

新北市政府 108 年度自行研究報告

隨機森林演算法於 UAV 影像農作物分類之研究

研究機關：新北市中和地政事務所

研究人員：黃子彥

研究期程：108 年 1 月 1 日至 10 月 31 日

新北市政府 108 年度自行研究成果摘要表

計 畫 名 稱	隨機森林演算法於 UAV 影像農作物分類之研究
期 程	108 年 1 月 1 日至 10 月 31 日
經 費	0
緣 起 與 目 的	<p>傳統航空攝影受限於時間與天氣的限制，光學衛星影像又容易受到雲霧遮蔽等等問題。而無人飛行載具(UAV)在近幾年的發展中成為重要的工具，其具有即時、高機動性、高解析度以及較不受天氣限制下等特性，成為衛星與航空攝影外另一個新形態的影像獲取工具。本研究藉由高解析度 UAV 正射影像，加上紋理資訊增加農作物不同類別間的空間特徵差異性，本研究先利用最短距離法與隨機森林分別進行可見光波段分類，經過實驗結果顯示隨機森林的分類精度明顯優於最短距離法，後續將以可見光波段加入紋理影像並利用隨機森林進行分類，進而提升高解析度無人機影像分類時的精度。</p>
方 法 與 過 程	<p>本研究係以高精度無人機影像分類之問題探討為主軸，因此須藉由以下方式進行：</p> <p>一、文獻回顧法：介紹本研究所需而蒐集的相關理論與文獻，包含紋理特徵與影像分類法。</p>

	<p>二、傳統影像分類器與機器學習分類器：首先利用最短距離法與隨機森林法在可見光波段下的情況下進行影像分類。</p> <p>三、精度比較：從最短距離法與隨機森林法分類後的結果中選擇出精度較高之分類器。</p> <p>四、可見光波段與紋理影像加入隨機森林法進行分類：將可見光波段與紋理影像加入隨機森林演算法中進行分類，並進行參數調整以得到最佳分類模型。</p>
研究發現及建議	<p>本研究所採用的 UAV 影像中，最短距離法所的可見光分類結果其總體精度為 59.46%，Kappa 為 0.38，而隨機森林的可見光分類結果為 88.56%，Kappa 為 0.82，顯示隨機森林分類器在無人機影像中分類的卓越性，而在加入適當的紋理影像後，總體精度更提高到 94.22%，Kappa 提升到 0.91，故得知加入適當的紋理因子後可提升地物的分類精度。</p> <p>選擇適合的移動視窗大小在紋理分析中佔非常重要的地位，但每次紋理分析時又會花費大量時間計算紋理因子，為了節省運算時間，未來關於紋理分析的部分可以運用半變異元分析計算每種地物最適合的移動視窗大小，以節省大量數據計算的時間。</p>

備	註
---	---

目 錄

目 錄.....	v
壹、 緒論	1
一、 研究動機與目的	1
二、 研究流程	2
三、 研究架構	4
貳、 文獻回顧.....	5
一、 水稻田判釋基礎	5
1、 水稻田生長知識	5
2、 水稻田生長光譜特性	6
3、 水稻判釋相關研究	7
二、 紋理分析理論	7
1、 紋理描述與種類	8
2、 紋理分析方法	9
3、 紋理分析相關研究	10
三、 影像分類理論	11
1、 影像分類理論	11
2、 影像分類相關研究	12
參、 研究方法.....	13
一、 灰階共生矩陣	13
1、 灰階共生矩陣參數決定	17
二、 隨機森林	21
1、 參數選擇	30
三、 最短距離法	30

1、 分類精度評估	30
肆、 實驗步驟與成果分析	33
一、 實驗區簡介	33
二、 實驗材料	34
三、 紋理分析	35
1、 移動視窗大小決定	35
2、 像元間距離與相對方向決定	36
3、 紋理量化因子決定	36
四、 最短距離法影像分類	39
1、 訓練樣本選取	39
2、 最短距離法原始影像分類	39
五、 隨機森林影像分類	41
1、 參數設置並建立分類模型	41
2、 隨機森林原始影像分類	42
3、 紋理影像加入原始影像分類	43
伍、 結論與建議	46
一、 結論	46
二、 建議	47
參考文獻	48
附錄	53

壹、緒論

一、研究動機與目的

早期農作物調查皆以人力進行，但往往受限於面積或其他因素，使得要對調查範圍做全面性的檢視如此不但費時而且不易行之，若能運用利用遙測(Remote Sensing)技術進行土地利用調查，即使調查範圍廣大仍可透過影像進行判釋與分類的工作。

遙測即所謂的遙感探測，是指利用感測器，在不接觸目標物的情況下，即能獲得該目標物的資料，來進行分析及應用，因此廣義來說，人類眼睛所看到的任何事物，即依靠眼睛這個感測器來獲得周遭的資料，也是屬於遙測的一種。

近年無人飛行載具(Unmanned Aerial Vehicles; UAVs)應用於農業的情形越來越多，除了具高機動性外，影像較不受雲霧遮蔽，特別是無人機所搭載的相機可以獲得比衛星或飛機航空攝影更細緻的彩色影像，更成為繼人造衛星與飛機外另一個遙測領域的重要工具。

本研究所使用的 UAV 彩色影像具有 RGB 三波段影像，雖然具有高解析度，但為了更有效分類光譜反應近似的農作物，而藉由其他地表特徵輔助判釋，例如地物之形狀(Shape)、大小(Size)、紋理(Texture)、位置(Site)及關連性(Association)等等，其中的影像紋理因子更是受到空間分布的影響，所以在光譜反應接近的地方便可利用紋理因子辨識不同的地物，本研究利用紋理因子加入原始影像，希望能提升地物分類精度。

從原始彩色影像產生紋理影像的過程，有若干參數需要手動設定，本研究在不同參數的情形下得到不同的紋理影像，並加入原波段影像後，利用機器學習中的隨機森林(Random Forest)演算法對影像做地物分類，並比較不同移動視窗大小所產生的紋理影像與原始影像所分類的結果並找出最佳分類的結果。綜合上述，將本研究之目的整理如下：

- 一、證明灰階共生矩陣(Gray-level Co-occurrence Matrix; GLCM)所產生的紋理因子的加入能提升整體影像分類的精度。
- 二、不同移動視窗大小的紋理影像將對分類造成不同的分類成果，本研究將測試出最適合的移動視窗大小。
- 三、探討隨機森林分類器在農作物分類上是否具有良好性能。
- 四、探討隨機森林在農作物分類時最佳參數的設定，並建立最佳分類模型。

二、研究流程

本研究之流程如圖 1.1 所示，首先為影像獲取與預處理。將無人機獲取之影像利用商用軟體 Pix4D 處理後得到正射化影像，接著分作兩部分進行影像分類與後續分析。第一部份利用三波段彩色影像(R、G、B)之光譜值進行最短距離法與隨機森林分類；第二部份為紋理分析，利用不同移動視窗大小的紋理影像加入三波段影像，找出隨機森林的最佳參數並進行影像分類；第三部分透過誤差矩陣(Error Matrix)作精度評估，以比較三波段原始影像與九波段的分類精度差異。

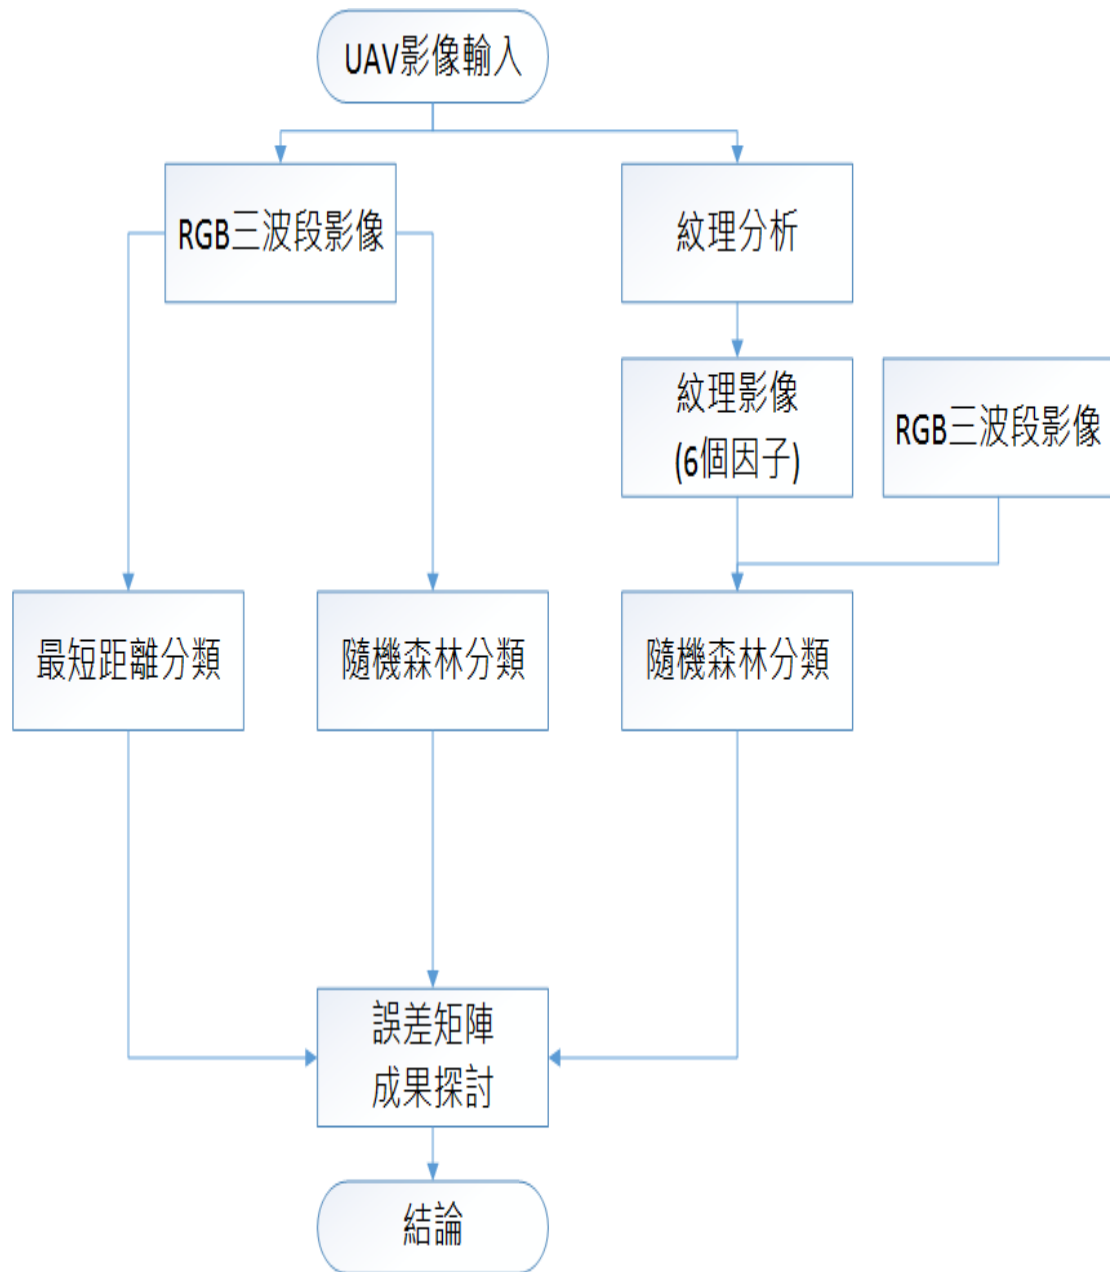


圖 1.1 研究流程圖

三、研究架構

本研究共分為四章，各章內容簡述如下：

緒論

介紹研究的動機與目的、研究流程與論文架構。

文獻回顧

介紹依照本研究所需而蒐集的相關理論與文獻，包含紋理特徵與影像分類法。

研究方法

介紹本研究中所應用到的理論與方法，以了解理論的使用方法與時機。

實驗流程與分析

本章將介紹實驗區域、影像來源，並顯示實驗成果與分析，先利用最短距離法與隨機森林分類器進行可見光波段的影像分類，接著紋理影像計算並加入隨機森林分類器，以誤差矩陣進行精度評估與分析。

結論與建議

將本研究得到的結果整理出結論與建議，針對後續研究提出新方向。

貳、文獻回顧

一、水稻田判釋基礎

1、水稻田生長知識

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，許多學者利用水稻特有的生長周期特性，結合地物光譜反應與時間特性對水稻田進行判釋，更有研究充分利用既有的耕地丘塊圖進行區域式分類；後來隨著商用高解析度衛星影像的發展，有學者利用影像紋理資訊，輔助高解析度衛星影像中水稻田面積判釋；近來更有學者利用影像邊緣資訊進行水稻田 GIS 底圖的製作。因此，在本章節中將對衛星影像於水稻田判釋之相關研究作介紹與回顧。

水稻自插秧到成熟收割所需時間的長短，隨著品種和種植環境的不同而有差異；在台灣，水稻的種植大致可區分為一期稻作和二期稻作兩期，僅少數區域可種植三期。通常一期稻作於春季插秧、夏季收穫，而二期稻作則是在夏季插秧、秋季收穫。一期稻作從插秧到收割所需的時間約為 110~140 天，而二期稻作則為 98~110 天。水稻生育期別及生長日期間的對照如圖 2.1 所示。




圖 2.1 水稻田生長週期圖 (黃則林, 1982)

2、水稻田生長光譜特性

水稻的種植，從插秧前 2~3 週起，水稻田即需開始供水以供整地育苗用，自整地育苗到水稻開始生長，田地皆需不斷地供水灌溉，直到收割前約十天才停止灌溉。

雖然水稻田大部分的時間一直保持著含水的狀態，但實際上水稻田在插秧前 2~3 週一直到插秧前，所呈現出來的地表覆蓋為水體或含豐富水分的土壤；而後水稻田插秧，田中的土地覆蓋變為植被與水體的組合；從最高分蘗期一直到收割前，水稻的成長使得水稻田的地表大部分被植被所覆蓋；直到收割後，水稻田才會又露出土壤，成為乾燥的裸露地，而隨著水稻生長周期的變化，影像光譜亦會呈現相應之規律變化。

3、水稻判釋相關研究

劉建慧(1988)以同一地區、不同時期經大氣輻射校正後之 SPOT 衛星多光譜影像為研究對象，藉以求取不同時期水稻的光譜反射率，建立水稻動態光譜，以作為水稻絕對分類的依據。

陳哲俊(1994)以不同時期 SPOT HRV 衛星影像，研究水稻在不同生長期各波段影像灰度值的光譜變化曲線；經由輻射正規化後，建立水稻動態植被光譜資料庫，以判釋稻作插秧期的種稻區域，並估算插秧進度。成果顯示水稻在不同生長期具有不同的光譜反應，避免與當地的其他地物混淆，藉以求得較高的分類精度；所以結合多時段影像可有效改善單一時期特定作物分類準確度不高的缺點。

吳政庭(2004)利用捷鳥(QuickBird)衛星影像進行水稻的耕作面積判釋，以半變異元(Semi-varogram)模型建立方向、絕對、交叉、虛擬半變異元影像紋理，以輔助光譜影像判釋，同時更進一步的使用融合後影像進行影像分類，成果顯示，加入影像紋理資訊能提升高解析度衛星影像於水稻田判釋精準度，另外在提高空間解析度的同時，亦對分類成果有所助益。

二、紋理分析理論

Haralick (1973)首先提出灰階共生矩陣(GLCM)，用以描述統計空間上具有某種位置關係的像元灰階對出現的頻率。灰階共生矩陣反映了圖像灰階分佈關於方向、局部鄰域和變化幅度的綜合資訊，但是它不能直接提取區域紋理的特性。因此，為了能描述紋理的性

質，有必要從灰階共生矩陣中進一步提取描述圖像紋理的特徵。

Haralick 定義了 14 種紋理特徵，用於提取遙感影像紋理資訊的特徵統計量主要有同質性(Homogeneity)、對比度(Contrast)、均值性(Mean)及角二階矩(Angular Second Moment)等，概要描述如後。

1、紋理描述與種類

紋理主要是用來描述地表物在影像中灰階的變化及空間排列之情形。在高解析力影像中，類別往往是由一群相鄰的像元組成的區塊，同一類別地表物在影像上所顯現出來的像元排列方式多半有一定的規則，如地表物的形狀、圖樣及排列方向等，這些資訊稱為紋理資訊，由於紋理分析能針對影像的光譜特性提供額外的輔助資訊，利用紋理特徵上的差異性達到分辨不同地物的目的，近年來在數位影像的處理及辨識上佔有越來越重要的地位。紋理概分為三類(沈育佳，1998；林榮章，1999):

1. 決定性紋理(Deterministic textures)：

可由人為方式計算出來，經由精確的排列規則所定的紋理。

2. 結構性紋理(Structural textures)：

由一種或多種紋理基元(Primitive)依照某種規則而組成的紋理，大部分的人工紋理皆屬之。

3. 隨機性紋理(Stochastic textures)：

大部分屬於自然的紋理，其排列的方式與組成基元多為隨機的，但必須是同質的(Homogeneous)。

2、紋理分析方法

紋理通常牽涉到圖形排列的問題，所以需要更高階的分法來達成紋理分析。紋理分析的主要目的是要模擬人類分辨紋理的能力，且在於找出合適的影像紋理描述子(Descriptor)或(Feature)，據以判別不同紋理或質地的影像類別。紋理的分析之中，最簡單的方法是透過灰度值統計圖來做分析，例如一些比較簡單的紋理，可以直接透過灰度值統計圖來分類。

方法之一是比較其灰度值出現機率最高的群族所出現的位置(郭立穎，1997)。但主要來說，紋理分析的方法分為三種：

1. 結構型分析法：

著重紋理基元及取代法則的製定，認為紋理是由一個或多個紋理基元透過某一排列規則組合而成的，像元解像力改變對影像紋理特徵與辨識將有所影響。

不過結構法在分析紋理規則較不明顯的影像時，卻容易遭到困難，因為這些影像的紋理單位不易萃取，而且想要描述其排列規則更是一件極為複雜的工作，所以結構法紋理分析較不適合於自然界的遙測影像(林榮章，1999)。

2. 統計型分析法：

著於紋理特徵的抽取，強調整個紋理給觀察者的印象，紋理可以由一組統計特徵所描述，這些統計值可由最簡單的一階統計量，比如統計灰階值的平均值、直方圖或變異數也可以分辨部份的紋理。較常見的影像量化法有灰階共生矩陣、碎形維度法與半變異元法等，其中又以 Haralick (1973)提出的灰階共生矩

陣最為大眾使用。

3. 頻譜型分析法:

乃利用影像之傅利葉頻譜，依其波形辨識整幅影週期性紋理之主要方向、空間週期、或光譜能量。

在數值影像中，區塊的形成是因為在某個範圍中，其像元的灰階值俱均調性、或形成一個固定形式的重現性，而使人類的眼睛的視覺自然地將它視為一個整體，稱為灰值均調區(Homogeneous Region)和相同紋理區(Uniform Texture Region)。

其中影像的能量頻譜定義如(Gonzalez & Woods, 1993)：

$$P(u, v) = F(u, v)F^{-1}(u, v) = |F(u, v)|^2$$

上式中 $F(u, v)$ 為影像 $f(u, v)$ 的傅立葉轉換， $F^{-1}(u, v)$ 為 $F(u, v)$ 的共軛複數。

3、紋理分析相關研究

紋理是影像中的重要特質之一，在先前的研究中，也可發現廣泛地應用紋理於遙測影像上，不論在微生物影像分析，醫學分析等等，都可見到紋理的實用性。且隨著影像處理技術的進步，有別於以往利用光譜值分類，利用地表紋理的變化作為分類的依據也逐漸普遍，以下將介紹相關紋理分析應用。

沈育佳(1998)應用紋理影像分析方法將影像的特徵如角二次矩、對比、相關度、同質度、熵、熵總和、熵差、群集傾向及行長機率等，對於都會區的空載多光譜掃瞄影像中，以討論不同地物類別其

光譜反射灰階在空間分佈的特性。分別比較各個地物類別的紋理特徵值之差異性。此研究未對影像間灰階的範圍作一討論，但此會對於紋理辨識空間是會造成影響的。

郭秀玲(2003)紋理分析於農地利用判釋之研究-以苗栗縣大湖鄉為例，將五種紋理因子參數影像個別加入原始影像圖分類後與傳統分類比較,發現每一種參數對於影像分類判釋上皆有提昇的效果。

陳彥宏(2004)運用紋理資訊輔助高解析度衛星影像於都會區水稻田萃取之研究，以 QuickBird 衛星影像，加入灰階共生矩陣輔以分析，進行都市地區水稻面積偵測，證明高解析度影像加入灰階共生矩陣提高分類精度的可行性。

杜青松(2016)利用灰階共伴隨矩陣輔助 UAV 於多光譜影像土地覆蓋與利用分類之研究，研究成果顯示當 UAV 光譜影像增加了紋理特徵時,在分類精度上有顯著的提升。

三、影像分類理論

1、影像分類理論

在影像分類中包含監督式分類與非監督式分類兩種，兩者的差異在於監督式分類需要選出訓練樣本再依據訓練樣本的資訊作為後續分類的依據，常見的監督式分類有支持向量機、最大概似法、決策樹、knn 與類神經網路等等；而非監督式分類則要先決定欲分類的類別數量等其他參數，由分類器檢視所有須被分類的資料的特徵值，利用這些資料的特性分成數個群體，稱為分群(clustering)，常見的非監督式分類器有 K-means、ISODATA 與 Fuzzy C-means 等。

2、影像分類相關研究

Gislason *et al.* (2006)將隨機森林與另外兩個集成學習演算法 (boosting 和 bagging), 利用 Landsat 衛星多光譜掃描儀(MSS)的四波段資料, 加上高程、斜率、和方向資料所形成的 7 個變量, 對科羅拉多土地覆蓋類別進行分類, 結果表明隨機森林的分類成效與 boosting 相近且大於 bagging, 但隨機森林的訓練速度比 bagging 快且比 boosting 快很多。

Mochizuki *et al.* (2012)研究中增加了分類迴歸樹, 利用日本新潟縣佐渡島土地覆蓋類別的分類, 對 boosting、bagging、分類迴歸樹和隨機森林等機器學習演算法進行比較, 與上述研究結果相似, 該研究成果顯示, 隨機森林分類成效略高於 boosting, 前述兩者皆較 bagging 為佳, 而分類迴歸樹最差, 證實集成學習能實現弱分類器可強化為強分類器之目標。

歐鐙元(2015)應用隨機森林演算法於 WorldView-2 衛星影像大蒜分類判釋之研究, 以最大概似法與隨機森林進行蒜頭判釋, 整體精度並無明顯差異, 但在訓練樣區面積僅佔整體影像約 1.3%之情形下, 顯示隨機森林擁有於遙測影像農作物大蒜判釋之分類能力。

參、研究方法

一、灰階共生矩陣

影像中灰階值的統計方式主要可分為一階與二階兩種。像是灰階的平均值(Mean)、變異數(Variance)、或直方圖(Histogram)都屬於一階的統計方式，這些統計方式的優點是簡單明瞭且計算快速，但是對於影像的整體描述卻稍嫌不足。

灰階共生矩陣(GLCM)(Haralick, 1973)是一種廣泛應用的紋理統計分析方法，由它所生成的參數可以描述紋理多方面的統計特徵。灰階共生矩陣描述統計空間上具有某種位置關係的像元灰階對出現的頻度。灰階共生矩陣反映了圖像灰階分佈關於方向、局部鄰域和變化幅度的綜合資訊，但是它不能直接提取區域紋理的特性。因此，為了能描述紋理的性質，有必要從灰階共生矩陣中進一步提取描述圖像紋理的特徵。Haralick (1973)定義了 14 種紋理特徵，用於提取遙感影像紋理資訊的特徵統計量主要有同質性(Homogeneity)、對比度(Contrast)、均值性(Mean)及角二階矩(Angular Second Moment)等。

本研究使用 GLCM 作紋理分析，它是用來統計每一對可能的灰階值出現在特定相關位置上的頻率。其步驟如下(沈育佳，1998)：

1. 首先對影像定義：假設原始影像 I 為矩陣，在水平方向有 N_x 像元，在垂直方向有 N_y 像元，並假設顯示在每一個像元的灰階色調是被量化為 N_g 階。接著令 $L_x = \{1, 2, \dots, N_x\}$ 為水平方向空間定義域， $L_y = \{1, 2, \dots, N_y\}$ 為垂直方向空間定義域， $G = \{1, 2, \dots, N_g - 1\}$

是 N_g 個量化的灰階組。此 $L_x \times L_y$ 是表示整幅影像像元組的排列。

2. 位移向量(d, θ)：欲將一幅影像轉換成共生矩陣時，必須先決定期像元對間的位移向量，如圖 3.1 所示，再依此位移向量計算出位置矩陣。




圖 3.1 位移向量(d, θ)

3. 位置矩陣(P_{ij})：即所謂的共生矩陣

- (1) 紋理的基本組程式由四個與紋理特徵推導緊密相關的方向來量測，如圖 3.2 所示，像元 4 和 8 與中心像元呈 0 度；像元 3 和 7 與中心像元呈 45 度；像元 2 和 6 與中心像元呈 90 度；像元 1 和 5 與中心像元呈 135 度。




圖 3.2 位置矩陣 4 個方向示意圖

- (2) 假設在影像 I 中，其兩相鄰的像元個別灰階值為 i 與 j 在相距 d 的距離時所發生的頻率，以矩陣來表示即為位置矩陣。此矩陣

為對稱矩陣，#符號表示為其個別方向位置矩陣裡像元的數目。
 以一幅灰階值介於 0~3 的影像而言，其位置矩陣的運算如下圖 3.3 所示：

	0	1	2	3
0	#(0,0)	#(0,1)	#(0,2)	#(0,3)
1	#(1,0)	#(1,1)	#(1,2)	#(1,3)
2	#(2,0)	#(2,1)	#(2,2)	#(2,3)
3	#(3,0)	#(3,1)	#(3,2)	#(3,3)

圖 3.3 影像 0~3 灰階的位置矩陣

4. 正規化共生矩陣 $C(ij)$ ：在求取紋理特徵之前，會先將位置矩陣 P_{ij} ，進行一個正規化的動作，如所示，其所代表的意義為影像灰階值 i 與 j 出現在相對位置 (d, θ) 的聯合機率(Joint probability)，可供各項紋理特徵之計算。

$$C_{ij} = \frac{P_{ij}}{\sum_{i=0}^n \sum_{j=0}^n P_{ij}}$$

式中 i 表示矩陣中的列， j 表示矩陣中的行， $C(ij)$ 表示 C 矩陣中的 i 列地 j 行的元素。

5. 假設紋理參數給定大小為 5×5 的灰階矩陣，其灰階值介於 0~2，所以 GLCM 矩陣大小為 3×3 。計算共生矩陣時，首先決定位移向量 (d, θ) ，在這個例子中距離為 1，角度方向 θ 分別取 0 度、45 度、90 度和 135 度四個方向，接著再依圖 3.3 的位置矩陣，計算出整個影像的共生矩陣 P ， $\#(i, j)$ 表示 i 與 j 相鄰時發生的次數，例如：以 0 度方向共生矩陣在 $(0, 0)$ 這個位置為值，先檢

查灰階值為 0，而且左邊或右邊同樣為 0 的情況，統計其在影像中發生的次數，如圖 3.4 原始影像的共生矩陣在(0, 0)的值，在整幅影像中發生的次數為 8，依此類推，計算出四個方向的位置矩陣。最後再經過正規化，即分別除以其位置矩陣出現的總次數，進而求得共生矩陣 C。以 0 度方向矩陣為例，計算成果如圖 3.5 及圖 3.6 所示。

0	1	1	2	0
1	0	1	2	0
0	0	1	1	0
2	1	1	0	0
2	1	0	0	0

圖 3.4 原始影像

	0	1	2
0	8	7	2
1	7	6	4
2	2	4	0

圖 3.5 0 度方向灰階位置矩陣

	0	1	2
0	8/40	4/40	2/40
1	7/40	6/40	4/40
2	2/40	4/40	0

圖 3.6 正規化後 0 度方向灰階共生矩陣

GLCM 矩陣提供了影像中灰階值空間分佈情形的資訊，但我們

尚需將之進一步量化為單一數值的形式，方能提供電腦直接分析使用。紋理的量化方式有許多種，Haralick (1973)曾建議了 14 種可用來量化 GLCM 矩陣的紋理統計量(Texture Statistics)，本研究將採用下列參數。

1、灰階共生矩陣參數決定

運用 GLCM 分析法進行分析時，有下列四個重要的參數需要決定，包括影像灰階值範圍、移動視窗大小、像元對之間的距離與方向及紋理量化因子。

一、影像的灰階值範圍

此參數間接決定了共生矩陣的大小，在遙測影像中灰階值之動態範圍通常為 0~255，其灰階共生矩陣 C_{ij} 將大到 256x256，計算運算時間較為耗時。若要節省時間，可以視精度要求，把影像的灰階值範圍做一個適當的縮減。若將影像的灰階範圍縮減為 16 個灰階，則計算時間將大幅減少為原來的 1/256 (黎瑋，1997)。

為減少矩陣之運算量與計算時間，本研究將以 8 的灰階量進行計算，且於先前已評估過此一灰階範圍之改變並不會對後續之分析與應用造成影響。再者 Marceau *et al.* (1990)的研究中指出，影像灰階值範圍相較於移動視窗大小及紋理統計量這兩個參數而言，其影響力僅佔約 3%，且此項參數並非本研究欲加以探討研究之部分，故未深入探究灰階範圍改變之影響。

二、移動視窗的大小

移動視窗的大小，主要是依據在計算每個像元的紋理值時，需要同時考慮到該像元周圍多大的範圍而決定。實際在做分析時，若

是移動視窗的大小比要分析的紋理取樣影像還小時，則視窗中所包含的資訊將不足以代表此一取樣影像；若是視窗過大，則可能會包含過多其他取樣影像的資訊進來。Marceau *et al.* (1990)指出此參數對於紋理分析結果之影響極大，佔了約 90%之多。

三、位移向量(距離、方向)

位移向量的決定又可分為距離及方向兩個部分。其中距離指的是取樣時相距的像元數目，於方向則是取樣時兩像元的相對方位，如 0° 、 45° 、 90° 、 135° ，在紋理分析的過程中，因為地物並無特定走向，我們會以各個方向的平均方向矩陣來取代單一方向矩陣。

四、紋理統計量的選取

有關紋理統計量(Texture Statistics)的選擇依據，目前並沒有有一定的準則，大部分多是採用前人所常用的一些統計量，如 Contrast、Energy、…等。在 Marceau *et al.* (1990)的研究中指出，不同的紋理統計量對於分析成果約有 7%的影響。由於這些統計量之間都具有一定程度的相關性(Baraldi & Parmiggiani, 1995)，使得同一張影像的某些紋理特徵的表現會相當類似，不過由於不同影像間最適用的紋理統計量都不盡相同，所以一般使用上多是同時選用幾組較常用之統計量一起進行分析。

本研究選用幾個比較常被使用的統計指標進行紋理分析，包含對比度、不相似度、角二次矩、同質度、熵、和相關度共六種紋理因子，下列將介紹本研究所使用的紋理因子：

令 N_g = 影像量化的灰階數

$$C_x(i) = \sum_{j=1}^{N_g} C(i, j) \quad C_y(j) = \sum_{i=1}^{N_g} C(i, j)$$

$$\mu_x = \sum_i^{N_g} i \sum_j^{N_g} C(i, j) \quad \mu_y = \sum_i^{N_g} j \sum_j^{N_g} C(i, j)$$

$$\sigma_x^2 = \sum_i^{N_g} (i - \mu_x)^2 \sum_j^{N_g} C(i, j) \quad \sigma_y^2 = \sum_j^{N_g} (j - \mu_y)^2 \sum_i^{N_g} C(i, j)$$

其中 μ_x, σ_x 是 C_x 的平均值和標準偏差

μ_y, σ_y 是 C_y 的平均值和標準偏差

一、對比度(Contrast)

乃用來度量影像中對比的強烈程度，其值與對比強度成正比。這項參數主要是反應出 C_{ij} 矩陣中元素在主對角線上集中的情形，當比較大的數值都集中在主對角線附近時，此參數值會趨小，即對比較差。

$$\text{Con} = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} (i - j)^2 C(i, j)$$

二、不相似度(Dissimilarity)

乃用來度量影像中灰階值的不相似程度，它對於灰階值在空間中的排列情形或是影像的色調都很敏感。

$$\text{Diss} = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} C(i, j) |i - j|$$

三、角二次矩(Angular Second Moment)

是灰階共生矩陣元素值的平方和，也稱作能量。乃是用來度量

紋理的一致性或均勻性，影像之紋理越均調或越一致時， C_{ij} 矩陣中的值就會集中在少數幾個元素上，則 ASM 值越大；反之，當矩陣的元素分佈的值越平均時，此項數值會越小。

$$ASM = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} (i - j)^2$$

四、同質度(Homogeneity)

或稱反差矩(Inverse Difference Moment，IDM)，此項參數是在計算 C_{ij} 矩陣中，元素聚集在主對角線附近的程度，當矩陣中比較大的數值都集中在主對角線附近時，此項數值會越大。其乃是用來度量影像中的均調程度，當影像越均調或對比越弱時，Homo 值越大。

$$HOMO = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} \frac{C(i, j)}{1 + (i - j)^2}$$

五、熵(Entropy)

是一個隨機性的度量，它表示了圖像中紋理的非均勻程度或複雜程度，當影像越是隨機時，Entropy 值越大。

$$Ent = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} C(i, j) \log(i - j)$$

六、相關性(Correlation)

描述 GLCM 中行或列之間的相似性，它反映某種灰階值延某個方向的延伸長度，若延伸的越長，則相關性越大，它是灰階線性關

係的度量。

$$\text{COR} = \frac{\sum_{i=0}^{N_g} \sum_{j=0}^{N_g} ij C(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$$

二、隨機森林

此演算法被歸類為機器學習的一種方法，是一種基於決策樹改良的演算法。到了 1980 年代的時候，Breiman 等人發明了分類回歸樹的演算法，透過反覆的二分資料進行回歸或分類，大大的減少計算量，雖然分類規則透明，但卻有著準確率不高的缺點。因此，到了 2001 年時，Breiman 和 Cutler 學者借鑒貝爾實驗室的 Ho 所提出之隨機決策森林(Random Decision Forest)的方法，在決策樹基礎上開發成隨機森林演算法(Breiman, 2001a)。隨機森林演算法是在樣本（列）的運用和特徵（行）的運用上將其隨機化，然後產生許多決策樹進行運算，再將各決策樹匯總成最後的結果。因此，隨機森林演算法可以在運算量並沒有顯著提升的前提之下提高了預測的準確度。而由於隨機森林演算法對於多元共線性不敏感，所以其結果對於非平衡的資料和遺漏資料比較穩健，也因此可以很好得預測多達幾千個解釋變量之作用(Breiman, 2001b)。

在了解隨機森林前，首先要先知道隨機森林的基礎，分類回歸樹的演算方式，分類回歸樹是決策樹的一種，以樹狀的結構（參考圖 3.7），從上而下由根節點(S1)，許多的分叉路徑(a1, a2, …, a10)與眾多的子節點(A1, A2, …, A4)組成，並在最後產生葉節點(B1, B2, …, B6)，將要分類的樣本由根節點輸入，而後在每個節點選用

一個特徵變量對節點內的樣本進行分割，經由分叉路徑到達下一個子節點，每個分叉路徑對應一個特徵變量值，而最後到達的葉節點便代表著每個分類，相較於傳統決策樹最大不同的地方在於，分類回歸樹所採用的是二元決策樹的概念，即每次的分割只分為兩類，而且分割時所選擇的特徵變量之方式是採用吉尼指數（Gini Index）的計算。假設集合 S 包含了 N 個類別的樣本，那麼其吉尼指數就是：

$$\text{gini}(S) = \sum_{j=1}^N P_j (1 - P_j) = \sum_{j=1}^N P_j - \sum_{j=1}^N P_j^2 = 1 - \sum_{j=1}^N P_j^2 \quad (3.1)$$

其中 P_j 為類別 j 在集合 S 中出現的機率。




圖 3.7 決策樹示意圖

吉尼指數所算得即是一個集合中的資料純度，因此在輸入樣本資料時，需給定已知之類別項目，即輸入訓練樣本（已知類別）之

資料，依此樣本所提供之類別項目，計算分割之吉尼指數，找尋最佳之特徵變量值（在遙測判釋中即為各波段之光譜反射值），吉尼指數的值愈大，則該集合純度越低；吉尼指數的值愈小，則該集合純度越高，而在最佳分割方式便是分裂出純度較高之集合，即求出吉尼指數的值最低之解，此解之值就是該次分割之特徵變量值。

而何謂純度，以下簡單的例子即可清楚了解，若集合 S 中，所有的資料都是同一個類別，帶入吉尼指數公式(3.1)中，即此類別 j 在集合 S 中出現的機率會等於 100%，而該集合 S 因只有一個類別，因此算式為：

$$\text{gini}(S) = 1 - 1^2 = 0$$

而若是集合 S 中有兩個類別，且所比例分別為 90%與 10%，將此帶入公式後，則為：

$$\text{gini}(S) = 1 - (0.9^2 + 0.1^2) = 0.18$$

若是合 S 中有兩個類別，且所比例分別為 50%與 50%，將此帶入公式後，則為：

$$\text{gini}(S) = 1 - (0.5^2 + 0.5^2) = 0.5$$

由此可知，當集合 S 中都為同一類別，即純度最大時，吉尼指數為 0，而在多個類別中，當一個類別所佔比例愈高，吉尼指數會愈小，分類回歸樹之分割方式，是以吉尼指數最小值來求最佳分割解。而公式 3.1 所代表的為單一集合時之計算情況，不會有分割的情形發生，如果現在要對 S 集合進行二元分割，如分割成兩區域 N_1 與 N_2 ，此時分割所根據的吉尼指數式子為：

$$gini_{split}(S) = \frac{N_1}{N} gini(D_1) + \frac{N_2}{N} gini(D_2) \quad (3.2)$$

而分類回歸樹在進行分割時所選擇的特徵變量之規則，即是選擇具有最小 $gini_{split}$ (吉尼指數值) 的特徵變量來進行分割。

為說明計算吉尼指數之分割方式，本研究帶入簡單案例說明之 (參照表 3.1)，若一個訓練樣本 (集合 S) 裡有 A 與 B 兩種類別 ($N=2$) 之樣本資料共 10 筆 (表 3.1)，所以在集合 S 中的吉尼指數帶入公式 (公式 3.1) 可得：

$$gini(S) = 1 - (0.6^2 + 0.4^2) = 0.48$$

表 3.1 範例之樣本資料

類別	X1	X2
A	13	6
A	19	9
A	15	5
A	20	6
A	11	3
A	15	7
B	8	9
B	9	9
B	10	11
B	9	6

而每筆資料有 X1 和 X2 兩種作為分類依據之特徵變量，為了找尋最佳分割方式，需將 X1 與 X2 兩種特徵變量之值，透過吉尼

指數之計算，可以發現若特徵變量值以 X_1 裡的 13 來做分割，一邊為 $X_1 \leq 13$ ，一邊則為 $X_1 > 13$ ，由圖 3.8 可以發現 A1 節點共有 6 個樣本，其中 A 類別有 2 個，而 B 類別有 4 個，而 A2 節點同樣有 4 個樣本，但皆為 A 類別之樣本，以此帶入(3.1 與 3.2) 計算，可得：

$$gini(X_1 \leq 13) = 1 - \left(\left(\frac{2}{6} \right)^2 + \left(\frac{4}{6} \right)^2 \right) = \frac{4}{9}$$

$$gini(X_1 > 13) = 1 - 1^2 = 0$$

$$gini_{split}(S) = \frac{6}{10} \times \frac{4}{9} + \frac{4}{10} \times 0 = \frac{4}{15}$$



圖 3.8 分割方式 1

若以 X_2 中的 6 作為分割之特徵變量值，一邊為 $X_2 \leq 6$ ，另一邊為 $X_2 > 6$ ，透過圖 3.6 可得知 A1 節點中共有 5 個樣本，其中 4 個為 A 類別，1 個為 B 類別，而 A2 節點中有 5 個樣本，其中 2 個為 A 類別，3 個為 B 類別，以此帶入公式可得：

$$gini(X_2 \leq 6) = 1 - \left(\left(\frac{4}{5} \right)^2 + \left(\frac{1}{5} \right)^2 \right) = \frac{8}{25}$$

$$gini(X_2 > 6) = 1 - \left(\left(\frac{2}{5} \right)^2 + \left(\frac{3}{5} \right)^2 \right) = \frac{12}{25}$$

$$gini_{split}(S) = \frac{5}{10} \times \frac{8}{25} + \frac{5}{10} \times \frac{12}{25} = \frac{10}{25}$$



圖 3.9 分割方式 2

依據選擇最小 $gini_{split}$ 之原則，因此此次最佳分割方式為以特徵變量值 $X_2 \leq 13$ 的方式進行分割。

分類回歸樹透過重複以上之方式來建構一顆完整的決策樹，而隨機森林便是以此基礎，將一棵棵的決策樹，組合成決策樹森林，隨機森林可以解釋多個特徵變量 $(X_1, X_2 \dots X_k)$ 對因變量 Y 的作用。如果因變量 Y 有 n 個樣本資料，有 k 個特徵變量與之相關，在建構決策樹的時候，隨機森林採用重複抽樣的方法，會隨機的在原訓練樣本資料中選擇 n 個樣本，其中有的樣本會被抽樣多次。同時，

隨機森林隨機的從 k 個特徵變量選擇部分變量進行決策樹節點的確定。這樣，每次建構的決策樹都可能不一樣。在一般情況下，隨機森林會隨機生成幾百個至幾千個決策樹，然後選擇重複程度最高的類別作為最終結果 (Breiman, 2001a)。

隨機森林的建構模型的方法是生成很多決策樹，接著，由這些決策樹的結果去投票得出最終預測。因為是由很多決策樹表決，勢必這些決策樹必須有所差異。為了讓這些決策樹有所差異，在隨機森林的決策樹生成時，於每個節點挑選變數前會從所有變數中，假設為 M 個，隨機抽取 \sqrt{M} 個變數從中挑選最適合的特徵數來當作此點的分割變數。如此一來就可以生成多種不同的決策樹。除了在切割節點時會作變數的隨機挑選外，在生成決策樹以前會以 bootstrap 的方法來創造新的訓練資料(Training data)，也就是說每棵決策樹都會有不同的訓練資料，這樣更加強化了決策樹間的差異性。而那些未被抽出的資料理論上為 $1/e$ 。若我們總共有 N 筆資料，則沒被抽出的機率為：

$$\left(1 - \frac{1}{N}\right)^N \approx \frac{1}{e} \approx 0.3679$$

平均約會有 36.79% 的資料未被抽取出來，在隨機森林中將這些變數稱為袋外(Out of bag)資料。袋外資料可以當作驗證資料(Testing data)，計算方法是每棵生成的決策樹分析各自的袋外的資料，並計算其錯誤率，稱為袋外錯誤率(Out of bag error rate)，接著將每棵決策樹的袋外錯誤率平均即可得到隨機森林的錯誤率。

由於採取重複抽樣，因此在一個決策樹的生成中，會有部分資料沒有被抽樣，在隨機森林的演算中，會將這些沒被抽樣的 OOB

資料，用來進行錯誤率的評估，首先對每個訓練樣本，丟回所有其作為 OOB 資料時所建構的決策樹中進行分類，計算其在那些決策樹中分類的結果，藉著同樣透過簡單的多數決方式，對該訓練樣本決定其分類類別，重複以上方法將所有訓練樣本重新分類後，以分類錯誤的訓練樣本佔全部訓練樣本的比例為隨機森林的 OOB 錯誤率估計值。

OOB 錯誤率是隨機森林泛化誤差的一種無偏估計，且已在 Mutanga et al.(2012)的研究中證實，OOB 錯誤率的估計與需要經過大量計算的十折交叉驗證之結果相似，因此利用 OOB 錯誤率估計可以得到準確的錯誤率評估。

簡單來說，隨機森林依據下列步驟建造森林中的每顆決策樹：

1. 用 N 來代表訓練樣本的數目， M 代表變量的數量。
2. 必需設定一個數字 m ，要用來決定在一個分裂節點上進行分裂時，需使用到多少個變量，而且 m 應當小於 M 。
3. 在 N 個訓練樣本資料裡利用重複取樣的方式進行取樣，取樣 N 次後，形成一組訓練樣本（即 Bootstrap 取樣）。而且會使用各棵樹未被取樣之樣本資料做為測試樣本，將測試樣本放回決策樹進行分類，來評估其誤差。
4. 在每一個分裂節點上，隨機選擇 m 個基於此節點上之變量。而後依據這 m 個變量，透過吉尼指數之運算，找尋其最佳的分裂方式。
5. 每棵決策樹都任其完整生長而不進行剪枝（Pruning）。

隨機森林分類流程示意圖如圖 3.10 所示：

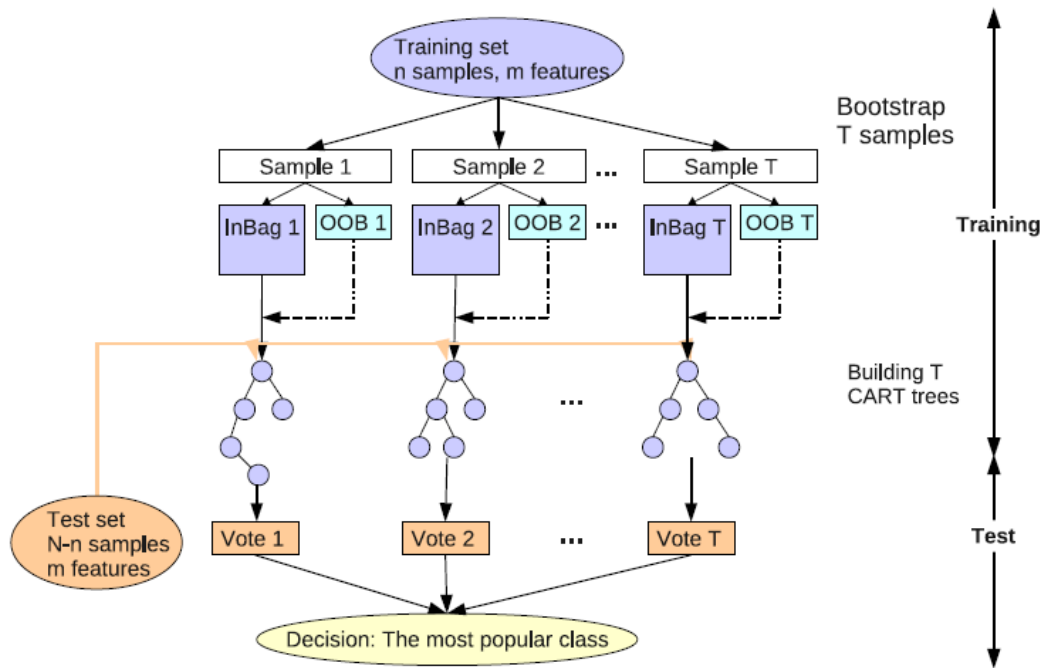


圖 3.10 隨機森林示意圖 (Guo *et al.*, 2011)

以上述方式重複產生不同的決策樹，最後將這些不同的決策樹組合起來，便可以產生一個隨機森林，而後以此訓練完成之隨機森林，將未分類之樣本資料輸入時，由這些決策樹對此未分類樣本進行分類，而此隨機森林分類之結果，即是將這這些決策樹對此未分類樣本之分類結果，每一顆決策樹只投一票給它認為最適合的分類類別，最後進行簡單的多數決方式，選擇投票最多的分類類別作為該未分類樣本之分類結果。

對於隨機森林來說，影響其分類效能的主要因素有以下兩點 (Breiman, 2001a)：

1. 森林中每棵樹的分類強度 (Strength)：每棵樹的差別越大，則隨機森林的分類效能越好。
2. 森林中每棵樹之間的相關性 (Correlation)：樹之間的相關性越大則隨機森林的分類效能越差。

1、參數選擇

依前一節所選定之訓練樣區，運行隨機森林進行訓練，首先透過隨機森林演算法內建之 OOB 錯誤率估計，評估最佳之參數設定，由於隨機森林對於使用者可調參數中，最重要的即為森林中決策樹的數量以及每次生成決策數所隨機採用的特徵變量數量，而本研究用於分類之波段數為 RGB 三波段加上四個紋理影像，代表分類的運算中可採用的特徵變量數總共為 9，另外，在決策樹數量的設定上，當 OOB 錯誤開始顯示收斂時應該獲得最優值。比最佳值更多的樹只會增加計算負擔，對準確度提高不會有太大的貢獻。

三、最短距離法

最短距離分類法 (Minimum Distance Classifier) 為一原理簡單、快速且使用方便的分類策略，其方法首先計算出每一類別訓練樣區的平均值 μ ，以決定出此類別位於空間之位置，最後未知類別的像元將依其光譜值的大小 DN，計算出其與各類別間之空間距離 D，依照空間距離的長短，將未知像元分為最靠近它的類別，其長度是使用歐基里德距離來度量 (Jensen, 1996)。

1、分類精度評估

影像經分類後須與地真資料進行精度分析，才能評估分類器的優劣與分類結果的精度，其中誤差矩陣 (Error Matrix) 是最常用來評估影像分類的方法，能顯示分類結果與地真資料的相對關係

(Lillesand *et al.*, 2004)。

本研究利用誤差矩陣進行分類評估，誤差矩陣內的行列值為總類別數，對角線上的元素 N_{ii} 代表每類別正確分類的數目，非對角線上的元素 $N_{ij}(i \neq j)$ 則表錯誤分類數目。以表 3.2 為例，各項精度指標可計算如下：

表 3.2 誤差矩陣

Error Matrix		分類成果					生產者精度
		類別 1	類別 2	類別 3	類別 4	合計	
檢核資料	類別 1	N_{11}	N_{12}	N_{13}	N_{14}	N_{1+}	PA_1
	類別 2	N_{21}	N_{22}	N_{23}	N_{24}	N_{2+}	PA_2
	類別 3	N_{31}	N_{32}	N_{33}	N_{34}	N_{3+}	PA_3
	類別 4	N_{41}	N_{42}	N_{43}	N_{44}	N_{4+}	PA_4
	合計	N_{+1}	N_{+2}	N_{+3}	N_{+4}	N	
使用者精度		UA_1	UA_2	UA_3	UA_4		

N_{ij} ：誤差矩陣中第 i 列第 j 行的數值。

N_{i+} ：誤差矩陣中第 i 列所有數值總和。

N_{+j} ：誤差矩陣中第 j 行所有數值總和。

N ：誤差矩陣中所有數值總和。

1. 生產者精度(Producer's Accuracy; PA): 表示已知地物被正確分類之百分比。

$$PA_i = \frac{N_{ii}}{N_{i+}} \times 100\%$$

2. 漏授(Omission Error; OE)：其意義與生產者精度相似，表示已知地物被遺漏掉而分類至其他類別之百分比。

$$OE_i = 1 - PA_i$$

3. 使用者精度(User's Accuracy; UA)：表示分類結果與已知地物確實相同之百分比。

$$UA_j = \frac{N_{jj}}{N_{+j}} \times 100\%$$

4. 誤授(Commission Error; CE)：其意義與使用者精度相似，表示分類結果與已知地物不同之百分比。

$$CE_j = 1 - UA_j$$

5. 整體精度(Overall Accuracy; OA)：為誤差矩陣中全部類別正確分類之百分比。

$$OA = \frac{1}{N} \left(\sum_{i=1}^M N_{ii} \right) \times 100\%$$

6. Kappa 指標(K hat ; \hat{k})：在同時考慮漏授與誤授之影響的情況下，分類結果與已知地物相似程度的指標， \hat{k} 值會介於 0~1 之間，而 \hat{k} 值越大則代表分類精度越高。

$$\hat{k} = \frac{OA - CA}{1 - CA} = \left[\frac{N \sum_{i=1}^M N_{ii} - \sum_{i=1}^M (N_{i+} N_{+j})}{N^2 - \sum_{i=1}^M (N_{i+} N_{+j})} \right]$$

$$CA = \frac{\sum_{i=1}^M (N_{i+} N_{+j})}{N^2}$$

肆、實驗步驟與成果分析

一、實驗區簡介

本研究以土庫鎮部分農田作為實驗區，如圖 4.1 所示，東與虎尾鎮交界，西與褒忠鄉為臨，南臨北港溪，西南與元長鄉為界，北接新虎尾溪崙背鄉為界，地形略為狹長方形，由此而南幅員緩緩增大，地勢平坦，南部幅員遼闊。其土地多為農地，又以水稻、花生為大宗，全鎮總面積約為 46 平方公里，本研究採用 UAV 影像，拍攝日期為 107 年 5 月 20 日。

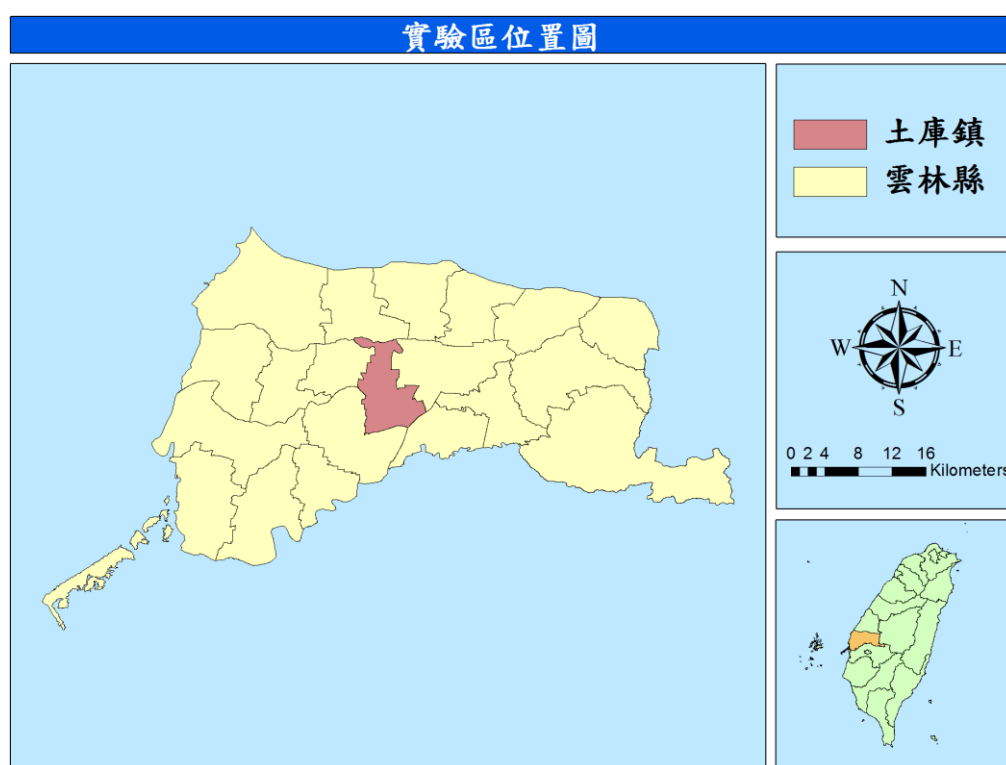


圖 4.1 實驗區位置圖

二、實驗材料

本研究所使用之無人飛行載具機型為 DJI Phantom 4 Pro，如圖 4.2 可獲得高品質、高解析度航測像片，基本規格如表 4.1。獲得的航測像片經 pix4D 軟體拼接後並裁切成實驗影像如圖 4.3 所示。

表 4.1 無人飛行載具基本規格(大疆官網，2018)

	DJI Phantom 4 Pro
起飛重量	1388 g
尺寸	289.5 × 289.5 × 196 mm (長×寬×高)
對角線軸距	350 mm
影像傳感器	1 英寸 CMOS 有效像素 2000 萬
鏡頭	視角：84 ° 等效焦距：24 mm 光圈：f/2.8-11 對焦點：1 m 至無窮遠 (帶自動對焦)
最大照片尺寸	5472×3648
GNSS	GPS+GLONASS
懸停精度	垂直： ±0.1 m (視覺定位正常工作時)； ±0.5 m (GPS 正常工作時) 水準： ±0.3 m (視覺定位正常工作時)； ±1.5 m (GPS 正常工作時)
圖片格式	JPEG / DNG (RAW)
最長飛行時間 (無風環境)	30 分鐘 (20 km/h 勻速飛行)
最大上升速度	6 m/s (S 模式) 5 m/s (P 模式)
最大下降速度	4 m/s (S 模式) 3 m/s (P 模式)
影像解析度	約 5 公分



圖 4.2 DJI Phantom 4 Pro(大疆官網，2018)



圖 4.3 可見光正射影像

三、紋理分析

本研究所取得的光譜影像具有 R、G、B 共三個波段，為了節省計算時間，本研究以綠色波段作為紋理分析的波段，並繼續後續的研究。

1、移動視窗大小決定

移動視窗大小在紋理分析中佔有非常重要的地位，若移動視窗太小，無法完整表現出地物特徵；若移動視窗太大，會涵蓋過多資

訊而無法凸顯地物的特徵，並造成後續的分類錯誤。Marceau *et al.* (1990)提到，影響分類結果最大的因素在於移動視窗大小的選擇，其影響可達 90% 以上。因此找出最適合的移動視窗大小極其重要，本研究選擇了 9×9、11×11、13×13、15×15、17×17、19×19、21×21、23×23、25×25、27×27 與 29×29 共 14 種移動視窗大小，在不同移動視窗大小下計算出的紋理特徵分別帶入到 RGB 圖像中以供進一步分類。

2、像元間距離與相對方向決定

移動視窗中像元間距的差別會對結果產生不同的影響，若選取的距離越大，兩像元間的相關性越小。本研究將採用固定 1 Pixel($d=1$)；像元間相對方向因為農作物生長方向並不完全一致，無法確切的以某個特定方向加以辨認，因此本研究將以四個方向 (0° 、 45° 、 90° 和 135°)的紋理影像加總取其平均。

3、紋理量化因子決定

計算出灰階共生矩陣後，要將矩陣內容量化成不同的因子進行後續的分析，本研究依 GLCM 計算六項統計指標紋理影像分別如圖 4.4~圖 4.9 所示：



圖 4.4 對比度(Contrast)紋理影像



圖 4.5 不相似度(Dissimilarity)紋理影像




圖 4.6 角二次矩(Angular Second Moment)紋理影像



圖 4.7 同質度(Homogeneity)紋理影像



圖 4.8 熵(Entropy)紋理影像




圖 4.9 相關性(Correlation)紋理影像

四、最短距離法影像分類

1、訓練樣本選取

本研究以最短距離法與隨機森林演算法進行影像分類，隨機森林屬於監督式分類的一種，必須在分類前先圈選出訓練區域，訓練樣本的分布位置如圖 4.10。




圖 4.10 訓練樣本分布圖

2、最短距離法原始影像分類

本研究以隨機森林進行可見光影像進行分類，得到的成果如圖 4.11 與誤差矩陣如表 4.3 所示：

表 4.2 最短距離法可見光影像誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	3918135	1750015	617327	85499	6370976	61.50%
	花生	1627154	2725966	649194	201726	5204040	52.38%
	玉米	230025	121623	131454	155548	638650	20.58%
	裸露地	25	22917	14808	1257242	1294992	97.08%
	合計	5903165	5056793	1235386	1313314	13508658	
使用者精度		67.84%	59.00%	9.30%	73.95%		
整體精度							59.46%
Kappa							0.38

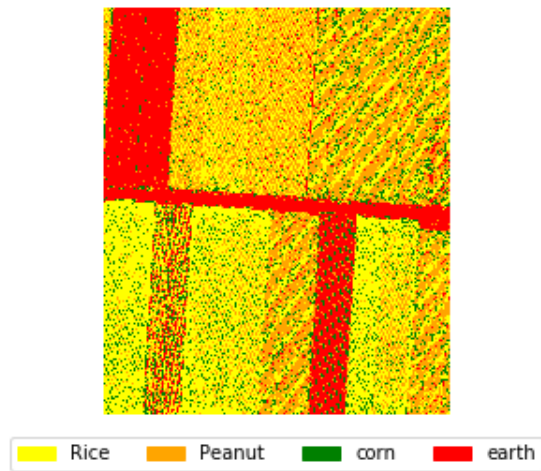


圖 4.11 最短距離法可見光分類成果圖

五、隨機森林影像分類

1、參數設置並建立分類模型

依前一節所選定之 12 個訓練樣區，運行隨機森林進行訓練，首先透過隨機森林演算法內建之 OOB 錯誤率估計，評估最佳之參數設定，由於隨機森林對於使用者可調參數中，用於分類的波段數為 9 個，代表分類的運算中可採用的特徵變量數總共為 9，另一個即為森林中決策樹的數量。為了評估最佳決策樹數量，本節利用 R+G+B 三波段訓練樣本與 R+G+B+texture 九波段訓練樣本作袋外錯誤率的評估，結果如圖 4.11 與圖 4.12 所示，顯示了不管是三波段或九波段的情況下，其袋外錯誤率皆在 750 棵決策樹左右得到收斂，但因此本研究將以 750 棵決策樹作為建構隨機森林模型的參數。




圖 4.12 R+G+B 之 OOB 評估




圖 4.13 R+G+B+texture 之 OOB 評估

2、隨機森林原始影像分類

本研究以隨機森林進行可見光影像進行分類，得到的成果如圖

4.13 與誤差矩陣如表 4.2 所示：

表 4.3 隨機森林可見光影像誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5482283	401703	486829	161	6370976	86.05%
	花生	409551	4611234	161949	21306	5204040	88.60%
	玉米	11331	43846	580879	2594	638650	90.95%
	裸露地	0	10	5729	1289253	1294992	99.56%
	合計	5903165	5056793	1235386	1313314	13508658	
	使用者精度	92.87%	91.19%	47.02%	98.17%		
整體精度							88.56%
Kappa							0.82

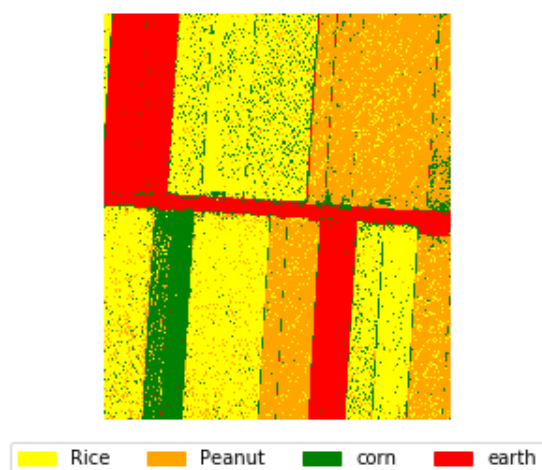


圖 4.14 隨機森林可見光分類成果圖

3、紋理影像加入原始影像分類

本研究將不同移動視窗大小的紋理影像分別加入原始三波段影像，最後得到最佳的精度是 21×21 的移動視窗所產生的紋理影像，其分類成果如圖 4.15 與誤差矩陣如表 4.5 所示：

表 4.4 隨機森林可見光+紋理影像誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核資 料	水稻	5812000	516301	10974	31701	6370976	91.15%
	花生	58321	5057320	70008	18391	5204040	97.13%
	玉米	1306	43274	581865	12205	638650	91.14%
	裸露地	119	17963	222	1276688	1294992	98.24%
	合計	5871746	563458	663069	1338985	13508658	
	使用者精度	98.98%	89.75%	87.75%	95.35%		
整體精度							94.22%
Kappa							0.91




圖 4.15 隨機森林可見光+紋理因子分類成果圖

另外，不同大小的移動視窗對整體分類、生產者與使用者精度之影響如圖 4.16~圖 4.18 所示。




圖 4.16 隨機森林可見光+紋理因子整體精度圖




圖 4.17 隨機森林可見光+紋理因子生產者精度圖




圖 4.18 隨機森林可見光+紋理因子使用者精度圖

伍、結論與建議

一、結論

1. 本研究所採用的 UAV 影像中，最短距離法所的可見光分類結果其總體精度為 59.46%，Kappa 為 0.38，而隨機森林的可見光分類結果為 88.56%，Kappa 為 0.82，顯示隨機森林分類器在無人機影像中分類的卓越性，而在加入適當的紋理影像後，總體精度更提高到 94.22%，Kappa 提升到 0.91，故得知加入適當的紋理因子後可提升地物的分類精度。
2. 本研究加入了六種紋理影像後並加入光譜影像中而分類的精度隨著移動視窗大小的擴大而逐漸提升整體精度，直到移動視窗大小為 21×21 來到最佳整體精度。
3. 在生產者精度方面，不管是哪個類別在不同的移動視窗大小下其生產者精度大部分都在 80%以上，而在使用者精度方面，受到移動視窗大小影響最大的類別為玉米，從 45.6%逐漸提升到 97.4%，應是影像整體精度提升最主要的類別。

二、建議

1. 選擇適合的移動視窗大小在紋理分析中佔非常重要的地位，但每次紋理分析時又會花費大量時間計算紋理因子，為了節省運算時間，未來關於紋理分析的部分可以運用半變異元分析計算每種地物最適合的移動視窗大小，以節省大量數據計算的時間。
2. 本研究僅利用紅、綠、藍三波段作實驗，未來如果能加入紅外光影像作光譜分析或許能進一步提升分類精度。
3. 在隨機森林分類中，有兩大參數需要設定，其一為決策樹數量之設定，另一為特徵變量之設定。未來可加入個特徵重要性分析，並選擇適合的特徵變量進行影像分類，可能得到更佳影像分類。
4. 在實務應用上，可先行建立各地形地物之影像資料庫，作為訓練樣本，日後如遇到尚未編訂之土地，可先利用無人機拍攝照片，並於室內完成初步的地形地物判定，當有疑義時再現場勘查，可節省大量人力與時間的成本，。

參考文獻

- 黃則林、廖閱郎、王賢杰，1982，水稻光譜特性之探討，林務局農林航空測量所，叢刊第 35 號，遙測報告第 7 號。
- 陳哲俊，1989，研究計畫綜合報告，國立中央大學太空及遙測研究中心研究計畫報告。
- 陳哲俊，1994，利用衛星影像資料改進稻作種植面積自動估測及生育查報計畫，國立中央大學太空及遙測研究中心研究計畫報告。
- 郭秀玲，2003，紋理分析於農地利用判釋之研究-以苗栗縣大湖鄉例，逢甲大學，土地管理學系碩士班碩士論文。
- 吳政庭，2004，多元尺度影像與半變異元紋理法於都市水稻田分類之研究，逢甲大學，土地管理學系碩士班碩士論文。
- 陳彥宏，2004，運用紋理資訊輔助高解析度衛星影像於都會區水稻田萃取之研究，逢甲大學，土地管理學系碩士班碩士論文。
- 周明中，2005，紋理輔助高解析度衛星影像分析應用於偵測入侵性植物分布之研究，中央大學，土木工程研究所碩士論文。
- 鄭丁元，2006，高解析度衛星影像於水稻田坵塊萃取之研究，逢甲大學，環境資訊科技研究所碩士論文。
- 陳奕霖，2009，利用空間技術於香蕉作物判釋之研究，逢甲大學，土地管理學系碩士班碩士論文。
- 歐鐙元，2015，應用隨機森林(Random Forest)演算法於 WorldView-2 衛星影像大蒜分類判釋之研究，逢甲大學，土地管理學系碩士班碩士論文。

- 杜青松，2016，利用灰階共伴隨矩陣輔助 UAV 多光譜影像於土地覆蓋與土地利用分類之研究，逢甲大學，都市計畫與空間資訊學系碩士班碩士論文。
- 郭懿萱，2016，應用 UAV 影像於農地分類之研究，中興大學，土木工程學系碩士學位論文。
- 蔡佳益，2016，應用機器學習演算法於高空間解析度影像農作物判釋，逢甲大學，土地管理學系碩士班碩士論文。
- Atkinson, P. M., P. Lewis, 2000. Geostatistical classification for remote sensing: an introduction, *Computers & Geosciences*, 26(4): 361-371.
- Baraldi, A., and F. Parmiggiani, 1995. An investigation of the Textural Characteristics Associated with Gray Level Cooccurrence Matrix Statistical parameters, *IEEE Trans. On Geosci. And Remote Sensing*, 33(2): 293-304.
- Connors, R. W., and C. A. Harlow, 1980a. Toward a Structural Texture Analyzer Based on Statistical Method, *Computer Graphic and Image Processing*, 12: 224-256.
- Connors, R.W., and C. A. Harlow, 1980b. A Theoretical Comparison of Texture Algorithms, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, PAMI-2(3):204-222.
- Du Buf, J. M. H., M. Kardan, and M. Spann, 1990. Texture Feature Performance for Image Segmentation, *Pattern Recognition*, 23(3-4): 291-309.
- Feng, Q., J. Liu and J. Gong, 2015. UAV Remote Sensing for Urban

- Vegetation Mapping Using Random Forest and Texture Analysis, *Remote Sensing*, 7(1):1074-1094 .
- Gislason, O., J. A. Benediktsson, and J. R. Sveinsson, 2006. Random Forests for land cover classification, *Pattern Recognition Letters*, 27(4):294-300.
- Guo, L., N. Chehata, C. Mallet, and S. Boukir, 2011. Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(1):56-66.
- Haralick, R. M., K. Shanmugam, and I. Dinstein, 1973. Textural feature for image classification, *IEEE Transactions on System, Man, and Cybernetics*, SMC-3(6): 610-621.
- Jensen, J. R., 1996. *Introductory Digital Image Processing: A Remote Sensing Perspective*. Englewood cliffs, New Jersey: Prentice-Hall.
- Lo, T.H.C., F.L. Scarpace, and T.M. Lillesand, 1986. Use of Multitemporal Spectral Profiles in Agricultural Land-Cover Classification, *Photogrammetric Engineering & Remote Sensing*, 52(4), 535-544.
- Marceau, D. J., P. J. Howarth, J.-M.M. Dubois, and D.J. Gratton, 1990. Evaluation of the Grey-Level Co-Occurrence Matrix Method For Land-Cover Classification Using SPOT Imagery, *IEEE Trans. On Geosci. And Remote Sensing*, 28(4):513-519.
- Mochizuki, S., and T. Murakami, 2012. Accuracy Comparison of Land Cover Mapping Using The Object-oriented Image Classification

- with Machine Learning Algorithm, *33rd Asian Conference on Remote Sensing 2012 (ACRS 2012)*, 126 -133.
- Mutanga, O., Elhadi Adam, Moses Azong Cho (2012). High Density Biomass Estimation for Wetland Vegetation Using WorldView-2 Imagery and Random Forest Regression Algorithm, *International Journal of Applied Earth Observation and Geoinformation*, 18, 399 -406.
- Ohanian, P. P., and Dubes, R. C., 1992. Performance Evaluation of Four Classes of Textural Features, *Pattern Recognition*, 25(8): 819-833.
- Sandra, E., 2012. Improved Forest Biomass and Carbon Estimations Using Texture Measures from WorldView-2 Satellite Data, *Remote Sensing*, 4(4), 810 -829.
- Tsai, F., M. J. Chou, 2006. Texture augmented analysis of high resolution satellite imagery in detecting invasive plant species, *Journal of the Chinese Institute of Engineers*, 29(4):581-592.
- Verikas, A., A. Gelzinis, and M. Bacauskiene, 2010. Mining data with random forests: A survey and results of new tests. *Pattern Recognition*, 44(2):330-349.
- Weszka, J. S., C.R. Dyer, and A. Rosenfeld, 1976. A Comparative Study of Texture Measures for Terrain Classification, *IEEE Trans. On Syst., Man, and Cybern.*, SMC-6(4):269-285.
- Yang, M. D. , K. S. Huang, Y. H. Kuo, H. P. Tsai, L. M. L. Chou, 2017. Spatial and Spectral Hybrid Image Classification for Rice Lodging Assessment through UAV Imagery, *Remote Sensing*, 9(6):583.

Zhang, H, Q. Li, J. Liu, J. Shang, X Du, H. McNairn, C. Champagne, T. Dong, and M. Liu, 2017. Image Classification Using RapidEye Data: Integration of Spectral and Textual Features in a Random Forest Classifier, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(12):5334-5349.

附錄

表 A-1 9 × 9 視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5622887	554410	193627	52	6370976	88.26%
	花生	627874	4127549	426147	22470	5204040	79.31%
	玉米	25395	73269	529088	10898	638650	82.84%
	裸露地	1	19052	5534	1270405	1294992	98.10%
	合計	6276157	4774280	1154396	1303825	13508658	
使用者精度		89.59%	86.45%	45.83%	97.44%		
整體精度							85.50%
Kappa							0.77

表 A-2 11 × 11 視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5830214	478386	62355	21	6370976	91.51%
	花生	388836	4464703	331674	18827	5204040	85.79%
	玉米	19220	87811	523753	7866	638650	82.01%
	裸露地	4	31720	4932	1258336	1294992	97.17%
	合計	6238274	5062620	922714	1285050	13508658	
使用者精度		93.46%	88.19%	56.76%	97.92%		
整體精度							89.40%
Kappa							0.83

表 A-3 13 × 13視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5933286	415239	22437	14	6370976	93.13%
	花生	215170	4647330	326872	14668	5204040	89.30%
	玉米	11951	72689	549326	4684	638650	86.01%
	裸露地	13	82387	6054	1206538	1294992	93.17%
	合計	6160420	5217645	904689	1225904	13508658	
使用者精度		96.31%	89.07%	60.72%	98.42%		
整體精度							91.32%
Kappa							0.86

表 A-4 15 × 15視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5893716	445063	11362	20835	6370976	92.51%
	花生	132779	4862368	193835	15058	5204040	93.43%
	玉米	10883	64982	557202	5583	638650	87.25%
	裸露地	42	129771	1623	1163556	1294992	89.85%
	合計	6037420	5502184	764022	1205032	13508658	
使用者精度		97.62%	88.37%	72.93%	96.56%		
整體精度							92.36%
Kappa							0.88

表 A-5 17 × 17視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5656884	682426	9180	22486	6370976	88.79%
	花生	92822	4997094	94220	19904	5204040	96.02%
	玉米	6381	59880	563962	8427	638650	88.30%
	裸露地	97	80744	1770	1212381	1294992	93.62%
	合計	5756184	5820144	669132	1263198	13508658	
	使用者精度	98.27%	85.86%	84.28%	95.98%		
整體精度							92.02%
Kappa							0.87

表 A-6 19 × 19視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5687688	595901	50765	36622	6370976	89.28%
	花生	71453	5068748	40042	23797	5204040	97.40%
	玉米	4730	51838	563843	18239	638650	88.29%
	裸露地	304	19911	362	1274415	1294992	98.41%
	合計	5764175	5736398	655012	1353073	13508658	
	使用者精度	98.67%	88.36%	86.08%	94.19%		
整體精度							93.23%
Kappa							0.89

表 A-7 23 × 23視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5669903	649561	35133	16379	6370976	89.00%
	花生	43538	5118373	29038	13091	5204040	98.35%
	玉米	145	47022	582786	8697	638650	91.25%
	裸露地	491	58125	68	1236308	1294992	95.47%
	合計	5714077	5873081	647025	1274475	13508658	
使用者精度		99.23%	87.15%	90.07%	97.01%		
整體精度							93.32%
Kappa							0.89

表 A-8 25 × 25視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5538859	798823	22507	10787	6370976	86.94%
	花生	56534	5121369	16441	9696	5204040	98.41%
	玉米	2041	49473	581188	5948	638650	91.00%
	裸露地	1974	75959	7	1217052	1294992	93.98%
	合計	5599408	6045624	620143	1243483	13508658	
使用者精度		98.92%	84.71%	93.72%	97.87%		
整體精度							92.22%
Kappa							0.87

表 A-9 27 × 27視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5582030	773951	7931	7064	6370976	87.62%
	花生	56733	5125293	13247	8767	5204040	98.49%
	玉米	1764	51306	582547	3033	638650	91.22%
	裸露地	3648	77395	0	1213949	1294992	93.74%
	合計	5644175	6027945	603725	1232813	13508658	
使用者精度		98.90%	85.03%	96.49%	98.47%		
整體精度							82.56%
Kappa							0.88

表 A-10 29 × 29視窗大小之誤差矩陣

Error Matrix		分類成果					生產者 精度
		水稻	花生	玉米	裸露地	合計	
檢核 資料	水稻	5466957	893448	5684	4887	6370976	85.81%
	花生	59490	5126532	9363	8655	5204040	98.51%
	玉米	1676	48158	585314	3502	638650	91.65%
	裸露地	200	75889	0	1218903	1294992	94.12%
	合計	5528323	6144027	600361	1235947	13508658	
使用者精度		98.89%	83.43%	97.49%	98.62%		
整體精度							91.78%
Kappa							0.87