

應用遺傳演算法 / 類神經網路於臺灣地區天氣預報

夏裕龍、吳明進

國立臺灣大學大氣科學研究所

摘要

天氣預報包括日最高最低溫度及降雨機率預報，一般傳統上均以數值大氣環流模式（Global Climate Model, GCM）輸出產品作為預報因子，並輸入線性統計模式藉以產生天氣預報產品為主。目前天氣預報最常使用的統計作業模式以多變量線性迴歸（Multiple Linear Regression, MLR）Yang(2004)為主。

MLR包括兩種作業方式，一為完全預報（Perfect Prognostic, PP）Wilks(1995); Maini(2002)一為模式輸出統計（Model Output Statistics, MOS）Glahn(1972)，PP是以實際觀測的預報因子（predict）和預報元（predictand）建立預報模式，代入模式的預報因子進行預報，而MOS則是以模式輸出和相對應的預報元建立預報模式，代入模式輸出的預報因子進行預報。MOS因而可以避免部分模式系統性誤差所造成的不確定性。一般在電腦計算速度提升後，MLR皆以MOS為主。羅(2003)研究也指出對於台灣地區的氣象預報MOS也優於PP，所以中央氣象局使用的預報模式也以MOS為主。

MOS以逐步迴歸法建立預報模式。本文以逐步迴歸法篩選預報因子，並用兩個非線性模式(混合遺傳演算法、倒傳遞類神經網路)建立模式來預報日最高最低溫度及分區雨量。研究結果顯示：日最高最低溫度在冬季，而分區雨量則在夏季有較高可預報度。混合遺傳演算法模式在大部分狀況之下有最佳的預報能力及誤差。混合遺傳演算法模式和倒傳遞類神經網路模式相較之下，混合遺傳演算法模式有更好的預報穩定度，對於天氣預報的業務作業有可供參考的價值。

一、前言

近年來統計預報模式技術有許多的發展，除了傳統上MLR模式的使用，亦發展出非線性的統計模式來解決預報因子間共線性的問題，其中具代表性的是使用類神經網路（Artificial Neural Network, ANN）Cavasos(1997)。過去幾年國外研究顯示

Schoof(2001)，類神經網路對於極端天氣的天氣預報有良好的效果，說明非線性統計模式可能可以避免傳統線性統計模式的天生限制。類神經網路在運用上最常見的是倒傳遞類神經網路（Error Back Propagation, BP）Rumelhart(1986)。

倒傳遞類神經網路在許多預報模式將他視為黑盒子來使用，因為他的結構並不是以線性理論出發，而是以試誤法來求得模式最佳結構，在建立模式其間有相當多需要調整的參數，其中包括隱藏層神經元個數，常需要使用經驗值求得。此外，由於權重組合初始值的選擇不同，很容易造成模式輸出值的期望誤差陷入局部最小值，對於預報結果有很大的差異性。周(2002)。

為了解決倒傳遞類神經網路的問題，本研究使用混合遺傳演算法。遺傳演算法(Genetic Algorithms, GA)是最優化方法，使用此法來搜索演化倒傳遞類神經網路本身架構，此即為混合遺傳演算法(Hybrid Genetic Algorithms, HGA, GABP)。周(2005)。在許多研

究上指出混合遺傳演算法，相較於倒傳遞類神經網路有更很好預報穩定度及誤差。

二、使用資料、評量標準、研究方法、模式建立及參數設定

(一) 使用資料：NCEP/NCAR Reanalysis 2 網格點資料(圖 1) Kalnay(1996)，取臺灣附近 4 個網格點。使用變數有 1000hPa 氣溫、850 hPa (南北向風速、東西向風速、相對濕度、重力位高度、相對溼度)、700 hPa 相對濕度、K index、850 hPa 24 小時重力位高度差、500hPa 和 1000hPa 厚度差及海平面氣壓。可供模式選取因子共 44 個。

預報對象：1.基隆、台中、高雄及花蓮地區（中央氣象局各測站觀測值為準）日最高最低溫度。2.台灣地區北中南東四區分區雨量（氣象局屬觀測站及自動雨量站以經緯度分區平均）(圖 2)。

(二) 評量標準：

1. 相關係數 $R(i,j) = \frac{C(i,j)}{\sqrt{C(i,i)C(j,j)}}$ (2.1)

C : covariance

$$2. \text{ 日平均誤差(Daily Mean Error)} = \frac{\sum |y - \hat{y}|}{n} \quad (2.2)$$

y : 預報值

\hat{y} : 觀測值

n : 日數

(三) 研究方法：

1. 逐步迴歸：逐步迴歸是篩選迴歸(Screening Regression, SR)的一種。逐步迴歸法對預報因子進行雙向篩選，在考慮每一預報因子是否納入迴歸方程的同時，亦考慮是否將迴歸方程中的預報因子剔除。如此利用預報因子篩選的特性，可以降低自由度並增加預報結果的穩定度，氣象上常用來作為MOS的預報方程。

篩選考量的因素是逐步入選預報因子的方差貢獻，以偏 F 檢定準則 (Partial F Test Criterion) 判斷預報因子加入迴歸方程後的貢獻度是否顯著。若統計值具顯著性，則將此預報因子納入迴歸方程；否之則否。逐步迴歸詳細執行步驟可參考 Draper(1981)。

2. 倒傳遞類神經網路：

類神經網路或稱為人工神經網路，為利用電腦模仿生物神經網路的資訊處理系統。其使用大量簡單的相連人工神經元來模仿生物神經系統刺激-記憶-反應的適應能力。人工神經元模擬生物神經元，從外界（輸入場）或其他神經元取得資訊加以簡單運算後記憶其資訊並將結果輸出到外界環境（輸出場）或其他神經元。人工神經元模型如圖 3 所示。

神經元輸出值(Y_j)與輸入值(O_i)的關係式：

$$Y_j = f \left[\sum_i W_{ij} O_i - b_j \right] \quad (2.3)$$

其中 f 為轉換函數、 W_{ij} 為神經元之間連結強度（神經元連結權值組合）、 b_j 為神經元閾值。

類神經網路是由許多神經元及其連結組成，不同的神經元和連結可以構成不同的網路模式。類神經網路的運作模式包括兩部分：1.學習階段 (Learning)：網路依學習演算法從範例中學習，一般來說學習演算法是從能量函數 (Energy Function) 或誤差平方和最小推導得到。能量函數用以評量網路學習效果，網路的學習階段就是能量函數的最小化過程。2.回憶階段 (Recalling)：網路依回憶演算法以輸入資料決定網路輸出資料的過程。

類神經網路模式約略可以學習過程分為監督式、無監督式、聯想式和最適化學習網路，其中以屬於監督式學習網路的倒傳遞類神經網路 Rumelhart(1985)應用最為普遍。

倒傳遞類神經網路的結構除了輸出及輸入層的神經元之外，尚包括至少一層的隱藏層。使用最陡坡降法 (the gradient steepest decent method) 將能量函數予以最小化，因為多層的類神經網路具有非線性的特性，因而可用來解非線性方程式或其他複雜計算的動作。

倒傳遞類神經網路架構(Back Propagation Neural Network, BP)為前向式演算及倒傳遞學習（誤差修正）完整架構如圖 3。Hagan(1996)。

網路分為幾層，每層都是由許多神經元組成。透過權重的加強或抑制，該層節點的輸入值是前一層節點輸出值與權值乘積之總和。每一節點依據節點的輸入轉換函數 (activation function) (圖 4)和閾值 (threshold) 激發。隱藏層神經元的前向式運算為將前一層的輸出值乘上對應權值總和減去閾值再透過轉換函數映射出輸出值。此輸出值又當作下一層的輸入值，經逐層個別神經元之計算即可得最後之輸出值。倒傳遞學習法則是利用最陡坡降法盡可能快速改變各層神經元之權重和閾值，以降低能量函數（即誤差函數）。

$$\text{能量函數 } E = \frac{1}{2} \sum (T_j - Y_j)^2 \quad (2.4)$$

T_j ：目標值 Y_j ：網路輸出值

執行步驟是由輸出層將誤差值依序逆向回饋（倒傳遞）至前一層，計算權值修正量來更新權值及閾值，如此逐步逆向修正權值和閾值的過程，即為倒傳遞學習法則。

倒傳遞類神經網路的能量函數 E 和轉換函數 f ，可以有不同的選擇。本研究的能量函數是採用最小平方法，而轉換函數是使用雙彎曲函數。

3. 遺傳演算法：

遺傳演算法的概念首先由 Holland(1975)提出。遺傳演算法是模擬生物在自然環境中適應“生存競爭、優勝劣敗、適者生存”的競爭機制而採取的遺傳演化過程所形成的一種自適應全域最佳化 (global optimum) 的概率搜索演算法。

遺傳演算法的基本架構(圖 5)是從一組隨機產生的初始解（初始族群），族群中每個個體就是問題的每個解，這每個個體可稱為染色體，遺傳演算法對染色體計算其個別適應值並進行問題解空間的搜索。適應值大的的染色體會有較大的機會被選入基因庫。在基因庫裡的染色體，透過交配和突變兩種程序來產生新世代的染色體。透過這些程序演化數個世代，最後會使具有優良基因的染色體數量增加，而染色體是代表所求問題的解答，也就是說最後可以求得問題解空間的最佳解或近似解。

遺傳演算法和傳統最佳化演算法的不同地方是：(1)遺傳演算法是對問題解空間加以編碼，也就是對染色體進行運算。(2)多點出發進行解空間的搜

索，也就是說族群中具有多條染色體並行搜索。(3)以適應值來進行染色體的評價工作。(4)採用機率搜索，並非直線搜索。由於這些特色使遺傳演算法具有廣泛的適用性和全局優化的優點。

遺傳演算法的執行步驟：

- (1) 預備工作：決定適應函數、編碼及解碼方式並產生初始族群。
- (2) 交配(crossover)：族群中各染色體互換基因。
- (3) 突變(mutation)：將交配後的子代，根據預設的突變機率突變。突變本身是一個在參數空間亂走的隨機過程，可以開發新的搜索領域，防止收斂到局部最佳解，可探詢全域最佳解。
- (4) 計算適應值(fitness)：適應值乃BP能量函數倒數，GA為求取適應值最大化。並利用輪盤法來計算各染色體在新族群中所佔的比例。

倒傳遞類神經網路模式使以最陡坡降法沿梯度資訊方向尋求問題解空間最佳解，但搜索到最佳解需要依靠運氣，原因在於初始權值的設定不易，加上問題解空間可能過於複雜，求解過程經常容易陷入解空間的局部最小值，而無法求得最佳解。遺傳演算法採用機率搜索的方式，並採用多點出發，由於具有突變過程，因而可以增加尋獲最佳解的機會，若不能獲得最佳解時，也能找到離最佳解不遠處的解。

混合遺傳算法是透過遺傳演算法在全域上搜索並趨向問題解空間最佳解附近的解，然後再以倒傳遞類神經網路逐步搜索精確解。以適應函數來模擬倒傳遞類神經網路的評價方式，並以遺傳演算法的染色體來模擬倒傳遞類神經網路的權重和閥值組合，如此可以結合遺傳演算法和倒傳遞類神經網路兩種模式。

(四) 模式建立：將前述 44 個網格點取得因子與預報元做常態化(normalize)處理。

$$pn = (p\text{-meanp})/stdp \quad (2.5)$$

meanp : mean for each p.

stdp : standard deviations for each p.

其次以逐步迴歸挑選對預報元有顯著貢獻的因子作為預報因子，納入預報模式。(圖 6)

以 1995 年-1999 年逐日資料作為模式訓練期，其後以 2000 年-2004 年逐日資料作為模式測試期。

(五) 參數設定：

1. 倒傳遞類神經網路(BP)：

使用一個隱藏層，神經元個數為輸入預報因子個數 Log2 個。

隱藏層轉換函數使用 tansig 函數，輸出層轉換函數使用 purelin 函數。

學習率：0.01

最大失敗次數：5 次

目標梯度：1e-10

網路學習終止次數：5000 次

2. 混合遺傳演算法(GABP)：

使用 GA 尋求 BP 最佳權重及閥值組合。

BP 架構參數同前。

使用二進位加碼、解碼方式。

每一族群有 50 條染色體。

染色體長度：10

最大疊代次數：100

使用輪盤法估計適應值(1/MSE 最大)。

交配率(0.7)、突變率(0.01)。

使用精英政策。

三、結果

在日極端溫度預報方面，藉由 3 種模式測試期預報值顯示全年度來看，溫度預報在冬季模式預報值和觀測值的相關係數均可達全年度最高。但是預報誤差較小的季節卻集中在夏季附近。猜測和全年度溫度標準差分佈有關，夏季溫度逐日變化較冬季小。臺灣地區夏季僅少數時間受颱風影響，大部分時候均受太平洋高壓籠罩，天氣晴朗炎熱。冬季長時間受大陸冷高壓影響，3 至 7 天冷高壓南下影響臺灣，鋒面及寒潮爆發更深深影響本區溫度變化。

夏季溫度變化不大，因為影響此區溫度變化的因子可能為區域尺度的天氣變化所掌握，本研究所使用網格點資料解析度達 250 公里，對於此類局部地區熱對流所生雷雨等非線性小尺度天氣現象所造成極端溫度變化，理應掌握能力較差。

在訓練期及測試期可以看出 3 種模式(GABP、BP 及 SR)相關係數趨勢變化相當一致。模式訓練期階段絕大部分排列為 BP 最高，其次為 GABP，最末為 SR。顯示 BP 對於溫度變化模擬具有最高的能力。可是在測試期階段大部分月份 GABP 為最高，這個狀況在夏季時最為顯著。圖 7 日最高溫度相關係數 GABP 顯示普遍較其他模式高。基隆、台中及花蓮地區 7、8 月有較低的技術的預報，相關係數在 0.5 至 0.6。高雄地區則在 5 至 10 月，相關係數 0.5 至 0.7 之間。其餘月份相關係數都在 0.7 之上，在冬季可達 0.9。

在最低溫度的預報方面，圖 9 顯示其分佈狀況和圖 7 各地逐月分佈近似，台中地區則略有不同。GABP 模式對最低溫度預報相關係數廣泛領先其他模式，以花蓮地區 7 至 12 月可以看出。

若由日均差來看，圖 8 顯示基隆、台中、花蓮地區最高溫度日誤差 GABP 一般來說均為最低，但高雄地區 5、10 月 SR 可達最低。基隆地區最大日均差集中在 2 至 5 月誤差達 1.5°C 以上。台中地區則在 1 至 3 月達 1.5°C 以上。其餘月份在 0.9 至 1.5°C 之間。

相對而言，日最低溫度預報所得到誤差較日最高溫度預報日誤差小。圖 10 顯示各地區最低溫度預

報逐月日均差均介於 0.8 至 1.2°C 之間。在花蓮地區 6 至 9 月達最小為 0.5 至 0.7°C。

相對溫度預報而言，雨量分佈更具有不連續、零星分佈等現象，所受影響的非線性因子更多，現行天氣預報作業也僅預報降雨機率，非定量降雨預報。

台灣地區累年月平均雨量峰值多集中在夏季，這是受颱風系統影響，且夏季全島各地均有大量降雨量。冬季降雨則集中北部及東部，中南部降雨量則極少。圖 11 顯示 GABP 普遍較其中模式有較高相對係數。北部地區 8、10 月可達 0.8，中南地區相關係數 0.3 至 0.5 之間為全年最低。圖 12 顯示分區雨量日均差逐月分佈狀況和月平均降雨分佈狀況相同，誤差集中在受颱風影響季節，GABP 模式在北部及東部地區在此季節日均差明顯小於其他模式。

四、討論

由最高最低溫度預報在夏季技術較差，受小尺度天氣現象或颱風影響。有可能是颱風路徑在模式訓練期和測試期不同所致，以致於測試期預報相關係數較低。未來或可納入區域因子(使用 EOF 技術)，以增進預報模式在夏季日最高最低溫度預報穩定度。

從實驗結果來看，GABP 模式較 BP 及 SR 模式有較高的技術及較低的預報誤差，對於統計預報的業務預報具有相當高的參考價值。

致謝

本文在國科會專題研究計畫 NSC 93-2111-M-002-005、NSC 94-2111-M-002-005 和 NSC 95-2111-M-002-012 支持下完成，研究所需由中央氣象局所提供之支持，謹此致謝。

參考文獻

- 周明、孫樹棟，2005：遺傳演算法原理與應用。國防工業出版社。
- 周鵬程，2002：遺傳演算法原理與應用-活用 Matlab。全華科技圖書股份有限公司。
- 羅存文與陳重功，2003：2001 年最高/低溫統計預報結果分析。氣象學報第四十五卷，33-50 頁。
- Cavasos T., 1997 : Downscaling large-scale circulation to local winter rainfall in North-eastern Mexico . International Journal of Climatology, Vol. 17, pp. 1069–1082 。
- D. E. Rumelhart and J. L. McClelland , 1986 : Parallel Distributed Processing : Explorations in the Microstructure of Cognition , Vol. 1, MA : MITPress 。

- Draper, N. R., H. Smith, 1981 : Selecting the "best" regression equation . Applied Regression Analysis, pp. 294-352 。
- Glahn, H. R., and D. A. Lowry, 1972: The use of model output statistics (MOS) in objective weather forecasting. J. Appl. Meteor., 11, 1203-1211 。
- Hagan, Demuth and Beale : Neural network Design 。 Thomson Learning Inc.
- J.T. Schoof, S.C. Pryor , 2001 : Downscaling temperature and precipitation: a comparison of regression-based methods and artificial neural networks . International Journal of Climatology , Vol. 21, Issue 7 , pp. 773-790 。
- Kalnay, E. et al. 1996 : The NCEP/NCAR 40-year reanalysis project . American Meteorological Society, Bulletin (0003-0007). Vol. 77, no. 3, pp. 437-471 。
- Ming-Jen Yang, Ben J.-D. Jou, Shi-Chieh Wang, Jing-Shan Hong, Pay-Liam Lin, Jen-Hsin Teng, and Hui-Chuan Lin, 2004 : Ensemble prediction of rainfall during the 2000–2002 Mei-Yu seasons: Evaluation over the Taiwan area. Journal of Geophysical Research , VOL. 109 。
- Parvinder Maini, Ashok Kumar, S V Singh, L S Rathore, 2002 : Statistical interpretation of NWP products in India. Meteorological Applications. Vol. 9, pp. 21-31 。
- Wilks, D. S. 1995. Statistical methods in the atmospheric sciences. Academic Press, San Diego, CA, pp. 467 。

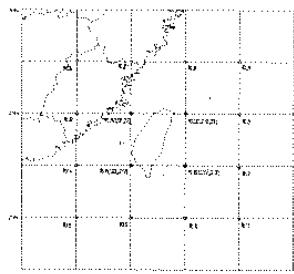


圖 1 NCEP-NCAR R2 網格點分佈

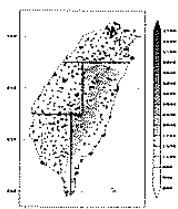


圖 2 台灣地區測站分佈及分區雨量劃分

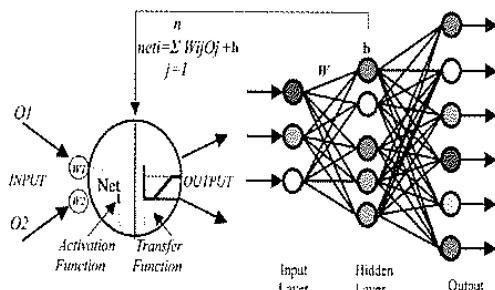


圖 3 BP 基本架構

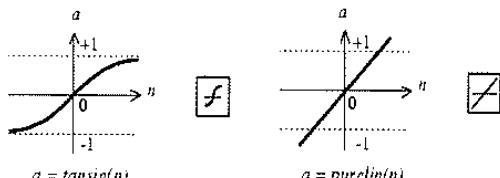


圖 4 活化函數 (activation function)

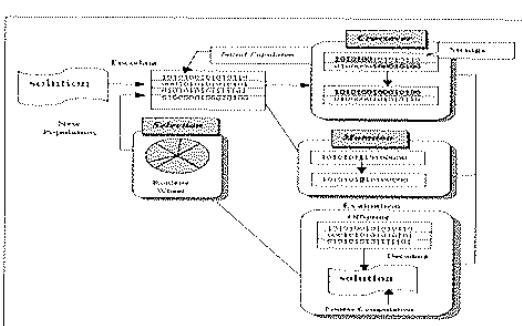


圖 5 GA 基本架構

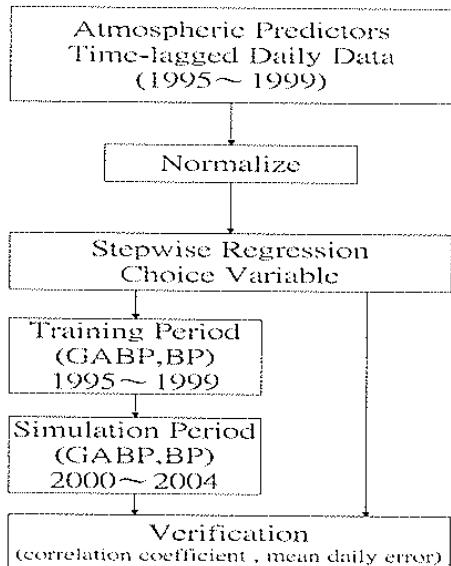


圖 6 預報模式建立流程

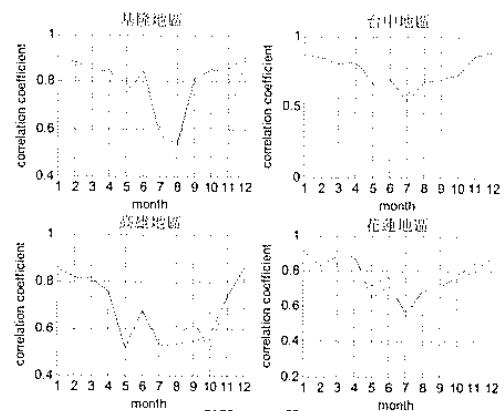


圖 7 日最高溫度測試期月平均相關係數分佈

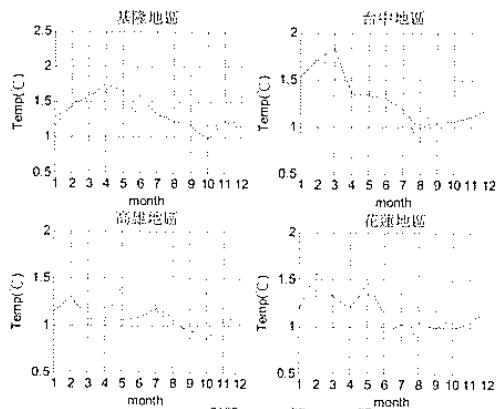


圖 8 日最高溫度測試期月平均日誤差分佈

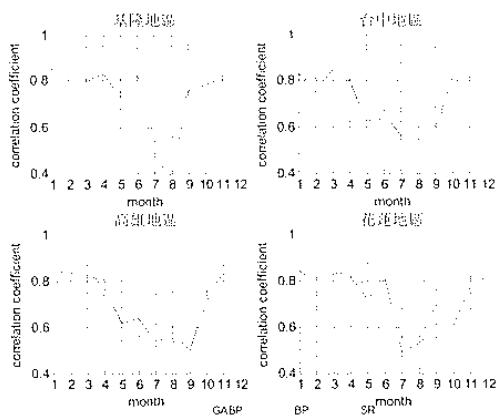


圖 9 日最低溫度測試期月平均相關係數分佈

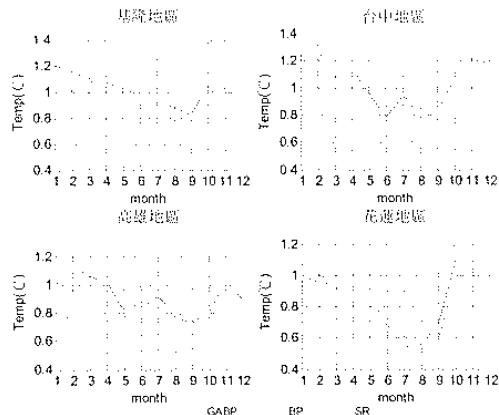


圖 10 日最低溫度測試期月平均日誤差分佈

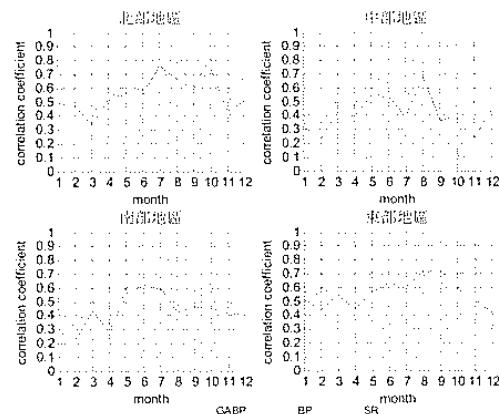


圖 11 日分區雨量測試期月平均相關係數分佈

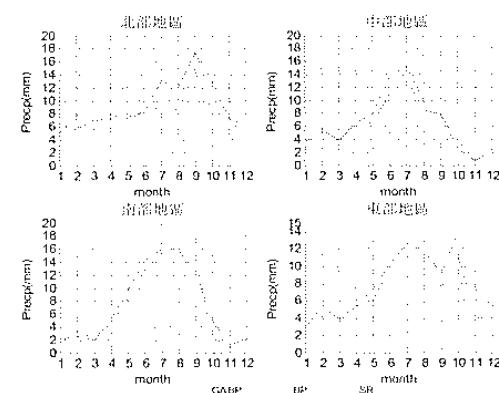


圖 12 日分區雨量測試期月平均日誤差分佈