

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

Precipitation Estimation and Flood Forecasting from Remotely Sensed Information using an Artificial Neural Network Cloud Classification System

國立台灣大學生物環境系統工程學系
博士班研究生

江 沂 銘

Yen-Ming Chiang

國立台灣大學生物環境系統工程學系
教授

張 斐 章*

Fi-John Chang

摘 要

洪水預報之精確性取決於上游集水區之雨量資訊是否充足，以往此項訊息皆由地面雨量站觀測所提供，然近十年來，各種遙測影像資訊已相繼應用於降雨之推估，其中氣象衛星影像資料之發展進一步掌握集水區降雨於空間之分佈，其主要優點在於能有效觀察大範圍降雨在時空之變化，故對定量降雨估計而言，衛星影像資訊在某些層面上能提供比地面雨量站更有力的訊息。因此，本研究首先應用美國水文氣象及遙測中心所建立之 PERSIANN-CCS 系統，藉由衛星影像資訊以推估颱風時期基隆河流域之即時雨量，推估之成果除與雨量站記錄做評比外，並分別架構流量預測模式以評估其優劣，此外，本文更提出一四層架構之回饋式類神經網路，藉由雨量站之觀測與 PERSIANN-CCS 系統所推估之雨量運用融合方法以獲得雨量融合產品，同時亦就融合雨量之參數及其對流量預測之改善進行探討。

關鍵詞：衛星影像，流量預測，回饋式類神經網路，融合雨量。

ABSTRACT

The accuracy of flood forecasting is based on whether the upstream rainfall data is sufficient or not and this information is usually provided by ground rain gauges. Various remotely sensed data have been applied to precipitation estimation over last decade. The development of meteorological satellite sensor further helps to capture the large scale of rainfall distribution. One of the major advantages of satellite imagery is to efficiently detect the temporal and spatial variations of precipitation. As far as quantitative

*通訊作者，國立台灣大學生物環境系統工程系教授，106 台北市大安區羅斯福路 4 段 1 號，changfj@ntu.edu.tw

precipitation estimation is concerned, the satellite imagery provides more useful information than ground-based gauges. Therefore, the PERSIANN-CCS built by Center for Hydrometeorology and Remote Sensing (CHRS), UC Irvine, is introduced and used to generate the real-time precipitation over Kee-Lung River during typhoon periods. A comparison of the observed and estimated precipitation and the forecasted hydrologic responses is evaluated. Besides, a four-layer recurrent neural network is developed to produce the merged rainfall products and flood forecasting. Finally, detailed discussions on the merging parameters and the improvement of flood forecasting are given.

Keywords: Satellite imagery, Flood forecasting, Recurrent neural network, Merged precipitation.

一、前言

近年來，遙測影像資訊如氣象雷達及衛星影像等已廣泛應用於許多不同領域，其中，氣象衛星對大尺度的水氣分布與推估或天氣預報而言，是較有效率的觀測工具，具有快速掌握全區域資料之能力，除可測得大氣現象之空間與時間的連續性變化外，亦不受天氣狀況與地理環境之限制而持續觀測。目前的氣象衛星依軌道不同，可分為地球同步衛星(Geostationary Operational Environmental Satellites: GOES)和繞極軌道衛星兩類。而 GOES 因可持續不斷的在一定點上進行觀測，因此在降雨的推估上可提供許多有用之資訊。

國內對於氣象衛星影像資訊之應用已日漸普及並常見於各種大氣現象之研究，其中對於長期氣候、天氣及水氣之推估與預報在精確度上有一定之提昇。相關之研究有劉等(1992)應用同步氣象衛星估算台灣地區之對流降雨，為國內早期利用同步衛星資料於降雨估計之先驅。王(2001)應用衛星資料探討台灣地區降雨雲之特性與降雨量間之關係。衛、鄭(2002)利用 GMS-5 同步氣象衛星的紅外光頻道資料與相對應地面測站之雨量紀錄，探討兩者在不同時空尺度之相關性。李等(2005)以衛星資料針對夏季午後對流潛勢環境做初步之分析。郭等(2005)應用 AVHRR 以及 MODIS 衛星影像資料估算潛勢蒸發散量之比較。

國外對於應用衛星影像資訊進行雨量之推估在近十年來已有許多不同之發展，其中，Kidd et al., (2003)發展結合紅外光以及微波影像之演算方法，於非洲地區進行雨量推估；此外，亦有諸多以類神經網路為主要方法於雨量之估算，例如：Bellerby et al., (2000)應用四層前向式網路藉由微波雷達與 GOES 影像資料之輔助以模擬雨量；Grimes, et al., 於非洲甘比亞地區建立一結合數值預報模式輸出與衛星影像資訊之類神經網路雨量推估模式(2003)。

台灣地區之降雨受地形、季節以及降雨系統之影響而有顯著之差異，故發展區域性之定量降雨估計為相當重要的課題。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，而衛星影像資訊可有效提供大範圍且即時的降雨發展及雨量在空間中之分佈情形，比傳統地面雨量站提供了更多有力的訊息。因此，本研究擬利用 PERSIANN-CCS (Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks-Cloud Classification System)系統以推估基隆河流域之雨量，推估之成果除與雨量站記錄做評比外，並以各雨量資訊分別架構流量預測，以評估其優劣，此外，本文更提出一四層架構之回饋式類神經網路，藉由將雨量站之觀測與系統所推估之雨量運用融合(merge)方式以獲得雨量融合產品，同時亦就融合雨量之參數及其對流量預測之改善進行探討。

二、PERSIANN 系統之簡介

在諸多以類神經網路為主要理論方法，並藉由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，其後再由其研究團隊提出改良之 PERSIANN-CCS (PERSIANN Cloud Classification System)系統(Hong et al., 2004)，目前兩者皆在 NASA 的贊助下發展出精確且穩定的降雨產品，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但不包含北緯 60°以北及南緯 60°以南的極區地帶(如圖 1 所示)；而 PERSIANN-CCS 模式之空間解析度雖提高為 4km×4km，但模式之輸出範圍目前僅止於北美地區，兩者皆可不斷地提供每小時之即時降雨推估。以下便針對此二系統之理論架構做一簡單之介紹。

PERSIANN 系統之主要理論架構為一三層之修正型反傳遞類神經網路(MCPN: Modified Counter Propagation Network)，其中包含兩個網路結構(如圖 2 所示)；第一個網路結構為自組織映射圖(SOM)網路，主要負責處理輸入層至隱藏層間之轉換及分類。第二個網路結構為修正型之 Grossberg 線性輸出層，其功能乃是將 SOM 網路分類之結果映射至輸出空間，方法乃是建構許多不同之雲頂亮帶溫度(T_b)與降雨強度(R)間之線性關係。至於輸入資料的部份，PERSIANN 利用目前於全球作業的五顆同步衛星，以獲得涵蓋全球的影像資料(紅外光波段)，模式所使用之輸入維度為 6 維，分別是：每一個 pixel 亮帶溫度(T^b_1)、地貌指標(SURF)、3×3 pixel 的平均亮帶溫度(T^b_3)、5×5 pixel 的平均亮帶溫度(T^b_5)、3×3 pixel 的標準偏差(SDT^b_3)以及 5×5 pixel 的標準偏差(SDT^b_5)。

PERSIANN-CCS 系統基本上仍是以 PERSIANN 為主，其不僅保留了 PERSIANN 的優點，更在架構上與影像前處理之步驟有所改




圖 1 PERSIANN 系統於線上即時推估全球水氣分布圖(<http://hydis8.eng.uci.edu/hydis-unesco/>)





圖 2 PERSIANN 系統之網路架構圖



雲影像切割 特徵萃取 雲塊分類 降雨量推估
圖 3 PERSIANN-CCS 系統之網路架構圖

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。其模式步驟大致可區分為四點(如圖 3 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。以下分別對每一步驟做概略之解說。

雲影像的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，PERSIANN-CCS 系統則應用一增溫門檻值(incremental temperature threshold: ITT)藉由逐漸

增加溫度的方式對雲塊進行切割；**雲塊特徵之萃取**亦即是對模式輸入變數之挑選，選擇之策略有三類-分別為雲塊冷特徵(coldness feature)、幾何特徵(geometric feature)以及組織特徵(texture feature)，共萃取出九項雲塊特徵，在冷特徵上選取個別雲塊溫度之最低值及平均值(T_{min} & T_{mean})，在幾何特徵上選取雲塊面積(AREA)及雲塊形狀指標(SI)，而在組織特徵上則是選取雲頂溫度之標準偏差(STD)、局部(5×5 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(STD⁵_{std})、雲頂溫度之梯度(TOPG)、灰階組織(ASMm)；**雲塊之分類**基本上乃是藉由 SOM 網路將所萃取出來之輸入變數，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；**降雨量之推估**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，以期能獲得較佳之雨量推估。

而上述兩模式其輸出資料來源的選擇，乃是以七顆繞極軌道衛星上所接收之 PR (Precipitation Radar)影像及所收集之地面雨量站資料所組成。基本上，模式乃是採用批次學習的方式進行訓練，與其他網路最主要之差別則在於 MCPN 模式具有分別訓練此二組架構(SOM & Grossberg Layer)之特徵，在 SOM 層中演算之方法是屬於非監督式學習而 Grossberg 層則是屬於監督式的學習策略(張斐章、張麗秋，2005)。

三、PERSIANN-CCS 系統之應用-以基隆河流域為例

3.1 研究區域與資料選取

本研究選擇基隆河流域上游五堵集水區為主要研究區域，其面積約為 204 平方公里，由於集水區內地形較高，故颱風時期洪水往往於短時間內抵達中下游，而引發一連串的災情發生，例如 2001 年納莉颱風帶來破紀錄的雨量因而導致水淹台北，因此精確的雨量估計乃至流量預測在洪災預警上扮演相當重要的角色。在地面測站資料上，本研究採用五堵集水區內一個水位(五堵




圖 4 應用衛星影像資訊推估台灣地區之雨量分布圖

-S1)流量站與兩個(瑞芳-R2 以及火燒寮-R3)雨量站之時資料，共收集 2004 年 6 場侵台的颱風事件為樣本，其中 4 場為流量預測模式訓練之用，而其餘 2 場則用以評估模式之精確性，而在雨量資料的處理上，為要使其與衛星影像所繁衍之雨量有相同之格式，並易於模式輸入使用，因此進一步計算以獲得集水區內之面積平均雨量(P_g)。至於應用衛星影像所估算之雨量便藉由 PERSIANN-CCS 系統來繁衍，如上所述，PERSIANN-CCS 系統提供的雨量產品為空間解析度 4 公里、時間解析度 1 小時之模式估計值，然因此系統目前尚未推廣至全球性的涵蓋，因此，本研究利用模式中已訓練好之參數套配至台灣地區，以推估所需之雨量資料(如圖 4 所示)。而圖 5 則為研究區域與測站以及 PERSIANN-CCS 系統輸出網格點之空間相對位置，而粗線條內之網格點為最後所選取之影像資料，共計 15 個網格點，相對地，將此 15 個網格點資料計算後以獲得集水區內之面積平均雨量(P_s)。除上述兩雨量資源外，本研究更進一步使用融合(merge)的方法來合成 P_g 與 P_s 兩種面積平均雨量資訊，以獲得雨量融合產品(P_m)，並測試融合後的雨量產品能否提供流量預測更多有效的訊息。

3.2 理論概述

(a) 雨量融合方法

在雨量融合的過程中，因無法有效得知各雨

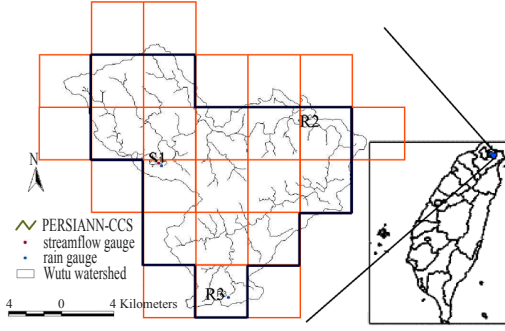


圖 5 研究區域與測站以及 PERSIANN-CCS 網格點之空間相對位置

量來源(P_g 和 P_s)是否存在著觀測上或推估上之誤差，故本研究考慮兩種情況，分別為有誤差存在及無誤差存在，詳細的融合過程則分別敘述如下

假設 P_g 和 P_s 是無誤差存在，則針對每一時刻之融合雨量(P_{m1})計算如下

$$P_{m1}(t) = P_g(t) \times \theta + P_s(t) \times (1 - \theta)$$

其中 θ 代表 P_g 在融合過程中之融合權重，其值介於[0 1]之間；而 $P_{m1}(t)$ 代表未經過誤差調整之融合雨量。

若 P_g 和 P_s 是有誤差存在的情況，則使用一比例誤差原則調整各雨量來源存在之誤差，故每一時刻之融合雨量(P_{m2})計算如下

$$P_{m2}(t) = (1 - \alpha_1)P_g(t) \times \theta + (1 - \alpha_2)P_s(t) \times (1 - \theta)$$

其中 θ 同樣代表 P_g 在融合過程中之融合權重； α_1 與 α_2 代表比例誤差係數，其值介於[-1 1]之間；而 $P_{m2}(t)$ 代表經過誤差調整後所融合之雨量。

(b) 回饋式類神經網路

本研究共使用四種雨量資訊(P_g 、 P_s 、 P_{m1} 以及 P_{m2})分別架構五堵集水區之降雨-逕流模式，並探討不同雨量輸入訊息於流量預測之優劣，針對前二者，本研究應用三層之回饋式類神經網路建立兩組單輸入(P_g 或 P_s)-單輸出($Q'(t+1)$)模式(RNN_g 與 RNN_s)。其次，為使融合與流量預測程序合併於同一模式，本研究提出一四層架構之回饋式類神經網路(如圖 6 所示)，包含輸入層、融合層、隱藏層以及輸出層，其中網路於隱藏及輸出兩層各有一時間延遲之回饋鍵結，同樣地，亦




圖 6 四層回饋式類神經網路架構圖

有兩組雙輸入-單輸出模式(RNN_{m1} 與 RNN_{m2})建立於不同情況下，當輸入為無誤差假設時， $X_1(t)$ 和 $X_2(t)$ 分別代表 $P_g(t)$ 和 $P_s(t)$ ；反之，若輸入為有誤差假設時， $X_1(t)$ 和 $X_2(t)$ 則分別代表 $P_g(t)(1 - \alpha_1)$ 和 $P_s(t)(1 - \alpha_2)$ 。

針對回饋式類神經網路之學習演算法，基本上皆屬梯度搜尋方法(Chang et al., 2002; Pan & Wang, 2004)，故本研究亦使用最陡坡降法為網路之訓練方法，並藉由優選目標函數的過程以調整網路之參數，而演算之方法則概述如下：

網路隱藏層神經元 J 之輸出可由下式計算獲得

$$y_J(t) = f \left(\sum_{i=1}^I w_{Ji} P_i(t) + \sum_{j=1}^J w_{Jj} y_j(t-1) \right)$$

其中， $y_J(t)$ 為隱藏層神經元 J 於時間 t 之輸出； $f(\cdot)$ 為隱藏層之非線性轉換函數； w_{Ji} 為輸入層神經元 i 至隱藏層神經元 J 之連結權重； $P_i(t)$ 為模式輸入值； w_{Jj} 則為隱藏層內時間延遲之回饋鍵結。而網路輸出層神經元 K 之輸出可由下式計算

$$Q'_K(t+1) = f \left(\sum_{j=1}^J w_{Kj} y_j(t) + \sum_{k=1}^K w_{Kk} Q'_K(t) \right)$$

其中， w_{Kj} 為隱藏層神經元 j 至輸出層神經元 K 之連結權重； w_{Kk} 為輸出層內時間延遲之回饋鍵結。

針對各層間之權重 W 其每次之更新可由目標函數 E_{total} 對權重 W 的偏微分推導

$$W_{new} = W_{old} - \eta \frac{\partial E_{total}}{\partial W}$$

其中， η 表示學習速率；而目標函數則如下所示

$$E_{total} = \sum_{t=1}^N E(t) = \frac{1}{2} \sum_{t=1}^N \sum_{k=1}^K [Q_k(t) - Q'_k(t)]^2$$

其中, $Q_k(t)$ 代表神經元 k 在時間 t 之目標輸出值; $Q'_k(t)$ 代表神經元 k 在時間 t 之目標輸出值。

詳細之演算方法可參考相關文獻(Ham and Kostanic, 2001; Haykin, 1999)。而模式融合過程中所需決定之三個參數(θ 、 α_1 、 α_2)因不受任何特定之方法所限制,故本研究選擇以直接搜尋法來進行全域搜尋,亦即搜尋其整個參數空間,過程雖然較為耗時,但一般皆能達到令人滿意的成果。至於網路隱藏層神經元的個數為3個,乃是藉由試誤法以決定。

四、結果與討論

為有效評估 PERSIANN-CCS 系統推估能力並比較不同雨量輸入資訊於模式預測之精確性,本研究選擇數個不同的指標,依不同的統計特性對模式之雨量估計與流量預測成果進行探討,首先,應用一誤差百分率(percentage bias: bias)指標評估 PERSIANN-CCS 系統在雨量估計上量的精確性,而流量預測的成果則以平均絕對誤差(mean absolute error: MAE)、均方根誤差(root mean square error: RMSE)、相關係數(correlation coefficient: CC)以及效率係數(coefficient of efficiency: CE)評估模式的穩定性與正確性。上述各指標分別定義如下

$$bias = \frac{\sum_{i=1}^N \hat{P}(i) - \sum_{i=1}^N P(i)}{\sum_{i=1}^N P(i)}$$

$$MAE = \frac{\sum_{i=1}^N |(Q'(i) - Q(i))|}{N}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q'(i) - Q(i))^2}{N}}$$

$$CC = \frac{\sum_{i=1}^N (Q(i) - \bar{Q})(Q'(i) - \bar{Q}')} {\sqrt{\sum_{i=1}^N (Q(i) - \bar{Q})^2 \sum_{i=1}^N (Q'(i) - \bar{Q}')^2}}$$

表 1 地面觀測與 PERSIANN-CCS 系統推估各颱風事件之累積雨量比較表

	事件 1	事件 2	事件 3	事件 4	事件 5	事件 6
P_g (mm)	169	145	379	511	479	332
P_s (mm)	65	229	111	400	130	153
Percent Bias	-61%	58%	-71%	-22%	-73%	-54%




圖 7 雨量測站與 PERSIANN-CCS 系統推估之面積平均雨量及其誤差序列

$$CE = 1 - \frac{\sum_{i=1}^N (Q(i) - Q'(i))^2}{\sum_{i=1}^N (Q(i) - \bar{Q})^2}$$

其中, \hat{P} 與 P 分別表示估計與觀測之雨量 (mm/hr); Q' 與 Q 分別代表預測與觀測之流量 (cms); \bar{Q} 與 \bar{Q}' 則分別代表觀測與預測之平均流量 (cms)。

(a) 雨量推估與流量預測成果

表 1 比較地面觀測雨量與 PERSIANN-CCS 系統推估各颱風事件之累積雨量以及相關之推估誤差百分率,除了事件 2 高估雨量外,其餘各事件皆有程度不一的低估(-73% ~ -22%),嚴格來說, PERSIANN-CCS 系統所推估之雨量並非單精確,其原因有二,其一是模式選用的參數乃建立自北美地區之暴雨事件,其天氣型態與降雨機制略有不同,其二則是無法有效證實地面所觀測之雨量正確無誤,本文後段將對此做一探討。而 PERSIANN-CCS 系統所估計之雨量序列如圖 7 所示,分別顯示地面雨量站觀測紀錄、

表 2 四種雨量資訊於流量預測之統計成果表

	測試階段			
	RMSE	CC	CE	MAE
RNN _g	117.7	0.91	0.81	70.5
RNN _s	154.7	0.82	0.66	83.9
RNN _{m1}	111.1	0.92	0.83	54.7
RNN _{m2}	98.0	0.95	0.87	67.8

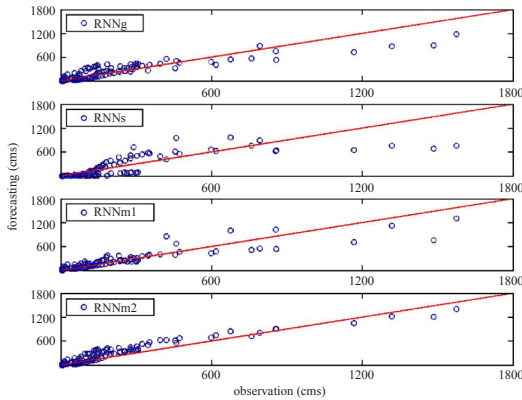


圖 8 四種類神經網路模式預測流量之散佈圖

PERSIANN-CCS 估計之雨量以及其誤差。基本上，系統之輸出在雨量之趨勢與尖峰暴雨值上尚能有效地推計，但在各降雨事件的初始時段有些微低估。

表 2 概括四種雨量產品架構回饋式類神經網路於流量預測之評估指標，基本上各模式皆有相當穩定的推估，測試階段之成果顯示，RNN_s 其精確性相對的偏低。其他三模式之成果以 RNN_g 為例，模式預測之相關係數為 0.91、RMSE 值為 117.7，RNN_{m1} 的 CC 值為 0.92、RMSE 為 111.1，而 RNN_{m2} 的 CC 值為 0.95、RMSE 為 98.0，這樣的結果驗證模式的輸入訊息以融合之雨量產品優於地面雨量之觀測，其中又以經過誤差調整後之雨量產品 (P_{m2}) 有最佳之預測且能有效降低預測之誤差。圖 8 為四種類神經網路模式其預測流量與觀測流量之散佈圖。由圖中可知，若是以地面雨量資訊來模擬流量時，並無法有效預測洪峰流量，其低估量約為 400 cms，若以 P_{m1} 為輸入其低估量約為 300 cms，若以 P_{m2} 為輸入時則其低估量減低至 100 cms。

表 3 各雨量融合參數及其提昇流量預測之改善率

	誤差調整	α_1	α_2	1- θ	RMSE	改善率
融合雨量	無 (P_{m1})	-	-	0.15	111.1	6%
	有 (P_{m2})	-0.11	0.54	0.15	98.0	17%

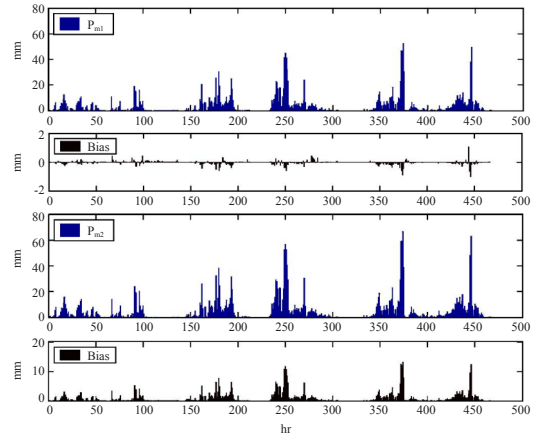


圖 9 兩融合雨量及其與觀測雨量間相對應之誤差序列圖

(b) 融合雨量參數之探討及其對流量預測之改善

本小節分別對地面雨量站及 PERSIANN-CCS 推估之雨量兩者於雨量融合過程所提供之貢獻進行探討，並就兩融合雨量提昇流量預測之精確性及相對應之改善率做一分析，首先透過表 3 可清楚得知，在無誤差調整的雨量融合過程中， P_g 提供 85% 的貢獻而 P_s 亦有 15% 的貢獻，而 P_{m1} 對於流量預測之改善率約為 6%，附帶說明此一改善率之計算乃是藉由模式 (RNN_{m1}) 預測之 RMSE 差值與 RNN_g 之 RMSE 值對比 (比值) 而獲得；在經過誤差調整的雨量融合過程中， P_g 與 P_s 提供的貢獻雖與無誤差調整程序相同，但模式經過誤差調整後，對於流量預測之改善率則大幅提昇至 17%，且由比例誤差係數 (α_1 與 α_2) 可知，不論是 P_g 或是 P_s 皆有推估上的誤差存在。圖 9 比較兩融合雨量之異同及各自與觀測雨量間相對應之誤差，圖上可清楚發現 P_{m1} 與 P_g 序列之誤差皆介於 ± 2 mm 之間，顯示兩序列之形式與大小幾乎相同，亦因如此 P_{m1} 序列所提供之改善率僅有 6%；值得注意的是 P_{m2} 序列雖然在形式及趨

勢上亦與 P_{m1} 序列相似，但在量上的差異卻相對較大，比較 P_{m2} 與 P_g 序列之誤差可發現，其差值皆大於 0 以上，又因 P_{m2} 序列比 P_g 序列在流量預測上提昇 17% 的改善率，綜合上述兩點可推斷，地面雨量站在接收雨量紀錄時或許因某些外在之因素而導致些微的低估。

五、結 論

本研究引進 PERSIANN-CCS 系統藉由其處理衛星影像資訊之能力以推估基隆河流域上游之即時雨量，並提出一四層架構之回饋式類神經網路以融合地面觀測與模式估算之雨量，進而建立精確之流量預測模式。此外亦評估四種不同之雨量資訊對模式輸出所產生之影響及貢獻，由研究結果可得下述之結論。

1. 本文提出之四層回饋式類神經網路可同時進行雨量融合及流量預測兩步驟，在操作上為一簡便且精確性高之方法，且融合層之參數與網路權重可分別進行優選，有效地降低模式複雜度，提供未來架構降雨-逕流模式另一選擇。
2. 模式融合之雨量資訊可從不同之雨量來源收截長補短之效，因雨量站資料雖精確但空間代表性差，而衛星影像之雨量推估雖空間代表性較高但精確低。此外，無論是有無誤差調整程序，PERSIANN-CCS 所推估之雨量在融合過程中皆有 15% 之貢獻，結果亦證實融合雨量確實能幫助提昇流量預測之精確性，相較於地面觀測雨量其改善率分別為 6% 與 17%。
3. 在誤差調整過程中亦可得知無論是地面雨量觀測或衛星影像之推估皆存在著觀測/推估上之誤差，其中地面雨量站之觀測有著 11% 之低估，而衛星影像之推估則有高達 54% 之偏差。研究之成果顯示，雨量融合方法不僅在獲得精確的雨量資訊上有其重要性外，對於流量預測精確性之提升亦有相當程度之改善。此外亦間接證實地面雨量站在接收雨量紀錄時因某些因素而導致其在觀測上些微的低估。

謝 誌

本研究承蒙國科會千里馬專案(NSC 094-2917-I-002-017)經費之補助以及美國加州大學爾灣分校 Soroosh Sorooshian 教授、徐國麟教授及其研究團隊於 PERSIANN-CCS 系統之架構與資料蒐集上提供諸多之協助始得以完成，特此致謝。

參考文獻

- 王光華，2001，「由衛星資料探討台灣地區降雨雲特性與降雨量關係」，大氣科學，第 29 卷，第 2 期，109-124 頁。
- 李紀恩，劉崇治，趙俊傑，葉南慶，2005，「衛星資料在夏季午後對流潛勢環境之初步析」，大氣科學，第 33 卷，第 3 期，189-214 頁。
- 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，第 53 卷，第 4 期，13-24 頁。
- 劉振榮、呂貴寶、徐天佑，1992，「應用同步衛星資料估算台灣地區對流降雨」，大氣科學，第 20 卷，第 3 期，233-265 頁。
- 衛強、鄭克聲，2002，「時空尺度對應用氣象衛星影像推估降雨量之影響」，台灣水利，第 50 卷，第 2 期，36-45 頁。
- 張斐章、張麗秋，2005，"類神經網路"，東華書局。
- Bellerby, T., M. Todd, D. Kniveton, and C. Kidd, 2000. Rainfall estimation from a combination of TRMM precipitation radar and GOES multispectral satellite imagery through the use of an artificial neural network. *Journal of Applied Meteorology*, 39: 2115-2128.
- Chang F. J., L. C. Chang, and H. L. Huang, 2002. Real time recurrent learning neural network for streamflow forecasting. *Hydrological Processes*, 16: 2577-2588.
- Grimes, D.I.F., E. Coppola, M. Verdecchia, and G.

- Visconti, 2003. A neural network approach to real-time rainfall estimation for Africa using satellite data. *Journal of Hydrometeorology*, 4: 1119-1133.
- Ham, F.M. and I. Kostanic, 2001. *Principles of neurocomputing for science & engineering*. McGraw-Hill. New York.
- Haykin, S., 1999. *Neural Network: A comprehensive foundation*. 2nd ed. Prentice Hall.
- Hong, Y., K.L. Hsu, S. Sorooshian, and X. Gao, 2004. Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system. *Journal of Applied Meteorology*, 43: 1834-1852.
- Hsu, K.L., X. Gao, S. Sorooshian, and H.V. Gupta, 1997. Precipitation estimation from remotely sensed information using artificial neural networks. *Journal of Applied Meteorology*, 36:1176-1190.
- Kidd, C., D.R. Kniveton, M.C. Todd, and T.J. Bellerby, 2003. Satellite Rainfall Estimation Using Combined Passive Microwave and Infrared Algorithms. *Journal of Hydrometeorology*, 4: 1088-1104.
- Pan, T.Y. and R.Y. Wang, 2004. State space neural networks for short term rainfall-runoff forecasting. *Journal of Hydrology*, 297:34-50.
- PERSIANN 系統：
hydis8.eng.uci.edu/hydis-unesco/
- Sorooshian, S., K. L. Hsu, X. Gao, H. V. Gupta, B. Imam, and D. Braithwaite, 2000. Evaluation of PERSIANN system satellite-based estimates of tropical rain. *Bulletin of the American Meteorological Society*, 81: 2035-2046.

收稿日期：民國 95 年 4 月 14 日

修正日期：民國 95 年 7 月 13 日

接受日期：民國 95 年 7 月 14 日