

# 整合遙測資訊於山區雨量推估

張斐章<sup>1\*</sup> 蔡孟蓉<sup>2</sup> 江衍銘<sup>3</sup> 謝明昌<sup>4</sup>

## 摘要

近年來遙測資訊相繼應用於降雨預報，其主要優點在於有效觀察大範圍降雨在時空之變化。本研究首先蒐集 QPESUMS 系統之雷達雨量產品、PERSIANN-CCS 衛星觀測系統之雨量產品以及地面雨量站觀測紀錄；接著以遺傳演算法融合地面雨量、雷達及衛星影像推估雨量三種資訊；為比較融合雨量之有效性，本研究再以 ANFIS 架構三種定量降雨預報模式分別為：(1)三種未融合資訊(2)二種融合資訊(3)三種融合資訊，預測未來一小時降雨，由研究結果可知三種融合資訊之定量降雨預報系統為最佳，模式測試部分相關係數、RMSE 及 MAE 分別為 0.88、3.88 及 2.39 且 RMSE 在 t+1 時刻有 28%之改善率。

**關鍵詞：**資料融合、類神經網路、定量降雨預報

## 1. 前言

目前許多國際性研究計劃皆將焦點著重於極端事件的雨量及洪水推估，其為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、季節及降雨分布等因素影響，使其預報之精確性往往不高，導致接續之水文模擬或流域水源管理不盡理想。

臺灣位處亞熱帶四面環海地理位置特殊，平均每年遭受 3~4 個颱風侵襲，降雨量之分佈在時間或空間上呈不均勻之狀態，且臺灣為一狹長型島嶼，中央山脈橫互其中，因此河川坡陡流急，加上山坡地開發，每逢颱風暴雨時期，上游的洪水往往在數小時內便抵達下游及注滿水庫(Chang *et al.*, 2002)。逕流滯留時間短暫，使得突發性洪水事件的發生更加難以預料，因此「時間」為相當關鍵之因素。在這種特殊的降雨-逕流特徵下(宋仁良, 2004, 王琮美, 2005, Chang *et al.*, 2008)，為期能減輕災害，因此發展一精確雨量預報模式有其必要性。(Pan *et al.*, 2004, Chiang *et al.*, 2007, Chiang & Chang, 2009) 在臺灣，以往主要的雨量觀測來自於地面測站，

然地面單點之觀測無法呈現雨量在空間中之變異；近幾年應用雷達觀測系統能提供較具體之雨量分布趨勢，然而卻會受山區地形遮蔽因素影響；而衛星影像應用於雨量推估之成果雖然空間解析度不若雷達觀測高，但卻不受地形變化影響。因此，本研究擬以石門水庫集水區為研究區域，整合地面雨量站、雷達觀測資訊(QPESUMS)(Quantitative Precipitation Estimation and Segregation Using Multiple Sensor)及衛星影像資訊(PERSIANN-CCS)(Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks- Cloud Classification System)，建立集水區定量降雨預報模式。

## 2. 研究區域及資料概述

石門水庫為台灣地區第三大水庫，以淡水河上游之大漢溪為其主流，集水面積約 763.4 平方公里。水庫集水區年平均降雨量約在 2,200 mm~2,800 mm 之間，雨量多集中分佈於五至九月，其主要原因乃颱風所造成，另外尚有西南氣流所造成之雷陣

<sup>1</sup> 國立臺灣大學生物環境系統工程學系 教授

<sup>2</sup> 國立臺灣大學生物環境系統工程學系 博士候選人

<sup>3</sup> 國立臺灣大學生物環境系統工程學系 博士後研究員

<sup>4</sup> 經濟部水利署防災中心 主任

\*通訊作者, 電話: 02-33663452, E-mail: changfj@ntu.edu.tw

收到日期:民國 101 年 06 月 14 日

修改日期:民國 102 年 01 月 03 日

接受日期:民國 102 年 01 月 18 日

雨、及熱帶性低氣壓所帶來之豪雨。石門水庫集水區氣象資料相當完備，資料來源主要為北區水資源局所設置之氣象觀測站及雨量站。其中雨量站又可分為無線電遙報雨量站及自計雨量站等二種。水庫集水區設有十六處雨量站，其中霞雲、高義、巴陵、玉峰、嘎拉賀、鎮西堡、池端、西丘斯山、白石等九站為無線電遙報雨量站，而自計雨量站則有石門、十一份、長興、復興、三光、鞍部、秀巒等七站。

本研究針對石門水庫集水區雨量站並配合雷達及衛星影像系統之觀測時間，蒐集西元 2006~2009 年期間之歷史颱風暴雨資料共 13 場，每場颱風所蒐集的資料長度皆為陸上颱風警報發布至陸上颱風警報解除。其中蒐集的資料可分為地面雨量站資料、QPESUMS 雷達推估降雨資料及 PERSIANN-CCS 衛星推估降雨資料三個部分，分述如下。

## 2.1 地面雨量資料

本研究蒐集石門水庫集水區包括：石門、復興、巴陵、霞雲、高義、玉峰、嘎拉賀、鎮西堡、白石、長興、三光、秀巒及西丘斯山等 13 個雨量站，集水區及各雨量站之位置如圖 1 所示。西元 2006~2009 年期間 13 場歷史颱風之基本資料如表 1 所示。

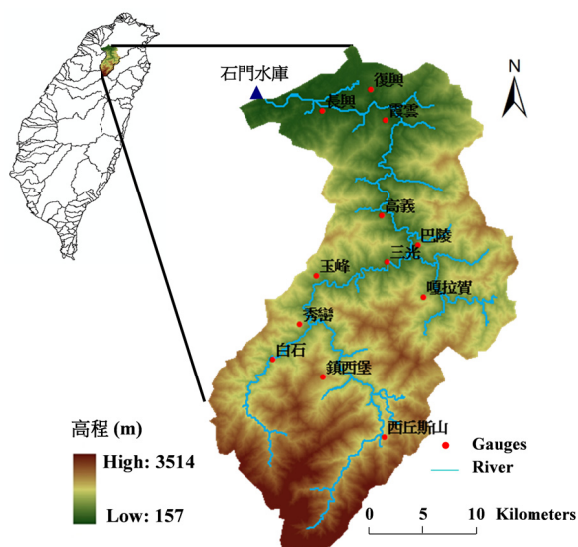


圖 1 石門水庫集水區雨量站位置圖

表 1 颱風事件基本資料表

事件名稱	英文名稱	觀測日期	強度
桑美	SAOMAI	2006/08/09~08/10	中度
寶發	BOPHA	2006/08/07~08/09	輕度
帕布	PABUK	2007/08/06~08/08	輕度
聖帕	SEPAT	2007/08/16~08/19	強烈
韋帕	WIPHA	2007/09/17~09/19	中度
柯羅莎	KROSA	2007/10/04~10/07	強烈
卡玫基	KALMAEGI	2008/07/16~07/18	中度
鳳凰	FUNG-WONG	2008/07/26~07/29	中度
辛樂克	SINLAKU	2008/09/11~09/16	強烈
哈格比	HAGUPIT	2008/09/21~09/23	中度
薔蜜	JANGMI	2008/09/26~09/29	強烈
蓮花	LINFA	2009/06/19~06/22	輕度
莫拉克	MORAKO	2009/08/05~08/10	中度

## 2.2 QPESUMS 雷達降雨推估產品

雖然地面雨量觀測記錄值為直接觀測最為接近真實降雨量，然而其空間代表性低，僅能代表單點之值；而遙測雨量產品便能有效解釋降雨系統在空間中的分布與移動情形。多重觀測工具之定量降雨估計與分類技術 QPESUMS (圖 2) 為經濟部水利署、氣象局、農委會水土保持局及美國劇烈風暴實驗室整合多重氣象觀測資料並結合地理資訊系統發展劇烈天氣監測系統，系統提供台灣地區整合後之定量降水估計與極短時之定量降水外延預報產品，而系統在產品顯示方面共包含五大類：(1) 雷達基本及整合產品；(2) 地面觀測資料；(3) 降水估計產品；(4) 降水預報產品；(5) 劇烈天氣資訊。(Chen *et al.*, 2007)

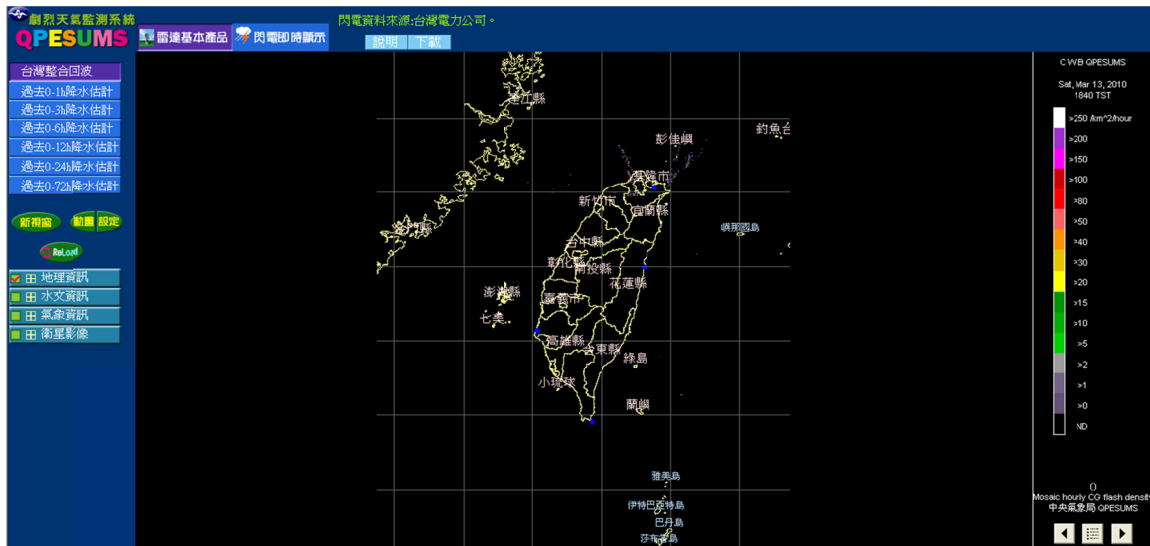


圖 2 QPESUMS 系統介面(<http://qpesums.cwb.gov.tw/>)

QPESUMS 系統網格資料起始點為  $27^{\circ}\text{N}$ ,  $118^{\circ}\text{E}$ , 範圍介於  $20^{\circ}\sim 27^{\circ}\text{N}$ ,  $118^{\circ}\sim 123.5^{\circ}\text{E}$ , 其南北方向共有 561 個網格; 東西方向共有 441 個網格。產品空間解析度為  $0.0125^{\circ}\times 0.0125^{\circ}$  (約  $1.25\text{km}\times 1.25\text{km}$ ); 時間解析度為 10 分鐘。QPESUMS 系統針對最低可用仰角回波資料設定一 Z-R 關係式, 透過 Z-R 關係式推估降雨量, 目前系統使用  $Z=32.5R^{1.65}$  為參考 Alberat, Canada 之夏季對流降雨與雷達觀測資料之關係(Xin *et al.* 1997)。

由於雷達觀測於山區將會受到地形遮蔽影響(如圖 3a 所示), 觀測資料無法直接拿來作為水文上之應用, 必需利用地面雨量站的降雨觀測資料來率定所需之參數, 目前模式之率定方法大致可區分為氣象方法與統計方法。氣象方法為直接量測雨滴粒徑與數量等相關資料, 而統計方法則利用雷達回波因子與地面雨量觀測值來作分析, 其中較常應用之分析方法有簡單之迴歸分析、多變量分析及分層分析法。無論氣象方法或統計方法皆希望獲得可靠之參數, 然如前述, 影響降雨強度之因子眾多, 較難以單一 Z-R 指數分佈關係式準確描述降雨強度與雷達回波因子間之複雜關係。因此, 本研究直接採用中央氣象局所提供校正後之雷達推估雨量產品(如圖 3b 所示), 作為後續定量降雨預報模式之輸入項。

## 2.3 PERSIANN-CCS 衛星降雨推估產品

西元 1957 年蘇聯發射人類史上第一顆人造衛星史波尼克號(SPUTNIK), 從此展開全球太空發展的序幕。往後數十年間衛星從只具備拍攝雲圖的簡單能力, 到分別具備不同功能及特性的衛星, 其中氣象衛星可以監測大尺度天氣系統的變化, 同時可以定量的觀測許多的氣象要素, 且能即時把所探測之資料傳送到地面上的衛星中心和各接收站使用, 因此以氣象衛星資料來推估地面降雨已成為近年來於雨量推估的主要方法之一。

在諸多以衛星影像資訊所建構之即時降雨推估模式中, 首推 PERSIANN (Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks)系統, 此一系統由 Hsu *et al.*, (1997)所提出, 其收集 GMS 紅外光影像以及地面資料, 利用自組特徵映射網路, 將每個像元的亮溫、SURF(為一指標, 用於表示此像元為陸地、海岸、海洋等)、目標區域中心  $3\times 3$  像元的平均亮溫、目標區域中心  $3\times 3$  像元的亮溫之標準偏差、目標區域中心  $5\times 5$  像元的平均亮溫與目標區域中心  $5\times 5$  像元的亮溫之標準偏差等 6 個項目為網路輸入資料, 預報日本島及佛羅里達半島二個區域之降雨量。其後研究團隊(CHRS)再提出改良之

PERSIANN-CCS 系統(Hong *et al.*, 2004),目前兩者皆在 NASA 的贊助下發展出降雨產品,且已實際應用於即時線上操作,其中,PERSIANN 模式之空間解析度為25km×25km,模式之輸出涵蓋全球;而 PERSIANN-CCS 模式之空間解析度更提高為4km×4km,兩者皆可不間斷地提供每小時之即時降雨推估。

PERSIANN-CCS 相較於 PERSIANN 而言,萃取出更多雲層的資訊,對於近紅外光影像中的雲層有更多的描述,例如雲高、雲最低溫度、雲面積與紋理等,並由這些特徵用於對衛星雲圖分類,分類採用 SOFM(Self Organization Feature Mapping Algorithm)類神經網路,其由20×20個拓撲層組成,並將 20x20 個拓撲層分類為 7 個類別,以此 7 個類別建立非線性模式建立雲頂溫度與降雨率(Tb-R)

的關係。PERSIANN-CCS 的主要核心為變動的門檻值演算法,該演算法能成功萃取出雲層的特徵;PERSIANN-CCS 系統之演算示意圖如圖 4 所示;

PERSIANN-CCS 系統不僅保留了 PERSIANN 的優點,更在架構上與影像前處理之步驟有所改良,首先,在架構上 PERSIANN-CCS 之輸出層由線性轉換改良成非線性轉換;其次,不同於 PERSIANN 將影像資料每一個 pixel 直接映射至降雨強度,PERSIANN-CCS 則是考慮了影像切割的方法,進而獲得不同大小的雲塊資訊,雖然模式之計算較為複雜但卻大幅增加模式推估的精確性(江衍銘及張斐章,2006)。其模式步驟大致可區分為四點(如圖 5 所示);(1)雲影像的切割 (2)雲塊特徵之萃取 (3)雲塊之分類 (4)降雨量之推估。

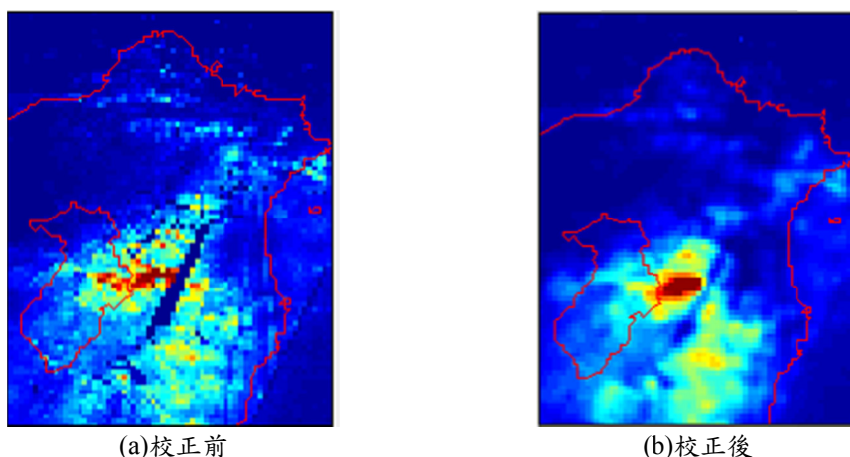


圖 3 雷達資料(QPESUMS)校正前後降雨分佈圖

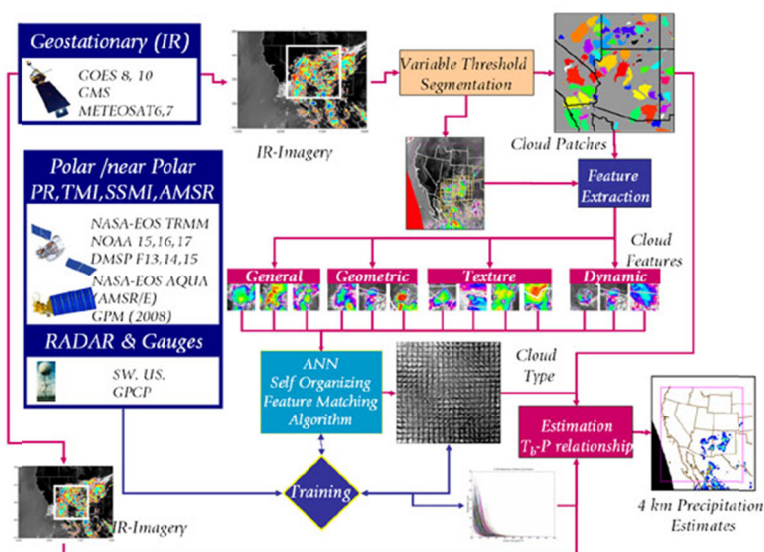



圖 4 PERSIANN-CCS 演算示意圖 ([http://chrs.web.uci.edu/research/satellite\\_precipitation/activities01.html](http://chrs.web.uci.edu/research/satellite_precipitation/activities01.html))



圖 5 PERSIANN-CCS 系統之網路架構圖 (Hong *et al.*, 2004)

**雲影像切割**乃是以溫度的設定為切割準則，一般皆以固定門檻值(253K)為主，低於此門檻值的雲頂溫度，其雲系視為有降水，而高於此門檻值的雲頂溫度則視為無降水機率，然而若影像包含許多對流胞，單一門檻值將無法有效分割出雲塊，故 PERSIANN-CCS 系統則利用增溫門檻值 (incremental temperature threshold: ITT)藉由逐漸增加溫度的方式對雲塊進行切割。

**雲塊特徵萃取**亦即是對模式輸入變數之挑選，包括：雲塊溫度之最低值及平均值( $T_{min}$  &  $T_{mean}$ )、雲塊面積(AREA)、雲塊形狀指標(SI)、雲頂溫度之標準偏差(STD)、局部( $5 \times 5$  pixel)雲頂溫度標準偏差之平均值(MSTD5)、局部雲頂溫度標準偏差之標準偏差(STD5std)、雲頂溫度之梯度(TOPG)及灰階組織(ASMm)等，共 9 項雲塊特徵。

**雲塊分類**即為將萃取出來之 9 項雲塊特徵作為 SOM 模式之輸入變數，依其在幾何空間上之相關性進行分類，同時亦將多維度之輸入向量映射至二維之特徵圖上，以簡化後續之計算。

**降雨量推估**則是在輸出層上依不同之分類結果各自建立不同雲頂溫度與降雨量之非線性迴歸式，其可獲得較佳之推估雨量。

### 3. 以資料融合方法整合地面雨量、雷達及衛星影像觀測

#### 3.1 遺傳演算法

遺傳演算法 (Genetic Algorithm, GA) 乃源自

達爾文進化論中「物競天擇、適者生存」的觀念，利用自然進化、擇優而生的理論來達到增進結果表現值的目的。John Holland 首先於其論著「Adaptation in Natural and Artificial Systems」(1975)中提出，染色體字串能夠用來模擬生物演化機制-適者生存，讓適應值較佳者進行繁衍下一代，其強大的演化能力即使在搜尋空間相當龐大的區域中仍能收斂於近似全域最佳解。

GA 應用於決策模式最佳解的搜尋機制時，首先將決策變數進行編碼轉換成 GA 中的基因，而問題中所有決策變數所轉換的基因集合成為染色體或稱為個體，透過初始化過程，產生第一個世代的群集由設定數目的染色體所集合而成，染色體的總數目稱為群集大小；在第一個世代產生後，須經由適合度評估每個個體(染色體)的優劣程度後，透過機率式的篩選法則選出所需親代的染色體個數，再由遺傳運算子進行複製 (reproduction)、交配 (crossover) 跟突變 (mutation) 產生下一代。遺傳演算法為具演化能力的最佳化搜尋方法，在許多研究與應用證實了 GA 在搜尋全域最佳解 (global optimum) 的問題上，表現出此法具有強健性與效能性，也可以解決傳統數學規劃中對於非連續性、不可微分、多峰及非凸函數的限制與瓶頸。

遺傳演算法主要的搜尋機制有三大運算子：複製、交配及突變，在解空間中進行反覆的進行搜尋，以下分別描述之：

- (1) 複製：每一個體之適合度的高低，影響了其本身是否被挑選或被淘汰，通常適合度越高的個體被選取複製到下一代的機率越高；反之，適

合度越低的個體也有可能被淘汰。常見的選取方法有輪盤式選取法 (roulette wheel selection) 與競爭式選取法 (tournament selection)、排序選取法 (ranking selection)。

- (2) 交配：交配運算就是在複製後從交配池中隨機選取兩個染色體，根據預先設定的交配率 (crossover rate) 決定是否基因交換以產生新子代，交配率愈高，有助於搜尋到表現較佳的解，交配率太低會使收斂速度緩慢，但若交配率太大可能造成較好的個體容易被替換，也會減緩收斂的速度；交配率一般設為 0.8~1。常見基因交換的位置與分割方法有單點 (single-point) 交配、多點 (multi-point) 交配、算術交配 (arithmetical crossover) 及模擬二位元交配 (simulated binary crossover, SBX)。
- (3) 突變：突變機制是為了避免提早收斂、落入局部解之困境。突變於實數編碼中最常見的方法是，突變基因在上下界範圍內隨機產生一個新值，稱為隨機突變。突變發生與否取決於突變率 (mutation rate) 的大小，若小於突變率，則該基因發生突變，反之則不發生突變；突變率門檻值的設定一般約在 0.01~0.1 左右，因過大的突變率則如同使用隨機的方式搜尋，如此便失去了使用遺傳演算法的意義。
- (4) 菁英策略：菁英策略則是將搜尋過程中最好的解保存下來，避免在演算過程中破壞前面搜尋的最佳解。一般在遺傳演算法中皆建議使用菁英策略來提高全域搜尋的效能。
- (5) 停止原則：遺傳演算法之搜尋停止原則，通常是設定一收斂範圍達到即停止；或是搜尋出最佳解的表現在一定程度內趨於收斂就停止搜尋；亦或是設定固定的演算代數，當演算到達設定代數即停止搜尋。

### 3.2 融合地面雨量、雷達及衛星估計之降雨量

本研究首先將地面雨量、雷達(QPESUMS)及衛星(PERSIANN-CCS)三種雨量資料來源，處理為

集水區平均面積雨量，計算方式如下所述：

- (1) 雨量站資料：使用徐昇式法計算平均面積雨量；
- (2) QPESUMS 資料：其涵蓋石門水庫集水區之網格共有 434 格，將 434 個網格之雨量值累加後除以網格總數，所求得平均面積雨量即為 QPESUMS 所推估之集水區每小時平均面積雨量；
- (3) PERSIANN-CCS 資料：處理步驟與 QPESUMS 相同，由於 PERSIANN-CCS 其空間解析度為 4kmx4km，因此所涵蓋之石門水庫集水區為 45 格，將 45 個網格之雨量值累加後除以網格總數，即可求得 PERSIANN-CCS 所推估之集水區每小時平均面積雨量。

在雨量融合過程中最重要的即是融合權重之搜尋，融合權重搜尋方法有很多種，常見有平均法、最陡坡降法及梯度法等。而最佳化搜尋方法中，遺傳演算法為相當熱門方法之一，其優點可搜尋全域最佳解，因此本研究使用遺傳演算法搜尋最佳融合參數。本研究使用雷達、衛星雨量產品及觀測雨量做資料融合處理，利用遺傳演算法求得最佳融合係數，產生融合雨量(Pm)。

本研究將分別融合出兩種不同融合雨量，第一種融合雨量為使用雨量站及雷達(QPESUMS)資訊分別計算出之集水區平均面積雨量，以上述二種雨量資訊透過遺傳演算法方式求得最佳融合係數  $\theta_1$  及  $\theta_2$ ，其 GA 目標函式及限制式如(1)式與(2)式所示，

$$\text{Min } f(X) = P_g(t) \times \theta_1 + P_r(t) \times \theta_2 - Y \quad (1)$$

$$\theta_1 + \theta_2 = 1 \quad (2)$$

其中  $\theta_1$  及  $\theta_2$  分別代表雨量站(Pg)及雷達(Pr)資訊在融合過程中所佔之權重，其值應介於[0 1]之間，Y 為石門水庫 t+5 時刻之入庫流量。根據研究文獻(何宜樺，2009)石門水庫集水區降雨與流量間之時間延遲為 5 個小時，即 t 時刻之降雨與 t+5 時刻之石門水庫入庫流量有最大之相關性，故本研究假設 t+5 時刻之入庫流量與 t 時刻之融合雨量有

最佳之相關性，因此透過 GA 搜尋之最佳融合權重所組成之融合雨量，即可視為石門水庫集水區  $t$  時刻之推估雨量。

第二種融合雨量為使用雨量站、雷達 (QPESUMS) 及衛星 (PERSIANN-CCS) 資訊分別計算出集水區平均面積雨量，以上述三種雨量資訊透過遺傳演算法方式求得最佳融合係數  $\theta_1$ 、 $\theta_2$  與  $\theta_3$ ，其 GA 目標函式及限制式如(3)式與(4)式所示，

$$\text{Min } f(X) = P_g(t) \times \theta_1 + P_r(t) \times \theta_2 + P_s(t) \times \theta_3 - Y \quad (3)$$

$$\theta_1 + \theta_2 + \theta_3 = 1 \quad (4)$$

其中  $\theta_1$ 、 $\theta_2$  及  $\theta_3$  分別代表雨量站(Pg)、雷達 (Pr) 及衛星 (Ps) 資訊在融合過程中所佔之權重，其值應介於 [0 1] 之間， $Y$  亦為石門水庫  $t+5$  時刻之入庫流量。

上述二種資訊之融合雨量與三種資訊之融合雨量，經由 GA 進行最佳融合權重搜尋結果如表 2 所示。由圖 6 及圖 7 結果可知，無論是融合二種資訊或融合三種資訊，透過  $t+5$  時刻流量所搜尋出之最佳融合參數，其融合雨量即  $t$  時刻之推估雨量與實際降雨量相當接近，其相關係數皆高達 0.99，因此可推論透過  $t+5$  時刻流量所搜尋出之融合參數，即為推估  $t$  時刻降雨量之最佳參數。




圖 6 二種資訊融合後  $t$  時刻雨量




圖 7 三種資訊融合後  $t$  時刻雨量

表 2 最佳融合權重

	二種資訊 融合	三種資訊 融合
$\theta_1$ (地面雨量站)	0.77	0.79
$\theta_2$ (QPESUMS)	0.23	0.14
$\theta_3$ (PERSIANN-CCS)		0.07

## 4. 建立石門集水區定量降雨預報模式

類神經網路經過了長時間的發展，已有許多不同的網路模型被提出，因此除了常被使用之倒傳遞類神經網路外，亦有學者選擇其他網路形式推估降雨量 (Luk *et al.*, 2001; Aksoy & Dahamsheh, 2009; Lin & Wu, 2009)，其中 Luk *et al.* (2001) 利用三種類神經網路，分別為多層前饋式類神經網路 (Multilayer Feedforward Networks, MLFN)、部分連結的類神經網路 (Partial Recurrent Neural Networks, PRNN) 及時間稽延的類神經網路 (Time-Delay Neural Networks, TDNN)，預報降雨量的空間分佈且應用於都市排水，結果顯示三種類神經網路在預報未來 1 小時之降雨量，只要網路架構良好且有足夠的訓練次數皆能得到不錯的結果。另亦有許多研

究指出調適性網路模糊推論系統具有處理高度非線性問題的能力，應用於雨量推估時優於傳統統計方法(陳正斌，2004; Talei *et al.* 2010)。

### 4.1 調適性網路模糊推論系統

近年來模糊推論系統與類神經網路常應用於實務界且有許多成功的案例。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。調適性網路模糊推論系統(Adaptive Network-based Fuzzy Inference System, ANFIS)(Zadeh, 1965, Jang, 1993)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、最佳化能力、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。

(Chiang *et al.*, 2010)

類神經網路雖無法處理定性的知識與邏輯推論過程，卻具有極佳的自我學習與組織能力，其強大的調整能力正可用來作模糊系統的結構與參數之調整，使合乎模糊推論系統中輸入、輸出間的關係。也就是說調適性網路模糊推論系統是用類神經網路的技術，由所獲取的資料中萃取出模糊規則，並利用新獲取的資料逐漸的調整這些規則。因此，ANFIS 結合了二種演算法，可充分發揮模式對於系統不確定性(uncertainty)與不精確性(imprecisely)的處理能力，透過 ANFIS 學習與自我調適進而求得參數最佳解。

調適性網路模糊推論系統之架構，如圖 8 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。本研究 ANFIS 模式建置係採用 MATLAB 之 ANN 模組進行計算。

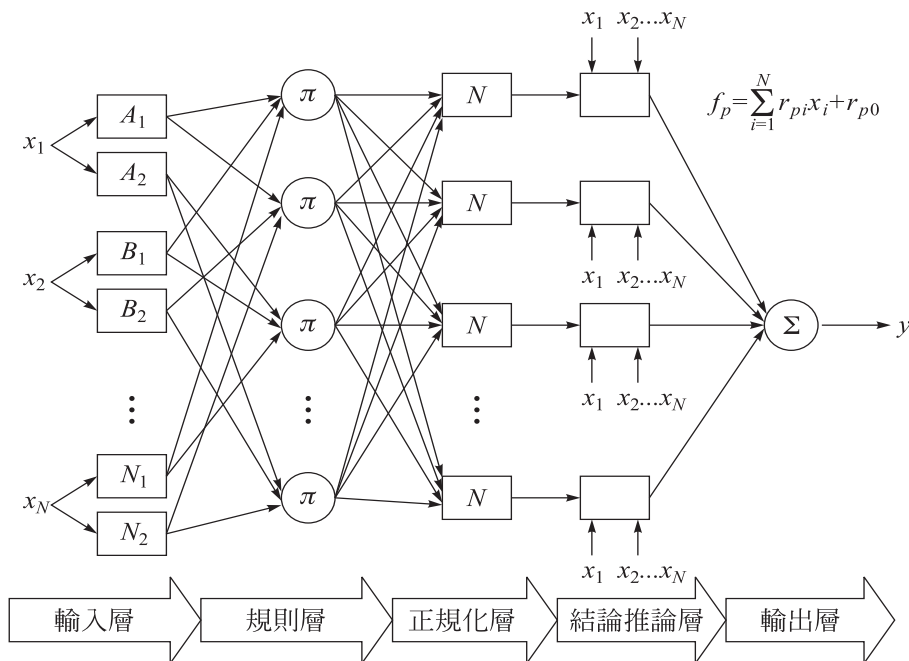


圖 8 ANFIS 架構圖(張斐章及張麗秋，2010)



### 第一層輸入層

將輸入變數映射至模糊集合，以設定之隸屬函數估算其隸屬度，在此隸屬函數以 S 型函數為例：

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) \quad \text{for } i = 1, 2 \\ O_{1,i} &= \mu_{B_{i-2}}(y) \quad \text{for } i = 3, 4 \\ \mu_{A_i} &= \frac{1}{1 + e^{-a_i(x-c_i)}}, \quad \mu_{B_{i-2}} = \frac{1}{1 + e^{-a_i(y-c_i)}} \end{aligned} \quad (5)$$

其中  $O_1$  為輸入值相對於模糊集合之隸屬函數， $\{a_i, c_i\}$  為模糊隸屬函數的參數，即前提項(premise)參數，當這些參數值改變，隸屬函數形式也會跟著改變。

### 第二層規則層

進行變數間模糊邏輯規則之先決條件配對，以得到各規則之 firing strength (即權重值)，再利用 T-norm 乘積運算，即輸出值為所有輸入訊息之乘積：

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), i=1,2 \quad (6)$$

### 第三層權重平均

此層各節點計算該規則相對於所有規則的 firing strength 之比例，也就是將第 i 條規則的輸出結果除以所有規則之輸出結果，使其輸出值介於 0 到 1 之間。

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2 \quad (7)$$

### 第四層結論推論層

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), i=1,2 \quad (8)$$

其中  $\{p_i, q_i, r_i\}$  為模糊推論之結論參數，即推論項(consequent)參數。

### 第五層輸出層

將前層訊息加總以計算輸出變數值，一如解模糊化之功能：

$$\text{輸出值} = O_{5,1} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (9)$$

## 4.2 模式評估指標

不同的評估指標可針對不同的颱風降雨預報模式判斷其優劣，因此本研究選用四個評比指標來評估三種模式(三種資訊(未融合)、二種資訊(融合)及三種資訊(融合))不同之輸入模型於颱風降雨預報模式之準確度與適用性，分別為 CC、RMSE、MAE 及 SS 四種，各指標定義如下：

(1) CC (Correlation Coefficient)：

$$CC = \frac{\sum_{t=1}^N [P_{pre}(t) - \bar{P}_{pre}(t)][P_{obs}(t) - \bar{P}_{obs}(t)]}{\sqrt{\sum_{t=1}^N [P_{pre}(t) - \bar{P}_{pre}(t)]^2} \sqrt{\sum_{t=1}^N [P_{obs}(t) - \bar{P}_{obs}(t)]^2}} \quad (10)$$

(10)式中 N 為資料筆數， $P_{pre}(t)$  為預報雨量， $P_{obs}(t)$  為實際觀測雨量， $\bar{P}_{obs}(t)$  為實際觀測雨量平均值， $\bar{P}_{pre}(t)$  為預報雨量平均值。

(2) RMSE (Root Mean Square Error)：

$$RMSE = \sqrt{\frac{\sum_{t=1}^N [P_{pre}(t) - P_{obs}(t)]^2}{N}} \quad (11)$$

(3) MAE (Mean Absolute Error)：

$$MAE = \frac{\sum_{i=1}^N |P_{pre}(i) - P_{obs}(i)|}{N} \quad (12)$$

(4) SS (Skill Score)：

SS 乃為計算不同預測成果間效能之優劣，通常選取一對照組與其他成果比較，因此 SS 又可以改善率代表。本研究以 SS 計算各模式於兩種不同條件下之評比，不同定量降雨預報模式間之改善率。

$$SS = \frac{E_m - E_n}{E_m} \times 100\% \quad (13)$$

(13)式中，下標 m 及 n 分別代表不同定量降雨預報模式，本研究共計算二種 SS，第一種組合為比較未融合的二種資訊(m)與融合的二種資訊(n)；第二種組合為比較融合的二種資訊(m)與融合的二種資訊(n)，當 SS 值大於 0 時，代表融合的二種資訊所建立之定量降雨預報模式優於其他模式，小於 0 時則反之。

### 4.3 定量降雨預報模式結果與討論

本研究於集水區定量降雨預報模式之建立上，將採用調適型類神經網路建構未來一小時之預報模型，為比較資料融合之有效性與否，本研究將架構三種不同定量降雨預報模式，第一種模式使用雷達(QPESUMS)、衛星(PERSIANN-CCS)及雨量站三種資訊未經融合作為 ANFIS 之網路輸入項，為一多輸入-單輸出之定量降雨預報模式；第二種模式僅使用雷達(QPESUMS)及雨量站資訊，將其二項資訊融合後作為 ANFIS 之網路輸入項，為一單輸入-單輸出模式；第三種模式為使用雷達(QPESUMS)、衛星(PERSIANN-CCS)及雨量站資訊，將其三項資訊融合後作為 ANFIS 之網路輸入項，亦為一單輸入-單輸出模式，其詳細網路架構圖如圖 9 所示。

ANFIS 定量降雨模式架構前需將資料區分為訓練、驗證及測試 3 個部份，故本研究將西元 2006~2009 年共 13 場颱風事件，區分為訓練部份

包含 7 場颱風事件，資料筆數為 350 筆；驗證部份包含 3 場颱風事件，資料筆數共 153 筆；測試部份包含 3 場颱風事件，資料筆數共 138 筆。

表 3 為三種定量降雨預報模式於 t+1 時刻預報雨量之結果，由表 3 可知在 t+1 時刻三種資訊未融合的預測雨量 CC、RMSE 及 MAE 之表現都不如三種資訊融合後的預測雨量，在模式中以融合了三種雨量資訊的定量降雨模式表現最佳，模式測試部分相關係數、RMSE 及 MAE 分別為 0.88、3.88 及 2.39；融合了二種雨量資訊的定量降雨模式表現次之；三種資訊未融合表現最差。而從表 4 亦可得知 QPESUMS、PERSIANN-CCS 及地面雨量站三種資訊融合後與三種資訊未融合之 RMSE 及 MAE 改善率分別為 28.23% 及 27.24%，由此可證明 QPESUMS、PERSIANN-CCS 及地面雨量站經融合成一融合雨量有其有效性。而在融合二種資訊與融合三種資訊於預測 t+1 時刻雨量之比較，由表 4 可知增加 PERSIANN-CCS 雨量產品於定量降雨預報模式中，模式改善並不顯著，然而就其 RMSE 及 MAE 改善率於模式仍然分別有 5.80% 及 6.20%。

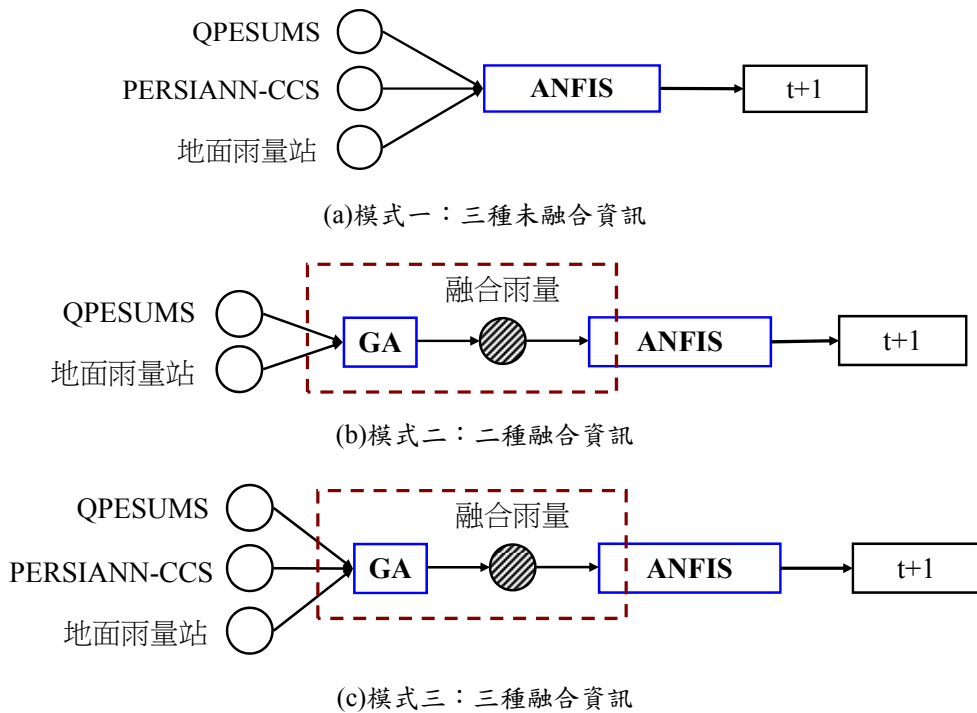



圖 9 (a)-(c)類神經網路定量降雨預報架構圖

表 3 模式結果比較表

	三種未融合資訊			二種融合資訊			三種融合資訊		
	訓練	驗證	測試	訓練	驗證	測試	訓練	驗證	測試
CC	0.85	0.80	0.71	0.88	0.86	0.83	0.88	0.85	0.85
RMSE	4.33	4.12	4.70	3.88	3.32	3.58	3.88	3.52	3.37
MAE	2.65	2.56	3.07	2.35	1.96	2.38	2.39	2.00	2.23


表 4 測試部分不同模式間之改善率

	t+1	
	SS(未融合-融合)	SS(二種-三種)
RMSE	28.23%	5.80%
MAE	27.24%	6.20%




t+1 時刻

圖 10 三種未融合資訊時序圖



t+1 時刻

圖 11 二種融合資訊時序圖



t+1 時刻

圖 12 三種融合資訊時序圖

## 5. 結論

近年來遙測技術之發展提供集水區降雨於空間之分佈，其主要優點在於有效觀察大範圍降雨在時空之變化，對定量降雨估計而言，遙測影像資訊可提供比地面雨量站更寬廣的訊息。因此，本研究蒐集 QPESUMS 系統提供之雷達雨量產品、PERSIANN-CCS 衛星觀測系統提供之雨量產品以及集水區地面之雨量觀測紀錄，首先以遺傳演算法融合地面雨量、雷達及衛星影像推估雨量三種資訊，其中二種資訊之融合雨量與三種資訊之融合雨量，經由 GA 進行最佳融合權重搜尋，其融合雨量即 t 時刻之推估雨量與實際降雨量相當接近，相關係數高達 0.99。本研究再以 ANFIS 架構定量降雨預報模式，預測未來一小時，在三種定量降雨預報模式中，以融合了三種雨量資訊的定量降雨模式表現最佳；融合了二種雨量資訊的定量降雨模式表現次之；三種資訊未融合的定量降雨模式表現最差，故可證明融合雨量分別擷取 QPESUMS 之高解析度、易探測降雨分布狀況及 PERSIANN-CCS 不受地形影響之優點，應用於定量降雨預報有最佳之表現。

## 致謝

本文感謝經濟部水利署(MOEAWRA0990040)及國家科學委員(Grand No. 100-2313-B-002-011-MY3)資料及經費提供，使本研究得以順利進行完成。

## 參考文獻

王琮美，2005，「降雨條件與集水區出流量關係之探討」，國立中央大學土木工程研究所碩士論文。

江衍銘及張斐章，2006，以遙測資訊建立類神經網路雲分類系統於雨量推估及洪水預測，中國農業工程學報 52(4): 39-47。

宋仁良，2004，「基隆河上游集水區地表特性與降雨逕流之關係研究」，中國文化大學地學研究所碩士論文。

何宜樺，2009，建構集水區多時刻降雨-逕流機制與類神經網路洪水預報模式，臺灣大學生物環境系統工程學研究所碩士論文。

陳正斌，2004，「應用模糊理論於颱風降雨量之推估」，成功大學水利及海洋工程研究所碩士論文。

張斐章及張麗秋，2010，類神經網路導論原理與應用，滄海書局。

Aksoy, H. & Dahamsheh, A., 2009. Artificial neural network models for forecasting monthly precipitation in Jordan, *Stochastic Environmental Research and Risk Assessment*, 23(7): 917-931.

Chang, F.J., Chang, L.C. and Huang, H.L., 2002. Real-time recurrent learning neural network for stream-flow forecasting. *Hydrological Processes*, 16(13): 2577-2588.

Chang, K.T., Chiang, S.H., and Lei, F., 2008. Analysing the relationship between typhoon-triggered landslides and critical rainfall conditions, *Earth Surface Processes and Landforms*, 33: 1261-1271.

Chen, C.Y., Lin, L.Y., Yu, F.C., Lee, C.S., Tseng, C.C., Wang, A.H., and Cheung, K.W., 2007. Improving debris flow monitoring in Taiwan by using high-resolution rainfall products from QPESUMS, *Natural Hazards*, 40: 447-461.

Chiang Y.M. & Chang F.J., 2009. Integrating hydrometeorological information for rainfall-runoff modeling by artificial neural networks. *Hydrological Processes*, 23(11):1650-1659.

Chiang YM, Hsu KL, Chang FJ, Hong Y, Sorooshian S. 2007. Merging multiple precipitation sources for flash flood forecasting. *Journal of Hydrology* 340: 183-196.

Chiang, Y.M, Chang, L.C, Tsai, M.J., Wang, Y.F, and Chang, F.J., 2010. Dynamic Neural Networks for Real-Time Water Level Predictions of Sewerage Systems-covering gauged and unguaged sites, *Hydrology and Earth System Sciences*, 14:1309-1319.

Hong, Y., Hsu, K.L., Sorooshian, S. and Gao, X.G., 2004. Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system. *Journal of Applied Meteorology*, 43(12): 1834-185

Hsu, K.L., Gao, X., Sorooshian, S., and Gupta, H.V., 1997. Precipitation estimation from remotely sensed information using artificial neural networks. *Journal of Applied Meteorology*, 36:1176-1190.



- Jang J.S.R., 1993. ANFIS: Adaptive Network-based Fuzzy Inference System. *IEEE Transactions on System, Man, and Cybernetics*. 23(3):665-685.
- Lin, G. F. & Wu, M. C., 2009. A hybrid neural network model for typhoon-rainfall forecasting, 375(3-4): 450-468.
- Luk, Kin C., Ball, J.E., Sharma, A., 2001. An application of artificial neural networks for rainfall forecasting, *neural networks*, 33(6-7):683-693.
- Pan, T.Y. & Wang, R.Y., 2004. State space neural networks for short term rainfall-runoff forecasting. *Journal of Hydrology*, 297: 34-50.
- Talei, A., Chua, L. H. C., Wong, T. S. W., 2010. Evaluation of rainfall and discharge inputs used by Adaptive Network-based Fuzzy Inference Systems (ANFIS) in rainfall-runoff modeling, *Journal of Hydrology*, 391(3-4): 248-262.
- Xin L, Reuter G, Larochelle B. 1997. Reflectivity–rain rate relationships for convective rainshowers in Edmonton. *Atmosphere–Ocean* 35:513–521
- Zadeh L.A., 1965. Fuzzy Sets. *Information and Control*. 8:338-353.

# Integrating Multiple Information for Precipitation Estimating in Mountainous Area

Fi-John Chang <sup>1\*</sup> Meng-Jung Tsai <sup>2</sup> Yen-Ming Chiang <sup>3</sup> Ming-Chang Shieh <sup>4</sup>

## ABSTRACT

Simulation of extreme rainfall-runoff events is the key issue for flood mitigation. The accuracy of flood forecasting driven by models is usually dependent on whether the upstream precipitation information is sufficient or not. In the past, such information was provided by ground measurements. The development of remotely sensed technology enables researchers to realize the spatial distribution of rainfall. Remote sensing data provide more useful information than ground measurements. The GA was applied to merging different precipitation products through various input combinations. Finally, the ANFIS was conducted to build three quantitative precipitation forecast models by feeding different input combinations, which are 1) three precipitation products, 2) merged precipitation generated by QPESUMS and ground measurements, and 3) merged precipitation generated by PERSIANN-CCS, QPESUMS and ground measurements, respectively. The improvement rate of model 3) over model 1) for quantitative precipitation forecast is 28% at t+1. The results show the model merging ground measurements, QPESUMS and PERSIANN-CCS produced the best precision for quantitative precipitation forecast.

**Keywords:** data integration, artificial neural network, quantitative precipitation forecasting

---

<sup>1</sup> Professor, Dept. Bioenvironmental Systems Engineering, National Taiwan University

<sup>2</sup> PhD Candidate, Dept. Bioenvironmental Systems Engineering, National Taiwan University

<sup>3</sup> Post-doctoral Researcher, Dept. Bioenvironmental Systems Engineering, National Taiwan University

<sup>4</sup> Head, Water Hazard Mitigation Center, Water Resources Agency, Ministry of Economic Affairs

\*Corresponding Author, Phone: 886- 2-33663452, E-mail : changfj@ntu.edu.tw

Received Date: Jun. 14, 2012

Revised Date: Jan. 03, 2013

Accepted Date: Jan. 18, 2013