

類神經網路分類法之探討及其於衛星影像分類之應用

Feature Space Partitioning in Satellite Image Classification by Artificial Neural Network

台灣大學生物環境系統工程學系博士班研究生

台灣大學生物環境系統工程學系教授兼系主任

江介倫

鄭克聲

Jie-Lun Chiang

Ke-Sheng Cheng

摘 要

影像分類是遙測學中非常重要的課題，近年來蓬勃發展的類神經網路亦被用於分類而有不錯的結果，類神經網路分類屬於數學的方法，它以線、面或曲面將平面或空間中不同類別所佔的區域分隔開來，與傳統常用之統計方式較不相同，例如最大概似法即以類別發生機率之高低為分類之機制。

由於傳統依據統計原理的分類方法，例如最大概似法，需要假設各個類別在特徵空間中為 N 維（其中 N 為選用特徵數）多變數常態分佈，然而實際上各類別在特徵空間中的分佈卻不見得符合此一假設，而類神經網路利用各神經鍵不同權重的組合可以達到非線性的切割特徵空間，而且不需知道樣本點在特徵空間中分佈的型態，故近年來類神經網路理論常被應用在各領域的預測或分類問題；其中倒傳遞類神經網路的多層認知器發展完整，且據以往研究，它在分類問題中有很好的結果表現；類神經網路在環境資源領域的衛星影像分類以往也有許多研究有不錯的成果，但大多將之視為一個黑盒，鮮少探討其分類的原理與機制及特徵空間之分割，故本研究首先探討各類別樣本點在特徵空間中之分佈狀況，除了以倒傳遞類神經網路來進行衛星影像之分類外，將著重於分類問題的剖析及各類別在特徵空間中之分布，並以南投水里地區之 SPOT 衛星影像為例，探討類神經分類法與傳統最大概似法二者在特徵空間劃分之情況與分類結果。研究中顯示倒傳遞類神經網路比最大概似法有較不規則的分割邊界，較符合實際類別分佈狀況，且分類之結果明顯優於最大概似法。

關鍵詞：類神經網路，衛星影像，分類，特徵空間。

ABSTRACT

Image classification is an essential issue in remote sensing. Recently Artificial

Neural Networks (ANNs) have been shown to have good performance in Image classification.

Unlike traditional statistical methods such as the maximum likelihood classifier which assumes a multivariate normal distribution in feature space for training data, ANN methods do not require to know the distribution types in a priori. ANNs achieve high accuracy of feature space partition by assigning neuron weights using nonlinear functions.

In this study, we compare the image classification performance by the maximum likelihood method and ANN method, in terms of classification accuracy and class boundaries delineated by two methods. The results show that ANN outperformed the maximum likelihood method.

Keywords: Artificial neural network, Image classification, SPOT, Feature space.

一、前言

影像分類是遙測學中主要的課題之一，近年來衛星遙測技術發展快速，衛星影像資料的品質提高，因為其迅速且大面積的得到地面訊息的優點，使它成為環境資源方面監測的一大利器；其中分類是應用影像資料最常見的需求，也是各領域研究過程中常用的工具，雖然分類的方法很多，然而傳統的分類方法所得的結果，並未能令人滿意，也因此很多專家致力於研發新的分類方法，如近年來蓬勃發展的類神經網路亦被用於分類而有不錯的結果。

遙測影像的分類方法，傳統上大致可以分為兩類，第一類是非監督性分類法，如 k-mean 等方法；第二類是監督性分類法，如貝氏分類法 (Bayesian Classifier)、最大概似法 (Gaussian Maximum Likelihood Classifier)、最小距離法 (Minimum Distance to Means Classifier)、平行桿法 (Parallelepiped Classifier) 等等。非監督性分類是利用相似像元自然聚成一體的特性，也就是物以類聚的概念，將特徵空間中聚在一起的人群視為同一類別，在演算上乃是利用資料點聚集中心 (平均值) 之絕對距離來決定，其過程開始於一個假定的聚集平均值，然後再重複多次的分割、合併、刪除與鏈接等工作，其重複至每個聚集中心均穩定為止，亦即每一組類的平均值均收斂到不再變動為止。

監督性分類法是根據地面真值 (ground truth)，如以航空照片、像片基本圖或是其他 GIS 的主題圖等等為真值，選取影像上對應的樣區為訓練樣本，依據訓練樣本計算各組類的均數與共變異矩陣等統計值，然後檢查各組類統計值的直方圖是否合乎均質的單峰狀態，否則即去除不適當的資料，直到滿意為止，當訓練樣區監選完畢後，再依據統計值產生之機率密度函數對整個影像各像元作分類即可。

但由於一般的非監督性的分類法並無指定訓練樣區的樣本，故常常無法得到滿意的結果，所以實際應用上一般採用監督性分類法。監督性分類需要較非監督性分類法多一個選取訓練樣區的步驟，分析者必須去圈選每一種已知地表覆蓋物在影像上的確切位置，將欲分類的類別之已知樣本 (像元) 圈選在衛星影像上，以用來分類，隨著近年來衛星遙測技術發展快速，衛星影像資料的品質提高，並因為其迅速且大面積的得到地面訊息的優點，使它成為環境資源方面監測的一大利器；近年來類神經網路常被引進遙測領域，應用於地表覆蓋的分類 (Hepner, 1990)；或應用類神經網路處理 LANDSAT 衛星影像及其他空間地理資訊如地表高程、坡度、坡向等之分類 (Benediktsson et al., 1990)；也有應用類神經網路處理 LANDSAT TM 的衛星資料，而有不錯的分類正確率 (Bischof et al., 1992；Yoshida et al., 1994)




圖 2.1 傳統分類方法之特徵空間分割及其判定法則示意圖

國內亦有將之應用在衛星遙測資料之分類的研究，如利用動態學習的類神經網路在地表覆蓋分類的應用(Chen et al.,1995)；及應用非監督性類神經網路與群集分析於 SPOT 衛星影像分類，可較快速的分類且精度略微提高(94%提升為 96%)，(陳繼藩等，1997)；應用 SPOT 多光譜影像以類神經網路分析台灣彰化地區之水稻田面積(邵泰璋等，2000)；此外有林文賜等(2001)，以類神經網路為基礎發展衛星影像分類的介面。

然而國內以往雖有將類神經網路應用於衛星影像之地表覆蓋分類的研究經驗，但鮮少有針對其分類之特性，與特徵空間之切割加以探討者，因此本研究除建構適合之倒傳遞類神經網路外，並著重對於其分類之原理及特徵空間切割之特性詳加探討，並與傳統常用之最大概似法比較。

二、傳統分類理論

各類別的資料點在特徵空間中，會佔有一定的群落位置；分類問題，主要工作為將不同類別之資料點在特徵空間上分離開來，目的就是在合理有效的分割特徵空間成幾個不同區域，使之分別對應到不同的類別；以下將簡單介紹幾種傳統的分類法則：

(一)最小距離法，計算某點與各類群落中心之距離，若該點與某類中心距離最近，則判為此類；如圖 2.1(a)，A、B、C 三類別之樣本點於特徵空間中群聚之分佈位置如圖，此為最簡單的法則，其缺點為各類群落之範圍半徑不同，可能將

某類較大群落內的點誤判為中心較近的其他類別，例如圖中 X_1 點離 B 類之中心最近，因此判為 B 類，但由圖我們可知 X_1 點實際上在 A 類之範圍內。

(二)平行桿法，如圖 2.1(b)沿訓練樣本在特徵空間中的分佈在其邊緣畫出平行線為其範圍，在此線內之點即判為該類，若特徵空間中座落於如點 X_2 的位置則會發生混淆或誤判。

(三)最大概似法，首先假設各分類特徵值之分佈為常態分佈，再由訓練樣本計算每一類的共變異矩陣(Covariance matrix)、平均值向量(mean vector)，再以式(2-1)計算第 i 類中 X 出現之機率，如圖 2.1(c)在某點 X_1 或 X_2 的機率可被計算出，機率最大的類別即為該點所屬之類別。

$$p(X | C_i) = \frac{1}{(2\pi)^{\frac{d}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp\left[-\frac{1}{2}(X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i)\right] \dots\dots\dots(2-1)$$

d 為特徵數。

Σ_i 為第 i 類的共變異數矩陣。

Σ_i^{-1} 為 Σ_i 的反矩陣。

$|\Sigma_i|$ 為 Σ_i 的行列式值。

μ_i 為第 i 類的平均值向量。

$(x - \mu_i)^T$ 為 $(x - \mu_i)$ 的轉置矩陣。

X 為某樣本以特徵表示，為 d 維矩陣。

$P(X | C_i)$: 為某 X 由第 i 類而來的機率。

S_{ij} : 第 i 類與第 j 類的共變異數。

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_d \end{bmatrix} \quad \mu_i = \begin{bmatrix} \mu_{1i} \\ \mu_{2i} \\ \vdots \\ \mu_{di} \end{bmatrix}$$

$$\Sigma_i = \begin{bmatrix} S_{11} & S_{12} & S_{13} & \cdots & S_{1d} \\ S_{21} & S_{22} & S_{23} & \cdots & S_{2d} \\ S_{31} & S_{32} & S_{33} & \cdots & S_{3d} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ S_{d1} & S_{d2} & S_{d3} & \cdots & S_{dd} \end{bmatrix}$$




圖 2.2 最大似法判別說明圖

在分類時，比較出某樣本 X 在那一類類別中的機率密度函數值最大，即可判釋該樣本為那一類，最大似法分類之決策如式(2-2)所示。圖 2.2 為最大似法判別說明圖，其中以一個一維兩個類別之例子說明判別 X 該屬於第 i 類抑或第 j 類的規則。若 $X > X_0$ 時， $p(X|C_j) > p(X|C_i)$ ，則將 X 分類成第 j 類。而若 $X < X_0$ 時， $p(X|C_i) > p(X|C_j)$ ，則將 X 分類成第 i 類。而如果 $X = X_0$ 時， $p(X|C_i) = p(X|C_j)$ ，則將 X 分類成第 i 類及第 j 類的機率相等。

$$X \in C_m, m \in \{1, 2, \dots, k\}$$

if

$$P[X|C_m] = \max\{P[X|C_j], j = 1, 2, \dots, k\} \quad \dots\dots\dots (2-2)$$

由上述可知分類問題主要在於如何於特徵空間中合理有效的將各類分離，也就是說如何劃分特徵空間，而在傳統的應用上最大似法是較常用的分類方法，並且有不錯的分類正確率，因此本研究中以最大似法與類神經網路比較。

倒傳遞類神經網路已發展多年，技術十分成熟，而且應用領域十分廣泛，以往也常被用於分類問題中，據以往研究顯示，將它應用於衛星影像之分類可以有不錯之結果，因此本研究以之與傳統常用的最大似法(Maximum likelihood classification)之分類結果進行比較，除分類正確率外，本文將著重於其分割特徵空間之原理與各類別於特徵空間中分佈情形及其被分隔的狀況。以下將介紹倒傳遞類神經網路之分類原理。

由上述傳統方法可知分類問題，目的就是在合理有效的分割特徵空間成幾個不同區域，使之分別對應到不同的類別；傳統常用於分類的最大似法或貝氏分類法都是假設各類別在特徵空間呈常態分佈，但事實上我們常常不知道各類別真實的分佈，更不確定假設其為常態分佈是否合理，因此無母數(non-parametric)的方法應當比較適合採用，而類神經網路分類就是一個不需要知道各類別於特徵空間中分佈型態等統計特性的方法，故本研究擬採用類神經網路的方法來正確切割各類別在特徵空間中的分佈，並詳加探討各類分佈於空間之劃分。

3.1 類神經網路理論

類神經網路(Artificial Neural Networks, ANNs)或稱人工神經網路是模仿動物神經細胞傳遞的機制，而建構出的一種演算法，早在 1960 年以前就被提出。早期的類神經網路為單層，可以用於某些問題，被統稱為認知器(perceptrons)；後來由於應用上遇到瓶頸(單層認知器無法解決互斥或閘(XOR)的問題，Minsky, 1969)，使很多專家對類神經網路的功能與用途感到失望，因此使類神經網路沈寂了二十幾年，在倒傳遞類神經網路及其他較先進之網路系統被提出後，近幾年又掀起一股研究熱潮，由於其具有學習、記憶、與回想的功能，類神經網路被應用到，人工智慧、影像分類、股市分析、天氣預測、水文歷程等各領域均有不錯的成果，本研究後續亦以倒傳遞類神經網路為基礎架構，建構適合本研

究問題之類神經網路。

生物學上的神經網路，以人類的神經網路為例，是由龐大的（ 10^{11} 個）神經元相互連接所組成(盧炳勳等，1992)，每個神經元有接收、處理、傳輸訊號的功能，所以人類才會對刺激有所反應，而神經元包括細胞本體(cell body)、樹突(dendrites)、軸突(axon)、神經鍵(synapse)等部分，神經元間由於樹突的互相延伸及神經鍵的互相連結而連成複雜的網絡；感覺細胞受刺激訊號由神經鍵傳送到細胞本體，這些訊號相加如果超過一個量就會被激發反應並經由軸突傳送到其他神經元，最後可能做出某項反應動作。

而類神經網路正是模仿此項機制，把輸入資料經由鍵結傳到不同神經元，經過神經元裡面的激發函數做簡單的數學運算再傳導給其他神經元，處理過後最後輸出反應結果。倒傳遞(Back-Propagation)類神經網路發展已久且應用在各領域都有非常成功的經驗，也被用在一般分類問題上，它屬於監督性的學習網路；故本研究將倒傳遞類神經網路應用在衛星影像之分類。此類神經網路常用的激發函數為 S 型函數(sigmoid function)，而其架構如下圖 3.1 所示。

倒傳遞類神經網路是在 1986 年所提出來的一種多層認知網路學習法則，它可克服以往認知器僅能處理線性可分離圖樣集合之限制(林昇甫等，1993)；它主要有輸入層、隱藏層、輸出層等，而隱藏層通常有一至兩層，大部分的文獻不將輸入層算為其中一層，故有一層隱藏層的類神經網路結構，因和輸出層共有兩層，所以稱之為兩層的類神經網路，有兩層隱藏層的則稱為三層的類神經網路，其他以此類推，而網路中隱藏層之神經元數目在一些關於類神經網路之研究與書籍中有些建議值(葉怡成，1993；Zurada，1995；Haykin，1999)可供參考，但實際數目仍因應用領域及資料型態不同而有不同的架構。如圖 3.1 倒傳遞類神經網路的輸入可能來自外界，也可能是來自上一層，而這些輸入值經過權重分配後再透過激發函數產生輸出，一般倒傳遞類神經網路常用的激發函數為 S 型函數，如式(3-1)所示；倒傳遞類神經之激發函數必須在任一點可微分，S 型




圖 3.1 倒傳遞神經網路架構圖

函數符合此要求，此外由此函數可知 net 在接近 0 的部分其斜率陡，net 極大或極小時，OUT 變化緩慢，所以信號不會因為太小而被忽略，也不至於因為過大而飽和，此為 S 型函數之特點。

$$OUT = \frac{1}{1 + e^{-net}} \dots\dots\dots(3-1)$$

整個類神經網路的應用主要分為兩大部分，一為訓練部分，一為回想部分。訓練時，是以已知的訓練樣本點各特徵為輸入值，以監督式方法訓練，不斷調整權重，使得輸出值趨近於目標值，而目標值則是此樣本點的類別，待訓練完成後此組權重即被固定；且應用於回想部分，即將未知點的各特徵輸入，藉由類神經網路透過此組權重，輸出結果。就像人類學習過程一般，根據以往的經驗，判斷此組輸入資料應得的結果，由簡單二維平面之問題來看此組參數(權重)即決定了直線的截距與斜率，直線被決定後也就是類別的分界線產生，下一小節將較詳細介紹其特徵空間切割。

3.2 類神經網路特徵空間切割

若在二維特徵空間中的四個象限，分別有可能是第一類(圖 3.2 中圓形部分)或第二類別(圖 3.2 中三角形部分)，則共有如圖 3.2(a)~(p)所示 16 種可能組合情況發生，除了圖 3.2(i)與圖 3.2(j)外皆可簡單的以一條直線將兩種類別分開(如式 3-2)，圖 3.2(i)與圖 3.2(j)，則至少需要 2 條直線才能將之分離(如式 3-3、3-4)，由類神經網路之架構來看，其他狀況僅需單層認知器之架構(如圖 3.3(a))即可處理，而此二圖因兩類分別居於對角的位置，因此必須要多一層隱藏層(如圖 3.3(b))





圖 3.2 二維特徵空間兩類別區分圖



(a) 前圖 3.2(a)~(p)分離兩類所需網路架構((i)(j)除外)

(b) 前圖 3.2(i)(j)分離兩類所需網路架構

圖 3.3 二維特徵空間兩類別分類神經網路架構圖

之架構方能解決此問題，此即著名的 XOR 問題，也就是 Minsky, 1969，指出的單層認知器無法解決互斥或閘(Exclusive OR, XOR)問題。因此隱藏層概念的發展就此醞釀中，直到 1986 年較完整的倒傳遞類神經網路的架構(Rumelhart et al, 1986)被提出後，分類問題即有長足進步。

$$\omega_1 X + \omega_2 Y = \theta \quad \dots\dots\dots (3-2)$$

$$\omega_{11} X + \omega_{21} Y = \theta_1 \quad \dots\dots\dots (3-3)$$

$$\omega_{12} X + \omega_{22} Y = \theta_2 \quad \dots\dots\dots (3-4)$$

由上例可知若要解決較複雜的分類問題(如 XOR)或高維度的問題，就非僅一直線可以清楚分類，有時需要多條直線或是超平面(hyperplane)來區分各類別，所以需要增加隱藏層及不同神經

元數目。在網路架構中的輸入層方面則配合輸入資料的維度，即其特徵數目，來決定輸入單元數目；輸出單元數目則依需要之輸出結果與形式而定。

四、研究區域與影像

本研究以南投水里地區 2000 年 9 月 21 日之 SPOT 衛星影像進行分析，選取之影像範圍為 350×500 像元，如圖 4.1 所示，像元解析度為 20 公尺×20 公尺，故地面實際範圍約 7 公里 × 10 公里，即面積為 70 平方公里，研究區內多為林地，影像右上角為水里市集其中並有陳有蘭溪流貫。參考農林航測所 1999 年 11 月 18 日拍攝之 1/5000 相片基本圖選取訓練樣區，並赴現場踏勘校驗，均勻的在整幅影像上選取若干水體、林地、農田、建物、裸露地等五類地物，選取訓練樣區時盡量均勻分散在全區，如圖 4.2 所示，為客觀評估分類結果，除評估訓練樣本之混淆表外，另外選取驗證樣區評估其分類正確率，其中圖 4.2(a)與圖 4.2 (b)包含訓練樣區與驗證樣區共 2618 個像元，且兩者不重複，圖 4.2(a)與圖 4.2 (b)分別為訓練樣區(1886 個像元)與驗證樣區(732 個像元)，經由上述步驟，分別採用最大概似法與倒傳遞類神經網路進行分類，而本研究選取 SPOT 衛星(IR、R、G)三個光譜波段，共 3 項特徵，建構 3 維的特徵空間，來分析實際問題。

此外為了更加瞭解類神經網路切割特徵空間的情形，本研究除了上述分析外，並以 IR 與 R 兩個波段的影像建立的二維特徵空間進行分類，並繪出其特徵空間之分割情況加以討論。

五、結果與討論

5.1 三維特徵

將地物分為水體、林地、農田、建物、裸露地等五類，選取訓練樣區後以最大概似法與倒傳遞類神經網路分類所得結果分別如圖 5.1(a)與圖 5.1(b)所示，結果混淆表如表 5.1~表 5.4 所示，由於類神經網路需採用訓練學習的方式來調整其分類參數之權重，故若樣本太少可能造成學習成效不佳，而一般衛星影像分類所需之訓練樣本




圖 4.1 研究區域位置示意圖與 SPOT 影像



圖 4.2(a) 研究區域內所選取之訓練樣本



圖 4.2(b) 研究區域內所選取之驗證樣本

數應當已足以供類神經網路訓練學習用；其中倒傳遞類神經網路以三層（兩層隱藏層）之架構，得到的結果較佳，因為本研究採 SPOT 影像之 IR、R、G 三波段為特徵，故輸入層有 3 個處理單元，而兩隱藏層的神經元數分別以 5、6 個時較佳；以本研究所用之 3 個特徵分類得到的結果，不論用最大概似法或是以倒傳遞類神經網路進行分類皆可以得到不錯之結果，整體仍以倒傳遞類神經網路有較高之準確率，就訓練樣本來看，以倒傳遞類神經網路分類之整體正確率可達到 93.16%，在驗證資料中其正確率亦可達到 93.85%，皆分別高於最大概似法的 89.08%及 90.30%；故倒傳遞類神經網路分類法，有其優越性。

表 5.1 最大概似法分類於訓練樣本之混淆表(3 維)

分類類別 \ 實際類別	水體	林地	農田	建物	裸露地	總和	使用者正確率%
水體	355	0	0	28	40	423	83.92
林地	0	706	9	0	0	715	98.74
農田	0	27	255	0	2	284	89.79
建物	9	0	0	202	23	234	86.32
裸露地	18	0	3	47	162	230	70.43
總和	382	733	267	277	227	1886	
生產者正確率%	92.93	96.32	95.51	72.92	71.37	總體正確率% :	89.08

表 5.2 最大概似法分類於驗證資料之混淆表(3 維)

分類類別 \ 實際類別	水體	林地	農田	建物	裸露地	總和	使用者正確率%
水體	201	0	0	7	14	222	90.54
林地	0	144	5	0	0	149	96.64
農田	0	23	134	0	3	160	83.75
建物	0	0	0	90	0	90	100.00
裸露地	8	0	0	11	92	111	82.88
總和	209	167	139	108	109	732	
生產者正確率%	96.17	86.23	96.40	83.33	84.40	總體正確率% :	90.30

表 5.3 倒傳遞類神經網路分類於訓練資料之混淆表(3 維)

分類類別 \ 實際類別	水體	林地	農田	建物	裸露地	總和	使用者正確率%
水體	353	0	0	7	26	386	91.45
林地	0	722	2	0	0	724	99.72
農田	0	11	265	0	0	276	96.01
建物	13	0	0	249	33	295	84.41
裸露地	16	0	0	21	168	205	81.95
總和	382	733	267	277	227	1886	
生產者正確率%	92.41	98.50	99.25	89.89	74.01	總體正確率% :	93.16

表 5.4 倒傳遞類神經網路分類於驗證資料之混淆表(3 維)

分類類別 \ 實際類別	水體	林地	農田	建物	裸露地	總和	使用者正確率%
水體	201	0	0	1	7	209	96.17
林地	0	150	0	0	0	150	100.00
農田	0	17	137	0	1	155	88.39
建物	2	0	0	100	2	104	96.15
裸露地	6	0	2	7	99	114	86.84
總和	209	167	139	108	109	732	
生產者正確率%	96.17	89.82	98.56	92.59	90.83	總體正確率% :	93.85



圖 5.1(a) 最大概似法分類結果



圖 5.1(b) 倒傳遞類神經網路分類結果

表 5.5 最大概似法分類於訓練樣本之混淆表(2 維)

分類類別 \ 實際類別	水體	林地	農田	建物	裸露地	總和	使用者正確率%
水體	354	0	0	20	53	427	82.90
林地	0	682	10	0	0	692	98.55
農田	0	51	251	0	3	305	82.30
建物	10	0	0	226	28	264	85.61
裸露地	18	0	6	31	143	198	72.22
總和	382	733	267	277	227	1886	
生產者正確率%	92.67	93.04	94.01	81.59	63.00	總體正確率% :	87.80

表 5.6 最大概似法分類於驗證資料之混淆表(2 維)

分類類別 \ 實際類別	水體	林地	農田	建物	裸露地	總和	使用者正確率%
水體	203	0	0	6	20	229	88.65
林地	0	143	3	0	0	146	97.95
農田	0	24	136	0	3	163	83.44
建物	0	0	0	92	2	94	97.87
裸露地	6	0	0	10	84	100	84.00
總和	209	167	139	108	109	732	
生產者正確率%	97.13	85.63	97.84	85.19	77.06	總體正確率% :	89.89

表 5.7 倒傳遞類神經網路分類於訓練資料之混淆表(2 維)

分類類別 \ 實際類別	水體	林地	農田	建物	裸露地	總和	使用者正確率%
水體	352	0	0	7	30	389	90.49
林地	0	720	4	0	0	724	99.45
農田	0	13	263	0	1	277	94.95
建物	13	0	0	250	37	300	83.33
裸露地	17	0	0	20	159	196	81.12
總和	382	733	267	277	227	1886	
生產者正確率%	92.15	98.23	98.5	90.25	70.04	總體正確率% :	92.47

表 5.8 倒傳遞類神經網路分類於驗證資料之混淆表 (2 維)

分類類別 \ 實際類別	水體	林地	農田	建物	裸露地	總和	使用者正確率%
水體	200	0	0	0	7	207	96.62
林地	0	151	3	0	0	154	98.05
農田	0	16	136	0	0	152	89.47
建物	2	0	0	101	3	106	95.28
裸露地	7	0	0	7	99	113	87.61
總和	209	167	139	108	109	732	
生產者正確率%	95.69	90.42	97.84	93.52	90.83	總體正確率% :	93.85

5.2 二維特徵

經由上述步驟，為便於瞭解特徵空間推估之特性與結果，除上述以三特徵(IR、R、G)分類外，選取 SPOT 衛星 IR 與 R 波段為特徵，並分別採用最大概似法與類神經網路法進行分類，此時類神經網路之輸入層處理單元數為 2，隱藏層層數

為 2，其內分別有 3、4 個神經元。僅看 IR 與 R 兩特徵時，最大概似法與倒傳遞類神經網路所得結果混淆表，分別如表 5.5~表 5.8 所示，以此 2 特徵分類得到的結果，在最大概似法時，不論是訓練樣區或驗證樣區其分類總體正確率均接近九成，已有不錯之結果，其中最大概似法在裸露

表 5.9 分類精度總表

方法與資料	水體	林地	農田	建物	裸露地	總體
最大概似法(訓練樣本, 3 維)	92.93	96.32	95.51	72.92	71.37	89.08
最大概似法(驗證資料, 3 維)	96.17	86.23	96.40	83.33	84.40	90.30
倒傳遞類神經網路(訓練樣本, 3 維)	92.41	98.50	99.25	89.89	74.01	93.16
倒傳遞類神經網路(驗證資料, 3 維)	96.17	89.82	98.56	92.59	90.83	93.85
最大概似法(訓練樣本, 2 維)	92.67	93.04	94.01	81.59	63.00	87.80
最大概似法(驗證資料, 2 維)	97.13	85.63	97.84	85.19	77.06	89.89
倒傳遞類神經網路(訓練樣本, 2 維)	92.15	98.23	98.5	90.25	70.04	92.47
倒傳遞類神經網路(驗證資料, 2 維)	95.69	90.42	97.84	93.52	90.83	93.85




圖 5.2(a) 各類訓練樣本點於二維特徵空間之分佈




圖 5.2(b) 最大概似法分類所得各類於二維特徵空間之分佈

地之正確率不甚理想，以訓練樣本為例，此類正確率為 63%明顯比其他類別要低，而倒傳遞類神經網路在此類之正確率仍可達到 70.04%。

5.3 特徵空間之探討

首先將訓練樣區各類別資料點繪於二維特徵空間中，如圖 5.2(a)所示，可知各類別在二維特徵空間中之分佈呈非等向狀態，並以最大概似法及類神經網路法推估出此二維特徵空間之所有點位應該指定之類別，分別如圖 5.2(b)與圖 5.2(c)所示，由此圖可以發現因為最大概似法假設各類別為二次常態分佈（因在二維特徵空間中），所以它所推估出的特徵空間各類別的邊界，在二維特徵空間中屬二次式，比較規整（如圖 5.2(b)），而類神經網路法之推估，可依訓練樣本空間分佈結構推估得到未知點位應屬類別，故可以在特徵空間中，畫出各類別之不規則邊界（如圖 5.2(c)）；由推估出之二維特徵空間各類別分佈圖可以更具體瞭解類神經網路法分類之原理。




圖 5.2(c) 倒傳遞類神經網路分類所得各類於二維特徵空間之分佈

最後由分類總表(表 5.9)，可以明顯看出倒傳遞類神經網路分類結果無論在二維或三維特徵時皆可以得到較好的結果，在訓練資料與驗證資料上，倒傳遞類神經網路皆明顯比最大概似法有較高的正確率，就訓練樣本來看，在倒傳遞類神經網路分類法之總體正確率可達到 92.47%，在驗證資料中其正確率亦可達到 93.85%，皆高於最大概似法的 87.80%及 89.89%；故倒傳遞類神經網路分類法，有其優越性。

六、結論建議

本研究由最大概似法與倒傳遞類神經網路法分類過程與結果探討此二方法分類之原理與機制，且比較各類別於特徵空間之分佈，結果以倒傳遞類神經網路為基礎的分類法無論在二維特徵或三維特徵之分類，在訓練樣本及驗證樣本上都有良好之正確率，皆優於最大概似法，總體正確率皆在九成以上。

傳統最大概似法需假設各類別在特徵空間中呈常態分佈，故所推估出之特徵空間中不同類別間之邊界較為規整，與實際狀況不符，以倒傳遞類神經網路分類所得之不規則邊界應該較符合實際問題，所以會有較佳之分類正確率。以倒傳遞類神經網路進行分類為近年來蓬勃發展的方法，它不需要假設各類別在特徵空間為多變數常態分佈或是其他分佈，不同於以往以統計理論為基礎之分類，它以超平面分割特徵空間中各類別所佔有之區域，且應用於衛星影像之分類有不錯的結果，其優點為可以輕易分析至多維度的特徵空間；由倒傳遞類神經網路分析二維特徵空間中各類別之分佈，可以幫助吾人對各類別於特徵空間上之分佈有清晰的瞭解，進而可以對倒傳遞類神經網路之分類功能有更深刻的認識，可以較明瞭其分類的運作機制，另由簡單的二維空間中兩類別的分類，可以較清楚參數之意義，而不再只將其視為一黑盒。

參考文獻

- Benediktsson, J.A., Philip H. Swain and Okank Ersoy, Neural Network Approaches Versus Statistical Methods in Classification Remote Sensing Data, IEEE Transactions on Geoscience and Remote Sensing, 28(4), pp. 540-551, 1990.
- Bischof, H., W. Schneider, and A. J. Pinz, Multispectral Classification of Landsat-Images Using Neural Networks, IEEE Transactions on Geoscience and Remote Sensing, Vol.30, No.3, pp.482-490, 1992.
- Chen, K. S., Y. C. Tzend, C. F. Chen, and W. L. Kao, Land-Cover Classification of Multispectral Imagery Using a Dynamic Learning Neural Network, Photogrammetric Engineering and Remote Sensing, Vol.61, No.4, pp.403-408, 1995.
- Haykin, Simon, Neural Networks a comprehensive foundation second edition, Prentice hall,1999.
- Hepner, G.F., Thomas Logan, Niles Ritter and Nevin Bryant, Artificial Neural Network Classification Using a Minimal Training Set: Comparison to Conventional Supervised Classification., Photogrammetric Engineering and Remote Sensing, Vol. 56, No. 4, pp. 469-473, 1990.
- Minsky M., Semantic Information Perceptrons, Cambridge MA: MIT Press, 1969.
- Rumelhart, D.E., Hinton, G.E., and Williams, R.J., Learning internal representations by error propagation, In Parallel distributed processing, vol.1, Cambridge, MA: MIT press,1986.
- Yoshida, Tomoji and Sigeru Omatu, Neural network approach to land cover mapping. IEEE Transactions on Geoscience and Remote Sensing, Vol.32, No.5, pp.1103-1109, 1994.
- Zurada, Jacek M., Introduction to Artificial Neural System, PWS publishing company, 1995.
- 林昇甫、洪成安，神經網路入門與圖樣辨識，全華科技圖書股份有限公司，1993年9月。
- 林文賜、周天穎、林昭遠，應用監督性類神經網路於衛星影像分類技術之探討，航測及遙測學刊，第六卷，第一期，pp.41-58，April 2001。
- 邵泰璋、史天元，類神經網路於多光譜影像分類之應用，航測及遙測學刊，第五卷，第一期，pp.1-14，March 2000。
- 陳繼藩、徐守道、陳世旺，應用非監督性類神經網路於 SPOT 衛星影像分類之研究，航測及遙測學刊，第二卷第一期，pp.1-12，1997。
- 葉怡成，類神經網路模式應用與實作，儒林，1993。
- 盧炳勳、曹登發，類神經網路理論與應用，全華科技圖書股份有限公司，1992年3月。

收稿日期：民國 92 年 11 月 19 日
修正日期：民國 92 年 12 月 28 日
接受日期：民國 93 年 1 月 6 日