

Sentinel-2 光譜與紋理特徵對土地覆蓋分類效能的改進

Enhancing land cover classification using spectral and texture features from Sentinel-2 data

黃靜宜

Jing-Yi Huang

農業部生物多樣性研究所 552005 南投縣集集鎮民生東路 1 號

Taiwan Biodiversity Research Institute, Nantou, Taiwan

通訊作者：lily@tbri.gov.tw

Corresponding author: lily@tbri.gov.tw

摘要

即時並有效地掌握土地覆蓋資訊，對於地景規劃或自然資源管理至關重要。遙測影像分類技術作為當代獲取該資訊的主要手段，如何提升其分類效能，仍是遙測研究持續關注的課題之一。本研究以大肚臺地為例，首先，透過 Sentinel-2 (S2) 原始波段的組合，生成可突顯地物光譜特徵的光譜指標，同時基於灰階共生矩陣，擷取可反映空間排列特徵的紋理指標，再分別令其與原始波段整合，作為隨機森林分類演算法的輸入資料集，對 7 種土地覆蓋類型進行分類，最後，評估並比較不同特徵組合的分類效果。研究結果顯示，儘管 S2 原始波段在地覆分類中具相當潛力，但用於辨別高異質性混淆植被或高變異性草本植被時，其效果仍顯不足。無論添加光譜或紋理特徵，均有助整體分類效能的提升，且兩類特徵

對特定類別準確度的提升具互補性，合併添加可獲得最佳分類效果，總體準確度與 Kappa 係數，分別可達 90.56%、0.88，相較於僅使用原始波段，約可提升 3.35%、0.04，並在 McNemar 檢定下，達差異顯著水準 ($p \leq 0.001$)，各類別 F1 分數亦能獲不同程度的改善 (0.64–11.06%)。綜合上述結果，本研究建議在選擇土地覆蓋分類輸入資料集時，除常見的光譜特徵外，亦可考慮額外添加紋理特徵，以最大程度提高分類準確度。

關鍵詞：灰階共生矩陣、植生指標、隨機森林、遙感探測、土地覆蓋分類

Abstract

Timely and effective acquisition of land cover information is crucial for landscape planning and natural resource management. Remote sensing image classification is a primary method for acquiring land cover information, and enhancing the performance of classification still remains a key research topic to focus on. In our study, spectral features were generated from the combinations of Sentinel-2 (S2) original bands in Dadu Terrace area to highlight the spectral characteristics of land cover types. Simultaneously, texture features reflecting spatial arrangement patterns were extracted using the gray-level co-occurrence matrix. These features were then combined with the original bands to form input datasets for the random forest classification algorithm, which was used to classify seven land cover types. Finally, the classification performance of different feature combinations was evaluated and compared. The results indicate that although the S2 original bands display considerable potential in land cover classification, they are still insufficient for distinguishing heterogeneous mixed vegetation or highly variable herbaceous vegetation. Incorporating either commonly used spectral features or texture features improved overall classification performance and also enhanced classification

accuracy from their complementary effects on the specific categories. Using the combination of spectral and texture features achieved the best results with an overall accuracy of 90.56% and a Kappa coefficient of 0.88, representing improvements of 3.35% and 0.04, respectively, over the use of original bands alone, and these improvements were statistically significant ($p \leq 0.001$), confirmed by the McNemar test. Additionally, the F1-scores across all categories also showed enhancement, ranging from 0.64 to 11.06%. In summary, this study recommends to use combination of texture features and spectral features to maximize classification accuracy when selecting input datasets for land cover classification.

Keywords: gray-level co-occurrence matrix, vegetation indices, random forest, remote sensing, land cover classification

收件日期：2024 年 11 月 22 日 Received: November 22, 2024

接受日期：2025 年 6 月 26 日 Accepted: June 26, 2025

緒言

土地覆蓋 (land cover) 資訊不僅為陸地表面元素的組成和分布提供描述，還反映了人類對這些元素的使用目的或影響 (Foody 2002)。即時且有效地掌握地覆資訊，對於地景規劃或自然資源管理至關重要，相較於傳統地面調查與航照判識，衛星遙測數據具備穩定性、可重複觀測、覆蓋範圍廣和成本低等優勢，儼然成為當代土地覆蓋分類的主要材料來源。通常，遙測數據在地覆分類上的應用，係基於地物對特定波段反射特徵的差異來進行 (Lu and Weng 2007)，其過程通常透過一組已標記且具代表性的訓練資料集，使用統計或機器學習演算法，探索各類別光譜特徵，並將影像的像元從原始資料轉換為具意義的分類資訊。分類準確性取決於訓練資料集的代表性 (Kavzoglu 2009)，以及目標類別在光譜特徵空間中的分離度 (Gambarova *et al.* 2010)。時至今日，免費開放獲取的多光譜影像，如 Sentinel-2 (S2) 或 Landsat，已成為地覆測繪或監測應用的首選材料 (Phiri *et*

al. 2020)，然而，在實務應用中，面對高度複雜的異質性地景時，經常囿於地景中生態複雜性、物候多樣性，以及光譜混淆等因素的影響 (Jozdani *et al.* 2019; Wei *et al.* 2023)，導致部分目標類別分類效果不彰。儘管新一代高光譜影像提供了更寬的光譜範圍，以及更高的光譜解析力，有助類別分離度的提高，然礙於成本昂貴與獲取不易等特性，未能廣泛應用。因此，持續在多光譜影像的基礎上，探尋有效的方法，精進分類性能，仍是當前遙測研究的重要課題 (Macintyre *et al.* 2020)。

添加輔助資料集 (ancillary datasets) 是提升多光譜影像分類性能常見的策略之一。輔助資料可由影像初始觀測數據直接進行特徵擷取或衍生計算，生成一組可豐富或突顯特定地表特徵的新訊息，以此作為分類用的補充解釋特徵，通常有助於提升分類準確度 (Lv *et al.* 2014)，植生與紋理指標即為常見的輔助資料 (Kavzoglu and Bilucan 2023) 類型之一。遙測影像所提供的光譜資訊，

是光學感測器以像元為單位，接收並記錄地表不同地物對電磁波譜的反射率，而兩個或多個波段的光譜反射率經過數學算術組合後，可為突顯特定地物特徵的光譜指標，相較於單一波段，更有利於強調地物間的差異（Brendel *et al.* 2019），惟常見植生指標（vegetation indices, VIs）仍存在飽和效應（saturation effect）、混合像元（mixed pixel），以及類別間光譜過於相似等不確定性（Huete *et al.* 1997; Rodriguez-Galiano and Chica-Olmo 2012），導致分類混淆的情形難以避免，此時紋理（texture）特徵有機會彌補此類缺失。與光譜特徵不同的是，紋理特徵非關注單個像元，而是強調影像局部區域色調強度的空間排列與變化（Hall-Beyer 2017），紋理特徵的擷取方法多樣，其中灰階共生矩陣（gray-level co-occurrence matrix, GLCM）最為常見，概念上是圖像中所有像元灰階值組合出現頻率的度量，最初用於圖像分類（Haralick *et al.* 1973），現今於地覆分類研究上多有應用，該類特徵有助降低因光譜

相似性所產生的類別混淆，使分類準確度獲得有效提升（Kabir *et al.* 2010; Hall-Beyer 2017）。

大肚臺地為林業及自然保育署國土生態綠網計畫指認關注區域之一，現已規劃為大肚臺地淺山保育軸帶，相關單位刻正積極推動區內植被復育、入侵種移除、生態廊道串連與棲地營造等工作，足見其生態保育價值。然而，近代都市擴張、農業使用，以及頻繁的野火干擾等因素，致其地覆變化快速而明顯（張及章 2004；邱等 2012；嚴 2012），至今由入侵植物大黍（*Panicum maximum*）所引發的野火干擾，仍持續且規律在發生，對生態復育工作構成嚴峻挑戰。由於土地覆蓋與野火風險息息相關，除直接供給燃料來源外，亦影響野火的發生與蔓延（Nunes *et al.* 2005; Pereira *et al.* 2014），故精準掌握土地覆蓋資訊，對於燃料管理與野火風險評估甚為重要。有鑑於此，本研究以大肚臺地為試驗區，首先自 S2 影像擷取植被與紋理等兩類特徵，並將其與 S2 原始波段進行整合，以隨機森林（random

forest, RF) 演算法，執行土地覆蓋分類，評估並比較不同特徵組合下的分類效能，研究目的在於一、評估 S2 對測繪研究區土地覆蓋的可行性；二、確立有助提升分類性能的特徵組合與重要變項，期研究成果可作為未來土地覆蓋監測與管理之參考資訊。

材料與方法

1、研究區概述

大肚臺地東臨臺中盆地，西接清水平原，北起大甲溪南岸，南至大肚

溪北岸，為一南北長約 20 km、東西寬約 5–7 km 的長形臺地，面積約 140 km² (圖 1)。臺地頂部平坦開闊，平均海拔約 180 m，海拔 310 m 的大肚山為其最高點。由於地形因素，土壤多為紅黏土，並含有大量礫石，保水性差，農業活動以旱作為主。根據鄰近之大雅 (中科園區) 氣象站 2018–2022 年的統計資料顯示，該區年均溫約 23°C，年降水量約 1,488 mm，具明顯乾濕季，乾季 (10 至翌年 2 月) 與濕季 (3 至 9 月) 月平均降雨量，

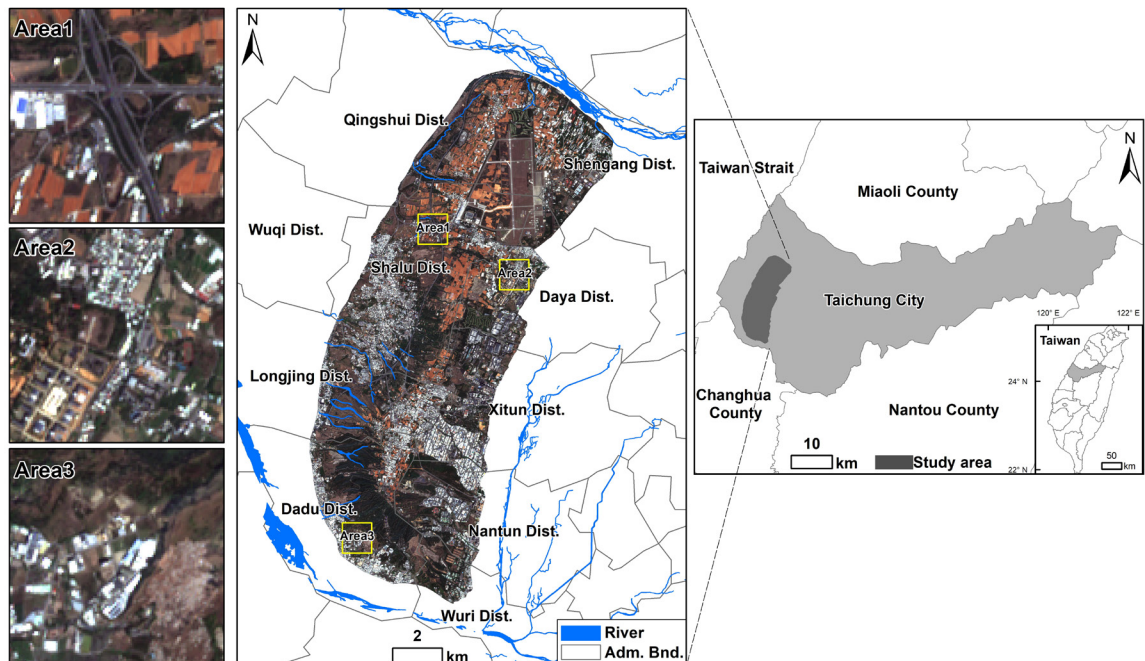


圖 1 研究區地理位置。

Fig. 1 Geographical location of the study area.

分別為 26 mm、194 mm。由於人為開發與野火干擾，目前植被組成以相思樹 (*Acacia confusa*)、大黍最為優勢 (Lin *et al.* 2022)，受乾季強烈東北季風與降水稀缺的影響，隨之大量凋萎乾枯的大黍植物體，遂成為野火重要燃料源 (Ho *et al.* 2016；張及章 2004；林等 2005)，所導致的火草循環，亦促使森林植被逐漸退化為疏林或草生地，且難以被恢復或逆轉 (Lin *et al.* 2022；邱等 2012)。

2、研究方法

(1) 遙測資料與前處理

考量研究區野火主要燃料源 (大黍) 對水分逆境敏感，其植物體於乾季呈現乾枯狀態 (Ho *et al.* 2016)，此物候特性有助於覆蓋類別的分類，故選擇乾季影像作為分析材料。所使用之 Sentinel-2B 影像自哥白尼數據空間生態系統 (<https://dataspace.copernicus.eu/>) 下載，篩選無雲或低雲覆率之清晰影像，選定的影像屬 Level-2A 處理等級的產品，即所提供之地表反射率已完成正射、大氣與地

形校正 (Gascon *et al.* 2017)，拍攝日期為 2024 年 2 月 14 日 (圖 1)。Sentinel-2 為歐洲太空總署 (European Space Agency, ESA) 發射之衛星，掃描寬度廣達 290 km，光譜資訊涵蓋可見光、近紅外、紅邊 (red-edge, 680–780 nm) 及短紅外光範圍 (443–2,190 nm)，具備 3 種空間解析力，共 13 個波段，其中除 B1、B9 與 B10 等 3 個波段為 60 m，主要供大氣校正使用，本研究不予納入分析外，其餘 B2 至 B4、B8 (10 m)，以及 B5、B6、B7、B8A 與 B11、B12 (20 m) 等 10 個波段影像均用於後續分類使用 (表 1)，同時透過 ESA 專為 Sentinel 系列影像所開發的免費軟體 SNAP (Sentinel Application Platform)，以最近相鄰法 (nearest neighbor) 進行像元重取樣，將前述 10 個波段影像之空間解析力統一為 10 m。此方法不僅簡單快速，且能完全保留原始像元訊息 (Parker *et al.* 1983)，有利確保數據的完整性與分析的一致性。

(2) 特徵擷取

所使用的特徵數據包含基於光譜

表 1 本研究所使用 Sentinel-2 多光譜影像波段參數

Table 1 The parameters of the Sentinel-2 spectral bands used in this study

Spectral bands	Central wavelength (nm)	Spatial resolution (m)
Blue (B2)	490	10
Green (B3)	560	10
Red (B4)	665	10
Vegetation Red Edge 1 (B5)	705	20
Vegetation Red Edge 2 (B6)	740	20
Vegetation Red Edge 3 (B7)	783	20
Near InfraRed (B8)	842	20
Narrow Near InfraRed (B8A)	865	20
Short Wave InfraRed (B11)	1610	20
Short Wave InfraRed (B12)	2190	20

所推導之植生指標，以及 GLCM 紋理指標兩類，均於 SNAP 9.0 平台進行運算。植生指標為兩個或兩個以上的波段的數學組合，演算容易且具穩健性，常應用於植被監測與生物物理參數的反演，對產製土地覆蓋圖資而言，具明確指示作用 (Mansourmoghad *et al.* 2022)，其中常態化差異植生指標 (normalized difference vegetation index, NDVI) 與植被生物量密切相關 (Ricotta *et al.* 1999)，應用最屬廣泛；土壤調整植生指標 (soil adjusted vegetation index, SAVI) 與增揚植生指標 (enhanced vegetation index, EVI)

則是納入土壤調整因子或大氣阻力因子，降低土壤背景或大氣條件對植被訊號的干擾，同時提升植被偵測的敏感度，兩者皆為常見的植生指標 (Huete *et al.* 2014)；紅邊對偵測植被葉綠素含量靈敏 (Horler *et al.* 1983)，亦為 S2 影像提供的光譜優勢，有助土地利用分類 (Pradhan *et al.* 2021)，故同步計算常態化差異紅邊指標 (normalized difference red edge index, NDRE)；再者，考量研究區在乾季存在大量乾枯或老化生物量，併同計算植物老化反射指標 (plant senescence reflectance index, PSRI)、

乾枯燃料指標 (dead fuel index, DFI) 與常態化差異水分指標 (normalized difference water index, NDWI) 等指標 (Cao *et al.* 2010; Gao 1996; Merzlyak *et al.* 1999)，用以反應植被水勢或乾燥植被的覆蓋狀態；此外，研究區在乾季適值休耕期，存在大面積裸露表土，使用裸土指標 (bare soil index, BSI) 可有效突顯其特徵 (Abida *et al.* 2022)，上述 8 項根據不同波段光譜反射率所衍生的植生指標計有 8 項，其演算公式如表 2。

除植生指標外，紋理特徵亦有助於提升分類準確度 (Hall-Beyer 2017;

Iqbal *et al.* 2021)，尤其在區分光譜反應特徵相似，但空間排列型態不同的植被類型時，效果尤為顯著 (Kupidura 2019)。首先，將 S2 的 10 個原始波段導入 SNAP 9.0 平台的紋理分析模組，基於 Haralick *et al.* (1973) 所提出的 GLCM 進行紋理特徵的擷取。所有參數是參考過去文獻 (Mohammadpour *et al.* 2022; Tavares *et al.* 2019) 進行設定，過程採用概率量化器，量化級別設為 32，視窗大小為 5×5 ，像元位移量為 1，在所有方向上，建構 GLCM $P(i, j | d, \theta)$ ，即計算影像中灰階級 i (參考像元) 與

表 2 本研究使用之植生指標

Table 2 Vegetation indices used in this study

Index	Abbreviation	Formula and S2 bands used	Reference
Normalized difference vegetation index	NDVI	$\frac{B_8 - B_4}{B_8 + B_4}$	Rouse <i>et al.</i> (1974)
Soil adjusted vegetation index	SAVI	$\frac{B_8 - B_4}{B_8 + B_4 + 0.5} \times 1.5$	Huete (1988)
Enhanced vegetation index	EVI	$\frac{B_8 - B_4}{B_8 + (6 \times B_4) - (7.5 \times B_2) + 1} \times 2.5$	Huete <i>et al.</i> (1997)
Normalized difference red edge index	NDRE	$\frac{B_7 - B_6}{B_7 + B_6}$	Peng and Gitelson (2012); Munyati (2022)
Plant senescence reflectance index	PSRI	$\frac{B_4 - B_2}{B_6}$	Merzlyak <i>et al.</i> (1999)
Dead fuel index	DFI	$100 \times \left(\frac{1 - B_{12}}{B_{11}} \right) \times \frac{B_4}{B_8}$	Cao <i>et al.</i> (2010)
Normalized difference water index	NDWI	$\frac{B_{8a} - B_{11}}{B_{8a} + B_{11}}$	Gao (1996); Munyati (2022)
Bare soil index	BSI	$\frac{(B_{11} + B_4) - (B_8 + B_2)}{(B_{11} + B_4) + (B_8 + B_2)}$	Dick <i>et al.</i> (2017)

灰階級 j (鄰近像元) 出現於特定空間關係下 (d, θ) 的聯合機率，其中 d 為距離， θ 為方向 (Humeau-Heurtier 2019)，所計算特徵指標包含對比 (contrast, CON)、相異性 (dissimilarity, DIS)、同質性 (homogeneity, HOM)、熵 (entropy, ENT)、角二階距 (angular second moment, ASM)、均值 (mean, MEAN)、變異數 (variance, VAR)、相關性 (correlation, COR) 等 8 種，其中 CON、DIS、HOM 等 3 項屬對比性類群 (contrast group)，主要透過灰階對 (i 與 j) 間灰階差，進行權重縮放，可作為圖像均勻度的量測；ASM 與 ENT 則屬規律性類群 (orderliness group)，權重的賦予取決於參考像元與某特定鄰近像元共同出現頻率 (即 P_{ij})，用以評估圖像規則性或複雜性；MEAN、VAR、COR 計算方式與常見描述性統計相似，惟仍須根據 P_{ij} 進行加權，可用來表現圖像灰階分布的平均值與離散情形，以及參考像元與某特定鄰近像元的間的線性關係，有助理解圖像本身的基本紋理

特徵，3 者可歸屬於描述性統計類群 (descriptive statistics group)。以 10 個原始波段演算上述 8 項紋理指標 (表 3, Hall-Beyer 2000)，共獲得 80 張紋理特徵影像。接續將所有紋理特徵影像以主成分分析 (principal components analysis, PCA) 進行降維，並依前人研究建議 (Liu *et al.* 2018)，選定新成分影像的數量以累積解釋變異量至少達 85% 為標準，最終保留前 8 張主成分影像，其累積解釋變異量達 86.71% (附錄 1)，可供為後續土地覆蓋分類輸入變項使用。

(3) 參考資料集

基於乾季野火風險控管的目的，本研究將土地覆蓋類別區分為植被與非植被兩類 7 種 (表 4、圖 2)。植被包含木本植被、草本植被、乾燥植被、乾燥植被混生木本植被、乾燥植被混生草本植被等 5 種，在此，本研究假設所有植被型皆可作為潛在燃料來源，尤其在低植被含水量的乾燥條件下，不僅存在更高的可燃性，亦能促使野火蔓延 (張及章 2004; Kang *et al.* 2022)；非植被則涵蓋人為不

表 3 本研究使用之 GLCM 紋理指標
Table 3 GLCM texture indices used in this study

Group	Index	Abbreviation	Formula	Reference
Contrast	Contrast	CON	$\sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2$	Hall-Beyer (2000)
	Dissimilarity	DIS	$\sum_{i,j=0}^{N-1} P_{i,j} i - j $	
	Homogeneity	HOM	$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2}$	
Orderliness	Angular Second Moment	ASM	$\sum_{i,j=0}^{N-1} P_{i,j}^2$	
	Entropy	ENT	$\sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j})$	
Descriptive statistics	GLCM Mean	MEAN	$\sum_{i,j=0}^{N-1} i (P_{i,j})$	
	GLCM Variance	VAR	$\sum_{i,j=0}^{N-1} P_{i,j} (i - \mu_i)^2$	
	GLCM Correlation	COR	$\sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right]$	

$P_{i,j}$ is the probability of values i and j occurring in adjacent pixels in the original image within the window defining the neighborhood. Both i and j are the labels of the columns and rows, respectively, of the GLCM. In the GLCM COR equation, μ is the mean and σ the standard deviation, both as defined by the formula for GLCM MEAN and GLCM VAR in the table.

透水層與裸土等 2 種，相對不具備燃料源潛力。於研究區範圍內，隨機選取 2,790 個地面參考資料，以 Google Earth 高解析度影像，作為地真參考資料，盡可能選擇與分類材料拍攝日期相近之高解析力影像，透過視覺判釋，並輔以現地勘查，逐一標記每樣點土地覆蓋類別。

(4) 土地覆蓋分類

以 10 個原始波段輸入變項作為對照組，並分別添加 8 個植生指標、8 個紋理特徵影像，以及涵蓋所有 26 個特徵圖層的 4 種變項組合，採 RF 演算法進行地覆分類。RF 建構在決策樹 (decision tree) 的基礎上，它透過 bagging 隨機產生大量訓練子集，生成大量的決策樹，對未被選擇的

袋外樣本 (out-of-bag, OOB) 進行預測，基於分類問題，其最後結果是經由每棵決策樹採投票取得共識所獲得 (Breiman 2001)。鑑於 RF 演算法是一種集成大量決策樹的分類器，不僅可在相對小的數據量上，求解高度非線性的問題，亦可同時處理大量的輸入特徵，相較於其他演算法，其分類效能佳，近代廣泛應用於生態學、土地利用與覆蓋分類等研究領域 (Gislason *et al.* 2006; Cutler *et al.* 2007)。本研究使用 R 軟體套件 "randomForest" (Breiman *et al.* 2018)，其中每個節點可隨機選取用以分裂之候選特徵數 (mtry)，以及建構決策樹的棵數 (ntree) 等兩參數，參考過去研究 (Immitzer *et al.* 2016; Sothe *et al.*

表 4 土地覆蓋類別與樣本數

Table 4 Land-cover classification scheme and sample size

Land cover type	Abbreviation	Description	Samples
Woody vegetation	WV	Woody vegetation (tree or shrub cover) (> 75%), interspersed with other cover types	642
Herbaceous vegetation	HV	Covered by herbaceous vegetation, including pineapple, ginger, banana, sweet potato, rice, artificial turf, or fallow land (> 75%), interspersed with other cover types	210
Dry vegetation	DV	Covered by vegetation lacking greenery, such as dead, aging, or post-harvest crop residues.	383
Mosaic dry vegetation / woody vegetation	MDW	Predominantly dry vegetation (> 50%) with interspersed tree or shrub cover (< 50%)	300
Mosaic dry vegetation / herbaceous vegetation	MDH	Predominantly dry vegetation (> 50%) with interspersed live, green herbaceous cover (< 50%)	151
Impervious surface	IS	Various artificial surfaces, such as buildings, roads, and graveyards	866
Bare soil	BS	Winter fallow fields or landslide sites characterized by exposed soil surfaces	238

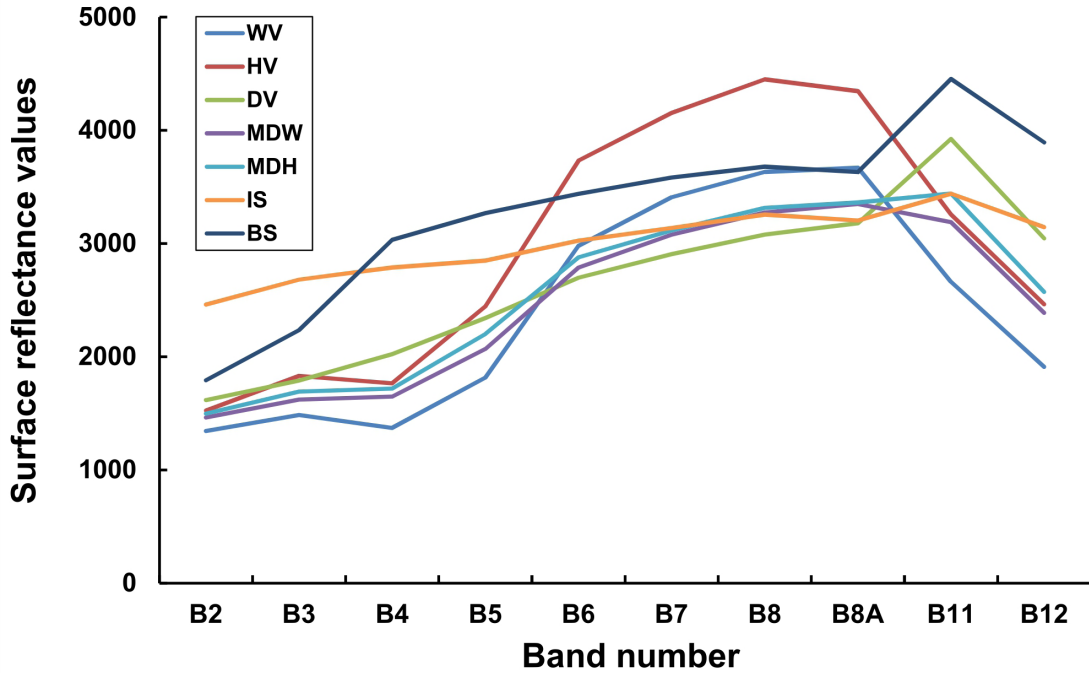


圖 2 不同土地覆蓋類別的光譜反射曲線，數據來自於 Sentinel-2 衛星影像 Level-2A 產品 12-bit 輻射解析力原始波段之地表反射率值。

Fig. 2 Spectral reflectance curve of different land cover types, derived from Sentinel-2 Level-2A product with the surface reflectance values of 12-bit radiometric resolution.

2017) 建議，採預設值設定，即 *mtry* 為輸入特徵數量的平方根、*ntree* 為 500。此外，RF 分類過程中，以 Gini 指數 (Gini index) 平均降低量，評估該特徵的重要性，當該指數降低量愈多，表示該特徵對分離類別的貢獻愈大。使用分層隨機取樣，先抽取 70% 地面參考資料 ($n = 1,953$)，作為訓練集 (training set)，用以訓練分類模型，剩餘的 30% 資料 ($n = 837$)，則

保留作為測試集 (test set)，用於後續分類模型的準確性評估。

(5) 準確度評估與差異性檢定

使用混淆矩陣 (confusion matrices) 計算總體準確度 (overall accuracy, OA) 和 Kappa 係數兩種常見指標，用以衡量整體分類效能，OA 表示圖面上隨機選擇位置，被正確分類的機率，OA 達 80% 可視為高準確度 (Teluguntla2018)；Kappa 係數則為

分類結果與真實參考資料的一致性，範圍為 0（無一致性）至 1（完全一致），Kappa 值大於 0.8 可謂高一致性（Landis and Koch 1977）。另外，生產者準確度（producer's accuracy, PA）、使用者準確度（user's accuracy, UA），以及兩者的調和平均數（harmonic mean）F1 分數（F1-score），可用以評估各類別的分類效能，其值愈高，代表分類性能愈佳（Sokolova and Lapalme 2009）。

參考 De Leeuw（2006）建議，採用 McNemar test 進行差異性檢定，用以瞭解原始波段在添加不同特徵數據後，對改變其分類效能的顯著程度，該檢定是基於卡方檢定（ χ^2 ）檢定統計量，由添加特徵數據前後的兩種分類誤差矩陣計算得出，其演算公式如下：

其中 f_{12} 表示原始波段輸入法（方法 1）分類錯誤，但添加特徵數據輸入法（方法 2）分類正確的樣本數； f_{21} 則表示方法 1 分類正確，但方法 2 分類錯誤的樣本數。

結果

在不同特徵組合下作為分類模型輸入集下，其分類後之 OA 與 Kappa 係數，以及添加光譜或紋理輔助特徵前、後準確度之差異性檢定結果（圖 3、表 5）顯示，單以原始波段作為 RF 分類輸入時，其 OA 為 87.22%、Kappa 為 0.84，整體準確度已達良好標準，然相較於其他添加輔助資料的處理而言，分類效果相對較弱。分別添加光譜特徵或紋理特徵後，其分類結果之 OA、Kappa 均可獲得提升，並達顯著差異（ $p \leq 0.05$ ）。將原始波段、光譜特徵與紋理特徵全數作為輸入時，可獲得最佳分類效果，並達差異極顯著水準（ $p \leq 0.001$ ），其 OA 與 Kappa，分別達到 90.56%、0.88，相較於無添加輔助特徵前，約可提升 3.35%、0.04。總結來說，S2 原始波段對研究區土地覆蓋類別分類已具相當潛力，無論添加光譜或紋理特徵，均有助於分類準確度的提升，兩類特徵合併使用，可獲得最佳的效果。

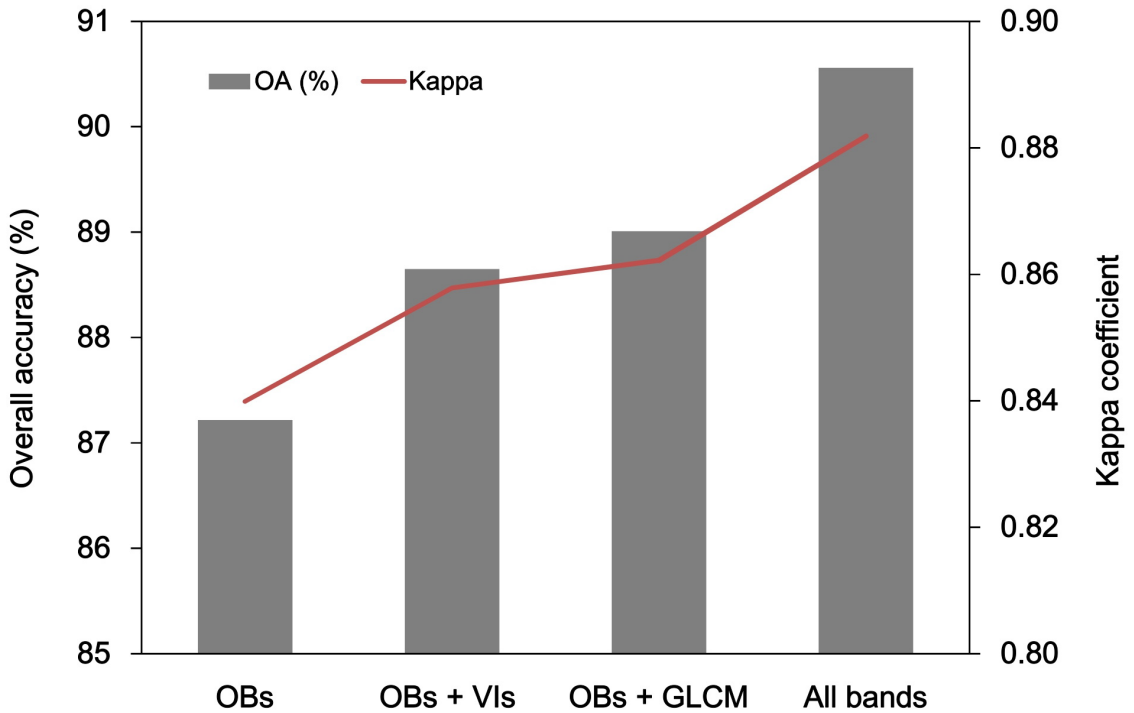


圖 3 不同特徵輸入組合下隨機森林分類結果的總體準確度與 kappa 係數。
 Fig. 3 Comparisons of overall accuracy and Kappa coefficient derived from RF in different feature sets.

表 5 添加不同類別特徵前後之 McNemar’s 差異性檢定

Table 5 McNemar’s test for comparing the differences between OBs and additional features

Input dataset	f_{11}	f_{12}	f_{21}	f_{22}	Total	Chi-square (χ^2)	P value
OBs vs. OBs + VIs	86	21	9	721	837	4.033	0.045
OBs vs. OBs + GLCMs	78	29	14	716	837	4.558	0.033
OBs vs. All bands	73	34	6	724	837	18.225	<0.001

f_{11} denotes the number of cases with wrong classifications in both maps: classifier 1 (original bands, OBs) and classifier 2 (inclusion of feature, IoF).

f_{12} represents the number of cases that are wrongly classified by OBs but correctly classified by IoF.

f_{21} indicates the number of cases that are correctly classified by OBs but wrongly classified by IoF.

f_{22} denotes the number of cases with correct classifications in both the OBs and IOF maps.

在不同特徵的輸入組合下，其 Gini 指數平均降低量排序結果如圖 4 所示。圖 4 顯示在無添加特徵的情況下，以可見光（B2、B3、B4）波段最屬重要，短紅外光波段（B11、B12）次之（圖 4a），且不論額外添加光譜或紋理特徵，抑或合併使用，B2（B）、B4（R）波段皆是 RF 分類過程相對重要的特徵變項。以額外添加光譜特徵來看，NDVI、SAVI 與 PSRI 等 3 項特徵，對增強類別分離度較為有效（圖 4b）；而紋理特徵部分，則以 PC3 貢獻度最高，其次為 PC1，其餘成分相重要性相對較低（圖 4c）；在所有特徵皆作為輸入的情況下，亦有類似的結果，整體而言光譜特徵的重要性優於紋理特徵（圖 4d）。總結來看，可見光範圍波段，尤其是 B2 與 B4 波段是執行研究區土地覆蓋分類不可或缺的輸入變項，在額外特徵的添加上，可優先選擇突顯綠色植被的 NDVI、SAVI，以及可突顯乾燥或老化植被的 PSRI 等光譜特徵，若需進一步添加紋理特徵，則可嘗試搭配 COR 特徵，即 PC3 的主要負荷變項

（附錄 1），儘管紋理特徵在輔助資料的添加處理中的表現多敬陪末座，然紋理特徵的添加，對提升分類準確度而言，仍具顯著效果。

不同特徵輸入組合下，各類別分類準確度與混淆矩陣結果，如表 6-9 所示。當僅使用 S2 原始波段作為輸入時（表 6），WV 與 IS 兩類型最容易判別，所有類別準確度指標均達 90% 以上，而 MDH、HV、MDW 等 3 類則效果較差，F1 分數均未達 80。具體而言，MDH 與 HV 的 PA 稍低，有較多測試樣本被錯誤歸類，MDH 錯誤歸類多集中於 MDW，HV 則是分散在各類別中。同樣的，MDW 也有相對多的樣本，被錯誤歸類為 MDH，導致 MDH 具有較低的 UA，顯示該 3 類別的混淆是造成分類誤差的主要原因。在添加光譜特徵的處理下，上述 3 類別，僅有 MDH 可獲得較顯著的改善，另可發現 DV、IS、BS 等高同質性類型，亦在此處理中獲得進一步的提升。添加紋理特徵後，幾乎可提升所有類別之分離度，尤其 HV、MDW、MDH 等 3 高異質類別，格

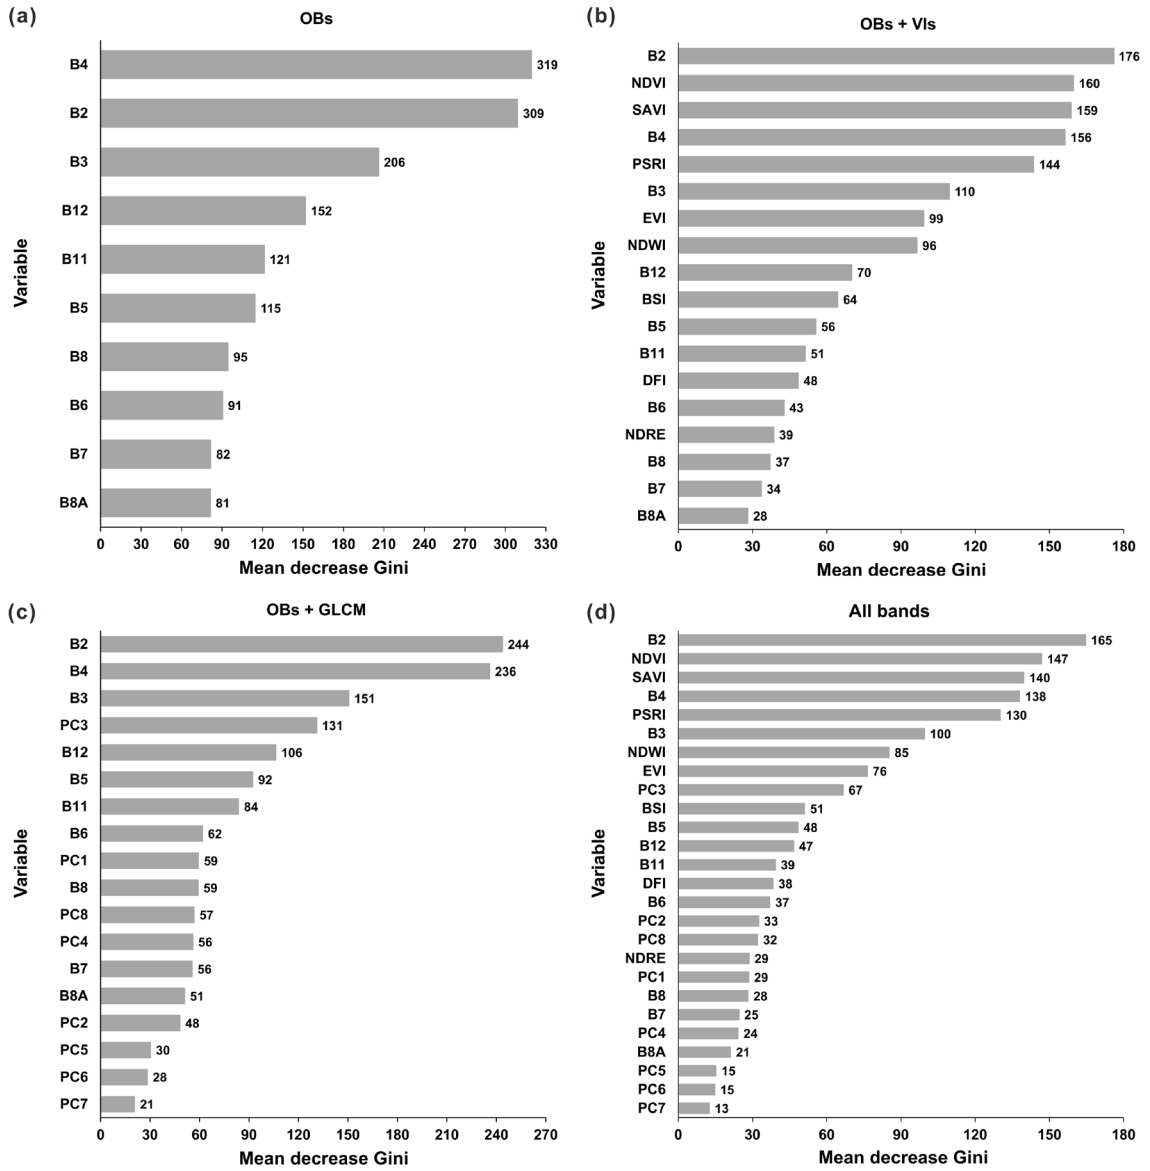


圖 4 不同特徵輸入組合下 Gini 平均降低量。(a) 原始波段；(b) 原始波段添加 VIs 光譜特徵；(c) 原始波段添加 GLCM 紋理特徵；(d) 所有特徵變項。

Fig. 4 The decreased mean of Gini in different feature sets. (a) OBs; (b) OBs + VIs; (c) OBs + GLCM, and (d) all bands.

外受惠於紋理特徵的添加。將原始波段、光譜特徵與紋理特徵全數作為輸入時，各類別 F1 分數皆可獲得不同程度的改善（0.64–11.06%）。在全區尺度下，不同特徵組合的分類結果在空間分布型態上呈現高度一致（附錄 2），各地表覆蓋類型的面積分配亦大致相近（圖 5），前三大組成類別為 IS（34.47–36.34%）、WV（21.64–22.33%）、DV（14.56–15.51%）。然而，進一步針對異質性較高的三個區域進行放大檢視（圖 6）後，仍可觀察到不同特徵組合對局部細節的影

響，特別是在植被與非植被鑲嵌而成的破碎化地景下，添加特徵有助改善椒鹽效應（salt and pepper effect），其中考量鄰域像元空間關係的紋理特徵效果略佳，不僅提升空間連續性，亦降低細碎雜訊。S2 原始波段雖對於研究區土地覆蓋分類已展現出潛力，但在高異質性或高變異性植被類別上，其準確度仍顯不足，無論添加光譜或紋理特徵，均有助於分類準確度的提升，且兩類特徵對不同特定類別準確度的提升具互補性，合併使用可獲得最佳的效果。

表 6 使用原始波段作為輸入之分類結果混淆矩陣

Table 6 Confusion matrix of the classification results with original bands

Land cover type	Classified data (OBs classifier)							
	WV	HV	DV	MDW	MDH	IS	BS	Row total
WV	185	3	2	2	0	1	0	193
HV	7	44	1	3	2	6	0	63
DV	1	2	105	3	2	1	1	115
MDW	8	2	1	72	4	3	0	90
MDH	1	4	4	15	20	1	0	45
IS	0	0	8	1	0	246	5	260
BS	0	0	1	0	0	12	58	71
Column total	202	55	122	96	28	270	64	837
PA (%)	95.85	69.84	91.30	80.00	44.44	94.62	81.69	
UA (%)	91.58	80.00	86.07	75.00	71.43	91.11	90.63	
F1 score	93.67	74.58	88.61	77.42	54.79	92.83	85.93	

表 7 使用原始波段添加光譜特徵作為輸入之分類結果混淆矩陣

Table 7 Confusion matrix of the classification results with OBs and additional spectral features

Land cover type		Classified data (OBs + VIs classifier)							Row total
		WV	HV	DV	MDW	MDH	IS	BS	
Reference data	WV	184	3	2	4	0	0	0	193
	HV	7	42	1	2	5	6	0	63
	DV	0	1	109	2	1	1	1	115
	MDW	10	3	1	68	5	3	0	90
	MDH	1	3	3	12	26	0	0	45
	IS	0	0	4	0	0	253	3	260
	BS	0	0	0	1	0	10	60	71
	Column total	202	52	120	89	37	273	64	837
PA (%)		95.34	66.67	94.78	75.56	57.78	97.31	84.51	
UA (%)		91.09	80.77	90.83	76.4	70.27	92.67	93.75	
F1 score		93.16	73.04	92.77	75.98	63.41	94.93	88.89	

表 8 使用原始波段添加 GLCM 紋理特徵作為輸入之分類結果混淆矩陣

Table 8 Confusion matrix of the classification results with OBs and additional GLCM texture features

Land cover type		Classified data (OBs + GLCM classifier)							Row total
		WV	HV	DV	MDW	MDH	IS	BS	
Reference data	WV	184	3	2	3	0	1	0	193
	HV	5	46	1	4	1	6	0	63
	DV	2	1	105	1	4	1	1	115
	MDW	8	4	1	76	0	1	0	90
	MDH	1	4	5	10	24	1	0	45
	IS	0	0	5	0	0	253	2	260
	BS	0	0	0	0	1	13	57	71
	Column total	200	58	119	94	30	276	60	837
PA (%)		95.34	73.02	91.30	84.44	53.33	97.31	80.28	
UA (%)		92.00	79.31	88.24	80.85	80.00	91.67	95.00	
F1 score		93.64	76.03	89.74	82.61	64.00	94.40	87.02	

表 9 使用所有特徵數據作為輸入之分類結果混淆矩陣

Table 9 Confusion matrix of the classification results using all bands

Land cover type		Classified data (All bands classifier)							Row total
		WV	HV	DV	MDW	MDH	IS	BS	
Reference data	WV	186	3	2	2	0	0	0	193
	HV	5	44	1	2	5	6	0	63
	DV	0	1	110	2	1	0	1	115
	MDW	5	3	0	76	3	3	0	90
	MDH	2	3	3	10	27	0	0	45
	IS	0	0	2	0	0	255	3	260
	BS	0	0	0	0	1	10	60	71
	Column total	198	54	118	92	37	274	64	837
PA (%)		96.37	69.84	95.65	84.44	60.00	98.08	84.51	
UA (%)		93.94	81.48	93.22	82.61	72.97	93.07	93.75	
F1 score		95.14	75.21	94.42	83.52	65.85	95.51	88.89	

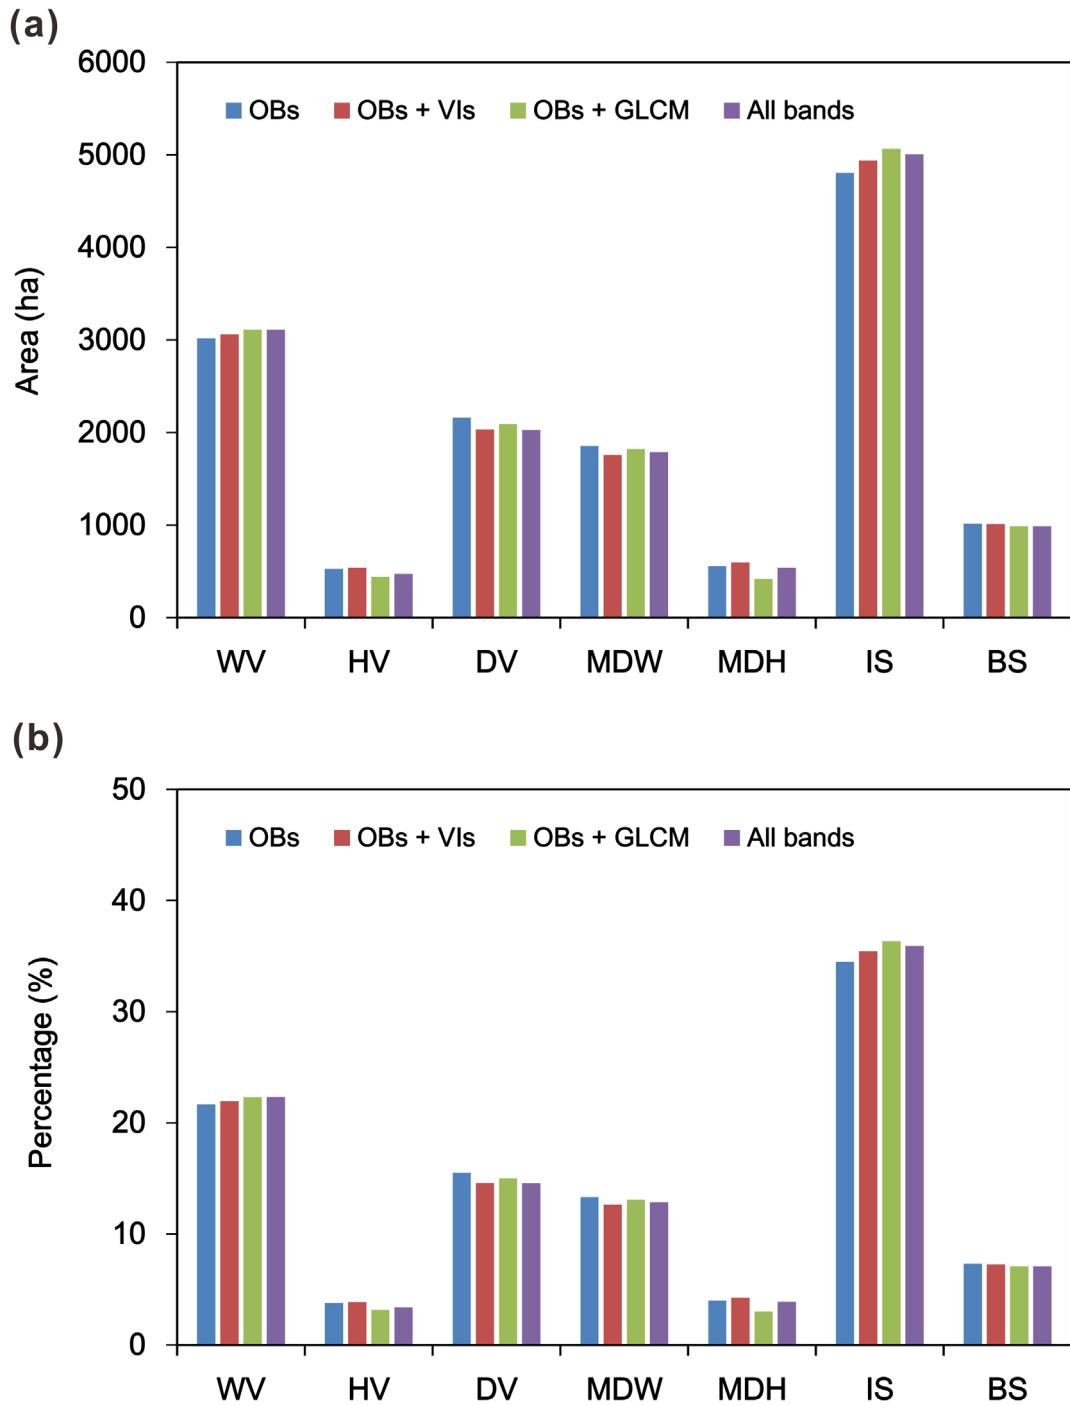


圖 5 不同特徵組合下土地覆蓋分類結果的比較。(a) 面積；(b) 於研究區域的占比。

Fig. 5 Comparison of land cover classifications using different feature sets in terms of (a) total area and (b) percentage of the entire study area.




圖 6 不同特徵組合下三個複雜區域土地覆蓋分類結果的放大檢視。(a) Sentinel-2 RGB 影像；(b) 原始波段；(c) 原始波段添加 VIs 光譜特徵；(d) 原始波段添加 GLCM 紋理特徵；(e) 所有特徵變項。

Fig.6 Detailed classification results of different feature sets in three complex areas. (a) RGB Sentinel-2 image, (b) OBs, (c) OBs + Vis, (d) OBs + GLCM, and (e) all bands.

討論

在不額外添加輔助資料的情況下，以 S2 原始波段作為輸入，已能達到良好的分類效果，其分類潛力可在過去研究獲得證實（Saini and Ghosh 2018b; Macintyre *et al.* 2020），分類層級甚至可達樹種或作物別（Persson *et al.* 2018; Saini and Ghosh 2018a）。然而，本研究中的 MDW、MDH、HV 等類別，原始波段並未能將其有效分離，檢視其光譜反射特徵（圖 2），推論其原因在於這些類別本質上屬於高異質性的混淆型植被，或類別內存在高變異性的農作植被。具體而言，MDW 與 MDH 具有相似的光譜特徵，而 HV 類別內組成多樣且生長階段差異大，易與其他類別間發生光譜特徵重疊，致使分類結果產生混淆（Rodriguez-Galiano and Chica-Olmo 2012）。又地景中存在高比例的不透水層或土壤背景，也可能削弱植被對光譜的反應（Huete 1988; Skougaard *et al.* 2015）。此外，歸納分類效果較差類別之空間特徵為一、區塊細小而破碎，與其他類別高度交錯鑲嵌；二、

多分布在人為與自然地景的過渡或邊緣區域，此種空間特徵，或許基於中解析力影像進行分類，本質上就較為困難。上述因素皆可能導致這 3 種類型在特徵空間中難以有效分離，即便添加能突顯地覆差異的植生指標，其分離度仍無法達到理想狀態。此種情況下，紋理特徵似乎有助於提升其分離度，此可歸因於紋理特徵在於提供同譜異物的空間資訊，反映了與周邊鄰近像元的關聯性，與光譜特徵僅基於像元光譜反射率的組合有所不同。Ma *et al.* (2021) 的研究結果也提到，添加光譜特徵可進一步區分木本與非木本植被，但對於相近植被型別的辨別仍有困難。相對地，添加紋理特徵可捕捉因灰階空間關聯所引起的局部差異，進而有助增強植被型別間的分離度，足見兩類特徵對不同類別的分離度各具貢獻，具有互補性，亦有文獻（Wikantika *et al.* 2004; Chairat *et al.* 2019）指出，兩類特徵的結合將為分類結果提供最佳準確度，這種多源數據產生的協同效應（synergistic effects），有助於建構更穩健且可靠的

分類模型 (Bazzo *et al.* 2024)。此外，本研究是以 DV 作為關鍵的潛在燃料源的假設下，將其視為優先關注的主要類別，而 MDW、MDH 作為 DV 與其他地覆的混淆植被，不可否認地存在某種程度的潛在風險，建議未來在應用分類結果時，進一步輔以高解析度影像或現地勘查，進行分類結果的編修，提升分類圖資的應用價值。

B2、B4、NDVI、SAVI、PSRI 為大肚臺地地覆分類最重要的波段或光譜特徵。Immitzer *et al.* (2016) 同樣發現 B2、B4 兩道可見光波段為樹種分類研究中最佳預測變項，而最廣為人知的 NDVI，已在多項複雜地覆分類研究中 (Jin *et al.* 2018; Somayajula *et al.* 2020) 確認以其作為分類變項的可行性與重要性。一般而言，自然或半自然地景為涵蓋植被與土壤背景的混合像元，不論植被密度如何，植被光譜即難以避免受到土壤亮度的干擾 (Huete *et al.* 1985)，本研究所使用的 S2 影像取自乾季，多數旱作地處於土壤裸露的休耕狀態，SAVI 針對土壤條件進行調整 (Huete 1988)，

可能對區內土壤背景的影響提供了有效的改進。值得注意的是，紅邊作為 S2 的優勢波段，並在森林植被或作物類別的分類研究中表現突出 (Immitzer *et al.* 2016; Persson *et al.* 2018; Wakulińska *et al.* 2020)，但在本研究結果中，除 PSRI 指標涉及 RE1 外，其餘重要相對較低，推測與本研究僅就單期的乾季影像進行分類有關，而紅邊可能更適用於多時序的植被物候監測 (Persson *et al.* 2018; Zhang *et al.* 2020; Yu *et al.* 2022)。在紋理特徵方面，PC1 與可見光的 ENT 與 DIS 特徵高度相關，主要反映局部區域的邊緣紋理資訊，該成分雖解釋最多的總變異量，但其涵蓋資訊可能更多是反映地景整體的紋理結構，而非特定地覆類別的區分特徵。相對的，PC3 主要與紅邊和近紅外光波段的 COR 特徵相關，反映局部區域中灰度值的線性關係或相似程度，這種內部紋理特徵對於區分光譜相似，但空間結構不同的類別 (如 MDW 與 MDH) 可能別具意義，此與 Kupidura (2019) 與 Mohammadpour *et al.* (2022) 的研究結果

一致，Hall-Beyer (2017) 檢測紋理指標在不同地景與尺度下的關連性的研究中亦指出，當需考慮邊緣特徵的情況下，COR 可作為 MEAN 的替代指標，用以進行基本紋理的度量，同時強調該指標對區塊 (patch) 內部特徵的解釋有關，有助於區別不同的目標類別。最後，由 Gini 平均降低量顯示 (圖 4)，紋理特徵雖非 RF 分類過程的重要變項，然其特徵納入與否，確實可對分類性能構成影響，這些單獨來看預測能力稍弱的紋理特徵，可能透過與其他特徵的協同作用發揮其影響力，進而獲得較佳的分類效果，只是目前尚難由 RF 的變項重要性評估，來解釋或確認此種效應 (Chen and Ishwaran 2012; Bazzo *et al.* 2024)。

儘管許多研究 (Adeli *et al.* 2022; Mohammadpour *et al.* 2022) 強調了紋理特徵對於改進地覆分類效能的重要性，但亦有研究 (Hurskainen *et al.* 2019) 持相反意見，指出紋理特徵在某些情境下無法顯著提升分類性能，甚至認為紋理特徵判別地覆類別的能力不如光譜特徵 (Lu *et al.* 2014)。

這種分歧可能源於感測器來源、地景特徵的差異，以及測量尺度和輸入特徵組合等複雜因素，使得對於最佳分類特徵的確認，極具挑戰且不具通用性 (Lu *et al.* 2014)。考慮到 GLCM 在捕捉多尺度紋理資訊方面的能力有限 (De Siqueira *et al.* 2013)，或許藉由多尺度 (視窗大小) 紋理特徵的比較，可獲得最佳分析尺度。然而，這一過程通常耗時費力，本研究在紋理特徵的運算上，僅先參考過去同樣使用 S2 作為材料的研究，進行空間參數設定，並未進行最佳尺度測試，這對掌握不同尺度下紋理特徵對分類性能影響，可能存在一定程度的侷限，未來的研究可考慮納入更廣泛的輔助資料集，並進行多尺度分析，以更深入探討紋理特徵在地覆分類的應用潛力和適用性。

最後，由於本研究所用的材料、年代、分類目的、方法及目標類別均存在差異，無法與其他同為大肚臺地土地利用或覆蓋的相關研究逕行比較。儘管如此，本研究基於衛星影像的尺度，在類別層級上尋求提升分類

準確度的策略，除對分類輔助資料的添加提供建議外，也為該地更新了有效的地覆資訊。事實上，大肚臺地多數野火與大黍物候習性及人為因素有關（莊及曾 2021），藉由精準的地覆資訊，強化對關鍵地覆類型的關注，應有助於野火風險控管，特別是不透水層與乾燥植被之間的空間關係，這些荒地與都市交界區（Wildland-Urban Interface），往往是野火問題最顯著的地方（Radeloff *et al.* 2018; Guo *et al.* 2024）。同時，理解高易燃性地覆類型的空間分布，有助推敲野火蔓延的潛在途徑（Gray and Dickson 2016; Buchholtz *et al.* 2023），以利未來燃料管理優先性與防火線佈局的規劃。

結論

本研究以 S2 原始波段作為地覆分類模型的基礎輸入變項，並嘗試額外添加光譜與紋理輔助特徵，以 RF 進行大肚臺地土地覆蓋分類，以評估與比較不同特徵組合在提升分類準確度方面的效能。根據研究結果，提出以下結論：一、就總體準確度來看，

單獨使用 S2 原始波段作為分類輸入已可獲得良好的分類效果，但相比添加輔助特徵的結果，其效能較差；二、高異質性類別是大肚臺地土地覆蓋分類中的主要誤差來源。光譜特徵在辨識高同質性類別時表現較佳；而在提升高異質性類別的分離度方面，紋理特徵則更具關鍵作用。總結而言，光譜與紋理特徵各自對不同類型的土地覆蓋具顯著貢獻，且彼此具有互補性。整合光譜與紋理特徵作為分類輔助特徵，可達到最佳分類效果。最後，本研究建議，當分類區域屬於高異質性地景，且光譜數據未能達到分類需求時，除了使用常見的光譜特徵外，應考慮額外添加紋理特徵作為輔助，以進一步提升分類準確度。

引用文獻

林朝欽、邱祈榮、陳明義、蕭其文、曾仁鍵。2005。大肚山地區林火危險預測模式之推導。中華林學季刊 38: 83–94。

邱祈榮、薛怡珍、劉宇安、賴彥任。2012。台中大肚山台地土地利

- 用及地覆變化趨勢之分析。都市與計劃 39: 25–50。
- 張集豪、章錦瑜。2004。大肚山地區火燒與植被關係之研究。林業研究季刊 26: 1–10。
- 莊智璋、曾俊偉。2021。大肚山台地野火潛勢區位建置評估。水土保持學報 51: 2725–2710。
- 嚴烽彰。2012。邊緣特性對景觀變遷影響之研究 - 以台中大肚山為例。中國文化大學環境設計學院景觀學系碩士論文。
- Abida, K., M. Barbouchi, K. Boudabous, W. Toukabri, K. Saad, H. Bousnina and T. S. Chahed. 2022. Sentinel-2 data for land use mapping: Comparing different supervised classifications in semi-arid areas. Agriculture 12: 1429.
- Adeli, S., L. J. Quackenbush, B. Salehi and M. Mahdianpari. 2022. The importance of seasonal textural features for object-based classification of wetlands: New York state case study. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 43: 471–477.
- Bazzo, C. O. G., B. Kamali, M. dos Santos Vianna, D. Behrend, H. Hueging, I. Schleip, P. Mosebach, A. Haub, A. Behrendt and T. Gaiser. 2024. Integration of UAV-sensed features using machine learning methods to assess species richness in wet grassland ecosystems. Ecological Informatics 83: 102813.
- Breiman, L. 2001. Random forests. Machine learning 45: 5–32.
- Breiman, L., A. Cutler, A. Liaw and M. Wiener. 2018. Package ‘randomforest’. University of California, Berkeley: Berkeley, CA, USA.
- Brendel, A. S., F. Ferrelli, M. C. Piccolo and G. M. Perillo. 2019. Assessment of the effectiveness of supervised and unsupervised

- methods: maximizing land-cover classification accuracy with spectral indices data. *Journal of Applied Remote Sensing* 13: 014503.
- Buchholtz, E. K., J. Heinrichs and M. Crist. 2023. Landscape and connectivity metrics as a spatial tool to support invasive annual grass management decisions. *Biological Invasions* 25: 637–644.
- Cao, X., J. Chen, B. Matsushita and H. Imura. 2010. Developing a MODIS-based index to discriminate dead fuel from photosynthetic vegetation and soil background in the Asian steppe area. *International Journal of Remote Sensing* 31: 1589–1604.
- Chairet, R., Y. B. Salem and M. Aoun. 2019. Features extraction and land cover classification using Sentinel 2 data. pp. 497–500. *In*: 2019 19th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA), IEEE, Sousse, Tunisia.
- Chen, X. and H. Ishwaran. 2012. Random forests for genomic data analysis. *Genomics* 99: 323–329.
- Cutler, D. R., T. C. Edwards Jr, K. H. Beard, A. Cutler, K. T. Hess, J. Gibson and J. J. Lawler. 2007. Random forests for classification in ecology. *Ecology* 88: 2783–2792.
- De Leeuw, J., H. Jia, L. Yang, X. Liu, K. Schmidt and A. K. Skidmore. 2006. Comparing accuracy assessments to infer superiority of image classification methods. *International Journal of Remote Sensing* 27: 223–232.
- De Siqueira, F. R., W. R. Schwartz and H. Pedrini. 2013. Multi-scale gray level co-occurrence matrices for texture description. *Neurocomputing* 120: 336–345.
- Diek, S., F. Fornallaz, M. E. Schaepman

- and R. De Jong. 2017. Barest pixel composite for agricultural areas using landsat time series. *Remote Sensing* 9: 1245.
- Foody, G. M. 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment* 80: 185–201.
- Gambarova, Y. M., A. Y. Gambarov, R. B. Rustamov and M. H. Zeynalova. 2010. Remote sensing and GIS as an advance space technologies for rare vegetation monitoring in Gobustan State National Park, Azerbaijan. *Journal of Geographic Information System* 2: 93.
- Gao, B. C. 1996. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment* 58: 257–266.
- Gascon, F., C. Bouzinac, O. Thépaut, M. Jung, B. Francesconi, J. Louis, V. Lonjou, B. Lafrance, A. Gaudel-Vacaresse, F. Languille, B. Alhammoud, F. Viallefont, B. Pflug, J. Bieniarz, S. Clerc, L. Pessiot, T. Trémas, E. Cadau, R. De Bonis, C. Isola, P. Martimort and V. Fernandez. 2017. Copernicus Sentinel-2A calibration and products validation status. *Remote Sensing* 9: 584.
- Gislason, P. O., J. A. Benediktsson and J. R. Sveinsson. 2006. Random forests for land cover classification. *Pattern Recognition Letters* 27: 294–300.
- Gray, M. E. and B. G. Dickson. 2016. Applying fire connectivity and centrality measures to mitigate the cheatgrass-fire cycle in the arid West, USA. *Landscape Ecology* 31: 1681–1696.
- Guo, Y., J. Wang, Y. Ge and C. Zhou. 2024. Global expansion of wildland-urban interface intensifies human exposure to wildfire risk in the 21st century. *Science Ad-*

- vances 10: eado9587.
- Hall-Beyer, M. 2000. GLCM texture: A tutorial v.3.0. University of Calgary, Calgary Alberta.
- Hall-Beyer, M. 2017. Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales. *International Journal of Remote Sensing* 38: 1312–1338.
- Haralick, R. M., K. Shanmugam and I. H. Dinstein. 1973. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics* 6: 610–621.
- Ho, C. Y., M. Y. Tsai, Y. L. Huang and W. Y. Kao. 2016. Ecophysiological factors contributing to the invasion of *Panicum maximum* into native *Miscanthus sinensis* grassland in Taiwan. *Weed Research* 56: 69–77.
- Horler, D. N. H., M. Dockray and J. Barber. 1983. The red edge of plant leaf reflectance. *International Journal of Remote Sensing* 4: 273–288.
- Huete, A. R. 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment* 25: 295–309.
- Huete, A. R., H. Q. Liu, K. V. Batchily and W. J. D. A. Van Leeuwen. 1997. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment* 59: 440–451.
- Huete, A. R., R. D. Jackson and D. F. Post. 1985. Spectral response of a plant canopy with different soil backgrounds. *Remote Sensing of Environment* 17: 37–53.
- Huete, A., T. Miura, H. Yoshioka, P. Ratana and M. Broich. 2014. Indices of vegetation activity. pp.1–41. *In*: J. M. Hanes (ed.). *Biophysical Applications of Satellite Remote Sensing*, Spring,

New York.

- Humeau-Heurtier, A. 2019. Texture feature extraction methods: A survey. *IEEE Access* 7: 8975–9000.
- Hurskainen, P., H. Adhikari, M. Siljander, P. K. E. Pellikka and A. Hemp. 2019. Auxiliary datasets improve accuracy of object-based land use/land cover classification in heterogeneous savanna landscapes. *Remote Sensing of Environment* 233: 111354.
- Immitzer, M., F. Vuolo and C. Atzberger. 2016. First experience with Sentinel-2 data for crop and tree species classifications in central Europe. *Remote Sensing* 8: 166.
- Iqbal, N., R. Mumtaz, U. Shafi and S. M. H. Zaidi. 2021. Gray level co-occurrence matrix (GLCM) texture based crop classification using low altitude remote sensing platforms. *PeerJ Computer Science* 7: e536.
- Jin, Y., X. Liu, Y. Chen and X. Liang. 2018. Land-cover mapping using Random Forest classification and incorporating NDVI time-series and texture: A case study of central Shandong. *International Journal of Remote Sensing* 39: 8703–8723.
- Jozdani, S. E., B. A. Johnson and D. Chen. 2019. Comparing deep neural networks, ensemble classifiers, and support vector machine algorithms for object-based urban land use/land cover classification. *Remote Sensing* 11: 1713.
- Kabir, S., D. C. He, M. A. Sanusi and W. M. A.W. Hussina. 2010. Texture analysis of IKONOS satellite imagery for urban land use and land cover classification. *The Imaging Science Journal* 58:163–170.
- Kang, Z., X. Quan and G. Lai. 2022. Assessing the effects of fuel moisture content on the 2018 Mega-

- fires in California. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 16: 868–877.
- Kavzoglu, T. 2009. Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling & Software* 24: 850–858.
- Kavzoglu, T. and F. Bilucan. 2023. Effects of auxiliary and ancillary data on LULC classification in a heterogeneous environment using optimized random forest algorithm. *Earth Science Informatics* 16: 415–435.
- Kupidura, P. 2019. The comparison of different methods of texture analysis for their efficacy for land use classification in satellite imagery. *Remote Sensing* 11: 1233.
- Landis, J. R. and G. G. Koch. 1977. The measurement of observer agreement for categorical data. *Biometrics* 33: 159–174.
- Lin, C. Y., M. C. Liao, W. Wang and H. Y. Tzeng. 2022. Composition characteristics of an urban forest soil seed bank and its influence on vegetation restoration: A case study in Dadu Terrace, central Taiwan. *Sustainability* 14: 4178.
- Liu, Y., J. Zhang, S. Wang, Y. Wang and A. Zhao. 2018. Assessment of environmental carrying capacity using principal component analysis. *Journal of Geoscience and Environment Protection* 6: 54–65.
- Lu, D. and Q. Weng. 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing* 28: 823–870.
- Lu, D., G. Li, E. Moran, L. Dutra and M. Batistella. 2014. The roles of textural images in improving land-cover classification in the

- Brazilian Amazon. *International Journal of Remote Sensing* 35: 8188–8207.
- Lv, Z. Y., P. Zhang, J. A. Benediktsson and W. Z. Shi. 2014. Morphological profiles based on differently shaped structuring elements for classification of images with very high spatial resolution. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7: 4644–4652.
- Ma, M., J. Liu, M. Liu, J. Zeng and Y. Li. 2021. Tree species classification based on Sentinel-2 imagery and random forest classifier in the eastern regions of the Qilian mountains. *Forests* 12: 1736.
- Macintyre, P., A. Van Niekerk and L. Mucina. 2020. Efficacy of multi-season Sentinel-2 imagery for compositional vegetation classification. *International Journal of Applied Earth Observation and Geoinformation* 85: 101980.
- Mansourmoghad, M., I. Rousta and H. R. Ghafarian Malamiri. 2022. Evaluation of the classification accuracy of NDVI index in the preparation of land cover map. *Desert* 27: 329–341.
- Merzlyak, M. N., A. A. Gitelson, O. B. Chivkunova and V. Y. Rakitin. 1999. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia Plantarum* 106: 135–141.
- Mohammadpour, P., D. X. Viegas and C. Viegas. 2022. Vegetation mapping with random forest using Sentinel 2 and GLCM texture feature—A case study for Lousã region, Portugal. *Remote Sensing* 14: 4585.
- Munyati, C. 2022. Detecting the distribution of grass aboveground biomass on a rangeland using Sentinel-2 MSI vegetation indices. *Advances in Space Re-*

- search 69: 1130–1145.
- Nunes, M. C., M. J. Vasconcelos, J. M. Pereira, N. Dasgupta, R. J. Allredge and F. C. Rego. 2005. Land cover type and fire in Portugal: do fires burn land cover selectively? *Landscape Ecology* 20: 661–673.
- Parker, J. A., R. V. Kenyon and D. E. Troxel. 1983. Comparison of interpolating methods for image resampling. *IEEE Transactions on Medical Imaging* 2: 31–39.
- Peng, Y. and A. A. Gitelson. 2012. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content. *Remote Sensing of Environment* 117: 440–448.
- Pereira, M. G., J. Aranha and M. Amraoui. 2014. Land cover fire proneness in Europe. *Forest Systems* 23: 598–610.
- Persson, M., E. Lindberg and H. Reese. 2018. Tree species classification with multi-temporal Sentinel-2 data. *Remote Sensing* 10: 1794.
- Phiri, D., M. Simwanda, S. Salekin, V. R. Nyirenda, Y. Murayama and M. Ranagalage. 2020. Sentinel-2 data for land cover/use mapping: a review. *Remote Sensing* 12: 2291.
- Pradhan, S., K. N. Tiwari and A. Dhar. 2021. Evaluation of Sentinel 2 red edge channel for enhancing land use classification. *Water Management and Water Governance: Hydrological Modeling* 96: 79–89.
- Radeloff, V. C., D. P. Helmers, H. A. Kramer, M. H. Mockrin, P. M. Alexandre, A. Bar-Massada, T. J. Hawbaker, S. Martinuzzi, A. D. Syphard and S. I. Stewart. 2018. Rapid growth of the US wildland-urban interface raises wildfire risk. *Proceedings of the National Academy of Sciences* 115: 3314–3319.

- Ricotta, C., G. Avena and A. De Palma. 1999. Mapping and monitoring net primary productivity with AVHRR NDVI time-series: statistical equivalence of cumulative vegetation indices. *ISPRS Journal of Photogrammetry and Remote Sensing* 54: 325–331.
- Rodriguez-Galiano, V. and M. Chica-Olmo. 2012. Land cover change analysis of a Mediterranean area in Spain using different sources of data: Multi-seasonal Landsat images, land surface temperature, digital terrain models and texture. *Applied Geography* 35: 208–218.
- Rouse, J. W., R. H. Haas, D. W. Deering, J. A. Schell and J. C. Harlan. 1974. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. *Remote Sensing Center, Texas A&M University College Station, USA*.
- Saini, R. and S. K.Ghosh. 2018a. Crop classification on single date Sentinel-2 imagery using random forest and support vector machine. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 42: 683–688.
- Saini, R. and S. K.Ghosh.2018b. Exploring capabilities of Sentinel-2 for vegetation mapping using random forest. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 42: 1499–1502.
- Skougaard Kaspersen, P., R. Fensholt and M. Drews. 2015. Using Landsat vegetation indices to estimate impervious surface fractions for European cities. *Remote Sensing* 7: 8224–8249.
- Sokolova, M. and G. Lapalme. 2009. A systematic analysis of performance measures for classifica-

- tion tasks. *Information Processing & Management* 45: 427–437.
- Somayajula, A., V. A. Kiranmai, D. Ghai and S. Kumar. 2020. A review on classification of land use/land cover change assessment based on the normalized difference vegetation index. *Journal of Critical Reviews* 7: 2416–2431.
- Sothe, C., C. M. D. Almeida, V. Liesenberg and M. B. Schimalski. 2017. Evaluating Sentinel-2 and Landsat-8 data to map successional forest stages in a subtropical forest in Southern Brazil. *Remote Sensing* 9: 838.
- Tavares, P. A., N. E. S. Beltrão, U. S. Guimarães and A. C. Teodoro. 2019. Integration of Sentinel-1 and Sentinel-2 for classification and LULC mapping in the urban area of Belém, eastern Brazilian Amazon. *Sensors* 19: 1140.
- Teluguntla, P., P. S. Thenkabail, A. Oliphant, J. Xiong, M. K. Gumma, R. G. Congalton, K. Yadav and A. Huete. 2018. A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing* 144: 325–340.
- Wakulińska, M. and A. Marcinkowska-Ochtyra. 2020. Multi-temporal Sentinel-2 data in classification of mountain vegetation. *Remote Sensing* 12: 2696.
- Wei, X., W. Zhang, Z. Zhang, H. Huang and L. Meng. 2023. Urban land use land cover classification based on GF-6 satellite imagery and multi-feature optimization. *Geocarto International* 38: 2236579.
- Wikantika, K., S. Uchida and Y. Yamamoto. 2004. An evaluation of the use of integrated spectral

and textural features to identify agricultural land cover types in Pangalengan, West Java, Indonesia. *Japan Agricultural Research Quarterly* 38: 137–148.

Yu, W., P. Zhao, K. Xu, Y. Zhao, P. Shen and J. Ma. 2022. Evaluation of red-edge features for identifying subtropical tree species based on Sentinel-2 and Gaofen-6 time series. *International Journal of Remote Sensing* 43: 3003–3027.

Zhang, H., J. Kang, X. Xu and L. Zhang. 2020. Accessing the temporal and spectral features in crop type mapping using multi-temporal Sentinel-2 imagery: A case study of Yi'an County, Heilongjiang province, China. *Computers and Electronics in Agriculture* 176: 105618.

附錄 1 主成分分析前 8 個主要成分及其主要貢獻變項

Appendix 1 Eight principal components and their key contributing variables identified by PCA

PC Layers	Variance (%)	Cumulative % of total variance (%)	Input variables	Factor loadings
PC1	33.460	33.460	B4_ENT	0.157
			B4_DIS	0.151
			B3_ENT	0.150
			B3_DIS	0.094
PC2	18.708	52.168	B3_CON	0.091
			B2_DIS	0.089
			B8A_COR	0.177
PC3	11.343	63.511	B8_COR	0.173
			B7_COR	0.169
			B4_COR	0.210
PC4	7.694	71.204	B5_COR	0.189
			B2_COR	0.187
			B8A_VAR	0.185
PC5	7.227	78.431	B8_VAR	0.177
			B7_VAR	0.173
			B3_COR	0.227
PC6	3.312	81.743	B4_COR	0.201
			B2_COR	0.198
			B11_HOM	0.211
PC7	3.032	84.775	B12_HOM	0.203
			B11_ASM	0.184
			B11_ENT	0.274
PC8	1.932	86.707	B2_VAR	0.199
			B12_ENT	0.181

附錄 2 不同特徵組合下研究區域的土地覆蓋分類結果。(a) 原始波段；(b) 原始波段添加 VIs 光譜特徵；(c) 原始波段添加 GLCM 紋理特徵；(d) 所有特徵變項。

Appendix 2 The result of Land cover classification in the study area using different feature sets. (a) OBs, (b) OBs + VIs, (c) OBs + GLCM, and (d) all bands.

