

基於人工智慧分類法之無人機影像在精準農業中的應用：以台灣宜蘭縣部分鄉鎮的水稻田坵塊分類為例

沈育璋¹ 雷祖強^{2*} 陳勝義^{3,4}

摘要

隨著無人機與影像分析技術進步，精準農業逐漸成為提升農業效率的關鍵，本研究使用高解析度 UAV 影像並比較三種機器學習與深度學習模型於宜蘭縣水稻田坵塊偵測問題。機器學習模型如倒傳神經網路、羅吉斯迴歸與 C5.0 決策樹利用原始波段與紋理特徵，最佳精度為倒傳神經網路(總體精度 95.62%、Kappa 值 0.912)；而深度學習模型為 Alexnet、VGG16、VGG19 同樣利用原始波段與影像增揚特徵後，最佳精度為 VGG16 (總體精度 93.83%、Kappa 值 0.894)。雖然機器學習部分工具精準度略高，但其需依賴繁瑣特徵工程才能達成目的，反之深度學習只需要原始波段加入簡單影像增揚特徵後就能產生一定程度的判釋結果，這顯示圖像式(2D)CNN 在地物判釋上的優越性，其在農業環境調查中具有高度的應用潛力。

關鍵詞：精準農業、水稻田、機器學習、深度學習、UAV 影像

1. 前言

精準農業是一種現代農業管理實踐，旨在通過精確控制的農業技術提高作物的產量與質量，同時降低對環境的影響。在稻米生產中，精準農業尤為關鍵，因為它涉及對生長條件的精確控制和監測，從而確保稻米的最佳生長狀態和收成。

稻米生產與精準農業的結合，則可使用先進的遙測技術和數據分析方法來實現。遙測技術能夠從空中或衛星視角獲取大範圍的農地影像，這些影像隨後可以用於監控作物的健康狀態、土壤濕度、病害侵染等關鍵參數。機器學習和深度學習在此過程中發揮著重要的角色，它們能夠從大量的遙測數據中學習和識別模式，從而對作物的生長條件進行準確預測和管理建議。這不僅提高了作物管理的效率，也使農民能夠及時應對潛在的問題，最終達到提高產量和質量的目的。

另一方面，無人飛行載具(Unmanned Aerial

Vehicle, UAV)多元應用發展正方興未艾，因其具有低空飛行能力以及高地面解析度之優勢，再加上還有高機動性與低成本性，因此容易在快速取得地表正射影像後對於地貌與地物進行判釋分類。如判釋山坡農地作物(李瑞陽等, 2018)、或者判釋倒伏水稻田等(周巧盈等, 2020)。基本上在透過 UAV 拍攝各類遙測影像後，輔以各類機器學習或深度學習工具，就能進行更多加值應用，例如生產總量統計與後續政策分析等。

由於機器學習的基本精神是使計算機能夠從數據中學習並作出決策或預測。機器學習極為依賴某些特定的演算法對數據進行模式識別和學習，以執行特定的任務。而深度學習則是機器學習的一個次分支，深度學習模型通過模仿人腦的工作方式，能夠從大量數據中自動/半自動學習複雜的模式和特徵，也就是使用神經網路的結構，特別是深層神經網路，來學習數據的內涵表示。由於這兩種方式都依賴數據驅動，但本質上這兩種方式還是有若干的

¹ 逢甲大學營建及防災研究中心 助理工程師

² 逢甲大學都市計畫與空間資訊學系 教授

³ 逢甲大學營建及防災研究中心智慧空間組 組長

⁴ 逢甲大學建設規劃與工程博士學位學程 博士生

* 通訊作者, E-mail: tclei@fcu.edu.tw

收到日期：民國 113 年 12 月 27 日

修改日期：民國 114 年 02 月 21 日

接受日期：民國 114 年 06 月 27 日

不同，差異如下：**(1) 特徵工程上的不同**，在機器學習中，特徵工程(選擇、創建和優化輸入特徵)是一個重要的步驟，而這個步驟通常仰賴人為操作(例如實際操作經驗、試誤分析等)或是電腦輔助分析(統計、資料挖掘技術等)，但深度學習模型能夠自動從原始數據中學習複雜的特徵表示，減少了手動特徵工程的需求；**(2) 數據量需求不同**，機器學習模型則可以在較少的數據下進行有效的學習，而深度學習通常需要大量的數據來有效地訓練模型；**(3) 模型結構的差別**，機器學習模型的結構相對簡單，可能無法直接處理非常複雜的數據結構，而深度學習模型通常構建為多層次的神經網絡，這使它們能夠學習數據的層次結構強大，也就是能夠處理非線性問題；**(4) 計算資源不同**，許多機器學習模型可以在一般的計算設備上有效運行，但深度學習模型由於其複雜性，通常需要更強大的計算資源，特別是圖形處理單元(GPU)來加速訓練過程。

本研究的機器學習演算法是具代表性的倒傳神經網路、羅吉斯迴歸、決策樹 C5.0，都是藉由人工來決定特徵表內所包含的特徵質與量，為了使模型有足夠特徵能學習到水稻田坵塊的特徵，過往的做法都是需要人們額外添加增益資訊來給模型進行有效的學習，而好壞價值則是人類所提供的特徵質與量，是否能滿足影像分類的目標來做為取捨標準，然而這個過程相當的繁瑣。本研究所使用的深度學習模型則是卷積神經網路(Convolutional Neural Networks, CNN)。

本研究的研究設計為首先處理 UAV 拍攝的 RGB 光學影像以及其衍伸之各類特徵後，在結合不同機器學習與深度學習演算法工具下，比較不同工具究竟能產生何種程度的分類差異性？並嘗試尋找出本研究中所使用的紋理與對比強化特徵中是否有哪一項特徵更有助於分類模型的判釋提升？這些分析程序不僅為新世代分類模型提供圖像數據處理經驗外，還可探索如何結合相關處理技術提升水稻田坵塊分類的準確性，這對於精準農業和遙感影像分析領域來說，具有實際應用的重要價值。

2. 地區與材料

本研究用來拍攝影像的 UAV 是使用了 ATMOS Marlyn 機種來進行拍攝，其有著滯空時間長(~50 Mins)、起降方式彈性、抗風能力 (~15 m/s)、4200 萬像素相機等特性。影像資料為屬於第一期稻作，日期為：2020/04/17、2020/04/24，這日期屬於水稻生長周期的孕穗期，其拍攝時飛行高度為 120M，最終輸出影像解析度為 5CM。拍攝影像共計四張分別位於宜蘭縣員山鄉(兩張)、三星鄉(一張)、以及冬山鄉(一張)。圖 1 為本研究使用 UAV 光學影像示意圖，本研究將四張 UAV 影像以隨機劃分 70%訓練而 30%驗證的比例來進行模型訓練與資料驗證。特別值得一提的是，本研究會固定訓練與驗證樣本的位置，也就是雖然使用不同的分類器，但所有方法的樣本都會保持相同的內容，以利本研究之後續比較與分析。

3. 研究流程

本研究流程圖如圖 2 所示。大致分成以下步驟：

(1) 使用資料與生成特徵

本研究採用的材料分別為 RGB 光學影像以及宜蘭水稻田坵塊，除了使用原始 RGB 光學波段以外，並對其相關特徵值運算，本研究基於前人論文之經驗(林榮章，1999、雷祖強等，2006、Liu *et al.*, 2017、Liu, 2024)後，決定將 RGB 光學影像分別生八種灰階共發生矩陣 (Gray Level Co-Occurrence Matrix, GLCM) 的紋理特徵 (Clausi, 2002、Alzhanov & Nugumanova, 2024)以及對原始 RGB 光學進行「線性對比擴展法」與「非線性直方圖等化法」兩種影像增揚對比強化之作法(Namdev & Lal, 2023)。

當上述資料完成後，本研究還對個別資料集分別進行主成分分析(Principal components analysis, PCA)，進而產生另外的特徵組合，以檢視這樣影像處理程序所產生的特徵是否能對於分類模型判釋有進一步的提升可能，以檢視其可行性和是否具有未來研究性。

特徵值運算完之後，同時使用本研究實證區的

宜蘭水稻田坵塊(GIS 檔案)作為切割影像的標準，以坵塊邊界作為影像擷取的範圍，將不屬於範圍內之影像像元進行遮罩後，取得水稻與非水稻之大數據樣本，進而建立特徵資訊資料庫。

(2) 水稻田坵塊特徵化處理

在進入演算法之前，需將上述所獲取資料進行水稻田坵塊特徵化處理，以達到符合所採用演算法要求的資料格式，方能進行相關訓練，而本研究將 RGB 光學影像以及基於之後其生成的紋理特徵，配合研究實證區的水稻田坵塊建立相關特徵資訊資料庫，由於同時使用了三種機器學習工具與深度學習 CNN 模型，這兩類模型分別需要進行不同的水稻田坵塊特徵化處理程序。機器學習工具所需的樣本資料為一個包含特徵值的特徵資料庫，其輸入格式為特徵表，而本研究所採用的方式是區塊化特徵 (Zoning) 法，也就是計算每個坵塊的光學與紋理特徵的平均值 (Mean) 後，來生成其水稻田坵塊特徵表；而 CNN 模型的樣本資料庫生成方式則是需要輸入

相關影像資料(包含位置與圖像)，本研究同樣結合影像與前述宜蘭水稻田坵塊(GIS 檔案)後，切割出屬於各個坵塊單獨影像資料，並將屬於非該坵塊範圍內的影像部分進行遮罩，進而減少其外部區域特徵對於模型判釋效果的影響。此外，在建立包含多種資訊的影像樣本的時候(含增益資訊之部分)，同時也要結合相關 GIS 軟體，將各特徵指標的影像，疊加成一個多層通道 (multi-band) 的影像後再進行坵塊範圍內的影像遮罩切割。

(3) 模型訓練過程

若將處理完成之資料進行後續模型訓練時，不同模型架構對於樣本的分析成效也有所不同，因此本研究分別使用了倒傳神經網絡、羅吉斯迴歸及決策樹 C5.0 之三種機器學習演算法，以及深度學習中屬於 CNN 模型家族的 Alexnet、VGG16、VGG19 模型，來進行模型建模及訓練，進而分別檢驗何種演算法對本次樣本與主題有較良好之適配性。

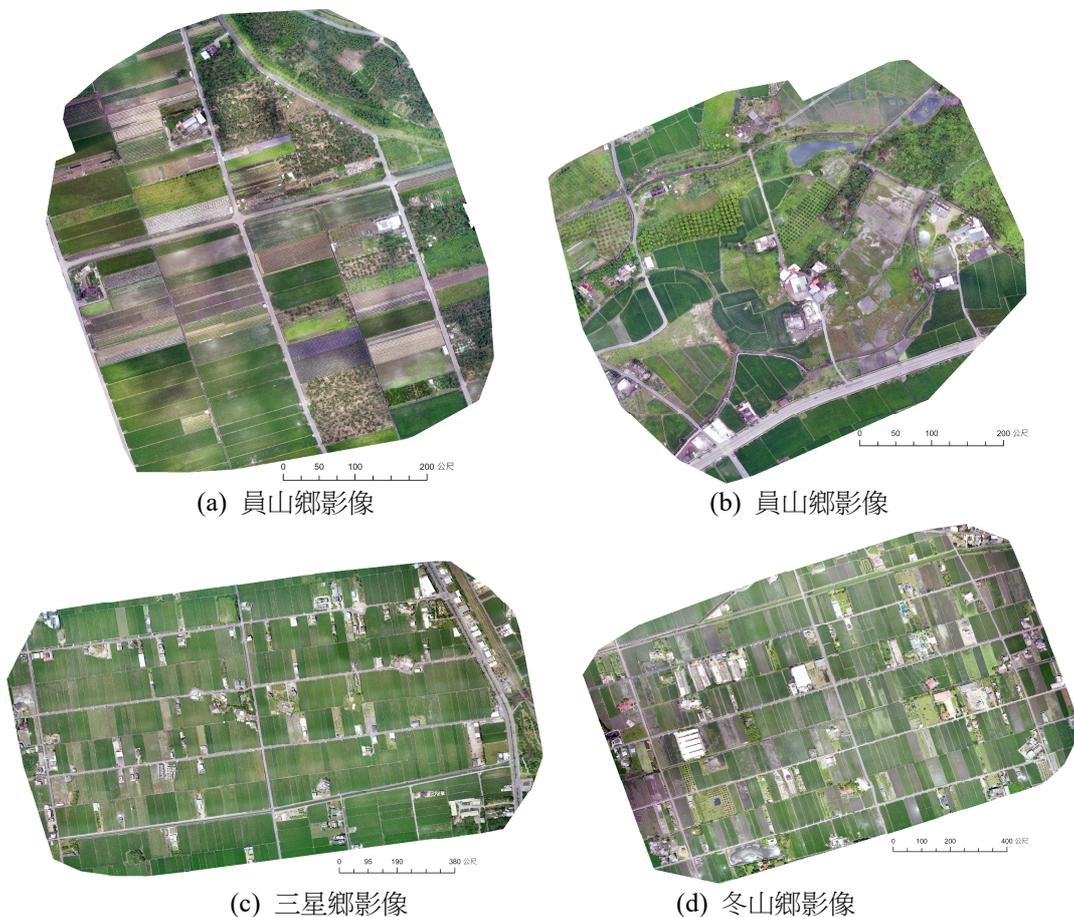


圖 1 本研究使用影像示意圖

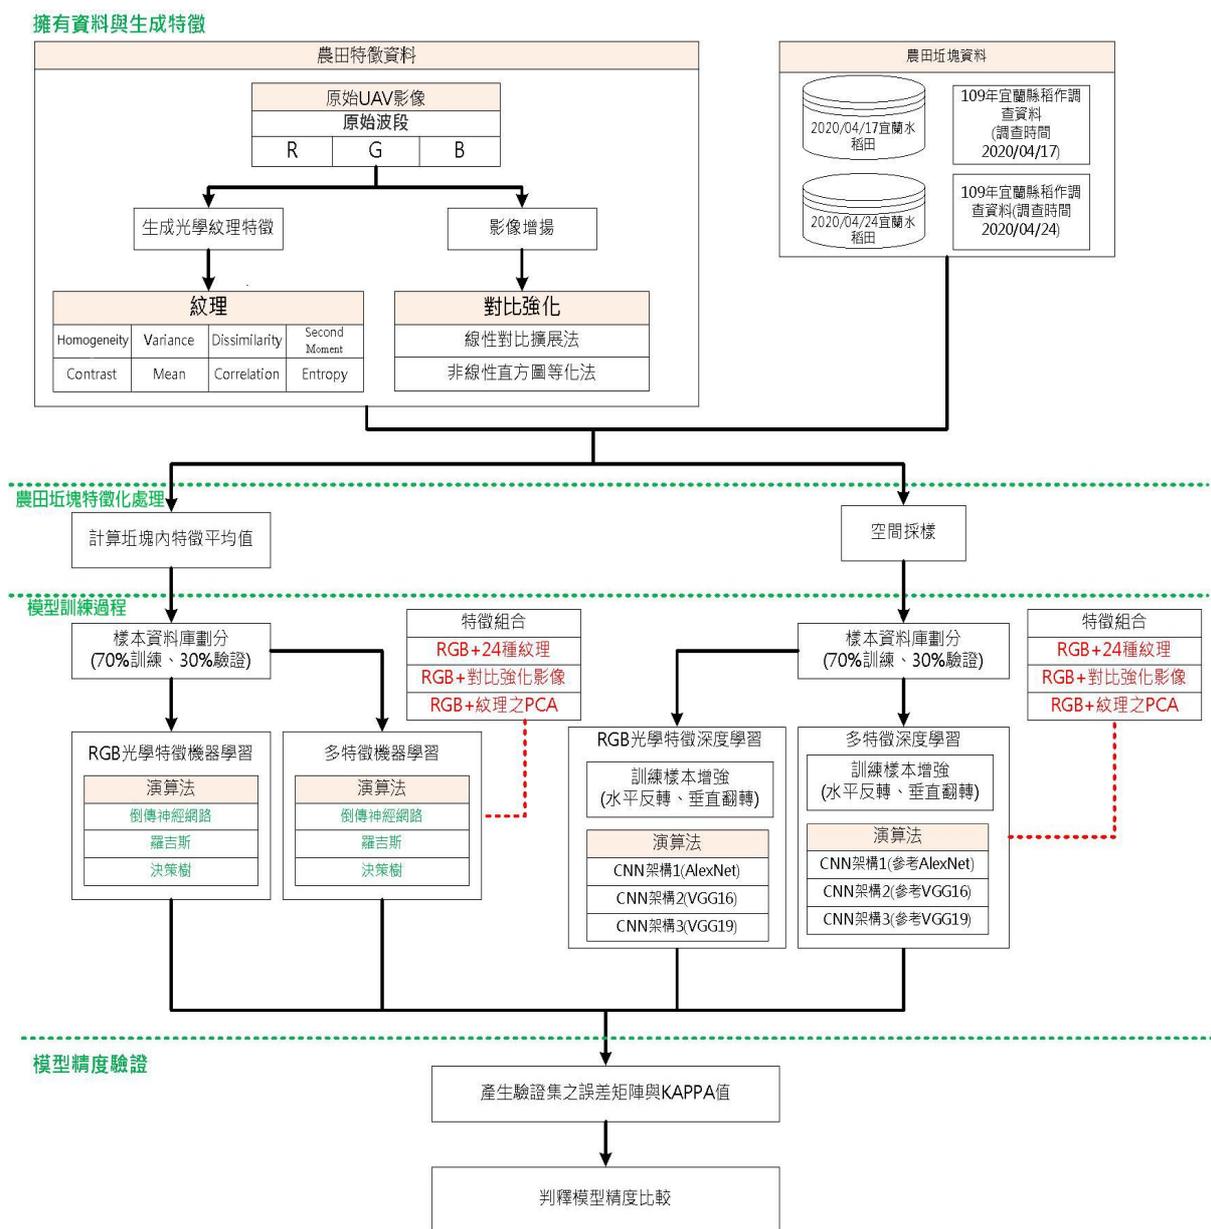


圖 2 研究流程圖

(4) 模型精度驗證

將各類模型與其在驗證樣區的分類成果進行彙整，並通過誤差矩陣(Error Matrix)計算其分類成果的整體精度與 KAPPA 值，以檢視模型分類成果好壞。

4. 研究方法說明

4.1 生成紋理特徵

紋理分析會對影像產生更多特徵值來強化模型訓練能力，本研究通過蒐集多方文獻整理後(林榮章，1999、Clausi, 2002、Liu, 2024)，決定使用灰階

共發生矩陣作為特徵值。

灰階共發生矩陣為一種二階統計方式(參考網站：Texture Metrics Background)，計算時會設定移動視窗格大小(如圖 3)，本研究設定：3×3 大小為資料分析範圍，而像素間距離則設定為 1 個像素， θ 是計算紋理特徵時的方向角度(如 0°、45°、90°、135°)，本研究使用 45°，其原理主要是統計每一對可能的灰階值出現在特定相關位置上的頻率，是一種通過研究影像灰度的空間相關特性來描述紋理的方法，下列式(1)至式(8)便是本研究所採用的灰階共發生矩陣(Clausi, 2002、Alzhanov & Nugumanova, 2024、參考網站：Texture Metrics Background)。

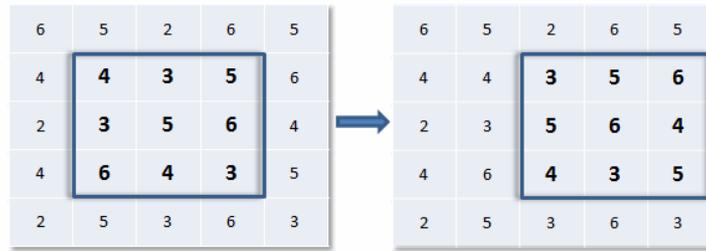


圖 3 GLCM 像素移動計算示意圖 (資料來源：NV5 Geospatial Solutions, Inc., 2023)

(1) 同質性(Homogeneity)：用來衡量影像中的均調性。

$$Homogeneity = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)^2} P(i,j) \dots\dots\dots (1)$$

(2) 對比度(Contrast)：和同質性相反，用來衡量影像中局部變化的強烈程度，其值和強度呈正比。

$$Contrast = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j)(i-j)^2 \dots\dots\dots (2)$$

(3) 不相似度(Dissimilarity)：和 Contrast 相似，用來衡量影像中灰階值的不相似程度，對灰階值於空間中 pattern 或影像色調都十分敏感。

$$Dissimilarity = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j) |i-j| \dots\dots\dots (3)$$

(4) 熵(Entropy)：是用以衡量影像紋理像元資訊的混亂程度，紋理分布越隨機，其數值會相對越低。

$$Entropy = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j) \log(P(i,j)) \dots\dots\dots (4)$$

(5) 相關性(Correlation, COR)：用來衡量影像中灰階值線性相依的程度。

$$Correlation = \frac{\sum_i \sum_j (ij)P(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \dots\dots\dots (5)$$

(6) 變異數(Variance)：這是中心像素及其鄰近像素之間的強度差的平方和，用來衡量影像像素間離散程度。

$$Variance = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i-\mu)^2 P(i,j) \dots\dots\dots (6)$$

(7) 平均值(Mean)：像素灰度值的平均值。

$$Mean = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} i * P(i,j) \dots\dots\dots (7)$$

(8) 均勻性(Second Moment)：表示影像中灰階值分佈的均勻性。

$$Second\ Moment = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \{P(i,j)\}^2 \dots\dots\dots (8)$$

N_g = 灰度級數(影像中不同灰度值的範圍)。

i, j = GLCM(灰階共發矩陣)的行列索引，代表像素的灰度值。

$P(i, j)$ = GLCM 中的元素，表示灰度值為 i 和 j 的像素對出現的歸一化機率。

4.2 影像增揚之對比強化

而影像增揚同樣也是用來強化樣本特徵的一種方式，而對比強化則是其常見的一種方法，本研究選用了「線性對比擴展法」與「非線性直方圖等化法」(童筱蓉，2016、Mini & Bhomini, 2024)。線性對比擴展法主要是利用線性映射函數轉換原始影像，於原始灰階值範圍內決定最大及最小兩個邊界值，而在進行線性強化時便會依照設定的百分比數量將接近 0 與 255 的像素都調整至 0 與 255 的範圍，以達到像素之間的特徵值產生差異，在本研究素材進行線性 5%對比強化後所呈現的成果如圖 4(a)所示。而非線性直方圖等化法的目的即是將原始影像直方圖轉換為均一分配(uniform distribution)以加強影像對比度，通常適於過曝或背光的圖片，而在本研究的成果如圖 4(b)所示，而本研究所兩種對比強化的直方圖如圖 4(c)與 4(d)所示。

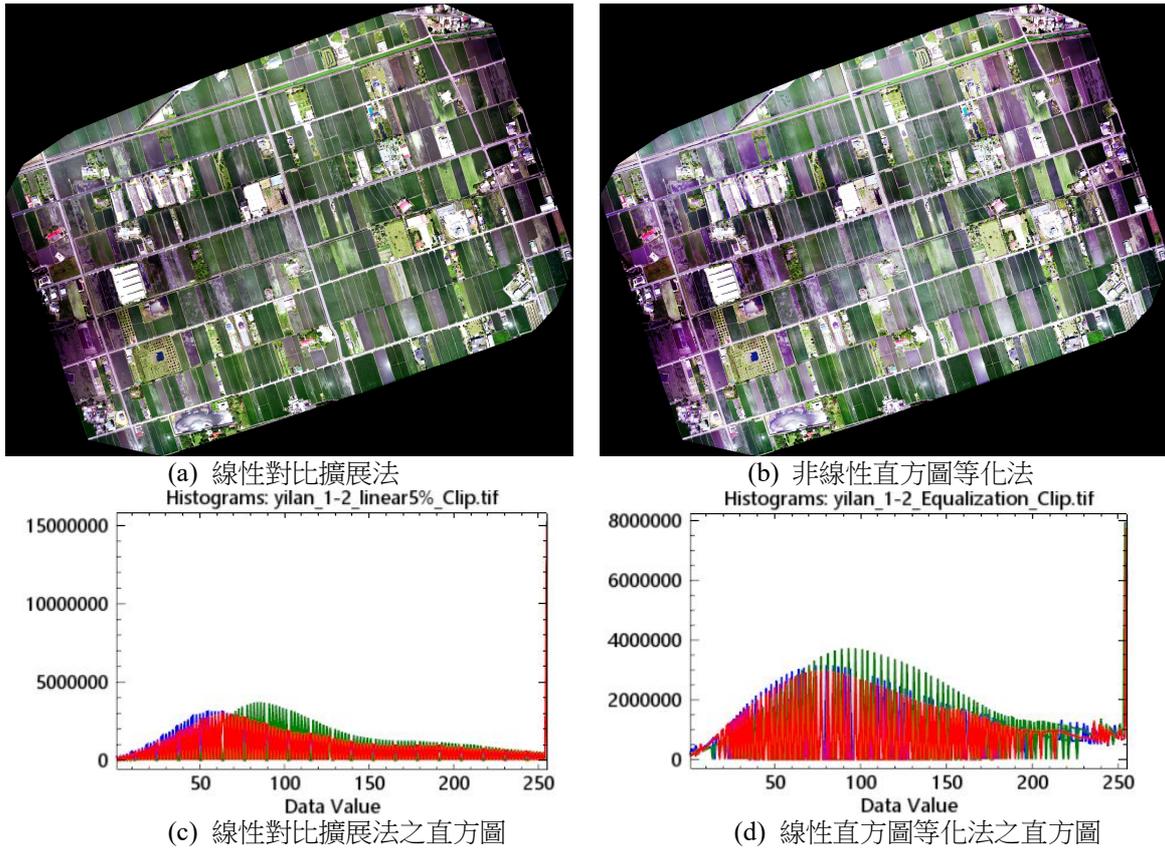


圖 4 影像增揚之對比強化成果圖

表 1 演算法測試結果整合表

測試編號	測試組合	使用之演算法
1	RGB 光學波段	機器學習倒傳神經網路
2	RGB 光學波段	機器學習羅吉斯迴歸
3	RGB 光學波段	機器學習決策樹 C5.0
4	RGB 光學波段+8 種紋理特徵	機器學習倒傳神經網路
5	RGB 光學波段+8 種紋理特徵	機器學習羅吉斯迴歸
6	RGB 光學波段+8 種紋理特徵	機器學習決策樹 C5.0
7	RGB 光學波段+影像對比強化	機器學習倒傳神經網路
8	RGB 光學波段+影像對比強化	機器學習羅吉斯迴歸
9	RGB 光學波段+影像對比強化	機器學習決策樹 C5.0
10	RGB 光學與紋理 PCA 影像處理	機器學習倒傳神經網路
11	RGB 光學與紋理 PCA 影像處理	機器學習羅吉斯迴歸
12	RGB 光學與紋理 PCA 影像處理	機器學習決策樹 C5.0
13	RGB 光學與對比強化之 PCA 影像處理	機器學習倒傳神經網路
14	RGB 光學與對比強化之 PCA 影像處理	機器學習羅吉斯迴歸
15	RGB 光學與對比強化之 PCA 影像處理	機器學習決策樹 C5.0
16	RGB 光學波段(3 Bands)	深度學習 CNN 之 Alexnet
17	RGB 光學波段(3 Bands)	深度學習 CNN 之 VGG16
18	RGB 光學波段(3 Bands)	深度學習 CNN 之 VGG19
19	RGB 光學波段+8 種紋理特徵	深度學習 CNN 之 Alexnet
20	RGB 光學波段+8 種紋理特徵	深度學習 CNN 之 VGG16
21	RGB 光學波段+8 種紋理特徵	深度學習 CNN 之 VGG19
22	RGB 光學波段+影像對比強化	深度學習 CNN 之 Alexnet
23	RGB 光學波段+影像對比強化	深度學習 CNN 之 VGG16
24	RGB 光學波段+影像對比強化	深度學習 CNN 之 VGG19
25	RGB 光學與紋理 PCA 影像處理	深度學習 CNN 之 Alexnet
26	RGB 光學與紋理 PCA 影像處理	深度學習 CNN 之 VGG16
27	RGB 光學與紋理 PCA 影像處理	深度學習 CNN 之 VGG19
28	RGB 光學與對比強化之 PCA 影像處理	深度學習 CNN 之 Alexnet
29	RGB 光學與對比強化之 PCA 影像處理	深度學習 CNN 之 VGG16
30	RGB 光學與對比強化之 PCA 影像處理	深度學習 CNN 之 VGG19

4.3 樣本資料庫劃分

本研究進行模型演算法訓練時所使用共 1694 個樣本(899 個水稻、795 個非水稻)，依照訓練 70% 與驗證 30%的比例進行劃分，而本研究同時會進行不同的演算法(機器學習與深度學習)的訓練，需要將每個演算法的訓練驗證組合都需要固定，否則無法比較；同時為了證實演算法具有泛用性，也要避免單次選擇的訓練和驗證過於集中某特徵或某次抽樣而造成分析成效受影響，故本研究將分別對每個演算法進行 5 次不同的訓練與驗證集的隨機分組，此 5 次的訓練與驗證樣本分組中各自被分類成訓練或驗證的樣本都是固定的，最後再將這 5 次結果平均，作為試驗結果數據。

本研究決定測試以表 1 分類模型組別，表 1 中的這些資料集其邏輯組合關係為 RGB 光學波段、RGB 光學波段+8 種紋理特徵、RGB 光學波段+影像對比強化、RGB 光學與紋理 PCA 影像處理以及 RGB 光學與對比強化之 PCA 影像處理等，分別由機器學習模型與深度學習模型同時操作之。

4.4 機器學習模型建立

4.4.1 水稻田坵塊特徵化處理

機器學習演算法需要生成一個坵塊的特徵資訊表作為輸入樣本，本研究採取的方式則是將所採用的特徵值使用同屬於 GIS 分析工具的 QGIS 中的 zonal statistics 功能，將各個坵塊之特徵平均值 (Mean) 添加到坵塊之 SHP 檔裡面，進而可以產生出其特徵值與編號值的特徵表，其成果如表 2 所示。

表 2 樣本特徵值資料庫示意圖

坵塊編號ID	Rmean	Gmean	各特徵指標標準化數值
3	0.414	0.333	
10003	0.311	0.331	
14004	0.153	0.252	
15004	0.17	0.262	
16004	0.286	0.373	
17004	0.235	0.329	
18004	0.164	0.276	
19004	0.314	0.389	● ● ● ● ● ●
20003	0.426	0.426	
20004	0.313	0.373	
21004	0.287	0.36	
22004	0.267	0.366	
23004	0.126	0.227	
24004	0.15	0.267	
25004	0.157	0.278	

4.5 深度學習模型建立

4.5.1 資料前處理：空間採樣

由於深度學習演算法 CNN 所需的輸入樣本格式為影像格式，而本研究所使用的原始 UAV 光學影像包含著大量的水稻與非水稻坵塊影像資訊，因此在進行 CNN 的資料前處理時需要空間採樣，所謂空間採樣是將影像屬於非目標坵塊範圍外的像元進行黑遮罩。而本研究所使用 ERSI 所開發的 Arcgis 中的 ArcMap 10.1 來進行 CNN 樣本切割，其操作時需要將 UAV 拍攝的 RGB 光學影像以及其坵塊資料的 SHP 檔同時放入 Arcgis 介面，之後使用 Clip 功能按照坵塊將不屬於坵塊範圍內的影像進行遮罩，並將處理完檔案依序存入所屬資料夾，其成果如圖 5 與圖 6 所示。

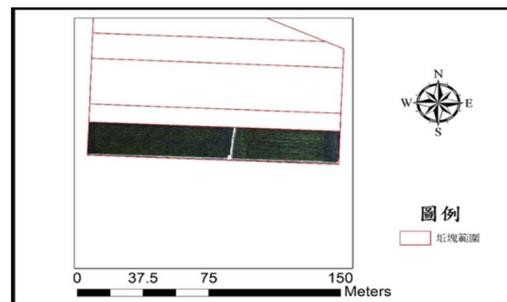


圖 5 切割樣本影像成果示意圖

4.5.2 CNN 模型建立

卷積神經網路顧名思義，是一個包含全連接層 (Fully connected layer) 前的卷積層與池化層，其有著可以直接將圖片當作資料輸入的能力 (Krizhevsky et al., 2012、Simonyan & Zisserman, 2015)，其卷積核會移動來汲取影像畫素特徵來達成減少噪點與銳化圖片，也能減少需要計算神經元數量進而提升效率，還能減少部分異常點對於訓練的影響，並且有著對於圖片局部特徵汲取的能力，至於池化層同樣有著汲取影像特徵以及減少噪點的特性，其效果則是會計算池化層步伐內的特徵的最大值或平均值 (依目的不同而設定不同參數)，而隨著 CNN 本身的發展，有著各項有著不同層數的卷積層與池化層以及其衍伸出各類不同的 CNN 架構可供參考，下面則會描述本研究所選用的架構。

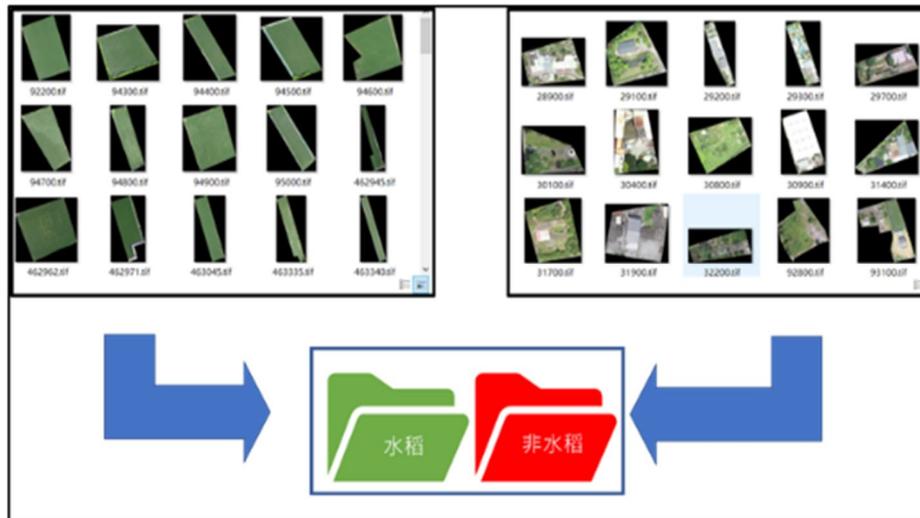


圖 6 影像樣本儲存示意圖

本研究分別採用了文獻中提及的第一個對於判釋精度有大幅提升的 CNN 模型架構：Alexnet (Krizhevsky *et al.*, 2012)，以及另外採用了 VGG16 和 VGG19 (Simonyan & Zisserman, 2015) 兩種架構，這兩種架構，是基於 Alexnet 模型發展後衍生的架構，兩者與 Alexnet 最大的差異在於卷積層與池化層運用的多寡的差異，因此能將其比較不同卷積池化層在對於模型判釋精度上的影響，CNN 已經在各類影像判釋已有各類實例，例如判釋水稻 (Murata *et al.*, 2019)；此外，CNN 有對於輸入之通道數有所要求，本研究除了使用預設的三通道 CNN (R、G、B 三光學波段) 外，還需使用其他數量通道的影像來作為訓練樣本，故需要將其輸入量的進行改變，另外也由於本次輸出判釋只有兩類，與預設的 1000 類也不同，這是需要調整的兩大參數部分。

本研究三種所使用 CNN 模型，其池化層、卷積層數量以 Alexnet、VGG16、VGG19 最初發表時的預設數量為基礎，重要的部分參數如 Activation function 在三種 CNN 皆為：relu、Loss function 為：Cross-Entropy、Optimizer 為：SGDM、學習率為：0.0001、MiniBatchSize：20、MaxEpochs：6 等，整體訓練時間約為 1 小時。

4.6 分類精度驗證

為針對最後建置完成的自動化分類模型做精度測試，本研究採用常見用於影像判釋分類的誤差矩陣 (Error Matrix) 中的整體精度與 KAPPA 值作為

本研究最終成果的驗證機制，通過從本研究區內隨機抽取幾塊不同的樣區作為驗證樣區，做最終成果自動分類模型的檢核。

5. 結果與分析

藉由將各演算法結果進行整理成表 3 後，後續本研究再將機器學習與深度學習成果的最高與最低精度整理成表 4，以及對於不同特徵組合的平均成果整理於表 5，並結合以下數張表的數據將對本研究這次研究成果進行總結。

5.1 演算法成果整合分析

由表 3 與表 4 觀察到機器學習與深度學習 (CNN) 在影像判釋的最高與最低精度組合有所不同，關鍵在於特徵表的生成方式與輸入數據的差異。表 3 當中編號 1-15 號為機器學習模型成果，編號 16-30 號為深度學習模型成果，其中兩大成果都可分成 RGB 光學波段、RGB 光學波段+8 種紋理特徵、RGB 光學波段+影像對比強化、RGB 光學與紋理 PCA 影像處理以及 RGB 光學與對比強化之 PCA 影像處理之分析成果所組成。若以整體分類成果來看，機器學習模型的成效變化大於深度學習模型，最高與最低的成果都發生在這個資料集當中，例如若僅使用 RGB 波段，因為特徵過少導致機器學習模型無法有效區分水稻與非水稻 (總體精度 60.37%，KAPPA 值 0.198) 的部分。但若加入紋理特徵後，倒傳神經

網路的模型精度則大幅提升(總體精度 95.62%，KAPPA 值 0.912)，成為本次試驗最佳之結果。但上述結果之所有內容必須完全仰賴人工所決定的特徵屬性內容，這些資訊的處理與選擇是非常耗費時間成本與專家經驗後方能建置成功。若將這樣的討論準則放到相同特徵且功能類似的羅吉斯迴歸與決策樹 C5.0 上，其表現就差強人意(編號 5 與編號 6)，其分類精度排名到 6 與 20，差距頗大，我們推論這類型的分類器，非常仰賴資料特徵的特性，若資料特徵無法明顯供給良好資訊，或是分類問題屬於非線性問題時，模型分類效能就會大打折扣。另外一方面額外引入影像增強與 PCA 處理方式亦有助於提高精度，但成效不大。

這樣的成果較難應用(這是本次實驗最低相比之下，表 3 中擅長處理非線性問題之深度學習模型無論使用何種特徵組合，均顯示其具有較為穩定的判釋能力，整體來說，不論是使用 RGB 光學波段或是加入其他增益資訊/PCA 處理的組合，大致上都呈現相對理想之成果。其中，RGB 光學波段+影像對比強化表現最佳(排名第二)，總體精度 93.83%、KAPPA 值 0.894(如表 3 編號 23)，而排名第三與第四的結果也出現在這部分的資料集(如表 3 編號 22 與 24)。特別值得一提的是，本研究尚未使用新世代影像增揚工具，如 ESRGAN (Enhanced Super-Resolution GAN)等工具就可獲得如此不錯之成果，這顯示影像增揚技術對於 CNN 模型之影響潛力極大。此外部分的紋理特徵與 PCA 處理的表現也比機器學習的成果要好一些。

我們同時比較機器學習與深度學習演算法最高與最低整體精度/KAPPA 展示(如表 4)，從表 4 中可以看出，機器學習模型的總體精度值範圍 60.37%-95.62%、KAPPA 值範圍 0.198-0.912，差距很大；而深度學習模型的總體精度值範圍 91.04%-93.83%、KAPPA 值範圍 0.820-0.894，差距甚小，這顯示深度學習模型比機器學習模型中的穩定度要

高。

本研究又觀察在各類不同特徵組合之各自平均精度(表 5)，如同個別的比較結果一樣，我們可以觀察出深度學習模型在大部分的特徵組合下仍有較好之表現，尤其在 RGB 光學波段+影像對比強化中是全體平均總體精度 93.79%、KAPPA 值(0.890)是最高之結果，而機器學習則是整體相對不穩定，最低平均精度在只使用 RGB 光學波段僅有總體精度 60.51%、KAPPA 值(0.2010)之結果。不過如果結合額外生成的特徵，機器學習模型可以達到與深度學習工具相似良好的成果，也就是在本次試驗中發現面對非線性問題時，機器學習需要花費較大力氣去建立其解決問題的資料庫，而且成效不一定會滿足所有的分類器(本次試驗)。

5.2 深度學習演算法成果圖討論

整體來說，因為深度學習模型的成效大致良好，因此本研究選定表 3 編號 23 的 VGG 16 成果進行主題圖的說明(圖 7)，圖 7 是從本研究判釋成果重新加值進入水稻田坵塊圖後，可以視覺化的方式清楚檢視本研究之成果，圖中灰色是訓練資料，而綠色與紅色是正確判釋，淺綠與粉紅則是漏判與誤判。表 6 則是針對誤判與漏判部分更進一步討論問題，在水稻漏判的問題中(地真為水稻、判釋為非水稻，圖 7 中的淺綠色部分)，主要是還是在漫灌期的水稻田判釋情形仍較差以外，另外還有在顏色較為深綠的水稻坵塊判釋情形較為不佳；而在水稻誤判問題(地真為非水稻、判釋為水稻，圖 7 中的淺紅色部分)，其多發生在顏色類似的綠色植被坵塊，或者部分生長較為規律，紋理分布與水稻較為相似的植被，或是顏色偏灰色的水體仍會與漫灌期水稻弄混，造成判釋情形較差，本研究後續可以增加樣本數量及類型，使用更為強大的影像增揚技術或以用國土利用預先排除方式來減少誤判與漏判問題發生。

表 3 演算法測試結果整合

測試編號	平均 KAPPA 值	總體精度	KAPPA 值標準差	精度排行
1	0.208	60.78%	0.015	28
2	0.198	60.37%	0.013	29
3	0.198	60.38%	0.015	30
4	0.912	95.62%	0.007	1
5	0.880	94.14%	0.010	6
6	0.806	90.31%	0.026	20
7	0.840	91.95%	0.015	16
8	0.812	90.73%	0.013	19
9	0.726	86.41%	0.016	24
10	0.802	90.19%	0.034	21
11	0.540	77.16%	0.041	27
12	0.786	89.37%	0.014	22
13	0.786	89.37%	0.012	23
14	0.686	84.52%	0.021	25
15	0.684	84.43%	0.037	26
16	0.864	93.16%	0.020	11
17	0.862	92.98%	0.045	12
18	0.842	92.15%	0.030	14
19	0.842	92.10%	0.020	15
20	0.866	93.46%	0.020	9
21	0.856	92.73%	0.026	13
22	0.890	94.27%	0.018	3
23	0.894	93.83%	0.024	2
24	0.886	93.28%	0.019	4
25	0.876	93.83%	0.015	7
26	0.866	93.39%	0.013	10
27	0.832	91.68%	0.015	17
28	0.884	94.20%	0.007	5
29	0.868	93.49%	0.025	8
30	0.820	91.04%	0.030	18

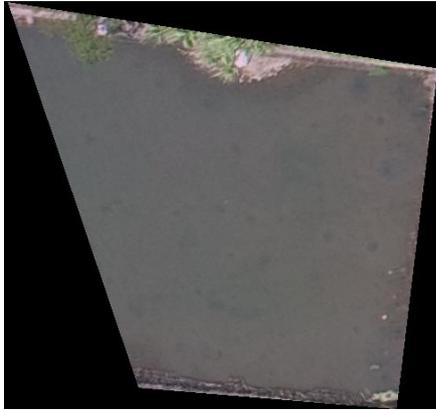
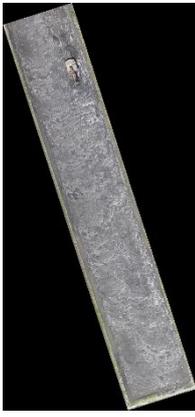
表 4 機器學習與深度學習演算法最高與最低整體精度/KAPPA 展示表

精度演算法	最高精度組合名稱與精度值 (整體精度, KAPPA 值)	最低精度組合名稱與精度值 (整體精度, KAPPA 值)	最高與最低整體精度, KAPPA 值差距
機器學習	倒傳神經網路之 RGB 光學波段+24 種紋理特徵 (95.62%, 0.912)	決策樹 C5.0RGB 光學波段 (60.37%, 0.198)	35.25%, 0.714
深度學習 (CNN)	VGG16 之 RGB 光學波段+ 影像對比強化 (93.83%, 0.894)	VGG19 之 RGB 光學與對比 強化 PCA 影像處理(91.04%, 0.820)	2.79%, 0.074

表 5 機器學習與深度學習演算法最高最低精度展示表

演算法 使用特徵組合	三種機器學習平均整體精度 /KAPPA 值	三種深度學習平均整體精度 /KAPPA 值
RGB 光學波段	(60.51%, 0.201) (測試編號 1-3)	(92.76%, 0.856) (測試編號 16-18)
RGB 光學波段+8 種紋理 特徵	(93.36%, 0.866) (測試編號 4-6)	(92.76%, 0.855) (測試編號 19-21)
RGB 光學波段+影像對 比強化	(89.70%, 0.793) (測試編號 7-9)	(93.79%, 0.890) (測試編號 22-24)
RGB 光學與紋理 PCA 強 化影像特徵	(85.57%, 0.709) (測試編號 10-12)	(92.97%, 0.858) (測試編號 25-27)
RGB 光學與對比強化之 PCA 強化特徵	(86.11%, 0.719) (測試編號 13-15)	(92.91%, 0.857) (測試編號 28-30)

表 6 部分判釋成果展示
光學與對比強化特徵組合之 VGG16 分類情形

水稻漏判	水稻誤判
	
	
	

5.3 本研究成果對精準農業的應用

應用本研究成果，可將無人機極高解析度影像結合人工智慧分類技術，不僅提高了水稻田管理的精準度，未來還可應用其在精準農業中的各項廣泛應用價值，這些價值有：可檢測水稻田內部不同的生長狀態和健康情況、識別病害蟲害、養分不足或

水分失衡等問題，也減少了農人對作物管理的經驗依賴，提高了農業管理的科學性。

6. 結論與建議

6.1 結論

(1) 研究成果顯示在機器學習的演算法中，非常仰賴資料的品質，如果資訊量少的情況下，分類精



圖 7 深度學習模式判釋成果圖

- 準度就會受到很大影響讓分類品質不穩定，例如在只使用 RGB 特徵的情況下，只有三種特徵，使得模型訓練不好且判釋很差的情形產生(表 3 中編號 1、2、3)，須配合更多如紋理或先進行影像增揚等來強化特徵或增加特徵後，來做為機器學習工具學習時的樣本參考依據(表 3 中編號 4~15)，其中又顯示紋理資訊是優於影像增揚的方式。但雖然紋理資訊能夠改善效果，不過這些成效是需依賴人類智慧來判定何種的輸入屬於理想特徵，這是一個曠廢時日不易收斂的過程。更重要一點則是，機器學習依賴資料品質，特別是在農業調查時，也非常依賴多光譜的資訊如 NIR，如果沒有 NIR 的波段資訊，通常就不會得到理想之結果，然而大部分的外業 UAV 擁有 NIR 的波段設備還是相對少數。
- (2) 有別於機器學習，在本研究目前嘗試深度學習的演算法中，由於此模型能夠處理非線性問題，因此所仰賴外部其他資訊的必要性較大幅降低，如只使用 RGB 特徵的情況下(表 3 中編號 16、17、18)，其整體精度與 KAPPA 都大幅提升至 (92.76%與 0.856) 左右，這顯示圖像式(2D)CNN 在地物判釋上的優越性，其不用依賴以前的多光譜資訊就可以達成一定的成效。另一方面，目前 CNN 雖然增加了一些過往分析影像分類時非常依賴的紋理資訊，但顯然效果不會太好(表 3 中編號 19、20、21)，最好的結果則是使用 RGB 光學波段+對比增揚的深度學習演算法，其精度最高可以達總體精度 93.83%的程度、KAPPA 值 0.894(表 3 與編號 23)。這也顯示 2DCNN 所著重的還是圖像中的色彩、對比、物件特徵等資訊，所以新世代影像增揚的技術，在 AI 分析時代應該有極高的結合應用的可能。
- (3) 整體來看，深度學習模型只需使用 RGB 光學波段就能生成具有一定成效判釋能力的模型，相較於機器學習模型需要藉助額外軟體輔助來生成紋理特徵之條件，深度學習模型在本研究中可以觀察到，在時間成本以及操作成本上比機器學習來的有更多的優勢。

6.2 建議

- (1) 未來可嘗試使用多波段 CNN 模型，也就是嘗試使用不同特徵影像進行更多的組合關係測試，來達到改善其判釋精度之可能性，例如利用 NIR 影像、水稻不同生長期光學波段變化大的差異特性、結合同一地區不同時期水稻田 UAV 影像，或是將實證區以外的地區納入進行學習遷移學習之概念等，後續研究可嘗試毒發法之一。
- (2) 精進模型參數來改進問題，由於本研究只挑選了機器學習與深度學習工具中常見的其中三個模型，後續研究仍可嘗試不同機器學習與深度學習的演算法進行模型訓練與判釋，其可能有不同精度與穩定度，也仍有再提升之可能性。

致謝

本研究衷心感謝農業部農糧署提供無人機影像資料(112 農科-4.4.4.2-糧-02)進行分析。特別感謝該機構(113 農科- 4.4.2-糧-04)提供相關研究經費支持本分析。

參考文獻

李瑞陽、歐鏡元、徐嘉徽，2018。應用 UAV 影像於山坡地作物判釋之探討，航測及遙測學刊，23(4)：245 - 256，DOI：10.6574/JPRS.201812_23(4).0002。[Lee, R.Y., Ou, D.Y., and Hsu, C.H., 2018. Utilizing unmanned aerial vehicle images to interpret crop types in the hillside area, Journal of Photogrammetry and Remote Sensing, 23(4): 245-256, DOI: 10.6574/JPRS.201812_23(4).0002. (in Chinese)]

周巧盈、巫思揚、陳琦玲，2020。無人飛行載具之航拍影像應用於水稻倒伏災損判釋，台灣農業研究，69(1)：25 - 45，DOI：10.6156/JTAR.202003_69(1).0003。[Chou, C.Y., Wu, S.Y., and Chen, C.L., 2020. Rice lodging detection using the photography from unmanned aerial vehicle (UAV), Journal of Taiwan Agricultural Research, 69(1): 25-45, DOI:

10.6156/JTAR.202003_69(1).0003. (in Chinese)]

林榮章，1999。都會區多解像力遙測影像之紋理分析，國立中興大學土木工程學系碩士論文。[Lin, R.Z., 1999. Texture analysis of remotely sensed multi-resolution images in urban area, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]

童筱蓉，2016。夜間影像強化，天主教輔仁大學電機工程學系碩士論文。[Tung, H.J., 2016. Night image enhancement, Master Thesis, Fu Jen Catholic University, Taiwan, ROC. (in Chinese)]

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，航測及遙測學刊，11(3)：297 - 310，DOI：10.6574/JPRS.2006.11(3).6。[Lei, T.C., Chou, T.Y., and Cheng, T.Y., 2006. A study of extraction paddy field from quickbird image, Journal of Photogrammetry and Remote Sensing, 11(3): 297-310, DOI: 10.6574/JPRS.2006.11(3).6. (in Chinese)]

Alzhanov, A., and Nugumanova, A., 2024. Crop classification using UAV multispectral images with gray-level co-occurrence matrix features, Procedia Computer Science, 231: 734-739, DOI: 10.1016/j.procs.2023.12.145.

Clausi, D.A., 2002. An analysis of co-occurrence texture statistics as a function of grey level quantization, Canadian Journal of Remote Sensing, 28(1): 45-62, DOI: 10.5589/m02-004.

Krizhevsky, A., Sutskever, I., and Hinton, G.E., 2012. ImageNet classification with deep convolutional neural networks, Advances in Neural Information Processing Systems 25 (NIPS 2012).

Liu, H., Yuan, Z., Zang, J., and Shuai, G., 2017. Highly efficient paddy classification using UAV-based orthorectified image, Proceedings of the IEEE International Geoscience and Remote Sensing Symposium, Fort Worth, TX, USA, pp.3230-3233, DOI: 10.1109/IGARSS.2017.8127685.

- Liu, N., 2024. Crop mapping using deep learning and multi-source satellite remote sensing, Crop mapping using deep learning and multi-source satellite remote sensing, PhD Thesis, University of Glasgow, Scotland, DOI: 10.5525/gla.thesis.84306.
- Mini, P.B., and Bhomini, P.A., 2024. A study in enhancement of satellite images, Engineering Applications of Artificial Intelligence, 138(A): 109259, DOI: 10.1016/j.engappai.2024.109259.
- Murata, K., Ito, A., Takahashi, Y., and Hiroyuki, H., 2019. A study on growth stage classification of paddy rice by CNN using NDVI images, Proceedings of the Cybersecurity and Cyberforensics Conference, Melbourne, VIC, Australia, pp.85–90, DOI: 10.1109/CCC.2019.000-4.
- Namdev, A., and Lal, N., 2023. Image enhancement based on histogram equalization with linear perception neural network method, International Journal of Advanced Computer Technology, 12(6):11-15.
- NV5 Geospatial Solutions, Inc., 2023. Texture Metrics Background, Available at: <https://envi.geoscene.cn/help/Subsystems/envi/Content/FindFeatures/TextureAnalysis/BackgroundTextureMetrics.htm>, Accessed September 9, 2024.
- Simonyan, K., and Zisserman, A., 2015. Very deep convolutional networks for large-scale image recognition, Proceedings of the International Conference on Learning Representations (ICLR), San Diego, CA, USA, DOI: 10.48550/arXiv.1409.1556.

Application of UAV Imagery in Precision Agriculture Based on Artificial Intelligence Classification Methods: A Case Study of Paddy Fields in Selected Townships of Yilan County, Taiwan

Yu-Zhang Shen ¹ Tsu-Chiang Lei ^{2*} Sheng-Yi Chen ^{3,4}

Abstract

With the advancement of UAV and image analysis technologies, precision agriculture has become a key strategy for enhancing productivity. This study uses high-resolution UAV imagery to evaluate three machine learning and three deep learning models for detecting rice paddy plots in Yilan County, Taiwan.

Among the machine learning models (BPNN, logistic regression, and the C5.0 decision tree), the BPNN performed best, achieving 95.62% accuracy and a Kappa coefficient of 0.912. In the deep learning category (AlexNet, VGG16, and VGG19), VGG16 yielded the highest performance with 93.83% accuracy and a Kappa of 0.894 using RGB bands and basic enhancements bands.

Although certain machine learning models demonstrated slightly higher accuracy, they required complex and time-consuming feature engineering. In contrast, deep learning models produced competitive interpretation results using only RGB bands and simple enhancement techniques. These findings demonstrate the superior capability of image-based (2D) convolutional neural networks (CNNs) in land cover interpretation and highlight their strong potential for application in agricultural environmental surveys.

Keywords: Precision Agriculture, Paddy Fields, Machine Learning, Deep Learning, UAV Imagery

¹ Assistant Engineer, Construction and Disaster-Prevention Research Center, Feng Chia University

² Professor, Department of Urban Planning and Spatial Information, Feng Chia University

³ Director of Smart Space, Construction and Disaster-Prevention Research Center, Feng Chia University

⁴ Ph.D. Candidate, Department of Urban Planning and Spatial Information, Feng Chia University

* Corresponding Author, E-mail: tclei@fcu.edu.tw

Received Date: Dec. 27, 2024

Revised Date: Feb. 21, 2025

Accepted Date: Jun. 27, 2025