

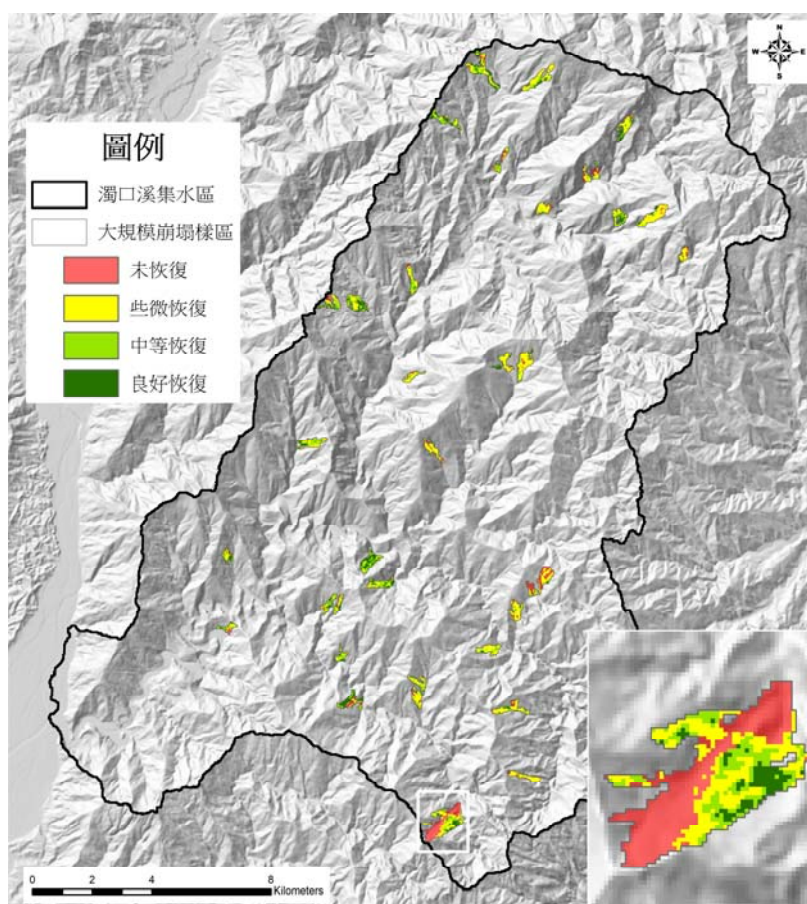
第二十九卷 第四期  
中華民國一一三年十二月

ISSN 1021-8661  
DOI: 10.6574/JPRS



# 航測及遙測學刊

中華民國航空測量及遙感探測學會出版



Journal of Photogrammetry and Remote Sensing

Volume 29 No.4

December

2024

Published by Chinese Society of Photogrammetry and Remote Sensing

# 航測及遙測學刊

## Journal of Photogrammetry and Remote Sensing

發行人：趙鍵哲

出版者：中華民國航空測量及遙感探測學會

地址：台北市文山區羅斯福路五段 113 號三樓

電子信件：csprsmail@csprs.org.tw

網址：http://www.csprs.org.tw

總編輯：楊明德

國立中興大學土木工程學系

電話：886-4-2285-2168

電子信件：jprssubmit@gmail.com

編輯委員(依中文姓氏筆劃排列)

王素芬 (國立彰化師範大學)

王聖鐸 (國立臺灣師範大學)

史天元 (國立陽明交通大學)

何宗儒 (國立臺灣海洋大學)

林玉儂 (中央研究院)

林昭宏 (國立成功大學)

林唐煌 (國立中央大學)

邱式鴻 (國立政治大學)

洪榮宏 (國立成功大學)

徐百輝 (國立臺灣大學)

張智安 (國立陽明交通大學)

莊永忠 (逢甲大學)

郭俊麟 (國立東華大學)

陳偉堯 (國立臺北科技大學)

陳國華 (國立臺北大學)

陳朝圳 (國立屏東科技大學)

黃倬英 (國立臺灣大學)

趙鍵哲 (國立臺灣大學)

蔡富安 (國立中央大學)

蔡榮得 (國立中興大學)

蘇東青 (國立金門大學)

C. Stewart (The Ohio State University) (USA)

M. Matsuoka (Tokyo Institute of Technology) (Japan)

T. Kim (Inha University) (South Korea)

PUBLISHER: Jen-Jer Jaw

PUBLISHED BY: Chinese Society of Photogrammetry and Remote Sensing

Address: 3F, No.113, Sec.5, Roosevelt Road, Taipei, Taiwan

E-mail: csprsmail@csprs.org.tw

WebSite: http://www.csprs.org.tw

EDITOR-IN-CHIEF: Ming-Der Yang

Department of Civil Engineering, National Chung Hsing University

Tel: 886-4-2285-2168

E-Mail: jprssubmit@gmail.com

EDITORIAL BOARD

S. F. Wang (National Changhua University of Education)

S. D. Wang (National Taiwan Normal University)

P. T. Y. Shih (National Yang Ming Chiao Tung University)

C. R. Ho (National Taiwan Ocean University)

Y. N. Lin (Academia Sinica)

C. H. Lin (National Cheng Kung University)

T. H. Lin (National Central University)

S. H. Chio (National Chengchi University)

J. H. Hong (National Cheng Kung University)

P. H. Hsu (National Taiwan University)

T. A. Teo (National Yang Ming Chiao Tung University)

Y. C. Chuang (Feng Chia University)

C. L. Kuo (National Dong Hwa University)

W. Chen (National Taipei University of Technology)

K. H. Chen (National Taipei University)

C. T. Chen (National Pingtung University of Science and Technology)

C. Y. Huang (National Taiwan University)

J. J. Jaw (National Taiwan University)

F. Tsai (National Central University)

J. D. Tsai (National Chung Hsing University)

T. C. Su (National Quemoy University)

C. Stewart (The Ohio State University) (USA)

M. Matsuoka (Tokyo Institute of Technology) (Japan)

T. Kim (Inha University) (South Korea)

### 封面照片說明 About the Cover

大規模崩塌地的復育過程具有高度時空間變異性，透過時間序列的遙測資料分析能更準確掌握長期植生演替動態。從遙測反演的植被光譜與結構時序資訊可以呈現一地的恢復軌跡，藉此區分植被再生狀態與復育速率差異，並且進一步估計恢復至成熟森林所需的時間，能為崩塌復育的生態評估工作提供重要訊息。

# 以時間序列遙測資料評估大規模崩塌地植被結構與 光譜指標的恢復速率差異

宋承恩<sup>1\*</sup> 王素芬<sup>2</sup> 陳毅青<sup>3</sup>

## 摘要

本研究以時間序列的植生光譜變量為基礎，建立冠層結構推估模型來檢測大規模崩塌的植被恢復，並比較植生指標與冠層結構的恢復速率差異。分析顯示，機器學習模型能有效模擬冠層結構，模擬值與觀測值的  $R^2$  可達 0.9 以上，可在廣泛的時空尺度下推演植被結構變化。植被恢復軌跡呈現高度變異，僅約 14% 的崩塌表面有望能恢復至成熟林分狀態。植生指標的恢復突顯了飽和效應問題，容易高估恢復速率，估計良好恢復的植被能在 15 年內到達成熟森林水準，但冠層結構則需要數十年至百年的發展時間。故植生指標適用於初期演替階段的評估，長期復育監測仍須考量植被結構變化，整合光譜與結構訊息將有助於更全面地評估復育動態。

**關鍵詞：**時間序列、植生指標、冠層結構、機器學習、崩塌復育

## 1. 前言

衛載光學遙測能以固定時間頻率對地表進行大尺度的連續觀測，目前已被廣泛應用在監測干擾 (Disturbance) 事件後的恢復。觀測歷史最悠久的 Landsat 系列衛星影像紀錄了 50 多年的地表變化，自 2008 年美國地質調查局 (United States Geological Survey, USGS) 開放資料取用後，促進時間序列影像的演算分析技術發展，大量應用於地表植被的復育研究 (Wang *et al.*, 2022、Zhu, 2017)。多光譜影像的時間序列分析是量化地表變化過程與特徵的有效方法 (Muro *et al.*, 2018)，透過對植被覆蓋敏感的波段、植生指標 (Vegetation index, VI) 或其他光譜衍生的變量，能檢測植被長期生長狀況與植覆類型變化 (Banskota *et al.*, 2014)。以植生指標的時序變化來表徵和推論地表植被動態是常見的應用方法，尤其是 NDVI 被廣泛用來描述植被演替 (Succession) 或復育概況 (João *et al.*, 2018、Song &

Woodcock, 2003)。然而，許多探討干擾恢復的研究指出，在早期演替階段因先鋒植被的快速定殖生長，容易導致以近紅外光 (Near infrared, NIR) 進行波段組合的 NDVI 很容易面臨飽和效應問題，對於再生植被的冠層結構估計具有不確定性 (Pickell *et al.*, 2016、Masseti *et al.*, 2019)。因此有部分研究建議採用對纖維素和木質素等木本結構化合物敏感的短波紅外光 (Short-wave infrared, SWIR) 波段 (Jacques *et al.*, 2014)，組合計算的植生指標更適合用來評估復育植被的冠層結構屬性，例如常態化燃燒比指標 (Normalized burn ratio, NBR) 或森林恢復指數 (Forest recovery index, FRI) 等 (Hislop *et al.*, 2018、Morresi *et al.*, 2019、White *et al.*, 2017)。

從植生指標的時間序列可以產生描述一地植被生長歷史的光譜軌跡，推論植被物種組成或冠層結構發展。冠層的物理結構很大的程度決定了生態系功能 (Wulder *et al.*, 2004)，明確的冠層結構量測對於評估植被復育狀況更具有意義。雖然由光學遙

<sup>1</sup> 國立彰化師範大學地理學系 博士

<sup>2</sup> 國立彰化師範大學地理學系 教授

<sup>3</sup> 國立彰化師範大學地理學系 副教授

\* 通訊作者, E-mail: pths5000@gmail.com

收到日期：民國 113 年 09 月 26 日

修改日期：民國 113 年 10 月 22 日

接受日期：民國 113 年 11 月 01 日

測資料推估森林結構特性已經證明其可行性，但估算的準確性通常會隨著生物量 (Biomass) 和葉面積指數 (Leaf area index, LAI) 的增加而降低 (Foody *et al.*, 2001、Hudak *et al.*, 2002)，對高密度森林的結構估計相關性僅介於 0.11 至 0.41 之間 (Ma *et al.*, 2018)。空載光達 (Airborne LiDAR) 是一種主動式的遙測技術，能夠在更大的空間尺度上準確測量植被三維特徵，提供森林結構屬性的量化數據 (Drake *et al.*, 2002)。相對於衛載光學影像，空載光達獲取資料的空間範圍及頻率仍有限，難以即時且全面性的量測。為了滿足更全面的測繪調查需求，結合光學遙測與空載光達資料建立冠層結構推估模型的方法能補充測繪調查的時空限制，描述受干擾地區的植被動態，進而更好的估計森林生態系的干擾恢復狀況 (Bolton *et al.*, 2020、Senf *et al.*, 2019)。

臺灣受到地理位置影響，頻繁面臨地震、颱風和強降雨事件的威脅，易引發土砂災害造成大量損失，也影響山地森林生態系的功能。崩塌是上游集水區主要的土砂災害類型，也是山區森林最主要的林分替代 (Stand-replacing) 干擾。遙測技術適合評估區域尺度的崩塌地植被恢復，從少量不連續的觀測雖然能呈現邊坡滑動後與當前植被狀態的差異，但很難反映植被再生過程的高度變異性。時間序列的分析能更全面地在不同空間、時間尺度上重構干擾事件後的恢復變化 (Banskota *et al.*, 2014)，並透過長期趨勢來推論不同恢復階段的植被狀況，提供有關坡地復育動態的見解。本研究以鮮少人為活動的濁口溪集水區為研究區，利用時間序列光學遙測影像結合多期空載雷射掃描產製的樹冠高程模型，分析 2009 年莫拉克風災後大規模崩塌地植生光譜與結構的恢復過程。研究目的為探索機器學習方法建立冠層結構推估模型的可行性，比較植生光譜與結構的恢復速率差異，藉此評估坡地森林復育的進程。

## 2. 材料與方法

### 2.1 研究區域

研究範圍以高屏溪上游的濁口溪集水區為主

(圖 1)，集水面積約 378 km<sup>2</sup>，海拔高度介於 87 至 3,287 m，坡度多介於 15° 至 86° 間，整體地勢向西傾斜，坡向多為西南坡。集水區內包含馬里山溪、山花奴奴溪及溫泉溪三條主要支流，出露地層以畢祿山層及潮州層為主。氣候上屬亞熱帶季風氣候區，年平均降雨量約 2,918 mm，90% 以上的降雨量及中在 5~10 月，年均溫約 22.9 °C。集水區內多為自然植被覆蓋，人為開發區域少，國土利用調查資料顯示集水區內聚落及農業使用土地面積僅占 1.62%。依據林業署全島崩塌判釋圖資顯示，2009 年莫拉克風災過後，集水區崩塌面積增加至 3,539.51 ha，相較災前大約增加了 3,190.86 ha 的崩塌地，流域崩塌比由 0.92% 上升至 9.35%，突顯該場風災事件對研究區地表覆蓋變化的影響甚鉅。

## 2.2 研究材料

### 2.2.1 衛載光學影像及前處理

研究蒐集莫拉克風災後至 2023 年間共 198 幅多光譜衛星影像，為 Landsat、SPOT 系列與 Sentinel-2 等三類資源衛星所拍攝 (附錄補充資料表 1)。Landsat 影像材料由 USGS 的 EarthExplorer 平台取得，為 Level-2 的地表反射率產品，包含可見光、NIR 以及 2 個 SWIR 波段，其中 Landsat-7 ETM+ 因掃描器故障導致影像資料有條帶缺失的情況，採用遙測影像處理軟體 ENVI 的 Gapfill 擴充套件進行空隙像元填補。Sentinel-2 為歐洲太空總署 (European space agency, ESA) 的光學衛星，哥白尼計畫開放存取中心平台 (Copernicus open access hub) 提供 Level-1C 等級的大氣層頂反射率產品。SPOT 為法國的商業資源衛星，研究使用 SPOT-4、SPOT-5、SPOT-6 及 SPOT-7 感測器拍攝之多光譜影像，其中 SPOT-4 與 SPOT-5 影像為綠光、紅光以及 NIR 與 SWIR 波段組成，而 SPOT-6 及 SPOT-7 則為可見光與 NIR 波段組成。在時間序列影像分析上，影像的大氣校正或相對輻射校正是必要的前處理流程，才能確保穩健且一致的結果 (Banskota *et al.*, 2014)。材料中僅 Landsat 影像為地表反射率產品，故將 Sentinel-2 影像及 SPOT 影像分別採用遙測影像處

理軟體 ENVI 的 FLAASH 與 QUAC 大氣校正模組進行地表反射率估算。由於感測器影像的空間解析度差異，前處理過程中統一重新取樣 (Resample)

為 30 m 解析度，參考 Landsat 影像採共同記錄 (Co-registration) 的方法調整像元至一致的地理位置，且去除雲遮像元補為空值。




圖 1 研究區及莫拉克風災崩塌地理位置圖

### 2.2.2 冠層高度模型

空載光達的雷射掃描能穿透植被冠層，密集地獲取地表及植被結構的三維點雲資料。透過點雲分類與內插轉換可以產生高精度的數值地表模型 (Digital surface model, DSM) 與數值高程模型 (Digital elevation model, DEM)，經由兩者相減獲得代表地表植被高度的冠層高度模型 (Canopy height model, CHM)，可作為量化植被結構的基礎資料。農業部林業試驗所於 2021 年期間針對位於濁口溪集水區的六龜試驗林進行空載光達掃描，同時也蒐集內政部國土測繪中心於 2010~2012 年及 2016 年間施測成果加值產製了空間解析度 1 m 的冠層高度模型，提供本研究分析莫拉克災後三個時段的復育植被冠層變化。

### 2.2.3 植生指標與冠層結構指標計算

為了估計崩塌地的復育植被生長狀況，研究選擇 NDVI 及 NBR 兩個植生指標來估計植生光譜特徵變化，兩者公式分別為：

$$NDVI = \frac{(NIR-R)}{(NIR+R)} \dots\dots\dots (1)$$

$$NBR = \frac{(NIR-SWIR_2)}{(NIR+SWIR_2)} \dots\dots\dots (2)$$

式中 NIR 為近紅外光波段，R 為紅光波段。NBR 是採用波長大於 2,000 nm 的短波紅外光 (SWIR<sub>2</sub>) 與近紅外光波段進行組合計算，在研究材料中只有 Landsat 及 Sentinel-2 影像可以計算，故 NBR 時間序列的資料頻率要低於 NDVI。

冠層高度模型是代表地上植被高度的數值模型，在以面積為基礎 (Area-based approach, ABA) 方法的操作下，可以計算區域或林分尺度的冠層結構量化指標 (White *et al.*, 2016)。研究劃設 30 × 30 m 的空間單元，並對齊 30 m 解析度的光學影像像元位置，依循 ABA 的方法將 CHM 計算為 2 個基本冠層結構指標，藉此估計植被的結構變化。第 1 個冠層結構指標為平均冠層高度 (Mean top-of-the-canopy, TCH)，代表像元空間範圍內植被冠層高度的平均值，計算公式如下：

$$TCH = \frac{\sum_{i=1}^N CHM_i}{N} \dots\dots\dots (3)$$

式中  $CHM_i$  為空間單元內第  $i$  個 CHM 值； $N$  為空間單元內 CHM 像元數量，在本研究中設定為常數 900。第 2 個冠層結構指標為樹冠層覆蓋率 (Canopy cover ratio, CCR)，代表空間單元內植被高度大於 2 m 的木本植被覆蓋比例 (Ahmed *et al.*, 2015、Smith *et al.*, 2009)，其公式為：

$$CCR = \frac{n_{CHM_i}}{N} \times 100, CHM_i \geq 2 m \dots\dots\dots (4)$$

其中  $n_{CHM_i}$  為空間單元中 CHM 值  $\geq 2$  m 的像元數量。

## 2.3 研究方法

### 2.3.1 崩塌判釋與復育像元位置判定

利用 2009 年莫拉克災後 10 月 30 日拍攝的 Landsat 影像，以物件式影像分析 (Object-based image analysis, OBIA) 方法進行影像物件分割後，並以物件 NDVI 平均值 0.05 為門檻標準，劃分為植被及非植被物件。再進一步透過人工編修方式去除河道灘地、道路建物等非植被物件，保留代表崩塌地的非植被物件遮罩來判釋崩塌範圍。最終依據農村發展及水土保持署的大規模崩塌地定義，選取崩塌面積大於 10 ha 為分析樣區。由於崩塌地的復育植被通常是非均質分布，且具高度空間變異。為了判定植被長期穩定再生的位置，透過統計檢定災後影像像元的 NDVI 時序趨勢，藉此區分樣區內發生復育及維持裸露的位置。Mann-Kendall (MK) 檢定方法被廣泛應用於時間序列趨勢檢定上，為無母數統計方法，用來判定時間數列是否具有顯著趨勢特性 (Hamed & Rao, 1998)。相較於其他趨勢檢定方法，如最小二乘法或 Cox-Stuart 檢定，MK 趨勢檢定不受極端值及缺漏資料影響，考量特定時間點與先前時間點的資料大小關係，更適合應用於時間序列資料。其方法如下：

當一組時間序列  $(t_1, t_2, \dots, t_n)$  其觀測值為  $X = \{x_1, x_2, \dots, x_n\}$ ，Mann-Kendall 檢定統計量  $S$  為：

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(x_i - x_j), \text{sgn}(x_i - x_j) = \begin{cases} +1, & x_i - x_j > 0 \\ 0, & x_i - x_j = 0 \\ -1, & x_i - x_j < 0 \end{cases} \dots\dots\dots (5)$$

其中  $n$  是時間序列資料的數量， $x_i$ 和 $x_j$ 分別是時間序列 $t_i$ 和 $t_j$  ( $j > i$ ) 的觀測值。變異數 $Var(S)$ 計算為：

$$Var(S) = \frac{n(n-1)(2n+5)}{18} \dots\dots\dots (6)$$

當  $n \geq 10$  時，檢定統計量  $S$  近似標準常態分布，平均值為 0，標準常態檢定統計量 $Z_s$ 計算方程式為：

$$Z_s = \begin{cases} \frac{S-1}{\sqrt{Var(S)}} & S > 0 \\ 0 & \text{if } S = 0 \\ \frac{S-1}{\sqrt{Var(S)}} & S < 0 \end{cases} \dots\dots\dots (7)$$

顯著水準  $\alpha = 0.05$  情況下， $Z_s \geq Z_{\alpha/2} = |\pm 1.96|$  代表趨勢變化具統計上的顯著意義。當顯著的  $Z_s$  正值時為漸增趨勢，代表該像元位置發生穩定植被復育；相對地， $Z_s$  負值的漸減趨勢或趨勢不顯著代表維持裸露。

### 2.3.2冠層結構推估模型

由於可取得的 CHM 資料在時間頻率與空間範圍上皆不完全，研究透過模擬方法來推演更大時空尺度的植被結構變化。應用傳統參數方法 (例如多元回歸) 建立植生光譜變量與冠層結構關係時，對於冠層結構變異大的地區通常很難得到良好的結果 (Chen & Hay, 2011)；而非參數機器學習模型能處理複雜的非線性關係，甚至可以接受高維度特徵資料的輸入，在估計冠層結構方面具有相當好的效果 (Ahmed *et al.*, 2015、Matasci *et al.*, 2018、Viana-Soto *et al.*, 2022)。在模型預測變量方面，選擇八個與植生結構相關的光譜變量：NDVI、NBR、纓帽亮度 (Tasseled cap brightness, TCB)、綠度 (Tasseled cap greenness, TCG)、濕度 (Tasseled cap wetness, TCW)、纓帽角度 (Tasseled cap angle, TCA)、纓帽距離 (Tasseled cap distance, TCD) 以及時間標準化干擾指數 (Temporal standardized disturbance index, DI<sub>t</sub>)。NDVI 是最廣泛應用的植生指標，NBR 是使

用 SWIR 波段組合的植生指標。纓帽轉換 (Tasseled cap transform, TCT) 是分析森林結構、狀態或變遷時常用的線性轉換方法，將多光譜波段轉為反應植被亮度、綠度及濕度的特徵分量。由 TCG 及 TCB 兩個分量構成的植生平面中，亮度與綠度形成的角度 (TCA)代表了植生與非植生的組成比例 (Gómez *et al.*, 2011)；而 TCD 則是植生平面內亮度與綠度的距離，被用來描述森林的結構和組成 (Duane *et al.*, 2010)。干擾指數是由標準化 TCB、TCG 及 TCW 進行組合計算 (Healey *et al.*, 2005)，用來衡量森林干擾受損或恢復的狀況。de Beurs *et al.* (2019) 則提出改以時間序列標準化來組合計算 DI<sub>t</sub>，不易受到季節物候影響而能穩定評估特定地點的干擾恢復變化。因纓帽轉換方法是依據固定的變換矩陣來轉換，須參考研究文獻的率定係數 (Crist, 1985、Huang *et al.*, 2002、Zhai *et al.*, 2022)。由於模型預測變量包含 NBR 與 TCT 方法衍生的光譜變量，須具有 SWIR<sub>2</sub> 波段與可信賴的 TCT 率定係數來轉換，故本研究的冠層結構模型僅對 Landsat 時間序列影像進行反演。

隨機森林 (Random forest, RF) 是多決策樹 (Decision tree, DT) 集成的機器學習演算法，每個 DT 會從原訓練樣本中抽取部份樣本進行訓練，從特徵集中隨機抽取  $k$  個特徵做為節點輸入，以 Gini 指數最小化的原則選出最佳屬性進行內部節點連結，最終集合  $N$  棵樹的決策結果來對樹的回歸預測值進行平均 (Breiman, 2001)。由三期 CHM 估算的冠層結構指標代表了不同恢復階段的植被狀況，研究選擇與六龜試驗林 CHM 資料時間最為相近的 Landsat 影像建立預測變量，在崩塌地及周邊良好森林覆蓋區提取三期資料樣本進行建模。這些混合樣本將隨機切分為 2/3 的率定資料及 1/3 驗證資料，最終以驗證樣本的決定係數 (Coefficient of determination, R<sup>2</sup>)、均方根誤差 (Root-mean-square Error, RMSE) 及偏誤值 (Bias) 來評估模型效能，並以散點圖檢核預測結果。模型率定及預測皆在 R

語言 (version 4.1.0) 環境下的 random Forest 套件進行。

### 2.3.3 恢復軌跡與恢復速率估計

為比較植生光譜與冠層結構的恢復速率差異，在每個像元位置上提取 NDVI、NBR、TCH 及 CCR 四項植被特徵的時間序列資訊，將影像時間換算為儒略日，定義 2009 年 8 月 8 日莫拉克風災為干擾發生日，並將所有時間轉換為距干擾發生時間 (Time since disturbance, TSD)。依復育發展假說，干擾後因空間及限制資源的釋放，預計會呈現快速成長，經歷競爭作用後逐漸降低增長速率而趨於穩定，因此適合以對數模型來描述恢復軌跡 (Senf *et al.*, 2019)。研究採用的自然對數擬合方程式為：

$$y(t) = a \cdot \ln(t) + b \dots\dots\dots (8)$$

其中  $a$  為回歸模型斜率， $b$  為截距值。 $t$  為 TSD，單位為日。 $y(t)$  為干擾發生  $t$  日後，模型預估的植生特徵值。在對數模型中，斜率  $a$  會直接影響恢復速率的估計，也代表每個位置植被恢復狀況的好壞。由於植生復育具有高度的空間異質性，依四項植被特徵恢復軌跡的斜率進行 K-means 集群分析，將所有復育位置分為良好恢復、中等恢復與些微恢復三個等級。每個等級群組計算組內軌跡模型的平均決定係數  $R^2_n$  來描述擬合程度，並以斜率排序中位數的恢復軌跡為代表，藉此評估不同恢復時間下植被特徵的變化 (圖 2)。此外，將崩塌樣區周邊未遭受干擾的成熟森林覆蓋像元，統計四項植被特徵的中位數作為森林參考閾值，可以透過下列公式自恢復軌跡反推到達成熟林分條件的可能恢復時間。

$$t = e^{\frac{MF_{ref}-b}{a}} \dots\dots\dots (9)$$

式中  $e$  為自然常數， $MF_{ref}$  為成熟林分參考值， $a$  與  $b$  為代表軌跡對數模型的斜率及截距值。而從恢復軌跡估計特定時間的植生特徵可以計算植生恢復比 (Vegetation recovery ratio, VRR)，反映該時間段復育植被相對於成熟林分條件的恢復程度。VRR 的公式如下：

$$VRR(\%) = \frac{y(t)}{MF_{ref}} \times 100 \dots\dots\dots (10)$$

## 3. 結果

### 3.1 崩塌地復育位置判定

經災後崩塌判釋結果，共選擇了 35 個大規模崩塌為研究分析樣區，總面積為 756.45 ha。沿崩塌樣區邊緣向外 90 m 範圍，NDVI 趨勢檢定顯示無顯著變化或漸增趨勢的森林覆蓋像元被定義為成熟林分位置，提供衡量成熟森林的植生特徵參考標準。崩塌地災後 NDVI 的趨勢檢定結果顯示，約 83.83% 的崩塌地表有發生植被恢復 (圖 3)。所有崩塌樣區中僅有 4 個崩塌地的復育比例小於 60%，3 個崩塌地的復育比例達 70%，其餘 28 個崩塌地的復育比例高於 80%，顯示災後至今大部份崩塌地表皆有穩定植被再覆蓋，具有明確的演替發展。

### 3.2 冠層結構模型效能評估

從研究區內六龜試驗林三期資料中共取得 68,003 筆樣本，以其中 45,421 筆樣本作為模型訓練，其餘為獨立驗證樣本。圖 4 為冠層結構模型的驗證結果，1:1 的驗證預測散點圖顯示 RF 模型具有良好預測效能，TCH 以及 CCR 的推估模型的  $R^2$  均達到 0.9 以上。TCH 模型的 RMSE 表現為 1.75 m，但 Bias 顯示整體模型有些微高估 (0.11 m) 的情形。雖然 CCR 模型在  $R^2$  表現略優於 TCH 模型，但 RMSE 為 8.88%，且散點圖表現更為分散，也存在些微偏差 (Bias = 0.32%)，模型準確度明顯較低。進一步檢視驗證樣本的預測殘差分布 (圖 5)。很明顯地，無論是 TCH 或 CCR 推估模型，殘差分布皆呈現低者高估、高者低估的情形。即使兩者模型的偏誤表現很小，殘差分布並非隨機，且在預測散點圖中可以發現趨勢斜率小於 1 的情形，說明以植生光譜變量建構的推估模型仍存在限制因素。






圖 2 復育區恢復軌跡及速率估計流程圖




圖 3 崩塌樣區 NDVI MK 趨勢檢定與復育位置判定結果圖




圖 4 冠層結構推估模型驗證樣本預測散點圖




圖 5 冠層結構推估模型驗證樣本預測殘差圖

### 3.3 植生恢復軌跡差異

四項植生特徵恢復軌跡斜率的 K-means 集群分析結果摘要如表 1。雖然有 83.83% 的崩塌位置有顯著的 NDVI 穩定恢復訊號，但其中超過一半（崩塌樣區總面積 41.78%）屬於些微恢復，約 27.98% 的崩塌樣區為中等恢復，僅 14% 的崩塌位置有良好植被恢復（圖 6）。在恢復等級群組的組內恢復軌跡擬合度表現顯示，NDVI 具有最佳的平均擬合度 ( $R^2_n$ ) 表現，CCR、TCH 依序次之，NBR 的組內平均擬合度表現最差。隨著恢復等級增加，植生特徵的平均擬合度表現顯著增加（表 1）。從些微恢復到

良好恢復群組，NDVI 的  $R^2_n$  表現從 0.48 上升到 0.78，CCR 及 TCH 的  $R^2_n$  表現也分別增加至 0.72、0.62，而 NBR 的  $R^2_n$  僅從 0.12 上升到 0.45。對於恢復程度差的位置，在植生光譜及反演結構的時間序列資料通常更具變異性，有時經歷急遽短期恢復後又遭受侵蝕，導致植被增長訊號不平穩，雖然有顯著的再植被趨勢，但通常很難恢復到更好的植被狀況。相反的，恢復程度好的位置，復育植被多能穩定成長，光譜與結構的時序變異相對小，對數曲線能更好地描述其軌跡變化。

圖 7 顯示所有復育位置的恢復軌跡分布狀況，相較於植生光譜，結構的恢復軌跡分布呈現明顯的

正偏態，近 50 % 的恢復軌跡保持低度結構增長趨勢，指示了些微恢復等級的復育位置即便有明顯的光譜恢復，然而結構的增長仍十分有限。從各恢復等級的代表軌跡估計光譜及結構特徵的 VRR 變化 (表 2)，災後 15 年 (2024 年)，所有復育位置已有顯著的植生光譜恢復 (附錄補充資料圖 1)，即使是恢復最差的些微恢復等級其植生指標的 VRR 值也多半能恢復到 40%~50%，但結構上發展緩慢，VRR 多在 15% 以下。恢復速率最快的好恢復等級中，NDVI 的 VRR 表現已經可達到 100%，NBR 的 VRR 也可恢復至 90%；在冠層結構的估計上，顯示了大比例的本木植被 (TCH=7.97 m, CCR=73.26%)，已具備森林結構的組成特徵。由代表軌跡推算到達森林參考閾值 (即 VRR 100%) 的復育時間 (表 1)，

僅在良好恢復等級位置有望百年內恢復至成熟林分的水準，NDVI 在 15 年內已經達到門檻條件，而 NBR 則需約 29 年；冠層結構的恢復相顯緩慢，CCR 要將近花費 41 年，TCH 則估計需要 95 年來恢復至成熟林分水準。中等恢復等級的 NDVI 代表軌跡也顯示有機會在災後 44 年到達成熟林分水準，但 NBR 訊號到達門檻值的時間可能長達 264 年之久；結構訊號方面雖能在 90 年後恢復到高木本植被組成特徵 (TCH ≥ 5 m, CCR ≥ 60%)，卻難以持續成長至成熟林分水準。些微恢復等級的代表軌跡在長期恢復下均呈現明顯的遲緩增長 (表 2)，災後百年仍缺乏木本植被組成 (TCH < 2 m, CCR < 20%)，很可能發生演替序列停滯，停留在演替初期的植物相。

表 1 各等級群組的植生特徵恢復軌跡表現與森林復育時間估計

指標	成熟林分參考值	恢復等級	R <sup>2</sup> <sub>n</sub>	代表軌跡估計方程式	森林復育時間 (年)
NDVI	0.823	良好	0.78	$y = 0.178 \ln(x) - 0.705$	14.64
		中等	0.68	$y = 0.145 \ln(x) - 0.580$	43.61
		些微	0.48	$y = 0.093 \ln(x) - 0.394$	∞
NBR	0.626	良好	0.45	$y = 0.092 \ln(x) - 0.226$	28.8
		中等	0.28	$y = 0.065 \ln(x) - 0.120$	264.1
		些微	0.12	$y = 0.027 \ln(x) + 0.036$	∞
TCH	12.42	良好	0.62	$y = 2.413 \ln(x) - 12.807$	95.02
		中等	0.49	$y = 0.943 \ln(x) - 4.316$	∞
		些微	0.32	$y = 0.256 \ln(x) - 0.854$	∞
CCR	93.03	良好	0.72	$y = 19.671 \ln(x) - 96.084$	40.99
		中等	0.58	$y = 10.590 \ln(x) - 49.830$	∞
		些微	0.34	$y = 3.050 \ln(x) - 13.931$	∞

標記"∞"為復育時間大於 1,000 年，代表難以恢復到成熟森林水準。

表 2 代表恢復軌跡估計不同時間的 VRR 變化表

恢復等級	指標	距干擾發生時間 (年)								
		3	7	10	15	20	25	30	50	100
良好恢復	NDVI	65.72%	84.04%	91.76%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
	NBR	66.76%	79.21%	84.46%	90.41%	94.64%	97.92%	100.00%	100.00%	100.00%
	TCH	32.87%	49.33%	56.26%	64.14%	69.72%	74.06%	77.60%	87.53%	100.00%
	CCR	44.71%	62.63%	70.17%	78.74%	84.83%	89.55%	93.40%	100.00%	100.00%
中等恢復	NDVI	52.84%	67.77%	74.05%	81.20%	86.27%	90.20%	93.41%	100.00%	100.00%
	NBR	53.51%	62.30%	66.01%	70.22%	73.20%	75.52%	77.41%	82.72%	89.92%
	TCH	18.39%	24.82%	27.53%	30.61%	32.80%	34.49%	35.87%	39.75%	45.02%
	CCR	26.11%	35.76%	39.82%	44.43%	47.71%	50.25%	52.32%	58.14%	66.03%
些微恢復	NDVI	31.22%	40.79%	44.82%	49.40%	52.66%	55.18%	57.24%	63.01%	70.84%
	NBR	35.94%	39.59%	41.13%	42.88%	44.12%	45.08%	45.87%	48.07%	51.06%
	TCH	7.55%	9.30%	10.03%	10.87%	11.46%	11.92%	12.30%	13.35%	14.78%
	CCR	7.97%	10.75%	11.92%	13.25%	14.19%	14.92%	15.52%	17.20%	19.47%

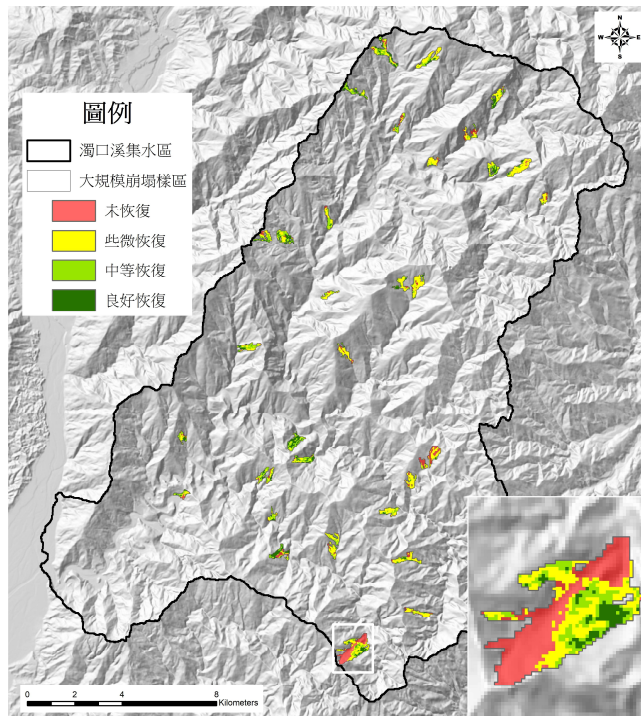


圖 6 崩塌樣區恢復等級位置分布圖

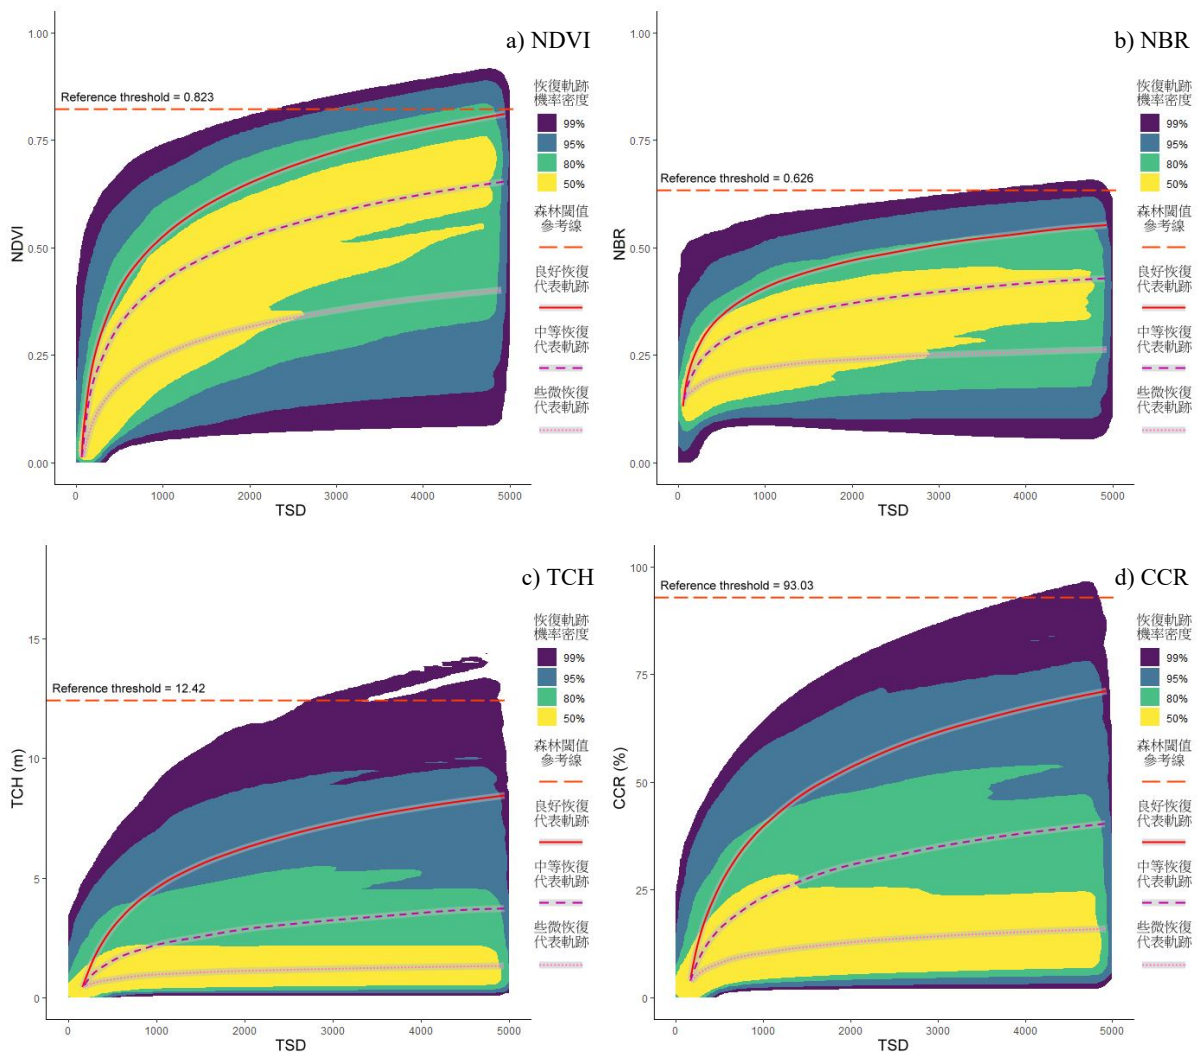


圖 7 植生光譜及結構指標恢復軌跡分布圖

## 4. 討論

### 4.1 冠層結構模擬的可行性

利用現有的時間序列光學影像及空載光達推導的冠層結構屬性，來模擬缺乏冠層結構測量的位置或資料時段是具有良好的應用潛力，這表明了兩種遙測資料的結合對於了解復育植被如何隨時間發展具有重大意義。本文利用 RF 建模方法取得了良好預測的結果，但估計上仍存在少許偏差，且殘差分布顯示隨冠層結構的增加，預測誤差會有從高估轉向低估的趨勢。同樣以機器學習模型來推估冠層結構的研究文獻顯示 (Ahmed *et al.*, 2015、Bolton *et al.*, 2018、Bolton *et al.*, 2020、Matasci *et al.*, 2018、Viana-Soto *et al.*, 2022)，這些模型方法通常有良好的  $R^2$  表現 (0.62~0.88)，TCH 的 RMSE 多介於 1.87 m ~ 2.88 m 之間，而 CCR 的 RMSE 多在 0.07% ~ 18.73%，且模型多半存在些微偏差。本研究的預測模型相較這些文獻，效能評估指標表現相對良好，但所有文獻與本研究模型的 1:1 預測散點圖存在「天花板效應」，高冠層結構的樣本明顯被低估，這反映了植生光譜相關變量在估計封閉冠層結構的侷限性，以及林下土壤及冠層表面濕度造成的影響 (García *et al.*, 2018)。而模型對低冠層結構的高估問題可歸因於植生指標對冠層結構的中度相關性，使得模型估計上容易出現錯誤和不確定性 (Glenn *et al.*, 2008)。通常在演替初期，良好的恢復條件下濃密的先鋒草本會產生強烈的植生指標訊號，即便是稍後演替序列物種的進入，混合光譜也難以正確估計冠層結構的特性。預測殘差圖顯示，林分平均高度達 5 m 的幼齡林存在嚴重高估情形，當成熟林分高度超過 30 m 時也更容易出現低估 10 m 以上的情形；而在樹冠層覆蓋率的模擬，隨著實際覆蓋率增加至 70%，高估的殘差離群值逐漸減少，相對地，低估的殘差離群值隨著實際覆蓋率增加，在 CCR 90% 容易發生嚴重低估情形。因此，在單期光學影像的反演上，不建議使用冠層結構模型來估計未密集成林的次生林或初期演替階段的復育地，對於冠層高度封閉且林分高度超過 30 m 以上的林地同樣也

不是理想的估計對象，以避免嚴重偏估的風險。若應用模型分析長期植被結構變化，則建議將模擬的多期冠層結構結合回歸方法估計代表值，或者將一年內多期影像的反演結果平均，降低極端偏估帶來的影響。總體來說，使用光學影像模擬冠層結構是種經濟有效的方法，可以在時間及空間向度上擴展產生更全面的估計結果，大幅度補充了植被動態資訊，然而準確度的問題無法完全取代詳細的現地調查量測，仍需在兩者之間權衡。

### 4.2 森林復育時間的估計差異

時間序列的分析方法在追蹤植生恢復過程具有相當的優勢，恢復軌跡的差異也確實反映了復育發展的空間異質性，大多數崩塌坡面能夠在長期恢復下發生再植被，卻不一定能穩定發展成林，每個坡面位置受到地形、遺留物、種子庫或侵蝕作用等因素影響，植被演替恢復的速率差異很大 (宋承恩等, 2022、林國聖等, 2023)。許多文獻顯示以植生指標估計林分替代後恢復至災前水準的時間可能短於 10 年 (Hislop *et al.*, 2018、Jin *et al.*, 2012、Pickell *et al.*, 2016、Shen *et al.*, 2020)，部份研究則認為森林光譜恢復需十幾年 (Cuevas-González *et al.*, 2009、Morresi *et al.*, 2019、Yunus *et al.*, 2020)，甚至二十年以上 (Chompuchan & Lin, 2017、Chu *et al.*, 2016)。對比之下，森林冠層結構的復育時間顯得更漫長。Senf & Seidl (2022) 指出歐洲大部分的溫帶森林的冠層覆蓋率在 30 年內可以恢復到干擾前水準，只有少數地區復育時間長達 100 年；Bartels *et al.* (2016) 的分析則認為寒溫帶針葉林的冠層覆蓋率及高度分別在干擾後 50 年與 100 年內達到最大值。對於熱帶森林，Suganuma & Durigan (2015) 在巴西的演替研究認為森林復育需要 70 年或更長的時間才有辦法達到原始森林的植物相、冠層結構條件，Okuda *et al.* (2019) 分析馬來西亞熱帶森林的冠層高度恢復，估計在自然復育的情況下約需 80 年才可達到原始森林的水準。與溫帶森林相比，熱帶森林的冠層結構恢復沒有比較快，只是不同的個案研究呈現很大的差異。但絕大多數的研究論點都支持森林冠層結構的復育至少是數十年起算，相較於植

生光譜的恢復速率要慢上許多。在本研究分析中，良好恢復位置的 NDVI 的確能在 15 年到達恢復門檻，NBR 代表軌跡指示的復育時間也與文獻相近，森林冠層覆蓋率跟高度的復育時間也與其他林分替代干擾類型相似 (表 3)，似乎依循著常規的演替過程發展。中等恢復位置的植生指標在更長久的恢復下也有機會達到門檻，但演替森林的冠層結構條件遠不及成熟森林；而些微恢復位置的恢復狀況更糟，普遍為耐受度高的草本或矮灌等先鋒植被能定殖。這些恢復發展不佳的位置，本研究的分析無法確定是由已定殖的物種造成的競爭抑制 (Competitive inhibition)，或者是不穩定邊坡的惡劣條件造成的環境過濾 (Environmental filtering) 所

致，難以到達晚期演替的階段，部分恢復停滯且植被狀況極差的位置，存在土地退化的風險。

無論是文獻研究或本文的分析結果均證實由植生指標估算的光譜恢復時間是遠小於森林結構的恢復時間。特別是到演替中期階段，幼齡林逐漸發展至冠層封閉時會產生類似成熟林的光譜反應，飽和效應的問題導致植生指標不適合作為森林復育的評估指標 (White *et al.*, 2018)。相對於 NDVI，包含 SWIR 波段訊息的 NBR 在恢復速率的估計上確實更接近冠層覆蓋率的恢復，對於高度木本覆蓋的情況下仍存在飽和問題，缺乏區辨複雜結構差異的能力。僅使用植生指標來估計恢復速率顯然會得

表 3 相關文獻估計森林復育時間表

研究文獻	干擾類型	復育指標	森林復育時間 (yr)
Morresi <i>et al.</i> (2019)	野火	NDVI	11.10 ~ 12.18
		NDMI	10.08 ~ 11.53
		NBR	10.73 ~ 11.85
		NBR2	11.12 ~ 12.36
		FRI2	15.69 ~ 15.58
Shen <i>et al.</i> (2020)	崩塌	NDVI	5
Yunus <i>et al.</i> (2020)	崩塌	NDVI	18
Chompuchan & Lin (2017)	野火	NBR	23.38 ~ 27.29
		SWIR Band	4.8
Pickell <i>et al.</i> (2016)	野火、伐林	NBR	5.6
		NDVI	2.7
		TCG	1.7
		NDVI	5
Hislop <i>et al.</i> (2018)	野火	SAVI	5
		TCG	5
		TCA	5
		NBR	8
		NDMI	7
		TCW	8
		NBR2	9
		Jin <i>et al.</i> (2012)	野火
Cuevas-González <i>et al.</i> (2009)	野火	NDVI	> 13
		NDSWIR	> 13
Chu <i>et al.</i> (2016)	野火	FRI	30 ~ 47
Bartels <i>et al.</i> (2016)	野火、伐林	Canopy cover ratio (CCR)	50
		Tree height	100
		Basal area (BA)	200
		Basal area (BA)	15
Suganuma & Durigan (2015)	放牧、伐林	Canopy cover ratio (CCR)	30
		Total density of tree species	51
		Species richness	70
Okuda <i>et al.</i> (2019)	伐林	Canopy height	80
Senf & Seidl (2022)	暴風、蟲害、野火	Canopy cover ratio (CCR)	10 ~ >100

到過於樂觀的結果，然而光學影像容易取得且有大量歷史紀錄，以植生光譜來監測地表植被恢復仍是經濟簡單的作法；另一方面，植生指標對於檢測演替前期的植物相變化相當敏感，應用在植被復育分析仍具有很大的價值 (Chu & Guo, 2013、Fairbanks & McGwire, 2004、Hernández-Clemente *et al.*, 2009)。隨開放資料的發展，日後將有更多機會以低成本取得 LiDAR 或合成孔徑雷達 (Synthetic aperture radar, SAR) 資料，可望透過這些遙測材料進一步補充植被結構訊息。譬如高密度點雲的 LiDAR 資料得以估計更多樣的植被結構屬性，包含樹木胸徑 (Diameter at breast height, DBH)、葉面積指數 (Leaf area index, LAI)、高度百分位 (Height percentile) 與冠層返回密度 (Canopy return density) 等 (Liu *et al.*, 2018、Véga *et al.*, 2016)，或者由 SAR 的偏極訊號結合多光譜資訊建模，來估計更大時空尺度的植被結構變化 (García *et al.*, 2018、Shao *et al.*, 2017)。以更高的頻率獲取多樣化的結構訊息，將更清楚地釐清復育植被的組成、細部的冠層特徵與生物量的變化，有助於更全面地評估森林復育動態，並連結生態系功能的恢復討論。

## 5. 結論

時間序列光學影像提供了連續且密集的地表資訊，利用植被光譜特性設計的植生指標適合用來追蹤干擾後的植被再生情形。受到飽和效應的影響，植生指標對演替中後期的植被發展不敏感，容易高估恢復速率，即使是使用了對木本植被敏感的短波紅外光組合植生指標，仍然無法反映演替森林的結構變化，因此僅適合在演替初期階段應用。空載光達能準確量測冠層結構，並衍生結構指標來評估復育植被的發展，但受限於成本與獲取頻率難以長期全面的觀測。結合植生光譜變量來模擬冠層結構是可行的方法，機器學習模型雖然受到光譜變量的限制而有所偏估，仍可有效反演植被冠層結構變化，在時序軌跡擬合的方法下，降低模擬歧異值的影響，呈現冠層結構的增長趨勢並估計恢復速率。大規模崩塌的恢復速率並未比其他林分替代干擾要來的

快或慢，良好恢復位置有明顯的演替發展，預估百年內可以達到成熟林分的水準。由於崩塌復育不是空間均衡發展的過程，受到多重因素所控制，許多復育位置不見得會發生演替序列變化，導入時間序列的遙測方法能剖析局部區位的發展狀況，並整合植生光譜與結構訊息來更好地推論整體復育進程。

## 參考文獻

- 宋承恩、王韻皓、林國聖、王培蓉、詹進發、陳毅青、王素芬，2022。以多時期衛星影像及樹冠高程模型分析崩塌植生復育與影響因素，農業工程學報，68(4)：44-62，DOI：10.29974/JTAE.202212\_68(4).0006。[Song, C.E., Wang, U.H., Lin, G.S., Wang, P.J., Jan, J.F., Chen, Y.C., and Wang, S.F., 2022. Analysis of the vegetation recovery and influencing factors for landslide restoration using multi-temporal satellite imagery and canopy height model, Journal of Taiwan Agricultural Engineering, 68(4): 44-62, DOI: 10.29974/JTAE.202212\_68(4).0006. (in Chinese)]
- 林國聖、宋承恩、王素芬，2023。森林崩塌復育及影響因子分析，航測及遙測學刊，28(3)：157-175，DOI：10.6574/JPRS.202309\_28(3).0002。[Lin, G.H., Song, C.E., and Wang, S.F., 2023. Analysis of forest restoration after landslide and the influencing factors, Journal of Photogrammetry and Remote Sensing, 28(3): 157-175, DOI: 10.6574/JPRS.202309\_28(3).0002. (in Chinese)]
- Ahmed, O.S., Franklin, S.E., Wulder, M.A., and White, J.C., 2015. Characterizing stand-level forest canopy cover and height using Landsat time series, samples of airborne LiDAR, and the Random Forest algorithm, ISPRS Journal of Photogrammetry and Remote Sensing, 101: 89-101, DOI: 10.1016/j.isprsjprs.2014.11.007.
- Banskota, A., Kayastha, N., Falkowski, M.J., Wulder, M.A., Froese, R.E., and White, J.C., 2014. Forest

- monitoring using Landsat time series data: A review, *Canadian Journal of Remote Sensing*, 40(5): 362-384, DOI: 10.1080/07038992.2014.987376.
- Bartels, S.F., Chen, H.Y., Wulder, M.A., and White, J.C., 2016. Trends in post-disturbance recovery rates of Canada's forests following wildfire and harvest, *Forest Ecology and Management*, 361: 194-207, DOI: 10.1016/j.foreco.2015.11.015.
- Bolton, D.K., Tompalski, P., Coops, N.C., White, J.C., Wulder, M.A., Hermosilla, T., Queinnec, M., Luther, J.E., van Lier, O.R., Fournier, R.A., Woods, M., Treitz, P.M., van Ewijk, K.Y., Graham, G., and Quist, L., 2020. Optimizing Landsat time series length for regional mapping of lidar-derived forest structure, *Remote Sensing of Environment*, 239, 111645, DOI: 10.1016/j.rse.2020.111645.
- Bolton, D.K., White, J.C., Wulder, M.A., Coops, N.C., Hermosilla, T., and Yuan, X., 2018. Updating stand-level forest inventories using airborne laser scanning and Landsat time series data, *International Journal of Applied Earth Observation and Geoinformation*, 66: 174-183, DOI: 10.1016/j.jag.2017.11.016.
- Breiman, L., 2001. Random forests, *Machine Learning*, 45(1): 5-32, DOI: 10.1023/A:1010933404324.
- Chen, G., and Hay, G.J., 2011. A support vector regression approach to estimate forest biophysical parameters at the object level using airborne lidar transects and quickbird data, *Photogrammetric Engineering & Remote Sensing*, 77(7): 733-741, DOI: 10.14358/PERS.77.7.733.
- Chompuchan, C., and Lin, C.Y., 2017. Assessment of forest recovery at Wu-Ling fire scars in Taiwan using multi-temporal Landsat imagery, *Ecological Indicators*, 79: 196-206, DOI: 10.1016/j.ecolind.2017.04.038.
- Chu, T., and Guo, X., 2013. Remote sensing techniques in monitoring post-fire effects and patterns of forest recovery in boreal forest regions: A review, *Remote Sensing*, 6(1): 470-520, DOI: 10.3390/rs6010470.
- Chu, T., Guo, X., and Takeda, K., 2016. Remote sensing approach to detect post-fire vegetation regrowth in Siberian boreal larch forest, *Ecological Indicators*, 62: 32-46, DOI: 10.1016/j.ecolind.2015.11.026.
- Crist, E.P., 1985. A TM tasseled cap equivalent transformation for reflectance factor data, *Remote Sensing of Environment*, 17(3): 301-306, DOI: 10.1016/0034-4257(85)90102-6.
- Cuevas-González, M.A.R.Í.A., Gerard, F., Balzter, H., and Riano, D., 2009. Analysing forest recovery after wildfire disturbance in boreal Siberia using remotely sensed vegetation indices, *Global Change Biology*, 15(3): 561-577, DOI: 10.1111/j.1365-2486.2008.01784.x.
- de Beurs, K.M., McThompson, N.S., Owsley, B.C., and Henebry, G.M., 2019. Hurricane damage detection on four major Caribbean islands, *Remote Sensing of Environment*, 229: 1-13, DOI: 10.1016/j.rse.2019.04.028.
- Drake, J.B., Dubayah, R.O., Clark, D.B., Knox, R.G., Blair, J.B., Hofton, M.A., Chazdon, R.L., Weishampel, J.F., and Prince, S., 2002. Estimation of tropical forest structural characteristics using large-footprint lidar, *Remote Sensing of Environment*, 79(2-3): 305-319, DOI: 10.1016/S0034-4257(01)00281-4.
- Duane, M.V., Cohen, W.B., Campbell, J.L., Hudiburg, T., Turner, D.P., and Weyerhann, D.L., 2010. Implications of alternative field-sampling designs on Landsat-based mapping of stand age and carbon stocks in Oregon forests, *Forest Science*, 56(4): 405-416, DOI: 10.1093/forestscience/56.4.405.
- Fairbanks, D.H., and McGwire, K.C., 2004. Patterns of



- floristic richness in vegetation communities of California: Regional scale analysis with multi-temporal NDVI, *Global Ecology and Biogeography*, 13(3): 221-235, DOI: 10.1111/j.1466-822X.2004.00092.x.
- Footy, G.M., Cutler, M.E., McMorrow, J., Pelz, D., Tangki, H., Boyd, D.S., and Douglas, I.A.N., 2001. Mapping the biomass of Bornean tropical rain forest from remotely sensed data, *Global Ecology and Biogeography*, 10(4): 379-387, DOI: 10.1046/j.1466-822X.2001.00248.x.
- García, M., Saatchi, S., Ustin, S., and Balzter, H., 2018. Modelling forest canopy height by integrating airborne LiDAR samples with satellite Radar and multispectral imagery, *International Journal of Applied Earth Observation and Geoinformation*, 66: 159-173, DOI: 10.1016/j.jag.2017.11.017.
- Glenn, E.P., Huete, A.R., Nagler, P.L., and Nelson, S.G., 2008. Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: What vegetation indices can and cannot tell us about the landscape, *Sensors*, 8(4): 2136-2160, DOI: 10.3390/s8042136.
- Gómez, C., White, J.C., and Wulder, M.A., 2011. Characterizing the state and processes of change in a dynamic forest environment using hierarchical spatio-temporal segmentation, *Remote Sensing of Environment*, 115(7): 1665-1679, DOI: 10.1016/j.rse.2011.02.025.
- Hamed, K.H., and Rao, A.R., 1998. A modified Mann-Kendall trend test for autocorrelated data, *Journal of Hydrology*, 204(1-4): 182-196, DOI: 10.1016/S0022-1694(97)00125-X.
- Healey, S.P., Cohen, W.B., Zhiqiang, Y., and Krankina, O.N., 2005. Comparison of Tasseled Cap-based Landsat data structures for use in forest disturbance detection, *Remote Sensing of Environment*, 97(3): 301-310, DOI: 10.1016/j.rse.2005.05.009.
- Hernández-Clemente, R., Navarro Cerrillo, R.M., Hernandez-Bermejo, J.E., Escuin Royo, S., and Kasimis, N.A., 2009. Analysis of postfire vegetation dynamics of Mediterranean shrub species based on terrestrial and NDVI data, *Environmental Management*, 43: 876-887, DOI: 10.1007/s00267-008-9260-x.
- Hislop, S., Jones, S., Soto-Berelev, M., Skidmore, A., Haywood, A., and Nguyen, T.H., 2018. Using landsat spectral indices in time-series to assess wildfire disturbance and recovery, *Remote Sensing*, 10(3), 460, DOI: 10.3390/rs10030460.
- Huang, C., Wylie, B., Yang, L., Homer, C., and Zylstra, G., 2002. Derivation of a tasseled cap transformation based on Landsat 7 at-satellite reflectance, *International Journal of Remote Sensing*, 23(8): 1741-1748, DOI: 10.1080/01431160110106113.
- Hudak, A.T., Lefsky, M.A., Cohen, W.B., and Berterretche, M., 2002. Integration of lidar and Landsat ETM+ data for estimating and mapping forest canopy height, *Remote Sensing of Environment*, 82(2-3): 397-416, DOI: 10.1016/S0034-4257(02)00056-1.
- Jacques, D.C., Kergoat, L., Hiernaux, P., Mougín, E., and Defourny, P., 2014. Monitoring dry vegetation masses in semi-arid areas with MODIS SWIR bands, *Remote Sensing of Environment*, 153: 40-49, DOI: 10.1016/j.rse.2014.07.027.
- Jin, Y., Randerson, J.T., Goetz, S.J., Beck, P.S., Loranty, M.M., and Goulden, M.L., 2012. The influence of burn severity on postfire vegetation recovery and albedo change during early succession in North American boreal forests, *Journal of Geophysical Research: Biogeosciences*, 117(G1), DOI: 10.1029/2011JG001886.
- João, T., João, G., Bruno, M., and João, H., 2018. Indicator-based assessment of post-fire recovery


- dynamics using satellite NDVI time-series, *Ecological Indicators*, 89: 199-212, DOI: 10.1016/j.ecolind.2018.02.008.
- Liu, K., Shen, X., Cao, L., Wang, G., and Cao, F., 2018. Estimating forest structural attributes using UAV-LiDAR data in Ginkgo plantations, *ISPRS Journal of Photogrammetry and Remote Sensing*, 146: 465-482, DOI: 10.1016/j.isprsjprs.2018.11.001.
- Ma, Q., Su, Y., Luo, L., Li, L., Kelly, M., and Guo, Q., 2018. Evaluating the uncertainty of Landsat-derived vegetation indices in quantifying forest fuel treatments using bi-temporal LiDAR data, *Ecological Indicators*, 95: 298-310, DOI: 10.1016/j.ecolind.2018.07.050.
- Massetti, A., Rüdiger, C., Yebra, M., and Hilton, J., 2019. The Vegetation Structure Perpendicular Index (VSPI): A forest condition index for wildfire predictions, *Remote Sensing of Environment*, 224: 167-181, DOI: 10.1016/j.rse.2019.02.004.
- Matasci, G., Hermosilla, T., Wulder, M.A., White, J.C., Coops, N.C., Hobart, G.W., Bolton, D.K., Tompalski, P., and Bater, C.W., 2018. Three decades of forest structural dynamics over Canada's forested ecosystems using Landsat time-series and lidar plots, *Remote Sensing of Environment*, 216: 697-714, DOI: 10.1016/j.rse.2018.07.024.
- Morresi, D., Vitali, A., Urbinati, C., and Garbarino, M., 2019. Forest spectral recovery and regeneration dynamics in stand-replacing wildfires of central Apennines derived from Landsat time series, *Remote Sensing*, 11(3), 308, DOI: 10.3390/rs11030308.
- Muro, J., Strauch, A., Heinemann, S., Steinbach, S., Thonfeld, F., Waske, B., and Dieckkrüger, B., 2018. Land surface temperature trends as indicator of land use changes in wetlands, *International Journal of Applied Earth Observation and Geoinformation*, 70: 62-71, DOI: 10.1016/j.jag.2018.02.002.
- Okuda, T., Yamada, T., Hosaka, T., Miyasaku, N., Hashim, M., Lau, A.M.S., and Saw, L.G., 2019. Canopy height recovery after selective logging in a lowland tropical rain forest, *Forest Ecology and Management*, 442: 117-123, DOI: 10.1016/j.foreco.2019.03.045.
- Pickell, P.D., Hermosilla, T., Frazier, R.J., Coops, N.C., and Wulder, M.A., 2016. Forest recovery trends derived from Landsat time series for North American boreal forests, *International Journal of Remote Sensing*, 37(1): 138-149, DOI: 10.1080/2150704X.2015.1126375.
- Senf, C., and Seidl, R., 2022. Post-disturbance canopy recovery and the resilience of Europe's forests, *Global Ecology and Biogeography*, 31(1): 25-36, DOI: 10.1111/geb.13406.
- Senf, C., Müller, J., and Seidl, R., 2019. Post-disturbance recovery of forest cover and tree height differ with management in Central Europe, *Landscape Ecology*, 34(12): 2837-2850, DOI: 10.1007/s10980-019-00921-9.
- Shao, Z., Zhang, L., and Wang, L., 2017. Stacked sparse autoencoder modeling using the synergy of airborne LiDAR and satellite optical and SAR data to map forest above-ground biomass, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(12): 5569-5582, DOI: 10.1109/JSTARS.2017.2748341.
- Shen, P., Zhang, L.M., Fan, R.L., Zhu, H., and Zhang, S., 2020. Declining geohazard activity with vegetation recovery during first ten years after the 2008 Wenchuan earthquake, *Geomorphology*, 352, 106989, DOI: 10.1016/j.geomorph.2019.106989.
- Smith, A.M., Falkowski, M.J., Hudak, A.T., Evans, J.S., Robinson, A.P., and Steele, C.M., 2009. A cross-comparison of field, spectral, and lidar estimates of forest canopy cover, *Canadian*

- Journal of Remote Sensing, 35(5): 447-459, DOI: 10.5589/m09-038.
- Song, C., and Woodcock, C.E., 2003. Monitoring forest succession with multitemporal Landsat images: Factors of uncertainty, IEEE Transactions on Geoscience and Remote Sensing, 41(11): 2557-2567, DOI: 10.1109/TGRS.2003.818367.
- Suganuma, M.S., and Durigan, G., 2015. Indicators of restoration success in riparian tropical forests using multiple reference ecosystems, Restoration Ecology, 23(3): 238-251, DOI: 10.1111/rec.12168.
- Véga, C., Renaud, J.P., Durrieu, S., and Bouvier, M., 2016. On the interest of penetration depth, canopy area and volume metrics to improve Lidar-based models of forest parameters, Remote Sensing of Environment, 175: 32-42, DOI: 10.1016/j.rse.2015.12.039.
- Viana-Soto, A., García, M., Aguado, I., and Salas, J., 2022. Assessing post-fire forest structure recovery by combining LiDAR data and Landsat time series in Mediterranean pine forests, International Journal of Applied Earth Observation and Geoinformation, 108, 102754, DOI: 10.1016/j.jag.2022.102754.
- Wang, Z., Wei, C., Liu, X., Zhu, L., Yang, Q., Wang, Q., Zhang, Q., and Meng, Y., 2022. Object-based change detection for vegetation disturbance and recovery using Landsat time series, GIScience & Remote Sensing, 59(1): 1706-1721, DOI: 10.1080/15481603.2022.2129870.
- White, J.C., Coops, N.C., Wulder, M.A., Vastaranta, M., Hilker, T., and Tompalski, P., 2016. Remote sensing technologies for enhancing forest inventories: A review, Canadian Journal of Remote Sensing, 42(5): 619-641, DOI: 10.1080/07038992.2016.1207484.
- White, J.C., Saarinen, N., Kankare, V., Wulder, M.A., Hermosilla, T., Coops, N.C., Pickell, P.D., Holopainen, M., Hyypä, J., and Vastaranta, M., 2018. Confirmation of post-harvest spectral recovery from Landsat time series using measures of forest cover and height derived from airborne laser scanning data, Remote Sensing of Environment, 216: 262-275, DOI: 10.1016/j.rse.2018.07.004.
- White, J.C., Wulder, M.A., Hermosilla, T., Coops, N.C., and Hobart, G.W., 2017. A nationwide annual characterization of 25 years of forest disturbance and recovery for Canada using Landsat time series, Remote Sensing of Environment, 194: 303-321, DOI: 10.1016/j.rse.2017.03.035.
- Wulder, M.A., Hall, R.J., Coops, N.C., and Franklin, S.E., 2004. High spatial resolution remotely sensed data for ecosystem characterization, BioScience, 54(6): 511-521, DOI: 10.1641/0006-3568(2004)054[0511:HSRRSD]2.0.CO;2.
- Yunus, A.P., Fan, X., Tang, X., Jie, D., Xu, Q., and Huang, R., 2020. Decadal vegetation succession from MODIS reveals the spatio-temporal evolution of post-seismic landsliding after the 2008 Wenchuan earthquake, Remote Sensing of Environment, 236, 111476, DOI: 10.1016/j.rse.2019.111476.
- Zhai, Y., Roy, D.P., Martins, V.S., Zhang, H.K., Yan, L., and Li, Z., 2022. Conterminous United States Landsat-8 top of atmosphere and surface reflectance tasseled cap transformation coefficients, Remote Sensing of Environment, 274, 112992, DOI: 10.1016/j.rse.2022.112992.
- Zhu, Z., 2017. Change detection using landsat time series: A review of frequencies, preprocessing, algorithms, and applications, ISPRS Journal of Photogrammetry and Remote Sensing, 130: 370-384, DOI: 10.1016/j.isprsjprs.2017.06.013.

# 附錄

補充資料表 1 光學衛星影像材料拍攝時間列表

SPOT-4							
2009/09/01	2010/02/10	2010/08/2	2010/12/10	2011/07/05	2011/10/28	2012/03/05	2012/10/05
2009/10/17	2010/05/10	2010/09/22	2011/04/02	2011/09/16	2011/12/18	2012/03/06	2012/11/10
2009/10/28	2010/05/21	2010/11/02	2011/06/09	2011/09/26	2012/01/08	2012/07/03	2012/11/16
SPOT-5							
2009/12/12	2010/04/01	2011/01/17	2012/03/29	2012/12/18	2013/04/02	2013/12/01	
2010/02/28	2010/08/14	2011/02/27	2012/04/13	2013/02/19	2013/06/02	2014/01/23	
2010/03/06	2010/11/21	2012/02/05	2012/10/23	2013/03/17	2013/09/09	2015/02/28	
SPOT-6							
2015/04/14	2016/10/02	2017/04/16	2019/04/07	2020/05/03	2021/05/09	2021/09/30	
2015/10/01	2016/12/14	2017/04/18	2019/04/25	2020/10/13	2021/05/16	2022/03/05	
2016/06/17	2017/01/30	2018/09/20	2019/12/08	2020/11/18	2021/09/04		
SPOT-7							
2015/05/09	2016/03/30	2017/02/19	2018/12/01	2019/08/27	2020/03/01	2021/03/17	2021/08/27
2016/01/26	2016/11/19	2017/07/11	2019/07/30	2019/10/28	2021/02/02	2021/07/01	2021/12/04
Landsat-5				Landsat-7			
2009/09/12	2010/1/18	2010/09/15	2011/02/06	2012/02/01	2012/10/14	2012/11/15	
2009/10/30	2010/02/03	2010/12/20	2011/10/20				
Landsat-8							
2013/06/03	2014/11/29	2015/12/02	2017/10/20	2018/11/08	2020/01/14	2021/05/08	2022/03/08
2013/07/05	2014/12/31	2016/06/27	2017/12/23	2019/01/11	2020/02/15	2021/08/28	2022/04/25
2013/08/06	2015/02/01	2016/12/04	2018/03/13	2019/02/12	2020/03/02	2021/09/29	2022/11/19
2014/03/18	2015/03/05	2017/01/05	2018/04/14	2019/06/20	2020/05/05	2021/10/31	2022/12/21
2014/08/25	2015/06/09	2017/06/30	2018/05/16	2019/11/11	2020/10/28	2021/11/16	2023/02/23
2014/10/28	2015/11/16	2017/08/17	2018/09/21	2019/12/13	2021/02/01	2022/01/03	
Landsat-9							
2021/12/10	2022/01/27	2022/02/12	2022/02/28	2022/07/22	2023/01/14	2023/04/04	
Sentinel-2							
2016/07/20	2017/08/14	2018/05/26	2019/04/11	2020/04/20	2020/12/01	2021/07/04	2022/06/19
2016/10/28	2017/10/28	2018/06/25	2019/11/17	2020/05/15	2020/12/26	2021/08/23	2022/09/27
2016/11/17	2017/11/17	2018/09/03	2019/12/17	2020/06/19	2021/01/20	2021/09/27	2023/03/16
2017/01/06	2018/01/16	2018/11/07	2020/01/16	2020/07/19	2021/03/01	2021/11/06	
2017/02/15	2018/02/20	2018/12/02	2020/02/20	2020/09/07	2021/03/26	2021/12/11	
2017/07/05	2018/03/12	2019/02/15	2020/03/21	2020/10/02	2021/04/15	2022/01/15	
2017/07/25	2018/05/06	2019/03/22	2020/03/26	2020/11/01	2021/05/15	2022/03/11	



補充資料圖 1 災後 15 年復育位置的植生特徵概況圖

# Evaluating Recovery Rate Differences between Vegetation Structure and Spectral Indices in Large-Scale Landslides Using Time Series Remote Sensing Data

Cheng-En Song<sup>1\*</sup> Su-Fen Wang<sup>2</sup> Yi-Chin Chen<sup>3</sup>

## Abstract

This study developed a canopy structure estimation model based on time-series vegetation spectral variables to detect vegetation recovery in large-scale landslides and compare the recovery rates between vegetation indices and canopy structure. The analysis showed that the machine learning model effectively simulates canopy structure, achieving an  $R^2$  of over 0.9 between simulated and observed values, enabling predictions of vegetation structural changes across broad spatial and temporal scales. The recovery trajectories of vegetation spectral indices and canopy structure revealed high variability in successional progress, with only approximately 14% of the landslide surface expected to recover to a mature forest state. The recovery of vegetation indices highlights saturation effects, tending to overestimate recovery rates and suggesting that well-restored vegetation could reach a mature forest state within 15 years. In contrast, canopy structure could require several decades to centuries to fully develop. Thus, vegetation indices are suitable for assessing early successional stages, while long-term restoration monitoring must also consider structural changes. Integrating spectral and structural information will facilitate a more comprehensive evaluation of restoration dynamics.

**Keywords:** Time-series, Vegetation index, Canopy structure, Machine learning, Landslide restoration

---

<sup>1</sup> Ph.D., Department of Geography, National Changhwa University of Education

<sup>2</sup> Professor, Department of Geography, National Changhwa University of Education

<sup>3</sup> Associate Professor, Department of Geography, National Changhwa University of Education

\* Corresponding Author, E-mail: pths5000@gmail.com

Received Date: Sep. 26, 2024

Revised Date: Oct. 22, 2024

Accepted Date: Nov.01, 2024

# 深度學習影像特徵匹配應用於無人機影像視覺定位

鄒來翰<sup>1\*</sup> 林昭宏<sup>2</sup>

## 摘要

當無人機 (unmanned aerial vehicle, UAV) 配備之定位及定向設備無作用時，可使用影像視覺定位技術單以影像共軛點進行空間後方交會推導載具外方位。本研究提出影像視覺定位流程，並改善使用深度學習模型特徵點匹配時因影像間平面旋轉而匹配成功率大幅降低地問題。加入資料擴增隨機旋轉影像，以特徵萃取模型提取特徵後輸入匹配模型學習。另外，透過提出內插法以及可學習參數法將原本用於匹配之特徵描述符替換為傳統特徵描述符，使其具有旋轉不變性。萃取影像中之特徵點並進行匹配後，可用一般傳統攝影測量空間後方交會求解位於載具上的相機 6 個外方位元素，進行載具定位。經本文影像視覺定位流程，解算外方位平面位置誤差最佳可達 3 m、姿態角誤差最佳可達 1.3°。

**關鍵詞：**深度學習、特徵萃取、影像匹配、視覺定位、旋轉不變性

## 1. 前言

現代大部分無人機都配備了全球定位系統 (Global Positioning System, GPS) 和慣性測量單元 (Inertial measurement unit, IMU) 等定位及定向設備，以確保飛行過程中的精確導航和定位。然而，在戰爭時期或存在遮蔽物的環境中，這些定位系統可能會失效，因此需要使用影像視覺地形輔助定位技術來解決問題。該技術是一種不依賴於傳統定位系統的技術，僅通過搭載的攝影鏡頭對地面拍攝取得即時航拍影像，並與參考影像匹配特徵共軛點，進行空間後方交會來推導載具的外方位元素。這種技術在無人機航拍影像應用中尤為重要，特別是在 GPS 信號受阻或干擾的情況下，能夠提供可靠的定位和導航解決方案。無人機的自主導航依賴於精確的路徑規劃演算法，目前許多基於圖論 (graph) 的演算法被廣泛應用於此領域，例如 Dijkstra (Luo *et al.*, 2020) 以及 A\* (Ju *et al.*, 2020) 等演算法，都被廣泛應用於搜尋最短路徑。隨後，D\* Lite 演算法 (Chang *et al.*, 2023) 作為 Dijkstra 和 A\* 的改進版本問世，進一步提升了路徑規劃的效率和靈活性。影

像視覺定位技術使無人機能夠在任務執行過程中即時計算自身位置，結合路徑規劃技術可實現自主飛行準確抵達目的地。

有關無人機影像輔助定位，根據研究 (黃敬群及黃偉立，2012、Lin & Medioni, 2007) 所提出的方法，透過影像匹配計算影像之間的對應關係，便可將一序列的無人機影像對應至衛星影像上，之後可透過座標系統的轉換進行無人機位置的計算。Chen *et al.* (2021a) 提出在無 GPS 的環境中快速且穩定的對無人機進行地理定位之框架，該研究將衛星影像事先透過深度學習模型編碼為全域描述符並封裝成資料庫裝載於無人機上，無人機拍攝影像後也會透過相同的方式進行編碼，並透過描述符於資料庫中搜尋相似之影像，並使用深度學習影像匹配演算法對無人機影像與搜索到的衛星影像進行匹配後求解無人機外方位，該方法將能夠運算的先執行以簡化運算的負荷，以達到近乎實時的定位方式。以上方式皆有使用到影像匹配技術，也說明使用無人機進行影像視覺定位時，與具地理座標之衛星影像之間的轉換關係，需透過影像匹配技術達成，如何獲取足夠且穩固的特徵點為研究的重要目標。

<sup>1</sup> 國立成功大學測量及空間資訊學系 碩士

<sup>2</sup> 國立成功大學測量及空間資訊學系 教授

\* 通訊作者, E-mail: ha095863@gmail.com

收到日期：民國 113 年 09 月 16 日

修改日期：民國 113 年 10 月 08 日

接受日期：民國 113 年 10 月 21 日

無人機的定位由六個外方位元素（包括位置和姿態）決定，可由空間後方交會解算獲得。空間後方交會解算需要特徵共軛點，主要依賴於影像特徵萃取和匹配技術。傳統的特徵偵測和描述演算法如 SIFT (Low, 2004)、SURF (Bay *et al.*, 2006) 等透過計算灰度值梯度萃取影像中特徵點的位置及描述特徵結構。特徵匹配負責比較前述萃取之特徵點描述符並找出對應的匹配關係，如 Brute-Force Matching，直接計算所有特徵點描述符之間的距離，並選擇距離最小的那一對作為匹配。FLANN (Muja & Lowe, 2009) 則專為高維度數據的最近鄰搜索。然而，傳統方法由於使用影像灰度值，容易受光影、亮度等影響，使得它們在面對複雜場景時性能和精度仍然存在一些局限。隨著時間的推移和技術的進步，深度學習相關的研究得到了迅速發展，並在計算機視覺領域取得了顯著的成果。深度學習 (Deep Learning) 方法能夠自動從數據中學習特徵表示，提高匹配的精度和穩定性，且因其可學習參數的特性，能夠針對特定領域進行特化和改善。如針對無人機航拍影像的應用，可用航拍影像訓練資料集使模型對於航拍影像的推演任務表現提升，使得深度學習方法於特徵萃取與匹配之表現相比於傳統方法更加穩定且精度較高 (Ma *et al.*, 2021)。眾多特徵提取之深度學習模型，其中監督式的方法，如 Lift (Yi *et al.*, 2016)、Tilde (Verdie *et al.*, 2015) 等，可能使得模型受限於人為錨點的設計而難以提出新的特徵點。自監督式學習的特徵點提取及描述模型 SuperPoint (DeTone *et al.*, 2018)，則只需要簡單的人為幫助進行預訓練。特徵匹配之深度學習模型，NCNet (Rocco *et al.*, 2020a)、Sparse-NCNet (Rocco *et al.*, 2020b) 等透過相關性比對匹配特徵。SGMNet 方法 (Chen *et al.*, 2021b) 引入種子點來引導圖匹配的過程，種子點是預先已知的匹配點，這些點在匹配過程中可以作為引導，幫助模型學習圖中其他點的對應關係。LoFTR 方法 (Sun *et al.*, 2021) 是一種不需描述符之匹配法，不需兩階段先提取特徵再匹配，模型可直接萃取全局資訊並產生密集匹配。

SuperGlue (Sarlin *et al.*, 2020) 則利用了自注意力與交叉注意力機制來分析空間分布關係增強特徵點之間的匹配。LightGlue (Lindenberger *et al.*, 2023) 為 SuperGlue 改進版，藉由對匹配難度自適應匹配提出更快速的匹配效率。由於 SuperGlue 模型相較其他模型輕量適合置入無人機，且經實測後 LightGlue 應用於航拍影像效率與 SuperGlue 相差甚小，因此本研究最終決定使用 SuperPoint 搭配 SuperGlue 的匹配流程，該改善模型訓練流程爾後也可應用於其他模型。

無人機執行任務時，以影像視覺定位方法決定自身位置，由於飛行方向的變化，不同航帶之間常會出現影像之間平面旋轉問題，導致使用深度學習匹配過程中的困難，因為影像中的特徵點在旋轉後的位置和方向都會發生變化。雖已有傳統匹配方法具有對旋轉的抵抗能力 (如 SIFT)，然而解算得外方位通常誤差較大且不穩定。欲使用深度學習匹配簡單之做法為每次旋轉 $90^\circ$ 無人機拍攝影像匹配一次，四個方向上匹配點數最多即作為匹配成果，雖可解決問題，但會大幅增加計算資源和時間的消耗。若能使用深度學習方法同時克服旋轉問題導致的匹配困難，可在獲得更精確定位之同時大幅降低所需計算時間與資源，使得解算更有效率。

本研究提出影像視覺地形輔助定位技術之自動化流程，將深度學習應用於特徵點匹配，並改良原本影像特徵萃取和匹配時需先對影像旋轉的問題，使得影像特徵匹配流程只需進行一次，減少計算資源和時間的消耗，使得影像視覺地形輔助定位技術更有效率。

## 2. 研究方法

本研究探討無人機地形輔助視覺定位應用如圖 1 所示，其流程可大致分為三個步驟：(1) 資料前處理，找出無人機影像對應參考影像位置與解析度一致化；(2) 匹配參考影像與無人機影像共軛特徵點；(3) 搭配 DSM 列出共線式，透過空間後方交會解算外方位。






圖 1 無人機地形輔助視覺定位詳細流程

## 2.1 資料前處理

由於無人機影像與參考影像之間像幅與拍攝範圍差距大，故匹配前須將參考影像裁切至適當大小且涵蓋地面位置與無人機影像重疊。此處可以影像檢索方法實現，如圖 2 所示。先將參考影像裁切成多張大小與無人機影像相當，再使用輕量化的模型如 MobileNet (Sinha & El-Sharkawy, 2019)，將裁切之參考影像萃取特徵圖並接上 NetVLAD (Arandjelovic *et al.*, 2016) 對影像產生一個全域特徵描述符 (Global Descriptor)，該描述符對整張影像的特徵進行描述，而後將所有參考影像之全域描述符組成一資料庫存入無人機機載記憶體中。無人機任務進行時可透過產生之無人機影像全域描述符於資料庫中檢索相似之參考影像，並選出前 N 個相似之參考影像，以利後續影像特徵點匹配步驟；同時也可根據檢索結果提供無人機影像之定位參數初始值，以利後續空間後方交會。




圖 2 影像檢索示意圖

此外，參考影像為帶有地理資訊之正射影像，地面空間解析度 (GSD) 與無人機影像解析度存在明顯差異，以本研究為例前者 0.5m，後者 0.0545m (影像資訊細節請見 3.2 節)，因此匹配前需先調降無人機影像解析度使其影像空間解析度一致化，避免影響匹配成果。本研究改善影像匹配之部分測試與分析，是直接將參考影像裁切，範圍以無人機本身拍攝時紀錄的外方位參數再加上參考影像地面空間解析度推算獲得，根據結果即可裁切出適當範圍之參考影像，同時外方位參數可做後續空間後方交會定位參數初始值。此外，資料部分還需 DSM (請見 3.2 節)，供後續空間後方交會解算。

本研究中之影像特徵點匹配方法使用的深度學習演算法 SuperPoint 以及 SuperGlue，前者以影像為輸入並提取其中特徵點與其描述符，後者輸入特徵點與其描述符並透過模型計算出其中之匹配關係。

## 2.2 影像特徵點萃取與匹配

本研究中影像特徵點匹配方法使用深度學習演算法 SuperPoint (DeTone *et al.*, 2018) 以及 SuperGlue (Sarlin *et al.*, 2020)，前者以影像為輸入並提取其中特徵點座標與其描述符，後者輸入特徵點座標與其描述符並透過模型計算出其中之匹配關係。

SuperPoint 為基於自監督式學習的特徵點之提取及描述器，可對一張影像提取其中特徵點之影像座標、信心值以及其固定長度之描述符，其架構如圖 3 所示。SuperPoint 之架構由全卷積神經網路構成 (fully-convolutional neural network)，並且

主要分為兩部分。第一部分為單一共享的編碼器 (encoder)，將輸入之影像維度降維處理；第二部分包含兩個解碼器 (decoder)，第一個解碼器提取特徵點之影像座標、信心值，第二個解碼器產生特徵點之描述符。第一部分之單一共享的編碼器 (encoder) 為一似 VGG 結構之編碼器，由 8 個  $3 \times 3$  之卷積層以及 3 個最大池化層 (Max-pooling) 組成。其中卷積層將影像之通道數從 1 提高到 256 維，而最大池化層使原本長寬為  $H \times W$  之影像縮小為  $H/8 \times W/8$ 。

第二部分包含兩個解碼器 (decoder)，分別輸入第一部份輸出之特徵圖，經過第一個解碼器後提取特徵點之影像座標、信心值 (Interest Point Decoder)。第二個解碼器提取特徵點之描述符 (Descriptor Decoder)。

第一個解碼器 Interest Point Decoder 將第一部分輸出之特徵圖通過卷積層後大小從原本  $H/8 \times W/8 \times 128$  轉換為  $H/8 \times W/8 \times 65$  之特徵圖。一個像素單元的通道深度 (channel depth) 從 128 轉換為 65 對應到原始影像  $8 \times 8$  像素的區域再加上一個額外的無特徵點放置區 (dustbin)。經過 Softmax

後，去除 dustbin 使其轉換為  $H/8 \times W/8 \times 64$  之特徵圖，最後轉換形狀 (reshape)，最後輸出結果為大小為  $H \times W \times 1$ ，每一個像素單元最多產生一特徵點座標  $x$ 、 $y$  以及該點之信心值  $c$ 。

第二個解碼器提取特徵點之描述符 (Descriptor Decoder)，將第一部分之特徵圖通過卷積層後大小從原本  $H/8 \times W/8 \times 128$  轉換為  $H/8 \times W/8 \times D$  ( $D$  一般預設為 256) 之描述向量，經過雙三次插值 (Bi-cubic interpolation) 以及正規化後 (L2-normalizes)，最後輸出結果轉換大小為  $H \times W \times D$ 。

SuperGlue 為一種匹配兩組特徵的神經網路，主要包含兩部分，其架構如圖 4 所示。第一部分為注意力圖像神經網路 (Attentional Graph Neural Network)，其中自注意力機制 (Self-attention) 中目標影像與參考影像上的候選特徵需與自身影像先行比較後，選出最具獨特性的特徵後，接著利用交叉注意力機制 (Cross-attention) 與參考影像上特徵進行比較。




圖 3 SuperPoint 模型架構




圖 4 SuperGlue 模型架構

注意力圖像神經網路 (Attentional Graph Neural Network) 承接 SuperPoint 最後的輸出，影像中之特徵點位置資訊 $p_i$  (包含特徵點之座標  $x$ 、 $y$ ，以及信心值  $c$ )、特徵點描述符 $d_i$  (預設為一維度為 256 之向量)，同時匹配兩張圖中之特徵點。如圖 4 所示， $(p_i^A, d_i^A)$  為圖 A 之特徵點  $i$  位置資訊以及描述符， $(p_j^B, d_j^B)$  為圖 B 之特徵點  $j$  位置資訊以及描述符。藉由將 $p_i$ 資訊與 $d_i$ 資訊整合，特徵點位置資訊 $p_i$ 先通過關鍵點編碼 (Keypoint Encoder) 提高位置資訊的維度再與描述符 $d_i$ 相加在一起。而後通過圖像神經網路 (Graph Neural Network, GNN) 及注意力機制分析點之間空間分布關係，以克服重複紋理之場景。注意力機制分為 (1) 自注意力機制 (Self-attention)，分析同一張影像中一特徵點與其他特徵點之間的關聯，使相似之各點具有其獨特性；(2) 交叉注意力機制 (Cross-attention)，分析一張影像中一特徵點與另一影像特徵點之間的關聯，比對較佳匹配。通過注意力機制後輸入第二部分最優匹配層，計算各點之間內積距離，最後輸出分數預測矩陣  $S$ 。並透過加入無特徵點放置區 (dustbin) 剔除無法匹配特徵點，如被遮蔽或視線不佳之特徵，以提升匹配之可靠度與穩定性。最後採用 Sinkhorn 演算法迭代數次，得到特徵點之最佳分配矩陣  $P$ 。

## 2.3 SuperPoint 描述符與 SIFT 描述符比較

SuperPoint 模型描述符由預設長度 256 的向量組成，表示一個維度 256 的特徵空間，描述圖像中特徵點周圍區域的訊息或數據結構，主要目的是在圖像之間找到相同或相似的特徵點。SIFT 尺度不變特徵變換演算法，通過計算特徵點周圍區域的梯度方向直方圖來生成描述符，對光照和噪聲有一定的抵抗性，對於尺度和旋轉也具有不變性，其特徵描述符由長度 128 的向量組成。

為比較兩種描述符的特性，將特徵向量以視覺化的方式使用極座標圖描繪出來。首先選定一張參考圖以及另一張目標影像如圖 5 所示，使用 SuperPoint 以及 SIFT 分別提取參考圖特徵點 (綠色原點) 座標及描述符；目標影像以  $90^\circ$  旋轉 3 次，於四個方向使用 SuperPoint 以及 SuperSIFT 分別提取參考圖特徵點座標及描述符。選取一同名點特徵，以極座標圖方式將特徵向量視覺描繪，結果如圖 6 所示。經比較後 SuperPoint 描述符除了  $0^\circ$  相對旋轉時參考與目標描述符相似，其餘旋轉角度皆無相似的描述符樣式；SIFT 描述符之參考與目標描述符於所有相對旋轉角度下皆展現相似描述符樣式。由於參考影像與目標影像原本就存在約  $20^\circ$  相對旋轉量，可推論 SuperPoint 描述符於小角度時擁有旋轉不變性，SIFT 描述符則於各種角度皆擁有旋轉不變性。

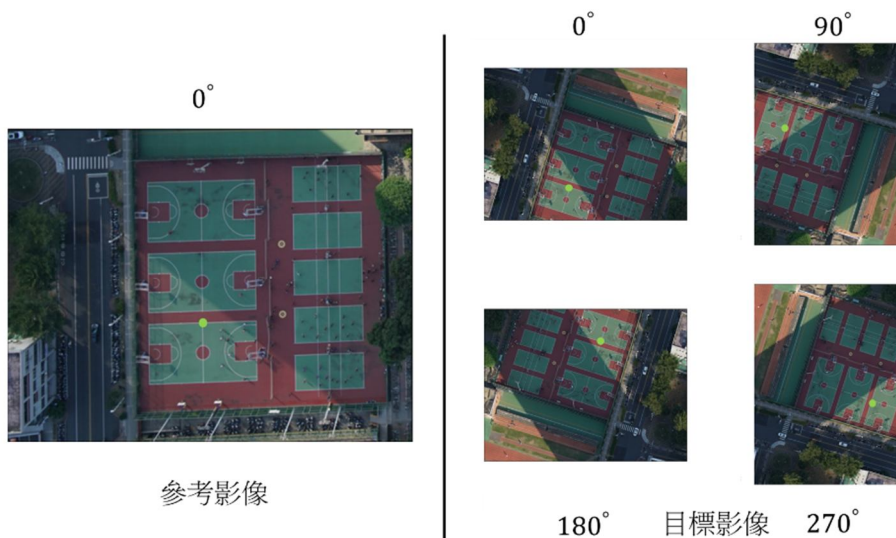


圖 5 左側為參考影像、右側為目標影像旋轉四個方向後結果，圖中角度為圖片旋轉角度

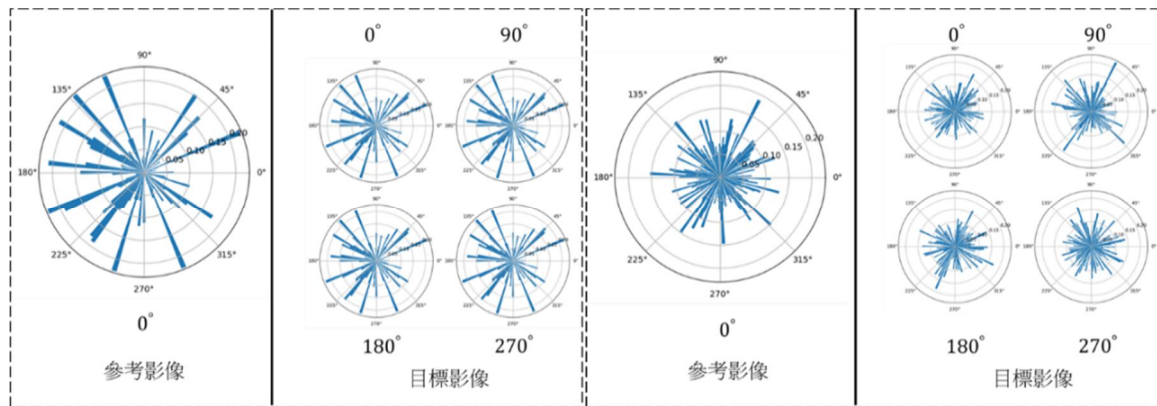


圖 6 左圖為 SuperPoint 描述符，右圖為 SIFT 描述符，圖中角度為圖片旋轉角度

## 2.4 SuperSIFT 與描述符提升維度

為改善匹配模型對於旋轉的抵抗性，採用 SIFT 描述符取代 SuperPoint 描述符，並取名為 SuperSIFT。由於 SuperPoint 之座標提取和特徵描述符萃取於模型中屬分枝的結構，可不使用特徵描述符分枝結果，於 SuperPoint 提取座標位置，並使用 SIFT 提取該位置描述符。使用 SuperSIFT 特徵訓練 SuperGlue 時，為使得模型收斂更快且匹配成果更好，訓練時採用 SuperGlue 預訓練模型，該模型使用 SuperPoint 特徵進行預訓練。SuperGlue 的結構中，第一部分通過特徵點編碼器，將座標點位置、信心值提升維度使其與描述符維度都為 256 後，相加聚合兩樣資訊再輸入注意力機制層。由於訓練時採用預訓練模型，且輸入特徵點描述符之維度一旦確定模型大小即不能變更，因此使用 SuperSIFT 提取特徵並訓練 SuperGlue 時，長度 128 之 SIFT 特徵點描述符需先經過描述符編碼器提升維度，才能與預訓練模型的大小相匹配，如圖 7 所示。描述符提升維度：本研究提出兩種方法分別為內插法以及可學習參數法。

### 2.4.1 內插法

SuperSIFT 特徵描述符維度為 128，而 SuperPoint 特徵描述符維度為 256 是 SIFT 特徵描述符兩倍的長度，內插法可用描述符向量中前後項兩兩相加並平均得到內插值，並且最後一項與第一項相加平均得到。圖 8 中數字部分為向量的索引，其中內插後描述符向量最後由 SuperSIFT 描述符最後

一個索引與第一個索引內插得到。此種提升維度的方法為非學習參數方法，不需要增加額外的模型參數量，結構較簡單且訓練也較快，內插方法計算容易，且不須微調模型即可使用經過資料擴增的訓練資料改善模型的旋轉抵抗性。然而此方法無法提供更多的特徵點描述資訊，因此本研究再提出另一個方法，並於後續比較與分析。

### 2.4.2 可學習參數法

可學習參數法則使模型自行學習如何提升 SuperSIFT 特徵描述符維度至與 SuperPoint 特徵描述符維度相同，如圖 9 所示。其結構由兩組可學習參數組成，每組由一層卷積層、一層 Batch Normalization、一層 Tanh 激活函數組成。SuperSIFT 特徵描述符向量值大約介於 $[0.2 \sim -0.2]$ ，Tanh 激活函數取值介於 $[-1, 1]$ ，因此相較於 Sigmoid、ReLU 等取值後大於 0 之激活函數，較能保留特徵描述符資訊因此更適合模型學習。

此方法須經過採用兩階段式的模型訓練 (如圖 10 所示)，目的是使得模型中的注意力機制層與最優匹配層也能學習適應 SuperSIFT 描述符。第一階段凍結除了提升維度部分以外的其他模型參數，並用較大的學習速度訓練模型，使得提升維度的編碼器部分適應 SuperSIFT 描述符與 SuperPoint 描述符的差別。第二階段模型訓練解除第一階段中凍結的參數後，同樣使用較小的學習速度微調整個模型，使得模型中的注意力機制層與最優匹配層學習適應 SIFT 描述符。




圖 7 左側為 SuperGlue 中原特徵編碼結構，右側為加入描述符提升維度後結構

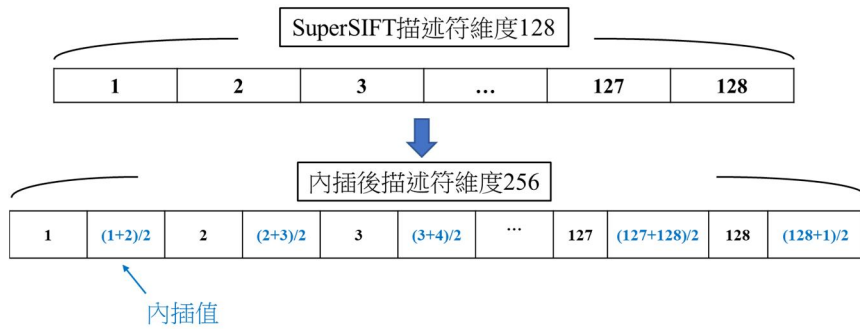


圖 8 內插法計算示意圖




圖 9 可學習參數法計算示意圖




圖 10 兩階段式的可學習參數訓練流程

## 2.5 匹配模型擴增訓練資料集

### 2.5.1 資料擴增

SuperGlue 模型訓練需要多組匹配特徵點對，包含特徵點的座標以及描述符。訓練資料中影像沒有相對旋轉，因此對於模型來說難以或無法推論影像有相對旋轉情形時的匹配。為增加模型對於旋轉的適應性，加入隨機角度的平面旋轉矩陣，以影像為中心旋轉影像，再輸入 SuperPoint 模型產生特徵點，比對後製作擴增訓練資料集。影像隨機旋轉以影像中心為基準， $\mathbf{M}$  為影像旋轉之轉換矩陣，則其轉換公式如下：

$$\mathbf{M} = \begin{bmatrix} \alpha & \beta & (1 - \alpha) * c_x - \beta * c_y \\ -\beta & \alpha & \beta * c_x + (1 - \alpha) * c_y \end{bmatrix} \dots\dots(1)$$

$$\alpha = scale * \cos \theta$$

$$\beta = scale * \sin \theta$$

其中， $c_x$ 、 $c_y$  為影像的中間點座標， $\theta$  為旋轉角度， $scale$  為縮放比例預設為 1。

### 2.5.2 擴增訓練資料集流程

本研究使用 GL3D 以及 Tourism 影像資料集訓練匹配模型 (細節請見 3.1 節)，其中紀錄每張影像之內、外方位參數，且紀錄相鄰兩影像間之重疊率、深度圖，使得影像對之間相對關係可確立。產生訓練 SuperGlue 模型訓練資料集，為使模型增加對於相對旋轉情境的適應能力，擴增訓練資料集製作步驟如圖 11 所示。

- (1) GL3D 成對的影像先經過介於某一區間之隨機旋轉，再使用 SuperPoint 提取每張影像中特徵點資訊，每個點包含其位置、信心度與其描述預設找出信心度最高之 2000 個點。
- (2) 訓練 SuperGlue 需輸入成對的特徵點，即兩張影像中的共軛點。由於使用內、外方位參數需要未經過旋轉之影像，使用  $\mathbf{M}^{-1}$  逆旋轉矩陣將經旋轉影像之特徵點逆轉換回無旋轉特徵位置。
- (3) 使用 GL3D 資料集提供之內、外方位參數及深度圖資訊，以投影方法比對特徵點，方法如下：現有兩張成對影像 A 和 B，各自有其內方位參

數矩陣  $\mathbf{K}_A$ 、 $\mathbf{K}_B$ ，深度圖  $Map_A$ 、 $Map_B$ ，外方位參數紀錄之相機姿態旋轉矩陣  $\mathbf{R}_A$ 、 $\mathbf{R}_B$  以及平移矩陣  $\mathbf{t}_A$ 、 $\mathbf{t}_B$ 。設影像 A 中有一特徵點  $p_A$ ，特徵點  $p_A$  為於影像 A 中在影像座標系下之特徵點座標，先透過內方位參數矩陣  $\mathbf{K}_A$  投影到相機坐標系 (cameracoordinate system)。

$$p_{camera\ coordinate\ system} = \mathbf{K}_A^{-1} p_A \dots\dots(2)$$

同時透過影像深度圖  $Map_A$  內插獲取特徵點  $p_A$  之深度值  $z$ ：

$$z = interpolate\_depth(p_A(x, y), Map_A) \dots\dots(3)$$

將特徵點  $p_{camera\ coordinate\ system}$  添加成齊次座標  $p_{Homogenous}$ ：

$$p_{Homogenous} = [p_{camera\ coordinate\ system}, 1] \dots\dots(4)$$

齊次座標乘以該特徵點深度計算三維座標  $p_{xyz}$ ：

$$p_{xyz} = p_{Homogenous} \cdot z \dots\dots(5)$$

使用旋轉矩陣  $\mathbf{dR}$  以及平移矩陣  $\mathbf{dt}$  進行座標變換：

$$p_{xyz}' = \mathbf{dR} \cdot p_{xyz} + \mathbf{dt} \dots\dots(6)$$

其中  $\mathbf{dR} = \mathbf{R}_B \cdot \mathbf{R}_A^{-1}$ ， $\mathbf{dt} = \mathbf{t}_B - \mathbf{dR} \cdot \mathbf{t}_A$

將三維座標  $p_{xyz}'$  投影到影像 B 之相機座標系：

$$p' = \frac{p_{xy}'}{p_z'} \dots\dots(7)$$

將投影特徵點從相機坐標系投影到影像座標系：

$$p_B = \mathbf{K}_A p' \dots\dots(8)$$

依據上述過程將 A 影像特徵點投影到 B 影像，並根據歐基里得距離取一閾值，若小於該閾值則認定兩點為同一點。同時將 B 影像特徵點投影到 A 影像，同樣根據歐基里得距離取一閾值，若小於該閾值則認定兩點為同一點，若確認兩點為彼此共同最鄰近點，即該兩點為一組共軛點。

(4) 根據步驟三比對結果，將步驟(1) 提取之特徵點資料整理並留下共軛點。由於訓練 SuperGlue 模型除須要成對特徵點，也需要無法匹配特徵點，因此除共軛點以外之特徵點也另外記錄起來，以便訓練模型無特徵點放置區中之可學習參數。

SuperGlue 模型訓練分為兩階段式訓練，如圖 12 所示，目的是使訓練過程更容易收斂，以漸進的方式加大相對旋轉角度。

第一階段訓練使用預訓練模型並輸入隨機旋轉角度介於  $90^\circ \sim -90^\circ$  之資料擴增訓練資料集，以小學習率微調 (Fine tune) 模型。待模型收斂後，再以第一階段訓練之模型為預訓練模型並輸入隨機

旋轉角度介於  $180^\circ \sim -180^\circ$  之資料擴增訓練資料集，以更小之學習率微調模型。兩階段式訓練使模型能漸進的適應旋轉的情形，增加資料多樣性的同時也能避免收斂困難。

## 2.6 空間後方交會求解外方位

空間後方交會的基本原理是基於光線的直線性質來求解外方位參數，如圖 13 所示。藉由投影中心、像素點和地面點之間形成的共線條件，可以利用至少三個已知地面控制點的座標及其在影像上對應的像點座標列出共線方程式。




圖 11 完整匹配模型擴增訓練資料集產生流程圖

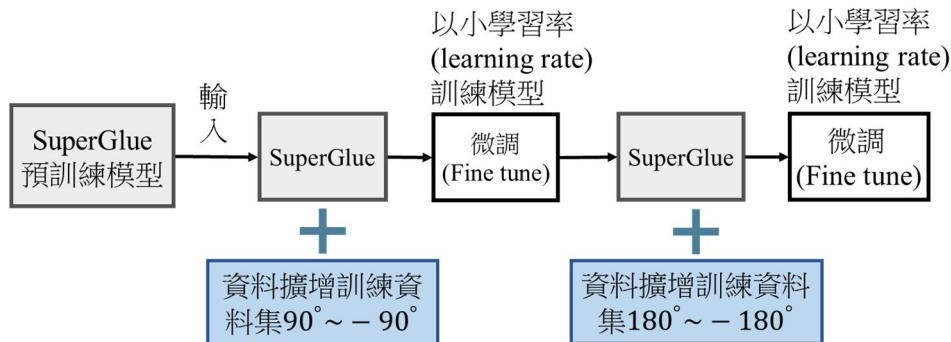


圖 12 以擴增資料集訓練 SuperGlue 模型流程示意圖




圖 13 單片空間後方交會示意圖

根據共線方程式反求相片的外方位元素，即  $X_c, Y_c, Z_c, \omega, \varphi, \kappa$ 。欲求得單張相片的外方位元素，需獲取待求外方位之目標影像與參考影像之間共軛點。參考影像之共軛點座標與地面採樣距離 (Ground sample distance)、影像左上角地理座標以及 DEM 可計算出共軛點之物空間座標。共軛點像座標與物空間座標可組成共線方程式。共線條件方程式如下：

$$x - x_0 = -f \frac{a_1(X-X_c) + b_1(Y-Y_c) + c_1(Z-Z_c)}{a_3(X-X_c) + b_3(Y-Y_c) + c_3(Z-Z_c)} \dots\dots\dots (9)$$

$$y - y_0 = -f \frac{a_2(X-X_c) + b_2(Y-Y_c) + c_2(Z-Z_c)}{a_3(X-X_c) + b_3(Y-Y_c) + c_3(Z-Z_c)} \dots\dots\dots (10)$$

其中， $f$  為像機焦距； $x_0, y_0$  為像主點； $x, y$  為地面已知點的像座標； $X, Y, Z$  為地面已知點的物空間座標； $X_c, Y_c, Z_c$  為投影中心的物空間座標； $a_1, a_2, a_3, b_1, b_2, b_3, c_1, c_2, c_3$  為相片姿態參數 ( $\omega, \varphi, k$ ) 組成的旋轉矩陣。當地面點已知，相機外方為元素  $X_s, Y_s, Z_s, \omega, \varphi, k$  未知，空間後方交會共線式可以透過泰勒級數展開成線性方程組並表示為矩陣形式如下：

$$AX = L + V \dots\dots\dots (11)$$

當匹配共軛點大於三組，此時觀測數方程式大於未知數數量，會產生多於觀測量，可根據最小二乘法原理求得  $X$  中各項未知參數改正值如下式：

$$X = (A^T A)^{-1} (A^T L) \dots\dots\dots (12)$$

根據預先設定門檻值，迭代計算直到未知參數改正值與上一次迭代之未知參數改正值差值小於門檻值，則迭代計算收斂，最後再加上給定初始外方位便可求得六個外方位參數。

### 3. 實驗成果

實驗結果與討論主要分五個部分：3.1 SuperGlue 模型訓練與驗證影像資料集、3.2 空間後方交會分析資料集、3.3 單片匹配具相對旋轉比較分析、3.4 無人機影像資料集解算外方位誤差分析、3.5 匹配密度及匹配分散程度分析。


#### 3.1 SuperGlue 模型訓練與驗證影像資料集

本研究於訓練 SuperGlue 模型時使用由 Shen *et al.* (2018) 提出為完成影像檢索研究而創建之 GL3D 基準資料集。該研究基於批量三元組損失函數結合網格重投影的方法訓練 CNN 模型，所提方法顯著加速 3D 重建中的影像檢索過程，並因此創建 GL3D 資料集訓練深度學習模型，全名 Geometric Learning with 3D Reconstruction，詳細資料如表 1 所示。包含都市、鄉村、旅遊景點、小物件等影像。總共 378 個子資料集中各一種場景，總共 90590 張高解析度影像，每個場景包含 50 到 1000 張影像且交疊比例高，適合應用於幾何相關且 3D 資訊豐富之情境，諸如：特徵軌跡匹配、相機姿態、點雲資料、網格模型。有別於其他資料集 Oxford5k (Philbin *et al.*, 2007)、Paris6k (Philbin *et al.*, 2008) 以及 Holiday (Jegou *et al.*, 2008)，有以下幾點特色。

- (1) 與現有資料集最大區別為每個資料集完整覆蓋該場景中的地物，每張影像間密集相連且平均分布於地物周圍的不同位置和視角。
- (2) GL3D 表現弱語意，資料集中包含缺乏紋理如草地、河流等場景，於其他資料集中不常見。
- (3) 豐富的幾何情境，影像間重疊率高且緊密連結，不僅有兩視角影像對，多視角觀測更好因應精確的幾何運算如相機姿態、點雲、網格模型等。



表 1 GL3D 基準資料集資訊

資料集名稱	Geometric Learning with 3D Reconstruction 資料集	
影像類型	空拍 (如：都市、鄉村)	近景 (如：旅遊景點、小物件)
影像波段	彩色波段 (R、G、B 波段) 產生訓練資料時會轉換至灰階影像	
影像大小	影像長寬為 1000*1000	
資料集影像張數	90590 張高解析度影像	
影像範例		

GL3D 資料集的一個潛在缺點是影像在短時間內拍攝，因此缺乏光照、天氣和季節變化。儘管可以應用光度數據增強，仍應尋求更多真實的數據來改進學習模型。Shen 等人參照 SiaMAC (Radenović *et al.*, 2016)，也從網路公共旅遊數據集中生成了幾何標籤，以進一步增加數據的多樣性。具體來說，從網路公共旅遊數據集中下載並提取影像，然後通過 3D 引擎重建每個數據，最終獲得了被認為構建良好的 530 個場景 (55,657 張影像)，並命名為 Tourism 基準資料集，詳細資料如表 2 所示。所有場景皆是旅遊景點，包含從多種角度拍攝之建築物的外觀，且於不同時間拍攝，可看出有明顯光照、天氣和季節變化。經由 Tourism 基準資料集訓練後的模型可更好的適應不同時間點光照、天氣和季節變化。

### 3.2 空間後方交會分析資料集影像資料集

成大校園無人機空拍圖總共 839 張影像，影像大小長寬為 7952 × 5304，地面空間解析度為 0.0545 m，無人機飛行高度 221 m，使用 sony Alpha 7R II 全片幅相機，選定焦距 15 mm 之鏡頭，其可視範圍 (Field of view) 可達 110°。各影像之外方位參數使用 Metashape 攝影測量軟體，進行影像空三平差得到六個外方位參數 (X、Y、Z、 $\omega$ 、 $\phi$ 、 $\kappa$ ) 作為真值供後續空間後方交會解算分析誤差。其中地面控制點誤差如表 3 所示，平均無人機位置誤差如表 4 所示。

空間後方交會時主要利用參考影像匹配共軛

點平面座標。如圖 14 所示，參考影像大小長寬為 3114 × 2787，為地面空間解析度 0.5 m 之正射影像，以 Metashape 攝影測量軟體將多張無人機影像合成製作，解算時還需搭配數值地表模型獲得高程。



圖 14 成大校園參考影像 (左) 與 DSM (右)

數值地表模型或稱 Digital surface model (DSM)，是一種數位化的地理數據表示形式，用於描繪地球表面上所有可見物體的高度，包括建築物、植被和其他構造物，用途是取得匹配特徵點於物空間座標高程值，其製作同樣由 Metashape 攝影測量軟體執行，空間解析度為 0.25 m。

### 3.3 單像匹配具相對旋轉結果評估與比較分析

本研究包含傳統影像特徵匹配方法 SIFT+FLANN、SUFT+FLANN，兩者皆加入 RANSAC (Fischler *et al.*, 1981) 濾除粗差。深度學習影像特徵匹配方法有 SuperPoint+ SuperGlue 與本研究提出之 SuperSIFT (內插法) + SuperGlue (擴增) 以及 SuperSIFT (可學習參數法) + SuperGlue (擴增)，由於深度學習方法本身包含濾除粗差能力 (2.2 節提到之無特徵點放置區)，因此未加入 RANSAC。

表 2 Tourism 基準資料集資訊

資料集名稱	Tourism 資料集
影像類型	近景，如：旅遊景點、建築物
影像波段	彩色波段 (R、G、B 波段) 產生訓練資料時會轉換至灰階影像
影像大小	影像長寬為 1000*1000
資料集影像張數	55,657 張高解析度影像
影像範例	

表 3 地面控制點誤差

點數	X 誤差 (cm)	Y 誤差 (cm)	Z 誤差 (cm)	XY 誤差 (cm)	總誤差 (cm)
14	11.1498	12.5868	5.91888	16.815	17.8263

表 4 平均無人機位置誤差

X 誤差 (m)	Y 誤差 (m)	Z 誤差 (m)	XY 誤差 (m)	總誤差 (m)
0.112799	0.138552	0.992594	0.178662	1.00855

前述總共五種匹配方法分別對測試資料集匹配，每匹配完一次逐漸旋轉目標影像每次 30°，共 0°、30°、60°、90°、120°、150°、180°五種角度並分別與參考影像匹配，比較匹配點對之數量，其中一匹配影像對中左圖為參考影像，右圖為目標影像，結果如圖 16~圖 21 所示。

圖 15 為兩張拍攝位置不同之垂直空拍成對影像，其中包含高樓、一般建物、城市景觀，左圖為參考影像，右圖為目標影像。

根據表 5 比較的結果可分析出，由於 SIFT 與 SURF 萃取特徵本身具有旋轉不變性，因此於各角度都能得到約 100 個匹配特徵點對。SuperPoint+SuperGlue 之匹配方法則是可應付相對旋轉角度 60°以下之匹配，最多可獲得約 800 個匹

配對，然而大於 60°則無法產生匹配對。本研究提出第一個方法 SuperSIFT (內插法) + SuperGlue (擴增資料集)，於 90°以下可獲得約 400 個匹配對，於 90°以上則可匹配得約 300 個匹配對，180°則有 133 個匹配。本研究提出之第二個方法 SuperSIFT (可學習參數法) + SuperGlue (擴增資料集)，除 180°於各角度都能獲得約 400 個以上之匹配對。相比之下本文提出之方法可在各角度下皆獲得足夠之匹配點數量供後續解算外方位，且匹配數量相較傳統方法 SIFT+FLANN 與 SURF+FLANN 能獲得較多匹配對。此外，SuperPoint + SuperGlue 之匹配方法於相對旋轉角度小時可獲得大量匹配點對，然而當角度大於 60°時則無法產生足夠數量的匹配點對解算外方位。



圖 15 參考影像 (左圖)，目標影像 (右圖)




圖 16 城市垂直空拍影像旋轉角度 0° 匹配成果，左上、中上、右上、左下、右下依序使用匹配方法 SIFT+FLANN、SURF+FLANN、SuperPoint+SuperGlue、本研究提出 SuperSIFT (內插法) +SuperGlue (擴增資料集)、本研究提出 SuperSIFT (可學習參數法) +SuperGlue (擴增資料集)




圖 17 城市垂直空拍影像 SIFT+FLANN 方法 左上、中上、右上、左下、中下、右下依序是旋轉角度 30°、60°、90°、120°、150°、180°




圖 18 城市垂直空拍影像 SURF+FLANN 方法 左上、中上、右上、左下、中下、右下依序是旋轉角度 30°、60°、90°、120°、150°、180°




圖 19 城市垂直空拍影像 SuperPoint+SuperGlue 方法 左上、中上、右上、左下、中下、右下依序是旋轉角度 30°、60°、90°、120°、150°、180°




圖 20 城市垂直空拍影像本研究提出 SuperSIFT(內插法)+SuperGlue(擴增資料集) 左上、中上、右上、左下、中下、右下依序是旋轉角度 30°、60°、90°、120°、150°、180°




圖 21 城市垂直空拍影像本研究提出 SuperSIFT (可學習參數法)+SuperGlue (擴增資料集) 左上、中上、右上、左下、中下、右下依序是旋轉角度 30°、60°、90°、120°、150°、180°

表 5 各方法匹配點數

匹配方法	目標影像旋轉角度						
	0°	30°	60°	90°	120°	150°	180°
SIFT+FLANN	184	160	154	177	158	158	188
SURF+FLANN	170	90	91	165	96	90	165
SuperPoint+SuperGlue	801	673	637	0	0	0	1
本研究提出 SuperSIFT (內插法)+SuperGlue (擴增)	566	423	425	547	381	327	133
本研究提出 SuperSIFT (可學習參數法)+ SuperGlue (擴增)	759	598	595	664	508	488	157

### 3.4 無人機影像資料集解算外方位誤差評估與分析

為模擬分析真實案例，以 3.2 節提到 839 張成大校園無人機空拍圖檢測各方法平均匹配點數以及外方位推算誤差，其中誤差計算方式如式 13 所示。其中 839 張影像隨機以相對參考影像 0°、90°、180°、270°旋轉後匹配特徵點，計算平均每張獲得多少匹配點，並統計解算後之外方位誤差。其結果

如下，其中誤差以 RMSE 計算：

$$RMSE = \sqrt{\frac{\sum(\hat{x}-x)^2}{n}} \dots\dots\dots(13)$$

其中 $\hat{x}$ 為經最小二乘原理解算得之六個外方位參數 X、Y、Z、 $\omega$ 、 $\phi$ 、 $\kappa$ ，而 $x$ 為已知六個外方位參數。結果如表 6 所示，由其分析得知，傳統匹配方法 SIFT+FLANN 與 SURF+ FLANN 可獲得平均點數相較深度學習法少，SuperPoint+SuperGlue 匹配方

法隨然於大旋轉角度難以匹配，然而小角度時可獲得大量匹配點，因此平均後依然有約 100 個匹配點。本研究提出之 SuperSIFT (內插法)+SuperGlue (擴增資料集) 方法，可獲得平均匹配點數 107 個，SuperSIFT (可學習參數法) +SuperGlue (擴增資料集) 可獲得約 161 個匹配點，皆優於其他方法。外方位解算部分，SIFT+FLANN 與 SURF+FLANN 姿態角度誤差約 10~80 m，位置誤差最大達 20°，由於匹配點個數較少，雖於各方向皆能獲得匹配點，仍相對缺乏多餘觀測量，且其本身也可能因匹配錯誤，導致解算成果較差。SuperPoint+SuperGlue 匹配方法位置誤差約 40 m，姿態角度誤差最大達 37°，較大誤差主要原因是旋轉角度大時，存在只有零星匹配之情形，此時若其中有匹配錯誤點對，會造成

解算誤差極大之情形。本文提出之兩種匹配方法，於各旋轉方向皆能獲得足夠數量之匹配點對，因此解算得誤差較小且相對穩定。

如圖 22 為外方位誤差分布圖，顯示出所有 839 張成大校園無人機空拍圖每張影像之外方位誤差分布。根據結果所示，本文提出之兩種匹配方法經解算所得之外方位誤差於三倍標準差外之離群值個數皆小於傳統影像匹配法，而原始 SuperPoint +SuperGlue 匹配方法則由於相對大角度旋轉下幾乎無法匹配，因此離群值相對其他方法最多。由以上所述顯示本文提出之兩種匹配方法相對其他三種方法於有相對旋轉之情形下解算外方位參數更準確且更穩定。

表 6 無人機外方位參數誤差 RMSE

匹配方法	平均分 配點數	外方位推算誤差 RMSE (角度單位：度，位置單位：m)					
		$\omega$	$\phi$	$\kappa$	X	Y	Z
SIFT+FLANN	57.048	6.991	10.453	8.994	20.071	19.880	17.965
SURF+FLANN	23.875	17.413	79.561	6.606	16.408	17.896	13.539
SuperPoint+SuperGlue	104.263	19.071	24.413	37.875	45.022	35.356	47.152
SuperSIFT (內插法) +SuperGlue (擴增)	107.384	3.005	0.846	3.363	4.844	5.936	8.481
SuperSIFT (可學習參數法) +SuperGlue (擴增)	161.654	1.765	1.639	3.278	5.932	6.351	3.600




圖 22 成大校園外方位誤差分布圖

### 3.5 匹配密度及分散程度分析

解算外方位時若能盡量滿足以下兩種條件，可獲得較穩定之解算成果。

- (1) 匹配點數量越多越好，由於使用最小二乘平差法求解未知參數，越多觀測量可獲得越接近真值之解算。
- (2) 匹配點之分布應盡量分散且佈滿整張影像，使得解算時不會產生外插的情況，造成誤差較大成果不穩定。

匹配密度及匹配分散程度計算之方法如下：將影像分成  $10 \times 10 = 100$  個子區域，並計算總匹配點數與有匹配點之子區域個數。匹配密度為匹配點數除以多少個子區中有匹配點；匹配分散程度則為 100 個子區域中有多少個子區域有匹配點，即整張圖有匹配點的比例。以圖 23 為例，共有 15 個匹配點且 11 個子區域中有匹配點，則匹配密度為  $\frac{15}{11} = 1.364$ ，匹配分散程度為  $\frac{11}{100} = 0.11$ 。




圖 23 子區域劃分及匹配點分布示意圖

以驗證資料集分析匹配密度及匹配分散程度，其中參考影像保持原樣，而目標影像給予隨機旋轉量，經匹配後分別計算匹配密度及匹配分散程度，並將成果平均計算得結果如表 7 所示。

傳統方法部分，SIFT+FLANN 與 SURF+FLANN 方法平均點密度皆較深度學習方法低，平均點分散程度則是前者較高，後者則是所有方法最低。深度學習方法部分，SuperPoint+SuperGlue 方法平均點密度較本文提出之方法低，其平均點分散程度也相對較低，原因是該方法只能應付旋轉角度  $60^\circ$  以下之匹配，所以經平

均後所得到之各項數據皆較低。本研究提出方法 SuperSIFT (內插法) + SuperGlue (擴增) 與 SuperSIFT (可學習參數法) + SuperGlue (擴增) 方法之平均點密度較其他方法高，其平均點分散程度也較高。顯示出其可獲得較多匹配點，雖有些區塊可能匹配點較集中，然而擁有匹配點之區塊也較多，匹配點分布相較其他方法分散於整張影像各處，有利於後續空間後方交會求解外方位。

表 7 平均點密度及點分散程度比較表

匹配方法	平均點密度	平均點分散程度
SIFT+FLANN	2.012	0.201
SURF+FLANN	1.513	0.098
SuperPoint+SuperGlue	3.162	0.178
SuperSIFT(內插法) +SuperGlue(擴增)	3.266	0.247
SuperSIFT(可學習參數法) +SuperGlue(擴增)	4.247	0.290

## 4. 結論

本研究旨在提出影像視覺地形輔助定位技術之自動化流程，並將深度學習應用於其中。完整流程首先輸入無人機拍攝影像並與影像檢索搜尋之參考正射影像匹配共軛特徵點。匹配過程應用深度學習模型，由於無人機在航拍過程中常會遇到影像平面旋轉問題，本研究透過增強深度學習模型對旋轉的抵抗能力，使影像視覺地形輔助定位技術更加高效且穩定。針對問題，本文首先提出以 SIFT 描述符取代原有 SuperPoint 描述符，使特徵點具備旋轉不變性，加強了匹配模型 SuperGlue 對旋轉的適應性。同時為加強模型對於旋轉適應能力，提出擴增訓練及驗證資料集的流程，隨機以某一區間角度旋轉影像，增加旋轉多樣性，製作成對特徵點資料集以供 SuperGlue 訓練，改善模型對旋轉問題的適應能力。由於 SIFT 描述符與 SuperPoint 描述符本身結構差異，因此提出兩種可改變 SIFT 描述符使其符合可輸入 SuperGlue 模型結構的方法，第一個方法內插法通過在特徵描述符階段內插 SIFT 特徵

點描述符，增加描述符維度；可學習參數法利用兩組可學習參數取代內插法，同樣增加描述符維度。由以上方法整合出兩種訓練 SuperGlue 模型流程，SuperSIFT (內插法) + SuperGlue (擴增資料集) 以及 SuperSIFT (可學習參數法) + SuperGlue (擴增資料集)，兩種方法皆顯著提高了影像匹配的精度和穩定性。使得影像在不同旋轉角度下均能獲得較多的匹配點對。與傳統的 SIFT+FLANN 和 SURF+FLANN 方法相比，本研究提出的方法在匹配點數量和分散性上具有明顯優勢。雖然 SuperPoint+SuperGlue 方法在相對旋轉角度小於 60° 時表現優異，能獲得匹配數量最多匹配點對，但在旋轉角度大於 60° 時無法產生足夠的匹配點對。而本研究的兩種方法在所有旋轉角度下均能保持穩定的匹配效果，提高了影像匹配的精度和穩定性。根據本研究提出方法匹配後結果加上 DSM，列出共線式後，以空間後方交會解算外方位平面位置誤差最佳可達 3 m、姿態角誤差最佳可達 1.3°。

## 參考文獻

- 黃敬群、黃偉立，2012。無人飛行監控器之定位技術探討，100-101 年度獎勵科技大學及技術學院典範科大計畫產學及研究成果轉專題製作教材，國立高雄應用科技大學。[Huang, C.C., and Huang, W.L., 2012. A study on positioning technology for unmanned aerial surveillance vehicles, 2012-2013 Awards for University of Science and Technology and Technical College, National Kaohsiung University of Applied Sciences. (in Chinese)]
- Arandjelovic, R., Gronat, P., Torii, A., Pajdla, T., and Sivic, J., 2016. NetVLAD: CNN architecture for weakly supervised place recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 5297-5307, DOI: 10.1109/CVPR.2016.572.
- Bay, H., Tuytelaars, T., and Van Gool, L., 2006. Surf: Speeded up robust features, Proceedings of the European Conference on Computer Vision (ECCV), Springer Berlin Heidelberg, pp. 404-417, DOI: 10.1007/11744023\_32.
- Chang, Y., Ballotta, L., and Carlone, L., 2023. D-Lite: Navigation-oriented compression of 3D scene graphs for multi-robot collaboration, IEEE Robotics and Automation Letters, 8(11):7527-7534, DOI: 10.1109/LRA.2023.3320011.
- Chen, H., Luo, Z., Zhang, J., Zhou, L., Bai, X., Hu, Z., Tai, C.L., and Quan, L., 2021b. Learning to match features with seeded graph matching network, Proceedings of the IEEE/CVF International Conference on Computer Vision, pp. 6281-6290, DOI: 10.1109/ICCV48922.2021.00624.
- Chen, S., Wu, X., Mueller, M.W., and Sreenath, K., 2021a. Real-time geo-localization using satellite imagery and topography for unmanned aerial vehicles, Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pp. 2275-2281, DOI: 10.1109/IROS51168.2021.9636705.
- DeTone, D., Malisiewicz, T., and Rabinovich, A., 2018. Superpoint: Self-supervised interest point detection and description, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, pp. 337-349, DOI: 10.1109/CVPRW.2018.00060.
- Fischler, M.A., and Bolles, R.C., 1981. Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography, Communications of the ACM, 24(6): 381-395, DOI: 10.1145/358669.358692.
- Jegou, H., Douze, M., and Schmid, C., 2008. Hamming embedding and weak geometric consistency for large scale image search, Proceedings of the European Conference on Computer Vision (ECCV), Springer Berlin Heidelberg, Vol.5302, pp. 304-317, DOI: 10.1007/978-3-540-88682-2\_24.
- Ju, C., Luo, Q., and Yan, X., 2020. Path planning using

- an improved a-star algorithm, Proceedings of the International Conference on Prognostics and System Health Management (PHM-2020 Jinan), pp. 23-26, DOI: 10.1109/PHM-Jinan48558.2020.00012.
- Lin, Y., and Medioni, G., 2007. Map-enhanced UAV image sequence registration and synchronization of multiple image sequences, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Minneapolis, MN, USA, DOI: 10.1109/CVPR.2007.383428.
- Lindenberg, P., Sarlin, P.E., and Pollefeys, M., 2023. Lightglue: Local feature matching at light speed, Proceedings of the IEEE/CVF International Conference on Computer Vision, Paris, France, pp. 17581-17592, DOI: 10.1109/ICCV51070.2023.01616.
- Low, D.G., 2004. Distinctive image features from scale-invariant keypoints, International Journal of Computer Vision, 60(2): 91-110, DOI: 10.1023/B:VISI.0000029664.99615.94.
- Luo, M., Hou, X., and Yang, J., 2020. Surface optimal path planning using an extended Dijkstra algorithm, IEEE Access, 8: 147827-147838, DOI: 10.1109/ACCESS.2020.3015976.
- Ma, J., Jiang, X., Fan, A., Jiang, J., and Yan, J., 2021. Image matching from handcrafted to deep features: A survey, International Journal of Computer Vision, 129(1): 23-79, DOI: 10.1007/s11263-020-01359-2.
- Muja, M., and Lowe, D.G., 2009. Fast approximate nearest neighbors with automatic algorithm configuration, Proceedings of the International Conference on Computer Vision Theory and Applications (VISAPP), Lisboa, Portugal, Vol.1, pp. 331-340, DOI: 10.5220/0001787803310340.
- Philbin, J., Chum, O., Isard, M., Sivic, J., and Zisserman, A., 2007. Object retrieval with large vocabularies and fast spatial matching, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Minneapolis, MN, USA, DOI: 10.1109/CVPR.2007.383172.
- Philbin, J., Chum, O., Isard, M., Sivic, J., and Zisserman, A., 2008. Lost in quantization: Improving particular object retrieval in large scale image databases, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Anchorage, AK, USA, DOI: 10.1109/CVPR.2008.4587635.
- Radenović, F., Tolias, G., and Chum, O., 2016. CNN image retrieval learns from BoW: Unsupervised fine-tuning with hard examples, Proceedings of the Computer Vision – ECCV 2016 (Lecture Notes in Computer Science), vol. 9905, pp. 3-20, Springer International Publishing, DOI: 10.1007/978-3-319-46448-0\_1.
- Rocco, I., Arandjelović, R., and Sivic, J., 2020b. Efficient neighbourhood consensus networks via submanifold sparse convolutions, Proceedings of the Computer Vision–ECCV 2020 (Lecture Notes in Computer Science), vol. 12354, pp. 605-621, DOI: 10.1007/978-3-030-58545-7\_35.
- Rocco, I., Cimpoi, M., Arandjelović, R., Torii, A., Pajdla, T., and Sivic, J., 2020a. NCNet: Neighbourhood consensus networks for estimating image correspondences, IEEE Transactions on Pattern Analysis and Machine Intelligence, 44(2): 1020-1034, DOI: 10.1109/TPAMI.2020.3016711.
- Sarlin, P.E., DeTone, D., Malisiewicz, T., and Rabinovich, A., 2020. Superglue: Learning feature matching with graph neural networks, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 4938-4947, DOI: 10.1109/CVPR42600.2020.00499.
- Shen, T., Luo, Z., Zhou, L., Zhang, R., Zhu, S., Fang,



- T., and Quan, L., 2018. Matchable image retrieval by learning from surface reconstruction, Proceedings of the Asian conference on computer vision, vol.11361, pp. 415-431, Cham: Springer International Publishing, DOI: 10.1007/978-3-030-20887-5\_26.
- Sinha, D., and El-Sharkawy, M., 2019. Thin mobilenet: An enhanced mobilenet architecture, Proceedings of the 2019 IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON), pp. 0280-0285, DOI: 10.1109/UEMCON47517.2019.8993089.
- Sun, J., Shen, Z., Wang, Y., Bao, H., and Zhou, X., 2021. LoFTR: Detector-free local feature matching with transformers, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 8922-8931, DOI: 10.1109/CVPR46437.2021.00881.
- Verdie, Y., Yi, K., Fua, P., and Lepetit, V., 2015. Tilde: A temporally invariant learned detector, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, pp. 5279-5288, DOI: 10.1109/CVPR.2015.7299165.
- Yi, K.M., Trulls, E., Lepetit, V., and Fua, P., 2016. Lift: Learned invariant feature transform, Proceedings of the Computer Vision–ECCV 2016 (Lecture Notes in Computer Science), vol. 9910, pp. 467-483, Springer, Cham, DOI: 10.1007/978-3-319-46466-4\_28.

# Deep Learning-based Image Feature Matching for UAV Visual Positioning

Lai-Han Zou <sup>1\*</sup>      Chao-Hung Lin <sup>2</sup>

## Abstract

When the positioning and orientation equipment on an unmanned aerial vehicle (UAV) is unavailable, visual positioning technology can be utilized to perform spatial resection using only conjugate points from images to derive the vehicle's exterior orientation. This study proposes a visual positioning workflow and addresses the issue of significantly reduced matching success rates when using deep learning models for feature point matching due to planar rotation between images. By incorporating data augmentation with random image rotations, feature points are extracted using a feature extraction model and then input into the matching model for learning. Additionally, the study introduces interpolation methods and learnable parameter methods to replace the feature descriptors used for matching with traditional feature descriptors, enhancing rotational invariance. After extracting and matching feature points from the images, conventional photogrammetry spatial resection can be used to solve for the six exterior orientation elements of the camera mounted on the vehicle, thus achieving vehicle positioning. With the proposed visual positioning workflow, the best achievable plane position error is 3 meters, and the best achievable attitude angle error is 1.3°.

**Keywords: Deep Learning, Feature Extraction, Image Matching, Visual Positioning, Rotational Invariance**

---

<sup>1</sup> Master, Department of Geomatics, National Cheng Kung University

<sup>2</sup> Professor, Department of Geomatics, National Cheng Kung University

\* Corresponding Author, E-mail: ha095863@gmail.com

Received Date: Sep. 16, 2024

Revised Date: Oct. 08, 2024

Accepted Date: Oct.21, 2024

# 使用深度學習演算進行 Sentinel-2 影像之土地利用 和土地覆蓋分類

呂明倫<sup>1\*</sup>

## 摘要

土地利用和土地覆蓋 (land use and land cover, LULC) 圖是各種景觀規劃與資源管理中不可或缺的基礎資料。深度學習的卷積神經網路 (convolutional neural network, CNN) 可自動擷取遙測影像特徵，快速獲取 LULC 圖，近年來已成為廣受關注的影像分類方法之一。本研究選擇 Sentinel-2 衛星影像做為材料，建構具有 7 層架構的 CNN 模型執行 LULC 分類，並與機器學習的隨機森林 (random forest, RF) 進行比較。結果顯示，CNN 在總體準確度 (89%) 和 kappa 係數 (0.84) 方面均優於 RF (分別為 87%與 0.81)。9 種 LULC 類型中，除草地、休耕稻作與農用設施外，其餘類型的分類結果均達到可接受的水準。總結而言，CNN 展現了深度學習結合衛星影像在大面積製圖上的應用潛力。

**關鍵詞：**遙測、卷積神經網路、隨機森林、製圖

## 1. 前言

土地覆蓋圖描繪了物理上的土地覆蓋範圍，如植被、草地、水體與裸地等，土地利用圖則強調特定的土地覆蓋類型中，受人類活動影響的地表特徵，如住宅區及農業用地 (Yang *et al.*, 2017b)。土地利用和土地覆蓋 (land use and land cover, LULC) 圖是各種景觀規劃與自然資源管理重要的基礎資料，因此，透過有效的 LULC 分類與製圖技術，有助落實合理的資源利用與永續經營。遙測技術是藉由衛星或機載感測器來接收從地球表面發射或反射的電磁輻射資訊，例如 Sentinel 或 Landsat 系列衛星所獲取的光學影像，具有探測範圍廣、多光譜及免費取得等優勢，被認為是測繪 LULC 圖時，最重要的材料來源之一 (Chaves *et al.*, 2020、Kumari & Karthikeyan, 2023)，搭配各種影像分類與製圖技術，即可迅速從影像中測繪出準確的 LULC 資訊。

近年基於遙測影像進行 LULC 分類的技術，已由過往傳統的最大概似法，逐漸轉變成以機器學

習為主流的趨勢 (Maxwell *et al.*, 2018)，常見的有決策樹 (decision tree)、隨機森林 (random forests, RF)、支援向量機 (support vector machines, SVM) 與人工神經網路等 (artificial neural network, ANN)，這些演算法中，ANN 仿生物大腦功能的運作，利用大量的神經元聯結，組成一個高度複雜且互聯的多層次網路，演算過程中，神經元的資訊可透過一個或多個隱藏層從輸入層向前傳播到輸出層，預測結果再利用反向傳播進行梯度下降式 (gradient descent) 的權重更新，經由如此的迭代運作求取最佳模型，在遙測領域中，已被證實能有效應用於衛星影像的資料分析 (Kanellopoulos & Wilkinson, 1997)。拜人工智慧科技快速發展所賜，深度學習技術提升了 ANN 的演算能力，特別是針對影像處理發展出的卷積神經網路 (convolutional neural network, CNN)，其受到了大腦中視覺皮層 (visual cortex) 處理視覺資訊機制的啟發，考慮了影像的空間脈絡，透過有限區域內的參數共享概念，自動提取像元的光譜和紋理等高

<sup>1</sup> 農業部生物多樣性研究所 副研究員

\* 通訊作者, E-mail: alan@tbri.gov.tw

收到日期：民國 113 年 09 月 30 日

修改日期：民國 113 年 12 月 12 日

接受日期：民國 113 年 12 月 30 日

階特徵，相較於其他的機器學習演算法，能省去繁雜又耗時的特徵工程步驟，不僅提升了衛星影像應用於 LULC 製圖的效率，更增進了分類的準確度 (Sharma *et al.*, 2017、Song *et al.*, 2019、Rosentreter *et al.*, 2020、Garajeh *et al.*, 2022)。

一般而言，CNN 的架構除了輸入與輸出層外，尚會使用卷積、池化和全連接層來搭建神經網路 (Schmidhuber, 2015)，其中，卷積層是 CNN 的核心，主要運用濾波器強化輸入影像的特徵；池化層則進行資料降維，旨在減少資訊量，同時保留重要的特徵；所有學習到的高階特徵最後傳遞給全連接層，並透過分類函數進行輸出 (Yildirim *et al.*, 2020)。國外有關 CNN 應用於 LULC 製圖的研究已相當多見 (Maggiore *et al.*, 2016、Kattenborn *et al.*, 2021、Digra *et al.*, 2022、Wang *et al.*, 2023、Kotariadis & Lazaridou 2023)，國內方面，大多是應用在高解析力的影像分類 (林迪詒等，2019、陳偉文等，2020、張智安及傅于洳，2021、王禹翔等，2023、Liu *et al.*, 2022、彭信瑋等，2023、洪浩源等，2024)。目前對於利用衛星影像執行大面積 LULC 製圖的研究案例仍少

見，有鑑於此，本研究選擇埔里鎮做為研究區，該地區的農業、人文及自然景觀相互交織，形成多樣的 LULC 型態，研究目標是基於中等空間解析力的光學衛星影像，建構高效又準確的 CNN 分類模型，進而測繪 LULC 圖。

## 2. 材料與方法

### 2.1 研究區概述

埔里鎮位於台灣中部，面積約 162 km<sup>2</sup>，境內平原面積占 26%，丘陵面積占 74%，海拔介於 380~700 m，全鎮由中央山脈、合歡山與雪山山脈所包圍，最高峰位於東北部的關刀山 (1,924 m)，為典型的盆地地形。土壤方面，東部以黏土為主，北部、南部和西部地區以黃土為主 (Wu *et al.*, 2014)。根據中央氣象局的埔里氣象站 2016 到 2023 年資料顯示，該區年平均的雨量為 2141 mm、降水日數約 132 日、相對濕度超過 80%、氣溫為 22.6°C，屬亞熱帶溫潤氣候。




圖 1 研究區位置圖 (背景為 Sentinel-2 的 RGB 影像)

## 2.2 蒐集衛星影像及地面資料

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、紅邊及短紅外光範圍，共切割成 13 個波段影像 (表 1)。研究區的 Sentinel-2 影像從 [browser.dataspace.copernicus.eu](http://browser.dataspace.copernicus.eu) 下載，篩選少雲層覆蓋且清晰的影像，選定的影像屬 Level-2A 處理等級的產品，即地表反射率經過大氣校正，拍攝日期為 2021 年 1 月 15 日 (圖 1)，屬雨量稀少的乾燥季節。由於 60 m 的波段影像，主要功能為雲霧過濾與大氣相關的應用，故本研究僅用到第 2 到 8、8A、11 和 12 等 10 個波段影像，透過 ESA 專為處理 Sentinel 影像資料所開發的免費軟體：Sentinel Application Platform ([eo4society.esa.int/resources/snap](http://eo4society.esa.int/resources/snap))，以最近相鄰法 (nearest neighbor) 進行 10 m 空間解析力的像元重取樣。

表 1 Sentinel-2 的波段影像描述

波段名稱	中心波長 (nm)	空間解析力 (m)
B01：海岸氣溶膠	442.7	60
B02：藍光	492.4	10
B03：綠光	559.8	10
B04：紅光	664.6	10
B05：紅邊 1	704.1	20
B06：紅邊 2	740.5	20
B07：紅邊 3	782.8	20
B08：近紅外光 1	832.8	10
B08A：近紅外光 2	864.7	20
B09：水蒸氣	945.1	60
B10：卷雲	1373.5	60
B11：短紅外光 1	1613.7	20
B12：短紅外光 2	2202.4	20

將 Sentinel-2 影像切割成 5×5 像元大小的區塊，整個研究區共計有 59778 個，逢機取樣 10% 的區塊做為樣本，並將每個區塊的邊界轉換為 KML 格式，匯入 Google Earth 平台，選擇與 Sentinel-2 拍攝時間接近的高解析力影像做為地真參考，對樣本區塊進行 LULC 視覺判讀與類型標註，每個區塊標註為一種 LULC 類型，依據最大覆蓋率決定。研究區總

共分成 9 種 LULC 類型 (表 2)，所有樣本完成 LULC 類型標記後，劃分 60% 做為訓練集，20% 為模型擬合過程中的驗證集，剩下 20% 用於評估模型性能的測試集。此外，由於水體分佈相當零星，僅東南方的鯉魚潭面積較大，因此，不參與建模工作，僅以人工標記為水體類型，最終的 LULC 圖共呈現 10 種類型。

## 2.3 卷積神經網路

卷積神經網路模型的輸入層為 4D 張量 (tensor)，包含樣本數、影像行、列及通道，其中，樣本數共有 4781 個 (訓練集加驗證集)，影像的行與列為 5×5 個像元，通道則為 10 (Sentinel-2 的 10 個波段)，運算過程中，所有濾波器運行的步幅設為 1，並用 0 填充確保輸出的大小與輸入相同，由於輸入的樣本屬小尺寸，降維的效果有限，故沒有使用池化層來簡化特徵。整體的架構計有 4 個的卷積層，前兩層各由 64 個濾波器所組成，後兩層增加到 128 個，濾波器大小均為 3×3 個像元，且各層之間都導入批次標準化 (batch normalization)、ReLU 激活函數與 dropout 率 (0.2)，以穩定模型及減少過度擬合 (Srivastava *et al.*, 2014、Ioffe & Szegedy, 2015)，最後一個卷積層結束後進入一個全域平均池化層 (global average pooling)，即最後卷積層的所有特徵圖取平均全域最大池化層，再由最終的全連接層附加 Softmax 激活函數進行輸出，輸出層即生成各 LULC 的分類結果 (圖 2)。

CNN 的演算尚需設置多種超參數，包括期數 (epoch)、批次大小 (batch size)、學習率 (learning rate)、優化器 (optimizer)、損失函數 (loss function) 等。本研究經反覆測試發現最佳的期數與批次大小皆為 50；學習率方面，設定 0.001 為初始值，搭配 Adam 優化器的梯度下降運算，根據驗證集的損失值變化自動調整 (最小設定 1e-10)；損失函數使用適用於分類任務的交叉熵 (cross-entropy)。關於開發模型的軟體和硬體工具，利用 R 語言介面的 TensorFlow 和 Keras 套件進行演算與測試，硬體方面仰賴工作站：Intel(R) Xeon(R) Silver 4208 CPU 及圖形處理器：NVIDIA RTX A6000。

表 2 各 LULC 類型的樣本分配與定義

類型	代號	樣本數	定義
森林	F	3090	丘陵地上及山區為主，由茂密的植被所覆蓋，影像的色澤呈現暗綠。
混生植被	M	138	多位於溪谷地帶，樹木、灌木與草地混生，影像的色澤較森林亮。
稀疏植被	S	1043	靠近平原，影像的色澤與森林類似，惟植被覆蓋分散，陰影成分也不明顯。
草地	G	599	平原及河床周邊，影像的色澤因逢乾季呈現暗褐色。
耕作地	C	227	均質的區塊型態，有植被覆蓋，影像的色澤鮮綠。
休耕旱作	D	156	均質的區塊型態，適逢乾季故無植被覆蓋，影像的色澤呈現黃及褐色。
休耕稻作	R	245	均質的區塊型態，適逢乾季故無植被覆蓋，影像的色澤較休耕旱作淡。
農用設施	H	158	均質的區塊型態，覆蓋塑料溫室設施，影像的色澤呈現灰色。
建地	B	321	建物、房舍及道路等不透水層人工設施。




圖 2 本研究使用之卷積神經網路架構

## 2.4 模型性能比較

除以上的 CNN 架構外，另使用機器學習的 RF 演算法，用於比較不同模型的性能差異，RF 屬於集成學習，即將決策樹由單棵擴展到多棵來執行分類，最後透過多數決確定最終的分結果，其演算過程是利用 bagging 法對訓練集重取樣，並藉由隨機特徵訓練出大量的決策樹模型，重取樣步驟中沒被抽到的樣本稱為 out-of-bag (OOB) 樣本，可用 OOB 誤差估計進行模型驗證 (Breiman, 2001)。本研究使用 R 的 randomForest 套件執行 RF 演算，超參數為樹的數量 (ntree) 及特徵數量 (mtry)，前者設定為 500，有利穩定 OOB 的誤差 (Belgiu & Drăguț, 2016)，另透過 tuneRF 函數選擇 OOB 誤差值最低的特徵數量。

模型建構完成後，依據 20% 測試集的樣本與對應的預測結果，產生誤差矩陣表，計算總體準確度 (overall accuracy, OA)、kappa 係數、生產者準確度 (producer accuracy, PA)、使用者準確度 (user accuracy, UA) 及 F1-score 等評估指標 (Congalton, 1991、Sokolova & Lapalme, 2009)。OA 是由正確分類樣本的總數，除以誤差矩陣中的樣本

總數所產生；kappa 係數是用來評估分類模型預測結果與實際值一致性的統計指標；PA 是將正確分類樣本除以某一 LULC 類型預測結果的樣本總數；UA 是將正確分類樣本除以某一 LULC 類型測試集樣本的總數；F1-score 公式為  $2 \times UA \times PA / (UA + PA)$ ，由於整合了 UA 和 PA，因此，該分數不僅是分類能力的指標，並且能反映兩者的相似度。OA、PA 及 UA 均以百分率表示，一般認為，大於 80% 是可接受的標準 (Teluguntla *et al.*, 2018)。

## 3. 結果與討論

### 3.1 分類準確度

表 3 顯示本研究使用不同演算法獲得的準確度，總體來說，CNN 在 OA (89%) 和 kappa 係數 (0.84) 方面均優於 RF (分別為 87% 與 0.81)。就各 LULC 類型的 F1-score，CNN 的分類結果顯示，除了休耕稻作 (R) 與農用設施 (H) 外，其餘都達到 80% 的標準，尤其森林 (F)、混生植被 (M) 及休耕旱作 (D) 的表現最佳；至於 RF 方面，僅 F 的分類表現相當，其餘的 8 種類型皆是 CNN 更勝一籌，並且草地 (G)、

耕作地(C)、R、H及建地(B)均未達80%。CNN作為最具代表性的深度學習演算法之一，在遙測領域得到廣泛的應用，其最大特色是透過卷積層自動捕捉空間的局部特徵，用於理解像元之間的相互關係，相反地，傳統的機器學習演算法，是基於單一像元的處理，對於空間結構的掌握性較弱，故在LULC分類的研究上，CNN獲得的性能往往更加優越(Sharma *et al.*, 2017、Song *et al.*, 2019、Rosentreter *et al.*, 2020)。本研究目的是建構基於Sentinel-2影像的CNN模型，用於LULC的分類與製圖，在性能表現上，與前人研究相仿，也優於屬機器學習的RF模型，再次證明CNN應用於衛星影像分類的優勢。

表 3 影像分類模型的 F1-score、總體準確度與 kappa 係數比較

類型	F1-score	
	卷積神經網路	隨機森林
森林	97.07	96.97
混生植被	90.57	80.77
稀疏植被	83.29	80.18
草地	80.00	77.73
耕作地	83.72	80.00
休耕旱作	88.52	77.19
休耕稻作	69.47	62.07
農用設施	71.19	65.38
建地	81.25	75.76
總體準確度	89.37	87.45
kappa 係數	0.84	0.81

透過誤差矩陣可詳細探究各LULC類型間的混淆情形，以及分類得到改善的原因，RF預測的結果如表4所示，有許多類型都未達75%，如C、D、R

和H的PA，以及R和B的UA，是拉低準確度的主因。相較於CNN(表5)，C與D被誤分為S的情形得到改善，使準確度當分別提升了13%和16%左右。單看CNN預測的結果，G、R與H的準確度都有出現未達80%的水準(表4)，因此，仍有改進的空間。本研究定義的H類型，多為散佈在農地中的塑料溫室設施，其影像色澤偏灰，與一些人造建物相近，如水泥地或施工地(B)，另由於影像拍攝季節為植物非生長季，也容易與植被稀少的河床地或裸地混淆(S)，這些都與Yang *et al.* (2017a) 檢測到的光譜特徵相似。此外，G與R也值得未來做更進一步的探討，其中，G和S都含有草本植物的成分，故S類型中，樹木分佈較分散的樣本，會放大草本植物的特徵，故存在一定的誤差；R的問題則與上述的H相似，即水稻非生長季的休耕狀態，光譜特徵容易與G、B兩類混淆。

### 3.2 LULC 製圖結果

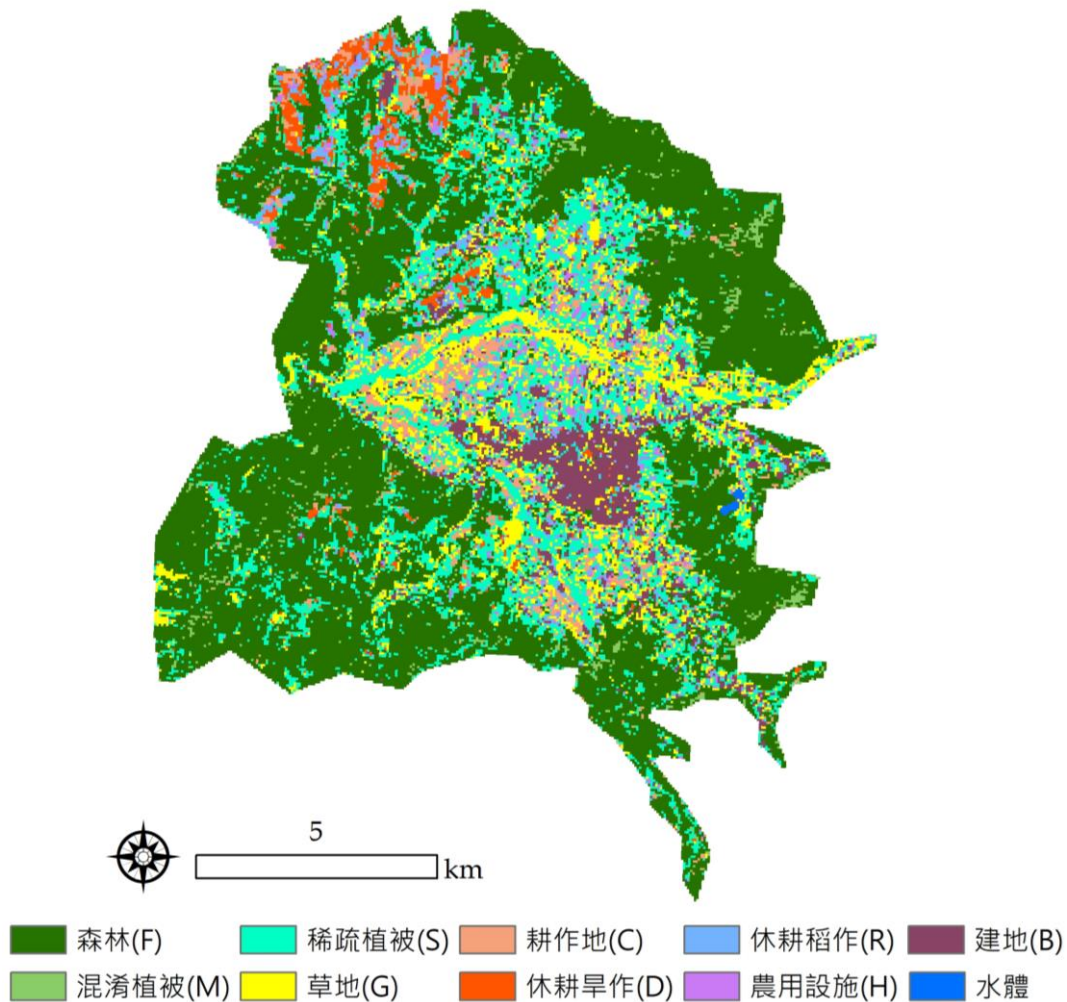
根據CNN模型進行製圖，並與人工標記的水體類型整合，研究區的LULC空間分佈如圖3，由於研究區四面環山，故以F的面積占大多數，並與一些小面積的M共存，S則大多座落在山區與平原的過渡帶。以B為主的城市地區位於盆地中心，環繞在其周邊的景觀結構複雜，尤其是分類有待改善的G、R與H，在此地區呈現零碎且彼此鑲嵌的景觀，是導致各類間混淆的原因。北面的農業區是由C、D與R所組成，這些類型呈現相對均質的區塊型態，因此，該區分類的效果相對較佳。

表 4 隨機森林模型產生之誤差矩陣表

		預測結果									
類型		F	M	S	G	C	D	R	H	B	PA%
測 試 樣 本	F	608	0	6	3	0	0	0	0	0	98.54
	M	5	21	2	0	0	0	0	0	0	75.00
	S	15	1	174	12	0	4	1	1	1	83.25
	G	7	0	10	96	0	0	3	0	4	80.00
	C	2	1	11	1	30	0	0	0	0	66.67
	D	0	0	6	0	0	22	2	1	0	70.97
	R	0	0	4	10	0	0	27	1	7	55.10
	H	0	1	6	1	0	0	1	17	6	53.13
	B	0	0	6	4	0	0	4	0	50	78.13
	UA%	95.45	87.50	77.33	75.59	100.00	84.62	71.05	85.00	73.53	

表 5 卷積神經網路模型產生之誤差矩陣表

		預測結果									
類型	F	M	S	G	C	D	R	H	B	PA%	
測試 樣本	F	596	0	15	4	2	0	0	0	0	96.60
	M	1	24	2	0	0	0	0	1	0	85.71
	S	10	0	177	16	1	2	1	1	1	84.69
	G	2	0	7	102	1	0	4	1	3	85.00
	C	1	1	5	1	36	0	0	1	0	80.00
	D	0	0	3	1	0	27	0	0	0	87.10
	R	0	0	1	7	1	1	33	2	4	67.35
	H	0	0	4	1	0	0	2	21	4	65.63
	B	1	0	2	3	0	0	6	0	52	81.25
	UA%	97.55	96.00	81.94	75.56	87.80	90.00	71.74	77.78	81.25	



## 4. 結論

本研究提出針對 Sentinel-2 影像進行 LULC 製圖的深度學習演算法，研究結果顯示，CNN 模型在 9 種 LULC 類型分類的表現上，OA 與 kappa 統計值可達 89%與 0.84，均優於傳統的 RF 演算法。儘管大多數類型的分類結果達到可接受水準，然而，

在景觀結構複雜的區域中，受農業的景觀多樣性及其季節性變化影響，CNN 在這些區域的分類準確度仍有提升空間。由於這些景觀的組成具有明顯的動態特徵，未來研究將考慮結合多時期的 Sentinel-2 影像，並採用具時間序列處理能力的深度學習架構，以擷取時序特徵，進一步提升模型的分類表現。



## 參考文獻

- 王禹翔、吳笙緯、魏擇壹、鄭錦桐、鍾智昕、吳淑華、鄧國楨、黃宗仁，2023。應用卷積神經網絡於自動化森林覆蓋型辨識工作，航測及遙測學刊，28(2)：125-139，DOI：10.6574/JPRS.202306\_28(2).0004。[Wang, Y.H., Wu, S.W., Wei, Z.U., Cheng C.T., Chung C.H., Wu S.H., Teng J.C., and Huang, T.J., 2023. The application of automatic forest cover detection tool with convolutional neural network, Journal of Photogrammetry and Remote Sensing, 28(2): 125-139, DOI: 10.6574/JPRS.202306\_28(2).0004. (in Chinese)]
- 林迪詒、謝嘉聲、翁綺君，2019。應用深度學習方法進行 UAV 影像植被區分類之研究，中國土木水利工程學刊，31(6): 579-588，DOI：10.6652/JoCICHE.201910\_31(6).0006。[Lin, D.Y., Hsieh, C.S., and Weng, C.C., 2019. The study of applying deep learning to vegetation classification using UAV images, Journal of the Chinese Institute of Civil & Hydraulic Engineering, 31(6): 579-588, DOI: 10.6652/JoCICHE.201910\_31(6).0006. (in Chinese)]
- 洪浩源、郭慶津、邵寶嬋、羅南璋、黃凱易，2024。應用四物候日無人機影像空間外推入侵外來種—小花蔓澤蘭之空間型態，航測及遙測學刊，29(1): 51-64，DOI：10.6574/JPRS.202403\_29(1).0004。[Hung, H.Y., Kuo, C.J., Shao, B.H., Lo N.C., and Huang, K.Y., 2024. Extrapolating the spatial patterns of invasive alien species-*Mikania micrantha* based on four phenological-Date drone images, Journal of Photogrammetry and Remote Sensing, 29(1): 51-64, DOI: 10.6574/JPRS.202403\_29(1).0004. (in Chinese)]
- 張智安、傅于洳，2021。應用深度學習於航照正射影像之房屋偵測，航測及遙測學刊，26(4): 209-220，DOI：10.6574/JPRS.202112\_26(4).0002。[Teo, T.A., and Fu, Y.J. 2021. Building detection from aerial orthoimage using deep learning technology, Journal of Photogrammetry and Remote Sensing, 26(4): 209-220, DOI: 10.6574/JPRS.202112\_26(4).0002. (in Chinese)]
- 陳偉文、卓柏漢、林莉珊，2020。火龍果與荔枝航照影像判釋－運用卷積神經網路影像辨識技術與作物特徵萃取分類演算法，航測及遙測學刊，25(1): 25-38，DOI：10.6574/JPRS.202003\_25(1).0003。[Chen W.W., Cho B.H., and Lin, L.S., 2020. Dragon fruit and litchi interpretation from aerial photographs - Using CNN network and crop feature extraction classification algorithms, Journal of Photogrammetry and Remote Sensing, 25(1): 25-38, DOI: 10.6574/JPRS.202003\_25(1).0003. (in Chinese)]
- 彭信璋、萬絢、鄭育欣，2023。應用卷積神經網路在集水區土地利用的多分類影像的分析研究，中華水土保持學報，54(2): 164-173，DOI：10.29417/JCSWC.202306\_54(2).0007。[Peng, H.W., Wan, S., and Cheng, Y.H., 2023. The study of multi-category image analysis by using convolutional neural network for land use of watershed, Journal of Chinese Soil and Water Conservation, 54(2): 164-173, DOI: 10.29417/JCSWC.202306\_54(2).0007. (in Chinese)]
- Belgiu, M., and Drăguț, L., 2016. Random forest in remote sensing: A review of applications and future directions, ISPRS Journal of Photogrammetry and Remote Sensing, 114: 24-31, DOI: 10.1016/j.isprsjprs.2016.01.011.
- Breiman, L., 2001. Random forests, Machine Learning, 45: 5-32, DOI: 10.1023/A:1010933404324.
- Chaves, M.E.D., Picoli, M.C.A., and Sanches, I.D., 2020. Recent applications of Landsat 8/OLI and Sentinel-2/MSI for land use and land cover

- mapping: A systematic review, *Remote Sensing*, 12(18): 3062, DOI: 10.3390/rs12183062.
- Congalton, R.G., 1991. A review of assessing the accuracy of classifications of remotely sensed data, *Remote Sensing of Environment*, 37(1): 35-46, DOI: 10.1016/0034-4257(91)90048-B.
- Digra, M., Dhir, R., and Sharma, N., 2022. Land use land cover classification of remote sensing images based on the deep learning approaches: A statistical analysis and review, *Arabian Journal of Geosciences*, 15(10): 1003, DOI: 10.1007/s12517-022-10246-8.
- Ioffe, S., and Szegedy, C., 2015. Batch normalization: Accelerating deep network training by reducing internal covariate shift, in proceedings of the 32nd International Conference on Machine Learning, PMLR, Lille, France, pp. 448-456.
- Kanellopoulos, I., and Wilkinson, G.G., 1997. Strategies and best practice for neural network image classification, *International Journal of Remote Sensing*, 18(4): 711-725, DOI: 10.1080/014311697218719.
- Kattenborn, T., Leitloff, J., Schiefer, F., and Hinz, S., 2021. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 173: 24-49, DOI: 10.1016/j.isprsjprs.2020.12.010.
- Garajeh, M.K., Blaschke, T., Haghi, V.H., Weng, Q., Kamran, K.V., and Li, Z., 2022. A comparison between sentinel-2 and landsat 8 OLI satellite images for soil salinity distribution mapping using a deep learning convolutional neural network, *Canadian Journal of Remote Sensing*, 48(3): 452-468, DOI: 10.1080/07038992.2022.2056435.
- Kotaridis, I., and Lazaridou, M., 2023. Cnns in land cover mapping with remote sensing imagery: A review and meta-analysis, *International Journal of Remote Sensing*, 4(19): 5896-5935, DOI: 10.1080/01431161.2023.2255354.
- Kumari, A., and Karthikeyan, S., 2023. Sentinel-2 data for land Use/land cover mapping: A meta-analysis and review, *SN Computer Science*, 4(6): 815, DOI: 10.1007/s42979-023-02214-0.
- Liu, L.Y., Wang, C.K., and Huang A.T., 2022. A deep learning approach for building segmentation in Taiwan agricultural area using high resolution satellite imagery, *Journal of Photogrammetry and Remote Sensing*, 27(1): 1-14, DOI: 10.6574/JPRS.202203\_27(1).0001.
- Maggiore, E., Tarabalka, Y., Charpiat, G., and Alliez, P., 2016. Convolutional neural networks for large-scale remote-sensing image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 55(2): 645-657, DOI: 10.1109/TGRS.2016.2612821.
- Maxwell, A.E., Warner, T.A., and Fang, F., 2018. Implementation of machine-learning classification in remote sensing: An applied review, *International Journal of Remote Sensing*, 39(9): 2784-2817, DOI: 10.1080/01431161.2018.1433343.
- Rosentreter, J., Hagenseiker, R., and Waske, B., 2020. Towards large-scale mapping of local climate zones using multitemporal Sentinel 2 data and convolutional neural networks, *Remote Sensing of Environment*, 237: 111472, DOI: 10.1016/j.rse.2019.111472.
- Schmidhuber, J., 2015. Deep learning in neural networks: An overview, *Neural Networks*, 61: 85-117, DOI: 10.1016/j.neunet.2014.09.003.
- Sharma, A., Liu, X., Yang, X., and Shi, D., 2017. A patch-based convolutional neural network for remote sensing image classification, *Neural Networks*, 95: 19-28, DOI: 10.1016/j.neunet.2017.07.017.
- Sokolova, M., and Lapalme, G., 2009. A systematic analysis of performance measures for classification tasks, *Information Processing &*

- Management, 45(4): 427-437, DOI: 10.1016/j.ipm.2009.03.002.
- Song, H., Kim, Y., and Kim, Y., 2019. A patch-based light convolutional neural network for land-cover mapping using Landsat-8 images, *Remote Sensing*, 11(2): 114, DOI: 10.3390/rs11020114.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R., 2014. Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, 15: 1929-1958.
- Teluguntla, P., Thenkabail, P.S., Oliphant, A., Xiong, J., Gumma, M.K., Congalton, R.G., Yadav, K., and Huete, A., 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, DOI: 10.1016/j.isprsjprs.2018.07.017.
- Wang, Y., Sun, Y., Cao, X., Wang, Y., Zhang, W., and Cheng, X., 2023. A review of regional and Global scale Land Use/Land Cover (LULC) mapping products generated from satellite remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 206: 311-334, DOI: 10.1016/j.isprsjprs.2023.11.014.
- Wu, C.F., Lin, Y.P., Chiang, L.C., and Huang, T., 2014. Assessing highway's impacts on landscape patterns and ecosystem services: A case study in Puli Township, Taiwan, *Landscape and Urban Planning*, 128: 60-71, DOI: 10.1016/j.landurbplan.2014.04.020.
- Yang, D., Chen, J., Zhou, Y., Chen, X., Chen, X., and Cao, X., 2017a. Mapping plastic greenhouse with medium spatial resolution satellite data: Development of a new spectral index, *ISPRS Journal of Photogrammetry and Remote Sensing*, 128: 47-60, DOI: 10.1016/j.isprsjprs.2017.03.002.
- Yang, D., Fu, C.S., Smith, A.C., and Yu, Q., 2017b. Open land-use map: A regional land-use mapping strategy for incorporating OpenStreetMap with earth observations, *Geo-spatial Information Science*, 20(3): 269-281, DOI: 10.1080/10095020.2017.1371385.
- Yıldırım, Ö., Baloglu, U.B., and Acharya, U.R., 2020. A deep convolutional neural network model for automated identification of abnormal EEG signals, *Neural Computing and Applications*, 32(20): 15857-15868, DOI: 10.1007/s00521-018-3889-z.

# Land-use and Land-cover Classification from Sentinel-2 Imagery Using Deep Learning Algorithms

Ming-Lun Lu <sup>1\*</sup>

## Abstract

Land use and land cover (LULC) maps are essential foundational data for various landscape planning and resource management applications. Convolutional neural networks (CNNs), a deep learning method, can automatically extract features from remote sensing imagery and efficiently generate LULC maps. In recent years, CNNs have emerged as a widely recognized technique for image classification. This study utilized Sentinel-2 satellite imagery to construct a CNN model with a seven-layer architecture for LULC classification and compared its performance with the random forest (RF) machine learning algorithm. The results indicate that the CNN model outperformed RF, achieving an overall accuracy of 89% and a kappa coefficient of 0.84, compared to 87% and 0.81, respectively. Among the nine LULC categories, most classifications reached acceptable levels, with the exception of grasslands, fallow rice fields, and agricultural facilities. Overall, these findings demonstrate the potential of combining CNNs with satellite imagery for large-scale LULC mapping.

**Keywords:** Remote sensing, Convolutional neural networks, Random forest, Mapping

---

<sup>1</sup> Associate Researcher, Taiwan Biodiversity Research Institute, Ministry of Agriculture

\* Corresponding Author, E-mail: alan@tbri.gov.tw

Received Date: Sep. 30, 2024

Revised Date: Dec. 12, 2024

Accepted Date: Dec.30, 2024

# 合歡山地區玉山箭竹分布與地形的關係探討

鄭絜鈺<sup>1</sup> 馮馨瑩<sup>2\*</sup>

## 摘要

合歡山區有大面積玉山箭竹覆蓋，鄰近山區相近海拔高度區域則不一定有大面積玉山箭竹分布。因此利用福衛五號衛星影像進行合歡山區地表覆蓋的非監督式分類及分類結果評估，結合 20 m 數值地形模型，進行地形分析。發現玉山箭竹所在的高度與前人研究所述一致，主要在 3100 m 至 3600 m，研究並發現箭竹分布區較針葉林的坡度緩。另從分析結果發現研究區的玉山箭竹主要分布於東坡及東南坡，與前人提出玉山箭竹多分布在南坡有差異。本研究整理出合歡山區的玉山箭竹從海拔 1800 m 以上即有分布，但 3000 m 以上箭竹林分布的面積比例大幅提高，且主要出現在山頭、山脊線等較為緩的區域。綜合上述，除了高度影響，坡度是影響合歡山區玉山箭竹分布的重要因素。

**關鍵詞：**合歡山、玉山箭竹、衛星影像、地形、非監督式分類

## 1. 前言

### 1.1 研究動機

筆者於 2023 年 11 月前往合歡東峰步道登山途中，觀察到該區域山頭呈現不同植被分布的現象，其中部分山頭為玉山箭竹覆蓋，而相似高度的其他山頭則主要為針葉林。此發現引發了對於這一現象的好奇：為何在高度相近的區域會出現不同的植被類型？由此，本研究希望釐清合歡山區箭竹與針葉林的分布範圍差異，並進一步探討箭竹分布區的海拔、坡度、坡向等地形特徵，以及這些特徵與針葉林分布區的差異。本研究透過衛星影像，結合數值地形模型 (Digital Terrain Model, DTM)，進行地形特徵分析，以回答上述問題，期望能夠增進對該區植被分布規律的理解。

### 1.2 研究目的

根據以上研究動機，擬定下列兩項具體研究目的：

(1)以福衛五號衛星影像判釋合歡山區玉山箭竹與

針葉林的分布範圍。

(2)分析比較合歡山區玉山箭竹與針葉林分布區之高度、坡度、坡向特徵。



圖 1 筆者登合歡東峰時拍攝之合歡山區植被景觀 (2023/11)

## 2. 研究區概況

### 2.1 玉山箭竹的分布地區

徐國士等(2001) 指出，高山地被植物有玉柏、玉山石松、玉山佛甲草、等高山草本植物，唯以玉

<sup>1</sup> 臺中市立大里高級中學二年級學生

<sup>2</sup> 臺中市立大里高級中學地理科教師

\* 通訊作者, E-mail: sponge@dlsh.tc.edu.tw

收到日期：民國 113 年 11 月 12 日

修改日期：民國 113 年 12 月 12 日

接受日期：民國 113 年 12 月 30 日

山箭竹佔絕對優勢，且玉山箭竹灌叢分布區域多為山頂及土地瘠薄區域，受氣候區域之影響，低溫乾旱樹木不易侵入。就臺灣而言，玉山箭竹最低可分布至海拔 1100 m 左右，但在 2800 m 以上常形成大面積而較穩定的玉山箭竹群團。臺灣山林復育協會(2023) 指出，高山玉山箭竹草原主要分布於冷杉林帶海拔帶(中部地區約 3100~3600m)。3000 m 以下的高海拔地也有零星的玉山箭竹草原分佈，但大範圍的玉山箭竹草原只出現在 3000 m 以上高山地帶(臺灣山林復育協會，2023)。玉山箭竹除了可在開闊地形成高山草原外，也可與雲杉、冷杉、鐵杉等林木混生(徐恩揚，2015)，其中開闊地形成之高山草原的植株高度大致小於 2 m，而在冷杉、鐵杉等林木下生長之玉山箭竹，植株高度則大於 2 m(吳昆松，2017)。

綜合以上文獻可知，合歡山研究區高山草原得植物群落應該不只有玉山箭竹，且玉山箭竹除生長於高山草原外，也會在森林底部生長。考量衛星影像由上至下之拍攝特性，無法清楚表現生長於針葉林下的玉山箭竹群落，故本研究僅評估生長在草原之玉山箭竹分布與地形因子之關聯。而高山草原中可能與箭竹一起生長的其他草本植物，其光譜特性應與箭竹類似，與冷杉針葉林有較大差異。因此，本研究仍以合歡山區玉山箭竹草原稱之，探討與山箭竹分布與地形的關係。

## 2.2 玉山箭竹與針葉林的分布關係

臺灣山林復育協會(2023) 也提到，臺灣高山地區冷杉林帶之下，主要有雲杉和鐵杉分布，這兩種樹種也屬於針葉林。此外，玉山箭竹主要分布於冷杉林帶，與冷杉分布海拔大致重疊。但同一地區箭竹大多生長於山脊稜線，而冷杉則分布於谷地。生態學者認為箭竹可耐強風，森林大火後迅速生長回復，故能生長於山頭、稜線；而不耐強風的冷杉，則生長於避風的谷地。因此，同一地區箭竹分布海拔高於冷杉。林茂克等(2012) 研究玉山箭竹與冷杉林下層的地被植物組成，發現合歡東峰地被植物社

會可區分為玉山箭竹草地區的高山芒型植物社會、臺灣冷杉森林邊緣的假石松—臺灣冷杉型植物社會，以及臺灣冷杉森林內為裂葉樓梯草型植物社會等三型。而位於森林邊緣的假石松—臺灣冷杉社會型可視為玉山箭竹草地及臺灣冷杉森林的推移帶。

臺灣省特有生物研究保育中心(1998) 指出，高山草原大都生長在南向、地勢較為平緩且乾燥的山坡。由以上可知，玉山箭竹草原在中高海拔地區皆可見，但主要分佈在高海拔的冷杉林帶，常生長於山頭與稜線，且南向坡度平緩的山坡更容易出現。因此，本研究將利用衛星影像判釋研究區植被覆蓋，並配合 20 m DTM 分析其地形特徵，分析玉山箭竹分布。

## 2.3 研究區地形、地質及地表覆蓋概況

圖 2 為研究區植被、地標圖，研究區內多為 3100 m 以上之高山，最高的山峰為海拔 3422 m 的合歡北峰，研究區最低海拔則為 1834 m。圖 2 中淺綠色植被為玉山箭竹，主要分布在山頂及山脊線；深綠色植被分布區為針葉林，為研究區內主要地表覆蓋。另外，顏色最淺的白色、灰色地區則為崩塌地以及道路。圖 3 為研究區地質圖，圖 3 中黑框內為本研究區範圍，約 95 km<sup>2</sup>。研究區西半部地層為中新世廬山層，東半部則為中新世大禹嶺層，本區地層走向大約成東北西南向，岩層向東傾斜，傾斜角度約為 40 至 50 度(經濟部地質調查及礦業管理中心，2019 之地質資料整合查詢網頁)。

## 3. 研究方法

### 3.1 研究流程

本研究流程如圖 4，主要透過福衛五號衛星影像判釋研究區地表覆蓋，再結合 20m 解析度 DTM，分析研究區箭竹分布面積與地形特徵的關係，討論影響箭竹分布面積的主要影響因素。

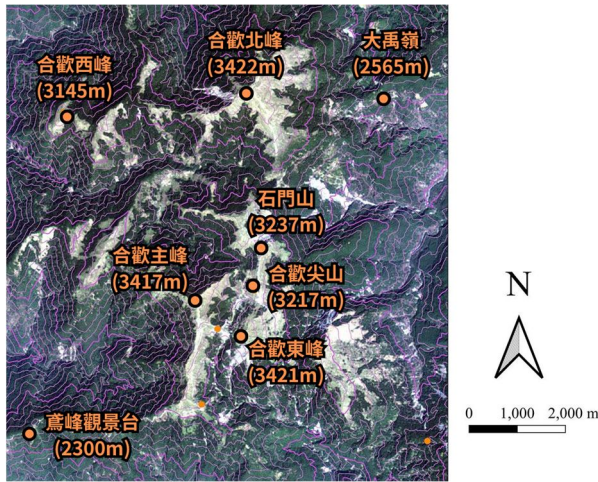


圖 2 研究區植被、地形、地標圖 (底圖為 2023 年 3 月 12 日福衛五號衛星影像，等高線以內政部 2022 年版 DTM 繪製，地標參考 google 地圖標示)



圖 3 研究區地質圖 (整理自經濟部地質調查及礦業管理中心, 2019 之地質資料整合查詢網頁)




圖 4 研究流程圖

### 3.2 福衛五號衛星影像蒐集

本研究衛星影像資料蒐集過程如下：首先，透過國家太空中心網站的「福衛影像申購」系統線上申請影像資料，進入「資料市集」選擇 2023 年福爾摩沙衛星五號 L4 南投資料夾，並填寫申請單，經主管單位核准後即可下載影像。下載後的影像檔名為 FS5\_G058\_MS\_L4TWD97\_20230312\_024912.zip。將此檔案解壓縮並裁切後，便可取得 2023 年 3 月 12 日拍攝的研究區多光譜衛星影像，包含紅光(B1)、綠光(B2)、藍光(B3) 及近紅外光(B4) 四個波段，且空間解析度為 4 m (劉小菁等, 2014)。

### 3.3 植生指標計算與影像合成

#### 3.3.1 標準化植生指標(NDVI)的計算

本研究區主要的地表覆蓋為針葉林與玉山箭竹，因此採用標準化植生指標來協助地表覆蓋的判釋。標準化植生指標 (NDVI) 為利用衛星影像判釋植被覆蓋時常用的指標 (黃麗娟等, 2008)，其計算方式為：

$$NDVI = (NIR - R) / (NIR + R) \dots\dots\dots (1)$$

公式(1) 中，NDVI 為標準化植生指標，NIR 為近紅外光波段數值，R 為紅光波段數值。NDVI 數值介於-1~1。

#### 3.3.2 福衛五號衛星影像+NDVI 圖層的製作方式

前人研究指出以像元為基礎的影像分類法，效果常不令人滿意 (謝漢欽等, 2017)，部分學者嘗試加入其他技術輔助影像判釋，如謝漢欽及黃俊元 (2020) 使用以物件為基礎的影像分割技術，進行森林覆蓋地的 NDVI 影像判釋，獲得不錯的判釋成果。考量合歡山研究區的植被覆蓋相對單純，因此仍採用像元為基礎的分類方法，但嘗試在福衛五號衛星影像原有的紅光、綠光、藍光及近紅外光四個波段外，加入 NDVI，成為一個五波段的影像，期能提高 QGIS 外掛軟體 Semi-Automatic Classification

Plugin (SCP) 非監督式分類之精度。上述五波段影像資料處理的程序如下：

#### (1) 福衛五號衛星影像各波段資料的抽取

利用 Raster Calculator 可分別抽取福衛五號衛星影像的四個波段，使其成為單獨紅光、綠光、藍光及近紅外光波段圖層。以抽取紅光波段為例，其做法為：在 QGIS 中打開研究區福衛五號衛星影像，開啟 Raster Calculator，以滑鼠點選紅光波段並將抽取後的檔案命名、存檔，即可獲得單獨的紅光波段圖層 (圖 5)。

#### (2) NDVI 資訊放大的方式

觀察圖 5 可發現，NDVI 數值明顯小於其他四個波段，為了避免 SCP 進行非監督式分類時因 NDVI 數值過小權重太低，而影響分類結果，本研究在 Raster Calculator 以下列公式將 NDVI 波段數值放大：

$$\text{NDVI intensify} = (\text{NDVI} + \text{NDVImax}) * \text{NIRmax} / (\text{NDVImax} - \text{NDVimin}) \dots\dots\dots (2)$$

公式(2) 中，NDVI intensify 為放大後的 NDVI 數值，NDVImax 為該 NDVI 圖層中的最大數值，NDVimin 為該圖層中的最小值，NIRmax 為近紅外光圖層中的最大數值，該數值會依據實際分類需求做適當調整，以獲得精度更高的分類結果。

#### (3) 紅光、綠光、藍光、近紅外光波段與 NDVI 資料的結合

本研究利用 QGIS 中的 Raster / Miscellaneous / Build Virtual Raster 功能、將上述獨立的紅光、綠光、藍光、近紅外光及 NDVI 波段結合成一個五波段影像圖層。

### 3.4 非監督式分類的操作與地表覆蓋之判釋

依據研究目的將研究區地表覆蓋分為針葉林、玉山箭竹及崩塌地與車道三大類，資料處理及判釋程序如下：

#### 3.4.1 非監督式分類的操作

利用 SCP 外掛程式的 Band Set 載入上述五波段影像圖層，接著用 Band Processing / Clustering 進行非監督式分類，選擇 ISODATA 模式。因研究區地表覆蓋大致為玉山箭竹、針葉林、崩塌地及車道等類型，相對單純，因此將非監督式分類的項目數設定為五類，其餘參數皆採用軟體預設值，執行後即可獲得一幅研究區五類地表覆蓋分布圖 (圖 6)。

#### 3.4.2 分類結果的判釋

以人工判斷編號 1 到 5 類分別是何種地表覆蓋，依本研究的操作經驗發現，其中三類可對應針葉林，一類為玉山箭竹，其餘一類為車道與崩塌地的地表覆蓋。因此後續操作會將三類針葉林合併，並針對針葉林、箭竹、崩塌與地車道三大類地表覆蓋進行分類結果評估。




圖 5 以 QGIS 操作福衛五號衛星影像波段抽取與疊合



### 3.4.3 三類地表覆蓋影像圖層的建立

使用 Raster Calculator 將上述圖層的針葉林、玉山箭竹、車道及崩塌地分類結果影像，分別抽取成獨立的影像圖層，如圖 7 底圖即為玉山箭竹分布圖。

本研究應用以上影像分類方法，分別進行研究區福衛五號原始 4 波段影像、NDVI 影像、原始 4 波段加 NDVI 影像等三種影像的地表覆蓋分類，並做分類結果的評估比較，選出最佳分類結果進行後續的分析。

## 3.5 地表覆蓋非監督式分類結果的評估

### 3.5.1 三類地表覆蓋驗證區域的圈選

運用 Google 衛星影像為底圖，以人工判釋方式，分別圈選玉山箭竹、針葉林及崩塌地與車道等三類地表覆蓋，各 20 個樣本。並將圈選好的樣本圖層，以 kml/kmz 格式匯出，做為非監督式影像分類成果的評估標準。




圖 6 非監督式分類分類結果




圖 7 箭竹林分類精度評估，白色區域為分類為箭竹林地區，多邊形區域為實際地表覆蓋類型驗證區範圍，黃色為針葉林，橘色為箭竹林，紫色崩塌地車道

### 3.5.2 誤差矩陣關係表的製作與生產者精度、使用者精度、整體精度及 kappa 係數的定義及計算

誤差矩陣關係表 (表 1) 是評估影像分類精確程度的基礎，利用誤差矩陣關係表，可以進一步計算各類地表覆蓋分類成果之生產者精度與使用者精度，也可計算影像分類之整體精度以及 Kappa 係數，本研究用以下步驟製作誤差矩陣關係表：

#### (1) 誤差矩陣表的製作

分別開啟三類地表覆蓋驗證區之向量圖層以及分類成果影像圖層。如圖 7，以玉山箭竹為例：使用 Processing / tool box / Zonal Statistics 功能計算三類地表覆蓋驗證區域內被分類為玉山箭竹之網格數量，即可填寫表 1 中 A 行之數據。將圖 7 底圖依序換成針葉林、崩塌地車道分類成果圖層，重複以上步驟，即可獲得表 1 中 B 行和 C 行的數據。

#### (2) 分類精度的評估指標

- A. 生產者精度：指某類別被正確分類佔所有分類結果之比例，計算方式如表 1 直行。
- B. 使用者精度：指地表覆蓋物經分類後，得被正確歸類的比例，計算方式如表 1 橫列。

C. 整體精度：正確分類量佔總資料量的比例，計算方式為表 1 對角線數值加總除以總資料量。

D. Kappa 係數：可表示分類成果較隨機分類結果好多少。計算公式如下：

$$Kappa = (\text{整體精度} - \text{期望精度}) / (1 - \text{期望精度}) \dots\dots (3)$$

### 3.6 箭竹林及針葉林區的高度、坡度、坡向分析方式

本研究針對玉山箭竹與針葉林的分布進行地形特徵分析，主要步驟如下：首先，在 QGIS 中利用 20m DTM 影像圖層生成坡度圖 (使用 Raster / Analysis / Slope 功能) 和坡向圖 (使用 Raster / Analysis / Aspect 功能)，其中坡度以角度表示，坡向以方位角表示。接著，通過 QGIS 的 Vector / Research / Grid 功能建立研究區 20m 網格系統，並透過 Processing / Tool Box / Zonal Statistics 功能，利用網格系統逐一擷取每個網格的高度、坡度、坡向值。此外，同樣使用 Zonal Statistics 功能擷取玉山箭竹林和針葉林分布區的植被覆蓋資料。以獲取研究區 20m 解析度的高度、坡度、坡向與植被覆蓋 (箭竹林或針葉林) 資料，詳如表 2、圖 8 所示。




圖 8 研究區 20 m 網格地表覆蓋分布圖

## 4. 研究結果與討論

### 4.1 衛星影像地表覆蓋分類結果

#### 4.1.1 福衛五號原始四波段影像之分類結果

表 3 為研究區福衛五號衛星影像原始 4 波段 ISODATA 分類成果精度評估表。由表 3 可發現，以原始 4 波段影像的 ISODATA 分類成果已可達一定水準。其中整體精度達 98.2%，Kappa 係數為 0.913，針葉林區的生產者精度及使用者精度達 99.9%，玉山箭竹的生產者精度達 87.7%，使用者精度為 93.8%，但崩塌地及車道的生產者精度與使用者精度略低，為 72.5%而其使用者精度更低，只有 52.9%。

#### 4.1.2 福衛五號 NDVI 影像之分類結果

表 4 為研究區 NDVI 影像 ISODATA 分類成果精度評估表，由表 4 可發現，分類成果精度偏低。整體精度為 86.5%，Kappa 係數只有 0.541，其中，玉山箭竹與車道崩塌地的使用者精度分別只有 44.8%及 38.6%，顯示誤判情況頗為嚴重。

#### 4.1.3 福衛五號衛星影像配合 NDVI 影像之分類結果

表 5 為研究區福衛五號衛星影像配合 NDVI 影像 ISODATA 分類成果精度評估表，由表 5 可知，此為三種組合中，精度最佳者。整體精度達 99.2%，Kappa 係數為 0.961，各類別地表覆蓋之生產者精度與使用者精度皆達 92%以上。

表 1 誤差矩陣關係表示意

分類成果(classification)	地面參考資料 (reference data)				
	種類	A(箭竹林)	B(針葉林)	C(崩塌地)	列總計
a(箭竹林)	XAa(1)	XBa(2)	XCa(3)	(1)+(2)+(3)=asum	(1)/asum
b(針葉林)	XAb(4)	XBb(5)	XCb(6)	(4)+(5)+(6)=bsum	(5)/bsum
c(崩塌地)	XAc(7)	XBc(8)	XCc(9)	(7)+(8)+(9)=csum	(9)/csum
行總計	(1)+(4)+(7)=Asum	(2)+(5)+(8)=Bsum	(3)+(6)+(9)=Csum	(1)+(2)+...+(9)=All sum	
生產者精度	(1)/Asum	(5)/Bsum	(9)/Csum		

資料來源：本表參考方彥凱 (2004) 繪製

表 2 以研究區 20m 網格擷取獲得高度、坡度、坡向及覆蓋植被種類示意表，其中植被影像像元數超過該網格總像元數 1/2 以上者，則判定該網格為該類植被覆蓋區，如 id：894 即為玉山箭竹林覆蓋區

id	海拔高度 (m)	坡度	坡向	坡向八方位	20m 網格總像元數	箭竹林像元數	針葉林像元數
374	1834	0.0	0.0	N	16	2	13
893	1834	5.4	273.8	W	16	6	9
373	1835	0.0	0.0	N	16	2	9
1413	1838	7.3	330.9	NW	16	7	9
1412	1838	14.0	241.5	SW	16	2	14
892	1838	19.6	210.6	SW	16	6	10
375	1839	0.0	0.0	N	16	3	13
894	1839	14.1	2.9	N	16	14	2
1933	1841	6.6	319.4	NW	16	7	9

表 3 研究區福衛五號衛星原始 4 波段影像 ISODATA 分類成果精度評估表

分類成果(classification)	地面參考資料 (reference data)					
	種類	箭竹林	針葉林	崩塌地車道	列總計	使用者精度
箭竹林		7520	63	431	8014	93.8%
針葉林		94	80703	0	80797	99.9%
崩塌地車道		958	52	1134	2144	52.9%
行總計		8572	80818	1565	90955	
生產者精度		87.7%	99.9%	72.5%		

表 4 研究區 NDVI 影像 ISODATA 分類成果精度評估表

分類成果 (classification)	地面參考資料 (reference data)					
	種類	箭竹林	針葉林	崩塌地車道	列總計	使用者精度
箭竹林		7456	9173	18	16647	44.8%
針葉林		662	69635	0	70297	99.1%
崩塌地車道		454	2010	1547	4011	38.6%
行總計		8572	80818	1565	90955	
生產者精度		87.0%	86.2%	98.8%		

表 5 研究區福衛五號衛星原始四波段加入 NDVI 影像 ISODATA 分類成果精度評估表

分類成果 (classification)	地面參考資料 (reference data)					
	種類	箭竹林	針葉林	崩塌地車道	列總計	使用者精度
箭竹林		8447	549	29	9025	93.6%
針葉林		20	80248	0	80268	100.0%
崩塌地車道		105	21	1536	1662	92.4%
行總計		8572	80818	1565	90955	
生產者精度		98.5%	99.3%	98.1%		

## 4.2 玉山箭竹與針葉林分布區的地形特徵

### 4.2.1 研究區玉山箭竹與針葉林分佈面積比例

圖 9 為研究區玉山箭竹與針葉林分布面積比例圖，由圖 9 可知，研究區大部分地表覆蓋皆為針葉林，玉山箭竹覆蓋區域則為 12.2%。




圖 9 研究區玉山箭竹林與針葉林分布面積比例

### 4.2.2 玉山箭竹與針葉林分佈面積與高度的關係

因前人研究提及大面積玉山箭竹分布主要位於海拔較高的冷杉林帶 (臺灣山林復育協會, 2023)，因此本研究將研究區依據海拔高度每 200 m 為一組，由 1800 m 至 3422 m 共分為 8 組，觀察不同海拔高

度玉山箭竹分布是否有所差異。圖 10 為研究區以每 200 m 海拔高度分組之玉山箭竹與針葉林分布面積比例圖。由圖 10 可發現海拔 3000 m 以下的玉山箭竹林分布面積比例偏低，大致小於 18%，而海拔 3000 m 以上區域，玉山箭竹分布面積比例則有顯著提升，尤其 3200 m 以上區域，玉山箭竹分布面積達 50% 以上。




圖 10 研究區每 200 m 海拔高度分組之箭竹林與針葉林分布面積比例




圖 11 研究區箭竹與針葉林隨高度累計面積比例

圖 11 為研究區箭竹與針葉林隨高度累計面積比例折線圖，由圖 11 可發現，研究區內生長在海拔 3000 m 以上地區的的箭竹，佔總箭竹面積的 57%。而生長在 3000 m 以上地區的針葉林，只佔總針葉林面積的 14%。

### 4.2.3 玉山箭竹與針葉林分佈面積與坡度的關係

圖 12 為研究區各坡度帶箭竹與針葉林面積比例柱狀圖，由圖 12 可發現，研究區內坡度低於 30 度的區域，箭竹生長面積占地表面積的比例大致都在 20% 以上，而坡度 30 度以上的區域，箭竹面積則不到 10%，顯示研究區箭竹多分布在坡度較平緩的地區。




圖 12 研究區各坡度帶箭竹與針葉林面積比例

圖 13 為研究區箭竹與針葉林隨坡度累計面積比例折線圖，由圖 13 可觀察到，研究區內 66% 的箭竹都分布在坡度 30 度以下較平緩範圍，而坡度 30 度以下的針葉林面積只佔總針葉林面積的 34%。




圖 13 研究區箭竹與針葉林隨坡度累計面積比例

### 4.2.4 玉山箭竹與針葉林分佈面積與坡向的關係

圖 14 為研究區各坡向帶箭竹與針葉林面積比例柱狀圖，由圖 14 可發現，箭竹在東北、東、東南及南四個方位生長面積比例較高，地表大致 16% 以上為箭竹覆蓋區；而其他四個方位（北、西南、西、西北），則不到 10% 的地表面積有箭竹覆蓋。




圖 14 研究區各坡向帶箭竹與針葉林面積比例




圖 15 研究區箭竹與針葉林各坡向面積比例

圖 15 為研究區箭竹與針葉林各坡向面積比例雷達圖，由圖 15 可知，生長在偏東（東北、東、東南、南）坡向的箭竹，佔總箭竹面積的 80%；而生長在偏東坡向的針葉林，其面積只佔總針葉林面積的 49%。

由圖 15 也可發現，偏東坡向的地表面積（圖 15 全區）範圍佔研究區總面積的 54%，佔比較偏西坡向的地表面積大，因此推測研究區偏東坡應較為平緩。

於是進一步計算偏東坡和偏西坡的坡度平均值及標準差，並進行 t 檢定，結果如表 6。由表 6 可發現，偏東坡的坡度確實較偏西坡平緩，而箭竹多

分布在偏東坡，有可能是因為該坡向地表的坡度較為平緩所致。

表 6 研究區兩組坡向的平均數、標準差及 t 檢定結果

坡向分組	坡度 平均值	坡度 標準差	t 檢定 p 值	f 檢定 p 值
偏東南坡	29.7 °	9.1 °	0.000000	0.000000
偏西北坡	35.6 °	11.0 °		

備註：偏東南坡包含東北、東、東南、南等坡向；  
偏西北坡包含西南、西、西北、北等坡向。

### 4.3 玉山箭竹生長面積與海拔高度、坡度的關係

根據上述資料，可判斷研究區玉山箭竹的生長面積應與海拔高度、坡度、坡向有關。將研究區的地表依據海拔高度、坡度、坡向，分成 12 種地形組合，如表 7。分別計算出這 12 種地形組合的地表面積、箭竹面積、箭竹面積佔地表面積比例、平均高度及平均坡度 (表 7)。

接著以平均海拔高度為橫軸，平均坡度為縱軸，繪製 XY 散布圖，再將箭竹面積比例，以比例圓的方式標在散布圖中相對應的位置，如圖 16。由圖 16 可發現，海拔高且坡度平緩的區域，玉山箭竹的面積較大；而海拔高度低、坡度較陡的區域，玉山箭竹的面積則較小。

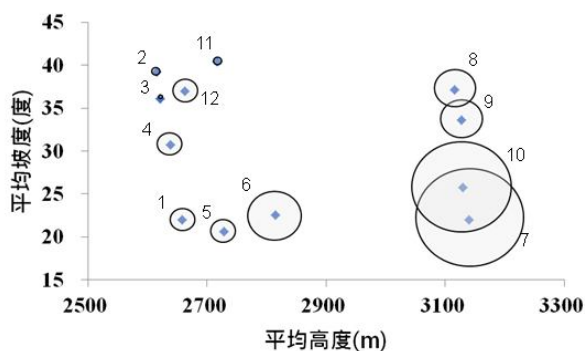


圖 16 研究區 12 組地形分區之平均高度、平均坡度與箭竹面積比例關係圖，圖中圓圈大小代表該地形分區的箭竹面積比例，圓圈旁的阿拉伯數字為地形分區編號，地形分區的高度、坡度特徵標準請參考表 7

進一步利用表 7 數據，以平均高度為橫軸，箭竹面積比例為縱軸做線性迴歸，如圖 17，可發現平

均高度與箭竹面積比例呈正相關， $R^2$  為 0.67。而平均坡度與箭竹面積比例的線性迴歸，則呈現負相關， $R^2$  為 0.31 (圖 18)。




圖 17 研究區 12 個地形分區之平均高度與箭竹面積比例的關係




圖 18 研究區 12 個地形分區之平均坡度與箭竹面積比例的關係

再將海拔高度、坡度及箭竹生長面積比例做複迴歸分析，結果如表 8-10。由表 8 及表 9 可發現，海拔高度及坡度的確是影響研究區箭竹面積的重要因素，其中表 8B 中的  $R^2$  值顯示，研究區箭竹面積的大小，75%可由海拔高度與坡度兩個因素決定。而表 10 中海拔高度的 p 值較坡度的 p 值小，則可得知海拔高度應是影響研究區箭竹面積最重要的因素。此與前人研究提到的：大範圍玉山箭竹草原只會出現在海拔 3000 m 以上地區一致 (臺灣山林復育協會，2023)。由於本研究區海拔由 1834 m~3422 m，高度跨距較大，若只觀察 3000 m 以上區域，則會發現箭竹面積明顯受坡度的影響 (圖 16)。除了海拔高度與坡度，影響箭竹面積的其他因素，推測為受坡向影響而導致的雨量、日照量及土壤性質的差異。

表 7 研究區 12 組地形分區之平均高度、平均坡度與箭竹面積比例的關係

地形組合 編號	地形組合特徵	全區面積 (網格數)	箭竹面積 (網格數)	箭竹比例 (%)	平均高度 (m)	平均坡度 (度)
1	<3000m, <30 度	66512	6987	10.5	2659	22.0
2	<3000m, >=30 度	123888	5592	4.5	2616	39.3
3	<3000m, NW	88359	1675	1.9	2622	36.1
4	<3000m, SE	102041	10904	10.7	2638	30.7
5	<30 度, NW	26578	3217	12.1	2728	20.6
6	<30 度, SE	64886	16095	24.8	2815	22.5
7	>=3000m, <30 度	24952	12325	49.4	3140	22.0
8	>=3000m, >=30 度	22869	4202	18.4	3115	37.2
9	>=3000m, NW	21173	4157	19.6	3127	33.6
10	>=3000m, SE	26648	12370	46.4	3129	25.7
11	>=30 度, NW	82954	2615	3.2	2717	40.4
12	>=30 度, SE	63803	7179	11.3	2663	37.0

表 8 研究區 12 組地形分區箭竹面積比例與平均高度、平均坡度的複回歸分析結果之一

迴歸統計	
R 的倍數	0.89324
R 平方	0.79787
調整的 R 平方	<b>0.75295</b>
標準誤	7.77734
觀察值個數	12

表 9 研究區 12 組地形分區箭竹面積比例與平均高度、平均坡度的複回歸分析結果之二

ANOVA					
	自由度	SS	MS	F	顯著值
迴歸	2	2148.833	1074.416	17.76276	<b>0.00075</b>
殘差	9	544.383	60.487		
總和	11	2693.216			

表 10 研究區 12 組地形分區箭竹面積比例與平均高度、平均坡度的複回歸分析結果之三

	係數	標準誤	t 統計	P-值
截距	-96.1607	33.4992	-2.8705	0.0185
X 變數 1-平均高度	0.0494	0.0106	4.6519	<b>0.0012</b>
X 變數 2-平均坡度	-0.8442	0.3162	-2.6701	<b>0.0256</b>

## 5. 結論

環境條件 (如氣候、土壤、海拔、坡度和坡向) 是影響植物的分布的重要因素，但植物在生態系統中對資源的需求和對環境的耐受性不同，即便環境相似，不同植物也可能在資源利用上有所差異，導致相似的環境條件未必會有完全相同的植物分布，具體分布情形仍依賴植物的生態適應、競爭關係以及環境的歷史和擾動等綜合因素決定。本研究透過福衛五號衛星影像分析合歡山區玉山箭竹與針葉

林之分布關係，並結合 20 m DTM 資料分析其分布區之高度、坡度、坡向等特徵，以討論玉山箭竹生長喜好的環境條件。

非監督式影像分類結果中，研究發現將福衛五號原始四波段加上 NDVI 成為五波段影像，並以 ISODATA 分類，可獲得最佳分類成果。而分析地表覆蓋與地形間的關係，則發現 3000 m 以上區域、整體坡度較平緩的東坡、東南坡，是玉山箭竹主要分布區。玉山箭竹分布海拔高度則與前人研究提及的：玉山箭竹在冷杉林帶等海拔較高區域，才得以大面

積生長的說法一致 (臺灣山林復育協會, 2023)。而根據分析結果, 本研究認為坡度為影響玉山箭竹分布的另一重要因素。

## 參考文獻

- 方彥凱, 2004。常態化植生指數標準差於土地利用分類之應用—以美濃中壇為例, 國立屏東科技大學土木工程學系碩士論文。[Fang, Y.K., 2004. Application on land cover classification using normalized difference vegetation indices —A case study at Meinung Zhangtan area, Master Thesis, National Pingtung University of Science and Technology, Taiwan, ROC. (in Chinese)]
- 吳昆松, 2017。玉山箭竹在不同光環境下葉片形態與生理特性的比較, 國立臺灣大學生態學與演化生物學研究所碩士論文。[Wu, K.S., 2017. The comparisons of leaf morphological and physiological traits of *Yushania niitakayamensis* growing under different light environments, Master Thesis, National Taiwan University. (in Chinese)]
- 林笈克、黃江綸、黃建陸、許秋容、楊國禎, 2012。臺灣中部合歡東峰玉山箭竹草地與臺灣冷杉林地被植群之研究, 國家公園學報, 22(4): 21-33。[Lin, J.K., Huang, C.L., Huang, J.L., Sheue, C.R., and Yang K.C., 2012. A study of the ground vegetation of *Yushania niitakayamensis* grassland and *Abies kawakamii* forest in the eastern peak of Hehuanshan, Central Taiwan, Journal of National Park, 22(4): 21-33. (in Chinese)]
- 徐恩揚, 2015。玉山箭竹, <https://highscope.ch.ntu.edu.tw/wordpress/?p=63540>, 引用日期 2024/12/15。[Hsu, E.Y., 2015. *Yushania niitakayamensis*, Available at: <https://highscope.ch.ntu.edu.tw/wordpress/?p=63540>, Accessed December 15, 2024. (in Chinese)]
- 徐國士、宋永昌、呂勝由, 2001。臺灣植被類型圖說, 國立臺灣科學教育館, 台北市。[Hsu, K.S., Sung, Y.C., and Lu, S.Y., 2001. Illustration of

vegetation in Taiwan, National Taiwan Science Education Center, Taipei. (in Chinese)]

- 黃麗娟、莊智璋、何世華、林昭遠, 2008。衛星影像植生指標優選之研究, 水土保持學報, 40(1): 39-50。[Huang, L.C., Chuang, C.W., Ho, S.H., and Lin C.Y., 2008. Selection of optimum vegetation index from SPOT satellite image, Journal of Soil and Water Conservations, 40(1): 39-50. (in Chinese)]
- 經濟部地質調查及礦業管理中心, 2019。地質資料整合查詢, <https://geomap.gsmma.gov.tw/gwh/gsb97-1/sys8a/t3/index1.cfm>, 引用日期 2024/12/15。[Geological Survey and Mining Management Agency, MOEA, 2019. National Geological Data Warehouse, Available at: <https://geomap.gsmma.gov.tw/gwh/gsb97-1/sys8a/t3/index1.cfm>, Accessed December 15, 2024. (in Chinese)]
- 臺灣山林復育協會, 2023。臺灣的植群分布與植物多樣性第八章冷杉林帶植群, <https://www.reforestation.tw/?p=14303>, 引用日期 2024/12/14。[Taiwan Reforestation Association, 2023. Distribution and diversity of vegetation in Taiwan, Chapter 8 *Abies kawakamii* forest zone, Available at: <https://www.reforestation.tw/?p=14303>, Accessed December 14, 2024. (in Chinese)]
- 臺灣省特有生物研究保育中心, 1998。台灣的高山草原, [https://www.tbri.gov.tw/redirect\\_file.php?theme=web\\_structure&id=2254](https://www.tbri.gov.tw/redirect_file.php?theme=web_structure&id=2254), 引用日期 2024/06/30。[Taiwan Endemic Species Research Institute, 1998. Highland grassland in Taiwan. Available at: [https://www.tbri.gov.tw/redirect\\_file.php?theme=web\\_structure&id=2254](https://www.tbri.gov.tw/redirect_file.php?theme=web_structure&id=2254), Accessed June 30, 2024. (in Chinese)]
- 劉小菁、曾世平、林喆、張和本, 2014。福衛五號遙測酬載系統工程經驗, 航測及遙測學刊,



- 18(1): 29-38, DOI: 10.6574/JPRS.2014.18(1).3。  
[Liu, C., Tseng, M., Ling, J., and Chang, H.P., 2014. The system engineering experience of FORMOSAT-5 remote sensing instrument, *Journal of Photogrammetry and Remote Sensing*, 18(1): 29-38, DOI: 10.6574/JPRS.2014.18(1).3 (in Chinese)]
- 謝漢欽、黃俊元，2020。應用 NDVI 與地景指標評估林地利用的衝擊地以苗栗獅潭地區多期福衛二號影像為例，*台灣林業科學*，35(2): 73-91，DOI: 10.7075/TJFS.202006\_35(2).0005。[Hsieh, H.C., and Huang, C.Y., 2020. Using NDVI and Landscape Metrics to Assess Impacts of Forest Land-Use in Shitan, Miaoli with Multi-Temporal FORMOSAT-2 Images *Taiwan Journal of Forest Science*, 32(3): 203-222, DOI : 10.7075/TJFS.201709\_32(3).0003. (in Chinese)]
- 謝漢欽、鍾智昕、黃俊元，2017。應用 NDVI 植生指標與平均值調整影像分割法於崩裸地萃取—以六龜試驗林地區多期福衛二號影像為例，*台灣林業科學*，32(3)：203-222，DOI：10.7075/TJFS.201709\_32(3).0003。[Hsieh, H.C., Chung, C.H., and Huang, C.Y., 2017. Using the NDVI and mean shift segmentation to extract landslide areas in the Lioukuei Experimental Forest region with multi-temporal FORMOSAT-2 images, *Taiwan Journal of Forest Science*, 32(3): 203-222, DOI: 10.7075/TJFS.201709\_32(3).0003. (in Chinese)]

## Discussion on the Relationship between the Distribution and Topography of Yushan Cane in Hehuan Mountain Area

Chieh-Fang Cheng <sup>1</sup>      Hsin-Ying Feng <sup>2\*</sup>

### Abstract

The Hehuan Mountain area has extensive coverage of Yushan Cane, while neighboring areas at similar altitudes do not exhibit widespread distributions of Yushan Cane. Therefore, an unsupervised classification of surface cover was conducted on the Hehuan Mountain area using Formosat-5 satellite images, and the classification results were evaluated. This process was combined with a 20m DTM for terrain analysis. The study found that the altitude range where Yushan Cane is located aligns with previous research, primarily between 3100-3600m. It also revealed that areas with Yushan Cane have gentler slopes than those with Abies Zone. Furthermore, the analysis showed that Yushan Cane in the study area is mainly distributed on eastern and southeastern slopes, differing from previous studies that indicated a southern slope preference.

This study found that Yushan Cane is distributed at elevations above 1800m in the Hehuan Mountain area, with a significant increase above 3000m, primarily on mountain peaks, ridges, and other gentler terrain. In summary, besides altitude, slope is a key factor influencing the distribution of Yushan Cane in the Hehuan Mountain area.

**Keywords: Hehuan Mountain, Yushan Cane, Satellite Images, Digital Terrain Model, Unsupervised Classification**

---

<sup>1</sup> Senior Student, Dali Senior High School, Taichung Municipal

<sup>2</sup> Geography Teacher, Taichung Municipal Dali Senior High School

\* Corresponding Author, E-mail: sponge@dlsh.tc.edu.tw

Received Date: Nov. 12, 2024

Revised Date: Dec. 12, 2024

Accepted Date: Dec.30, 2024

## 中文稿件投稿注意事項（英文稿件請參閱下頁 Author Guidelines）

本學刊定期出版攝影測量及遙感探測領域之學術論著、技術短文(按中文及英文摘要、關鍵字、前言、材料及方法、結果、討論、參考文獻等撰寫)及應用性報導。收錄之稿件 皆經本編輯委員會安排之專家學者審查程序，並由通訊作者簽署著作權讓渡書。作者可自行聲明文稿和所屬類別，本編輯委員會將依此及審查委員意見決定收錄 文稿之類別。本學刊不接受已經刊載過之文稿，於研討會發表過之論文，經適當增補其內容者為例 外。

投稿地址為 [jprsubmit@gmail.com](mailto:jprsubmit@gmail.com)，請以附件寄送稿件之 WORD 檔及 PDF 檔各一份。為便利編審作業，請於 PDF 稿件中移除作者資料(如姓名、服務機關、電話、及電子郵件信箱等)。稿件撰寫要點如下：

1. 頁面：採用 A4 規格頁面。
2. 字體：(1) 中文均以新細明體橫式打字；(2) 英文均以 Times New Roman 字體橫式打字。
3. 單位：內文、圖表及符號中之度量單位皆採用 SI 公制單位。
4. 首頁：首頁應含內容依次為「題目、作者姓名、摘要、關鍵詞、及作者服務機關及職稱（置於頁尾）」，接續文稿內文。
5. 末頁：末頁應含內容與首頁相同，但皆以英文書寫。
6. 題目：論文題目宜簡明，字體大小為 20 粗體，英文題目每字第一位字母以大寫字體打印。
7. 作者：作者姓名列於題目之下方，字體大小為 14 粗體，其服務機關及職稱以<sup>1,2,...</sup>上標編號註記於頁尾，字體大小為 9。
8. 摘要：摘要字數以 250 字為限，字體大小為 10 粗體。
9. 關鍵詞：列出三至五個關鍵詞，字體大小為 12 粗體。
10. 章節及標題：(1) 章節標題置中，編號一律為阿拉伯數字，如 1, 2, ...，標題字體大小為 18 粗體；(2) 小節標題靠左，編號一律為 1.1, 1.2, 1.1.1, 1.1.2.....，字體大小為 14 粗體。
11. 內文：內文之長度(含圖表)以不超過 22 頁為原則，各段落第一行應縮排，字體大小為 10。
12. 數學式：所有數學式均須標式號於圓括弧內，數學式內所有符號須於符號第一次出現時，應於數學式下方逐一加以定義。
13. 圖及影像：(1) 圖及影像均須數位化置於文稿中適當位置；(2) 所有圖及影像下方須附圖流水編號及說明；(3) 本刊接受彩色圖及影像，但紙版印刷一律採灰階印刷；(4) 結尾毋加「。」及「.」。
14. 表格：(1) 表格均須數位化置於文稿中適當位置；(2) 所有表格上方須附表流水編號及說明；(3) 本刊接受彩色表格，但紙版印刷一律採灰階印刷；(4) 結尾毋加「。」及「.」。
15. 參考文獻(中、日文須英譯)：(1) 參考文獻應列於文末，文稿中未直接引用者不得列入；(2) 中文文獻需加英文翻譯，於結尾加上(in Chinese)，日文書寫同中文文獻，於結尾加上(in Japan)。先排列中、日文參考文獻，再排列英文參考文獻，其他文字參考文獻列於英文參考文獻之後；(3) 中文參考文獻以第一作者 姓名筆劃順序排列，英文參考文獻以第一作者之姓依英文字母順序排列。當作者相同時，依發表年代排列，作者及發表年代完全相同時，依日期在年代後加以 a, b, c 順序。第一作者姓名相同時，先排列單一作者之參考文獻，其次為多作者文獻；(4) 參考文獻之格式如下列：
  - 期刊論文：作者姓名，年代。文章標題，期刊名稱，卷數(期數)：起始頁數 - 結束頁數。
  - 書籍：作者姓名，年代。書名，出版者，出版地。
  - 研討論文集：作者姓名，年代。篇名，論文集名稱，發表地點，卷(期)：起始頁數 - 結束頁數。
  - 網路引用：作者姓名，年代。篇名，取自網址，檢索日期。
16. 參考文獻引用：(1) 作者為一人時，以作者全名(中文文獻)或姓(英文文獻)及發表年代，如楊明德(2007)或(楊明德，2007)、Yang (2007)或(Yang, 2007)；(2) 作者為二人時，以二作者全名(中文文獻)或姓(英文文獻)及發表年代，如楊明德及蘇東青(2014) 或(楊明德及蘇東青，2014)、Yang & Su (2014)或(Yang & Su, 2014)；(3) 作者為多人時，以第一作者全名(中文文獻)或姓(英文文獻)，之後加「等」(中文文獻)或「*et al.*」(英文文獻)及發表年代，如(楊明德等，2016)或楊明德等(2016)、Yang *et al.* (2016)或(Yang *et al.*, 2016)，「*et al.*」請以斜體；(4) 作者及發表年代完全相同時，依日期在年 代後加以 a, b, c 引用，如 Yang & Su (2008a)、Yang & Su (2008b)。

# Author Guidelines

The Journal of Photogrammetry and Remote Sensing periodically publishes academic articles, technical short papers, and application reports addressing topics in photogrammetry and remote sensing. Acceptance of submitted manuscripts for publication is based on a peer-reviewing process arranged by the editorial board. A manuscript will not be formally accepted until a copyright agreement is received. Although authors can indicate their submitted manuscripts belonging to one of the categories of academic articles, technical short papers or application reports, the editorial board will make the final decision based on the suggestions of reviewers. This journal accept no paper ever been published, but a revised appropriately paper published in conference proceedings is an exception.

The manuscript submission address is [jprsubmit@gmail.com](mailto:jprsubmit@gmail.com). Please send your manuscript in both WORD and PDF formats via e-mail attachments. However, for blind reviewing, please eliminate author information in the PDF file. Instructions for authors to prepare a manuscript are as follows:

1. Typing format: Manuscripts should be typed single-column and double-space on A4 page size using font-type of 10pt **Times New Roman**. The pages should be numbered.
2. Units: Manuscripts must use SI (Metric) units in text, figures, or tables.
3. Cover page: The cover page should contain manuscript title, author names, abstract, key words, and author affiliations.
4. End page: The end page contains the same information as the cover page, but in Chinese.
5. Title: The title of the manuscripts should be concise and informative. Please use font size of 20pt, Bold and capitalize the initial letter of each word in the title.
6. Authors: Authors names (using font size of 14pt, Bold) are listed below the title, affiliations (using font size of 9pt, Bold) are listed at the end of the first page marked with <sup>1, 2, ...</sup>.
7. Abstract: The abstract should be shorter than 250 words and typed using font size of 10pt..
8. Keywords: Keywords (no more than 5 words) should be given and placed below the abstract (using font size of 12pt, Bold).
9. Sections and Sub-sections: Section heading (using font size of 18pt, Bold) should be centered and numbered in 1, 2... etc. Sub-sections (using font size of 14pt, Bold) are justified to the left in 1.1, 1.2, 1.1.1, 1.1.2...etc.
10. Paper length: Published papers are limited to 22 pages.
11. Equations: Type formulae and equations clearly in black and numbered in curved brackets. All symbols in equations should be clearly defined when they firstly appear in the manuscripts.
12. Figures and Tables: Figures and tables are numbered and described in short. When papers are accepted, original figures, tables, and photographs are expected for reproduction. Color figures and tables are acceptable in digital version, but they will be printed in gray levels in hard copies.
13. References: Only works cited in the text will be included. References should be cited in the text by giving the last name of the author(s) and the year of publication of the reference, such as Yang and Su (2014) or (Yang and Su, 2014). With three or more names use the form “Yang *et al.* (2016) or (Yang *et al.*, 2016)” in the text. When two or more references have the same text identification, please distinguish them by appending “a”, “b”, etc., to the year of publication. References should include the complete title(s), the number of the volume and the page(s) of the information cited. References should be listed in alphabetical order, according to the last name of the first author, at the end of the paper.

# Journal of Photogrammetry and Remote Sensing

## CONTENTS

### Regular Papers

- Evaluating Recovery Rate Differences between Vegetation Structure and Spectral Indices in Large-Scale Landslides Using Time Series Remote Sensing Data  
(Cheng-En Song, Su-Fen Wang, Yi-Chin Chen) ..... 191
- Deep Learning-based Image Feature Matching for UAV Visual Positioning  
(Lai-Han Zou, Chao-Hung Lin)..... 211

### Short Papers

- Land-use and Land-cover Classification from Sentinel-2 Imagery Using Deep Learning Algorithms  
(Ming-Lun Lu)..... 231
- Discussion on the Relationship between the Distribution and Topography of Yushan Cane in Hehuan Mountain Area  
(Chieh-Fang Cheng, Hsin-Ying Feng) ..... 241

# 航測及遙測學刊

## 目 錄

### 學術論著

- 以時間序列遙測資料評估大規模崩塌地植被結構與光譜指標的恢復速率差異  
(宋承恩、王素芬、陳毅青) .....191
- 深度學習影像特徵匹配應用於無人機影像視覺定位  
(鄒來翰、林昭宏) .....211

### 技術短文

- 使用深度學習演算進行 Sentinel-2 影像之土地利用和土地覆蓋分類  
(呂明倫) .....231
- 合歡山地區玉山箭竹分布與地形的關係探討  
(鄭絜鈺、馮馨瑩) .....241