

# 融合多重雨量資訊於水庫集水區即時雨量推估及入庫

## 流量預報技術之研究(1/2)

### Investigation of merging multiple precipitation information on reservoir watersheds rainfall estimation and inflow forecasting techniques (1/2)

主管單位:經濟部水利署

張斐章

Fi-John Chang

國立臺灣大學生物環境系統工程學系

#### 摘要

極端事件的雨量推估乃是一具有挑戰性且受重視的議題，而集水區雨量更受氣候變遷、地形、氣流及降雨分布等因素影響，使其推估之精確性往往不高。在台灣，以往主要的雨量觀測來自於地面測站，然地面觀測雖然準確但空間代表性較低，對於雨量在空間中之變異較難呈現；而近幾年上線應用之雷達觀測系統QPESUMS(Quantitative Precipitation Estimation and Segregation Using Multiple Sensor)能提供即時雨量分布資訊，對於集水區之空間雨量觀測可較有效的掌握。

本計畫第一年度首先蒐集國內外相關文獻，並以中部德基水庫及南部曾文水庫集水區為研究區域，整合地面雨量站及雷達觀測資訊(QPESUMS)探討降雨逕流特性，結果顯示德基水庫集水區6個雨量站於7場事件之時間延遲平均5~11小時，而QPESUMS即時雨量推估與入流量之時間延遲約為5~10小時，且發現降雨-逕流之時間稽延由上游到下游逐漸遞減；曾文水庫集水區上游8個雨量站之雨量在10場事件之時間延遲則約為2小時，QPESUMS即時雨量推估與入流量之時間延遲分析結果亦為2小時。另本計畫使用QPESUMS即時雨量推估資訊，以ANFIS及BPNN二種類神經網路，建立德基水庫及曾文水庫集水區未來1~5小時水庫入流量預報模式，其結果顯示BPNN在整個流量預報的趨勢掌握度較好，但在預報未來3~5小時水庫入流量時重，尖峰流量值有低估的情形發生，反觀ANFIS雖然在整體趨勢的掌握度沒有BPNN來的好，但是在流量尖峰值的預報結果較準確。

在實際操作已建置之石門水庫自動化即時入庫水位預報系統，本年度颱風豪雨期間(6月12日豪雨及泰利、蘇拉颱風)可逐時提供線上預報服務，並驗證預報結果及探討改進方法，本計畫並分別舉辦專家座談會，依據專家學者及相關使用者之建議，做為後續規劃設計德基水庫及曾文水庫集水區自動化即時線上預報系統之參考依據。再者，為提昇研究品質及國際能見度望，將本計畫成果彙整成學術論文投稿於國際SCI期刊。

**關鍵詞:**類神經網路、水庫入流量預報系統、自動化線上預報系統

## Abstract

Estimation of extreme rainfall has been a long-term challenge in Taiwan. Rainfall estimation is generally not very accurate due to various reasons such as complex terrain, atmospheric interaction, climate change, or heterogeneous spatial distribution of extreme rainfalls. Traditionally, most rainfall data were measured from gauges. However, spatial information was ignored by point measurements. Recently, grid-based radar rainfall products become more common and show high potentials in storm rainfall estimation.

In the first year of this project, the catchments of Dechi Reservoir and Tsenwen Reservoir were selected as study areas. We first combined rainfall data collected from gauges and radars and then explored the relationship between rainfall and runoff in these two catchments. The correlation analysis based on seven rainfall events shows that the lag time between rainfall (both gauge and radar data) and runoff ranges approximately from 5 to 11 hours in Dechi Reservoir. For Tsenwen Reservoir, the lag time is about 2 hours for this catchment based on both gauge and radar data of ten rainfall events.

We also applied radar rainfall data (Quantitative Precipitation Estimation and Segregation Using Multiple Sensor, QPESUMS) to real-time rainfall forecasting using ANFIS and BPNN neural networks for estimating 1 to 5 hour-ahead inflow at Dechi and Tsenwen Reservoirs. The results show that BPNN is superior to ANFIS in catching the inflow trend based on real-time rainfall forecasting while the ANFIS performs better at peak values of the inflow forecasting.

Finally, we also investigated the online system of automatic real-time rainfall estimation and water level forecasting for Shihmen Reservoir using storm rainfall events (including Typhoons Talim and Saola as well as the storm occurred in June, 2012). This online system has been validated well. Several expert symposiums were held in this year, which received many comments and suggestions that would be beneficial to our future planning of constructing similar online systems for Dechi and Tsenwen Reservoirs. Furthermore, the results of this project were aggregated into papers that were submitted to SCI journals this year.

**Keywords : Artificial Neural Networks, Reservoir Inflow Forecasting Model, Automatic Online Forecasting System**

### 一、前言

臺灣地區位處亞熱帶受特殊的地形與氣候條件影響，降雨量之分佈在時間或

空間上呈不均勻之狀態，再加上山坡地之開發造成逕流滯留時間短暫，每逢豪大雨爆發的山洪往往在短暫的時間內嚴重威脅沿岸與下游居民生命與財產的安全，近年來更由於全球氣候變遷日趨顯著，極端水文事件之發生更見頻繁，使得突發性洪水事件的發生更加難以預料，在這種特殊的降雨—逕流特徵下，水庫集水區的經營管理可靠性受到相當程度的影響。降雨—逕流歷程之模擬與預測為水資源規劃及洪水預報重要之前置工作，為期能減輕洪水災害，因此發展一精確及穩定之多時刻流量預測模式實有其必要性。

以水文觀點而言，降雨資訊為進行集水區內水文模擬之重要輸入因子，因此本計畫擬以中部德基水庫及南部曾文水庫集水區為研究區域，整合地面雨量站及雷達觀測資訊(QPESUMS)(Quantitative Precipitation Estimation and Segregation Using Multiple Sensor)，探討降雨逕流特性，並分別建立德基水庫及曾文水庫集水區定量降雨推估及水庫入流量/水位預報模式，最後操作石門水庫集水區已建置之自動化即時線上雨量推估及入庫流量（或水位）預報系統，颱風豪雨期間逐時提供線上預報服務，並更新模式參數、維護系統相關資料與展示介面，驗證預報結果並探討改進方法，且依據專家學者及相關使用者之建議，規劃設計德基水庫及曾文水庫集水區自動化即時線上預報系統。

## 二、 研究區域

### 2.1 德基水庫集水區概述

德基水庫集水區位於大甲溪最上游，為全臺灣水庫中壩高及海拔最高的水庫。此集水區分別轄屬台中、宜蘭、花蓮及南投等四縣，集水區面積約為592平方公里，位置約在台灣中部台中市東偏北約100km的中央山脈中，為國內第四大水庫，該區河系以大甲溪為主流，山壁陡峭狹窄且山勢高聳，兩岸坡度介於40至60度，大甲溪主河道高程約介於1300至3300公尺，在大甲溪上游地質構造控制下，自東北向西南流動，在梨山附近轉向南南西，流入德基水庫。集水區內水系以大甲溪為主流，並由十九條小支流匯集而成，主要有七家灣溪、雪山溪、四季朗溪、松茂溪、佳陽溪等，匯集了桃山、雪山、佳陽山等東南坡之水注入大甲溪主流。德基水庫集水區年平均氣溫15.83。C，早晚溫差大，年平均降雨量為2132.9mm，但是在空間上分布並不一致，在合歡山附近有一降雨中心，其年雨量超過3000mm，較其他地區為高。雨量在時間上分布亦不均：夏季半年(4~9月)降雨量為1,454mm，佔年雨量68.2%，自11月至翌年的2月為乾季，雨量僅及年雨量之18.15%。

德基水庫集水區的氣象資料，雨量資料來源以台灣電力公司所建置之氣象觀測站及雨量站，位於集水區內的雨量站有14站，包括梨山、合歡山、環山、松茂、桃山、合歡啞口、思源、達見、志佳陽大、平岩山、佳陽山、無明山、捫山、松峰等站，雨量站管理單位為台灣電力公司，其使用無線電傳輸資料，並已敲擊式雨量計回傳，降雨期間每秒回傳一次；無降雨期間，每六小時回傳一次；流量站有7站，包括南湖、環山(2004年已廢站)、七家灣、四季朗(2004年已廢站)、松茂、合歡及有勝溪等7站，其為人工自記資料，每個月紀錄一次，雨量站與流量站分

布圖如圖1所示。



圖1、德基水庫集水區雨量站位置圖

## 2.2 曾文水庫集水區概述

曾文水庫集水區位於嘉義縣大埔鄉曾文溪流域上游，集水區面積達481平方公里，橫跨嘉義高雄兩縣市，係屬台灣容量及湖面面積最大之水庫，為一具有灌溉、給水、發電、防洪及觀光等多目標水庫。集水區平均標高963公尺，平均坡度54.4%，溪流平均波降達1/65，平均寬度可達8.56公里，主流曾文溪貫穿其中中央部分，再連接東北與西南兩對角。集水區內雨量充沛，集水區內平均降雨量約為2900mm，但雨量分佈極不平均，每年5月至10月的降雨量約佔全年80%以上，而每年11月至隔年4月因雨量稀少，多呈現乾旱現象。

集水區的雨量資料方面主要以南區水資源局所設置之雨量站，位於集水區內的雨量站有9站，包括曾文、水山、樂野、里佳、表湖、馬頭山、龍美、三角南山及大棟山等站之雨量資料，雨量站管理單位為經濟部水利署，其使用無線電傳輸資料，並以敲擊式雨量計回傳，降雨期間每秒回傳一次；無降雨期間，每六小時回傳一次。雨量站分布圖如圖2所示。



圖2、曾文水庫集水區雨量站位置圖

### 三、 研究方法

類神經網路(張斐章、張麗秋, 2010)係由很多非線性的運算單元(一般稱其為神經元)互相聯結而成,其基本架構可分為: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的形式而定;隱藏層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,其層數依問題的複雜度可能有一層或數層;而輸出層則表現輸出變數。神經元則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輸出、輸入及隱藏層間之神經元,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;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,即可進行分析與預測的工作,故而廣泛應用於不同的領域。以下分別簡短介紹本研究所使用的兩種類神經網路模式基本理論:

#### 3.1 倒傳遞類神經網路(BPNN)

倒傳遞類神經網路(Back Propagation Neural Network, BPNN)屬多層前饋式網路的一種監督式學習法,以監督式學習方式來處理輸入與輸出間的非線性映射關係,其學習演算法為誤差倒傳遞演算法,學習目的在降低網路輸出值與目標輸出值間的差距,透過修改各層神經元的權重與偏權值,使誤差函數值達到容忍誤差範圍而停止。其優點為學習精度高、回想速度快,為目前最具代表性且應用最普遍的類神經網路模式。

倒傳遞類神經網路之架構,如圖3所示,包括了輸入層、隱藏層及輸出層,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。其數學式可表示如下:

$$y_j^n = f(\text{net}_j^n) \quad (3.1)$$

$$\text{net}_j^n = \sum_i w_{ji}^n y_i^{n-1} + b_j^n \quad (3.2)$$

$y_j$ 為第j個神經元輸出訊號; $F(\text{net}_j)$ 為神經元的活化函數; $\text{net}_j$ 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個神經元之加權值

$$E = \frac{1}{2} \sum_k (d_k - y_k)^2 \quad (3.3)$$

$d_k$  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

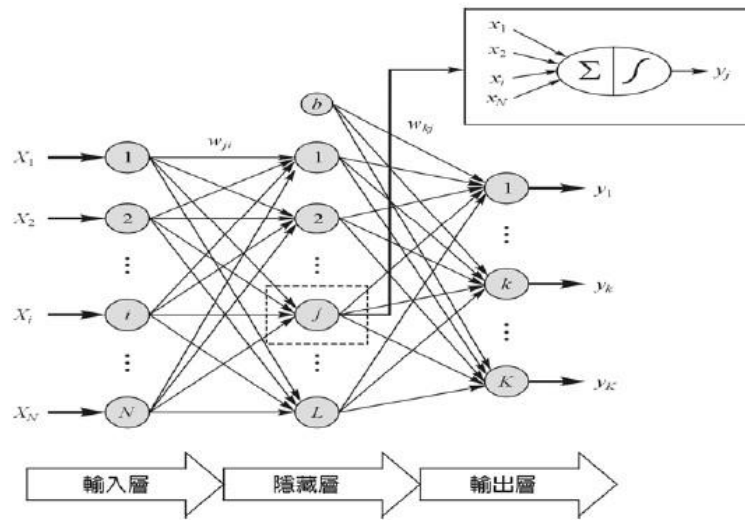


圖3、倒傳遞類神經網路架構圖

### 3.2 調適性網路模糊推論系統(ANFIS)

類神經網路可擷取不明確知識與處理不完全的輸入資訊來解決系統的問題，但是由於類神經網路所獲得的知識是以權重的方式來表示，因此無法解釋推論系統建構的過程。而調適性網路模糊推論系統(Adaptive Network-based Fuzzy Inference System, ANFIS) 即利用以上二種技術加以整合並相互補償個別技術的缺點，使結合的系統將具有類神經網路的優點(如：學習能力、連結式的結構)，與模糊推論系統的優點(如：接近人類的思考行為、容易結合專家知識)，類神經網路也可藉此改善自身透明度使其更接近模糊系統，而模糊推論系統則可加強自我調整的功能以更趨近於類神經網路，如此可有效地解決非線性系統的建構與控制問題。

調適性網路模糊推論系統之架構，如圖4所示，分為五層，同一層節點的隸屬函數或轉換函數採用相似的函數；在學習與調整參數方面，則是結合前饋式類神經網路與監督式學習方法，使得模糊推論系統的所有參數可獲得適當的調整，讓模式具有自我學習與組織能力。




圖4、ANFIS架構圖

ANFIS結合了前饋式類神經網路的監督式學習法，在代入訓練範例後，比較真實輸出值與模式推估值間的誤差，在求得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。參數的修正方法是採用二階段的複合式學習演算法：(1)在訊號向前傳的部分，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。(2)誤差訊號逐層逆向傳導至第一層，再利用最陡坡降法將誤差往前傳以更新前提項參數。當前提項參數與推論項參數在改變的過程中，其各個隸屬函數亦隨之改變，最後當前提項參數與推論項參數固定後，就出現了各個配合適當之隸屬函數。藉由這樣的二階段學習程序，ANFIS即可透過輸入—輸出資料與專家知識(化為模糊If-then規則形式)建立出輸入—輸出之映射關係。

### 3.3 模式評估指標

關於模式穩定性及可靠性之評估，本研究選用3個評比指標來評估不同之輸入模型於入流量預報模式之準確度與適用性，不同的評估指標可針對不同的入流量預報模式判斷其優劣，分別為CC、RMSE及CE共3種，各指標定義如下：

(1)CC (Correlation Coefficient)：

$$CC = \frac{\sum_{t=1}^N [Q_{pre}(t) - \bar{Q}_{pre}] [Q_{obs}(t) - \bar{Q}_{obs}]}{\sqrt{\sum_{t=1}^N [Q_{pre}(t) - \bar{Q}_{pre}]^2} \sqrt{\sum_{t=1}^N [Q_{obs}(t) - \bar{Q}_{obs}]^2}} \quad (3.4)$$

N為資料筆數， $Q_{pre}(t)$ 為預報流量， $Q_{obs}(t)$ 為實際觀測流量， $\bar{Q}_{obs}(t)$ 為實際觀測流量平均值， $\bar{Q}_{pre}(t)$ 為預報流量平均值。

(2) MAE( Mean Absolute Error)：

$$\text{MAE} = \frac{\sum_{t=1}^N |Q_{pre}(t) - Q_{obs}(t)|}{N} \quad (3.5)$$

(3) RMSE (Root Mean Square Error) :

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^N [Q_{pre}(t) - Q_{obs}(t)]^2}{N}} \quad (3.6)$$

(4) CE (coefficient of efficiency) :

$$\text{CE} = 1 - \frac{\sum_{t=1}^N [Q_{obs}(t) - Q_{pre}(t)]^2}{\sum_{t=1}^N [Q_{obs}(t) - \bar{Q}_{obs}]^2} \quad (3.7)$$

## 四、 研究結果

### 4.1 集水區雨量與流量相關性

本研究以相關性分析分別探討德基水庫集水區與曾文水庫集水區上游雨量站之時雨量(R(t)~R(t-10))與水庫時入流量(Q(t))之時間延遲關係。

#### 4.1.1 德基水庫集水區降雨-逕流特性探討

由於影響颱風降雨因子甚多，例如：路徑、風向、風速、氣壓及強度等等多項因素，各雨量站若以單一事件判斷降雨-逕流時間延遲關係將較不具代表性，故分別計算6個雨量站於7場事件之時間延遲平均相關係數，以雨量站雨量與水庫入流量間之最大相關係數判斷降雨-逕流之間平均延遲時間。圖5為6個雨量站於7場事件之時間延遲平均相關係數，從圖可知松茂、梨山、松峰及合歡山四站降雨-逕流稽延時間為5小時；平延山站降雨-逕流稽延時間為8小時；思源站降雨-逕流稽延時間為10小時。






圖5、德基集水區各個雨量站與流量時間延遲之平均相關係數圖

圖6為7場颱風事件最大平均相關係數分佈圖；圖7為最佳之時間延遲分佈圖，即為最大平均相關係數所對應之時間延遲。由圖7可知雷達推估雨量與入流量之時間延遲約為5~10小時(藍色代表無資料區域)，且可發現降雨-逕流之時間稽延由上游到下游逐漸遞減，但由於雷達推估之雨量產品受地形遮蔽因素影響，雖經校正後仍有誤差，因此越往上游區域相關係數值越低。

QPESUMS涵蓋德基水庫集水區之網格數為341格，若將341個網格降雨資料做為降雨-逕流模式之輸入項，會造成任何模式參數過多、資料太少之窘境，因此本計畫依據雷達推估雨量與水庫入流量間時間延遲關係分佈圖配合DEM資料計算河川流向，判斷每個網格之流向路徑，將德基水庫集水區劃分為不同次集水區，關於次集水區劃分方法及水庫入流量預測模式於第五章詳述。

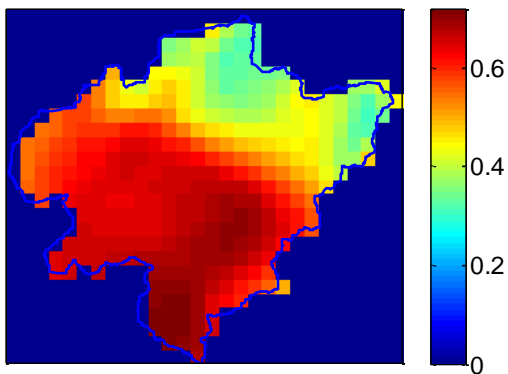


圖6、德基水庫最大平均相關係數分佈圖




圖7、德基水庫最佳之時間延遲分佈圖

#### 4.1.2 曾文水庫集水區降雨-逕流特性探討

本研究利用相關性分析分別探討曾文水庫集水區上游8個雨量站之時雨量與水庫時入流量於不同時間延遲之關係。圖8為雨量站在十場事件中雨量及流量於不同時間延遲之相關性分析之結果，由圖可知8個雨量站在各場事件分析結果皆有相同之趨勢，相關係數當時間延遲約為1~2小時為最大相關係數，接著相關係數隨著時間延遲而下降。




圖8、曾文集水區各個雨量站與流量時間延遲之平均相關係數圖

QPESUMS涵蓋曾文水庫集水區之網格數為270格，分別計算每個網格每小時之降雨量與水庫入流量於不同時間延遲之時間與空間相關性分析，相關性分析所使用之颱風場次共10場，與地面雨量站及入流量不同時間延遲之相關性分析所採用之颱風場次相同，如表4-2。由於每場颱風事件於空間中之降雨分布皆不相同，因此每場事件所計算得知相關係數圖會有些差異，故本計畫取其10場颱風事件平均相關性分析結果，以判斷曾文水庫集水區雷達即時推估雨量及入流量間之時間延遲關係。

圖9為10場颱風事件平均最大相關係數分佈圖；圖10為最佳之時間延遲分佈圖，即為最大平均相關係數所對應之時間延遲。由圖10可知雷達推估雨量與入流量之時間延遲約2小時，且可以發現整個曾文集水區的時間延遲相當一致。

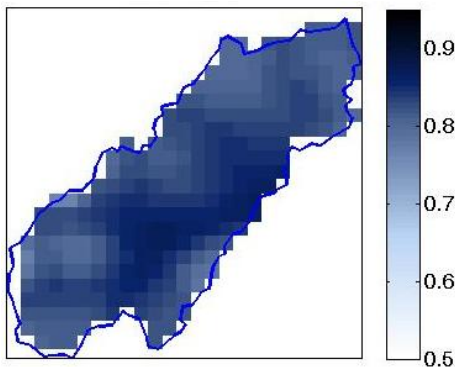


圖9、曾文水庫最大平均相關係數分佈圖




圖10、曾文水庫最佳之時間延遲分佈圖

## 4.2 集水區流量預報模式

### 4.2.1 德基水庫集水區流量預報模式

本研究採用ANFIS及BPNN二種類神經網路，建構德基水庫集水區多時刻流量預報模式，預報未來1~5小時之流量，其網路輸入之變數組合不同次集水區降雨-逕流時間延遲關係，使用QPESUMS即時推估雨量資料及水庫入流量觀測值等資訊，網路輸出為未來1~5小時德基水庫入流量。

從ANFIS及BPNN兩組流量預報模式可知，在t+1時刻兩種模式都有相當高的精準度，其CC值皆可高達到0.98以上，CE值亦可達0.95以上；然而隨著預報時間增加，ANFIS及BPNN兩組流量預報模式CC和CE值逐漸下降，而RMSE及MAE則隨著預報時間增加而變大。

整體上來說，BPNN在整個流量預報的趨勢掌握度較好，但在預報未來3~5小時水庫入流量時，尖峰流量值有低估的情形發生，反觀ANFIS雖然在整體趨勢的掌握度沒有BPNN來的好，但是在尖峰流量值的預報結果較準確。

表1、德基水庫集水區ANFIS流量預報模式之結果比較表

M2	rules	CC			RMSE			MAE			CE		
		training	validation	testing	training	validation	testing	training	validation	testing	training	validation	testing
t+1	3	0.99	0.98	0.98	66.08	63.42	80.45	40.77	42.89	54.14	0.98	0.96	0.95
t+2	2	0.97	0.96	0.95	105.71	100.95	123.39	67.09	72.65	99.34	0.95	0.90	0.89
t+3	3	0.96	0.91	0.91	137.46	148.08	155.22	82.16	108.57	118.96	0.92	0.78	0.82
t+4	6	0.93	0.91	0.86	179.51	167.77	193.58	99.72	120.72	153.11	0.86	0.71	0.71
t+5	2	0.91	0.91	0.82	192.11	182.67	218.26	112.83	140.93	168.27	0.84	0.65	0.61

表2、德基水庫集水區BPNN流量預報模式之結果比較表

	隱藏層 神經元個數	CC			RMSE			MAE			CE		
		training	validation	testing	training	validation	testing	training	validation	testing	training	validation	testing
t+1	6	0.99	0.98	0.98	71.37	64.70	82.67	43.40	45.47	54.92	0.98	0.96	0.95
t+2	4	0.98	0.97	0.94	108.32	80.08	127.51	71.31	59.10	90.16	0.95	0.94	0.88
t+3	4	0.94	0.93	0.92	163.83	121.98	153.68	107.55	91.98	118.19	0.88	0.85	0.82
t+4	5	0.93	0.91	0.86	189.02	146.35	204.45	123.13	111.00	171.34	0.84	0.78	0.67
t+5	5	0.91	0.89	0.82	207.69	155.50	226.41	123.91	118.62	177.55	0.81	0.75	0.58

#### 4.2.2 曾文水庫集水區流量預報模式

本研究採用BPNN以及ANFIS建構曾文水庫集水區多時刻流量預報模式，預報未來1~5小時之流量，其網路輸入之變數組合集水區降雨-逕流時間延遲關係，使用QPESUMS即時推估雨量資料及水庫入流量觀測值等資訊，網路輸出為未來1~5小時曾文水庫入流量。

在ANFIS及BPNN兩組模式之間的比較當中，在t+1時刻兩種模式都有相當高的精準度，相關係數CC皆可達到0.97以上，效率係數CE也達0.96以上；但隨著預報的時間增加，CC和CE值逐漸下降，而RMSE則隨著時間向上增加，BPNN在t+5的時刻相關係數CC值仍然有0.77，效率係數CE也有0.68的表現；而ANFIS在t+5時，相關係數CC值有0.66以上，效率係數CE和BPNN模式相同有0.68的表現。

整體上來說，BPNN在整個流量預報的趨勢掌握度較好，但在重要的尖峰流

量值有些許低估的情形，反觀ANFIS雖然在整體趨勢的掌握度沒有BPNN來的好，但是在峰值的預報結果較準確，未來可以考慮以系集預報之概念將此兩種模式整合，藉此建立更完善的流量預報系統。

表3、BPNN模式預測結果

	CC			RMSE			CE		
	training	validation	testing	training	validation	testing	training	validation	testing
t+1	0.99	0.97	0.97	328	345	331	0.98	0.97	0.98
t+2	0.97	0.93	0.91	554	568	606	0.95	0.91	0.91
t+3	0.95	0.89	0.86	696	699	771	0.93	0.86	0.84
t+4	0.93	0.83	0.80	792	869	906	0.90	0.76	0.77
t+5	0.92	0.77	0.77	864	990	949	0.88	0.68	0.74

表4、ANFIS模式預測結果

	CC			RMSE			CE		
	training	validation	testing	training	validation	testing	training	validation	testing
t+1	0.99	0.97	0.97	364	421	385	0.98	0.96	0.97
t+2	0.95	0.88	0.87	651	802	796	0.94	0.87	0.87
t+3	0.93	0.85	0.84	800	861	817	0.90	0.85	0.84
t+4	0.91	0.76	0.80	910	1106	927	0.87	0.77	0.80
t+5	0.89	0.66	0.75	983	1355	1033	0.84	0.68	0.75

### 4.3 自動化即時線上預報系統

自動化即時線上預報系統在主機端經由類神經網路即時預測模式進行入庫水位預測後，即可透過網頁傳輸技術將預測結果傳遞至用戶端；透過網際網路的便利與Google Map API模組的服務，使用者無需額外安裝任何程式，僅以網路瀏覽器即可檢視預測結果，不受時間或地域上之限制。圖11為自動化即時線上預報系統預測結果展示介面，提供地圖展示與圖表展示等兩種展示形式，圖11展示石門水庫集水區QPESUMS分區的雨量累積資料以繪圖與列表顯示，左方表格顯示預報水位（即時水位與未來1~5小時預報水位）及過去時雨量資料（過去1~6小時）。

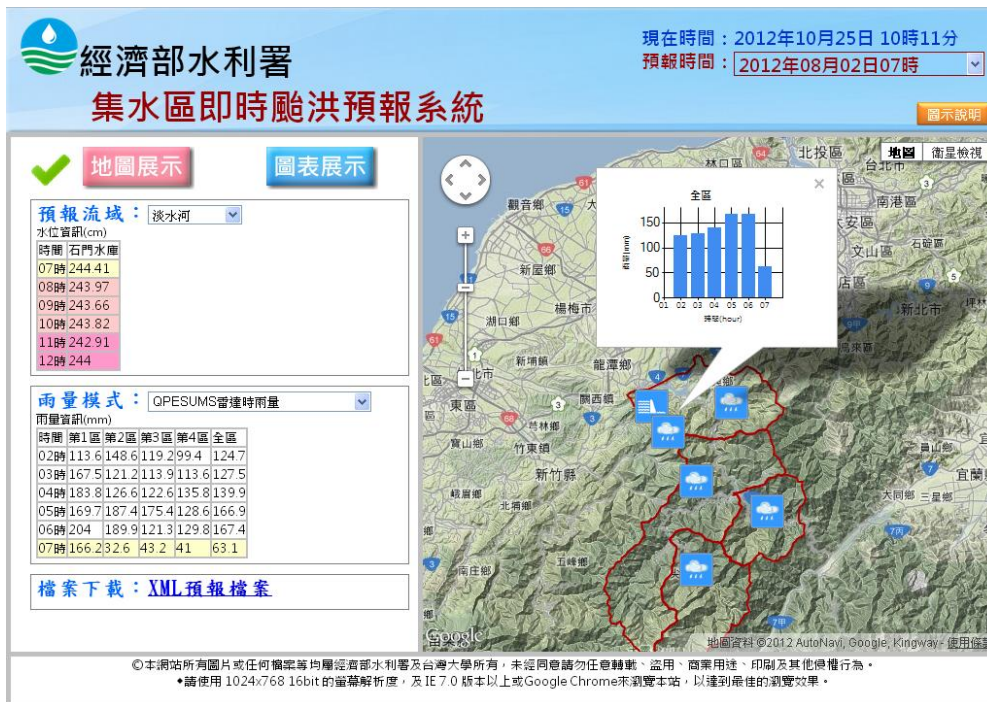


圖 11、自動化即時線上預報系統 Google Map 展示介面

XML(eXtensible Markup Language，可延伸標記語言)語法是從標準通用標記語言 (SGML) 中簡化修改出來的，XML被廣泛用來作為跨平台之間交互數據的形式，以為網路不同資料庫格式進行資料交換的標準格式。為符合水利署需求，自動化即時線上預報系統完成相關預測後，將以XML檔格式自動儲存各時刻預測結果，以利日後檢視或作為後續研究之參考。圖6-7為自動化即時線上預報系統在完成石門水庫集水區之水庫預報水位及過去雨量資訊，以XML檔的格式標準儲存，可供使用者下載。

## 五、 結論與建議

### 5.1 結論

極端事件的雨量推估乃是一具有挑戰性且受重視的議題，而集水區雨量更受氣候變遷、地形、氣流及降雨分布等因素影響，使其推估之精確性往往不高。在台灣，以往主要的雨量觀測來自於地面測站，然地面觀測雖然準確但空間代表性較低，對於雨量在空間中之變異較難呈現；而近幾年上線應用之雷達觀測系統QPESUMS即能提供較具體之雨量分布趨勢，對於集水區之空間雨量觀測可有效進一步掌握。降雨—逕流歷程之模擬預測為水資源管理及洪水預報之重要工作，為期能減輕洪水災害，發展一精確及穩定之水庫集水區多時刻流量(水位)預測模式係本計畫主要目的。本計畫第一年度重要結果如下所述：

1. 本計畫以德基水庫及曾文水庫集水區為研究區域，整合地面雨量站及QPESUMS資訊探討降雨逕流特性，結果顯示德基水庫集水區6個雨量站於7場事件之時間延遲平均5~11小時，而QPESUMS即時雨量推估與入流量之時

間延遲約為5~10小時，降雨-逕流之時間稽延由上游到下游逐漸遞減；曾文水庫集水區上游8個雨量站之時雨量在10場事件之時間延遲則約為2小時，QPESUMS即時雨量推估與入流量之時間延遲分析結果亦為2小時。

2. 在即時雨量推估模式中，由CC、CE、RMSE及MAE四個評估指標可知德基水庫及曾文水庫集水區之QPESUMS即時雨量推估在高雨量推估時會產生較大的誤差；整體而言本計畫所建置之BPNN模式表現較佳，其RMSE及MAE誤差值較QPESUMS模式小；效率係數(CE值)較QPESUMS模式高。
3. 本計畫以ANFIS及BPNN二種類神經網路，建立德基水庫及曾文水庫集水區未來1~5小時水庫入流量預報模式，其結果顯示BPNN在整個流量預報的趨勢掌握度較好，但在預報未來3~5小時水庫入流量時，尖峰流量值會有低估的情形發生，反觀ANFIS雖然在整體趨勢的掌握度沒有BPNN來的好，但是在流量尖峰值的預報結果較為精確。
4. 石門水庫集水區自動化即時線上雨量推估及入庫水位預報系統，本年度在颱風豪雨期間已提供逐時線上預報服務，並彙整預報結果電子郵寄到相關單位整合。
5. 今年度有三場颱風暴雨事件之驗證預報結果，以蘇拉颱風預報準確度最高，其他兩場因降雨量較少，水位又受到人為操作干擾，預報模式無法掌握人為操作關係，影響預報準確度。
6. 本計畫分別於德基與曾文水庫舉辦座談會，瞭解水庫人員之需求及意見；並於石門水庫舉辦專家座談會，依據專家學者及相關使用者之建議，做為後續規劃設計德基水庫及曾文水庫集水區自動化即時線上預報系統之參考依據。
7. 本計畫為署內遴選參加第六屆世界水論壇，於國際間展示相關研究成果，詳細內容收錄於附錄三中。

## 5.2建議

1. 由ANFIS及BPNN二種類神經網路流量預報模式可知各有其優劣點，故未來可考慮系集預報方式整合，期可增加流量預報之精確度。
2. 北中南各水庫在颱風豪雨時期即時流量的傳輸狀況不同，本計畫所建置之線上即時預報模式目前應用於石門水庫為水庫水位預報，依據本年度北部石門水庫線上預報之經驗，建議明年度德基、曾文水庫可依即時流量或水位資料傳輸的穩定性研判進行流量或水位預報。
3. 本年度以ANFIS及BPNN建置德基與曾文水庫集水區未來1~5小時水庫入流量預報模式，分別在整體表現及尖峰流量有不同的優點，建議明年度線上即時預報系統整合此二模式為其預報參考值。

4. 本計畫所建置水庫入流量預報模式，所選用之輸入資料為水庫入流量及QPESUMS全區平均雨量，此選取方式較可確保模式之穩定性，建議相關研究於資料選取上，可參考本計畫之研究結果。
5. 模式建立的資料選取是把累積雨量門檻設為100mm，將各區域低於門檻之颱風場次去除，選用影響較大的颱風資料建構預報模式，輸入資料為水庫入流量及QPESUMS全區平均雨量，此選取方式較可確保模式之穩定性，建議相關研究於資料選取上，可參考本計畫之研究結果。

## 六、 參考文獻

1. 張斐章、張麗秋，2010，類神經網路導論原理與應用，滄海書局。
2. 經濟部水利署，2011，整合多重觀測資訊於山區雨量推估及洪水預報風險管理評估(2/2)。
3. Akhtar, M. K., Corzo, G. A., Andel, S. J. van, Jonoski, A., 2009. River flow forecasting with artificial neural networks using satellite observed precipitation pre-processed with flow length and travel time information: case study of the Ganges river basin. *Hydrology and Earth System Sciences*, 13, 1607-1618.
4. Borga, M. (2002). "Accuracy of radar rainfall estimates for streamflow simulation." *Journal of Hydrology* 267(1-2): 26-39.
5. Campolo, M., P. Andreussi, and A. Soldati (1999), River flood forecasting with a neural network model, *Water Resour. Res.*, 35(4), 1191-1197, doi:10.1029/1998WR900086.
6. Chang, F.J., Chang, L.C., Huang, H.L., 2002. Real time recurrent neural network for streamflow forecasting. *Hydrology Processes* 16, 2577-2588.
7. Chiang, Y.M., Chang, F.J., 2009, "Integrating hydrometeorological information for rainfall-runoff modeling by artificial neural networks", *Hydrological Processes*, 23(11):1650-1659.
8. Collaboration, M., et al. (2006). "Observation of Muon Neutrino Disappearance with the MINOS Detectors in the NuMI Neutrino Beam." *Physical Review Letters* 97(19): 191801.
9. Minns, A. W. and M. J. Hall (1996). "Artificial neural networks as rainfall-runoff models." *Hydrological Sciences Journal* 41(3): 399-417.
10. Nayak, P. C., Sudheer, K. P. and Ramasastri, K. S. (2005), Fuzzy computing based rainfall-runoff model for real time flood forecasting. *Hydrol. Process.*, 19: 955-968. doi: 10.1002/hyp.5553
11. Rajurkar, M. P., et al. (2004). "Modeling of the daily rainfall-runoff relationship with artificial neural network." *Journal of Hydrology* 285(1-4): 96-113.