M., Murakami, A., "Novel application of a backpropagation artificial neural network model formulated to predict algal bloom," *Water Sci. Technol*, 36 (5), pp. 89-97, 1997.
8. 王英義，「整合類神經網路與遺傳演算法於水庫水質管理之研究」，國立臺灣大學土木工程學研究所博士論文，2005。
9. 張斐章、張麗秋、黃浩倫，「類神經網路—理論與實務」，東華書局，2003。
10. 郭益銘，「應用多變量統計與類神經網路分析雲林沿海地區地下水水質變化」，國立臺灣大學農業工程學研究所碩士論文，1999。
11. 黃建源，「多變量統計方法在日月潭水庫水質管理之應用」，逢甲大學土木及水利工程研究所碩士論文，2000。
12. 黃証國，「應用基因演算法於動態投資組合保單中操作策略的最適化」，國立交通大學資訊管理研究所碩士論文，2002。
13. 蔡宗志，「智慧型理論於水庫防洪操作之研究」，中華大學土木工程研究所碩士論文，2000。
14. 蔡政賢，「多目標非點源污染總量管制策略分析--以寶山水庫的總磷管制為案例」國立交通大學環境工程研究所碩士論文，1993。
15. 謝明翰，「應用倒傳遞類神經網路於水庫水質之分析—以德基與曾文水庫為例」，國立臺灣大學土木工程學研究所碩士論文，2002。

收稿日期：民國 97 年 11 月 10 日

修正日期：民國 98 年 3 月 2 日

接受日期：民國 98 年 3 月 9 日