

結合 SSM/I 衛星資料與類神經網路推估 海面上颱風降雨量之研究

魏曉萍¹ 葉克家¹ 劉振榮² 趙俊傑²

¹ 國立交通大學土木工程學系

² 國立中央大學太空暨遙測中心

(中華民國九十七年二月二日收稿；中華民國九十七年六月二十四日定稿)

摘 要

每年颱風所帶來的豪大雨常帶給台灣地區民眾生命及財產損失，尤其一些停滯在台灣地區較久颱風，如納莉及桃芝等皆造成大規模之淹水與土石流災害。因此定量降雨預測是目前防災上重要課題之一，而氣象衛星資料估算降雨在此課題上扮演著重要之角色。本研究即使用氣象衛星上之 SSM/I 儀器估算海面之降水量。

早期推估降雨量最常使用方法有物理法與統計法兩種。物理法之模式常加以簡化，以致無法完全符合實際大氣狀況；統計法雖然具有簡便迅速優點，但常依特定季節與地區建立亮度溫度與降雨量間之關係。因物理法與統計法有上述之缺點，遂有利用人工智慧相關理論而為另一種替代方法。本文採用四種類神經網路，及三種不同 SSM/I 微波頻道之組合，嘗試建立適用於海面上推估颱風降雨量之方法，並以綠島、蘭嶼、彭佳嶼及東吉嶼等 4 個觀測站資料進行驗證。研究結果顯示，所建立之類神經網路以利用第三種 SSM/I 微波頻道組合，可較準確預測海面上之颱風降雨量；在四種類神經網路中，以 FNN 及 AASN 方法較適合於海面上颱風降雨量之推估。

關鍵詞：SSM/I 衛星資料、類神經網路、颱風降雨量

一、前言

台灣地區夏秋兩季受到颱風侵襲之威脅，常直接或間接造成人民生命危害、農作物損失、環境破壞等災害。颱風整個生命期幾乎都在海洋上，目前海洋上因缺乏直接的觀測資料，無法提供颱風接近陸地時所挾帶之降雨量，事先進行災害預警之工作，因此如何準確提供海上颱風定量降水實為一重要之研究課題。

傳統降雨量推估係利用地面雨量筒所收集之資料，但由於地面雨量筒為點估計降雨量，對於大面積區域並不能準確推估真實降雨量分佈。衛星資料因具備大面積、全面性特徵，且對於海面區域亦能提供資訊，因此利用衛星資料來推估海面上降雨量有其優勢。早期應用衛星資料推估降水研究中，多使用紅外線及可見光雲圖，但由於紅外線受卷雲之影響大，且只能提供雲頂溫度資訊，而往往高估降雨量；可見光雖然可消除卷雲之影響，但所能提供資訊為雲厚反射率，且只能於白天使用。此外，紅外線與可見光都會受到雲層的遮蔽，無法觀測到雲層下之降雨情形，並非真實之降雨資訊，而屬於間接降雨推估。

目前衛星上裝載被動式微波頻道衛星有：美國國家海洋大氣總署(National Oceanic and Atmospheric Administration, NOAA)所發射裝載微波探測單元 AMSU (Advanced Microwave Sounding Unit)之 TIROS-N 衛星；美國國防氣象衛星計畫 DMSP (Defense Meteorology Satellite Program)所發射裝載被動式微波輻射儀 SSM/I (Special Sensor Microwave/Imager)之氣象衛星；1997 年 11 月 27 日由美、日合作發射的 TRMM (Tropical Rainfall Measuring Mission)衛星，裝載 TMI (TRMM Microwave Imager)等衛星頻道系

統。上述三種衛星之任務及特性不同，NOAA 的 MSU 頻道，主要目的不在反演降水，但可以滿足即時預報需求。SSM/I 與 TMI 有較高解析度及更多頻道，且兩種衛星主要目的在求取各種大氣物理參數，適於降水推估。但 TRMM 衛星目前是實驗性質衛星，因此本文先利用 SSM/I 頻道推估海面上之降雨量。

近年來微波頻道遙測降雨技術已逐漸成熟，在應用 SSM/I 衛星資料於颱風降雨量估計方面，Chiu et al. (1990)、Hollinger (1989, 1991)、Adler et al. (1991)、Ferraro et al. (1997)等，均曾發展出降雨運算式。李(2002)以 TMI 之資料來反演梅雨時期降雨，使用統計與物理兩種方法。在統計法方面，建立 1998 年梅雨期間島嶼測站的每小時降雨量，與 TMI 九個頻道亮度溫度間之關係，使用單(多)變數線性迴歸方法，然後利用 1999~2001 年梅雨季內的島嶼測站降雨紀錄，來驗證降雨區判別及定量降雨之反演結果。另外，在物理法方面由美國太空總署(NASA)技術轉移的 GPROF 法，利用 TMI 微波資料反演垂直水相剖面及海面降雨強度，對梅雨期間之海上降雨進行研究。林(2003)則利用 SSM/I 之微波資料對颱風進行降雨研究，使用 Chiu et al. (1990)所提之降雨公式來反演颱風八個環之平均降雨分佈，且分析八個環中降雨量與颱風強度之關係，發現當颱風風速愈強則降雨量愈高。何(2005)利用 Chiu et al. (1990)以及 Ferraro et al. (1997)發展之降雨反演式，反演 2000~2004 年中央氣象局發佈之 34 個經過台灣之颱風降雨量，採 Chiu et al.反演式反演之降雨量複判定係數(R^2)最大為 0.66，採 Ferraro et al. 反演式之降雨量複判定係數(R^2)最大為 0.72，後者之相關性高於前者，且使用彭佳嶼、東吉嶼、蘭嶼和綠島四個島嶼來做驗證，除了蘭嶼測站的相關

係數只有 0.48，其餘三個測站相關係數落在 0.60~0.80 之間。一般反演出之降雨運算式大部分侷限於海洋上，因為估算陸地上降雨量時須先分辨其地表特性(Grody, 1991; Ferraro et al., 1997)。估算降雨因所使用的資料（如實際觀測、模式模擬）、微波頻道及微波頻道的數目不同，以致這些反演出式子從簡單到複雜的形式都有，但主要目的都在推求亮度溫度和降雨量間之關係式。

除了上述利用迴歸方法進行降雨量研究外，類神經網路具有聯想速度快、平行處理能力和解決最佳化、非線性問題等優點。周等（2000）採用雨量站多個連續時段之颱風中心位置、風速、氣壓、七級暴風半徑、特性參數等颱風特性資料及雨量站降雨量、風速、相對溼度、露點溫度及地形參數等資料，透過倒傳遞網路將複雜的颱風降雨機制記憶在類神經網路架構內，以達到推估颱風降雨量之目的。劉等（2001）蒐集啟德、象神兩個颱風之雷達資料（最低三層：0.5km、1.5km、2.5km）、衛星資料（IR1、IR2 及水氣頻道的雲頂溫度、緯度及經度雲頂溫度梯度）、雨量站高度、颱風中心位置與雨量站之距離及各時間之時雨量等資料，為 Levenberg-Marquardt 類神經網路輸入變數，而各時間之時雨量為目標輸出值，建立降水估計模式。Mallet et al. (2000) 以類神經網路使用 SSM/I 微波資料來推估液態水含量(cloud liquid water, CLW)與可降水量(total precipitable water, TPW)，該研究網路架構採用五個低頻 SSM/I 頻道為輸入值，隱藏層為一層，輸出目標為由 ECMWF 模式(Tiedtke 1993)推估出的 CLW 與 TPW 資料。Francisco et al. (2004)使用 SSM/I 資料測試 FF MLP、ART1、ART2、ARTMAP、Fuzzy ARTMAP 及 Distributed ARTMAP 等類神經模式推估降雨量，其中以 ART 模式在訓練階段表現良

好，但當使用新參數時，ART 模式推估降雨量並不理想。因此本文嘗試使用 SSM/I 資料，選用目前運用最廣且最具代表性之倒傳遞類神經網路(back-propagation networks, BPN)，且考慮微波頻道（輸入變數）對轉換函數之敏感度，因此另外選用以倒傳遞類神經網路架構為基本核心，具不同轉換數之擴展神經元網路(extend-neuron networks, ENN)、模糊神經網路(fuzzy-neuron networks, FNN)及調整綜合網路(analysis-adjustment-synthesis networks, AASN)四種不同類神經網路模式，推估颱風期間之降水量，建立適合台灣海面上之降雨量模式，提高颱風降雨量之準確率，以期對颱風期間豪大雨之估算及預測有所幫助。

二、資料來源及處理

本研究使用之衛星資料為 DMSP 所發射裝載的 SSM/I 微波頻道資料。DMSP 於 1987 年 6 月 19 日發射第一顆代號為 F-8 之衛星，陸續發射 F-10、F-11、F-12、F-13、F-14 和 F-15 進入繞行軌道，其中 F-12 儀器故障無法正常運作，且 F-8、F-10 和 F-11 陸續停止使用。因此，本研究選用目前正常運行之 F-13、F-14 和 F-15 三顆衛星資料。DMSP F 系統衛星為太陽同步繞極衛星，繞行地球的週期約為 102 分鐘，每天繞地球 14.1 圈，一天會通過赤道同一點附近上空兩次，稱為升交點與降交點，DMSP F 系列衛星的升交時間為早上 5 點到 9 點之間，降交時間為下午 4 點到 9 點之間。

SSM/I 可以接收 19.35GHz、22.5GHz、37.0GHz 與 85.5GHz 四種頻率之微波輻射，其中除了 22.5GHz 只有垂直極化頻道外，其餘的皆有垂直和水平雙極化頻道，故共有 7 個頻道，接收

的頻道介於 19.35GHz~85.5GHz 之間，避開受陽光反射影響較大波段，所以觀測到的輻射值主要來自大氣和地表的貢獻。SSM/I 衛星掃描方式分為 Scan A 和 Scan B 兩種，Scan A 之 19.35GHz、22.5GHz 和 37.0GHz 頻道空間解析度為 25 公里，85.5GHz 頻道解析度為 12.5 公里。Scan B 則只有 85.5GHz 頻道之觀測值，空間解析度為 12.5 公里。上述空間解析度是配合 SSM/I 移動速度和所需操作時間的空間解析度，而實際上微波在不同頻率頻道下之有效空間解析度與其可應用之方向如表一所示。

在 SSM/I 數據資料處理步驟中，將衛星之數據資料分成全區域（有雨+無雨）及有雨區域兩種，其目的是想瞭解先剔除無雨地區時，類神經網路是否有較佳表現。本研究分析之 2000~2004 年颱風案例為中央氣象局發布之颱風警報，總共有 34 個。估算降雨範圍為東經 115~135 度、北緯

10~30 度，如圖 1 所示，此一範圍包含了大部分可能侵襲台灣之颱風。將收集之衛星資料皆轉換為 12.5 公里解析度，全區域共 1,396 筆資料，有兩區域為 288 筆。




圖 1 研究範圍

表一 SSM/I 微波頻道之解析度與其可應用之方向

頻率	SSM/I 頻道	觀測時間	3 dB Footprint Size		可應用之方向	
			Along-track	Cross-track		
19.35 GHZ	垂直極化	7.95ms	69km	43km	1.海-冰之覆蓋 2.海洋雲水和降水 3.地海邊界 4.土壤濕度 5.植被	
	水平極化					
22.35 GHZ	垂直極化	7.95ms	50km	40km		1.海洋之水氣
37.0 GHZ	垂直極化	7.95ms	37km	28km		1.海-冰之覆蓋 2.海洋雲水和降水 3.海面風
	水平極化			29km		4.陸地之豪雨 5.雪之覆蓋
85.5 GHZ	垂直極化 水平極化	3.89ms	15km	13km	1.海-冰之覆蓋 2.海洋上之非降雨雲 3.陸地和海洋之降雨 4.雪之覆蓋	

表二 陸地測站編號、位置及面積

測站名稱	測站編號	經度	緯度	面積(km ²)
綠島	467730	121.48	22.65	16.34
蘭嶼	467620	121.55	22.033	45.74
彭佳嶼	466950	122.067	25.633	1.14
東吉嶼	467300	119.667	23.267	1.39

以台灣附近之綠島、蘭嶼、彭佳嶼和東吉嶼四個小島嶼觀測降雨量資料做驗證，目的在於避免受地形對較低頻道亮度溫度之影響，使用之雨量站資料為中央氣象局逐時雨量資料，綠島全區域為 370 筆，有雨區域為 49 筆，蘭嶼全區域為 350 筆，有雨區域為 134 筆，彭佳嶼全區域為 350 筆，有雨區域為 72 筆，東吉嶼全區域為 353 筆，有雨區域為 33 筆。表二為四個測站之相關資料。

在空間處理上，以地面雨量站為中心，向四方外延 12.5km，形成 25x25 km² 方塊，為代表平均雨量的面積，並找出 25km² 方塊之衛星資料來比較。在時間上，由於衛星資料在同一地點是屬於瞬間觀測，而地面雨量站資料為一個地點長時間連續的觀測，此二種資料有其不同特性，為了讓此二種資料可比較，參考趙 (1998) 之方法，找出最接近衛星掃描時間兩小時內之地面雨量資料，並取其平均值。

三、研究方法

目前類神經網路(network model)的應用頗為廣泛，雖然國內外已有不少以類神經網路預測颱風降雨的相關研究，但以類神經網路使用微波衛星資料來推估台灣海面附近之降雨量研究然有發展空間。本研究流程如圖 2，首先收集 2000~2004 年 34 個台灣海面上颱風之 SSM/I 資料及 4 個島嶼之雨量測站資料，然後對 SSM/I 資料作前期處理，如衛星掃描時間與經緯度範圍選取等。而在

數據處理步驟中，將衛星之數據分成全區域及有雨區域兩種數據。處理完之數據資料為類神經網路輸入值，經過演算後之評鑑指標與推估雨量為輸出值，然後經由評鑑指標與推估雨量判斷何種方法較適合用來推估台灣海面上之降雨量。

(一) 類神經網路

類神經網路是由許多人工神經細胞所組成，人工神經元模型為每一個處理單元以扇狀輸出，作為其他處理單元的輸入，其輸入值與輸出值的關係式，如式(1)，可用輸入值的加權乘積和函數表示：

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

其中， Y_j 為模仿生物神經元模型之輸出訊號； f 為模仿生物神經元模型之轉換函數 (transfer function)； W_{ij} 為模仿生物神經元模型之神經強度，又稱連結加權值； X_i 為模仿生物神經元模型之輸入訊號； θ_j 為模仿生物神經元模型之閾值。

類神經網路結構可分為輸入層、隱藏層及輸出層三個部分。類神經網路有幾個重要參數，如隱藏層處理單元數目、隱藏層層數及學習速率。

(二) 倒傳遞網路

倒傳遞類神經網路(BPN; Yeh, 2002)之基本原理是利用最陡坡降法(gradient steepest descent method)，將誤差函數予以最小化。其中隱藏層及輸出層神經元之轉換函數為雙彎曲函數(sigmoid function)。

(三) 擴展神經元網路

擴展神經元網路(ENN; Yeh, 2002)是在倒傳遞網路架構上加入擴展神經元使其輸入變數對不

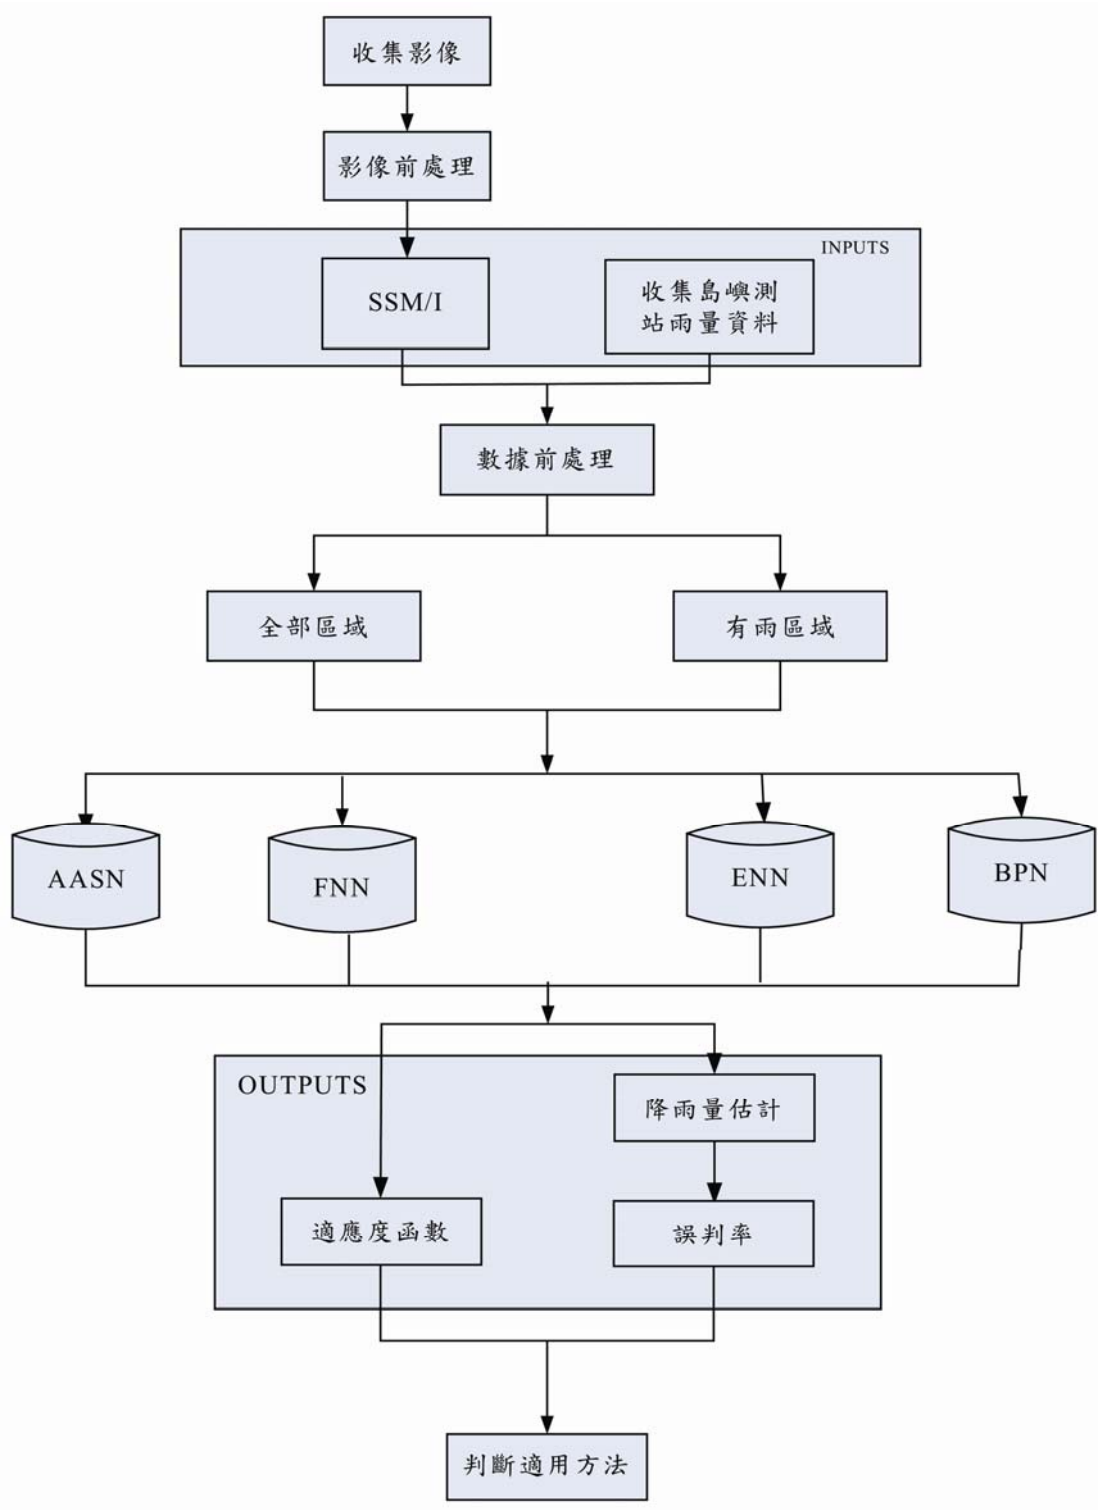


圖 2 研究流程圖

同的非線性轉換函數有不同的敏感度，可改善網路效能及強化網路架構，其中輸出層及隱藏層神經元的轉換函數為雙彎曲函數。

(四) 模糊神經網路

模糊神經網路(FNN; Yeh, 1999)在倒傳遞網路架構上加入模糊神經元，使其輸入變數對不同隸屬度函數(membership function)有不同之敏感度，進而改善網路效能及強化網路架構，其中隱藏層及輸出層神經元之轉換函數為雙彎曲函數。

(五) 分析調整綜合網路

分析調整綜合網路(AASN; Yeh, 2003)是由分析次網路、調整次網路、綜合次網路等三個次網路組成之神經網路。於網路完成訓練後，在回想(recall)階段，綜合次網路接收展開輸出單元之輸出值，並以加權方式綜合這些輸出值為高度精確之輸出值，進而改善網路效能及強化網路架構。其中隱藏層及輸出層神經元之轉換函數為雙彎曲函數，網路架構如圖 3。




圖 3 分析調整綜合網路模型

(六) 評鑑指標

採用不同模式將產生不同之學習與預測結果，因此以誤差均方根(root of mean square, RMS)與複判定係數(coefficient of multiple determination, R^2)評鑑所推估之颱風降雨量，藉以判斷不同模式預測之優劣；另由誤判率(error rate, ER)評估何種方法判斷無雨區域有較高之準確度。

1. 誤差均方根

均方根誤差代表觀測值與預測值之誤差量，其值越小代表模式之預測越佳，誤差均方根如式(2)所示：

$$RMS = \sqrt{\frac{\sum_{i=1}^n (y_i - y_i')^2}{n}} \quad (2)$$

上式中， n 為觀測數目； y_i' 為類神經網路推算之輸出值； y_i 為島嶼之地面雨量觀測值。

2. 複判定係數

複判定係數(R^2)表示由於預測變數進入模式後， y' 變異降低之比例，如式(3)所示：

$$R^2 = 1 - \frac{\sum (y_i - y_i')^2}{\sum (y_i - \bar{y})^2} \quad (3)$$

上式中， \bar{y} 為島嶼地面雨量觀測值之平均值。

3. 誤判率

誤判率(ER)表示被誤判之機率，如式(4)所示：

$$ER = \frac{(N - Y)}{N} \quad (4)$$

上式中， N 為範例總數； Y 為正確判斷數。

四、案例應用與討論

微波估計降雨可分為放射法與散射法兩類物理機制(李, 2002), 利用海面較低之放射率所呈現冷(低)的輻射背景, 在冷(低)輻射背景下水滴的吸收、再放射所增加輻射量非常容易被偵測出來, 而依據所增加亮度溫度與水滴含量關係, 估算降雨量稱為放射法; 散射法理論基礎係建立在較強降雨會具有較厚的冰晶層論點上, 由於大氣中的冰晶對較高頻的微波頻道會產生散射作用, 散射作用會減弱向上微波輻射能量, 造成微波頻道的亮度溫度隨降雨強度增加而減少。放射法通常使用低頻(19.35、22.5及37.0GHz)微波資料適用於海面上, 而散射法為使用高頻(85.5GHz)微波資料可兼具海面與陸地使用。

(一) 網路演算過程

由於SSM/I微波頻道共有七種頻道, 可組合組數眾多。因此本研究先嘗試使用三種不同SSM/I微波頻道組合為輸入變數, 第一種組合考慮微波的放射與散射特性, 因此選用一個低頻與一個高頻微波資料來推估降雨量; 由於本研究為推估颱風時期海面上之降雨量, 因此選用適合推估海面上降雨量之低頻微波資料為第二種組合, 第三種組合為參考早期應用SSM/I衛星資料反演颱風降雨量之研究, 而發展出之降雨運算式, 如Smith et al. (1992)提出19.35GHz與85.5GHz頻道亮度溫度與降雨有密切關係; Schulz et al. (1993)利用SSM/I 19.35 GHz及22.5GHz雙頻道推求水汽含量有不錯表現; Hollinger (1989)在反演颱風公式時, 使用19.35GHz、22.5GHz及37.0GHz之垂直和水平頻道來反演颱風速度時, 得知37.0GHz頻道極化程度受到雲滴和液態水之影響頗大; Kidd (1998)提出PCT(85)反演式($PCT(85)=85V+b(85V-85H)$), V 為代表垂直極化、 H 為

代表水平極化、 b 為代表常數)推估海面上降雨量, 公式中包含85V-85H參數。由以上文獻可發現SSM/I微波頻道中19.35GHz、22.5GHz、37.0GHz、85.5GHz和85V-85H可用來估算降雨量, 因此第三種組合使用七個SSM/I原始頻道及一個延伸頻道共八個頻道。本研究使用三種不同SSM/I微波頻道組合如下所示:

1. 19.35GHz與85.5GHz之水平及垂直極化頻道。
2. 19.35GHz與22.5GHz之垂直與水平極化及37.0GHz五個頻道。
3. 19.35GHz、22.5GHz、37.0GHz與85.5GHz四種頻道及19.35GHz、37.0GHz、85.5GHz垂直極化頻道與85.5GHz極化差。

過去相關研究(Villiers and Barnard, 1992)指出兩層隱藏層的網路不易訓練, 且容易落入局部最小值, 因此本研究採用一層隱藏層。網路中輸出層節點僅有一個, 即目標輸出雨量。其中類神經網路須設定參數參, 請參考葉(2002)之論述。本文收集2000~2004年颱風資料, 其中前2/3資料用以訓練, 其餘1/3資料當測試範例, 範例取樣採用依時間循序取樣法(sequential sampling), 即前面範例作訓練範例, 後面則作測試範例。

(二) 成果及討論

1. 輸入變數

本研究使用三種不同頻道組合, 找尋適合推估海面上降雨量之組合。如表三及表四所示, 當19.35GHz、22.5GHz、37.0GHz與85.5GHz四種頻道及19.35GHz、37.0GHz、85.5GHz垂直極化頻道與85.5GHz極化差值(第三種組合)為輸入變數時, 可得到較精確之降雨估計。

表三 未經調整之全區域評鑑指標

		島 嶼		綠 島		蘭 嶼		彭佳嶼		東吉島		
		資料筆數		230	114	234	116	234	116	235	117	
區域	組合	網路	指標	訓練	測試	訓練	測試	訓練	測試	訓練	測試	
全區域	第一種	BPN	RMS	1.89	2.11	2.64	2.51	1.84	2.16	1.07	0.91	
			R ²	0.50	0.02	0.53	0.39	0.68	0.64	0.62	0.44	
		ENN	RMS	1.44	1.81	1.86	2.92	1.58	1.60	0.73	0.78	
			R ²	0.71	0.28	0.76	0.17	0.76	0.81	0.82	0.59	
		FNN	RMS	1.47	1.90	1.74	2.54	1.72	1.89	0.67	0.71	
			R ²	0.70	0.21	0.79	0.37	0.72	0.73	0.85	0.66	
		AASN	RMS	1.16	1.47	1.63	2.58	1.56	1.46	0.71	0.75	
			R ²	0.81	0.53	0.82	0.35	0.77	0.84	0.84	0.62	
		第二種	BPN	RMS	2.02	2.14	2.81	2.49	1.54	1.88	1.06	0.87
				R ²	0.43	0.01	0.46	0.40	0.77	0.73	0.63	0.49
			ENN	RMS	1.81	1.88	2.68	2.39	1.92	2.67	1.00	0.99
				R ²	0.54	0.23	0.51	0.44	0.65	0.45	0.67	0.34
	FNN		RMS	1.80	1.81	2.52	2.39	2.11	2.91	0.96	0.95	
			R ²	0.55	0.28	0.57	0.44	0.57	0.35	0.70	0.39	
	AASN		RMS	1.73	1.77	2.44	2.43	1.74	2.36	0.96	0.96	
			R ²	0.58	0.31	0.59	0.43	0.71	0.57	0.70	0.39	
	第三種		BPN	RMS	1.56	1.96	2.50	2.74	1.55	1.88	1.09	0.83
				R ²	0.66	0.15	0.58	0.27	0.77	0.73	0.61	0.54
			ENN	RMS	1.06	1.24	1.68	2.68	1.59	1.60	0.60	0.66
				R ²	0.84	0.66	0.81	0.30	0.76	0.80	0.88	0.70
		FNN	RMS	0.98	1.10	1.38	2.36	1.68	1.74	0.47	0.79	
			R ²	0.87	0.73	0.87	0.46	0.73	0.77	0.93	0.58	
		AASN	RMS	0.64	0.86	1.53	2.56	1.55	1.53	0.66	0.69	
			R ²	0.94	0.84	0.84	0.36	0.77	0.82	0.86	0.67	

2. 降雨區辨識

使用第三種頻道組合為四個類神經網路之輸入值，經由類神經網路反演出降雨量，而類神經網路反演出之降雨量有可能包含負值，其可能原因為訓練範例之樣本，不包含測試範例資料，故須先進行調整，把不合理負數值剔除，以零值取

代。經由調整後，計算其誤判率，所謂誤判率即為當實際為無（或有）雨地區而類神經網路卻辨識為有（或無）雨地區的機率。由表五可知，倒傳遞網路之誤判率較低，因此該方法對於降雨或無降區域之辨識有較佳結果。

表四 未經調整之有雨區域評鑑指標

島 嶼				綠 島		蘭 嶼		彭佳嶼		東吉島		
資料筆數				35	14	90	44	48	24	22	11	
區域	組合	網路	指標	訓練	測試	訓練	測試	訓練	測試	訓練	測試	
有雨區域	第一種	BPN	RMS	4.62	5.82	7.67	6.20	2.99	7.85	3.05	3.11	
			R ²	0.25	0.10	0.10	0.10	0.46	0.41	0.37	0.18	
		ENN	RMS	3.82	5.33	6.49	6.67	1.36	4.48	1.86	3.03	
			R ²	0.49	0.24	0.10	0.10	0.89	0.81	0.77	0.22	
		FNN	RMS	3.06	4.91	6.10	5.78	1.83	5.42	2.10	2.33	
			R ²	0.67	0.36	1.00	1.00	0.80	0.72	0.70	0.54	
		AASN	RMS	2.18	0.41	5.21	5.93	1.30	4.12	1.71	2.29	
			R ²	0.83	-0.09	1.00	1.00	0.90	0.84	0.80	0.56	
		第二種	BPN	RMS	4.53	5.20	4.36	4.03	2.98	7.99	2.99	3.00
				R ²	0.30	0.25	0.40	-0.18	0.47	0.39	0.39	0.24
			ENN	RMS	3.55	4.23	3.51	4.51	2.28	6.53	2.02	3.51
				R ²	0.51	0.50	0.61	-0.48	0.69	0.59	0.72	-0.04
	FNN		RMS	2.73	5.22	3.51	4.53	2.33	6.56	1.92	3.82	
			R ²	0.74	0.24	0.61	-0.49	0.67	0.59	0.75	-0.23	
	AASN		RMS	3.08	4.20	2.88	4.50	2.00	5.99	1.68	3.09	
			R ²	0.65	0.51	0.74	-0.47	0.76	0.66	0.81	0.23	
	第三種		BPN	RMS	3.90	4.08	3.98	5.11	2.99	7.84	2.25	2.11
				R ²	0.47	0.56	0.50	-0.90	0.46	0.41	0.66	0.63
			ENN	RMS	1.60	3.99	2.37	3.58	1.45	5.54	0.21	1.38
				R ²	0.91	0.58	0.82	0.07	0.87	0.71	1.00	0.84
		FNN	RMS	1.52	3.80	2.20	3.54	1.33	5.46	0.21	1.13	
			R ²	0.92	0.62	0.85	0.09	0.89	0.72	1.00	0.89	
		AASN	RMS	0.59	3.74	2.29	3.17	1.18	5.01	0.39	1.86	
			R ²	0.99	0.63	0.83	0.27	0.92	0.76	0.99	0.71	

表五 未經調整之有雨區域評鑑指標

(誤判率)	綠 島		蘭 嶼		彭佳嶼		東吉島	
	訓練	測試	訓練	測試	訓練	測試	訓練	測試
BPN	0.40	0.43	0.35	0.35	0.40	0.40	0.36	0.26
ENN	0.47	0.51	0.45	0.46	0.45	0.53	0.38	0.31
FNN	0.67	0.63	0.40	0.40	0.50	0.47	0.37	0.39
AASN	0.75	0.82	0.45	0.38	0.69	0.68	0.24	0.10

3. 颱風降雨量反演分析

傳統進行颱風降雨之預測，往往需要複雜數值運算與分析，而本研究利用類神經網路經由一組範例（由輸入值與輸出值所組成的資料）建立系統模型（輸入值與輸出值間的關係），利用此系統模型推估颱風降雨量。由表六可得知，在全部區域時使用第三種組合為輸入值，所推估出的颱風降雨量，經負值調整為零後 RMS 平均降低 0.29， R^2 平均提高 0.25，調整後結果都較優於未經調整者。

在全區域使用第三種頻道組合資料，四種模式所推估出之降雨量經過調整後，倒傳遞網路方法結果較不理想，擴展神經元網路、模糊神經網路及分析調整綜合網路除了蘭嶼測站之 R^2 為 0.3~0.5 之間，其餘都落於 0.7~0.9 之間。且由表 6 可得知，綠島與彭佳嶼以 AASN 方法反演出雨量與實際測站降雨量間之 R^2 最高。綠島之 R^2 在訓練時為 0.95，測試時為 0.87，RMS 在訓練與測試分別為 0.62mm/h 及 0.77mm/h，由圖 4 可觀察出，所反演出雨量與實際降雨量接近；彭佳嶼訓練及

表六 第三種組合調整後之全區域評鑑指標

島嶼		綠島		蘭嶼		彭佳嶼		東吉島	
資料筆數		230	114	234	116	234	116	235	117
全區域		訓練	測試	訓練	測試	訓練	測試	訓練	測試
BPN	RMS	1.51	1.56	2.47	2.72	1.55	1.83	1.07	0.81
	R^2	0.69	0.27	0.59	0.32	0.77	0.75	0.62	0.57
ENN	RMS	1.02	1.12	1.67	2.67	1.59	1.60	0.56	0.65
	R^2	0.86	0.72	0.81	0.35	0.76	0.86	0.90	0.75
FNN	RMS	0.94	1.08	1.37	2.35	1.67	1.73	0.45	0.77
	R^2	0.88	0.76	0.87	0.47	0.73	0.82	0.94	0.76
AASN	RMS	0.62	0.77	1.52	2.55	1.49	1.53	0.66	0.69
	R^2	0.95	0.87	0.84	0.38	0.80	0.89	0.86	0.70
平均值	RMS	1.02	1.13	1.76	2.57	1.57	1.67	0.69	0.73
	R^2	0.85	0.66	0.78	0.38	0.77	0.83	0.83	0.70




圖 4 第三種組合 AASN 反演之降雨量與綠島測站之降雨量比較 (全部區域)

測試之 R^2 分別為 0.80 及 0.89，訓練及測試之 RMS 分別為 1.49mm/h 及 1.53mm/h，由圖 6 可觀察出，訓練時較大降雨量時有較好之相關性，但測試所反演出雨量卻有低估現象，可能為多數測試範例降雨量較小所造成。而蘭嶼與東吉島，以 FNN 方法反演出雨量和實際測站降雨量間之 R^2 最高。蘭嶼訓練時之 R^2 為 0.87，測試時只有 0.47，訓練及測試之 RMS 分別為 1.37mm/h 及 2.35mm/h，由圖 5 可觀察出，測試所反演出雨量有低估的現象，故測試範例相關性比訓練範例低很多；東吉

島訓練及測試之 R^2 為 0.94 及 0.76，RMS 為 0.45mm/h 及 0.77mm/h，圖 5 可觀察出，訓練及測試所反演出雨量與實際降雨量接近。

4. 綜合討論

綜合上述，本研究所採 BPN、ENN、FNN、AASN 四種方法中，以 BPN 對於降雨或無降區域之辨識有較佳結果，準確度約 63%，而採 AASN 與 FNN 方法反演出之降雨量較準確，四個觀測站訓練時 R^2 平均約為 0.86，測試為 0.71，而訓練與




圖 5 第三種組合 FNN 反演之降雨量與蘭嶼測站之降雨量比較 (全部區域)

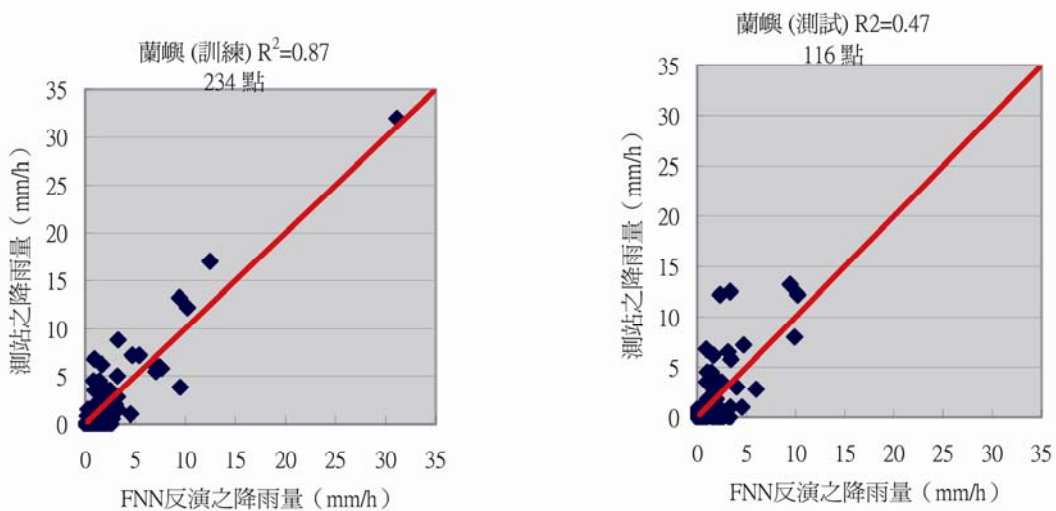


圖 6 第三種組合 AASN 反演之降雨量與彭佳嶼測站之降雨量比較 (全部區域)




圖 7 第三種組合 AASN 反演之降雨量與東吉島測站之降雨量比較（全部區域）

測試 RMS 約為 1mm/h；以 4 個島嶼驗證所推估降雨量中綠島相關性最高，蘭嶼站相關性最低。

何 (2005) 以 Ferraro et al. (1997) 降雨式子反演出之降雨量（統計法）分別就彭佳嶼、東吉嶼、蘭嶼和綠島測站來做驗證，除了蘭嶼測站 R^2 只有 0.23，其餘 R^2 都落在 0.36~0.64 之間，而本研究除了蘭嶼測站之 R^2 為 0.3~0.5 之間，其餘 R^2 落於 0.7~0.9 之間。因此，使用類神經網路推估海面上降雨量，確實可提高準確度。

Mallet et al. (2000) 以類神經網路使用低頻 SSM/I 微波資料來推估 CLW 與 TPW，該研究只選取一種類神經網路及一種輸入值組合（微波頻道），目標輸出值為使用 ECMWF 模式推估出之 CLW 與 TPW，而本研究考慮微波頻道（輸入變數）對轉換函數之敏感度採用四種類神經網路，及三種不同 SSM/I 微波頻道組合嘗試建立適用的降雨量推估模式，且輸出值為真實降雨量不需複雜計算及收集。

劉等 (2001) 利用 2000 年啓德、象神及 2001 年納莉颱風三個颱風個案，以雷達、衛星及雨量

站等 14 個相關參數當 Levenberg-Marquardt 倒傳遞網路輸入值， R^2 可達 0.81 較本研究使用倒傳遞網路高，但該研究需耗費許多時間收集相關參數，而本研究方法只需收集光波頻道當類神經網路輸入值，因此在資料處理方面可節省人力與物力。

五、結論與建議

台灣地區每年因颱風帶來豐沛雨量，但常造成嚴重災害，因此對於豪大雨預報需求相當殷切。近幾年透過類神經網路及 SSM/I 微波資料進行海面上颱風降雨強度之相關研究雖然不少，但應用於台灣地區附近海域卻不多，且目前國內使用衛星資料推估降雨量一般都引用國外學者所反演之式子，因此，本研究利用 SSM/I 衛星資料，以三種 SSM/I 微波頻道組合，使用 BPN、ENN、FNN 及 AASN，探討適合台灣海面上之降雨量模式。本文所使用三種不同頻道組合中，以第三種頻道組合為模式輸入變數時，降雨估計較為精確。倒傳遞網路在降雨區之辨識優於其它幾種方法。研究結果顯示使用 SSM/I 資料，以 AASN 與

FNN 反演颱風時期海面上降雨量及使用 BPN 對降雨區域之辨識,可提升海面降雨預測之準確度。

由研究結果可知,使用類神經網路可提高颱風時期,推估海面上降雨量之準確度,且本研究參數收集上比劉等 (2001) 與 Mallet et al. (2000)較為簡單。

本研究只選用三種不同 SSM/I 微波頻道組合為輸入變數,未來可多收集相關資訊,增加較多光波頻道組合,探討不同頻道組合對於降雨量推估是否有影響。本研究只針對海上颱風降雨量進行推估分析,未來可進一步考慮推估陸地上降雨量。陸地上降雨量分佈常因地形環境改變而有很大變動,可考慮加入地形因子,以期能較準確推估陸地上颱風降雨量。此外,因微波解析度低,較不適用於推估陸地上颱風降雨量,可考慮加入紅外線頻道,以解決解析度問題。

參考文獻

何姿儀,“應用 SSM/I 衛星觀測資料估算颱風定量降水”,國立中央大學大氣物理研究所碩士論文,2005。

李慶忠,“TRMM 微波資料海面降雨反演及應用”,國防大學中正理工學院國防科學研究所博士論文,2002。

周乃昉、鄭子璉、林柏承,“應用類神經網路於颱風降雨量的推估”,第十一屆水利工程研討會論文集,台灣台北, C23~ C28, 2000。

林家幹,“應用衛星資料分析颱風降雨與颱風強度變化之關係”,國立中央大學大氣物理研究所碩士論文,2003。

葉怡成,“類神經網路模式應用與實作”,儒林圖

書有限公司,2002。

劉清煌、劉廣英、劉敏香,“類神經網路估計颱風降水之研究”,兩岸颱風研討會,台灣台北, 179-1852, 2001。

Adler, R. F., Yeh, H-Y. M., Prasad, N., Tao, W. K., and Simpaon, J., “Microwave simulations of a tropical rainfall system with a three-dimension cloud model”, *J. Applied Meteorology*, Vol. 30, 924-953, 1991.

Chiu, L. S., North, G. R., Short, D. A., and McConnell, A., “Rain estimation from satellites effect of finite field of view”, *J. Geophys. Res.*, 95, 2177-2185, 1990.

Ferraro, R. R., “SSM/I derived global rainfall estimates for climatological applications”, *J. Geophys. Res.*, 102, 16715-16735, 1997.

Francisco J., Tapiador, Kidd, Chris, Levizzani, Vincenzo, Marzano, Frank S.” A Neural Networks-Based Fusion Technique to Estimate Half-Hourly Rainfall Estimates at 0.1° Resolution from Satellite Passive Microwave and Infrared Data”, *J. Applied Meteorology*, Vol. 43, No. 4, pp. 576-594, 2004.

Grody, N.C., “Classification of snow cover and precipitation using the special sensor microwave imager”. *J. Geophys. Res.*, Vol. 96, 7423-7435, 1991.

Hollinger, J. P., “DMSP special sensor microwave/imager calibration/ validation”, Final Report, Vol.1.I, 120, 1989.

Hollinger, J. P., “DMSP special sensor

- microwave/imager calibration/ validation”, Final Report, Vo1.II, 55, 1991.
- Kidd, C., “The rainfall retrievals using the polarization-corrected temperature algorithm”, Int. J. Remote Sens., 1998.
- Mallet, C., Moreau, E., Casagrande, L., and Klapisz, C., “Determination of integrated cloud liquid water path and total precipitate water from SSM/I data using a neural network algorithm,” Int. J. Remote Sens., vol. 23, 661–674, 2002.
- Schulz, J., Schluessel, P., and Grassl, H., “Water vapor in the atmospheric boundary layer over oceans from SSM/I measurements”, Int. J. Remote Sensing., Vol.14, No.15, 2773-2789, 1993.
- Smith, A. E., Alberto, M., Hugnai, Harry J. C., Gregory J. T., and Xuwu X., “Foundations for statistical physical precipitation retrieval from passive microwave satellite measurement, Part I: Brightness temperature properties of a time dependent cloud radiation model,” Journal of Applied Meteorology, Vol. 31, 506-531, 1992.
- Smith, E. A., J. E. Lamm, R. Adler, J. Alishouse, K. Aonashi, E. Barrett, P. Bauer, W. Berg, A. Chang, R. Ferraro, J. Ferriday, S. Goodman, N. Grody, C. Kidd, D. Kniveton, C Kummerow, G. Liu, F. Marzano, A Mugnai, W. Olson, G. Petty, A. Shibata, R. Spencer, F. Wentz, T. Wilheit, and E. Zipser,”Results of WetNet PIP-2 project,” J. Atmos. Sci., 55, 1483-1536, 1998
- Tiedtke, M., “Representation of clouds in large-scale models”, Monthly Weather Review,121, 3040 – 3061,1993.
- Villiers, J. D. and Barnard, E., “Backpropagation neuralnets with one and two hidden layer”, IEEE Trans. On Neural Network, Vol. 4, No. 1, 136-141, 1992.
- Yeh, Y. C., “Classification using extended-neuron networks”, 16-22, 電腦學刊, 2002.
- Yeh, Y. C., “Modeling chaotic dynamic systems using analysis adjustment synthesis networks”, J. Technology, Vo1. 18, No. 3, 369-376, 2003.
- Yeh, Y. C., “Modeling chaotic two-dimensional mapping with fuzzy-neuron networks”, Fuzzy Sets and Systems, Vol. 105, No. 3, 421-427, 1999.

Study on Estimating Typhoon Rainfall over Sea from SSM/I Satellite Data Utilizing Artificial Neural Networks

Hsiao-Ping Wei¹ Keh-Chia Yeh¹ Gin-Rong Liu² Chun-Chieh Chao²

¹Department of Civil Engineering, National Chiao Tung University

²Space and Remote Sensing Center, National Central University

(Manuscript received 02 February 2008; in final form 24 June 2008)

ABSTRACT

Heavy rainfalls resulted from the typhoons cost human lives and financial damages in Taiwan every year. This is especially the case for stagnant typhoons over Taiwan area such as Nari and Toraji, which bring large scale disasters in forms of floods and debris flows. Therefore, one of the most important topics in disaster prevention in Taiwan would be the prediction of precipitation, and rainfall estimation using meteorological satellite data plays an important role in this topic.

In earlier times, physical and statistical methods are the two most frequently used methods for estimating rainfall. The physical method is usually over-simplified and its results are incoherent with the realistic atmospheric conditions, while the statistical method often over-relies on the relationship built according to a specific season and region, despite its advantages of simple and fast computation. Since the physical and statistical methods have the limitations described above, theories related to the artificial intelligence arise to be an alternative method in recent years. This research utilizes four types of artificial neural networks, combining with three different combinations of SSM/I microwave frequency channels, in an attempt to establish a suitable method for estimating rainfall at sea surface during typhoon periods. These results are then verified with the data from four rainfall stations located at Lyudao, Lanyu (Orchid Island), Peng Chiayu, and Tungchityu. From the results, it is found that data from the third type of combination of SSM/I microwave frequency channels is more accurate at estimating the rainfall in typhoon periods. Among the four types of artificial neural networks, the FNN and AASN methods are more suitable for estimation of sea-surface rainfall in typhoon periods.

Key words: SSM/I satellite data, Artificial neural network, Typhoon rainfall