



以類神經網路推估蒸發量

Estimating Evaporation by Artificial Neural Networks

國立台灣大學
生物環境系統工程學系
博士班研究生

吳國儒

Gwo-Ru Wu

國立台灣大學
生物環境系統工程學系
碩士

高慧珊

Huey-Shan Kao

國立台灣大學
生物環境系統工程學系
碩士班研究生

鍾昌翰

Chang-Han Jong

國立台灣大學
生物環境系統工程學系
碩士班研究生

何宜樺

Yi-Hua Ho

國立台灣大學
生物環境系統工程學系
教授

張斐章

Fi-John Chan

摘要

蒸發現象係水文循環中重要的一環，蒸發量的估算為水資源規劃與農業灌溉營運之重要參考依據。蒸發量的估算可藉由蒸發皿直接量測，惟若無蒸發皿量測資料，一般都以傳統經驗式利用氣象因子推估；因參數不易推估而影響其精確性及使用性。本研究擬以具有高度訊息處理與非線性映射能力的類神經網路，並利用氣象量測資料，如風速、溫度、日照等，建立蒸發量推估模式。本研究選用倒傳遞類神經網路(BP)、自組特徵映射網路(SOM)及調適性網路模糊推論系統(ANFIS)等三種類神經網路架構來建立推估模式，並與 Modified Penman 經驗式及 Penman-Monteith 經驗式的推估結果進行比較。本研究以中央氣象局恆春站 2002-2004 年的日氣象觀測資料共計 1035 筆，作為模式訓練與測試用，結果顯示三種類神經網路推估日蒸發量之結果皆相當準確，其均方誤差約為 1.1 mm/day，較傳統經驗公式推估結果低 0.1 mm/day，研究結果可為往後相關研究之參考依據。

關鍵詞：蒸發量，倒傳遞類神經網路，自組特徵映射網路，調適性網路模糊推論系統。

ABSTRACT

The phenomenon of evaporation is an important component of the hydrological circle, and it's an important basis of reference for planning the use of the water resources and managing the agricultural irrigation. Estimation of evaporation could be measured by evaporimeter directly; in case of no evaporimeter, it is generally estimated by traditional evaporation formulas. However, the formulas indeed is complex with many parameters which are difficult to properly estimate. In this study, we plan to establish an applicable model for precisely estimating evaporation based on climate variables, such as wind speed, temperature, and radiation, by using artificial neural networks (ANNs). Three different kinds of ANN, i.e. Back Propagation Neural Network, Self-Organizing Map, and Adaptive Network-Based Fuzzy Inference System, are used. The data obtained from Central Weather Bureau in HengChuen station during the period of 2002-2004 are used to train and verify the networks. The results are compared with the outcome of Modified Penman formulas and Penman-Monteith formulas, and we find that estimation of evaporation by using the proposed artificial neural networks is much more precise than the traditional evaporation formulas. The ANNs can be a potential tool for estimating the evaporation effectively from limited climatic data.

Keywords: Evaporation, Back Propagation Neural Network, Self-Organizing Map, Adaptive Network-Based Fuzzy Inference System.

一、前言

台灣地區降雨在時間與空間分佈上極為不均，加上河川坡陡流急，大部分的降雨量快速奔流入海，以致無法充分有效利用；隨著社會結構的改變及經濟快速發展，民生及工業用水需求急遽增加，確保穩定供水已成為目前重要的施政課題；惟如何有效運用水資源，有賴於水文循環中各環節的估算與掌握。蒸發為水文循環中重要的一環，蒸發量的估算為水資源規劃與農業灌溉營運之重要參考依據。蒸發現象非常複雜，取決於眾多的氣象因子，而氣象因子會隨著區域、時間及季節的不同而改變，以致於無法有效的掌握蒸發量的變化。蒸發量推估一般可利用蒸發皿量測；若無蒸發皿量測值，為推估蒸發量一般都使用傳統經驗式計算，利用氣象參數，間接求出潛勢蒸發散量，亦即自由水面的蒸發量。

類神經網路是模擬人類腦神經細胞結構的平行計算模式，具有從輸入項的環境訊息中獲取

並累積經驗、儲存知識，進而加以利用的智慧型演算程序，是一種功能強大的演算技巧。類神經網路架構由很多非線性的運算單元和位於運算單元間的聯結所組成，利用非線性函數的轉換，以平行且分散的方式進行運算，能有效的對大量資料進行分析，且因具有學習能力，不需前提假設，也不需先對問題定義複雜的數學模式，只要有充分的歷史資料，即可進行分析、預測的工作，故而廣用於不同的社會科學領域。

由於傳統經驗式利用氣象參數推估蒸發量，需具備眾多氣象因子的資料及相關參數的推估；而類神經網路可藉由學習與記憶的方式來處理複雜且具不確定性的非線性問題。本研究提出以目前廣用於各項科學與工程實務問題的類神經網路，期能提供另一便捷而精確的推估方式。本研究利用倒傳遞類神經網路(BP)、自組特徵映射網路(SOM)及調適性網路模糊推論系統(ANFIS)等三種類神經網路架構，以建立一合適的蒸發量推估模式，並與 Modified Penman 經驗

式及 Penman-Monteith 經驗式的推估結果進行比較。

二、文獻回顧

利用氣象資料推估區域性蒸發散量，已有長久的歷史，國內對於作物需水量估算的研究有：張本初(1990)利用 Blaney-Criddle、Thornthwaite、Priestley-Taylor、Hargreaves 及 Modified Penman 等五種經驗式，推估比較嘉義地區作物需水量，其結果以 Modified Penman 最佳。張煜權(1995)以 Modified Penman、Modified Blaney-Criddle、Radiation 及 Pan Evaporation 等四種經驗式推估，亦認為 Modified Penman 最適合台灣地區水田灌溉用水量之推估。甘俊二等人(1996)以 Modified Penman、Modified Blaney-Criddle、Radiation、Pan Evaporation 及 Penman-Monteith 等五種經驗式推估比較，認為 Penman-Monteith 為適用於台灣地區作物需水量的推估。陳清田(1998)則利用 Penman-Monteith 公式推估不同區域的作物需水量。童慶斌等人(2001)藉由小型森林集水區進行土壤水分觀測，建立蒸發散折算係數，以推估實際蒸發散量。施鈞程(2003)以水平衡法、Thornthwaite 及 Hamon 等推估台灣森林集水區的蒸發散量。葉信富等人(2004)進行潛勢能蒸發散經驗公式的最佳化比較。邱奕霖(2004)利用儀器觀測土壤水分變動，以估計土壤水分損失，並與 Priestley-Taylor、Penman-Monteith、Bowen ratio 及空氣動力法推估之蒸發散量比較。邱湏瑋(2006)，利用 Hamon、Thornthwaite、Priestley-Taylor、Makkin、Ture 及 Modified Penman 等六種經驗式，以探討勢能蒸發散計算公式在中海拔地區的適用性。

近年來由於遙測技術進步，已發展利用衛星影像估算氣象因子，並配合經驗式估算蒸發散量，有曾柏凱(2004)以 Modified Penman、Penman-Monteith 及 Priestley-Taylor 等三種經驗式，結合衛星遙測估算蒸發散量。郭振民等人(2005)應用 AVHRR 及 MODIS 衛星影像估算潛勢蒸發散量。陳朝圳等人(2006)應用 MODIS 衛星影像推估台灣地區之蒸發散量。

使用類神經網路推估蒸發量則有：Sudheer *et al.* (2002)利用倒傳遞類神經網路推估 A 型蒸發皿的日蒸發量，以最高、最低溫度、最大、最小相對濕度、日照時數、風速作為模式的輸入，推估日蒸發量與實際日蒸發量之均方根誤差(rmse)為 1.47 mm/day。Keskin *et al.* (2004)運用七個氣象變數對蒸發量作相關性分析，並選擇空氣溫度、水溫、太陽輻射、壓力等四個變數作為模糊推論系統的輸入來架構模式，結果顯示日蒸發量估計之均方差(mse)為 1.6 mm²/day²，較 Penman 法好。Kisi. (2006)，使用模糊類神經方法配合不同組合的輸入氣象變數：溫度、太陽輻射、風速、氣壓、濕度推估日蒸發量，並與 Stephens-Stewart (SS)法、倒傳遞類神經網路做比較，結果顯示以所有氣象變數架構的模糊神經網路有最好的表現，且發現氣壓為一影響日蒸發量之重要因素。楊國珍(2004)將平均氣溫、平均相對濕度、日照率、平均風速等變數，利用不同型態的隸屬度函數，使用在模糊推論系統推估所得的月蒸發量，並與實際觀測值作比較。郭勝豐等人(2006)，以倒傳遞類神經網路推估嘉南灌區作物蒸發散量。高慧珊等人(2007)，以自組特徵映射網路架構日蒸發量推估模式，並以溫度、露溫、風速、相對濕度、日照時數及日射量等六項氣象變數推估日蒸發量，結果顯示拓模層架構能詳細說明輸入與輸出間的映射關係。

三、理論分析

類神經網路由眾多的神經元連結而成，神經元為系統中最小的訊息處理及傳遞單元，由輸入向量、權重、活化函數與輸出值構成，為整個系統運作的基礎，類神經網路靠著相關權重連結各層間之單元，公式(1)及(2)分別表示輸入值經由加權累加後到達隱藏層，並透過轉換函數作非線性轉換，再傳至輸出層。

$$y_j = F(net_j) \dots\dots\dots(1)$$

$$net_j = \sum_{i=1}^m w_{ji}x_i + b_j \dots\dots\dots(2)$$

式中， y_j 為第 j 個神經元輸出訊號；

$F(net_j)$ 為神經元的活化函數；

net_j 為輸入值加權值與偏權值 b_j 總和；

w_{ji} 為連結第 i 個輸入值與第 j 個神經元之權重值。

類神經網路的基本架構為：輸入層、隱藏層及輸出層。其中輸入層僅以表現輸入變數，只當輸入訊息的傳遞界面，並不對輸入資訊做處理，其單元數目則依問題之型式而定；隱藏層則為表現輸入處理單元間之交互影響，其單元數目通常以試誤法決定其最佳數目，層數則依問題的複雜度可能有一層或數層；輸出層則以表現輸出變數(張斐章、張麗秋，2005)。以下分別簡短介紹用於本研究的三種類神經網路及二種經驗估算式。

3.1 倒傳遞類神經網路(BP)

倒傳遞類神經網路(Back Propagation Neural Network, BP)的架構為多層感知器，學習演算法為誤差倒傳遞演算法，屬前饋式網路，並以監督式學習方式來處理輸入、輸出間的非線性映射關係，因為有學習精度高、回想速度快的優點，為目前最具代表性、應用最普遍的類神經網路模式，其適用範圍泛如：樣本識別、分類問題、函數模擬、預測、系統控制、雜訊過濾、資料壓縮等。

網路架構包括了輸入層、隱藏層、輸出層，如圖 1 所示，每層架構中都包含若干個處理單元，並由權重連結各層間的處理單元，輸入訊息由輸入層直接傳入隱藏層，於隱藏層中加權計算並透過活化函數轉換處理後，傳至輸出層計算出網路輸出值。

倒傳遞類神經網路的學習過程，即為各連結權重的調整，每一層神經元的輸入為上一層神經元的輸出，若網路輸出結果與目標輸出值有差異，則轉為反向傳遞，將誤差訊息沿原來的連接通路回傳，透過修改各層神經元的權重與偏權值，期能使誤差值達到容忍誤差範圍。由於倒傳遞類神經網路屬於監督式學習，其方法就是在降低目標輸出值和網路輸出值間的差異，使誤差函數 E 最小化，並利用最陡坡降法來搜尋 E 的最佳




圖 1 倒傳遞類神經網路架構圖

解，也就是最小的誤差平方和，如(3)式所示。

$$E = \frac{1}{2} \sum_k (d_k - y_k)^2 \dots\dots\dots (3)$$

式中， d_k 為第 k 個神經元的目標輸出值；

y_k 為輸出層第 k 個神經元的網路輸出值。

在隱藏層中的活化函數中，最常使用的為 S 型函數 $f(x) = 1/(1 + \exp(-\alpha x))$ ，因為其變數趨向正負無限大時，函數值趨於常數，其值域在 [0,1] 之間。另因 S 型函數為一平滑曲線可微分，所以可利用最陡坡降法在網路學習過程中修正權重與偏權值，使誤差值逐次減小，以達到學習的目的。

3.2 自組特徵映射網路(SOM)

自組特徵映射網路(Self-Organizing Map, SOM)，屬前饋式網路，為非監督式且為競爭式的學習方式，在學習過程中，不需目標輸出值的誤差修正而能產生自我組織性，在一群樣本輸入值中尋找不同的特性，再將具有相似特性的樣本聚類。其演算法是以特徵映射的方式，將任意維度的輸入向量，映射至較低維的特徵映射圖上，並依據輸入向量在神經元間彼此競爭，優勝神經元可獲得調整連結權重向量的機會；最後拓樸層的神經元會依據輸入向量的特徵，以有意義的拓樸結構展現在輸出空間中，稱作為拓樸圖。此一網路的優點為學習速度快，而拓樸圖具有綜合聚

類的效果，容易依聚類結果解釋各輸入因子的對照關係，被廣泛應用於影像、語音辨識、機器人學習及手寫數字辨識系統等(Chang *et al.*, 2007)。

自組特徵映射網路是一個聚類的過程，而其拓樸層可稱為聚類中心層，其中的每一個神經元皆可代表輸入向量的一個聚類中心點。如圖 2 所示，每一筆輸入向量透過連結權重與每個神經元連結，各神經元間以競爭式學習法來決定被調整的神經元，可求得對應的優勝神經元，也就是與該輸入向量最近似的神經元。

決定優勝神經元的方式，為比較所有神經元的連結權重與輸入向量的距離，選取距離最近的神經元為優勝神經元。在此採用歐式距離公式，如(4)式所示。

$$q(x) = \min_{\forall i} \|x - w_i\|_2 \quad i = 1, 2, \dots, m \quad \dots\dots\dots(4)$$

$q(x)$ 為神經元 w 與輸入向量 x 的最短距離，此距離最短的神經元即為優勝神經元。

對每一筆輸入向量而言，自組特徵映射網路只更新其優勝神經元與其相對應的鄰近神經元，其更新權重的公式則如(5)~(7)式所示：

$$\eta_{qj} = \exp(-\|r_j - r_q\|^2 / R^2) \quad \dots\dots\dots(5)$$

$$\Delta w_j = \mu(k) \eta_{qj}(k) [x(k) - w_j(k)] \quad \dots\dots\dots(6)$$

$$w_j(k+1) = w_j(k) + \Delta w_j \quad \dots\dots\dots(7)$$

式中， w 表聚類中心層神經元權重；

x 為輸入向量；

μ 為學習速率；

η 為鄰近函數；

η_{qj} 為第 j 個神經元與優勝神經元 q 之鄰近關係值；

r_j 為鄰近區域中其他神經元於拓樸圖上的位置座標；

r_q 為優勝神經元於拓樸層上的位置；

R 為鄰近半徑。

訓練完成後，輸入向量皆可獲得相對應聚類中心層之神經元，但並沒有網路的輸出向量產生，因此需再建構一層網路輸出層，使自組特徵




圖 2 自組特徵映射網路網路架構圖

映射網路得以擷取輸入向量的統計聚類特性而獲得輸出值。為突顯各聚類中心點特性，可於聚類中心點上建構相對應的隸屬度函數，以彰顯資料結構對於聚類中心層神經元的遠近強弱關係，如(8)式所示。

$$\phi = \exp(-\|x - c\|^2) \quad \dots\dots\dots(8)$$

依據上式可獲得每筆輸入向量對於每個聚類中心層神經元的隸屬度值，因此對於 K 筆訓練資料與 N 個聚類中心點，可以獲得 $K \times N$ 的隸屬度矩陣 ψ ；利用 ψ 矩陣與網路的期望輸出向量 y ，可獲得(9)式之矩陣表示法。

$$\phi \times w = y \quad \dots\dots\dots(9)$$

以線性迴歸方式經過矩陣轉換與運算之後，可推得 w 向量如(10)、(11)式所示。

$$\phi^T \times \phi \times w = \phi^T \times y \quad \dots\dots\dots(10)$$

$$w = (\phi^T \phi)^{-1} \phi^T \times y \quad \dots\dots\dots(11)$$

因此可獲得自組特徵映射網路之聚類中心層與輸出層間的權重連結向量 w 。

3.3 調適性網路模糊推論系統(ANFIS)

調適性網路模糊推論系統(Adaptive Network-Based Fuzzy Inference System, ANFIS)是以模糊推論系統為模式基礎，並結合類神經網路自我組織的特性架構而成，可以充分發揮模式對於系統不確定性與不精確性的處理能力，同時能透過學習與自我調適，而使模式參數可得到最佳的調整。ANFIS 在馬達故障偵測系統、動態電力負載

系統及水庫即時操作系統等有許多成功的應用案例(Chang and Chang, 2006; Chang et al., 2005)。

以下以 N 個輸入變數、1 個輸出值，5 層網路架構為例說明：

第一層輸入層：將輸入變數映射到模糊集合，計算方式如(12)式所示。

$$O_{1,ji} = \mu_j(x_i) = \frac{1}{1 + \left| \frac{x_i - c_{ji}}{a_{ji}} \right|^{2b_{ji}}} \quad \text{.....(12)}$$

for $i = 1, 2, \dots, N; j = 1, 2, \dots, M_i$

$\mu_j(x_i)$ 為第 i 個輸入變數的第 j 個集合之隸屬函數，並設定為鐘型函數(具有三個參數 a_{ji} , b_{ji} , c_{ji})，此層產生的參數即為前提部分的參數。

第二層規則層：進行各輸入變數間模糊邏輯的先決條件配對，再選用 T-norm 進行 AND 或乘積運算，計算方式如(13)式所示。

$$O_{2,p} = w_p = \prod_{i=1}^N \mu_{j_i}(x_i) \quad \text{.....(13)}$$

for $j_i = 1, \dots, M_i; p = 1, \dots, P$

第三層正規化層：將上層各節點所得的結果正規化，使其輸出值介於 0 到 1 之間，計算方式如(14)式所示。

$$O_{3,p} = \bar{w}_p = w_p / \sum_{p=1}^P w_p \quad \text{.....(14)}$$

第四層結論推論層：將上層獲得之正規化結果與 Sugeno 模糊模式相乘，計算方式如(15)式所示。

$$O_{4,p} = \bar{w}_p f_p = \bar{w}_p \left(\sum_{i=0}^N r_{pi} x_i \right), x_0 = 1 \quad \text{.....(15)}$$

r_{pi} 為一次 Sugeno 模糊模式的相關係數，為結論部分的參數。

第五層輸出層：總和上層各節點的輸出結果，計算方式如(16)式所示。

$$O_{5,1} = \sum_{p=1}^P \bar{w}_p f_p = \frac{\sum_{p=1}^P w_p f_p}{\sum_{p=1}^P w_p} \quad \text{.....(16)}$$

ANFIS 結合了前饋式類神經網路的監督式




圖 3 調適性網路模糊推論系統架構圖

學習法，在代入訓練資料後，比較真實輸出值與模式推估值間的誤差，在求誤差的最小平方和過程中，使模糊推論系統中的所有參數作適當的調整。參數的修正方法採用二階段的混合學習演算法：在訊息前傳部分，各層節點輸出值往前傳至第四層後，藉由最小平方推估法來調整推論項參數。誤差訊息逐則層逆向傳導至第一層，再利用最陡坡降法更新前提項參數，其網路架構如圖 3 所示。藉由二階段學習程序，ANFIS 即可透過輸入--輸出資料與人類知識建立輸入--輸出之映射關係。

3.4 Modified Penman 經驗公式

FAO (Food and Agricultural Organization)於 1984 年推薦使用，結合能量平衡理論與空氣動力學之方法模擬地表之蒸發散量(ET)，因理論基礎完善，在世界各地廣泛使用，經驗公式如(17)式所示。

$$ET_0 = \frac{\Delta}{\Delta + \gamma} \times 86400 \times \frac{(R_s - S)}{\gamma} + \frac{\gamma}{\Delta \gamma} \times 2.7 \times f(u) \times (e_a - e_d) \quad \text{.....(17)}$$

式中， ET_0 為潛勢蒸發散量，mm/day；

Δ 為飽和蒸氣壓力曲線斜率，kPa/°C；

γ 為濕度常數，kPa/°C；

R_n 為淨輻射量，W/m²；

λ 為水蒸發潛熱，J/kg， $\lambda = 2.45 \times 10^6$ ；

$f(u)$ 為風速函數， $f(u) = 1 + 0.864 u$ ；

表 1 中央氣象局恆春測站日氣象變數之統計特性

	平均值	標準偏差	與蒸發量的相關係數
平均溫度 $\langle^{\circ}\text{C}\rangle$	25.30	3.22	0.2504
平均相對濕度 $\langle\%\rangle$	71.50	7.47	-0.3871
平均風速 $\langle\text{m/s}\rangle$	3.52	1.91	0.1868
累積日照時數 $\langle\text{hour}\rangle$	6.51	3.32	0.5637
日射量 $\langle\text{MJ/m}^2/\text{day}\rangle$	11.59	5.89	0.5768
蒸發量 $\langle\text{mm/day}\rangle$	4.50	1.53	1

u 為 2 公尺高處所量測之風速, m/sec ;
 e_a 為平均溫度之飽和蒸氣壓, kPa ;
 e_d 為平均溫度之蒸氣壓, kPa ;
 S 為土壤熱通量, W/m^2 。

3.5 Penman-Monteith 經驗公式

ICID (International Commission on Irrigation

and Drainage)於 1994 年推薦,以作物遮蔽阻力 (Crop Canopy Resistance)及空氣動力阻力 (Aerodynamic Resistance)等二項關係式取代 Modified Penman 原有之風速函數值,以消弭氣候因子及地域參數之影響。作物高度在 12 cm 時,且溫度及溼度量測高度為 2 cm 時,則參考作物蒸發散量公式如(18)式所示。

$$ET_0 = \frac{\Delta \times 86400 \times \frac{(R_n - S)}{\lambda} + \gamma \times \frac{900}{(T + 275)} \times u \times (e_a - e_d)}{\Delta + \gamma(1 + 0.337u)} \dots\dots\dots (18)$$

式中, T 為平均日溫度($^{\circ}\text{C}$),其餘參數定義與(17)式相同。

四、研究案例

本研究採用中央氣象局恆春測站 2002~2004 年的氣象觀測資料,共計 1035 筆,並選取與蒸發量相關的日射量、日照時數、平均氣溫、風速、相對濕度等五項氣象因子進行運算,由恆春測站氣象觀測統計資料如表 1 所示。表中看出累積日照時數及日射量和蒸發量的相關係數較高。

五、結果與討論

恆春測站 2002~2004 年的氣象觀測資料,因 2004/8/15~9/21 日射量為 0,故剔除該二個月的資料後,取 34 個月的日平均資料,並分成訓練 792 筆(26 個月),驗證 121 筆(4 個月),測試 122 筆(4 個月)。

本研究使用倒傳遞類神經網路(BP)、自組特徵映射網路(SOM)及調適性網路模糊推論系統(ANFIS)等三種類神經網路架構來建立推估模式,與 Modified Penman 經驗式及 Penman-Monteith 經驗式的推估結果進行比較,並選擇均方根誤差(RMSE)以及平均絕對誤差(MAE)當作模式的評比指標,如(19)及(20)式所示。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_{obs}(i) - E_{est}(i))^2}{n}} \dots\dots\dots (19)$$

$$MAE = \frac{\sum_{i=1}^n |E_{obs}(i) - E_{est}(i)|}{n} \dots\dots\dots (20)$$

式中, E_{est} 、 E_{obs} 為模式推估與實際觀測之蒸發量; n 為資料筆數。

倒傳遞類神經網路(BP)的隱藏層層數依間

表 2 各模式的日蒸發量推估結果

模式	訓練資料 <i>RMSE (mm/day)</i>	驗證資料 <i>RMSE (mm/day)</i>	測試資料 <i>RMSE (mm/day)</i>
BP	1.0635	1.0770	1.1717
SOM	1.0481	1.1218	1.1623
ANFIS	1.0169	1.0654	1.1813
Modified Penman 經驗式	1.2627	1.2611	1.3048
Penman-Monteith 經驗式	1.1372	1.2514	1.3068

表 3 測試資料的日蒸發量推估結果

模式	<i>RMSE (mm/day)</i>	<i>MAE (mm/day)</i>	<i>MAE (%)</i>
BP	1.1717	0.8911	19.80
SOM	1.1623	0.8832	19.63
ANFIS	1.1813	0.8861	19.69
Modified Penman 經驗式	1.3048	1.0352	23.00
Penman-Monteith 經驗式	1.3068	1.0141	22.54

題複雜度而定，隱藏層神經元數目則以試誤法決定，神經元個數過少將無法建構適當函數來描述問題，個數過多將對訓練範例過度描述(overfitting)，本研究中隱藏層設定為一層，並利用訓練及驗證資料推估結果的 *RMSE* 值來決定網路架構，最適當的神經元個數為 2。

自組特徵映射網路(SOM)，亦利用訓練及驗證資料的 *RMSE* 值來決定拓樸層的大小，由於類神經網路的訓練資料用來調整參數，而驗證資料則用來決定網路架構，經由驗證資料的結果，以 6×6 的架構具有最小的誤差。

調適性網路模糊推論系統(ANFIS)，改變輸入層的隸屬函數和輸入值所對應的隸屬函數個數，經由試誤法，找出最佳的隸屬函數為鐘型隸屬函數，每一層神經元個數分別為[2 2 2 2 3]，經由排列組合得到規則數 48 個。

恆春氣象站日蒸發量的觀測平均值約為 4.50 mm/day，由表 2 的數據顯示，類神經網路模式的推估誤差 *RMSE* 值大約介於 1.0~1.2 mm/day 範圍內，傳統經驗式的誤差 *RMSE* 大約為 1.3 mm/day，因而類神經網路比傳統經驗式的計算結果為佳。單就測試資料(表 3)的部份來作比較，BP、SOM、ANFIS 三種類神經網路推估值，其

平均絕對誤差分別為 0.8911 mm/day、0.8832 mm/day 及 0.8861 mm/day，Modified Penman 經驗式及 Penman-Monteith 經驗式的計算結果，平均絕對誤差則分別為 1.052 mm/day 及 1.0141 mm/day；另 BP、SOM、ANFIS 推估值之 *RMSE* 分別為 1.1717 mm/day、1.1623 mm/day 及 1.1813 mm/day，皆比 Modified Penman 經驗式的 1.3045 mm/day 及 Penman-Monteith 經驗式的 1.3068 mm/day 為佳，顯示類神經網路能較精確的推估日蒸發量，惟其誤差比例和觀測平均值 4.50 mm/day 相比，仍屬高比例之誤差，約有 20 %。

圖 4 到圖 8 顯示各類神經網路及傳統蒸發量的推估誤差值。由測試資料之觀測值與各模式推估值序圖可看出，三種類神經網路推估的結果類似，除極端值的推估結果差異較大外，誤差大都分佈於-1.5 mm/day 至 1.5 mm/day 間，且推估值變化波動與實際觀測相比較為平緩，有高觀測值低估、低觀測值高估的現象，另經驗式 Modified Penman 推估值則普遍較觀測值高估，Penman-Monteith 則普遍低估。因類神經網路因可藉由學習與記憶的方式來處理複雜且具不確定性的非線性問題，可較經驗式準確推估日蒸發量，整體的表現也較好。




圖 4 BP 推估日蒸發量之殘差序列圖(測試資料)




圖 5 SOM 推估日蒸發量之殘差序列圖(測試資料)




圖 6 ANFIS 推估日蒸發量之殘差序列圖(測試資料)




圖 7 Modified Penman 推估日蒸發量之殘差序列圖(測試資料)




圖 8 Penman-Monteith 推估日蒸發量之殘差序列圖(測試資料)




圖 9 日蒸發量觀測值與 BP 推估值之誤差分佈直方圖




圖 12 日蒸發量觀測值與 Modified Penman 推估值之誤差分佈直方圖




圖 10 日蒸發量觀測值與 SOM 推估值之誤差分佈直方圖




圖 13 日蒸發量觀測值與 Penman-Monteith 推估值之誤差分佈直方圖




圖 11 日蒸發量觀測值與 ANFIS 推估值之誤差分佈直方圖

圖 9 至 13 顯示各模式推估蒸發量的誤差分佈直方圖，表 4 則陳列各模式日蒸發量推估誤差

於各區間的分佈比例。由各模式日蒸發量之推估值與觀測值之誤差分佈可知，BP、SOM、ANFIS、Modified Penman、Penman-Monteith 模式之誤差分佈於 1.5 mm/day 至 -1.5 mm/day 間，所佔之比例分別為 82.79%、84.43%、82.79%、77.05%及 74.59 %。Modified Penman 經驗式計算結果高估，誤差分佈右偏於 0.00 至 2.0 mm/day 間之比例則為 84.43 %；Penman-Monteith 經驗式的計算結果則略為低估，誤差分佈左偏於 -2.0 至 0.00 mm/day 間之比例為 83.61 %。顯示三種類神經網路推估誤差較小，且準確度無分軒輊。

表 4 測試資料各模式日蒸發量推估誤差比例分佈

殘差(mm/day)	BP	SOM	ANFIS	Modified Penman	Penman-Monteith
<-4.5	0.00%	0.00%	0.82%	0.00%	0.82%
-4.5<-4.0	0.82%	0.82%	0.00%	0.82%	0.00%
-4.0<-3.5	0.82%	0.82%	0.00%	0.00%	0.82%
-3.5<-3.0	0.00%	0.00%	0.00%	0.82%	1.64%
-3.0<-2.5	0.00%	0.00%	0.82%	0.00%	0.82%
-2.5<-2.0	4.10%	2.46%	4.10%	1.64%	3.28%
-2.0<-1.5	3.28%	3.28%	2.46%	0.00%	13.11%
-1.5<-1.0	11.48%	10.66%	10.66%	3.28%	11.48%
-1.0<-0.5	16.39%	18.03%	13.11%	9.02%	16.39%
-0.5<0	15.57%	15.57%	21.31%	18.03%	18.03%
0<0.5	21.31%	18.85%	20.49%	13.93%	13.11%
0.5<1.0	9.02%	13.11%	6.56%	18.03%	11.48%
1.0<1.5	9.02%	8.20%	10.66%	14.75%	4.10%
1.5<2.0	5.74%	4.92%	4.10%	10.66%	3.28%
2.0<2.5	1.64%	1.64%	3.28%	4.10%	0.82%
2.5<3.0	0.00%	0.82%	0.82%	4.10%	0.00%
3.0<3.5	0.00%	0.00%	0.00%	0.00%	0.82%
3.5<4.0	0.82%	0.82%	0.82%	0.00%	0.00%
4.0<4.5	0.00%	0.00%	0.00%	0.82%	0.00%

表 5 日蒸發量累計旬推估結果

模式	RMSE (mm/旬)	MAE (mm/旬)	MAE (%)
BP	3.9394	3.1368	6.49
SOM	3.4066	2.6012	5.38
ANFIS	3.5344	2.7190	5.63
Modified Penman 經驗式	7.1857	5.5230	11.43
Penman-Monteith 經驗式	7.4446	6.5099	13.47

鑒於水資源規劃利用與農業灌溉營運管理，長期蒸發量的推估更為重要，爰利用日蒸發量推估結果累加換算旬蒸發量。恆春氣象站旬蒸發量的量測平均值約為 48.33 mm/旬，以 BP、SOM、ANFIS 三種類神經網路的旬累計推估值，其平均誤差分別為 3.1368 mm/旬、2.6012 mm/旬及 2.7190 mm/旬，Modified Penman 經驗式及 Penman-Monteith 經驗式的計算結果，平均誤差則分別為 5.5230 mm/旬及 6.5099 mm/旬，如表 5 所示。

由於以恆春地區的氣象資料代入經驗公式計算日蒸發量、Modified Penman 經驗式有普遍

高估現象，Penman-Monteith 經驗式則有普遍低估現象，導致以日蒸發量累計為旬蒸發量時，誤差比例仍高達 11.43%及 13.47%，類神經網路則因推估誤差分布較為集中且平均分佈，誤差分佈於-1.5 mm/day 至 1.5 mm/day 間，累計為旬蒸發量，誤差有抵銷減緩的結果，誤差率將大幅降低，三種類神經網路推估誤差比例降至 6.5%以下。

六、結論

本研究提出以類神經網路推估日蒸發量並與傳統經驗式作比較，利用中央氣象局恆春站

2002 – 2004 的日氣象資料為例，相關分析結果彙整如下。

1. 恆春氣象站日蒸發量的量測平均值約為 4.50 mm/day，以 BP、SOM、ANFIS 等三種類神經網路推估恆春地區的日蒸發量，其平均絕對誤差分別為 0.8911 mm/day、0.8832 mm/day 及 0.8861 mm/day，其推估值比推估蒸發散量之 Modified Penman 經驗式的 1.052 mm/day 及 Penman-Monteith 經驗式的 1.0141 mm/day 較低，顯示類神經網路能依一般的氣象資料獲致較精確的蒸發量推估結果。
2. 利用日蒸發量推估結果累加換算較長期的旬蒸發量，仍可看出類神經網路推估結果優於經驗式。恆春氣象站旬蒸發量的量測平均值約為 48.33 mm/旬，經驗式的日推估值因誤差分佈有明顯偏估，累加換算為旬蒸發量，平均誤差則分別為 5.5230 mm/旬及 6.5099 mm/旬，誤差率仍達 11.43%及 13.47%。BP、SOM、ANFIS 等三種類神經網路推估恆春地區的旬蒸發量，則因推估誤差分布較為集中且平均分佈，累加為旬誤差後，誤差比重將會因相戶抵消而降低，其平均誤差分別為 3.1368 mm/旬、2.6012 mm/旬及 2.7190 mm/旬，誤差比例皆低於 6.5%。
3. 因日蒸發量的量測值變動大，類神經網路以平均氣溫、風速、相對濕度、日射量、日照時數等五個影響因子推估日蒸發量，除極端值的推估差異較大外，有不錯的推估結果，但推估值較為平緩，有極高觀測值低估、極低觀測值高估的情形，惟累計為旬蒸發量，極端值的誤差有抵銷減緩的結果，誤差率因而大幅降低。日蒸發推估量之平均絕對誤差佔觀測平均值的比例約為 20%，旬蒸發推估量之誤差比例則皆低於 6.5%。
4. 蒸發量的推估可透過蒸發皿直接量測，惟若無蒸發皿量測資料，一般都以傳統經驗式利用氣象變數推估蒸發量，惟經驗式需具眾多不易精確量測的氣象因子。類神經網路因具有學習能力，不需前提假設，也不需要先針對問題定義複雜的數學模式，只要有充分的歷史資料，即

可進行分析、預測的工作，應可有效應用於蒸發量的推估。

七、參考文獻

1. 甘俊二、陳清田、陳焜耀，1996，「臺灣地區作物需水量推估模式之合適性研究」，農業工程學報，42(2): 8-19。
2. 邱滇瑋，2006，「勢能蒸發散計算方法應用於中海拔地區之比較」，臺灣大學森林環境暨資源研究所碩士論文。
3. 邱奕霖，2004，「地表過程蒸發散之觀測與分析」，中央大學水文科學研究所碩士論文。
4. 施鈞程，2003，「台灣森林集水區的蒸發散量推估」，中興大學水土保持研究所碩士論文。
5. 高慧珊、何宜樺、黃振昌、張斐章，2007，「以自組特徵映射網路推估日蒸發量」，台灣水利，Vol. 55, No. 3, pp. 18-25。
6. 高慧珊，2007，「以自組特徵映射網路推估蒸發量」，臺灣大學生物環境系統工程研究所碩士論文。
7. 張本初，1990，「作物需水量最佳模式之探討」，臺灣大學農業工程研究所碩士論文。
8. 張斐章、張麗秋，2005，「類神經網路」，東華書局。
9. 張煜權，1995，「臺灣之地域性水田灌溉用水量之推估研究」，臺灣大學農業工程研究所碩士論文。
10. 陳清田，1998，「以 Penman-Monteith 法估算區域性參考作物需水量之研究」，嘉義技術學院學報，58: 53-62。
11. 陳朝圳、吳守從、江彥鋒，2006，「應用 MODIS 衛星影像推估台灣地區之蒸發散量」，台灣林業科學，21(2): 249-261。
12. 郭振民、杜榮鴻、林錦源、游保杉，2005，「AVHRR 及 MODIS 衛星影像估算潛勢蒸發散量之比較」，台灣水利，53(4): 13-24。
13. 郭勝豐、程澄元、劉振宇，2006，「倒傳遞神經網路應用於嘉南灌區作物蒸發散量之推估」，農業工程學報，52(1): 24-34。

14. 曾柏凱，2004，「結合衛星遙測估算蒸發散量之應用探討」，成功大學水利及海洋工程研究所碩士論文。
15. 童慶斌、陳主惠，2001，「台灣地區合理之蒸發散折算係數與區域蒸發散量推估方法之建立」，經濟部水資源局計畫報告。
16. 葉信富、陳進發、李振誥，2005，「潛勢能蒸發散經驗公式之最佳化比較」，農業工程學報，51(1): 27-37。
17. 楊國珍，2004，「類神經模糊系統應用於蒸發量推估之研究」，成功大學水利及海洋工程研究所碩士論文。
18. Chang F. J., Chang Y. T., 2006, "Adaptive neuro-fuzzy inference system for prediction of water level in reservoir", *Advanced in Water Resources*, Vol. 29 pp.1-10.
19. Chang F.J., Chang L.C., Wang Y.S., 2007, "Enforced Self-Organizing Map Neural Networks for River Flood Forecasting", *Hydrological Processes*, Vol. 21 pp.741-749.
20. Chang Y. T., Chang L. C. and Chang F. J., 2005, "Intelligent control for modeling of real time reservoir operation: Part II ANN with operating curves", *Hydrological Processes*, Vol. 19 pp. 1431-1444.
21. Keskin, M. E., O. Terzi, and D. Taylan, 2004, "Fuzzy logic model approaches to daily pan evaporation estimation in western Turkey", *Hydrological science journal-journal des science*, 49(6): 1001-1010.
22. Kisi, O., 2006, "Daily pan evaporation modelling using a neuro-fuzzy computing technique", *Journal of Hydrology* (in press).
23. Sudheer, K. P., A. K. Gosain, D. M. Rangan, S. M. Saheb, 2002, "Modelling evaporation using an artificial neural network algorithm.", *Hydrological Processes*, 16: 3189-3202.

收稿日期：民國 97 年 3 月 13 日

修正日期：民國 97 年 4 月 15 日

接受日期：民國 97 年 4 月 22 日