

使用樹狀倒傳遞類神經網路於 水稻田空間影像辨識研究

萬鈞

嶺東科技大學
資訊管理系 副教授

陳明華*¹

嶺東科技大學
資訊管理系 副教授

陳達祺

嶺東科技大學
資訊科技應用研究所 研究生

雷祖強

逢甲大學
都市計畫學系 助理教授

摘要

水稻為台灣地區主要的糧食作物，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。本研究的目地是就衛星影像，使用自動判釋技術來分辨水稻田的區域，以達有效降低水稻田產量與面積的估算成本。

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)作為輔助資訊。我們開發的分類器部份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。過去研究中很少有人提出關於水稻田分類上的田埂判釋問題，由於田埂為區隔出水稻與水稻或水稻與非水稻的一個界線，因此若能提高田埂的判釋精度，水稻田坵塊將會更明顯的被區隔出來。因此本研究將探討倒傳遞對於田埂的判釋成果，首先利用倒傳遞將光譜影像一次分為三類(case a)，隨後使用樹狀的概念(case b)逐一分離出水稻、非水稻以及田埂，最後兩者比較並探討其優缺點。

關鍵詞：影像分類、類神經網路、樹狀類神經網路。

Abstract

Rice is one of the major corps 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 additional information (Texture Information) and NDVI were used as auxiliary material to enhance the quality of the images. Leave is one of the most important component to extract information on evaluating the area of paddy rice. Thus, We 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, leave, non-paddy rice) and Case (b)using Tree-Neural Network concept to step-by-step output the paddy rice, leave, non-paddy rice. The results are drawn and rational discussion are made.

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

*¹ 通訊作者- mhc@mail.ltu.edu.tw

1. 前言

由於台灣地形特徵豐富，在都市區中又包含農作物、建物、水體等多樣的地形，以往對於水稻田的判斷都是以航空攝影，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，因此希望藉由衛星影像高解析度與大面積的特性，配合本研究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，經由不斷的學習歸納得到水稻田的知識來協助辨識水稻。

本研究利用倒傳遞類神經網路結合了 EDBD 演算法(A.A.Minia and R.D.Williams, 1990)進行台中縣潭子地區之地表特性分類，並且利用 K-means 方法取得分類的門檻值。而在輔助資訊方面，將所得到的高解析度之衛星影像資料藉由空間資訊技術，擷取出常態化差異植生指數與紋理資訊。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。

2. 研究方法

2.1 研究範圍

本研究材料地區位於台中縣潭子地區，相對位置如圖 1 所示。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 衛星多光譜影像，拍攝時間為 2003 年 10 月 25 日，其中多光譜影像解析度為 2.8m*2.8m、全色態影像空間解析度為 0.69m*0.69m，融合後影像像幅為 2526×2097 像元。

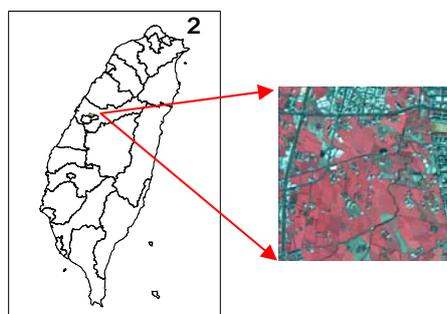


圖 1 實證區位置

2.2 研究流程

本研究在訓練樣區的選擇上，總共選擇了 425 組訓練樣區，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，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。研究流程如圖 2 所示。

2.3 倒傳遞類神經網路

2.3.1 回顧倒傳遞類神經網路

倒傳遞網路 (Back-Propagation Networks, 以下簡稱 BPN) 是目前類神經網路(Artificial Neural Network)中最具代表性, 應用最為普遍的模式。BPN 學習目的在於降低輸出單元之目標輸出值與推論輸出值兩者之差距, 差距越小表示學習效果越佳, BPN 之網路架構增加了隱藏層, 使得網路可表現輸入處理單元之間的交互影響, 大大地提升學習能力, 其中內含輸入層、隱藏層、輸出層。

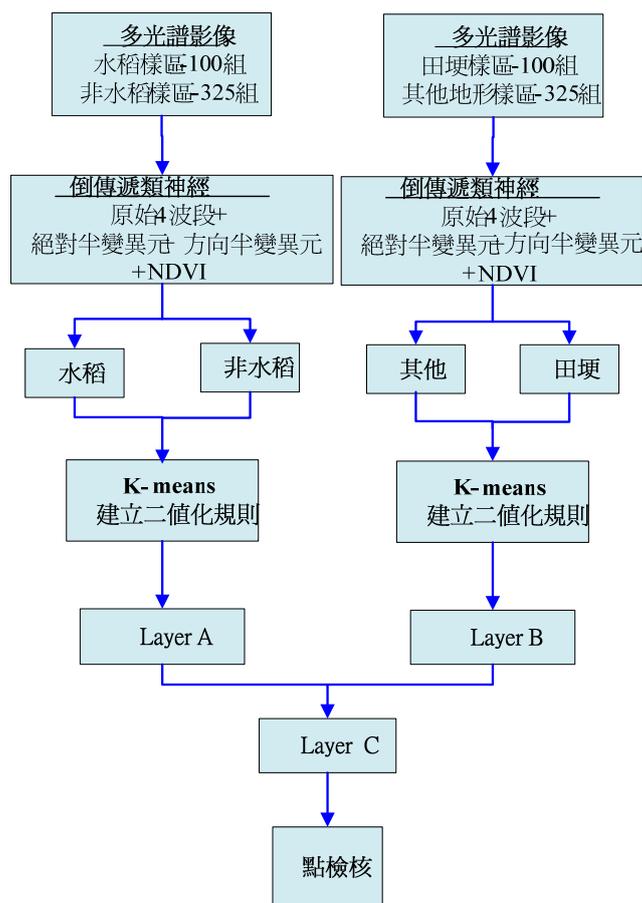


圖 2 樹狀類神經研究流程圖

2.3.2 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。

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。

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。

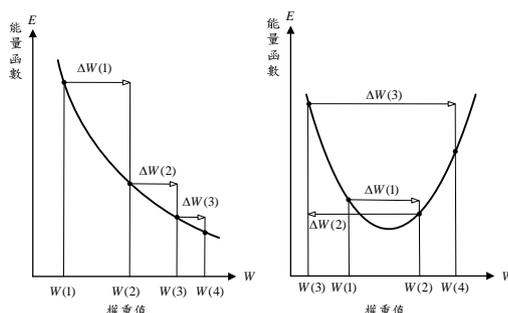


圖 3 趨緩現象

圖 4 跳躍現象

為了改善上述兩種現象，本研究將引 A.A.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， $0 \leq \alpha_{ij}(t) \leq 1$ 。

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

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。

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

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

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

$\delta_{ij}(t)$ ：第 t 次的差距量。

2.4 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：

$$\text{MSE} = \sqrt{\frac{\sum_P^M \sum_j^N (T_j^P - Y_j^P)^2}{M \cdot N}} \quad (7)$$

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訓練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，本研究設定訓練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。

2.5 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：

$$\frac{x_{\max(i)} + x_{\min(j)}}{2} = k \quad (8)$$

$$d = \begin{cases} 1 & \text{若 } x \leq k \text{ (水稻)} \\ 2 & \text{若 } x > k \text{ (非水稻)} \end{cases} \quad (9)$$

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。

2.6 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。

3. 實證結果與討論

BPN-EDBD 演算法的各項數據參數共分為 κ_l 、 ϕ_l 、 γ_l 、 η_{\max} 、 κ_m 、 ϕ_m 、 γ_m 、 α_{\max} 、 ξ 等九個參數，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。而在神經元個數的設定上參考(11)式分別設為：

Case a 圖 5：17-9-1(輸入層神經元、隱藏層神經元、輸出層神經元)。

$$\text{隱藏層神經元數目} = (\text{輸入層神經元數目} + \text{輸出層神經元數目}) / 2 \quad (10)$$

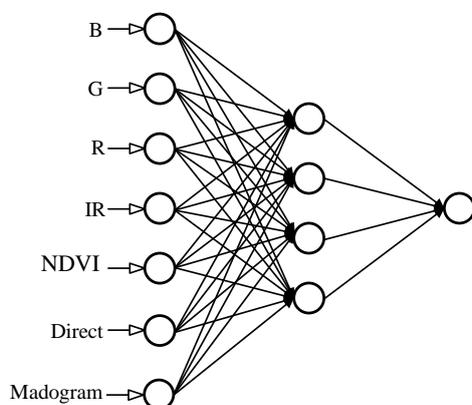


圖 5 網路架構圖

3.1 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，在樣區上共有 525 組分別為 100 組水稻、100 組田埂、325 非水稻，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。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，表 2 顯示總體精度為 91.3，但在田埂方面誤漏判相當的嚴重，此表示田埂的光譜值與水稻與非水稻的光譜值相當接近。

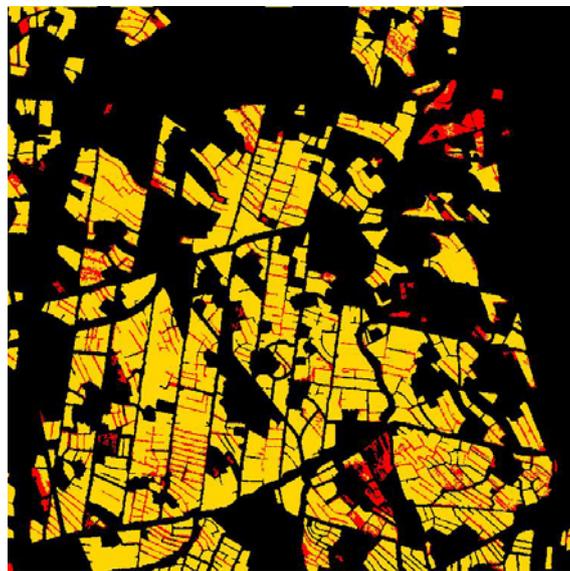


圖 6 BPN+EDBD(Case a 分三類)二值化

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	$y_i > 2.65$

表 2 分三類的誤差矩陣

		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%						

3.2 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，尤其在水稻田與田埂間的判釋有明顯的誤漏判情況，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

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

(4) 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。

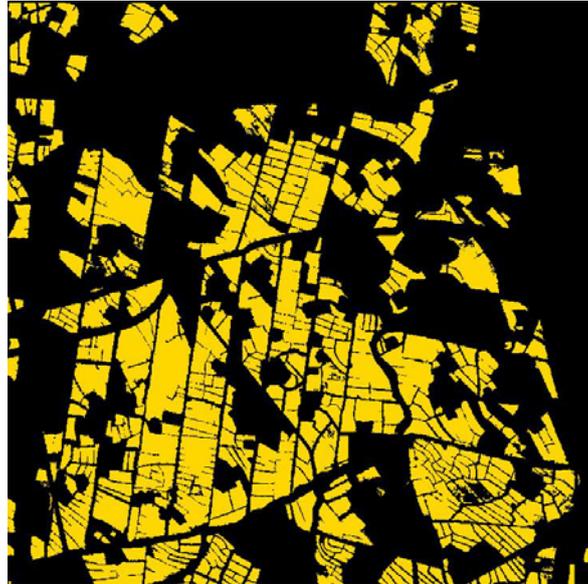


圖 7 BPN+EDBD(Case b 樹狀倒傳遞)二值化

表 3 樹狀倒傳遞的誤差矩陣

		地真資料			
		水稻	非水稻	總數	使用者精度
分類結果	水稻	139	0	139	100
	非水稻	11	150	161	0.93
	總數	150	150	300	
	生產者精度	0.93	100		
		總體精度 = 96.3%			

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，來判釋衛星影像中水稻、非水稻以及田埂。我們分成兩個 case 來研究樹狀倒傳遞對多分類的優點。以兩種不同的 case 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、非水稻以及田埂的識別。

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% 至 96.3%，約提昇五個百分點，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。

5. 參考文獻

- [1] 王吉成、萬絢，2006，應用空間資訊與布林粗集合分析雪霸崩塌地，TGIS 研討會。
- [2] 吳升享，2004，應用倒傳遞網路於鉛心橡膠隔震墊基本設計參數之分析評估，中興大學土木工程學系碩士論文。
- [3] 施奕良、雷祖強、周天穎、鄭丁元，2004，遙測影像分類資訊有效性之研究。
- [4] 許晉嘉，2006，應用支援向量機法於高解析度衛星影像分類之研究，逢甲大學環境資訊科技系碩士論文。
- [5] 葉怡成(2001)，「應用類神經網路」，儒林圖書有限公司，台北。
- [6] 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.
- [7] Garson, G.D. (1991). "Interpreting Neural-Network Connection Weights", AI Expert, pp.47-51.
- [8] 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.
- [9] 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.