

植生指標對影像分類準確度影響之研究

林世峻⁽¹⁾ 莊智瑋⁽²⁾ 何世華⁽²⁾ 林昭遠⁽³⁾

摘要

影像分類時易受空間解析度、波譜解析度等影響，進行分類時，加入輔助特徵值如(NDVI、CMFI)可稍有效提升影像精度。本研究以南投縣九份二山為研究試區，以最大概似法(Maximum-Likelihood Decision Rule)和倒傳遞類神經網路(Back Propagation Neural Network)進行影像分類之探討，結果顯示，除倒傳遞類神經網路搭配原始波段加入NDVI外(Kappa為0.5954)，加入植生指標均可稍微提升分類精確度；在分類模式整體比較上，倒傳遞類神經網路稍優於最大概似法，但差距甚微。

(**關鍵詞**：植生指標、倒傳遞類神經網路、最大概似法、影像判釋)

Effect of the Vegetation Index on the Accuracy of Image Classification

Shih-Chu Lin⁽¹⁾, *Chin-Wei Chuang*⁽²⁾, *Shia-Hua HO*⁽³⁾

Graduate Student, Department of Soil and Water Conservation,
National Chung-Hsing University, Taichung 402, Taiwan, R.O.C.

Chao-Yuan Lin⁽⁴⁾

Professor, Department of Soil and Water Conservation,
National Chung-Hsing University, Taichung 402, Taiwan, R.O.C.

ABSTRACT

The accuracy of image classification is easily influenced by the image's spatial and spectrum resolution. Feature values extracted from the image can be used effectively to promote the accuracy of the classification. Chiufenershan landslide area in Nantou County was chosen as the study site. The improvement of image classification can be achieved by using the maximum-likelihood decision rule and the back-propagation neural network after adding the calculation of the vegetation index.

-
- (1) 國立中興大學水土保持學系碩士研究生
 - (2) 國立中興大學水土保持學系博士班研究生
 - (3) 國立中興大學水土保持學系教授

The results show that vegetation index can increase the accuracy of image classification , and the back-propagation neural network is better than maximum-likelihood decision rule in the performance of image classification by using vegetation index except NDVI (When Kappa is 0.5954).

(Keywords : Vegetation index, Back Propagation Neural Network, Maximum-Likelihood Decision Rule, Image Classification)

壹、前言

傳統調查方法常需花費大量人力、物力、時間及金錢，加上經費有限、人力不足、調查區域範圍廣大，常造成結果不如預期理想。隨著科技進步，傳統調查方式逐漸被遙測技術所取代，常以拍攝之多光譜影像來獲取地面資訊。

目前國內外學者針對影像判釋紛紛提出不同研究及應用。如廖軒吾（2000）利用影像比較法進行崩塌區位判釋；黃筱梅（2001）利用多種不同植生指標進行植生變遷之研究；黃凱易及張偉顛（1997）使用植生指標法及主成份分析法進行東勢林區大甲溪事業區之林地進行被覆變遷偵測。林昭遠等（2001）則利用不同時期衛星影像之 NDVI 差值，進行崩場地植生監測與評估，提出植生復育率（VRR），可量化檢測崩場地植生恢復情形。

因此，如何利用以多光譜影像配合有效分類方法乃是目前遙測判釋重要課題之一。本研究選以九份二山為研究區域，利用人工智慧中之倒傳遞類神經網路及統計方法中之最大概似法來進行影像判識，並加入不同植生指標，如 NDVI、CMFI 等，探討分類精確度，其結果供日後進行影像分類或植生變遷分析之參考。

貳、研究試區

九份二山地位於南投縣國姓鄉崁斗山山麓一帶，韭菜湖溪自南往北於崩塌處與支流澀仔坑溪匯流，匯流處已被土石掩埋。長石巷地區崩塌範圍北起太平角海拔 650 公尺至崁斗山南稜海拔 1040 公尺，沿順向坡向東南崩塌，南屆韭菜湖溪堰海拔 530 公尺，東起崁斗山南稜，西迄中興橋前，全區呈西北向東南傾斜約 28 度。

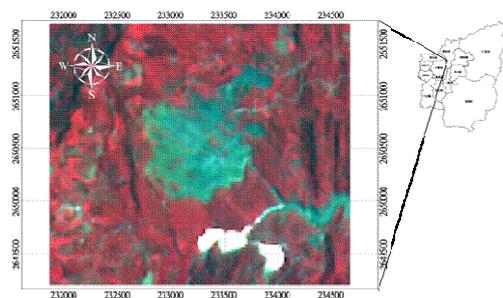


圖 1. 研究區域位置圖（2004.07.12）
Figure 1 . Site of the study area.

參. 研究材料與方法

一、研究流程

首先蒐集試區內之衛星影像，將蒐集之衛星影像進行植生指標之計算（NDVI 及 CMFI），並將其與原始波段進行合併，建立影像資料庫，供後續訓練樣本選取及判釋使用。再以 Erdas Imagine 影像軟體進行訓練樣本選取，分別選取植被、裸露地及水域三

類，並進行合併，最後帶入倒傳遞類神經網路進行訓練樣本，當網路非收斂時則重新訓練，直到收斂為止；最後帶入合併後影像進行驗證網路，並進行精確性評估，且與統計分類方法之最大概似法進行比較，探討兩者之優缺點。研究流程圖如圖 2 所示。

二、材料

法國 SPOT 衛星影像，其為太陽同步衛星，掃瞄寬度為 60 公里，空間解析度則依不同衛星有所不同（表 1）。因九份二山位屬山區，易受雲層及陰影影響，為力求分析之精確性，其影像因避免雜訊之干擾，故本研究選用 2004 年 7 月 12 日之 SPOT 4 多光譜態 XI 衛星影像為研究材料。

三、方法

(一) 植生指標 (Vegetation index, VI)

1. Cropping management factor index (CMFI)

SPOT 衛星影像感測器所接收的波段為綠光、紅光及近紅外光，且綠色植物具有吸收藍光、紅光及強烈反射紅外光之特性，利用

此原理可計算常態化差異植生指標 (NDVI)。其值介於-1~1 之間，NDVI 小於零，屬非植生之雲層、水域及陰影等；值愈大時，代表地表植物生育愈旺盛、植被覆蓋佳 (Burgan and Hartford, 1993)。為配合作物及管理因子 (C) 之合理值域 (0~1)，即當植生覆蓋愈差，所對應之土壤覆蓋因子愈大的條件下。將其線性反向配置為作物及管理因子指標 (CMFI)，其公式為：

$$CMFI = \frac{R}{NIR + R} = \frac{1}{2} \left(1 - \frac{NIR - R}{NIR + R} \right)$$

式中，R 為紅光；NIR 為近紅外光。

2. Normalized difference vegetation index (NDVI)

Rouse et al. (1973) 第一次提出 NDVI 的概念，NDVI 的定義為近紅外光波段與紅光段的差值除以兩者之和 (Elvidge & Chen, 1995)。NDVI 的數值分布在 -1 至 1 之間，對於有植被分布的地方來說，會有較高的 NDVI 值，因為有植被分布的地方具有較高

表 1. SPOT 衛星空間解析度與感測器光譜模式
Table 1. The spatial resolution and sensor bands of SPOT image.

衛星代號	感測器	光譜模式	空間解析度
SPOT-1~3	HRV	全色態 PAN	10 m
		多光譜態 XS	20 m
SPOT-4	HRV	單色態 M	10 m
		多光譜態 XI	20 m
		全色態 HM	5 m
SPOT-5	HRG	超解像模式 THR	2.5 m
		多光譜態 HI	10 m

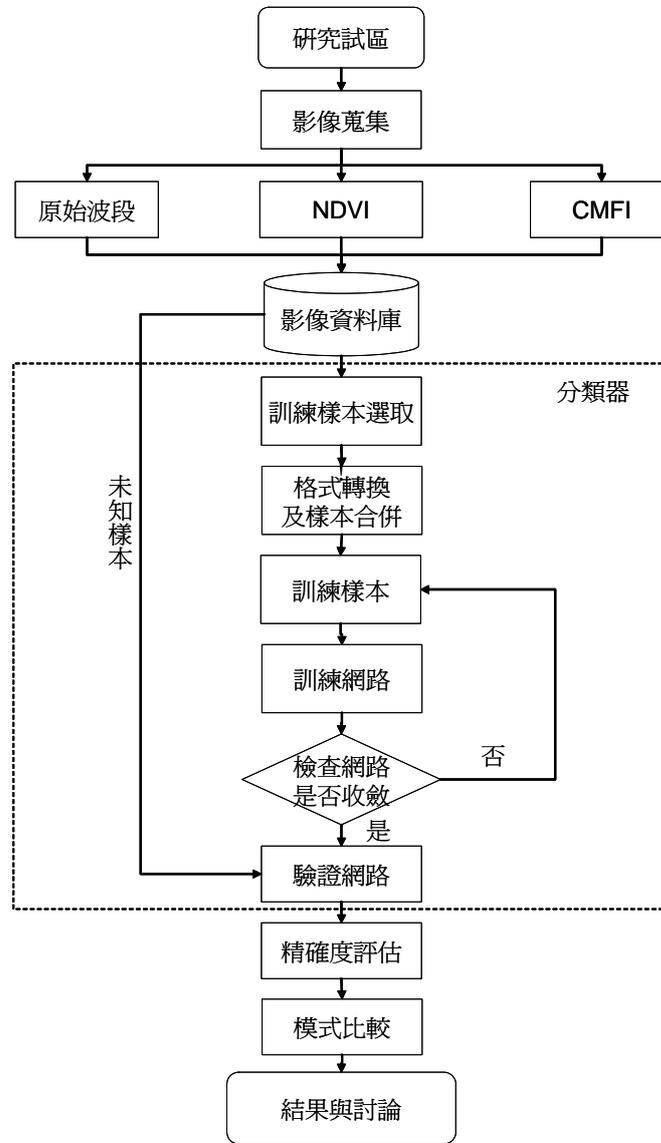


圖 2. 研究流程圖
 Figure 2. Flowchart of the study.

的近紅外光段反射與較低的紅光段反射，如果是在植被分布密集的地方，NDVI 的數值在 0.1 到 0.6 之間變動，其數值取決於植物頂部的密度與綠度。土壤與岩石會產生近乎於 0 的數值，因為這兩者在紅光段與近紅外

光段的數值相近，水、雲與雪會有數值比近紅外光段較高的紅光段，所以會產生負值。

$$NDVI = \frac{NIR - R}{NIR + R}$$

式中，R 為紅光；NIR 為近紅外光。

(二) 分類方法

1. 倒傳遞類神經網路 (Back-propagation Neural Network, BPNN)

倒傳遞類神經網路的結構 (圖 3) 分為三層：分別為輸入層 (input layer)、隱藏層 (hidden layer)、輸出層 (output layer)。其中輸入層的神經元數目即為輸入變數的個數；隱藏層的層數與神經元的個數視問題複雜性而有所調整，並無一定的層數或個數，一般多採以 (輸入層+輸出層) / 2；輸出層神經元數即為輸出變數的個數。採用訓練學習次數為 6000 次、植被選取次數為 490、裸露地選取次數為 219、水域選取次數為 114。運算基本原理中主要是利用最陡坡降法 (the gradient steepest descent method) 的觀念，將誤差函數值予以最小化，目的為降低輸出單元實際輸出值與目標輸出值間的差距 (葉怡成，2003)。而倒傳遞類神經網路運作流程共可分為兩階段，一為學習階段，另一為回想階段。

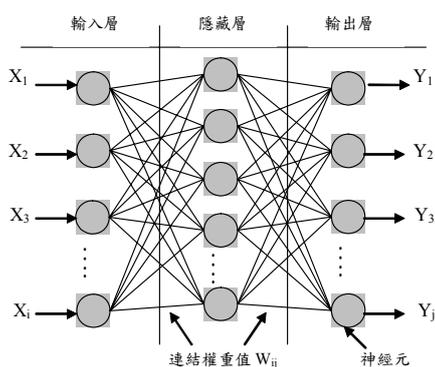


圖 3. 倒傳遞類神經網路架構圖
Figure 3. The structure of Back Propagation Neural Network.

(1)學習階段：

a.計算輸出變數

$$net = \sum W * X - \theta$$

$$Y = f(net) = \frac{1}{1 + \exp^{-net}}$$

式中，W 是各節點間權重值，X 是輸入值，θ 是閾值，net 是淨值，f 是轉換函數，Y 是輸出值。

b.誤差函數值，

$$E = \frac{1}{2} \sum (T - Y)^2$$

式中，E 是誤差函數值，T 是目標值。

c.計算權重值修正量，

$$W^{n+1} = W^n + \alpha * \Delta W$$

$$\theta^{n+1} = \theta^n + \alpha * \Delta \theta$$

式中，α 是慣性項。

d.重複步驟 a~c 直到符合下列之一項條件。

- (a)誤差函數值 E 收斂；
- (b)達到設定目標值；
- (c)重複執行到一定次數。

(2)回想階段：

- a.輸入全區資料，
- b.計算並輸出各點回想值。

2.最大概似法 (maximum-likelihood decision Rule)

通常假設影像之分類特徵具有多變量常態分佈。計算訓練樣區每一類的共變異矩陣

(Covariance matrix) 、平均向量 (mean vector) ，再計算第 i 類中 X 出現之機率，以進行分類。其公式如下。

$$P(X|i) = (2\pi)^{-\frac{d}{2}} |\sum_i|^{-\frac{1}{2}} \exp\left[-\frac{1}{2}(X-\mu_i)^T \sum_i^{-1}(X-\mu_i)\right]$$

式中 d 為特徵數；

\sum_i 為第 i 類的共變異數矩陣；

$$\sum_i = \begin{bmatrix} S_{11} & S_{12} & S_{13} & \wedge & S_{1d} \\ S_{21} & S_{22} & S_{23} & \wedge & S_{2d} \\ S_{31} & S_{32} & S_{33} & \wedge & S_{3d} \\ M & M & M & O & M \\ S_{d1} & S_{d2} & S_{d3} & \wedge & S_{dd} \end{bmatrix}$$

\sum_i^{-1} 為 \sum_i 的反矩陣；

$|\sum_i|$ 為 \sum_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；

$$X = \begin{bmatrix} X_1 \\ X_2 \\ M \\ X_d \end{bmatrix} \quad \mu_i = \begin{bmatrix} \mu_{1i} \\ \mu_{2i} \\ M \\ \mu_{di} \end{bmatrix}$$

X 為某樣本以特徵表示，為 d 維矩陣；

$P(X|i)$ ：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。

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，最大概似法分類之決策如下所示。矩陣中選擇最大的值，並將 X 指定為該類別。

$$X \rightarrow \left\{ \begin{array}{l} P(X | 1) \rightarrow \\ P(X | 2) \rightarrow \\ P(X | 3) \rightarrow \\ \wedge \wedge \\ P(X | r) \rightarrow \end{array} \right.$$

茲以圖4 (一維二類別為例) 說明判別 X 該屬於第 i 類或第 j 類的規則。

(1) 若 $X > X_0$ 時， $P(X|j) > P(X|i)$ ，則將 X 分類成第 j 類；(2) 若 $X < X_0$ 時， $P(X|i) > P(X|j)$ ，則將 X 分類成第 i 類；(3) 若 $X = X_0$ 時， $P(X|i) = P(X|j)$ ，則將 X 分類成第 i 類及第 j 類的機率相等。

機率密度函數

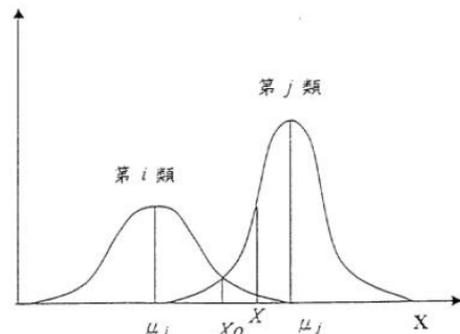


圖 4. 最大概似法示意圖

Figure 4. The diagram of Maximum-Likelihood Decision Rule.

(三) 精確度評估

一般精確度評估的方法常見有四種，分別為整體精度 (Overall Accuracy)、生產者精度 (Producer's Accuracy) 及使用者精度 (User's Accuracy)，以及 Kappa 係數；生產者精度又稱為 Omission Accuracy，是應分入該組類而未分入之誤差 (漏授)；使用者精度

又稱為Commission Accuracy，則為不該分入該組類而分入該組類所造成之錯誤（誤授）。而Kappa係數因具有考量誤授及漏授關係，故本研究將採用整體精確度及Kappa係數作為判釋準則，精確度評估各項說明如下：

1. 生產者精度（Producer's Accuracy）

生產者精度為針對單一類別的精度表示。採用任一種類中，分類正確的元素量除以參考資料中屬於此一類型的元素總和，公式如下：

$$Pr\ oducersAccurac = \frac{X_{ii}}{\sum X_{i+}} \times 100\%$$

漏授表示已知類別被遺漏而歸類到其他類別與生產者精度有同樣意義，其公式定義為：

$$\text{漏授 (OE)} = 1 - \text{Producer's Accuracy (PA)}$$

2. 使用者精度（User's Accuracy）

使用者精度和生產者精度同樣為針對單一類別的精度表示。採用任一類別中分類正確的元素除以分類後被歸為此種類別的元素總和，公式如下：

$$UsersaAccuracy = \frac{X_{ii}}{\sum X_{+i}} \times 100\%$$

表示地面覆蓋物經分類後，類別被正確歸類的機率；另一個相似意義的是誤授誤差（Commission Error），表示分類後之類別被錯誤分類的百分比。其表示式為：

$$\text{誤授 (CE)} = 1 - \text{User's Accuracy}$$

3. 整體精度

最簡單的整體描述法，對角之樣點數目總和除以所有樣點數目的總和，由於已考慮到每

個類別相對的權重關係，所以整體精度具較客觀性，公式如下：

$$Overall\ Accuracy = \frac{\sum_{i=1}^n X_{ii}}{\sum_{i=1}^n \sum_{j=1}^n X_{ij}} \times 100\%$$

式中 n 為分類矩陣之列數， X_{ii} 為分類矩陣中欄列對角之樣點數目， X_{ij} 為分類矩陣中第 i 列第 j 行之樣點數目。

4. Kappa係數

Kappa係數於1960年由Cohen提出，用以表示分類結果與地面參考真值相近程度，後來被廣泛地應用於遙測影像分類的精度評估，Kappa係數所表示為分類成果與完全隨機分類比較下，其所減少錯誤的百分比。一般而言，Kappa係數介於0~1間，Kappa值愈大表示兩者接近度愈大。其公式如下（Congalton, 1991）：

$$Kappa = \frac{N \sum_{i=1}^n X_{ii} - \sum_{i=1}^n (X_{i+} \times X_{+i})}{N^2 - \sum_{i=1}^n (X_{i+} \times X_{+i})} \times 100\%$$

式中 n 為分類矩陣之列數， X_{ii} 為分類矩陣中欄列對角線之樣點數目， X_{i+} 、 X_{+i} 為分類矩陣中各欄及各列之樣點數目， N 為全部樣點數目。

肆、結果與討論

一、最大概似法

以原始波段（G、R及NIR）及原始波段分別加入CMFI及NDVI進行分類（圖5~圖7）；

結果顯示，原始波段加入CMFI為最佳，其次為原始波段加入NDVI，最差為僅利用原始波段進行判釋，Kappa係數分別為0.8517、0.8439及0.8340（表2～表4）；三者間主要錯誤多數集中於裸露誤判為植被或植被誤判為裸露地，因本研究所採用之衛星影像空間解析度為20M X 20M解析度較差，建議未來可採用較高空間解析度之衛星影像。一般水域與崩塌地波段較為接近，於判釋上較易產生誤授或漏授，而本研究所採用之衛星影像經校正後，水域幾近呈現白色，於波段上與崩塌地波段差異較大，故於水域上判釋皆無錯誤。

二、倒傳遞類神經網路

倒傳遞類神經網路為黑盒模式，主要從一群資料萃取有效資訊，本研究所採用之訓練樣本其波段組合均皆同最大概似法之方式，其分類結果如圖8～圖10，結果顯示，以原始波段加入CMFI為最佳，其次為原始波段，最差為原始波段加入NDVI，Kappa係數分別為

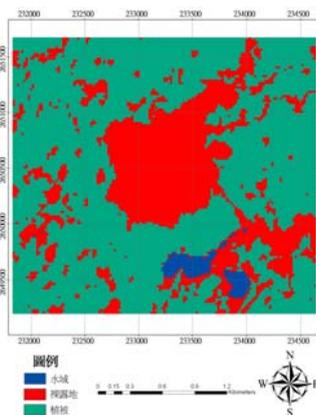


圖 5. 最大概似法分類成果圖 (原始波段)
Figure 5. Image classification by maximum-likelihood decision rule. (original bands)

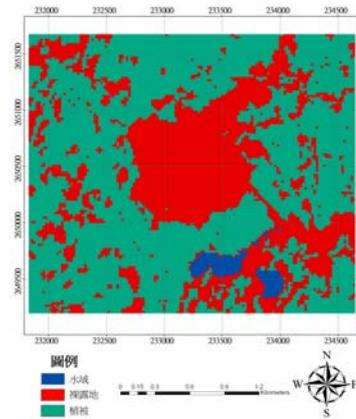


圖 6. 最大概似法分類成果圖 (原始波段及 CMFI)

Figure 6. Image classification by maximum-likelihood decision rule. (original bands plus CMFI)

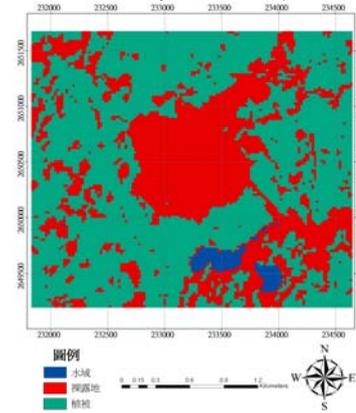


圖 7. 最大概似法分類成果圖 (原始波段及 NDVI)

Figure 7. Image classification by maximum-likelihood decision rule. (original bands plus NDVI)

0.8712、0.8540及0.5954。主要錯誤與最大概似法分類結果相同，皆多為於植被誤判為裸露地或裸露地誤判為植被，原因應亦為空間解析度之問題。

就使用者精度而言，植被部份以原始波段加上常態化差異植生指標 (NDVI) 之使用者精度為100%為最佳，植被經分類後能全部正確

被分類無誤授情況，因常態化差異植生指標加入NDVI雖對植被判釋於使用上有較高準確性，但裸露地誤判為植被卻高達39.26%，因此，經由整體考量下，其整體精確度及Kappa仍較劣於其他兩者。

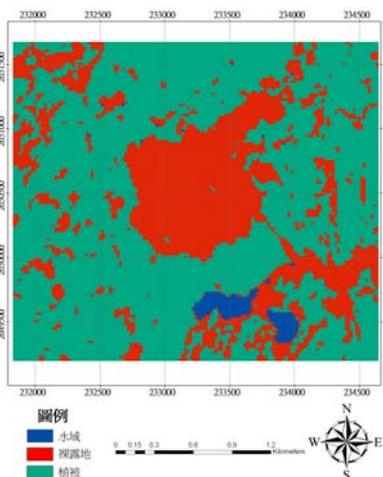


圖 8 倒傳遞類神經網路分類成果圖 (原始波段)

Figure 8. Image classification by back propagation neural network. (original bands)

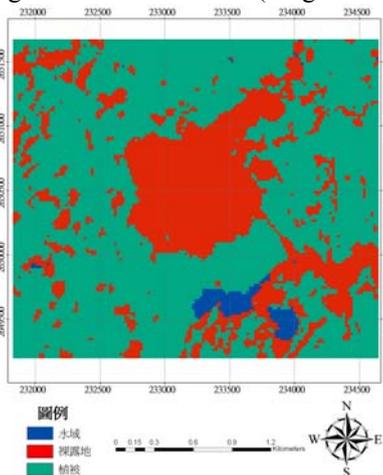


圖 9 . 倒傳遞類神經網路分類成果圖 (原始波段及 CMFI)

Figure 9. Image classification by back propagation neural network. (original bands plus CMFI)

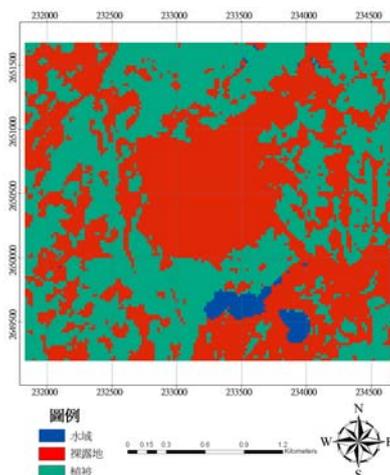


圖 10 . 倒傳遞類神經網路分類成果圖 (原始波段及 NDVI)

Figure 10. Image classification by back propagation neural network. (original bands plus NDVI)

三、模式比較

整體精確度與 Kappa 係數中，倒傳遞類神經網路除原始波段加入 NDVI 較劣於最大概似法外，其餘均優於最大概似法 (圖 11 及圖 12)。因此未來若採用原始波段或原始波段加入 CMFI 可採用倒傳遞類神經網路，若採用原始波段加入 NDVI 則可採用最大概似法應屬較佳。

表 2 . 最大概似法分類之誤差矩陣 (原始波段)
 Table 2. Error matrix of maximum-likelihood decision rule. (original bands)

地表覆蓋	植被	裸露地	水域	使用者精度	誤授
植被	156	11	0	93.41%	6.59%
裸露地	8	71	0	89.87%	10.13%
水域	0	0	4	100.00%	0.00%
生產者精度	95.12%	86.59%	100.00%	(整體精確度= 92.40%)	
漏授	4.88%	13.41%	0.00%	(Kappa 係數 = 0.8340)	

註:樣本數 N=250 分類數 n=3

表 3 . 最大概似法分類之誤差矩陣 (原始波段及 NDVI)
 Table 3. Error matrix of maximum-likelihood decision rule. (original bands plus NDVI)

地表覆蓋	植被	裸露地	水域	使用者精度	誤授
植被	145	0	0	100.00%	0.00%
裸露地	19	82	0	81.19%	18.81%
水域	0	0	4	100.00%	0.00%
生產者精度	88.41%	100.00%	100.00%	(整體精確度= 92.40%)	
漏授	11.59%	0.00%	0.00%	(Kappa 係數 = 0.8439)	

註:樣本數 N=250 分類數 n=3

表 4 . 最大概似法分類之誤差矩陣 (原始波段及 CMFI)
 Table 4. Error matrix of maximum-likelihood decision rule. (original bands plus CMFI)

地表覆蓋	植被	裸露地	水域	使用者精度	誤授
植被	146	0	0	100.00%	0.00%
裸露地	18	82	0	82.00%	18.00%
水域	0	0	4	100.00%	0.00%
生產者精度	89.02%	100.00%	100.00%	(整體精確度= 92.80%)	
漏授	10.98%	0.00%	0.00%	(Kappa 係數 = 0.8517)	

註:樣本數 N=250 分類數 n=3

表 5. 倒傳遞類神經網路分類之誤差矩陣 (原始波段)
Table 5. Error matrix of Back-propagation Network. (original bands)

地表覆蓋	植被	裸露地	水域	使用者精度	誤授
植被	154	7	0	95.65%	4.35%
裸露地	10	75	0	88.24%	11.76%
水域	0	0	4	100.00%	0.00%
生產者精度	93.90%	91.46%	100.00%	(整體精確度= 93.20%)	
漏授	6.10%	8.54%	0.00%	(Kappa 係數 = 0.8540)	

註:樣本數 N=250 分類數 n=3

表 6. 倒傳遞類神經網路分類之誤差矩陣 (原始波段及 NDVI)
Table 6. Error matrix of Back-propagation Network. (original bands plus NDVI)

地表覆蓋	植被	裸露地	水域	使用者精度	誤授
植被	110	0	0	100.00%	0.00%
裸露地	53	82	0	60.74%	39.26%
水域	1	0	4	80.00%	20.00%
生產者精度	67.07%	100.00%	100.00%	(整體精確度= 78.40%)	
漏授	32.93%	0.00%	0.00%	(Kappa 係數 = 0.5954)	

註:樣本數 N=250 分類數 n=3

表 7. 倒傳遞類神經網路分類之誤差矩陣 (原始波段及 CMFI)
Table 7. Error matrix of Back-propagation Network. (original bands plus CMFI)

地表覆蓋	植被	裸露地	水域	使用者精度	誤授
林地	155	6	0	96.27%	3.73%
裸露地	9	76	0	89.41%	10.59%
水域	0	0	4	100.00%	0.00%
生產者精度	94.51%	92.68%	100.00%	(整體精確度= 94.00%)	
漏授	5.49%	7.32%	0.00%	(Kappa 係數 = 0.8712)	

註:樣本數 N=250 分類數 n=3

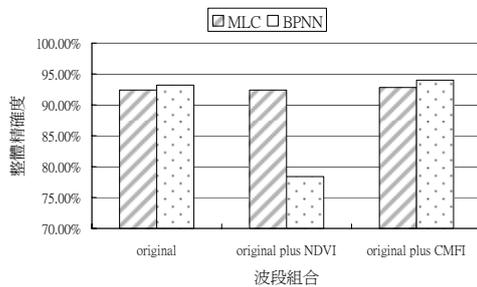


圖 11. 整體精確度比較表

Figure 11. Overall accuracy of the classification methods.

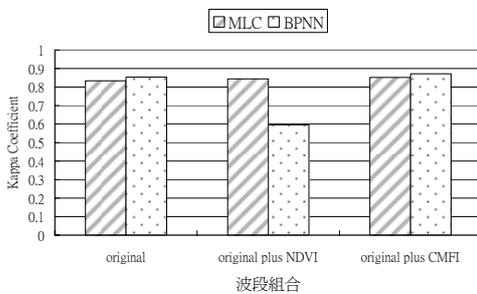


圖 12. Kappa 係數比較表

Figure 12. Kappa coefficient of the classification methods.

伍、結論

最大概似法中，原始波段加入植生指標對植物判釋具有相當助益；在倒傳遞類神經網路中，原始波段加入CMFI可提升判釋精確度，但加入NDVI卻造成樣本訓練不佳以致精確度降低。

疑係因受空間解析度原因，最大概似法及倒傳遞類神經網路主要錯誤皆發生於植被漏授為裸露地或裸露地誤授植被所致，建議未來可採用較高空間解析度之衛星影像或航拍影像進行分類。

於本研究中，除原始波段加入NDVI外，利用

倒傳遞類神經網路分類法較統計之最大概似法有較佳分類成果，但差距甚微，可供後續及其它研究參考。

誌謝

本文承國科會NSC 95-2625-Z-005-004-計劃之支持，作者在此表達謝意。

引用文獻

1. 林昭遠、吳瑞鵬、林文賜（2001）「921 震災崩場地植生復育監測與評估」，中華水土保持學報，32(1):59~66。
2. 葉怡成（2003）「類神經網路模式應用與實作」，儒林圖書公司。
3. 黃筱梅（2001）「SPOT 衛星影像於裸露地變遷之偵測研究—以和社地區為例」，國立臺灣大學森林學研究所碩士論文。
4. 黃凱易、張偉顛（1997）「SPOT 衛星影像分析應用於林地被覆變遷偵測」，中華林學季刊，30(1): 55-70。
5. 廖軒吾（2000）「集集地震誘發之山崩」，國立中央大學應用地質研究所碩士論文。
6. Burgan, R.E., and R.A. Hartford (1993) "Monitoring vegetation greenness with satellite data," USDA Forest Service Intermountain Research Station General Technical Report INT-297.
7. Cohen, J. (1960) "A Coefficient of Agreement for Nominal Scales," Educ. Psychol. Measurement.
8. Congalton, R.G. (1991) "A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data," Remote

- Sensing of Environment, 37 : 35-46.
9. Elvidge, C.D. and Z. Chen (1995)
“Comparison of broad-band and narrow-band red and near-infrared vegetation indices,” Remote sensing of environment, 54 : 38-48.
10. Rouse, J.W., Jr. R.H. Haas, J.A. Schell and D.W. Deering. (1973) “Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. Prog. Rep.” RSC 1978-1. Remote Sensing Cent., Texas A and M Univ., College Station.
-
- 97 年 3 月 3 日 收稿
97 年 3 月 26 日 修改
97 年 4 月 4 日 接受