

非線性主成份分析在台灣地區颱風降雨之初步應用

蔡孝忠

林旭信

中央氣象局氣象預報中心 中原大學土木工程學系

摘要

本研究利用非線性主成份分析法(Nonlinear Principal Component Analysis, 簡稱 NLPCA), 分析台灣地區颱風降雨的主要特徵型態, 並與具有線性假設之主成份分析法(Principal Component Analysis, 簡稱 PCA; Lorenz 1956)進行比較, 分析比較兩者之差異性。初步分析結果顯示: 使用類神經網路架構進行 NLPCA 分析, 確實可以萃取出多變量變數(如颱風降雨)的主要特徵。此外, 給定任意主成份值(p)之 PCA 空間特徵皆為固定型態, 僅有量值大小的差異; NLPCA 具有解釋非線性特徵的能力, 因此不同 p 值所對應的特徵型態可能會不同, 這將更有利於解釋多變量變數的主要特性。

一、前言

主成份分析法(PCA)經常被應用至大量資料的分析, 藉由主軸旋轉的方式, 將多變量資料進行主軸轉換, 以進行資料萃取或壓縮。PCA 假設多變量資料可藉由線性轉換, 將其重新組合為純量場(即主成份), 藉以減少資料的維度, 並根據解釋變異量的大小, 依序找出具有代表性且相互獨立的各個主要特徵。

若資料具有非線性的特徵, 或是需要更有效的資料萃取方式, 則可考慮使用非線性的分析方法。Hsieh 等人(1998)利用類神經網路(Artificial Neural Network, 簡稱 ANN)的特性, 發展了非線性主成份分析法。研究結果顯示, NLPCA 的分析結果可解釋更多的變異數, 並可有效的找出具有非線性特徵之變數的主要型態, 如 Lorenz(1963)的三維渾沌系統的特徵, 同時並實際應用至大氣及海洋現象的分析與比較, 如聖嬰現象。

有鑑於颱風降雨時空之高度非線性特徵, 本研究乃利用 NLPCA 分析方法, 分析氣象局 21 個具有長期觀測氣象站之雨量資料, 找出台灣地區颱風降雨的主要型態, 並與具有線性假設之 PCA 法比較兩者的分析結果, 分析降雨型態的差異。

二、研究方法

本研究使用 Hsieh 等人(1998)所發展具有對稱特性之類神經網路架構(請見圖 1), 進行台灣地區颱風降雨之 NLPCA 分析。該 ANN 架構中的輸入和輸出層資

料都屬於同一種多變量變數，主要是求解下列目標函數(J)之最小化問題:

$$J = \langle \| \mathbf{x} - \mathbf{x}' \|^2 \rangle$$

其中， \mathbf{x} 為輸入資料， \mathbf{x}' 為輸出資料。此一網路架構在輸入和輸出層之間採用了三個隱藏層。其中最為特別的是，整個網路架構的中間層僅有一個神經元(neuron)；將該層其稱之為瓶頸層(bottleneck layer)。藉由瓶頸層僅具有單一神經元的特性，將輸入層的多變量資料經過網路架構濃縮成單一純量；在後續計算至輸出層時，此單一純量將不容易還原成原始輸入層的型態。但是藉由此網路架構所得到的輸出值，將可表現原始輸入資料之重要特徵，即為最重要的主成份。若要繼續擷取重要性次之的主要成份，則可將先前求得的重要成份去除，然後再將資料輸入上述之網路架構進行計算。類神經網路內各項權重係數、閾值..等參數，則採用系集(ensemble)計算的方式，藉由多組的訓練及測試結果，求取最佳參數，以避免落入局部最小值(local minima)的問題(Tangang 等人 1998)。

上述之類神經網路架構除了可以求取非線性主成份(NLPC)之外，亦可求取具有線性假設的主成份(PC)。其做法僅需將類神經網路內的轉換函數(transfer function)，更換為恆等函數(identity function)，使得資料在映射(mapping)的過程中僅進行線性加總的運算，因此即可藉由圖 1 的 ANN 架構求取線性主成份。

三、使用資料

本研究採用 1987-2004 年的 JTWC 的颱風最佳路徑資料，雨量資料則是採用氣象局的 17 個具有長期觀測的氣象站；此外為了增加山區的降雨資訊，則另外在雪山山脈區域選取 4 個自動雨量站的觀測值納入分析。最佳路徑資料在經過線性內插處理成每小時的資料，並經過雨量資料的比對之後，一共約有 5000 小時的颱風各案資料可供本研究進行颱風降雨量的非線性主成份分析。

四、初步成果

本研究首先測試線性主成份(PCA)的特徵。圖 2(a)為使用 IMSL 函式庫求得之颱風降雨量第一主成份(PC1)之特徵向量(eigenvector)。由圖可知 PC1 主要是反映山區降雨特徵，如北部的竹子湖站和雪山山脈區域之測站，以及中南部的阿里山站的降雨。圖 2(b)的結果則是使用可進行 NLPCA 分析的 ANN 架構所求得之 PC1，其主成份 p 值為 8.69(最大值)，單位為 mm/hr。而圖 2(b)和圖 2(a)的降雨量空間特徵型態(pattern)相當類似，因此可確定使用圖 1 之 ANN 架構，確實可以萃取多變量變數的主要特徵。

圖 3 為颱風降雨之 NLPC1 於 3 種不同 p 值(分別為：-11.86、-2.25、0.61)所對應之空間特徵。由圖 3 可知，三種不同 p 值所對應的降雨特徵型態會有所差異。當 $p=-11.86$ (最小值)時，全台灣降雨量的最大值是出現在阿里山站；隨著 p 值的遞增，台灣山區的降雨整體來說越來越不明顯，較為顯著的局部區域已轉移至雪山山脈與北部陽明山區，相較之下，阿里山的降雨已較不明顯(圖 3(b))；而當 p

值繼續增加至 0.61 時，台灣地區降雨量已轉換至負相位(negative phase)，各測站之降雨量皆比測站平均值要來的低，其中以雪山山脈與北部陽明山區減少較多。

由以上結果可知，給定任意 p 值之 PCA 空間特徵(圖 2)皆為固定型態，僅有量值大小的差異。相較於 PCA 來說，NLPCA 具有解釋非線性特徵的能力，因此不同 p 值所對應的特徵型態可能不同。藉由單一 NLPC 的數值變化，即可顯示當 p 值相位不同時，變數在空間上所對應的不對稱(asymmetry)特徵，如圖 3 之降雨顯著區域的變化，或是 El Niño 和 La Niña 所反映的海溫距平顯著區域的位置差異(Hsieh 等人 1998 之圖 4(e)和 4(f))。

五、結論

本研究利用 NLPCA 具有解釋非線性特徵的能力，以可進行 NLPCA 分析的類神經網路架構，分析台灣地區颱風降雨之主要特徵。經分析結果顯示：不同 p 值所對應的特徵型態可能不同，此將更有利於解釋多變量變數的主要特性，進而提升分析多變量資料主要特徵的正確性。

參考文獻

- Hsieh, W. W., and B. Tang, 1998: Applying neural network models to prediction and data analysis in meteorology and oceanography, *Bull. Am. Meteorol. Soc.*, 79, 1855–1870.
- Lorenz, E. N., 1956: Empirical orthogonal functions and statistical weather prediction. Statistical Forecasting Project, Dept. of Meteorology, Massachusetts Institute of Technology, Cambridge, MA, 49 pp.
- Lorenz, E. N., 1963: Deterministic nonperiodic flow. *J. Atmos. Sci.*, 20, 130–141.
- Tangang, F. T., W. W. Hsieh, and B. Tang, 1997: Forecasting the equatorial Pacific sea surface temperatures by neural network models. *Climate Dyn.*, 13, 135–147.

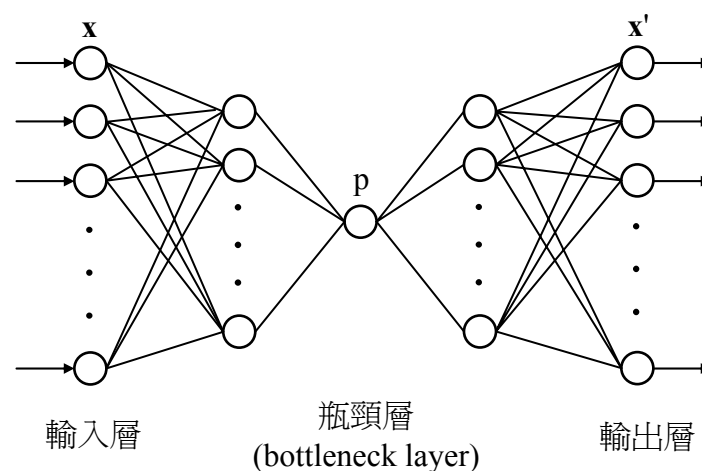


圖 1. NLPCA 所使用之類神經網路架構示意圖。其中，圖內標示之 x 為輸入資料， x' 為輸出資料， p 即為非線性主成份(NLPC)。

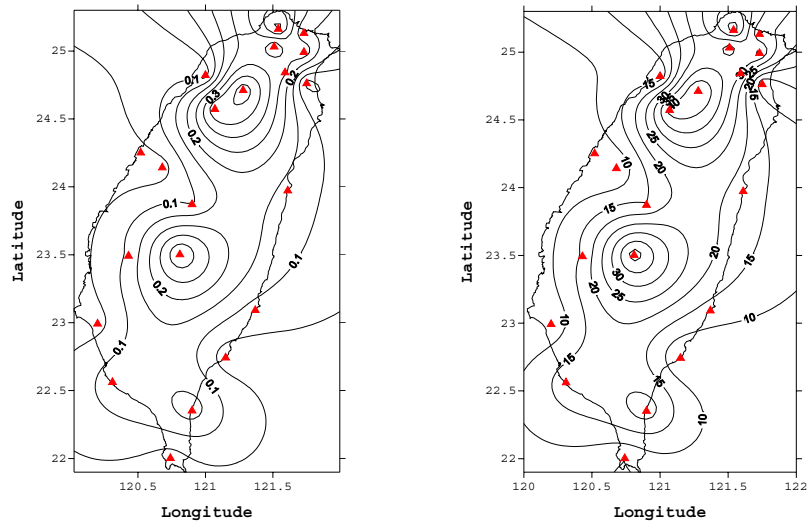


圖 2.颱風時雨量之第一主成份(PC1)特徵圖。(a)使用 IMSL 函式庫求得之颱風降雨 PC1，單位為無因次；(b)使用 ANN 架構所求得之 PC1 ($p=8.69$ ，最大值)，單位為 mm/hr。測站位置亦以三角形標示於圖中。

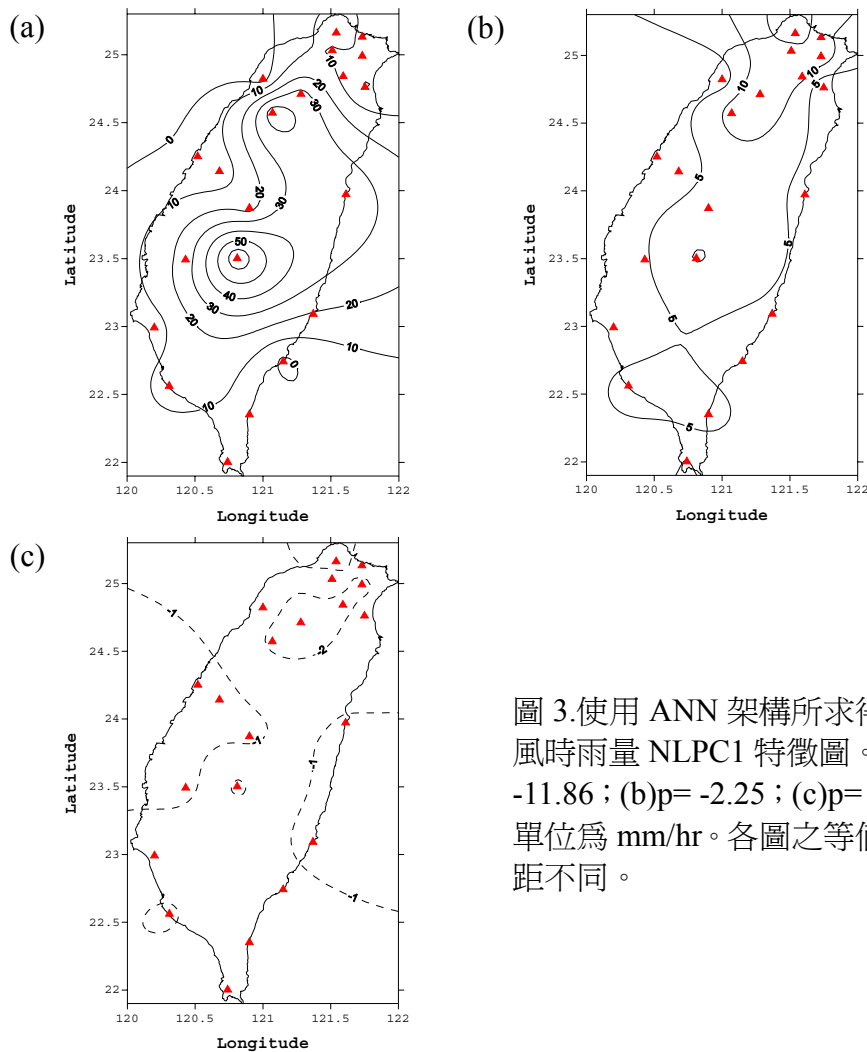


圖 3.使用 ANN 架構所求得之颱風時雨量 NLPC1 特徵圖。(a) $p=-11.86$ ；(b) $p=-2.25$ ；(c) $p=0.61$ ，單位為 mm/hr。各圖之等值線間距不同。