

以樹狀倒傳遞類神經網路於田埂判釋研究

萬鈞^{1*} 雷祖強² 陳達祺³

摘要

台灣地區主要的糧食作物為水稻，因此政府每年都需耗費大筆經費與人力來估算水稻田的產量與面積。本研究採用 QuickBird 高解析度衛星影像搭配紋理資訊(Texture Information)和常態化差異植生指數(NDVI)作為影像分類時的輔助資訊，而分類器部份則使用倒傳遞類神經網路(Back Propagation Neural Network, BPNN)作為影像空間特徵分類器，其主要目的則是以自動判釋技術來分辨衛星影像中水稻田的區域，如此將有效的降低水稻田產量與面積的估算成本。然而過去的研究很少人討論水稻田分類時田埂判釋之問題，而水稻田埂為區隔出水稻與非水稻一個重要的地理界線，因此若能提高田埂判釋精度則水稻田坵塊特徵將會明顯的被區隔出來。因此本研究提出改良式樹狀多層邏輯判識方法，進而改善倒傳遞類神經網路對於田埂特徵的判釋成果，並以兩種不同的狀況分析作為說明案例:(1)案例 a:利用倒傳遞類神經網路將光譜影像一次分為三類(水稻、非水稻以及田埂)，(2)案例 b:使用樹狀倒傳遞類神經網路的概念逐一分離出水稻、非水稻以及田埂的識別結果(以圖層的邏輯判識規則)，兩者一起比較並探討其優缺點。研究結果顯示，本研究所提出之改良式樹狀多層邏輯判識方法，可提高分類器效能，進而解決了田埂判釋問題，而此方法也可大幅度改善坵塊面積的計算成果。

關鍵詞：影像分類、相對重要性、類神經網路

1. 前言

以往台灣地區對於水稻田的判斷都是以航空攝影方式獲取影像再由人工判讀方式來數化水稻坵塊圖，往往需耗費相當龐大的人力與物力，因此本研究希望藉由衛星影像高解析度與大面積的特性，來調查水稻田面積之分佈情形。目前就應用遙測影像來調查水稻面積時時間因素之特性必須考量其中，水稻田從整地育苗、插秧、生長、到收割，相應的地表覆蓋分別為水體、水體 + 植被、植被及裸露土壤四種而言，其接收的反射光譜值亦有所區別(Diuk-Wasser *et al.*, 2004)；水稻田在整地育苗時期，田地開始灌水整地但尚未種植水稻，此時水稻田的地表覆蓋為水體或含豐富水分的土壤，影像中近紅外光的波段亮度較暗其灰階值較低；而在成

活期~有效分蘖期時，水稻田已經插秧，但尚在分蘖生長階段，此時水稻田之地表覆蓋為水體與植被，而影像中波段的亮度微亮，其灰階值提升至中高；在最高分蘖期~黃熟期時水稻已達分蘖盛期，且漸趨成熟，此時水稻田之地表覆蓋為植被，此時影像中的波段亮度最亮且灰階值最高(光譜反射最強)；而收穫期為收割後水稻田所呈現的地表覆蓋為乾燥的裸露土壤，近紅外光的波段亮度恢復為暗，其灰階值亦降為低，基本上合適應用於水稻調查問題之影像則是最高分蘖期~黃熟期的影像。另一方面在影像空間解析力問題之方面，由於高解析度衛星影像的不斷誕生，影像空間解析度已大幅提昇，影像欲使用傳統分類器來獲得良好分類精準度之目標愈加困難，這是因為影像空間資訊量大幅增加，將會導致類別間混淆誤判之情況加劇(雷祖強，2006, Lloyd *et al.*, 2004)，因此本研究改進上述問題

¹ 嶺東科技大學資訊管理學系 副教授

² 逢甲大學都市計畫與空間資訊學系 副教授

³ 嶺東科技大學資訊管理學系 碩士

*通訊作者, 電話: 8886-4-23892088, E-mail: shiuan123@mail.ltu.edu.tw

收到日期: 民國 98 年 03 月 10 日

修改日期: 民國 98 年 05 月 03 日

接受日期: 民國 98 年 08 月 04 日

之作法有二：1. 使用紋理特徵(Texture Feature)的增益資訊來改善影像地物特徵的描述能力。2. 使用非線性倒傳遞類神經網路(Back Propagation Neural Network, BPNN)來強化傳統線性分類器分類效能較差之問題(Atkinson and Tatnall 1997)。

紋理資訊是在遙測影像分類問題時，一種有效且可改進影像分類精準度之方法(Miranda 1992)。所謂影像當中之紋理特性，就是影像中相同物體在群集時，會以某種規律的方式排列出現，而這種排列的方式，可認為是代表地物的某一種特性，而這種特性就是組織特徵(Haralick and Shaunmugam, 1973)。基本上計算影像紋理的法則可分為三類：組織結(Structure) 法頻譜(Spectral) 分析法及統計(Statistical) 分析法等 (Chica-Olmo and Abarca-Hernandez, 2000)。在面積萃取的部分，因影像解析度提高的情形之下，並不等於就會獲得較高分類精度之結果 (Chica-Olmo and Abarca-Hernandez, 2000)，因此紋理組織(Texture) 價值又被學者重新的討論與運用。Franklin 等人(2000)利用 IKONOS 全色態影像計算變異數(Variance)與均值度(Homogeneity)，對影像中林木的年齡進行分離度的檢驗。而在 Wang 等人(2004)的研究中，利用 IKONOS 與 QuickBird 影像分別萃取影像變異數與熵值(Entropy)，並探討紋理種類與其視窗大小對於紅樹林樹種分類的幫助。

而在空間特徵分類器運用方面，本研究以倒傳遞類神經網路模仿生物神經網路的處理過程能力和容錯性的特色(Bishop 1995; Haykin 1995)，經由不斷的學習歸納得到水稻田的知識來協助辨識水稻坵塊。本研究所使用之倒傳遞類神經網路結合了 EDBD 演算法(Minia and Williams, 1990)，而本文作

者曾利用此分析方法解決中科精密機台的隔減震的預測問題(Wan 2006; Wan 2007)。由於該分類器能適用各種分類問題，因此本研究進行台中縣潭子鄉農業地區高解析度影像之地表特徵分類問題。此外由於倒傳遞類神經網路有加速收斂過程與提高精準度之效果，加入紋理資訊透過倒傳遞類神經網路來達到有效的分類特徵，並提升影像判釋精度之目的。另一方面在過去有關水稻田問題的分類上甚少人提到水稻田田埂間的判釋，然而田埂為區隔出水稻與非水稻重要的地理界線，若能提高田埂判釋度相信水稻田坵塊將會更明顯的被區隔出來，如此將有利於水稻田面積的估算。因此本研究利用倒傳遞類神經網路對光譜影像區分為三類的成果，並嘗試使用改良式樹狀多層邏輯判識方法，以樹狀概念於不同階段逐一分離出水稻、非水稻以及田埂，並與倒傳遞對光譜影像分類成果互相比較，並突顯樹狀多層邏輯判識倒傳遞類神經網路的應用價值。

1.1 研究地區與材料

本研究材料地區位於台中縣潭子地區，該地區地形包含水稻、旱作、草地、林地、建物、其他等多樣性地形特性，由於地區影像中所包含多種不同地形特性反應，因此適合測試類神經網路對於多屬性資料在學習中的訓練過程。本研究材料為 Quick Bird 多光譜衛星影像，拍攝時間為 2003 年 10 月 25 日，其中多光譜影像解析度為 2.8 公尺、全色態影像為 0.69 公尺，融合後影像像幅為 2526x2097，相對位置如(圖 1)所示，換算實地面積約為 51.4 公頃。




圖 1 實證區位置

1.2 紋理資訊

所謂的紋理資訊，就是在影像中相同物體聚集在一起時，通常會以某種規律的方式排列出現，而這種排列的方式，可認為是代表地物的某一種特性，在許多研究中顯示，使用紋理資訊將可加強類別與類別間的差異性，有助於提升影像的分類成果 (Miranda *et al.*, 1992; Carr, 1996)。而在雷祖強等 (2006) 的研究中指出，方向半變異元紋理 (Director Semivarogram) 應用在高解析度衛星影像上，於水稻田、草地與林地等地物類別的區分上能獲得不錯效果。這樣的結果顯示半變異元模型在高解析度遙測影像判釋中，能提供良好的紋理資訊，以利影像判釋之進行，所以本研究便利用半變異元模型進行紋理資訊之萃取。而本文所引用相關紋理資訊之定義與數量，請參閱雷祖強等 (2006) 的研究。

2. 研究方法

本研究在訓練樣區的選擇上，總共選擇了 425 組訓練樣區，並以 300 組作測試樣本，分別包含水稻、草地、林地、道路、建物、陰影、水體。過程中使用 Quick Bird 融合後影像以及 12 個紋理資訊與差異化植生指數來作為輔助資訊 (雷祖強等 2006, 雷祖強等 2007)。在判斷有效植生的因子中，進行多影像類別的權重分析 (陳達祺等 2007, Lei *et al.*, 2007)，我們考慮以 NDVI、絕對半變異元和方向半變異元三種因子來建構多層次類神經網路學習，以提昇田埂的判釋。

最後在倒傳遞類神經的結果中我們以非監督的 K-mean 來取得各類別間的門檻值，最後再做精準度的評估。研究流程圖如 (圖 2) 所示：

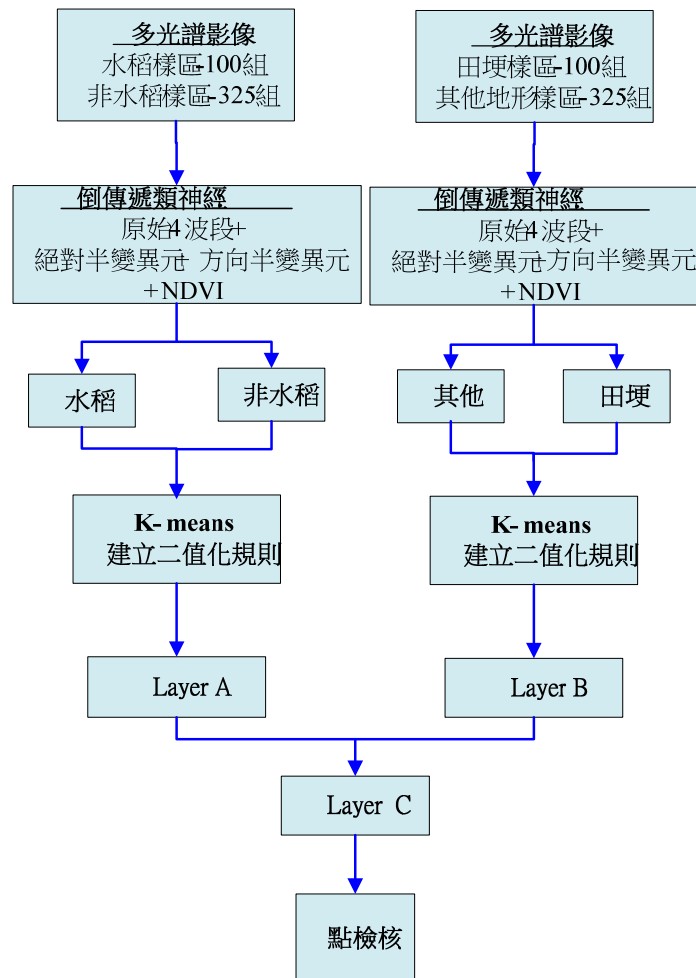


圖 2 樹狀類神經研究流程圖(case B)

2.1 倒傳遞類神經網路

類神經網路是一種基於腦與神經網路所啟發的資訊處理技術。利用系統之輸出與輸入所組成的資料建立系統模型，用以推估、預測、決策與診斷等應用範圍。廣義的角度來看，類神經網路也可看成一種在輸入與輸出問題極具學習能力的「非線性統計技術」。本研究採用類神經網路系統中最具代表性及應用最為普遍的倒傳遞網路演算法，進行水稻與非水稻問題之分類，並探討各輸入參數與輸出參數之關係。

BPN 之基本架構包含以下三部分：(1) 輸入層，用以表現網路的輸入變數，其處理單元數目依問題而定，輸入層使用線性轉換函數，即；(2) 隱藏層，用以表現輸入處理單元間之交互影響，其處理單元數目並無標準方法可以決定，經常需要以試驗的方式來決定其最佳數目；(3) 輸出層，用以表現網路的輸出變數，其處理單元數目依問題而定。隱藏層與輸出層均使用平滑可微分之非線性轉換函數，即雙曲線函數。

BPN 隱藏層使用非線性轉換函數是無爭議的；然，BPN 輸出層習慣上可使用線性或非線性轉換函數。事實上，隱藏層使用非線性轉換函數加上輸出層使用線性轉換函數在文獻上稱之為 Universal approximator。同時雙曲線函數有雙極(bi-polar)與單極(uni-polar)二種，前者適用於函數近似，而後者適用於分類。BPN 之運算內容可分為向前餽入與誤差向後推倒兩步驟。在向前餽入中，欲學習資料中的輸入值經由輸入層向前傳至第一層隱藏層，再經由隱藏層中每一神經元之轉換函數作用後，求出相對應的輸出值，此時輸出值成為下一層的輸入值，一層一層的向前傳遞，最後再經由輸出層將結果計算並輸出，如此一次完整的向前餽入便完成。

經由上一步驟所計算出來的最後輸出值將被拿來與所目標輸出值比較，如果兩者之誤差已小於系統所要求的誤差，則整個學習步驟結束，並且儲存於連結上的權值即為網路訓練後的知識。反之，誤差向後推倒的步驟開始運作，誤差訊息將由輸入層反向向後一層層往輸出層傳遞，並修改各層網路

間連接上的權值，如此反覆迭代執行上述兩步驟，使整個系統的能量函數 (Energy Function) 降至最低點，而 EDBD 演算法就是一種加速使能量函數收斂至最低點的方法。

2.2 EDBD 演算法 (Extended Delta-Bar-Delta Algorithm)

當 BPN 使用固定學習速率進行學習時，經常會遭遇兩種現象，分別為減緩現象與跳出現象，而 Y 軸為能量函數意指目標輸出值與推論輸出值兩者之差距程度，也代表網路學習的品質，X 軸為每次變動的權重值，說明如下所述：

2.2.1 趨緩現象(slowing)：

在網路學習過程中，某一連結的權重值改變量連續數次為同號，即連續為正或連續為負，這表示該連結的上端神經元之差距量連續為正或連續為負（如圖 3）所示。這種現象也表示著使誤差函數達到最低值的權重值尚未被跳過。如果誤差函數遞減的速度遞減，稱為減緩現象。




圖 3 趨緩現象

2.2.2 跳躍現象(jumping)：

在網路學習過程中，某一連結的權重值改變量連續數次為異號，即正負連續穿插，這表示該處神經元的差距量連續正負相互穿插（如圖 4）所示。

這種現象也表示著使誤差函數達到最低值的權重值已經跳過。如果誤差函數值遞增，稱為跳出現象。

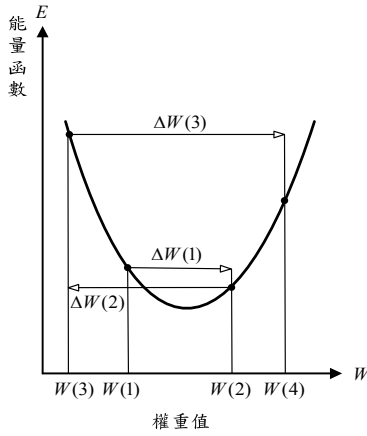


圖 4 跳躍現象

為了改善上述兩種現象，本研究將引 Minia 等人所提出之 EDBD 演算法使 BPN 學習時之速率與精度提高，EDBD 演算法相關之數學式如下所述：

$$\Delta W_{ij}(t) = -\eta_{ij}(t) \frac{\partial E(t)}{\partial W_{ij}} + \alpha_{ij}(t) \Delta W_{ij}(t-1) \quad (1)$$

其中

i ：第 $n-1$ 層處理單元的編號。

j ：下標 j 代表該層之處理單元編號。

W_{ij} ：第 $n-1$ 層與第 n 層處理單元連結上之權值， i 、 j 分別代表連結上權值之起始與終點處理單元之編號。

ΔW_{ij} ：為 W_{ij} 的調整量。

$\Delta W_{ij}(t)$ ：為 W_{ij} 第 t 次學習循環的改變量，其餘類推。

$\alpha_{ij}(t) \Delta W_{ij}(t-1)$ ：慣性項，可以改善收斂過程中震盪的現象及加速收斂。

$\alpha_{ij}(t)$ ：慣性因子，控制慣性項之比例， $0 \leq \alpha_{ij}(t) \leq 1$ 。

$$\eta_{ij}(t+1) = \text{Min}[\eta_{\max}, \eta_{ij}(t) + \Delta \eta_{ij}(t)] \quad (2)$$

其中

η_{\max} ：學習速率上限值。

$$\alpha_{ij}(t+1) = \text{Min}[\alpha_{\max}, \alpha_{ij}(t) + \Delta \alpha_{ij}(t)] \quad (3)$$

其中

α_{\max} ：慣性因子上限值

$$\Delta \eta_{ij}(t) = \begin{cases} \kappa_l \exp(-\gamma_l |\bar{\delta}_{ij}(t)|) & \text{if } \bar{\delta}_{ij}(t-1) \delta_{ij}(t) > 0 \\ -\phi_l \eta_{ij}(t) & \text{if } \bar{\delta}_{ij}(t-1) \delta_{ij}(t) < 0 \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

$$\Delta \alpha_{ij}(t) = \begin{cases} \kappa_m \exp(-\gamma_m |\bar{\delta}_{ij}(t)|) & \text{if } \bar{\delta}_{ij}(t-1) \delta_{ij}(t) > 0 \\ -\phi_m \alpha_{ij}(t) & \text{if } \bar{\delta}_{ij}(t-1) \delta_{ij}(t) < 0 \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

$$\bar{\delta}_{ij}(t) = (1 - \xi) \delta_{ij}(t) + \xi \delta_{ij}(t-1) \quad (6)$$

其中

$\delta_{ij}(t)$ ：第 t 次的差距量。

2.3 學習收斂與誤差測試

網路學習方式以每載入一個訓練範例便更新加權值與閾值一次，當所有的訓練範例都已載入一次時，便完成一次學習循環，網路於每次的學習循環結束時，便以訓練範例和測試範例進行誤差均方根（Mean-Squared Error, MSE）計算：

$$\text{MSE} = \sqrt{\frac{\sum_{p=1}^M \sum_{j=1}^N (T_j^p - Y_j^p)^2}{M \cdot N}} \quad (7)$$

其中

T_j^p ：第 P 個訓練（測試）範例的第 j 個輸出神經元之目標輸出值。

Y_j^p ：第 P 個訓練（測試）範例的第 j 個輸出神經元之推論輸出值。

M ：訓練（測試）範例數目。

N ：輸出層神經元數目。

在每學習一個循環後即分別對學習範例與測試範例之學習成果計算一次 MSE，來監測網路學習之完成度，本研究設定學習範例與測試範例在輸入網路作循環學習的過程中，若兩者之 MSE 均小於 2.5% 即告學習完成。

2.4 K-means 取門檻值過程

本研究由 BPN 結合 EDBD 演算法的分類結果下，每個 Pixel 所分類出的結果為介於 0.8~2.2 的離

散型數值，這樣導致所分類出的影像為一個包含灰階值的結果，因此在最後我們再使用非監督式的 K-means 方法來取出門檻值，其門檻值計算如下：

$$\frac{x_{max(i)} + x_{min(j)}}{2} = k \tag{9}$$

$$d = \begin{cases} x < k & d=1 \text{ 代表水稻} \\ x > k & d=2 \text{ 代表非水稻} \end{cases} \tag{10}$$

其中

- i : K-means 分類為水稻數值。
- j : K-means 分類為非水稻數值。
- x : BPN-EDBD 分類的離散型數值。

3. 實證結果與討論

為了方便讀者了解，本研究以 case A 的網路架構與參數初值設定作說明：

3.1 網路架構與參數初值設定

而在神經元個數的設定上參考(11)式分別設為：

CASE A (圖 5)：7-4-1(輸入層神經元、隱藏層神經元、輸出層神經元)。

$$\text{隱藏層神經元數目} = (\text{輸入層神經元數目} + \text{輸出層神經元數目}) / 2 \tag{11}$$




圖 5 網路架構圖

BPN + EDBD 演算法的各項數據參數共分為 κ_i 、 ϕ_i 、 γ_i 、 η_{max} 、 κ_m 、 ϕ_m 、 γ_m 、 α_{max} 、 ξ 等九個參數，本研究採取上界與下界平均值(Wan and Yen, 2006, Wan and Yen 2007)，即在此次的 3 個範例中我們皆設為(20、0.7、10、0.1、20、0.7、10、0.1、0.01)，初始權重值與閾值則隨機設為-1 至 1 之間值。其中
 隱藏層神經元數目=(輸入層神經元數目+輸出層神經元數目)/2 (11)

3.2 Case A：倒傳遞分水稻、田埂、非水稻三類分析

本研究在將光譜影像分為三類的過程當中水稻類別設為 1、田埂設為 2、非水稻(道路、建物、草地...等等)設為 3，其地真資料(農糧署所提供 GIS 資料)並透過點檢核的方式以隨機撒點，力求均勻分佈，在樣區上共有 300 組分別為 135 組水稻、12 組田埂、153 非水稻，同樣的在 BPN 分類後以 K-mean 的方法取出門檻值並二值化影像如圖 6。特別在此說明，圖 5 的輸出層為 0 到 3 之間的實數值並以公式(9)與公式(10)製成表 1。

可看出雖然在判釋田埂方面有所改善可是相對的也增加了誤判，將一些水稻坵塊判釋為非水稻的情形頗為嚴重。因此以 BPN 直接來判釋出三類別的效果並不算好，在表 2 中得知雖然總體精度到了 91.3，但在田埂方面誤漏判相當的嚴重，也誤判大量非水稻如建物成田埂(如圖中綠色圈)此可說明以類神經網路輸出田埂所代表的光譜值與一部分非水稻成份的相當接近。

表 1 分三類門檻值

類別	門檻值
水稻	$y_i < 1.69$
田埂	$1.69 < y_i < 2.65$
非水稻	$y_i > 2.65$

3.3 Case B: 倒傳遞樹狀分類+If then 規則

由於利用 BPN 直接將光譜影像分為三類的成果不甚理想，尤其在水稻田田埂間的判釋上更是有明顯的誤漏判，因此接著我們以樹狀分類的概念配合階段一所產生的水稻與非水稻的成果圖，再以相同的光譜影像使用 BPN 分類出田埂與非水稻的成果圖，兩張圖層以 IF-Then 的規則判別像元在水稻與非水稻的分類類別。流程詳見圖 2，簡單的說明如下：

- (1) 圖 2 中左分枝主要在判識水稻(類別 1)和非水稻(類別 2)的成份，並產生 layer A。
- (2) 圖 2 中右分枝主要在判識非水稻中田埂(類別 1)和其它如道路、水體、建物(類別 2)等等，並產生 layer B。
- (3) 由以下判識規則 產生 Layer C 即為最後輸出圖。

IF-Then 規則：

layer A : BPN+EDBD(田埂與其他)

layer B : BPN+EDBD(水稻與非水稻)

layer C : 以 IF-Then 規則產生圖

Rule 1: IF layer A pixel = 1 and layer B pixel = 1
Then layer C pixel = 1

Rule 2: IF layer A pixel = 2 and layer B pixel = 2
Then layer C pixel = 2

Rule 3: IF layer A pixel = 1 and layer B pixel = 2
Then layer C pixel = None (levees)

Rule 4: IF layer A pixel = 2 and layer B pixel = 1
Then layer C pixel = None (levees)

因此我們以 IF-Then 的規則將階段一 Case b 的成果圖(如圖 7)。表 3 即為最後樹狀分類成果圖的精準度誤差矩陣表，由表 2 與表 3 中得知與 BPN 分三類相比總體精準度由 91.3 提昇至 96.3 約五個百分點，但在水稻田的誤判與非水稻田的漏判較嚴重，反觀在水稻田的漏判與非水稻田的誤判上卻有明顯的優勢。

一個基本問題延伸出來：CASE A 僅採用 EDBD+BPN 法，CASE B 中則採用 BPN +EDBD

+ if then 規則，實驗結果顯示 CASE B 成果較佳，則此精準度提昇究竟是因為採用 EDBD 還是 if-then 規則所產生的效果？本研究其實主要在探討如果能有效的建立監督式學習的 if-then 規則，可大幅度降低 GIS 套圖時，其圖層(layer)之間的誤差，如果良好的訓練樣本可以突顯 layer 之間的特徵，影像中不易分離組成(component)或類別(categories) 都可逐次的解析出來，這就是本研究的價值與貢獻。

4. 結論

本研究利用類神經網路理論中的倒傳遞類神經網路 (BPN)，配合 EDBD 演算法來模擬分析衛星影像判釋水稻田之結果，並從中探討衛星影像輔助資訊的相對重要性。我們分成兩個案例來研究樹狀倒傳遞對多分類的優點。以兩種不同的案例分析:(1)case a:利用倒傳遞將光譜影像一次分為三類(水稻、非水稻以及田埂)，(2)case b:使用樹狀倒傳遞的概念逐一分離出水稻、非水稻以及田埂的資訊內涵。

倒傳遞樹狀分類+If then 規則與 BPN 分三類相比總體精準度由 91.3 提昇至 96.3 約五個百分點，但在水稻田的誤判與非水稻田的漏判較嚴重，反觀在水稻田的漏判與非水稻田的誤判上卻有明顯的優勢。




圖 6 BPN+EDBD(Case A 分三類)二值化

表 2 分三類的誤差矩陣(case A)

		地真資料				
		水稻	田埂	非水稻	總數	使用者精度
分類結果	水稻	125	6	2	133	0.94
	田埂	4	4	6	14	0.29
	非水稻	6	2	145	153	0.95
	總數	135	12	153	300	
	生產者精度	0.93	0.33	0.95		
總體精度 = 91.3%						

表 3 樹狀倒傳遞的誤差矩陣(case B)

		地真資料				
		水稻	田埂	非水稻	總數	使用者精度
分類結果	水稻	131	1	2	134	0.98
	田埂	1	10	3	14	0.71
	非水稻	3	1	148	152	0.97
	總數	135	12	153	300	
	生產者精度	0.97	0.83	0.97		
總體精度 = 96.3%						




圖 7 BPN+EDBD(Case B 樹狀倒傳遞)Layer C 輸出

參考文獻

- 雷祖強、周天穎、鄭丁元，2006，運用QuickBird 衛星影像於水稻田坵塊萃取之研究，航測與遙測學刊，第11卷，第3期，pp. 297-310。
- 雷祖強、周天穎、鄭丁元，2007。應用半變異元模式於Quickbird影像中植生類別分類特性之研究，航空測量與遙感探測學刊，Volume 12, No.1, pp. 1-16。
- 鄧敏松，1997。結合多時段遙測影像、耕地坵塊與領域知識之區域式影像辨識法於水稻田耕作調查之應用，國立成功大學測量工程研究所碩士論文。
- 陳達祺、萬絢、雷祖強、黃家健、2007 BPN+EDBD 空間特徵分類器之研究-以台中水稻田為例，台灣地理資訊學會2007年年會暨學術研討會，台灣/台南
- Atkinson, P.M. and Tatnall, A.R.L., 1997. Introduction: neural networks in remote sensing. *International Journal of Remote Sensing*, 18 (4), 699–709(11).
- Bishop, C.M. *Neural Networks for Pattern Recognition*. Oxford University Press. 1995.
- Chica-Olmo, M. and Abarca-Hernández, F., 2000, Computing geostatistical image texture for remotely sensed data classification, *Computers & Geosciences*, 26(4): 373-383.
- Carr, J. R. and Miranda, F. P., 1998, The Semivariogram in Comparison to The Co-occurrence Matrix for Classification of Image Texture, *IEEE Trans. On Geo. and Remote Sensing*, 36(6): 1945-1952.
- Diuk-Wasser, M. A., Bagayoko, M., Sogoba, N., Dolo, G., Touré, M. B., Traoré, S. F., Taylor, C. E. 2004. Mapping Rice Field Anopheline Breeding Habitats in Mali, West-Africa, using Landsat ETM+ sensor data, *International Journal of Remote Sensing*, 25 (2), 359–376.
- Franklin, S. E., Wulder, M. A. and Gerylo, G. R., 2001, Texture analysis of IKONOS panchromatic data for douglas-fir forest age class separability in British Columbia, *International Journal of Remote Sensing*, 22(13): 2627-2632.
- Garson, G.D., 1991, *Interpreting Neural Network Connection Weights*, *AI Expert*, pp.47-51.
- Haralick, R.M., Shanmugam, K., and Dinstein, I., 1973. Textural features for image classification. *IEEE Transaction System, Man, and Cybernetics*, 67, 786–804.
- Haykin, S. *Neural Networks: A Comprehensive Foundation*, 2nd Edition, 1999; Prentice-Hall, New Jersey.
- Lei, T.C., Wan, S., and Chou, T.Y., 2007. The comparison of PCA and discrete rough set for feature extraction of remote sensing image classification – a case study on rice classification, *Taiwan. Computational Geosciences*, 12 (1), 1–14.
- Lloyd, C. D., S. Berberoglu, P. J. Curran and P. M. Atkinson, 2004, A comparison of texture measures for the per-field classification of Mediterranean land cover. *International Journal of Remote Sensing*, 25, 3943-3965.
- Minai, A.A. and Williams, R.D., 1990, Back-propagation heuristics: a study of the extended delta-bar-delta algorithm, *Neural Networks*, vol.1, pp.595-600.
- Miranda, F. P., Macdonald, J. A. and Carr, J. R., 1992, Application of the Semivariogram Textural Classifier (STC) for Vegetation Discrimination Using SIR-B Data of Borneo, *International Journal of Remote Sensing*, 13(12): 2349-2354.
- Wang, L., Sousa, W. P., Gong, P. and Biging, G. S., 2004, Comparison of IKONOS and QuickBird images for mapping mangrove species on the Caribbean coast of Panama, *Remote Sensing of Environment*, 91: 432-440.
- Wan S., J. Y. Yen, 2007, The Study of Base Isolation on the Precise Machinery System for Regional Ground Motion Records with Modified Back Propagation Neural Network Approach, *Structural Control and Health Monitoring* Volume 14, Issue 5 ,pp750-776.
- Wan S., J.Y.Yen, 2006, The Study on SSI Problems in an Industrial Area with Modified Neural Networks Approach *International Journal for Numerical and Analytical Methods in Geomechanics* vol. 30, Issue 15, pp.1563-1578

The Application on Improved-Tree Neural Network on Rice Image Classification

Shiuan Wan ^{1*} Tsu Chiang Lei ² Da Chi Chen ³

ABSTRACT

Rice is one of the major crops of Taiwan. Accordingly, in the past, governments put great efforts on estimating the size of paddy rice. The objective of this study is to classify the area of paddy through satellite images by our spatial information system. In the present study, the material adopted is QuickBird satellite images. Owing to the low resolution of QuickBird satellite images, the texture information and NDVI were used as auxiliary material to enhance the quality of the images. On the other hands, levee is one of the most important component to extract information on evaluating the area of paddy rice. Thus, it is decided to use two different cases to study the outcomes of extracting the levees: Case (a) using BPN to classify the image into three category (paddy rice, levee, non-paddy rice) and Case (b) using Tree-Neural Network concept to step-by-step output the paddy rice, levee, non-paddy rice. The results are drawn and rational discussions are made.

Keywords: image classification, Neural Networks, Tree-Neural Network

¹ Associate Professor, Department of Information, Management, Ling Tung University

² Associate Professor, Department of Urban Planning, Feng Chia University

³ Master Student, Department of Information Management, Ling Tung University

* Corresponding Author, Phone: 8886-4-23892088, E-mail: shiuan123@mail.ltu.edu.tw

Received Date: Mar. 10, 2009

Revised Date: May 03, 2009

Accepted Date: Aug. 04, 2009