

應用類神經網路於氣象衛星圖中雲之識別

劉仁俊 莊金曉

大葉大學電機工程學系

(中華民國八十五年十一月二十六日收稿；中華民國八十六年六月十二日定稿)

摘 要

雲的變化為許多大自然現象的指標，因而有許多研究是投入在雲的分析上。本文提出以類神經網路的方法來進行衛星圖中雲的識別，期望能突破傳統所利用的統計或門檻法則而得到更好的結果。處理的步驟是先以奇異值分解法或K-L轉換法來擷取影像之紋理特徵，有效地利用最少的資訊來表達圖像之意義；再將擷取出來的特徵送入一屬於自組織特徵映射之KOHONEN類神經網路來作自動化雲之識別。類神經網路的技術擁有普及性、容錯能力和並行處理的優點，因此大幅提升了影像處理之速度和準確性。本文是以GMS-5紅外線衛星雲圖來作驗證，結果中清楚的說明此方法有效地彌補了傳統方法之缺點，達到相當高的辨識率和低的誤判率，且對雲圖能作到某種程度的分類，對於未來的大氣科學的研究發展應有相當的助益。

關鍵詞：類神經網路、雲識別、奇異值分解、K-L轉換法、特徵擷取、自組織特徵映射

一、前 言

雲在大氣科學中扮演了重要的角色，並且是大氣中最具特色的現象之一。他不僅影響了地表輻射的發散和反射，且能指示出許多大氣過程之現象，任何氣團的特徵，如不連續、下降、穩定或不穩定等，都反應在雲的形影，深淺，總量，以及結構上(Houghton, 1985)。因此若能對雲的特性和變化做深刻的了解與追蹤預測，則不論是在氣象學的研究上，或對大自然的預測與掌控都將會有很大的幫助。

早期人類對雲的觀測係集合各地面觀測站所得的資料來加以分析。後太空科技日益發達，以衛星影像進行雲的觀測係溯自1960年代第一個氣象衛星TIROS-1 (Television Infra-Red

Observational Satellite)升空開始(曾, 1988; Kidder et al., 1995), 衛星上裝載的儀器成功地觀測到地球上空雲系的分佈, 使人類更能以宏觀的角度來分析天氣。而之後不斷研發創新的衛星更能攜帶高科技的儀器來偵測到許多有用的資料, 使得對大氣的現象與動態能做更整體性的觀察。然而太空衛星是以三十分鐘至一小時之頻率不斷傳回對地球之掃描, 數十年來累積了龐大的資料, 遠超越一般人所能接受和消化的能力, 以致很多有用的資訊都未能善加分析利用。也由於此一原因有許多的努力投入在雲圖資料的自動化處理上。儘管在硬體的技術不斷進步, 衛星雲圖處理發展的癡結仍在於缺乏一套有效的方法來完善地分析和利用這筆龐大的資料。而分析這些資料的第一步驟就是辨識衛星影像的內容, 雲的識別自然成爲一重要課題。

傳統雲識別的方法不外統計(Statistics)或門檻(Thresholding)法則(Goodman, 1988; Rossow, 1989), 這些方法只能對此問題提出一個簡單而不嚴謹的答案, 沒有人能證實它們在各種不同環境下的適用性, 且在進入分析的過程後往往得投入大量的人力, 因此在處理速度上大打折扣。且人工的處理過程是依個人對主觀和客觀條件的認知和判斷, 但因標準的不同, 所得到的結果常造成與事實的出入。本研究之最大挑戰在雲特性的複雜和地表背景的高度變化。此兩大因素使得傳統的方法始終不能得到完整的結果。例如對紅外線感測器而言, 較低的雲層因與地表之溫度接近而難以辨識。此外, 地表上的雪和冰等其他覆蓋物, 都會對識別產生直接影響; 而可見光感測器則無法有效區別較薄的雲層。一般來說, 在海面上的背景較爲單純, 故比陸地上的雲容易識別。因此我們經常可在電視上的氣象衛星雲圖中發現陸地被誤判爲雲。

近年來由於類神經網路(Artificial Neural Networks)技術的迅速發展, 在影像處理的問題上提供了一套有效的工具, 研究結果也顯示出其處理大量資料的能力, 因此有許多傳統的問題都嘗試以類神經網路的方法來解決, 而且也能證明它真正提供了使用者另一種更迅速確實的選擇。本文的目的在提出一套完整的衛星雲圖處理工具, 不僅要彌補傳統方法在主觀和客觀上之不足, 建立精確而迅速的處理法則, 且期望能達到高度自動化的過程, 有效地以最新科技分析大量的衛星資料, 以期在不同的環境下均能獲得更可靠的結果。

圖1爲本研究所提出之雲圖識別系統流程圖。在所接收到之衛星雲圖經過定位處理之後, 進行一道紋理(Texture)特徵擷取之過程。本研究使用了常見的奇異值分解法(Singular Value Decomposition, SVD)和K-L(Karhunen-Loeve)轉換法, 此步驟不僅能縮減影像之空間, 提高處理速度, 且有利於神經網路之訓練與未來使用上之普及性。第三個步驟便爲神經網路對雲作識別的學習和訓練, 我們選用了非監督型(Unsupervised)的Kohonen網路, 其原因和特性會在文中詳加說明。此種類型的神經網路會自動進行分類的工作, 但在訓練完成之後的決策過程需對不同的輸出所代表之意義加以判斷, 最後則是進行測試與評估。

本文之內容安排如下: 第二節爲衛星影像特徵擷取之介紹; 第三節說明了類神經網路的架構和學習方法與過程, 並討論了如何應用在影像識別上; 電腦模擬的結果在第四節中提出; 而第五節則是結論。

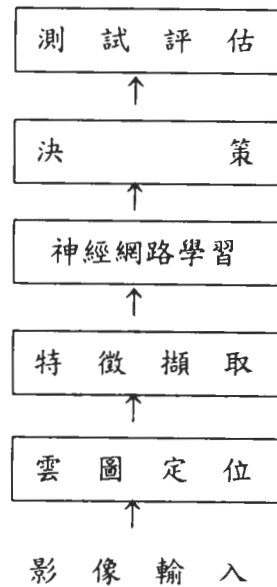


圖1 雲圖識別系統流程圖

二、特徵擷取

影像特徵擷取之目的在縮減資料空間，功能在於減少記憶體需求，提高計算速度，並排除對處理過程不必要的干擾。在影像處理和圖形識別上，這是一個重要的步驟，常見的影像壓縮也是屬於此技術的一環。特徵擷取的方法有很多種，因衛星影像的資料太過龐大，故我們選取了在壓縮上最有效率的兩種方法SVD和K-L轉換法來擷取影像特徵。

(一) SVD轉換

SVD轉換(Jain, 1989)在影像重整(Restoration)、頻譜估計(Spectrum Estimation)和資料壓縮等問題上是一種常被使用的方法。在數值分析中，是處理奇異矩陣(Singular Matrix)或方程式組等問題強而有力的工具，能以量化的方式表示出系統結構的資訊。而在影像處理上可提供最佳的能量壓縮效果。不同的影像紋理在經過此轉換之後，可擁有極大差異而產生不同的特徵。

假設有一個 $M \times N$ ($M \leq N$)的影像矩陣 X ，令 r 代表 X 影像陣列的秩(Rank)。SVD法則是使 X 成爲一對角矩陣(Diagonal Matrix)以達縮減資料的目的。若定義兩矩陣 U 、 V 使得

$$U = XX^T \quad , \quad V = X^T X \quad (1)$$

則 U 、 V 均爲不小於零的對稱矩陣 (Symmetric Matrix)，且 U 、 V 具有相同的非零特徵值 (Eigenvalue) $\lambda_1, \lambda_2, \dots, \lambda_r$ ($r = \min(M, N)$) 其中 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r$ 。若 ψ_i, ϕ_i 分別爲 U 、

V的特徵向量，則

$$\begin{aligned} \mathbf{X}\mathbf{X}^T\boldsymbol{\psi}_i &= \lambda_i\boldsymbol{\psi}_i \quad (i=0,1,\dots,M-1) \\ \mathbf{X}^T\mathbf{X}\boldsymbol{\phi}_i &= \lambda_i\boldsymbol{\phi}_i \quad (i=0,1,\dots,M-1) \end{aligned} \quad (2)$$

若將上式用矩陣形態表示，並加以比較，便可將影像矩陣X和特徵向量 $\boldsymbol{\psi}_i, \boldsymbol{\phi}_i$ 與特徵值 λ 之間的關係重新表示成

$$\boldsymbol{\Lambda} = \boldsymbol{\psi}^T \mathbf{X} \boldsymbol{\phi} \quad (3)$$

其中， $\boldsymbol{\Lambda}$ 為一由特徵值開根號所組成的(r×r)對角線矩陣

$$\boldsymbol{\Lambda} = \begin{bmatrix} \sqrt{\lambda_1} & 0 & \dots & 0 \\ 0 & \sqrt{\lambda_2} & \dots & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & 0 & \dots & \sqrt{\lambda_r} \end{bmatrix} \quad (4)$$

式(3)即稱為影像矩陣X的奇異值分解或SVD轉換。因 $\boldsymbol{\psi}, \boldsymbol{\phi}$ 均為單元矩陣(Unitary Matrix)，即 $\boldsymbol{\psi}\boldsymbol{\psi}^T = \boldsymbol{\phi}\boldsymbol{\phi}^T = \mathbf{I}$ ，故將式(3)左右移項，可得到SVD之反轉換，即

$$\mathbf{X} = \boldsymbol{\psi} \boldsymbol{\Lambda} \boldsymbol{\phi}^T \quad (5)$$

式(3)中 $\boldsymbol{\Lambda}$ 很明顯的代表了影像X的必要特徵，且隨著影像X的強度和內容改變。因此一筆M×N的資料可以用r個資料來表示，而r是遠小於M×N，資料壓縮的效果由此顯而易見。若再觀察 λ_i 的大小順序，則又能發現差距頗大，將較小的 λ_i 予以捨去，可進一步達到壓縮資料的效果。

(二) K-L轉換

K-L轉換(Jain, 1989)是由Karhunen和Loeve相繼發展出來的。此為一種線性轉換法，是依據影像的統計特性，將輸入轉換成非相關(Uncorrelated)的係數。此過程可經由將自相關矩陣(Autocorrelation Matrix)對角化來完成。而轉換後得到之特徵則無論選用多少，在經反轉換或重整(Reconstruction)後與其他任何轉換法比較都和原始影像間有最低的均方誤差(Mean Squared Error)。

假設有一個M×N的X影像，X的自相關矩陣R之元件定義為

$$R(i, j; m, n) = E[X(i, j)X^T(m, n)] \quad (6)$$

令 $\boldsymbol{\phi}_i$ 和 λ_i 為R之單位特徵向量及其對應之特徵值，其中 $i=1, 2, \dots, k$ 且 $(k=M \times N)$ ，並依序排列 λ_i ，使得 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$ ，故特徵向量 $\boldsymbol{\phi}_i$ 亦為k維向量，因此

$$\mathbf{R} \boldsymbol{\phi}_i = \lambda_i \boldsymbol{\phi}_i, \quad i=1, 2, \dots, k \quad (7)$$

依特徵值與向量特性，R可轉換成一由 λ_i 之所組成之對角矩陣，即

$$\lambda = \phi^T R \phi = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & 0 & \cdots & \lambda_k \end{bmatrix} \quad (8)$$

上式中， ϕ 為由特徵向量所組成之矩陣，其第*i*列元素為 ϕ_i ，即

$$\phi = \begin{bmatrix} \phi_1^T \\ \phi_2^T \\ \vdots \\ \phi_k^T \end{bmatrix} \quad (9)$$

且因特徵向量間互為垂直(Orthogonal)關係，故

$$\phi_i^T \phi_j = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (10)$$

式(9)中的 ϕ 是一個 $k \times k$ 階的單元矩陣，影像 X 的K-L轉換便被定義成

$$f = \phi X \quad (11)$$

f 為轉換後所產生之非相關係數，即代表了影像 X 的真正特徵。而K-L之反轉換則定義為

$$X = \phi^T f \quad (12)$$

應注意的是 f 的大小亦為 $M \times N$ ，此雖與原始數據 X 相同，但為達資料壓縮目的，只需取用前幾個值較大的部份來做處理即可，通常能僅取低於50%便能足夠表達影像所包含之資訊。

三、類神經網路學習

類神經網路的技術突破了傳統的計算法則(Freeman 1991)，以模擬人腦的動作原理，在經學習的過程之後會有辨別事物的能力。此種吸收、儲存和應用知識的方法被視為人工智慧技術的一環。而其過程即成為了影響處理結果與成效最重要的一部份。類神經網路是由許多處理元件(Processing Element)所組成的輸入層和輸出層所構成，在有些結構中會加入中間隱藏層(Hidden Layer)，層與層之間是以不同的權值(Weights)連接。輸出的計算方式一般是由不同的輸入乘上對應的權值，相加後再經過一轉換函數便可得到結果。圖2即為一典型的類神經網路架構。在輸出或隱藏層中，單一處理元件之運算法則如圖3。若輸入為 x_i ， w_i 為所對應之權值，輸出 O 則為

$$O = f\left(\sum_{i=1}^n w_i x_i\right) \quad (13)$$




圖2 類神經網路之典型結構，層與層之間是以不同大小的權值相連結。




圖3 單一神經網路元件之結構與輸出之計算法則。

f 為轉換函數，有數種不同的定義法，但最常用者為Sigmoid函數，即

$$f(\text{net}) = \frac{1}{1 + \exp(-\lambda \text{net})} \quad (14)$$

式中 λ 為大於0之常數。

決定類神經網路訓練成效的因素包括了網路的結構、學習的法則和訓練樣本的選取。在選擇網路的結構上，輸入層和輸出層處理元件的數目是由問題本身的輸入和輸出來決定。為使未來網路的使用能夠擁有普及化(Generalization)的能力，應選擇適當數目的隱藏層和其處理元件。一般來說此數目愈小愈好，以便在使用上能有良好的普及性，但較多的隱藏層處理元件能提高網路整體的記憶容量。目前尚未有通用且合適的理論來決定這個數字，一般多靠經驗來

做調整。此外，在學習的過程應提供充足的資料樣本，亦即從各種不同的情況和環境下來選取大量的影像特徵，如此才能使網路在不同的環境下學習，以增加使用時的應變能力。

神經網路的學習法則可分為監督型(Supervised)和非監督型(Unsupervised)兩種，主要的區別在於監督型學習需要對每組輸入指定相對應的輸出，亦即所謂的期望輸出值係已知；而非監督型學習則可經由網路內部自動的權值調整，來自行決定每組輸入所對應的輸出，不必在事前擔心每組輸入應有的輸出種類。在本研究中因輸入種類繁雜，且有些輸入類型不易判定，故提出以非監督式的KOHONEN神經網路來學習圖像之紋理特徵，以達到自動分類的效果。

KOHONEN神經網路僅含有輸入層和輸出層，其學習法則為一種類別聚集(Clustering)的過程，且是自組織(Self-Organization)的方式。其架構約如圖4所示。在學習的過程當中，只




圖 4 Kohonen 自組織特徵映射網路的架構，輸入為向量 x ，輸出則為方型矩陣 y 。

對和輸入向量接近的權值向量加以修正。其方法為每次載入一訓練向量以便計算各輸出神經元與其輸入向量的距離，若輸入網路的向量是 X ，權值矩陣是 W ，則勝利神經元 W_c ，可由下式決定：

$$\|X_i - W_{ic}\| = \text{Min}_j \|X_i - W_{ij}\| \quad (15)$$

式中 $\| \cdot \|$ 代表向量間之歐幾里德距離(Euclidean Distance)， i 為輸入層神經元的指標， j 則為輸出層神經元的指標。在決定 W_c 後，便對此勝利神經元及其鄰近之神經元稱為鄰域 N_c 之權值依下式來做調整，即

$$W_{ij}(t+1) = W_{ij}(t) + \alpha [X_i - W_{ij}(t)] \quad (16)$$

式中 α 為學習係數，在學習的過程中將線性遞減直到零為止，而鄰域 N_c 的大小也將線性遞減直到只剩一個勝利神經元，如此便能強化對相似向量的修正，為一種贏者全勝(Winner-Take-

All)的規則，常在非監督式或競爭型(Competitive)的學習中使用。常用的 α 和 N_c 遞減函數為

$$\begin{aligned}\alpha(t) &= \alpha\left(1 - \frac{t}{T}\right), \quad 0 < \alpha < 1 \\ N_c(t) &= N_c(0)\left(1 - \frac{t}{T}\right) + 1\end{aligned}\quad (17)$$

式中 T 為學習訓練的總次數， $N_c(0)$ 則表示鄰域半徑的起始大小， $N_c(t)$ 會隨時間 t 的增加而減少。為方便且容易了解， $\alpha(t)$ 和 $N_c(t)$ 常被合併成用一個函數 $h(N_c, t)$ 來表示，被稱為鄰域交互作用函數(Neighborhood Interactive Function)。Kohonen(1990)對鄰域半徑提出了以高斯(Gaussian)型式的定義法來模擬神經元的側向激勵作用，並得到很好的結果。即

$$h(N_c, t) = \alpha(t) \exp\left(-\frac{\|r_c - r_i\|^2}{\sigma^2(t)}\right), \quad i \in N_c(t) \quad (18)$$

式中 r_c 和 r_i 分別為勝利神經元和其周圍鄰點的位置向量， $\alpha(t)$ 和 $\sigma(t)$ 均為適當的遞減函數。權值更新的式子因此可寫成

$$W_j(t+1) = \begin{cases} W_j(t) + h(N_c, t)[X_i - W_j(t)], & j \in N_c(t) \\ W_j(t), & j \notin N_c(t) \end{cases} \quad (19)$$

這個學習法則又叫做自組織特徵映射(Self-Organization Feature Maps, SOM)，此種權值調整的方法，能使未來類似的訓練輸入樣本加強反應在同一個輸出神經元上。

四、電腦模擬結果與討論

本研究主要是利用1996年二月至四月GMS-5紅外線衛星雲圖資料來做分析。一張完整雲圖的解析度是 2291×2291 ，包含了將近半個地球的範圍。我們選取了台灣周圍 600×600 大小的區域(約東經 105 度至 140 度及北緯 5 度至 40 度)來作分析，資料來源主要是經國際網路FTP所得。

在收到原始雲圖後，我們先以海岸線特徵來做概略的雲圖定位，之後便進行特徵擷取的工作。我們分別使用了SVD和K-L法則，以比較兩者間之差別。因為一次處理 600×600 的範圍實在太大，不僅在運算上造成困擾，且特徵間易互相干擾，不易觀察出細微的現象，故在擷取特徵的過程中，先將整個雲圖分割成許多相等大小的區塊來處理。決定此雲圖區塊的大小時，必須考慮運算處理的速度和辨識的準確性等因素，因此以SVD和K-L法則所用的區塊大小會有不同。

在SVD轉換的處理時，是將整張雲圖分割成 900 個 20×20 大小的區塊，每個區塊經過式(3)的運算後便可得到如式(4)之矩陣 Λ ，所以最多可得到 20 個特徵值。此特徵值可直接送入神經網路進行學習，但若仔細觀察可發現後面幾個特徵值非常小，只要選取前 12 個較大的特徵值來

當作神經網路的輸入即已足夠。此部份已包含99%以上的影像資訊，故不會影響整體的辨識效果。至於K-L轉換則因在計算上耗費較龐大，故需使用較小的區塊，整張雲圖是分割成3600個 10×10 大小的區塊來處理。由式(6)知此計算過程將產生 100×100 的自相關矩陣，經過式(11)的轉換會產生100個特徵值，因鄰近的特徵值大小接近，我們可以固定間隔或取較大值的方式選用這些資料，以達空間縮減的目的。經測試得知取10個特徵值當作神經網路的訓練資料便已足夠。

在適當的特徵擷取出來之後，便能直接將這些資料送入神經網路來進行訓練的工作。我們在所有的雲圖資料中選取了24張較具代表性不同時間的雲圖來作訓練，訓練開始之前必須先決定類神經網路的架構，因Kohonen網路只有輸入和輸出層，這兩層的神經元數目需先加以指定。其中輸入即為特徵擷取之數量，用上述SVD和K-L的方法分別需要12和10個輸入神經元。Kohonen的法則中輸出即為分類的結果。本研究的目的雖然為辨識，在處理的結論上僅有是與不是兩種情形，但若在輸出層指定較多的輸出神經元，則會自動得到某種程度的分類效果，因此我們選擇了16個輸出神經元以便觀察神經網路對各種情況下的雲區與非雲區所可能做的分類。在訓練的方式上，一張雲圖裡的每一個小區塊的處理是各自獨立的。圖5所示為雲圖資料的訓練處理程序。每一組訓練樣本包含了24個雲圖區塊是由同一位置的不同日子或時間所組成，因此第一組訓練範例是由第一張到第二十四張的1號區塊特徵所組成，此區塊訓練完成後便繼續訓練同樣包含了二十四個範例的2號區塊，直到在SVD轉換中第900組或K-L轉換中第3600組範例訓練完成為止。




圖 5 雲圖資料的訓練處理程序，方格代表小雲圖區塊，在處理完第一區塊的第一張到第二十四張資料後才處理第二個小區塊。

表一 SVD 特徵所得之訓練結果，WINNER 表勝利輸出神經元亦即神經網路之分類結果，粗體加底線者代表無雲之狀況。

雲圖編號	0	1	2	3	4	5
WINNER	<u>2</u>	<u>6</u>	<u>2</u>	<u>14</u>	<u>15</u>	<u>15</u>
雲圖編號	6	7	8	9	10	11
WINNER	<u>7</u>	<u>3</u>	<u>10</u>	<u>0</u>	<u>15</u>	<u>9</u>
雲圖編號	12	13	14	15	16	17
WINNER	<u>5</u>	<u>0</u>	<u>0</u>	<u>4</u>	<u>15</u>	<u>9</u>
雲圖編號	18	19	20	21	22	23
WINNER	<u>12</u>	<u>15</u>	<u>10</u>	<u>10</u>	<u>15</u>	<u>1</u>




圖6 對應表一之實際小雲圖區塊。

我們分別從SVD和K-L特徵訓練的結果中，選取了一個小區塊來做說明。表一是由24張的SVD特徵輸入所得之輸出勝利神經元，圖6則為依編號排列對應的24張雲圖。Kohonen在訓練的過程中自行決定了每組輸入所對應的勝利輸出神經元(表中是以WINNER來代表)，編號是從0到15共有16個。經觀察比對後便可發現各輸出神經元所代表的種類歸屬，表中數字被標示成粗體且加上底線者表示此神經元對應的輸入區塊為背景(即晴天)，其餘的則代表該區域全部或部份為雲所覆蓋。此例中有三張為晴天，分別為第9、第13和第14張，所對應之輸出均被自動歸類到第0個神經元；而輸出神經元1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 12, 14,則是屬於有雲的

狀態。值得觀察的是有雲的幾張，網路對部份有雲和全部為雲也作了適當的分類，例如輸出神經元若為15，則屬80%以上為雲的狀況，這些是發生在第4, 5, 10, 16, 19和22張，雖然這些圖中雲的紋路有所不同，但只要增加輸出神經元的數目，分類即可更加細緻。而在整個輸出神經元中可發現第8, 11和13個神經元未被使用，這是Kohonen自動分類的結果。該法則依據所提供的訓練樣本和權值起始的設定，自行將24種的輸入分成13個種類。表二則為以K-L特徵所產生的訓練結果。第12個輸出神經元是屬於背景，而第0, 2, 3, 4, 5, 7, 8, 9, 10, 11, 14, 15則是屬於有雲的狀態。同樣的神經網路也對這些有雲的情況作了一定程度的分類。圖7為依表二排列順序所對應之雲圖。

表二 K-L 特徵所得之訓練結果，WINNER 表輸出勝利神經元亦即神經網路之分類結果，粗體加底線者代表無雲之狀況。

雲圖編號	0	1	2	3	4	5
WINNER	<u>12</u>	3	7	<u>12</u>	2	<u>12</u>
雲圖編號	6	7	8	9	10	11
WINNER	4	10	0	11	<u>12</u>	<u>12</u>
雲圖編號	12	13	14	15	16	17
WINNER	14	0	10	9	11	<u>8</u>
雲圖編號	18	19	20	21	22	23
WINNER	4	5	8	2	15	15




圖7 對應表二之實際小雲圖區塊。

另外從圖6和圖7中可以發現，背景的圖形並不完全相似，其原因可能有兩種：一、雲圖定位時的誤差，當此範圍較小時是可以被特徵擷取和神經網路容許的；二、影像亮度的均勻改變，此現象會因時間和氣候的變化而經常發生，但本文所提出的方法對此有很高的接納能力。以上兩種情況也常在傳統的處理方法中發生，但一直都被認為是相當棘手的問題，由此可證明本研究所提出方法之普及化能力。

在整體的處理結果上，我們以一張不為訓練範例的雲圖來作測試，如圖8所示，時間為1996年4月9日1332GMT。圖9和圖10則分別為圖8利用SVD和K-L特徵擷取經Kohonen神經網路測試後的雲圖辨識結果。從這些圖中可以明顯的觀察到本研究的成效。首先是有相當高的識別率(Detection Rate)，雖然這方面很難以具體而正確的數字表示，但將原始圖和結果以點與點比較估計至少達99%以上。其次是有較低的誤判率(False Alarm Rate)，這方面可由原始雲圖中間上方的海岸線觀察得知。因海洋的溫度較低而使得在圖中亮度較高並且已接近雲的亮度，但整個識別系統強調了紋理特徵的辨識，故此區域不會被誤判成雲。想要同時擁有高的識別率和低的誤判率，一直是傳統方法很難達成的目標，由本範例可知本研究確實提供了一個相當有效的方法。




圖 8 600×600 原始雲圖，時間是 1996 年 4 月 9 日 1332GMT。




圖 9 利用 SVD 特徵擷取法經 KOHONEN 神經網路訓練完成後之雲圖辨識結果。




圖 10 利用 K-L 特徵擷取法經 KOHONEN 神經網路訓練完成後之雲圖辨識結果。

若比較SVD和K-L特徵擷取所得結果之不同，則可發現K-L有較高的辨識率。使用K-L特徵擷取法因所得之自相關矩陣維度(Dimensionality)較高，故可獲得較多的特徵資訊，在神經網路訓練之後便能得到較細膩的分類結果。從許多測試中我們發覺通常以K-L的方法，背景會對同一個輸出神經元產生較高的反應，而SVD法則可能會將兩個以上的輸出神經元指定成背景。然而K-L轉換法則的缺點是花費較多的計算時間，主要也是因為自相關矩陣維度較高的關係，因此大量的時間是消耗在解特徵值的運算上。在整個雲圖辨識系統的架構中，神經網路的訓練學習步驟花費了最長的時間。但這個步驟並不需要是線上或即時的，唯一的目標就是要達到良好的訓練成效。而在使用階段的執行速度則相當的快，包含特徵擷取的運算和神經網路的辨識過程，在一台SUN Sparc10的機器上只需花數十秒的CPU時間。當然SVD方法的速度會較快。若整個運算能在針對類神經網路架構設計的並行處理器上執行，所需時間更可大幅減少。

五、結 論

本文提出了以SVD和K-L特徵擷取配合Kohonen類神經網路的方法來作雲圖的辨識，並以實際的GMS-5衛星雲圖進行驗證，其效果可從結果中明顯的觀察出來。以影像的紋理訊息來作處理，確實可以修正傳統方法以亮度為基礎之缺陷，且因類神經網路的學習能力和普及性，可提昇系統對輸入資料的包容性與容錯能力，故能得到相當好的辨識結果。而在速度的要求上，若以特殊設計的專屬並行處理硬體來執行，則能達到即時處理的目的，進一部提昇系統的效率。

雲之識別為雲圖分析的第一步驟，本研究高度自動化之結果，對更進一步之分類(Weger, etal, 1990; Lee, etal. 1990; Bankert and Aha, 1994 and 1996)和追蹤(Lure, etal. 1991; Schmetz, 1991)等工作有絕對性的助益。在能夠迅速、正確的辨識出雲的存在後，其他後續的分析才能做的更精確，更可靠，並能節省大量人力。而建立一整合的系統，直接或間接地將本文之辨識結果更深入的加以分析，可成為本研究未來之發展方向。

致 謝

感謝國科會自然處部分資助本研究計劃，計劃編號NSC85-2612-M-212-001，此外也要感謝科羅拉多州立大學大氣合作研究中心的同僚所給予的協助、建議與批評。

參考文獻

- 曾忠一，1988：大氣衛星遙測學。博海堂，台北市，630頁。
- Bankert, R. L., 1994: Cloud Classification of AVHRR Imagery in Maritime Regions Using a Probabilistic Neural Network. *Journal of Applied Meteorology*, Vol. 33, 909-918.
- Bankert, R. L. and Aha, D. W., 1996: Improvement to a Neural Network Cloud Classifier. *Journal of Applied Meteorology*, Vol. 35, 2036-2039.
- Freeman, J.A. and Skapura, D. M., 1991: Neural Networks, Algorithms, Applications and Programming Techniques. Addison-Wesley, NY.
- Goodman, A.H. and Henderson-Sellers, A., 1988: Cloud Detection and Analysis: A Review of Recent Progress. *Atmospheric Research*, 21, 203-228.
- Houghton, D.D., 1985: The Handbook of Applied Meteorology. John Wiley & Sons, NY.
- Jain, A.K., 1989: Fundamentals of Digital Image Processing. Prentice-Hall, NJ.
- Kidder, S.Q. and Vonder Haar, T.H., 1995: Satellite Meteorology, an Introduction. Academic Press, London, 466pp.
- Kohonen, T., 1990: The Self-Organizing Map. *Proceedings of the IEEE*, Vol. 78, No. 9, 1464-1480.
- Lee, J., Weger, R.C., Sengupta, S. K. and Welch, R. M., 1990: A Neural Network Approach to Cloud Classification. *IEEE Transaction on Geoscience and Remote Sensing*, Vol. 28, No. 5, 846-855.
- Lure, Y. M. F., Yeh, H. Y., and Arnold, C. P., 1991: Potential Application of Artificial Neural Network to Wind Extraction Based on Cloud Motion in Satellite Images. Proceedings of 1991 Workshop on Wind Extraction from Operational Meteorological Satellite Data, 207-220.
- Schmetz, J., 1991: Further Improvements of Cloud Motion Wind Extraction Technique. Proceedings of 1991 Workshop on Wind Extraction from Operational Meteorological Satellite Data, 15-20.
- Rossow, W.B., 1989: Measuring Cloud Properties from Space: A Review. *Journal of Climate*, 2, 201-213.

Detection of Cloud Data from GMS-5 Satellite Using Artificial Neural Networks

Ren-Jean Liou Jing-Shao Juang

Department of Electrical Engineering , Da-Yeh University

ABSTRACT

The variations of clouds indicate many global phenomena. Thus many efforts have been dedicated on cloud analysis. In this research we propose a method using artificial networks for cloud detection in the hope to obtain better results as opposed to many conventional methods, which utilize thresholding or statistical type of approaches. The process of this research first uses singular value Decomposition and Karhunen-Loeve transform to extract image textural features in addition to mean value methodologies. The extracted features are then presented of a self-organizing feature map or Kohonen network for automatic detection and classification of cloud areas. Neural network techniques have the capabilities of generalization, fault tolerance, and parallel processing which can increase the speed and accuracy of the process. We used GMS-5 satellite data in the infrared (IR) rage for demonstration. The results clearly indicate the superiority of this approach under many situations which are considered difficult for the conventional method. High detection rates and low false alarm rates were achieved. The processed results also show some interesting classification capabilities which can facilitate future studies on this topic

Key words: Artificial neural network, Cloud detection, Singular value decomposition, Karhunen-Loeve transform, Feature extraction, Kohonen self-organizing feature maps.