


內容列表可於 [ScienceDirect](#) 查閱

## 農業中的計算機與電子學

期刊主頁：[www.elsevier.com/locate/compag](http://www.elsevier.com/locate/compag)

## 基於機器學習與無人機多光譜影像的水稻氮肥施用量精準監測\*

楊明德<sup>a,b,e</sup>, 許育鈞<sup>c,\*</sup>, 陳奕璇<sup>a,b</sup>, 楊靜瑩<sup>b,d,e</sup>, 李凱雲<sup>f,g</sup><sup>a</sup> 土木工程學系暨永續農業創新發展中心, 中興大學, 臺中 40227, 臺灣<sup>b</sup> 智慧永續新農業研究中心 (SMARTer), 臺中 40227, 臺灣<sup>c</sup> 都市設計與永續發展學系, 銘傳大學, 桃園 33348, 臺灣<sup>d</sup> 農藝學系, 中興大學, 臺中 40227, 臺灣<sup>e</sup> 永續農業創新發展中心 (IDCSA), 中興大學, 臺中 40227, 臺灣<sup>f</sup> 農業與環境科學研究所, 愛沙尼亞生命科學大學, 克雷茨瓦爾迪 5 號, 51006 塔爾圖, 愛沙尼亞<sup>g</sup> Eawag, 瑞士聯邦水產科學與技術研究所, 水資源與飲用水部門, 8600 杜本多夫, 瑞士

## 文章資訊

關鍵字：  
氮肥監測  
機器學習  
多光譜影像  
特徵選擇  
精準農業

## ABSTRACT

水稻是全球主要的糧食作物，有效的氮肥管理對於在最小化環境影響的同時優化產量至關重要。本研究結合無人機 (UAV) 影像、多光譜成像與機器學習 (ML) 方法，對稻田中的氮素等級 (N levels) 進行分類。於2020年和2021年使用無人機對具有不同氮素水平 (施肥不足、適量施肥及過量施肥) 的試驗田區進行拍攝。所獲取的影像經過幾何與光譜校正，並利用決策樹分類器進行水稻像素分割，其召回率達95.3%，整體準確率為88.8%。氮素等級分類通過從影像中提取16種光譜與結構特徵來實現，包括色彩空間轉換、植被指數與冠層覆蓋率。這些特徵被輸入支援向量機 (SVM) 與k最近鄰 (KNN) 模型，並應用特徵選擇方法以提升模型表現。SVM模型的表現優於KNN模型，尤其在第二期，當採用卡方特徵選擇方法時，整體精度達到90.0%。紅邊比值植被指數與冠層覆蓋率是分類中最具有資訊價值的特徵。本研究整合無人機多光譜影像與機器學習技術，提升了氮分類的準確性與可擴展性。該方法為精準農業與永續施肥管理提供了數據驅動的解決方案。

## 1. 簡介

水稻 (*Oryza sativa* L.) 是全球主要的糧食作物。2016 年至 2020 年間，臺灣每年平均稻米產量在 27 萬公頃的土地上達到約 170 萬噸 (臺灣農業委員會, 2020)。氮素是一種重要的大量營養元素，在水稻生長與產量形成中扮演關鍵角色。雖然通常透過施肥來補充氮素，但施肥效率不彰仍是現代水稻栽培中的主要挑戰。儘管氮肥施用對提升生產力至關重要，但不當的施肥 (不足或過量) 可能導致負面的農藝與環境後果。氮素缺乏會降低葉綠素合成，導致生長遲緩以及

產量下降。施肥過量則會增加優養化、土壤酸化、病蟲害發生以及水稻植株結構弱化的風險，進而使植株在強風或大雨下更容易倒伏 (Yang 等人, 2020)。一項研究探討了水稻施肥間隔，並揭示倒伏與栽培條件之間存在密切關係 (Wu 等人, 2022)。傳統的氮素管理策略多基於固定時程或外觀判斷，但這些方法缺乏精確率，亦無法因應田區條件的變化。因此，有必要採用先進的監測技術以提升決策品質。

傳統上，農民根據自身經驗判斷和葉色卡 (LCCs) 來評估氮素狀態。LCCs 提供了一種視覺

\* 本文屬於《精準養分管理》特刊，該特刊發表於《農業中的計算機與電子學》。\* 通訊作者。\* 電子郵件地址：[mdyang@nchu.edu.tw](mailto:mdyang@nchu.edu.tw) (M.-D. Yang)，[bigq@mail.mcu.edu.tw](mailto:bigq@mail.mcu.edu.tw) (許育誠)，[emiyang@dragon.nchu.edu.tw](mailto:emiyang@dragon.nchu.edu.tw) (楊啟元)，[kai-yun.li@eawag.ch](mailto:kai-yun.li@eawag.ch) (K.-Y. Li)。

<https://doi.org/10.1016/j.compag.2025.110523> 於 2024 年 12 月 30 日收到；2025 年 5 月

4 日收到修訂稿；2025 年 5 月 6 日接受

線上提供日期：2025 年 5 月 12 日 0168-1699/© 2025 The Author(s). 由 Elsevier B.V. 出版。本文為依據 CC BY-NC 授權條款 (

<http://creativecommons.org/licenses/by-nc/4.0/>) 發表的開放取用文章。

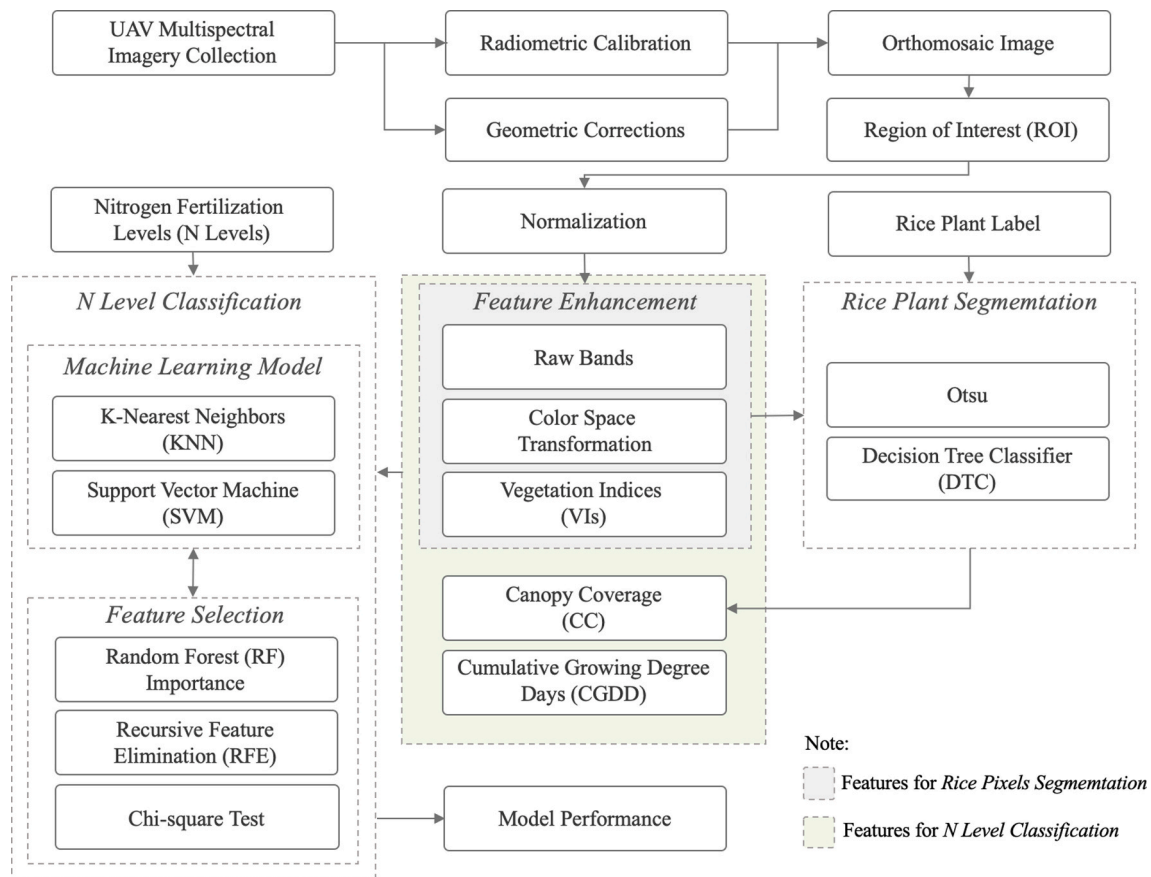


圖1. 無人機多光譜影像氮濃度分類框架的工作流程。無人機影像經過輻射校正與幾何校正以建立正射影像，並從中擷取且標準化ROI。水稻植株分割透過Otsu與DTC執行。特徵增強整合了原始波段、色彩空間轉換、植被指數、冠層覆蓋度與CGDD。特徵選擇方法（包含RF重要性、RFE與卡方檢定）則用於篩選特徵，並以KNN與SVM進行氮素等級分類。

參考，用於估算葉綠素含量並相應調整施肥（Haboudane 等人，2002）。然而，這些方法本質上具有主觀性；由於個人感知差異、光照條件和經驗水平不同，評估結果會有所差異，這些因素都可能導致氮肥施用不一致（Wang 等人，2018）。此外，葉色卡和主觀評估僅能提供氮素狀態的粗略指標，難以適應田間實時狀況或捕捉田區內的空間變異性；因此，往往導致過度或不足施肥（Li 等人，2014）。基於葉色卡的評估也僅是粗略指標，其精確度不如定量氮素分析，且不足以支持實施精準施肥策略（Orillo 等人，2014）。可擴展且以數據為基礎的監測解決方案可克服這些限制，並支持精確的氮素管理。

隨著農業勞動人口老化與勞動力短缺日益嚴重，數位工具與自動化已成為提升農場管理與效率的關鍵。近年來，機器學習（ML）技術 increasingly 應用於精準農業。這些技術可加強作物生長監測、優化施肥並提升產量預測。例如，Tseng et al. (2022) 採用機器學習模型來監測幼苗生長，而Yang et al. (2021, 2025a) 與Brinkhoff et al. (2025) 則建立了光譜與多光譜預測框架，以優化水稻收穫時機。在氮素管理方面，監督式學習模型已展現出根據葉片影像的光譜特徵對氮素水平（N levels）進行分類的潛力。Wang et al. (2018) 利用支援向量機（SVM）與極限學習機模型對高光譜茶葉影像中的氮含量進行分類；模型比較結果顯示，SVM 模型在防止過度或不足施肥方面具有更佳

表現。Orillo et al. (2014) 使用多層感知器（MLP）將水稻葉片的氮含量進行分類，透過比較可見光樣本影像與葉色卡（LCCs）來優化氮肥施用並提高產量。然而，這些模型需要高品質的影像資料，因而必須仰賴遙測技術進行資料收集。

近年來，基於無人機（UAV）的遙測技術進展已徹底改變了精準農業，實現了對作物健康狀況和施肥需求的高解析度、即時監測。研究人員已將多光譜無人機影像與深度學習、物件偵測以及語義分割技術相結合，以優化施肥策略和產量估算；例如，這些技術已被用於確定青花菜收穫時機（Lee 等人，2023）。這些技術相比傳統的單點取樣更具彈性與精確性，而傳統方法難以實際應用於田區內空間變異性的評估。與航空及衛星影像相比，無人機影像可提供更高解析度的數據以及更細緻的場域特定監測。因此，無人飛行載具是進行大尺度氮素評估的理想工具（Yang 等人，2021）。葉綠素濃度作為氮素等級的指標，可透過遙測技術進行估算（Yang 等人，2000）。一些傳統的植被指數（如正規化差值植被指數（NDVI）），在估算茂密冠層的氮含量時效果較差。

為了提升無人機監測的氮分類準確性，目前的方法通常會整合光譜、紋理和結構特徵（Liu 等，2023）。測量結構屬性，例如以色彩參數加權的冠層體積，也能增強生物量估算（Liu 等，2024）。在本研究中，使用無人機影像來評估氮素等級。為確保準確性，進行了精確的影像前處理

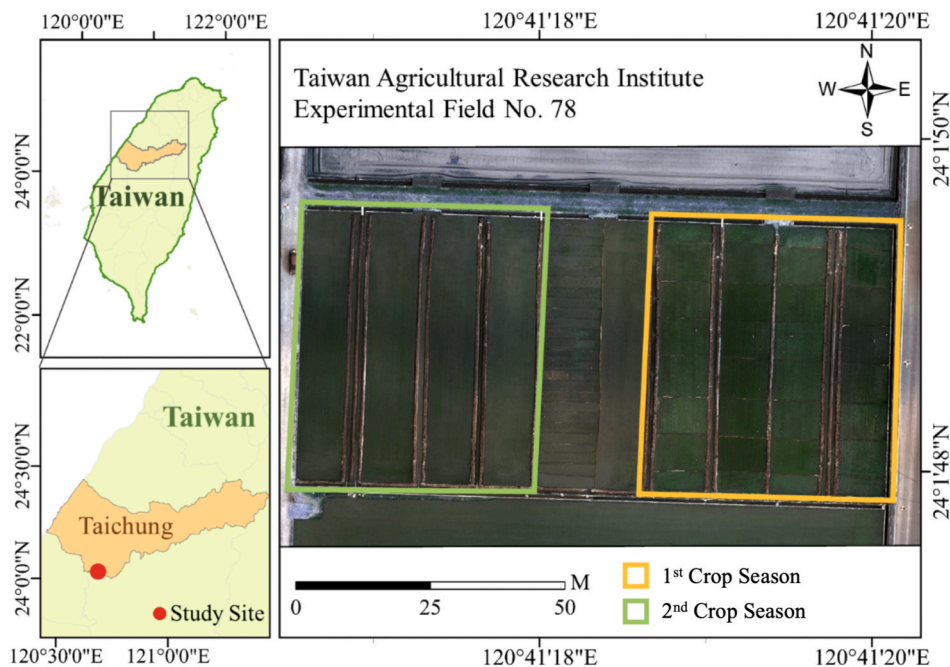


圖 2. 實驗地點位於臺灣臺中市的地理位置。研究區域標示於臺灣地圖（左），而航空影像（右）顯示了第一期作（黃色）與第二期作（綠色）作物季節的稻田劃分。無人機多光譜影像於2020年和2021年作物季節期間在這些田區上收集。

方法，例如從收集的影像中移除非作物像素，皆已被應用。此先進的無人機感測與影像前處理的整合，為水稻的精準農業提供了一種可擴展且有效的氮素管理方法。

用於像素分割的典型影像處理方法包括光譜閾值法和機器學習分類。Yang 等人 (2021) 透過整合多光譜影像與機器學習來區分馬鈴薯像素與背景像素，從而提升模型準確率。在非監督式方法中，Otsu 演算法 (Otsu, 1975) 已被證明適用於簡單的背景分割 (Khan & Narvekar, 2022)。Qiao 等人 (2020) 結合小波轉換與 Otsu 演算法進行近紅外影像分割，而 Dutta 等人 (2022) 則使用過綠減過紅指數 (ExGR) 搭配 Otsu 演算法，成功將植物與背景分離。關於機器學習的應用，Yang 等人 (2015) 採用色相-飽和度-明度 (HSV) 色彩空間與決策樹分類 (DTC) 來分割玉米影像中的作物像素與背景元素。Yang 等人 (2017) 亦應用 DTC 於水庫集水區的土地利用分類；他們解決了與光譜混合相關的挑戰。Li 等人 (2014) 指出，當使用標準化紅邊差異 (NDRE) 指數時，土壤背景會降低玉米氮含量預測的準確性。Qiao 等人 (2020) 證實，去除影像中的土壤背景可改善葉綠素含量監測。應用過量綠色指數 (ExG) 與過紅指數 (ExR) 能增強植物與土壤之間的光譜對比度 (Woebbecke 等人, 1995; Meyer & Neto, 2008)，而 ExGR 更進一步強化此對比 (Yang 等人, 2020)。因此，本研究採用大津法分割與 DTC 預處理以提高氮分類準確率；同時使用原始光譜資料與轉換型植被指數，以提升水稻像素提取的精確率。

已有多種植被指數 (VIs) 與幾何特徵被用於作物的氮分類。冠層覆蓋率 (CC) 是氮素狀態的重要指標，因為氮肥施用會影響冠層擴展 (Haboudane 等人, 2002)。綠色歸一化差異植被指數 (GNDVI) 可用於監測水稻的葉綠素濃度 (García Cárdenas et al., 2018)，而改良三角植被指數2 (MTVI2) 則可有效追蹤玉米的氮含量

(Bagheri 等人, 2013)。NDRE 指數與紅邊比值植被指數 (RERVI) 皆可用於監測水稻葉片的氮素狀態 (Li 等人, 2018)，而 NDVI 則可用於測量整體葉綠素濃度。最佳化土壤調整植被指數 (OSAVI) 可在監測作物葉綠素含量時降低土壤背景干擾 (Haboudane 等人, 2002)。因此，本研究結合 CC 與多個植被指數作為輸入特徵以進行氮素等級分類；並利用這些特徵所提供的互補性光譜與幾何資訊，提升模型效能。

為了提高氮分類的準確性，採用特徵選擇技術以僅保留最相關的預測因子並降低計算複雜度。所使用的特徵選擇技術包括隨機森林 (RF) 重要性、遞迴特徵消除 (RFE) 以及卡方檢定 (Wang & Xie, 2014; Shao & Dai, 2018; Zou et al., 2019; Bantan et al., 2020; Shi et al., 2021; Wang et al., 2021; Sheng et al., 2022; Barzin et al., 2022)。結合多個特徵的機器學習模型通常比線性統計模型提供更優異的預測效果。Moghimi et al. (2020) 使用支持向量機 (SVM)、隨機森林 (RF)、多層感知器 (MLP)、極限梯度提升以及二次判別分析模型對葡萄無人機多光譜影像中的氮素等級進行分類；其中支持向量機模型表現最佳。Li et al. (2022) 實施了一個 AutoML 框架，以優化高光譜影像分析用於作物營養評估，提升了在不同農業條件下的適應性。

本研究整合無人機多光譜影像、特徵選擇與機器學習，以對稻田中的氮素等級進行分類，進而實現精準的數據驅動式氮素管理，改善水稻種植中的肥料施用。

## 2. 材料與方法

本研究的工作流程如圖 1 所示。首先，收集並預處理無人機影像，包括標記與分割以提取特定的水稻植株像素。接著評估分割結果，以確定最合適的演算法。然後從分割後的影像中獲取光譜資訊，並計算水稻光譜特徵、累積生長度日 (CGDD)、冠層覆蓋度及植被指數作為氮素等級分類模型的輸入資料。

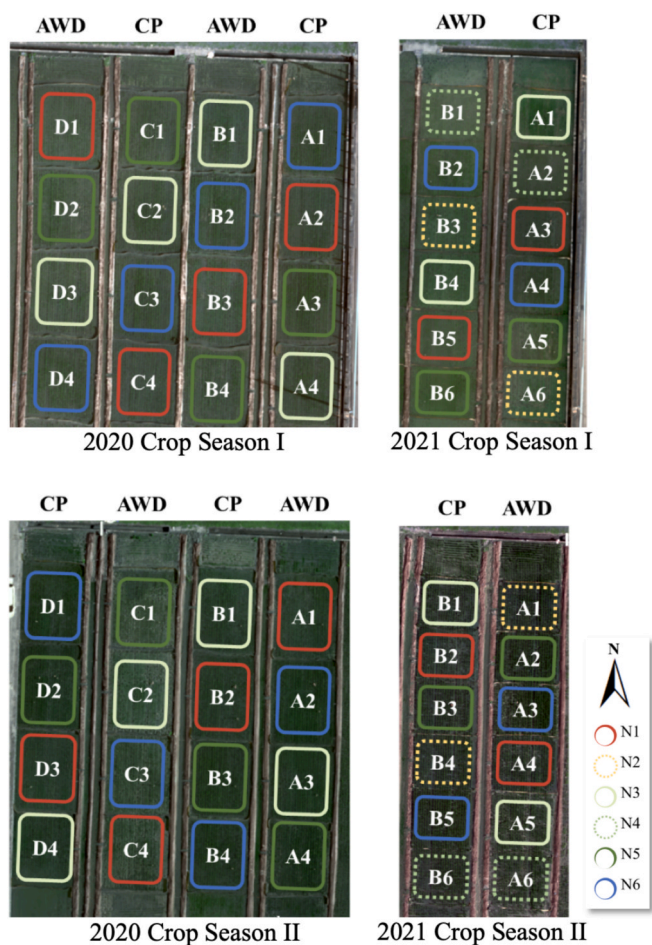


圖3. 2020年與2021年試驗田設計，顯示作物季節I與II中的六種氮肥處理（N1–N6）。田區採用慣行栽培（CP）與交替灌溉與乾濕（AWD）兩種灌溉方法。田區分為四個區段（A、B、C、D），各小區以數字標示。本研究選取其中四種處理（N1、N3、N5、N6）。

表1  
TNG71 栽培所採用的氮素等級。三種處理類別——施肥不足、適量、施肥過量——分別對應相應的氮肥施用（公斤/公頃）。

氮素等級	類別	氮肥（公斤/公頃）
0	施肥不足	80 (N1)
1	適量（下限）	120 (N3)
	適量（上限）	160 (N5)
2	施肥過量	200 (N6)

表2  
無人機規格。

無人機名稱	DJI Matrice 210 RTK	Gryphon
無人機重量	4.4 公斤（含 2 顆電池） 5.2 公斤（含 2 顆電池）	8.5 公斤（含 1 顆電池）
最大飛行負載	6.14 公斤	12.5 公斤
垂直精度	±0.1 公尺	±0.1 公尺
水平精度	±0.1 公尺	±0.1 公尺
作物季節	2020 I, II & 2021 I	2021 II

用於訓練和評估氮素等級分類模型。此綜合性方法可實現對水稻栽培的精確氮素評估，這可能

表3

飛行任務參數與多光譜感測器規格，包含飛行高度、重疊度、解析度、光譜波段，以及估計的數位化足跡（GB/公頃）。

參數	MicaSense Altum
飛行高度 (m)	40
前向重疊 (%)	80
側向重疊 (%)	80
飛行速度 (m/s)	< 2
輻射解析度 (位元)	16
空間解析度 (公分/像素)	1.77
波段 (奈米)	藍光 (475, 32)
(中心波長, 頻寬)	綠光 (560, 27)
	紅光 (668, 14)
	紅邊 (717, 12)
	近紅外光 (842, 57)
飛行任務次數	26
空間覆蓋面積 (公頃)	0.5
數位化足跡 (GB/公頃)	6.25

加強氮肥施用的管理。

## 2.1. 資料收集

研究地點位於臺中霧峰區的臺灣農業試驗所試驗田第78號。於2020年與2021年的第一期及第二期水稻生長季期間，使用搭載多光譜感測器的無人飛行載具拍攝影像，共獲得四組影像資料。第一期作生長期為三月初至六月初，第二期作為八月初至十一月初，兩期作的生長週期分別約為107天與98天。在2020年與2021年，水稻種植面積均約為1300平方公尺<sup>2</sup>。2020年將此區域分為16個區塊，每區約80平方公尺<sup>2</sup>；2021年則分為24個區塊，每區約50平方公尺<sup>2</sup>。各區塊範圍如圖2所示。水稻採用移植方式種植，行距與株距分別為0.3公尺與0.21公尺。

選擇TNG71水稻品種是因為它在臺灣中部普遍種植。田區管理採用兩種灌溉方法：慣行栽培（CP）與交替灌溉乾濕（Li等人, 2021）。在慣行栽培中，維持水位於3–5公分。在交替灌溉乾濕中，灌溉至水位達3–5公分後停止，直至水位降至0公分；24小時後再重新灌溉，使水位再次達到3–5公分。2020年，TNG71施予四個氮素等級：N1（80公斤/公頃）；N3（120公斤/公頃）；N5（160公斤/公頃）及N6（200公斤/公頃）。2021年則增加了兩個氮素等級（共六個）：N2（100公斤/公頃）與N4（140公斤/公頃）。每種氮處理在2020年進行四次重複，2021年進行兩次重複（圖3）。氮素等級分類係根據2020年與2021年作物季節 I所收集的四個等級（N1、N3、N5與N6）資料進行。N1、N3、N5與N6分別代表施肥不足、下限適量、上限適量與施肥過量（表1）。有關試驗田區詳細之氣候與土壤資料，請參見表A1與圖A1。

數據收集使用配備多光譜感測器的無人機。在2020年及2021年作物季節I中，採用大疆（中國深圳）的Matrice 210 RTK無人機。2021年作物季節II則部署了Avilon Intelligence（臺灣臺南）的Gryphon無人機。有關這些無人機的詳細資訊列於表2。所有無人機均搭載MicaSense Altum多光譜感測器（AgEagle Aerial Systems，瑞士洛桑）。飛行參數與感測器波長列於表3，包含數位化足跡，表示每公頃的資料量（Marinello等人, 2019）。

為確保幾何精度，使用四個地面控制點框定研究區域。所有無人機資料皆以即時動態衛星定位儀（SouthGNSS，中國廣州）獲取，基準座標由臺灣政府提供

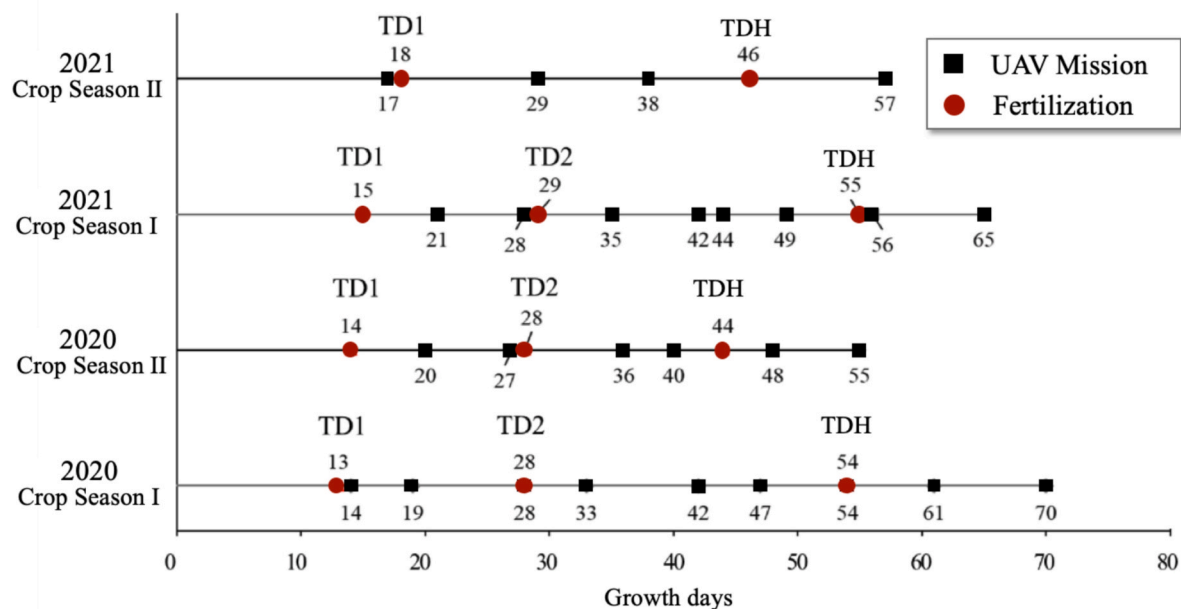


圖4. 2020年與2021年作物季節中施肥事件（紅色圓圈）與無人機拍攝任務（黑色方塊）的時間軸。無人機任務約每兩週執行一次，在作物季節I中，從TD1到TDH進行水稻像素分割，並從TD2到TDH進行氮素等級分類。

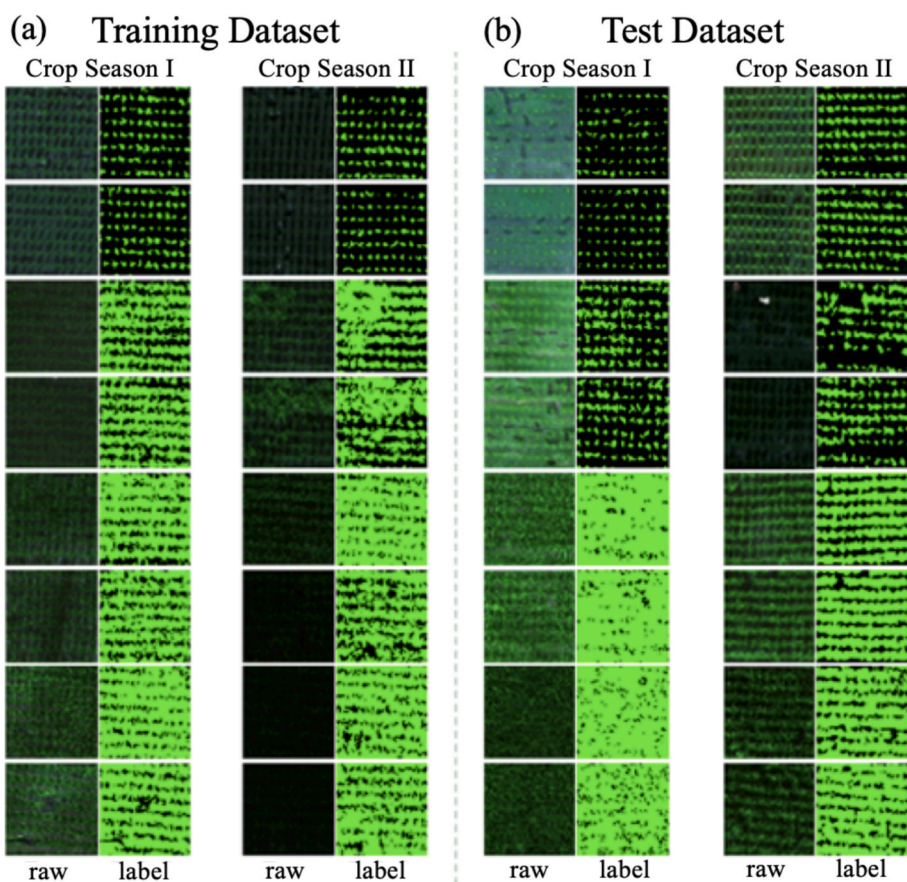


圖5. 水稻像素分割的代表性 $128 \times 128$ 影像圖塊及其真實標籤。(a) 來自2020年作物季I與II的訓練資料集樣本。(b) 來自2021年作物季I與II的測試資料集樣本。真實值分割由領域專家手動標註，將像素分類為水稻植株和土壤背景。

表 4

用於分類的 N 層級資料集規格。無人機影像於 2020 年與 2021 年作物季節 I 的 TD2 至 TDH 期間收集，並分為時期 I (TD2-TDH) 與第二期 (post-TDH)。資料被分割為訓練 (80%) 與測試 (20%) 資料集。由於施肥時程不同，作物季節 II 被排除在外。

時期	栽培階段	2020	2021	訓練資料	測試資料
		作物季節 I			
I	TD2-TDH	4 個任務	4 個任務	76	38
II	post-TDH	2 mission	2 mission	20	10

表 5

HSV 色彩空間轉換的公式。

色彩空間	公式	來源
HSV Hue	$H = \begin{cases} \theta & \text{如果 } B' \leq G' \\ 360 - \theta & \text{如果 } B' > G' \end{cases}$ $\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R' - G') + (R' - B')]}{\sqrt{\frac{1}{4}(R' - G')^2 + (R' - B')(G' - B')}} \right\}$	Smith, 1978
飽和度	$s = 1 - \frac{\min(R', G', B')}{\max(R', G', B')}$	
明度	$\text{植被指數} = \frac{1}{3}(R' + G' + B')$	

表 6

水稻像素提取的植被指數公式。

植被指數	公式	來源
過量綠色指數 (ExG)	$\frac{2 \times G' - R' - B'}{B' + G' + R'}$	Woebbecke 等人, 1995
過量紅色植被指數 (ExR)	$\frac{1.4 \times R' - G'}{B' + G' + R'}$	Meyer 與 Neto, 2008
ExGR (過量綠減過量紅植被指數)	$\text{ExG} - \text{ExR}$	Meyer 與 Neto, 2008

內政部國土測繪中心確保定位測量誤差小於 ±1 公分。飛行任務的飛行高度為 40 公尺，縱向與側向影像重疊度設定為 80%，以優化攝影測量處理與影像拼接的準確性。無人機以低於 2 公尺/秒的飛行速度作業，以維持高影像解析度並最小化動態模糊。為減少飛行轉彎次數並提升效率，飛行路徑沿田區長軸方向規劃為東西向，確保資料收集期間保持前向飛行，並減少不必要的機動操作。

除了幾何校正外，還進行了光譜校正以提高反射率資料的可靠性。每次飛行前後均使用校正反射板進行輻射校正，以確保所有光譜波段之間的一致性。多光譜資料依照 MicaSense Altum 在 Metashape (Agisoft LLC, 俄羅斯) 中的標準流程進行處理。此處理程序包含幾個關鍵校正步驟：首先根據校正板的認證反照率值進行面板偵測與反射率校正；為最小化鏡頭暗角所造成的扭曲，採用多項式校正演算法；由於陽光變化可能影響反射率讀數，因此使用下行光感測器對輻亮度測量進行標準化，從而在整個飛行過程中因太陽條件變化時仍能確保一致性。

在進行輻射和幾何校正後，於 Metashape 中進行正射影像處理，包括影像對齊、點雲重建以及數值地表模型生成。最終的正射影像地面解析度為每像素 6.36 毫米；重投影誤差為 0.391 像素，且總均方根誤差

為 0.98 公分，確保了高幾何保真度。這些校正建立了穩固的基礎，以利後續透過準確且空間一致性高的多光譜影像分析稻田中的氮素等級。

無人機任務約每兩週執行一次，以捕捉水稻生長的關鍵生育期以及氮素吸收的變化。水稻影像像素分割針對第一次追肥 (TD1) 至穗發育追肥 (TDH) 期間的資料進行。氮素等級分類則針對 2020 年與 2021 年作物季節 I 中，從第二次追肥 (TD2) 至 TDH 期間拍攝的影像進行。在 2020 年作物季節 I 共獲取九次無人機多光譜影像，2021 年作物季節 I 八次，2020 年作物季節 II 六次，以及 2021 年作物季節 II 四次。施肥時間軸與每次任務所收集影像數量詳見圖 4。

為確保氮分類的準確性，所收集的資料集被分為兩個時期：時期 I (TD2-TDH) 與第二期 (post-TDH)。此劃分基於水稻的生理發育及其氮素吸收動態。時期 I 對應營養生長與早期生殖生長的關鍵階段，此時氮需求高，且由於葉綠素含量與生物量累積的變化，冠層反射光譜有顯著差異。第二期發生於 TDH 之後的灌漿期，此時以氮素再分配為主；在此階段，冠層光譜變化趨於穩定。

在水稻像素分割過程中，影像會依定義的網格劃分為 128 × 128 像素圖塊。為了建立真實資料，領域專家使用 GIMP 軟體將影像手動分割為兩類：水稻植株與土壤背景。2020 年作物季 I 與 II 的影像被用作訓練資料集，共包含 737,280 筆資料 (影像圖塊)。2021 年作物季 I 與 II 的影像則被用作測試資料集，共包含 360,448 筆資料 (圖 5)。氮素等級的資料集包含於 2020 年與 2021 年作物季節 I 期間，自 TD2 至 TDH 所拍攝的稻田影像。作物季 II 的影像因施肥時程與其他季節不同而被排除。此資料集進一步分為兩個時期：TD2 至 TDH (時期 I) 與 TDH 之後 (第二期)。在 2020 年，四個氮素等級各自於四個獨立區塊中重複設置，總計 16 個區塊；在 2021 年，每個等級於兩個區塊中重複設置，總計八個區塊。針對這兩年，時期 I 各收集四次資料，第二期各收集兩次資料，最終產生 96 筆時期 I 資料與 48 筆第二期資料。這些資料以 80%–20% 的比例分為訓練與測試資料集，詳見表 4。此種分割策略提升了模型在不同氮肥施用條件下的泛化能力。's ability to generalize across different nitrogen application conditions.

## 2.2. 特徵增強

為了準確監測氮素等級，必須消除非水稻像素。水稻影像分割程序使用了幾個原始光譜波段，即藍光 (B)、綠光 (G)、紅光 (R)、紅邊波段 (RE) 和近紅外光 (NIR)，以及 HSV 的色相與三種植被指數 (ExG、ExR 和 ExGR)。在對原始波段進行標準化後 (Riehle 等人, 2020)，利用表 5 和表 6 中的公式計算色相與植被指數。每個原始光譜波段均以 16 位元輻射解析度採用最小-最大標準化法進行標準化，如公式 (1) – (5) 所述。標準化後的結果值以質數符號表示 (例如，B')。

$$B' = \frac{B - B_{\min}}{B_{\max} - B_{\min}} \quad (1)$$

$$G' = \frac{G - G_{\min}}{G_{\max} - G_{\min}} \quad (2)$$

$$R' = \frac{R - R_{\min}}{R_{\max} - R_{\min}} \quad (3)$$

表 7  
氮素等級分類之植被指數公式。

植被指數	公式	描述能力	來源
GNDVI (綠色歸一化差異植被指數)	$\frac{\text{近紅外光}' - \text{綠光}'}{\text{近紅外光}' + \text{綠光}'}$	葉綠素濃度	Gitelson 等人, 1996
MTVI2 (修正三角形植被指數2)	$\frac{1.8(NIR' - G') - 3.75(R' - G')}{\sqrt{2 + 1^2 - (6 \sqrt{1 - 0.5 \text{近紅外光}'})}}$	葉片氮素狀態	Haboudane 等人, 2004
NDRE (正規化差異紅邊指數)	$\frac{\text{近紅外光}' - 5 \text{紅光}'}{\text{近紅外光}' - \text{紅邊波段}' + \text{近紅外光}' + \text{紅邊波段}'}$	葉片氮素狀態、葉綠素濃度	Barnes 等人, 2000
NDVI (正規化差異植被指數)	$\frac{\text{近紅外光}' - \text{紅光}'}{\text{近紅外光}' + \text{紅光}'}$	葉片氮素狀態, 葉綠素濃度	Rouse 等人, 1973
OSAVI (優化土壤調整植被指數)	$\frac{1.16(\text{近紅外光}' - \text{紅光}')}{1 + 0.16 \frac{\text{近紅外光}' + \text{紅光}'}{\text{近紅外光}' + \text{綠光}'}}$	葉綠素濃度	Lawrence 與 Ripple, 1998
RERVI (紅邊比值植被指數)	$\frac{\text{近紅外光}' - \text{紅光}'}{\text{近紅外光}' - \text{紅邊}'}$	葉片氮素狀態	Tucker, 1979




圖 6. Otsu 演算法用於水稻與土壤像素分割。

$$RE' = \frac{RE - RE_{min}}{RE_{max} - RE_{min}} \quad (4)$$

$$NIR' = \frac{NIR - NIR_{min}}{NIR_{max} - NIR_{min}} \quad (5)$$

冠層覆蓋度 (CC) 定義為水稻像素佔樣區總像素的比例 (Qiao 等人, 2020), 並透過公式 (6) 計算。在這些計算中, 使用 B'、G'、R'、RE'、NIR'、色相以及六種植被指數 (GNDVI、MTVI2、NDRE、NDVI、OSAVI 和 RERVI) 作為特徵。色相透過將最大值設為 360、最小值設為 0 來標準化為 NHue, 如公式 (7) 所示。RERVI 則假設其最大值為 10 進行標準化 (NRERVI), 如公式 (8) 所述。用於氮素等級分類的植被指數詳見表 7。

$$CC = \frac{Area_{rice}}{Area_{all}} \quad (6)$$

$$NHue = \frac{HSV_H - HSV_{H_{min}}}{HSV_{H_{max}} - HSV_{H_{min}}} \quad (7)$$

$$NRERVI = \frac{RERVI - RERVI_{min}}{RERVI_{max} - RERVI_{min}} \quad (8)$$

CGDD 是水稻栽培中評估植被生長階段的常用指標。Sharma 等人 (2021) 建立了棉花生長階段與 CGDD 之間的關係, 觀察到隨著氣溫上升, 生長速度加快。CGDD 的計算首先需確定生長度日, 如公式 (9) 和 (10) 所示 (9) 和 (10), 其中  $T_{max}$  為每日最高氣溫,  $T_{min}$  為每日最低氣溫; 臺灣水稻生長的基礎溫度為 10 °C。在 CGDD 公式中,  $n$  為水稻生長天數。本研究所使用的氣溫資料 (圖 A1) 來自交通部中央氣象署。

$$GDD = \max \left[ 0, \left( \frac{T_{max} + T_{min}}{2} - T_b \right) \right] \quad (9)$$

$$CGDD = \sum_{i=1}^n GDD_i \quad (10)$$

### 2.3. 影像處理

#### 2.3.1. 水稻像素分割

Otsu 提出了一種演算法, 用於確定最佳閾值  $k'$ , 以將灰階影像分割成二值形式, 從而區分目標像素與背景像素。在此演算法中, 像素值大於  $k'$  者設為 1, 其餘像素設為 0; 此過程如圖 6 所示, 並以公式 (11) 表示。該演算法旨在透過評估 0 到  $L - 1$  之間各個閾值的類間變異數  $\sigma_B^2$  來使其最大化, 其中  $L$  為最高強度值。最佳閾值  $k'$  可使此變異數最大化, 如公式 (12) 與 (13) 所示。群組  $C_0$  與  $C_1$  分別包含強度大於與小於  $k$  的像素。這些群組的平均強度值分別為  $\mu_0$  與  $\mu_1$ , 而  $P_0$  與  $P_1$  則分別為  $C_0$  與  $C_1$  中像素分佈的對應機率。此演算法為分析影像像素分佈及提升影像分割精確度提供了穩健的架構。

$$g(x,y) = \begin{cases} 1, & f(x,y) > k' \\ 0, & f(x,y) \leq k' \end{cases} \quad x = 0, 1, \dots, N - 1 \\ y = 0, 1, \dots, M - 1 \quad (11)$$

$$\sigma_B^2(k) = P_0(\mu_0 - \mu_t)^2 + P_1(\mu_1 - \mu_t)^2 \quad (12)$$

$$\sigma_B^2(k') = \max_{0 \leq k \leq L-1} \sigma_B^2(k) \quad (13)$$

分類與迴歸樹方法透過反覆將父節點分割為兩個子節點, 以最大化資訊增益或降低吉尼不純度來建立決策樹。此過程會持續進行, 直到達到停止條件, 或進一步分割無法改善模型為止。資訊增益的計算方式如公式 (14) 中定義的熵值 [所示], 在分割前後進行計算; 最大化熵值可產生最適量的分割, 如公式 (15) 所示。同樣地, 吉尼不純度的計算如公式 (16) 所示, 並依公式 (17) 所示進行最佳化。公式 (14) 提出了  $\Delta I(t)$  的公式, 代表分割  $t$  的資訊增益。其中,  $I(t)$  為初始熵值,  $P_{left}$  與  $P_{right}$  分別為分割後左右子節點中資料點的比例。在公式 (15) 中,  $T$  是使  $\Delta I(t)$  最大化的閾值。對於公式 (16) 中的吉尼指數,  $e(t)$  表示預期分類錯誤; 在公式 (17) 中,  $i(t)$  表示根據資料集中類別  $i$  的機率  $p(i)$  計算出的不純度。這些公式有助於微調

表 8

本研究中決策樹分類器 (DTC) 的超參數搜尋空間。採用十折交叉驗證的網絡搜尋來確定分割準則、樹深度以及節點分割所需的最小樣本數之適量設定。類別權重設為平衡，以應對類別不平衡問題。

屬性	超參數
干擾值	熵, 基尼指數
最大深度	1, 5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 75, 80, 85, 90, 95, 100
最小樣本數分割	2, 50, 100, 150, 200, 250, 300, 350, 400, 450, 500, 550, 600, 650, 700, 750, 800, 850, 900, 950, 1000, 1050, 1100, 1150, 1200
類別權重	平衡

表 9

本研究所使用的支援向量機 (SVM) 模型之超參數搜尋空間。該模型採用徑向基函數 (RBF) 核函數, 並透過網絡搜尋與十折交叉驗證從廣泛的範圍中選取懲罰參數 C 與核函數係數  $\gamma$ 。類別權重設定為平衡, 以處理類別不平衡問題, 並使用一對多 (OvR) 決策函數進行多類別分類。

屬性	超參數
核函數	徑向基函數 (RBF)
懲罰參數 C	$10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 10^0, 10^1, 10^2, 10^3, 10^4, 10^5$
$\gamma$	$10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 10^0, 10^1, 10^2, 10^3, 10^4, 10^5$
類別權重	平衡
決策函數形狀	一對多 (OvR)

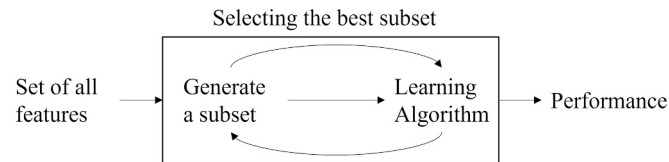


圖 7. RFE 特徵選擇流程。

決策樹以獲得最有效的分類結果。

$$\Delta I(t) = I(t_p) - [P_{left} \times I(t_{left}) + P_{right} \times I(t_{right})] \quad (14)$$

$$T = \text{argmax}[\Delta I(t)] \quad (15)$$

$$e(t) = - \sum_{i=1}^c p(i) \log_2 p(i) \quad (16)$$

$$i(t) = \sum_{i=1}^c p(i) \times (1 - p(i)) \quad (17)$$

scikit-learn 中實現的分類迴歸樹根據基尼指數或熵等標準選擇最佳分割。該模型透過評估不同的超參數來適應各種訓練資料集, 如下所示表 8 及以下詳述的超參數。

### 2.3.2. 氮素等級分類

在特徵空間中,  $k$  最近鄰 (KNN) 演算法會根據資料點之間的接近程度對其進行分類。點與點之間的距離可以使用各種度量方法來計算, 以確定每個資料點的「鄰域」。距離度量的選擇會顯著影響 KNN 演算法的性能。常用的度量包括歐幾里得、曼哈頓和閔可夫斯基距離, 如公式所示。

(18)–(20)。當  $p = 2$  時, 閔可夫斯基距離等同於歐幾里得距離。(Raschka & Mirjalili, 2019; Imandoust & Bolandraftar, 2013)。

$$D = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (18)$$

$$D = \sum_{i=1}^n |x_i - y_i| \quad (19)$$

$$D = \left( \sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (20)$$

支援向量機模型是一種強健的分類演算法。它在高維空間中構建一個超平面, 此超平面將資料點分為不同類別, 並使資料點與超平面之間的距離最大化。該超平面如公式(21)所示, 其中  $w$  代表權重向量, 而  $b$  代表偏置項。最接近超平面的資料點稱為支援向量, 會影響該平面的位置和方向。支援向量機模型使用核函數來處理資料點之間的非線性關係。此核函數表示於公式(22)中, 它將資料轉換到更高維的空間, 以利於超平面進行分離。在本研究中, 多個超參數, 包括核函數類型 (例如, 徑向基函數)、懲罰參數以及核係數  $\gamma$ , 這些對模型性能有顯著影響的參數, 皆透過十折交叉驗證取得。超參數的搜尋範圍列於表 9。

$$w^T x + b = 0 \quad (21)$$

$$K(X_i, X_j) = \phi(X_i)^T \phi(X_j) = e^{-\frac{\|X_i - X_j\|^2}{2\sigma^2}} = e^{-\gamma \|X_i - X_j\|^2}, \gamma > 0 \quad (22)$$

在特徵選擇過程中, 必須考慮每個特徵變數對預測目標的潛在影響。RF 重要性方法根據特徵對二元分類模型的貢獻進行排序, 並為特徵選擇提供依據。此外, RFE 程序在多元回歸期間迭代地移除最不相關的特徵, 以識別關鍵特徵。RFE 中的特徵選擇順序可作為特徵排序的參考。最後, 也使用卡方檢定來評估不同氮肥類別下特徵分佈的顯著性, 以確定各特徵在分類中的相關性。

RF 重要性演算法會根據吉尼不純度或熵來評估每個決策樹節點的不純度減少量。降低不純度越多的特徵, 其重要性越高 (Lowe & Kul-karni, 2015)。資料集  $D$  的吉尼不純度計算方式如公式 (23) 所示, 其中  $p_i$  代表類別  $i$  在  $D$  中的比例 (Cassidy & Deviney, 2014; Yuan 等人, 2021)。特徵  $k$  分割後的吉尼不純度減少量以公式 (24) 計算, 其中  $D_{incoming}$  代表輸入的資料集, 而  $P_L$  與  $P_R$  分別代表分割後左右子節點中資料集的比例。在隨機森林中, 吉尼不純度減少量越大的特徵, 其重要性越高; 一個特徵在所有樹中的平均不純度減少量即為其最終的重要性分數。


$$I(D) = 1 - \sum_{i=1}^n (p_i)^2 \quad (23)$$

$$\Delta I(D_{incoming}, k) = I(D_{incoming}) - P_L \bullet I(D_L) - P_R \bullet I(D_R) \quad (24)$$

RFE 是一種用於特徵選擇的包裝法, 透過評估估算模型所計算出的特徵權重或相關性, 迭代地移除不相關或有害的特徵 (Lin 等人, 2012; Darst 等人, 2018; Misra & Yadav, 2020)。其目標是識別出模型中最相關的特徵。RFE 程序的概述如圖 Fig. 7 所示。

**表 10**  
使用不同光譜波段與色彩轉換特徵的 Otsu 模型性能。在光譜波段中，NIR' 實現最高的整體準確率 (OA)，而 ExG 在色彩轉換中表現最佳，其整體準確率達 79.4%，且水稻召回率最高 (77.6%)。

方法	功能	土壤類別 (%)			水稻類別 (%)			整體精度 (%)
		精確率	召回率	F1 分數	精確率	召回率	F1 分數	
Otsu	B'	45.4	76.7	57.1	67.6	34.6	45.7	52.1
	G'	55.5	78.7	65.1	78.5	55.1	64.7	64.9
	R'	46.9	39.7	43.0	61.4	68.0	64.5	56.3
	RE'	59.9	87.2	71.1	86.6	58.5	69.9	70.5
	NIR'	64.6	98.6	78.1	98.4	61.6	75.8	77.0
	NHue	45.1	53.2	48.8	61.8	53.9	57.6	53.6
	ExG	72.2	82.1	76.8	85.9	77.6	81.5	79.4
	ExR	71.0	87.0	78.2	89.0	74.8	81.3	79.9
	ExGR	71.9	84.0	77.5	87.1	76.7	81.5	79.7



**圖 8.** 使用各種特徵的大津法分割結果。左側：(a)可見光、(b)真實值、(c)RE'、(d)NIR'、(e)ExG、(f)ExR、(g)ExGR 及 (h)NHue。藍色與紅色區域分別表示型一錯誤與型二錯誤。右側：ExG 的混淆矩陣。

**表 11**  
使用不同光譜與色彩轉換特徵的決策樹分類器 (DTC) 性能表現。在原始光譜波段中，NIR' 表現最佳，其 F1 分數達 90.2%，整體精度為 89.0%。複合特徵模型「all」進一步提升了性能，達到的最高的水稻召回率 (95.3%)、F1 分數 (90.8%) 與整體精度 (88.8%)，使其成為水稻像素分割最有效的方法。

方法	功能	水稻類別 (%)			土壤類別 (%)			整體精度 (%)
		精確率	召回率	F1 分數	精確率	召回率	F1 分數	
DTC	B'	81.1	37.2	51.0	67.8	93.8	78.7	70.3
	G'	61.8	19.2	29.3	61.4	91.6	73.5	61.5
	R'	83.7	36.3	50.6	67.7	95.0	79.0	70.6
	RE'	60.3	50.8	55.1	68.5	76.3	72.2	65.7
	NIR'	82.8	92.7	87.5	94.3	86.4	90.2	89.0
	NHue	84.7	63.1	72.3	77.8	91.9	84.2	79.9
	ExG	96.6	54.2	69.4	75.2	98.7	85.3	80.2
	ExR	95.8	55.7	70.4	75.7	98.3	85.5	80.6
	ExGR	96.6	53.3	68.7	74.8	98.6	85.1	79.8
	All	92.3	79.7	85.5	86.8	95.4	90.8	88.8

特徵選擇旨在去除對分類較不重要的特徵。本研究亦採用卡方檢定來評估兩個資料分佈之間的獨立性。較高的卡方值表示兩個變數較不可能獨立；相反地，較低的值則表示具有獨立性。這些卡方值可用於選取適當的特徵。卡方檢定是一種用於特徵選擇的過濾法 (Saeyns 等人, 2007)，其表示如公式 (25) 所示，其中  $A$  表示觀察值，而  $E$  表示期望值。

$$\chi^2 = \sum \frac{(A - E)^2}{E} \quad (25)$$

### 2.3.3. 性能估計

使用混淆矩陣來衡量評估分類模型準確性的關鍵指標，例如精確率、召回率，

F1 分數和整體準確率 (OA)。精確率是指某類別的正確預測比例相對於所有預測結果而言，定義於公式 (26)。較高的精確率表示假陽性較少。召回率定義於公式 (27)，是某類別的正確預測比例相對於該類別所有實際樣本的比例。較高的召回率代表假陰性較少。F1 分數結合了精確率與召回率 [公式 (28)]，並提供模型準確率的一個平衡衡量指標。分數越接近 1 表示表現越好；低分數則表示模型在預測某些類別時存在困難。OA 透過公式 (29) 計算，測量所有類別中正確分類的數量，作為正確預測數與資料點總數之比率。這些指標提供了對模型推論能力的全面評估，可進行每類別及整體性能的詳細分析。




圖9。DTC分類結果視覺化。左側：(a)可見光，(b)真實值，(c)ExG，(d)ExR，(e)ExGR，(f)RE'，(g)NIR'，以及(h)「All」特徵組合。右側：ExG的混淆矩陣。

表12

使用16項特徵資料集對KNN與SVM於氮素等級分類的性能比較。在時期 I 中，SVM優於KNN（整體精度為60.0%對比50.0%），而在第二期中兩者皆達到70.0%的整體精度。SVM在等級0與等級1的分類表現較佳，而KNN在第一期的等級2分類上表現不佳，但在第二期有所改善。這些結果凸顯了SVM在處理非線性分類上的優勢。

N 層級		時期 I (%)		第二期 (%)	
		KNN	SVM	KNN	SVM
等級0	精確率	60.0	75.0	100	100
	召回率	100	100	50.0	100
	F1 分數	75.0	85.7	66.7	100
等級1	精確率	60.0	75.0	57.1	57.1
	召回率	50.0	50.0	100	100
	F1 分數	54.5	60.0	72.7	72.7
等級2	精確率	20.0	37.5	100	100
	召回率	20.0	60.0	50.0	25.0
	F1 分數	20.0	46.2	66.7	40.0
	OA	50.0	60.0	70.0	70.0

$$Precision = \frac{\text{The number of correct predictions for class } n}{\text{The number of all predictions for class } n} \quad (26)$$

$$Recall = \frac{\text{The number of correct predictions for class } n}{\text{The number of classes } n} \quad (27)$$

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (28)$$

$$Overall Accuracy = \frac{\text{The sum of the correct predictions for each category}}{\text{The number of data}} \quad (29)$$

### 3. 結果與討論

#### 3.1. 水稻像素分割

##### 3.1.1. Otsu模型性能

在使用基於原始光譜波段特徵的模型中，由於葉綠素在這些波段具有較高的反射強度，紅邊波段 (RE)' 和近紅外光 (NIR)' 特徵相比可見光波段特徵表現出更優異的分割性能 (表 10)。對於非監督式 Otsu 演算法，土壤召回率與水稻精確率皆高。土壤類別的 NIR' 具有最高的召回率 (98.6%)，水稻類別的精確率 (98.4%)、F1 分數 (75.8%) 和整體精度 (OA) (77.0%)。在色彩空間轉換特徵與植被指數 (VIs) 中，ExG 在水稻分類中表現最佳，其召回率、F1 分數和 OA 分別為 77.6%、81.5% 和 79.4%。水稻像素是氮素等級分類與冠層覆蓋度 (CC) 計算的關鍵輸入；因此，成功識別水稻區域對模型至關重要，而水稻召回率是關鍵的性能

表13

使用 RF 重要性 選取之特徵進行 SVM 分類的效能。於選取的特徵上進行網絡搜尋後，整體精度提升至 60.0% (時期 I) 與 70.0% (第二期)。相較於使用所有特徵，此特徵子集提供了更平衡的分類結果，在第二期維持了等級0的精確率，並儘管精確率略有下降，仍提升了等級2的召回率與 F1 分數。

N 層級	特徵數量	時期 I	第二期
		6	6
等級0	精確率	40.0 %	100 %
	召回率	66.7 %	50.0 %
	F1 分數	50.0 %	66.7 %
等級1	精確率	80.0 %	60.0 %
	召回率	66.7 %	75.0 %
	F1 分數	72.7 %	66.7 %
等級2	精確率	40.0 %	75.0 %
	召回率	40.0 %	75.0 %
	F1 分數	40.0 %	75.0 %
	OA	60.0 %	70.0 %

指標。Otsu演算法的結果如圖8所示；藍色和紅色像素分別代表型一錯誤和型二錯誤。圖8 (e) 顯示，ExG在召回率和整體精度方面表現優於 NIR，因此是基於Otsu進行水稻與土壤分割的最佳特徵。

##### 3.1.2. 決策樹模型性能

DTC模型的結果如表11所示。這些結果是在超參數調校後取得的最佳表現。對於使用原始波段的模型，土壤與水稻類別之間的精確率與召回率在可見光波段中差異極大；這可能是由於資料不平衡所致。儘管可見光波段的水稻召回率很高，但精確率普遍較低，許多像素被錯誤分類為水稻。F1 分數與整體精度則考慮了精確率與召回率之間的平衡。在所有原始波段中，NIR' 表現最佳，其F1分數為90.2%，整體精度為89.0%。基於NIR'的DTC模型之最佳超參數為熵準則、最大深度5層，以及最小樣本分割數2。對於色彩空間轉換與植被指數特徵，土壤與水稻類別的精確率與召回率亦存在差異；相應的F1分數約為85%，整體精度約為80%，顯示其性能可靠，與原始波段相當。DTC模型與Otsu演算法的不同之處在於，DTC模型能納入複合特徵進行訓練。DTC模型包含了九個組合特徵，標記為「All」。訓練時的最佳超參數為熵準則、最大深度15層，以及最小樣本分割數150。這些增加是因應特徵數量較多所致。

與使用單一特徵 (原始波段、色彩空間轉換或植被指數) 的模型相比，使用複合特徵的模型




圖 10. 基於隨機森林的特徵重要性分析（第一期與第二期）。最佳特徵集合從 16 個減少至 6 個。大多數選出的特徵在不同時間保持穩定，僅 NHue 與 NIR' 除外。縮減特徵空間有助於提升跨氮素等級的推論穩定性，凸顯了色彩轉換、覆蓋率與植被指數 (VIs) 的重要性。

表 14

使用遞迴式特徵消除 (RFE) 所選取的特徵進行 SVM 分類的結果。基於 RFE 的特徵選擇將整體精度提升至 75.0 % (時期 I) 和 80.0 % (第二期)，表現優於使用全部特徵或由隨機森林選取特徵的模型。適量特徵組合在時期 I 包含九個特徵，第二期則包含三個特徵，其中 RE' 與 NIR' consistently ranking among the top contributors,

凸顯其在氮素等級分類中的重要性

氮素等級	特徵數量	時期 I	第二期
		9	3
等級 0	精確率	75.0 %	100 %
	召回率	100 %	50.0 %
	F1 分數	85.7 %	66.7 %
等級 1	精確率	88.9 %	66.7 %
	召回率	66.7 %	100 %
	F1 分數	76.2 %	80.0 %
等級 2	精確率	57.1 %	100 %
	召回率	80.0 %	75.0 %
	F1 分數	66.7 %	85.7 %
	OA	75.0 %	80.0 %

在水稻像素分割中表現更佳，達到 95.3% 的召回率、90.8% 的 F1 分數以及 88.8% 的整體精度。非監督式 Otsu 演算法能有效分類土壤背景與水稻類別，並在 ExG 特徵上取得最佳結果。然而，以複合特徵訓練的監督式 DTC 模型則具有更高的精確率。與單一特徵模型相比，複合特徵 DTC 模型的型一錯誤與型二錯誤較少，F1 分數與整體精度更高；因此，建議採用此方法進行水稻像素分割。該 DTC 模型以九個特徵作為輸入，可成功識別水稻像素以進行 CC 計算，並提供氮素等級分類的特徵。圖 9 展示 DTC 模型的結果。

### 3.2. 氮素等級分類

建立了一個氮素等級資料集，以開發用於分類的 KNN 與 SVM 模型。分類結果彙整於表 12。在時期 I 中，SVM 模型表現優於 KNN 模型，達到的整體精度為

表 15

使用卡方檢定所選特徵進行 SVM 分類的結果。最佳特徵子集 (NDRE、GNDVI、RERVI 和冠層覆蓋度) 在時期 I 達到 60.0% 的整體精度，在第二期達到 90.0% 的整體精度，在第二期表現優於先前的特徵選擇方法。結果表明，這些所選特徵能有效解釋 N 層級的變化，特別是在後期生長階段。

N 層級	特徵數量	時期 I	第二期
		4	4
等級 0	精確率	100 %	100 %
	召回率	50.0 %	100 %
	F1 分數	66.7 %	100 %
等級 1	精確率	50.0 %	100 %
	召回率	75.0 %	75.0 %
	F1 分數	60.0 %	85.7 %
等級 2	精確率	66.7 %	80.0 %
	召回率	50.0 %	100 %
	F1 分數	57.1 %	88.9 %
	OA	60.0 %	90.0 %

表 16

依 N 層級進行特徵重要性的 Dunn-Bonferroni 分析。各特徵的統計顯著性根據 p 值評估 (p < 0.05 : \* , p < 0.01 : \*\* , p < 0.001 : \*\*\*)。在兩期中均最顯著的特徵 (p < 0.001) 包括 GNDVI、MTVI2、NDRE、NDVI、OSAVI、RERVI 和冠層覆蓋度。

功能	P-值		功能	P-值	
	時期 I	第二期		時期 I	第二期
B'	0.053	0.000***	GNDVI	0.000***	0.000***
G'	0.007**	0.000***	MTVI2	0.000***	0.000***
R'	0.003**	0.000***	NDRE	0.000***	0.000***
RE'	0.097	0.002**	NDVI	0.000***	0.000***
NIR'	0.016*	0.000***	OSAVI	0.000***	0.000***
NHue	0.000***	0.000***	RERVI	0.000***	0.000***
S	0.035*	0.016*	CC	0.000***	0.000***
V	0.007**	0.000***			




圖 11. 使用 KNN、SVM、RF 重要性、RFE 和卡方檢定對第一期 (P1) 和第二期 (P2) 進行的綜合特徵選擇結果。被選中的特徵以綠色標示，顏色越深表示排名越高。最右側欄位顯示各特徵在不同方法中被選中的次數。RERVI 和冠層覆蓋度為最常被選中的特徵，其次為 GNDVI、NDRE、OSAVI 和 NIR'，顯示其對氮素等級分類具有強烈影響力。

60.0%，高於 KNN 模型的 50.0%。兩個模型在第二期的表現皆有所提升，達到 70.0% 的整體精度。由於 KNN 模型依賴基於距離的最佳化進行分類，而 SVM 模型則利用基於超平面的分割方法，因此 SVM 模型在處理氮素等級分類中的非線性關係時更為有效。

超參數調校顯著影響模型準確性。對於 KNN 模型而言，表現最佳的距離度量為閔可夫斯基距離；其最佳化超參數包含  $p = 2$ 。最佳的  $n_{neighbors}$  設定（範圍從 1 到 7）則取決於特徵選擇方法。SVM 模型使用 RBF 核函數時達成最高的分類準確率，其中  $C$  值介於  $10^2$  到  $10^4$ ，且  $\gamma$  值為 0.1 或 1。該模型維持平衡的類別權重設定，並採用 OvR 決策函數，此函數透過為每個類別訓練一個二元分類器來簡化多類別問題。比較這些模型可知，SVM 模型由於能優化超平面並利用基於核函數的轉換，在氮素等級分類上提供了比 KNN 模型更穩健的架構——特別是在應用特徵選擇方法時。

在時期 I 和第二期的氮素等級分類表現中，各模型之間的精確率、召回率和 F1 分數有所差異，凸顯了氮建模的複雜性。如表 12 所示，支持向量機模型在等級 0 分類中 consistently 優於 KNN 模型。在等級 1 分類中，支持向量機模型在時期 I 略具優勢

相較於 KNN 模型，在第二期則兩者表現相當。在等級 2 分類中，KNN 模型在時期 I 表現不佳，但在第二期表現稍好。整體而言，支持向量機模型表現較佳，因此透過特徵選擇方法進行優化。

在 RF 重要性方法中，應用網絡搜尋來評估特徵的組合。最佳結果被作為 SVM 模型的輸入，結果列於表 13。第一期與第二期的整體準確率分別為 60.0% 和 70.0%。然而，與使用所有特徵相比，使用由重要性所選出的特徵表現略佳。不同氮素等級之間的分類性能觀察到顯著差異。特徵選擇後，第二期的等級 0 精確率保持穩定，但召回率與 F1 分數明顯下降。相反地，在等級 2 中，召回率與 F1 分數較高，但精確率下降。這些觀察表明，所選的特徵組合導致各等級間的推論性能更趨平衡，特別是在第二期。

圖 10 顯示所有特徵的 RF 重要性值。最佳特徵組包含六個特徵。在時期 I，最佳特徵為 NHue、冠層覆蓋度、OSAVI、RERVI、MTVI2 和 NDRE。在第二期，排名最高的特徵為冠層覆蓋度、OSAVI、MTVI2、近紅外光、GNDVI 和 NDRE。因此，特徵組從 16 個減少至 6 個，且所選特徵在兩個時期之間的貢獻相似，僅 NHue 和近紅外光除外。因此，一半的選定特徵，特別是植被指數，提供了穩定的貢獻

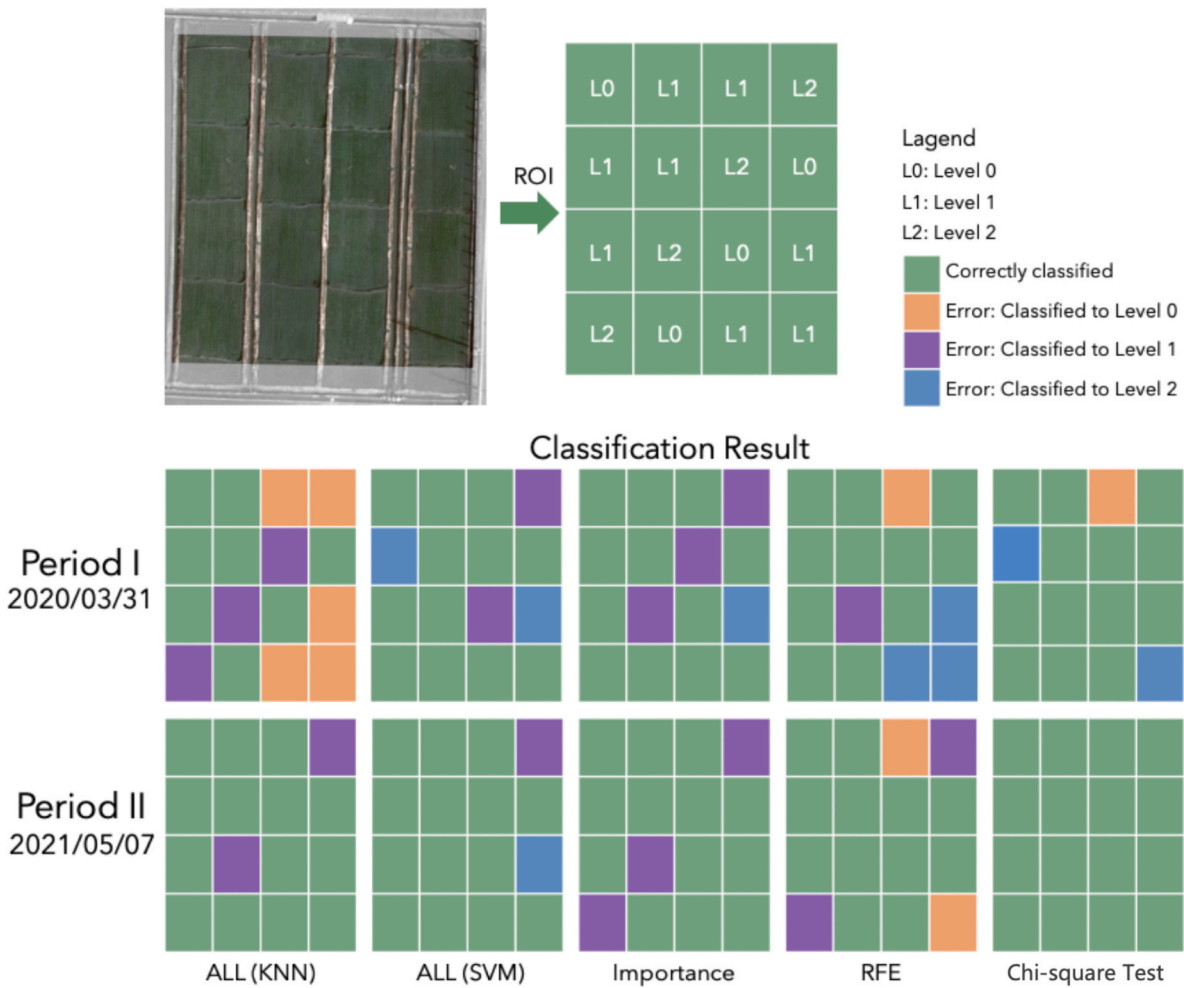


圖 12. 各模型與特徵選擇方法的視覺化結果。地圖顯示 ROI 與分類層級 (L0、L1、L2)。正確分類的區域以綠光顯示，錯誤則依誤分類的層級進行色彩編碼。格網比較了不同模型 (KNN、SVM) 與特徵選擇方法 (RF重要性、RFE、卡方檢定) 之間的性能。

在兩個時期皆然。代表色彩空間轉換與覆蓋率的NHue和冠層覆蓋度是最重要特徵，而CGDD的貢獻最低。這可能是由於CGDD在不同等級之間缺乏變異所致。

特徵與氮素等級之間的關係可能在相關性上有所不同。複合特徵被用來訓練模型。可使用多元線性迴歸模型擬合特徵與氮素等級之間的方程式，然後RFE可根據回歸係數所顯示的貢獻來選擇特徵。RFE會迭代地調整特徵數量，並在每個步驟評估模型的預測性能，以確定每個特徵的貢獻。使用RFE選出的特徵訓練的支持向量機模型之測試表現如表14所示。

支持向量機模型在第一期和第二期使用RFE時的整體準確率分別為75.0%和80.0%，表現優於使用所有特徵或隨機森林重要性特徵的模型。第一期的最佳特徵集合包含九個特徵，如下所示（按RFE排序）：紅邊波段、近紅外光、紅光、綠光、CGDD、GNDVI、OSAVI、RERVI及冠層覆蓋度。第二期的最佳特徵集合則包含紅邊波段、近紅外光和RERVI。紅邊波段與近紅外光在兩個時期中始終是最主要的貢獻者，顯示其與氮素等級具有高度相關性。對於氮水平2，無論是在第一期還是第二期，使用RFE特徵的模型在精確率、召回率和F1分數方面均優於使用全部特徵或由RF重要性所選取特徵的模型。

特徵重要性表示每個

特徵對於氮素等級的解釋能力。採用卡方檢定來評估特徵與氮素等級之間的統計顯著性，並選取關聯性最強的特徵進行模型訓練與測試。檢定結果彙整於表15。

使用卡方檢定所選特徵的支持向量機模型在時期I的整體精度為60.0%，在第二期的整體精度為90.0%。在兩個時期中，適量的特徵組合均包含四個特徵：NDRE、GNDVI、RERVI和冠層覆蓋度。第二期所獲得的整體精度與氮素等級分類結果皆優於時期I。所有特徵的卡方檢定個別p值列於表16中，其中 $p < 0.05$ （標記為\*）表示顯著， $p < 0.01$ （標記為\*\*）表示高度顯著，而 $p < 0.001$ （標記為\*\*\*）表示極度顯著的特徵。兩個時期中表現最佳的特徵組合僅包含極度顯著的特徵。這些結果也顯示，大多數特徵在第二期的顯著性高於時期I。

進行了Dunn-Bonferroni檢定以進一步評估各等級間特徵的顯著性。等級0與等級2之間差異最大，而等級1與等級2之間差異最小。此結果凸顯了僅憑單一特徵來區分常規與過量施肥處理的困難。這些發現與觀察到的分類表現一致；也就是說，精確率、召回率和F1分數在等級0和等級1之間比在等級2更為穩定。




圖 13. 相關性熱圖，說明所有特徵之間的關係。原始光譜波段與某些植被指數之間存在強烈相關性。儘管 NDRE、GNDVI 和 RERVI 存在相關性，但納入這些指數可透過捕捉葉綠素含量、冠層綠度和生物量累積的不同方面，全面評估水稻的氮素反應。

### 3.3. 特徵選擇

本研究透過考慮16個特徵對氮素等級進行分類，即5個原始波段、3種色彩空間轉換、6種植被指數、冠層覆蓋度 (CC) 以及CGDD。在此集合中，通過隨機森林重要性 (RF importance)、RFE或卡方檢定選取出具有預測能力的特徵。各特徵的表現綜合彙總於圖11；顏色強度表示特徵排名。最佳特徵係根據其表現仔細選出。

特徵選擇結果揭示了影響氮分類的關鍵因素。RERVI 和冠層覆蓋度是最常被選用的方法，顯示其具有強大的預測能力。RERVI 對檢測氮濃度十分有效，而冠層覆蓋度的變化也受到氮素供應狀況所驅動。在植被指數中，GNDVI、NDRE 和 OSAVI 持續被選中。GNDVI 可捕捉葉綠素變化，NDRE 在揭示高氮濃度方面表現出色，而 OSAVI 則能減輕土壤背景的影響。對近紅外光'的頻繁選取進一步強調了近紅外光反射率在氮評估中的重要性。

第一期與第二期之間所選特徵的差異反映了水稻生育期的差異。第一期主要代表營養生長，涉及冠層結構和綠度的變化。在第二期的生殖生長期，相關性較低的光譜指數反而具有更高的預測能力。卡方檢定在第二期達成了最高的整體精度，並識別出 NDRE、GNDVI、RERVI 和冠層覆蓋度為最有效的特徵組合。這些結果凸顯了整合光譜、結構及基於指數的預測因子，對於穩健的氮分類以及指導精準農業中無人機監測策略的重要性。

圖 12 的視覺化結果展示了各機器學習模型與特徵選擇方法於兩個時期預測氮素等級的表現。感興趣區域圖代表實驗區內三個氮素等級 (L0、L1 和 L2) 的真實分類情況。分類錯誤在時期 I 特別普遍，

尤其是包含所有特徵的 KNN 模型。L0 與 L1 之間的誤分類情況頻繁。這表示由於水稻植株在營養生長階段具有較高的表型變異性，早期季節的氮素等級分類更具挑戰性。

在第二期，所有模型與特徵選擇方法的分類準確率皆較高。卡方檢定在各氮素等級間取得最平衡的分類結果，顯示其能識別出用於區分氮素等級的最重要特徵。然而，RFE 與 RF重要性方法亦達成具競爭力的結果。整體而言，適量的特徵選擇方法提升了模型的穩健性並減少分類錯誤。這些方法提高了基於無人機的多光譜分析在稻田中進行精確氮素管理的可行性。

某些演算法經常選取原始波段中的近紅外光'與紅邊波段'作為關鍵特徵。本研究所使用的植被指數係由近紅外光與紅邊波段導出，凸顯了氮含量與水稻植株在 785–899 和 705–729 nm 波長處高反射率之間的關聯。色彩空間轉換係由可見光波段推導而來，可能極度依賴這些波段，進而導致模型中潛在的加權偏差，降低其可靠性。圖 13 呈現所有特徵的相關性熱圖。高度相關的特徵可能涉及相依性。原始波段之間具有高度相互依賴性，紅邊波段與紅光亦然。可見光亦依賴於飽和度與明度。在各植被指數中，OSAVI 與 MTVI2 具有高度相關性。

透過RFE與卡方檢定，選出第一期與第二期整體精度最高的特徵組合。在時期 I 中，RFE所選出的部分特徵具有高度相關性。在第二期中，卡方檢定識別出四個關鍵特徵——NDRE、GNDVI、RERVI與冠層覆蓋度，儘管這些特徵彼此相關，但仍能全面評估氮素狀態。每個植被指數皆捕捉到氮素反應的不同面向：GNDVI在偵測氮誘導的葉綠素變化與冠層綠度方面表現有效，NDRE利用紅邊光譜對高葉綠素密度與葉片氮含量具備敏感性，而

RERVI提供近紅外光與紅邊反射率的直接比值，與生物量累積及氮素吸收相關。綜合使用這些特徵可降低忽略關鍵光譜響應的風險，確保更穩健的氮分類。這些特徵之間的協同作用提升了分類準確性，整合NDRE、GNDVI、RERVI與冠層覆蓋度的模型表現優於使用較少指數的模型。此綜合方法提高了氮素評估的可靠性，有助於水稻栽培中精準且數據導向的施肥管理。

#### 4. 結論

本研究提出了一種創新的氮素等級分類架構，利用無人機與機器學習支持大規模、定量的養分評估方法。水稻像素分割是透過九個光譜特徵以及非監督與監督分類模型來進行。ExG特徵搭配Otsu演算法在水稻植株分割中達到77.6%的召回率與79.4%的整體精度。以全部九個特徵訓練的決策樹方法性能高得多，召回率達95.3%，整體精度為88.8%。

在氮素等級分類分析中，資料根據關鍵生長階段分為時期I與第二期。分類使用了一組共16個光譜與結構特徵。支持向量機模型表現往往優於KNN模型，特別是在具有非線性關係的資料上。多種特徵選擇演算法（RF重要性、RFE與卡方檢定）被用來進一步優化支持向量機模型；其中以卡方檢定選出的特徵在第二期獲得最高的整體精度（90.0%）。NDRE、GNDVI與RERVI，以及冠層覆蓋度，是對分類貢獻最大的關鍵特徵。

冠層覆蓋度（CC）在營養生長階段（時期I）一直具有重要性，因為此時期存在顯著的表型變化。光譜特徵如NDRE、GNDVI和RERVI在生殖階段（第二期）則更具影響力。透過選取關鍵特徵，該模型實現了穩健的準確性和可靠性，支持可與自動施肥系統結合實施的精準大規模氮管理措施，從而促進農業永續性。

#### 附錄 A

**表 A1**  
試驗田區的土壤化學性質。該表格包含酸鹼值（pH）、磷（P）、鉀（K）、銨態氮（ $\text{NH}_4^+\text{-N}$ ）、硝酸態氮（ $\text{NO}_3^-\text{-N}$ ）以及有效性氮（available N）的濃度（ppm）。各測試區的氮肥施用量（N Apply）以公斤/公頃（kg/ha）列出。田區根據不同的氮肥處理（N1-N6）與灌溉方式（慣行栽培，CP；交替灌溉與乾燥，AWD）分為四個區域（A、B、C、D）。

作物季節	田區	氮肥施用量 (kg/ha)	pH	磷 (ppm)	鉀 (ppm)	$\text{NH}_4^+\text{-N}$ (ppm)	$\text{NO}_3^-\text{-N}$ (ppm)	有效性氮 (ppm)
2020 I	A1	200	5.05	38.14	39.52	3.73	1.97	5.70
	A2	80	4.96	37.99	40.15	4.93	2.38	7.31
	A3	160	5.10	40.76	39.95	3.84	3.24	7.08
	A4	120	4.89	12.71	36.17	4.10	1.75	5.85
	B1	120	5.21	16.65	43.76	2.37	3.41	5.78
	B2	200	5.33	24.96	43.32	3.37	3.48	6.85
	B3	80	5.17	48.38	39.38	3.30	3.39	6.69
	B4	160	4.97	34.57	30.55	3.36	2.46	5.82
	C1	160	5.28	45.35	46.87	4.60	3.49	8.09
	C2	120	5.06	43.31	45.15	3.25	2.70	5.95
	C3	200	5.06	31.76	49.39	3.00	2.71	5.71
	C4	80	4.92	36.91	49.30	3.89	3.66	7.55
	D1	80	5.18	54.89	37.32	3.52	3.29	6.81
	D2	160	5.35	21.73	40.77	3.96	3.77	7.73
	D3	120	5.19	46.90	42.55	4.12	2.13	6.25
	D4	200	5.53	36.87	47.29	4.25	3.85	8.10
2020 II	A1	80	5.63	29.70	64.14	3.21	5.15	8.36
	A2	200	5.56	29.60	51.73	4.20	5.37	9.57
	A3	120	5.59	26.60	41.52	2.98	4.49	7.47

(接下頁)

然而，本研究存在局限性。數據僅來自一個地點的兩個作物季節，可能限制其普遍適用性。此外，水稻品種、土壤類型和氣候因子的變異也可能影響結果的推廣性。無人機調查成本目前約為每 10 公頃 1,200 美元；若採用適應性巡查，成本可降至 600 美元以下，提升應用性（Yang 等人, 2020）。無人機影像所需的高儲存空間與數位化足跡亦構成挑戰（Kayad 等人, 2022）。未來研究應透過收集更多樣且廣泛的數據集，並策略性優化無人機影像獲取時機，以平衡數據效率與儲存需求，來解決這些限制。此外，整合時間序列機器學習方法以捕捉養分動態，以及運用領域適應技術（Yang 等人, 2025b），將進一步提升模型在永續農業應用中的普遍適用性與實用價值。

#### CRedit 作者貢獻聲明

**楊明德**：撰寫一審核與編輯、督導、方法論、取得經費、概念化。  
**許育鈞**：撰寫一審核與編輯、撰寫一原始草稿、方法論、正式分析、概念化。  
**陳奕璇**：撰寫一原始草稿、軟體、方法論、正式分析。  
**楊靜瑩**：視覺化、方法論、概念化。  
**李凱雲**：撰寫一原始草稿、方法論。

#### 利益衝突聲明

作者聲明，他們沒有已知的競爭性財務利益或可能被視為影響本文所報告工作的個人關係。

#### 致謝

本研究部分由國家科學及技術委員會（臺灣）資助，計畫編號為 NSTC113-2634-F-005-002—智慧永續新農業研究中心（SMARTer）。

表 A1 (續)

作物季節	田區	氮肥施用量 (kg/ha)	pH	磷 (ppm)	鉀 (ppm)	NH <sub>4</sub> <sup>+</sup> -N (ppm)	NO <sub>3</sub> <sup>-</sup> -N (ppm)	有效性氮 (ppm)
	A4	160	5.82	20.39	42.10	2.24	4.36	6.60
	B1	120	5.26	40.96	39.00	3.47	2.19	5.66
	B2	80	5.16	57.46	36.91	1.89	1.93	3.82
	B3	160	5.04	46.78	38.86	2.26	2.27	4.53
	B4	200	5.22	24.87	33.18	4.81	0.62	5.43
	C1	160	5.27	60.33	41.32	4.89	1.63	6.52
	C2	120	5.33	57.65	39.42	2.67	2.30	4.97
	C3	200	5.34	53.86	38.19	2.60	2.56	5.16
	C4	80	5.56	31.15	40.36	4.32	1.20	5.52
	D1	200	5.43	69.17	38.51	1.79	2.74	4.53
	D2	160	5.35	60.17	39.58	3.65	3.44	7.09
	D3	80	5.07	44.78	35.64	4.06	3.38	7.44
	D4	120	5.39	42.16	32.69	3.19	2.14	5.33
2021 I	A1	120	5.68	55.29	48.01	2.78	10.35	13.13
	A2	140	5.71	60.42	53.79	4.75	7.25	12.00
	A3	80	5.51	66.27	57.07	2.23	11.12	13.35
	A4	200	5.58	63.54	57.59	2.06	8.66	10.72
	A5	160	5.56	52.07	61.71	3.50	8.35	11.85
	A6	100	5.46	56.34	51.83	3.21	4.11	7.32
	B1	140	5.57	44.82	55.37	4.10	2.20	6.30
	B2	200	5.53	68.69	50.21	5.18	8.42	13.60
	B3	100	5.59	68.61	60.39	3.35	6.05	9.40
	B4	120	5.59	62.05	46.34	4.50	6.66	11.16
	B5	80	5.52	53.32	49.22	4.68	4.24	8.92
	B6	160	5.28	49.45	48.40	4.16	2.85	7.01
	C1	80	5.56	60.12	52.16	4.17	4.34	8.51
	C2	140	5.71	65.26	49.51	1.54	7.37	8.91
	C3	100	5.66	64.74	52.89	2.21	6.63	8.84
	C4	160	5.45	32.43	47.36	1.69	7.71	9.40
	C5	120	5.51	31.05	52.83	1.44	8.48	9.92
	C6	200	5.42	23.29	60.83	1.14	4.10	5.24
	D1	160	5.82	31.30	48.99	3.80	6.05	9.85
	D2	120	5.85	30.08	51.94	2.38	9.87	12.25
	D3	200	5.99	30.96	51.77	2.77	8.47	11.24
	D4	100	5.86	43.24	50.02	2.58	5.18	7.76
	D5	80	6.16	53.87	45.09	2.66	6.78	9.44
	D6	140	5.78	40.36	36.46	2.70	1.53	4.23
2021 II	A1	100	5.09	33.02	55.00	3.45	4.46	7.91
	A2	160	5.04	29.83	58.17	3.44	3.81	7.25
	A3	200	5.08	30.75	61.43	4.75	8.01	12.76
	A4	80	5.05	35.42	57.79	4.70	9.28	13.98
	A5	120	5.17	23.12	58.98	6.64	4.14	10.78
	A6	140	5.17	22.61	58.47	6.93	10.65	17.58
	B1	120	4.89	27.53	75.87	4.69	7.14	11.83
	B2	80	4.91	30.13	98.56	9.79	6.86	16.65
	B3	160	5.08	27.91	74.44	5.76	3.59	9.35
	B4	100	4.75	31.56	62.97	4.08	5.49	9.57
	B5	200	4.66	17.59	67.15	6.29	6.24	12.53
	B6	140	4.57	11.87	65.74	4.76	5.59	10.36
	C1	200	5.04	27.05	59.90	5.23	9.09	14.32
	C2	120	5.10	26.04	55.97	6.65	6.23	12.89
	C3	160	5.00	24.90	80.08	6.76	17.68	24.45
	C4	80	5.08	30.71	57.71	2.48	10.25	12.74
	C5	140	4.92	20.06	62.17	3.27	5.99	9.25
	C6	100	4.85	16.04	61.40	3.71	3.77	7.48
	D1	120	5.08	38.63	68.05	5.13	17.56	22.68
	D2	100	5.40	31.36	46.27	4.54	9.63	14.17
	D3	140	5.36	30.16	49.45	4.87	9.41	14.28
	D4	200	5.30	34.17	58.92	5.23	11.20	16.43
	D5	80	5.12	24.90	61.92	4.68	9.09	13.77
	D6	160	4.69	25.40	69.05	5.83	13.79	19.63




圖 A1。2020 年 2 月至 2021 年 11 月 G2F820 五峰氣象站的每月氣候資料。左側面板顯示氣溫 (°C, 線條) 和降水量 (mm, 長條圖), 而右側面板則呈現作物季節 I 和 II 期間的相對濕度 (% , 長條圖) 和日照時數 (小時, 線條)。

## 資料可用性

資料將依請求提供。

## 參考資料

- Bagheri, N., Ahmadi, H., Alavipanah, S.K., Omid, M., 2013. Multispectral remote sensing for site-specific nitrogen fertilizer management. *Pesquisa Agropecuaria Brasileira* 48 (10), 1394–1401. <https://doi.org/10.1590/S0100-204X2013001000011>.
- Bantan, R.A.R., Ali, A., Naem, S., Jamal, F., Elgarhy, M., Chesneau, C., 2020. Discrimination of sunflower seeds using multispectral and texture dataset in combination with region selection and supervised classification methods. *Chaos: Interdiscip. J. Nonlinear Sci.* 30 (11). <https://doi.org/10.1063/5.00244017>.
- Barnes, E.M., Clarke, T.R., Richards, S.E., Colaizzi, P.D., Haberland, J., Kostrzewski, M., Waller, P., Choi C., R.E., Thompson, T., Lascano, R.J., Li, H., Moran, M.S., 2000. July. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: Proceedings of the fifth international conference on precision agriculture, Bloomington, MN, USA, Vol. 1619, No. 6.
- Barzin, R., Lotfi, H., Varco, J.J., Bora, G.C., 2022. Machine learning in evaluating multispectral active canopy sensor for prediction of corn leaf nitrogen concentration and yield. *Remote Sens. (Basel)* 14 (1), 1–17. <https://doi.org/10.3390/rs14010120>.
- Brinkhoff, J., Dunn, B.W., Dunn, T., Schultz, A., Hart, J., 2025. Forecasting field rice grain moisture content using Sentinel-2 and weather data. *Precis. Agric.* 26 (1), 28.
- Cassidy, A.P., Deviney, F.A., 2014, October. Calculating feature importance in data streams with concept drift using Online Random Forest. In: 2014 IEEE International Conference on Big Data (Big Data), pp. 23–28. IEEE. doi: 10.1109/BigData.2014.7004352.
- Darst, B.F., Malecki, K.C., Engelman, C.D., 2018. Using recursive feature elimination in random forest to account for correlated variables in high dimensional data. *BMC Genet.* 19 (Suppl. 1), 1–6. <https://doi.org/10.1186/s12863-018-0633-8>.
- Dutta, K., Talukdar, D., Bora, S.S., 2022. Segmentation of unhealthy leaves in cruciferous crops for early disease detection using vegetative indices and Otsu thresholding of aerial images. *Measurement* 189, 110478. <https://doi.org/10.1016/j.measurement.2021.110478>.
- García Cárdenas, D.A., Ramón Valencia, J.A., Alzate Velásquez, D.F., Palacios Gonzalez, J.R., 2018. Dynamics of the indices NDVI and GNDVI in a rice growing in its reproduction phase from multi-spectral aerial images taken by drones. *Adv. Intell. Syst. Comput.* 893, 106–119. [https://doi.org/10.1007/978-3-030-04447-3\\_7](https://doi.org/10.1007/978-3-030-04447-3_7).
- Gitelson, A.A., Kaufman, Y.J., Merzlyak, M.N., 1996. Use of the green channel in remote sensing in global vegetation for EOS-MODIS. *Remote Sens. Environ.* 58, 298.
- Haboudane, D., Miller, J.R., Pattey, E., Zarco-Tejada, P.J., Strachan, I.B., 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. *Remote Sens. Environ.* 90 (3), 337–352. <https://doi.org/10.1016/j.rse.2003.12.013>.
- Haboudane, D., Miller, J.R., Tremblay, N., Zarco-Tejada, P.J., Dextraze, L., 2002. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sens. Environ.* 81 (2–3), 416–426. [https://doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4).
- Imandoust, S.B., Bolandraftar, M., 2013. Application of K-Nearest Neighbor (KNN) approach for predicting economic events: theoretical background. *Int. J. Eng. Res. Appl.* 3 (5), 605–610.
- Kayad, A., Sozzi, M., Paraforos, D.S., Rodrigues, F.A., Cohen, Y., Fountas, S., Francisco, M., Pezzuolo, A., Grigolato, S., Marinello, F., 2022. How many gigabytes per hectare are available in the digital agriculture era? A digitization footprint estimation. *Comput. Electron. Agric.* 198, 107080. <https://doi.org/10.1016/j.compag.2022.107080>.
- Khan, S., Narvekar, M., 2022. Novel fusion of color balancing and superpixel based approach for detection of tomato plant diseases in natural complex environment. *J. King Saud Univ. – Comput. Inf. Sci.* 34 (6), 3506–3516. <https://doi.org/10.1016/j.jksuci.2020.09.006>.
- Lawrence, R.L., Ripple, W.J., 1998. Comparisons among vegetation indices and bandwise regression in a highly disturbed, heterogeneous landscape: Mount St. Helens, Washington. *Remote Sens. Environ.* 64 (1), 91–102. [https://doi.org/10.1016/S0034-4257\(97\)00171-5](https://doi.org/10.1016/S0034-4257(97)00171-5).
- Lee, C.J., Yang, M.D., Tseng, H.H., Hsu, Y., Sung, Y., Chen, W.L., 2023. Single-plant broccoli growth monitoring using deep learning with UAV imagery. *Comput. Electron. Agric.* 207, 107739. <https://doi.org/10.1109/10.1016/j.compag.2023.107739>.
- Li, F., Miao, Y., Feng, G., Yuan, F., Yue, S., Gao, X., Liu, Y., Liu, B., Ustin, S.L., Chen, X., 2014. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. *Field Crop Res.* 157, 111–123. <https://doi.org/10.1016/j.fcr.2013.12.018>.
- Li, G.S., Wu, D.H., Su, Y.C., Kuo, B.J., Yang, M.D., Lai, M.H., Lu, H.Y., Yang, C.Y., 2021. Prediction of plant nutrition state of rice under water-saving cultivation and panicle fertilization application decision making. *Agronomy* 11 (8), 1626. <https://doi.org/10.3390/agronomy11081626>.
- Li, K.Y., de Lima, R.S., Burnside, N.G., Vahtmae, E., Kutser, T., Sepp, K., Pinheiro, V.H.C., Yang, M.D., Vain, A., Sepp, K., 2022. Toward automated machine learning-based hyperspectral image analysis in crop yield and biomass estimation. *Remote Sens. (Basel)* 14 (5). <https://doi.org/10.3390/rs14051114>.
- Li, S., Ding, X., Kuang, Q., Ata-Ul-Karim, S.T., Cheng, T., Liu, X., Tian, Y., Zhu, Y., Cao, W., Cao, Q., 2018. Potential of UAV-based active sensing for monitoring rice leaf nitrogen status. *Front. Plant Sci.* 9, 1834. <https://doi.org/10.3389/fpls.2018.01834>.
- Lin, X., Yang, F., Zhou, L., Yin, P., Kong, H., Xing, W., Lu, X., Jia, L., Wang, Q., Xu, G., 2019. A support vector machine-recursive feature elimination feature selection method based on artificial contrast variables and mutual information. *J. Chromatogr. B Anal. Technol. Biomed. Life Sci.* 910, 149–155. <https://doi.org/10.1016/j.jchromb.2012.05.020>.
- Liu, Y., Feng, H., Yue, J., Fan, Y., Bian, M., Ma, Y., Jin, X., Song, X., Yang, G., 2023. Estimating potato above-ground biomass by using integrated unmanned aerial system-based optical, structural, and textural canopy measurements. *Comput. Electron. Agric.* 213, 108229. <https://doi.org/10.1016/j.compag.2023.108229>.
- Liu, Y., Yang, F., Yue, J., Zhu, W., Fan, Y., Fan, J., Ma, Y., Bian, M., Chen, R., Yang, G., Feng, H., 2024. Crop canopy volume weighted by color parameters from UAV-based RGB imagery to estimate above-ground biomass of potatoes. *Comput. Electron. Agric.* 227, 109678. <https://doi.org/10.1016/j.compag.2024.109678>.
- Lowe, B., Kulkarni, A., 2015. Multispectral image analysis using random forest. *Int. J. Soft Comput.* 6 (1), 1–14. <https://doi.org/10.5121/ijsc.2015.6101>.
- Marinello, F., Bramley, R.G.V., Karkee, M., Cohen, Y., Fountas, S., Guo, H., Vellidis, G., 19, 83–89. [https://doi.org/10.3920/978-90-8686-888-9\\_9](https://doi.org/10.3920/978-90-8686-888-9_9).
- Meyer, G.E., Neto, J.C., 2008. Verification of color vegetation indices for automated crop imaging applications. *Comput. Electron. Agric.* 63 (2), 282–293. <https://doi.org/10.1016/j.compag.2008.03.009>.
- Misra, P., Yadav, A.S., 2020. Improving the classification accuracy using recursive feature elimination with cross-validation. *Int. J. Emerg. Technol.* 11 (3), 659–665.
- Moghimi, A., Pourreza, A., Zuniga-Ramirez, G., Williams, L.E., Fidelibus, M.W., 2020. A novel machine learning approach to estimate grapevine leaf nitrogen concentration using aerial multispectral imagery. *Remote Sens. (Basel)* 12 (21), 3515. <https://doi.org/10.3390/rs12213515>.
- Orillo, J.W., Emperador, G.J., Gasgonia, M.G., Parpan, M., Yang, J., 2014, November. Rice plant nitrogen level assessment through image processing using artificial neural network. In: 2014 International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM) (pp. 1–6). IEEE. doi: 10.1109/HNICEM.2014.7016187.
- Otsu, N., 1975. A threshold selection method from gray-level histograms. *Automatica* 11 (285–296), 23–27.
- Qiao, L., Gao, D., Zhang, J., Li, M., Sun, H., Ma, J., 2020. Dynamic influence elimination and chlorophyll content diagnosis of maize using UAV spectral imagery. *Remote Sens. (Basel)* 12 (16). <https://doi.org/10.3390/RS12162650>.

- Raschka, S., Mirjalili, V., 2019. *Python Machine Learning: Machine Learning and Deep Learning with Python, Scikit-learn, and TensorFlow 2*. Packt Publishing Ltd.
- Riehle, D., Reiser, D., Griepentrog, H.W., 2020. Robust index-based semantic plant/background segmentation for RGB-images. *Comput. Electron. Agric.* 169, 105201. <https://doi.org/10.1016/j.compag.2019.105201>.
- Rouse, J.W. Jr., Haas, R.H., Schell, J.A., Deering, D.W., 1973. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation (No. NASA-CR-132982).
- Saeys, Y., Inza, L., Larrañaga, P., 2007. A review of feature selection techniques in bioinformatics. *Bioinformatics* 23 (19), 2507–2517. <https://doi.org/10.1093/bioinformatics/btm344>.
- Shao, Y.E., Dai, J.T., 2018. Integrated feature selection of ARIMA with computational intelligence approaches for food crop price prediction. *Complexity* 2018 (1), 1910520. <https://doi.org/10.1155/2018/1910520>.
- Sharma, A., Deepa, R., Sankar, S., Pryor, M., Stewart, B., Johnson, E., Anandhi, A., 2021. Use of growing degree indicator for developing adaptive responses: a case study of cotton in Florida. *Ecol. Ind.* 124, 107383. <https://doi.org/10.1016/j.ecolind.2021.107383>.
- Sheng, R.T.C., Huang, Y.H., Chan, P.C., Bhat, S.A., Wu, Y.C., Huang, N.F., 2022. Rice growth stage classification via RF-based machine learning and image processing. *Agriculture* 12 (12), 2137. <https://doi.org/10.3390/agriculture12122137>.
- Shi, P., Wang, Y., Xu, J., Zhao, Y., Yang, B., Yuan, Z., Sun, Q., 2021. Rice nitrogen nutrition estimation with RGB images and machine learning methods. *Comput. Electron. Agric.* 180, 105860. <https://doi.org/10.1016/j.compag.2020.105860>.
- Smith, A.R., 1978. Color gamut transform pairs. *Comput. Graph (ACM)* 12 (3), 12–19. <https://doi.org/10.1145/965139.807361>.
- Tseng, H.H., Yang, M.D., Saminathan, R., Hsu, Y.C., Yang, C.Y., Wu, D.H., Wu, D.H., 2022. Rice seedling detection in UAV images using transfer learning and machine learning. *Remote Sens. (Basel)* 14 (12). <https://doi.org/10.3390/rs14122837>.
- Tucker, C.J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8 (2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0).
- Wang, J., Zhou, Q., Shang, J., Liu, C., Zhuang, T., Ding, J., Xian, Y., Zhao, L., Wang, W., Zhou, G., Tan, C., Huo, Z., 2021. UAV-and machine learning-based retrieval of wheat SPAD values at the overwintering stage for variety screening. *Remote Sens. (Basel)* 13 (24), 1–19. <https://doi.org/10.3390/rs13245166>.
- Wang, Y., Hu, X., Hou, Z., Ning, J., Zhang, Z., 2018. Discrimination of nitrogen fertilizer levels of tea plant (*Camellia sinensis*) based on hyperspectral imaging. *J. Sci. Food Agric.* 98 (12), 4659–4664. <https://doi.org/10.1002/jsfa.8996>.
- Wang, Z., Xie, Z., 2014, June. Infrared face recognition based on local binary patterns and Kruskal-Wallis test. In: 2014 IEEE/ACIS 13th International Conference on Computer and Information Science (ICIS). IEEE, pp. 185–188. doi: 10.1109/ICIS.2014.6912131.
- Woebbecke, D.M., Meyer, G.E., Von Bargen, K., Mortensen, D.A., 1995. Color indices for weed identification under various soil, residue, and lighting conditions. *Trans. Am. Soc. Agric. Eng.* 38 (1), 259–269. <https://doi.org/10.13031/2013.27838>.
- Wu, D.H., Chen, C.T., Yang, M.D., Wu, Y.C., Lin, C.Y., Lai, M.H., Yang, C.Y., 2022. Controlling the lodging risk of rice based on a plant height dynamic model. *Bot. Stud.* 63 (1). <https://doi.org/10.1186/s40529-022-00356-7>.
- Yang, C., Wu, G., Ding, K., Shi, T., Li, Q., Wang, J., 2017. Improving land use/land cover classification by integrating pixel unmixing and decision tree methods. *Remote Sens. (Basel)* 9 (12). <https://doi.org/10.3390/rs9121222>.
- Yang, C.Y., Yang, M.D., Tseng, W.C., Hsu, Y.C., Li, G.S., Lai, M.H., Wu, D.H., Lu, H.Y., 2020a. Assessment of rice developmental stage using time series uav imagery for variable irrigation management. *Sensors* 20 (18), 1–21. <https://doi.org/10.3390/s20185354>.
- Yang, M.D., Hsu, Y.C., Liu, T.T., Huang, H.H., 2025a. Enhancing grain moisture prediction in multiple crop seasons using domain adaptation AI. *Comput. Electron. Agric.* 231, 110058.
- Yang, M.D., Boubin, J.G., Tsai, H.P., Tseng, H.H., Hsu, Y.C., Stewart, C.C., 2020b. Adaptive autonomous UAV scouting for rice lodging assessment using edge computing with deep learning EDANet. *Comput. Electron. Agric.* 179, 105817. <https://doi.org/10.1016/j.compag.2023.107739>.
- Yang, M.D., Hsu, Y.C., Tseng, W.C., Lu, C.Y., Yang, C.Y., Lai, M.H., Wu, D.H., 2021a. Assessment of grain harvest moisture content using machine learning on smartphone images for optimal harvest timing. *Sensors* 21 (17). <https://doi.org/10.3390/s21175875>.
- Yang, M.D., Hsu, Y.C., Tseng, W.C., Tseng, H.H., Lai, M.H., 2025b. Precision assessment of rice grain moisture content using UAV multispectral imagery and machine learning. *Comput. Electron. Agric.* 230, 109813. <https://doi.org/10.3390/s21175875>.
- Yang, M.D., Tseng, H.H., Hsu, Y.C., Yang, C.Y., Lai, M.H., Wu, D.H., 2021b. A UAV open dataset of rice paddies for deep learning practice. *Remote Sens. (Basel)* 13 (7). <https://doi.org/10.3390/rs13071358>.
- Yang, M.D., Tseng, H.H., Hsu, Y.C., Tsai, H.P., 2020c. Semantic segmentation using deep learning with vegetation indices for rice lodging identification in multi-date UAV visible images. *Remote Sens. (Basel)* 12 (4). <https://doi.org/10.3390/rs12040633>.
- Yang, M.D., Sykes, R.M., Merry, C.J., 2000. Estimation of algal biological parameters using water quality modeling and SPOT satellite data. *Ecol. Model.* 125 (1), 1–13.
- Yang, W., Wang, S., Zhao, X., Zhang, J., Feng, J., 2015. Greenness identification based on HSV decision tree. *Inf. Process. Agric.* 2 (3–4), 149–160. <https://doi.org/10.1016/j.inpa.2015.07.003>.
- Yang, Y., Zhao, X., Huang, M., Wang, X., Zhu, Q., 2021c. Multispectral image based germination detection of potato by using supervised multiple threshold segmentation model and Canny edge detector. *Comput. Electron. Agric.* 182, 106041. <https://doi.org/10.1016/j.compag.2021.106041>.
- Yuan, Y., Wu, L., Zhang, X., 2021. Gini-impurity index analysis. *IEEE Trans. Inf. Forensics Secur.* 16, 3154–3169. <https://doi.org/10.1109/TIFS.2021.3076932>.
- Zou, K., Ge, L., Zhang, C., Yuan, T., Li, W., 2019. Broccoli seedling segmentation based on support vector machine combined with color texture features. *IEEE Access* 7, 168565–168574. <https://doi.org/10.1109/ACCESS.2019.2954587>.