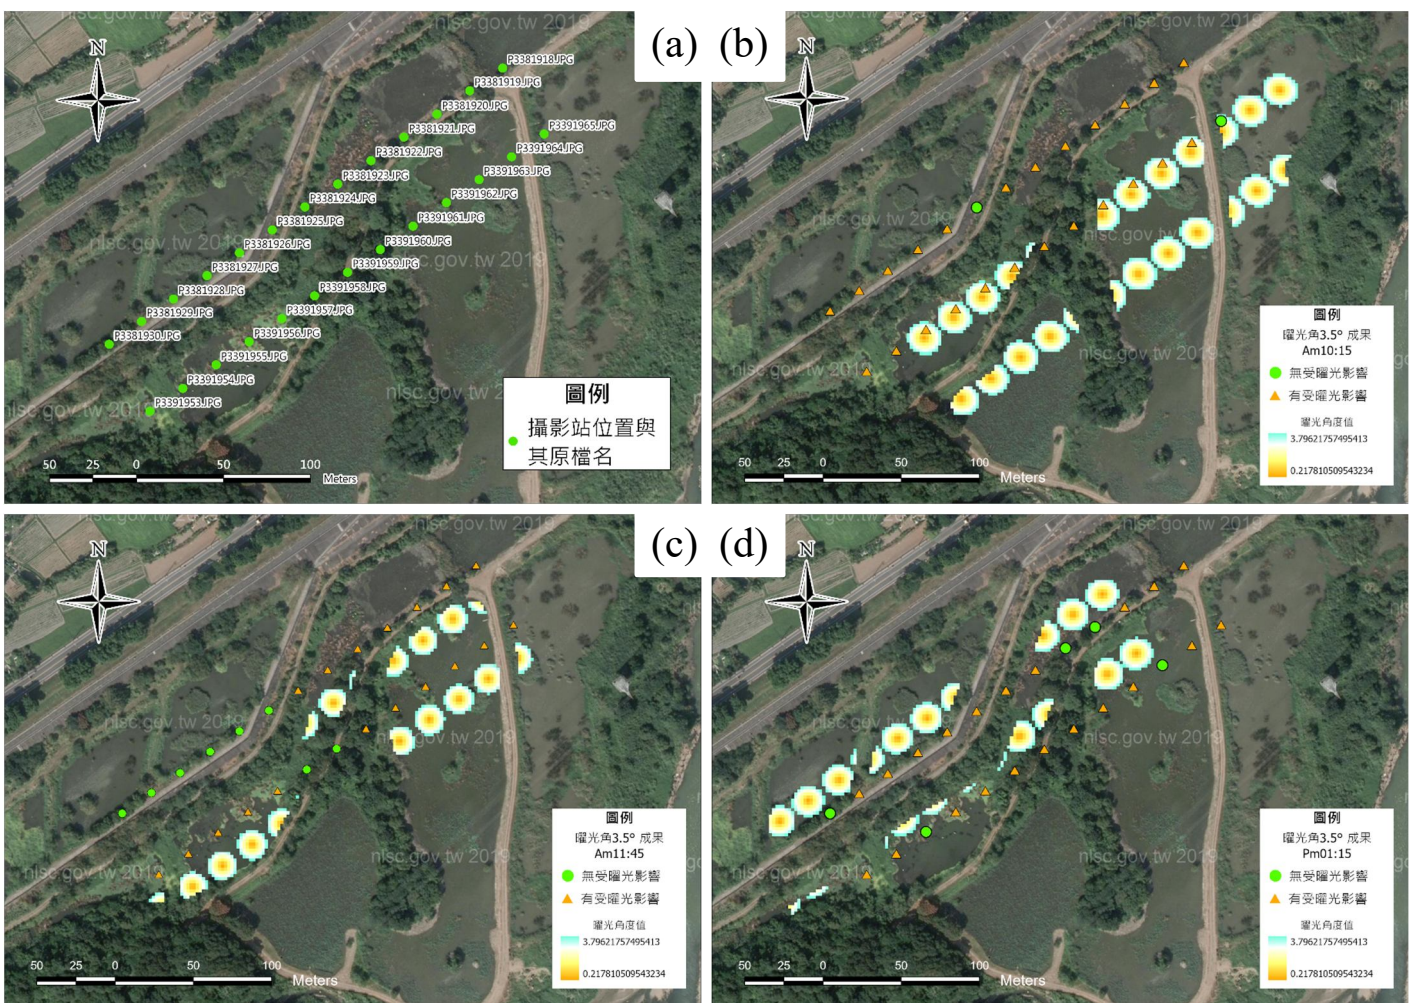


航測及遙測學刊

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.1

March

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

本研究以過去航拍專案中，曙光影響較為嚴重的兩條航帶進行曙光預估的模擬，探討若在同一航線規劃設定與日期條件下，透過時間的選擇是否可以減少專案中的曙光影響程度。根據預估的成果，透過 GIS 軟體中的 point to raster 功能至做出 raster 形式的圖層後，便可將垂直攝影下不同時段的曙光出現情形進行視覺化。如此便可比較原飛行時段 (b) 和其他飛行時段下，曙光出現狀況的變化。

以攝影測量方式建立無人機影像曜光模式之研究

李祈叡¹ 王聖鐸^{2*}

摘要

無人機影像和航遙影像同樣會受到太陽曜光影響。雖已有不同方式可最小化太陽曜光對影像的影響，但目前尚不確定過去使用於低空間解析度影像的處理方法，是否能夠有效應用於高空間解析度的影像。

本研究欲於無人機於航線規劃階段，瞭解曜光可能的出現情形。在對研究區域建立地表、太陽及攝影站之空間關係後，研究將進行曜光預估的計算。根據研究之模擬，使用攝影測量方式建立之曜光預估模式可使使用者於航線規劃階段得知曜光於整體影像蒐集過程之分佈，並可依時間、外方位元素之調整要點，為目標飛行時段帶來較佳有效影像蒐集效率之航拍規劃。

關鍵詞：曜光、無人機、攝影測量、飛行規劃

1. 前言

長久以來，限制航遙影像數據品質的最大干擾因素便是太陽曜光 (Sun Glint)，又稱日映或耀光。曜光的出現是由大氣中的冰晶，或水表或地表在特定條件下形成之反射所引起，同時也代表星載或空載感測器接收到不準確的輻射率。它的出現會使影像中部分區域的數據產生誤差或無法使用，導致是錯誤的影像判釋或影像分類的正確。因此過去研究已對衛星或航照影像中曜光之影響進行廣泛討論 (Hochberg *et al.*, 2003、Goodman *et al.*, 2008、Kay *et al.*, 2009、Hossain *et al.*, 2015、Anggoro *et al.*, 2016、Overstreet & Legleiter, 2017、Harmel *et al.*, 2018)，反映影像中的曜光是航遙影像所亟欲避免的要素。Cox & Munk (1954) 從風速與海面波斜率分布關係建立出的曜光偵測方式後，除了在不同載體的感測器影像上被應用與改良 (Mermelstein *et al.*, 1994、Shaw & Churnside, 1997、Monzon *et al.*, 2006)，同時開啟海面波與曜光關係方面之研究 (Ottaviani *et al.*, 2008、Zhang & Wang, 2010)，並且也被應用於曜光改正技術中前置曜光預估模式建立 (Wang & Bailey, 2001、Lyzenga *et al.*, 2006)，開啟曜光處理之相關研

究。

而隨著無人機問世並開始大量被應用在海洋及水域調查中，其影像亦會受到曜光的影響，並且在其應用過程無可避免的需要面對曜光所帶來的問題 (Hodgson *et al.*, 2013、Stow *et al.*, 2019、Windle & Silsbe, 2021)。儘管已有研究以使用於衛星影像之的曜光改正方式切入，使用近紅外線波段處理無人機影像 (Hossain *et al.*, 2015)，但該方法於有底棲基質的水域下，會因近紅外線與短波紅外線波段之訊號較高而影響該模式之處理結果，並可能存在過度改正問題 (Muslim *et al.*, 2019)。且在消費級無人機中，有搭載除可見光波段以外感測器的機型仍未完全普及，該方式無法為缺少這方面資源之使用者所用。

因此除了從曜光改正的角度出發，亦有研究以深度學習開發偵測影像中曜光的方式 (Giles *et al.*, 2021)，或利用不同天氣資訊作為變量來避免曜光並獲取較佳品質影像 (Doukari *et al.*, 2021) 等非改正方式對曜光進行處理。同時，無人機良好的操作彈性使使用者得以透過事先預估或航線規劃上的調整，來改善所蒐集影像的品質或影像應用的成果 (Dhanda *et al.*, 2018、Manconi *et al.*, 2019、

¹ 國立臺灣師範大學地理學系 碩士

² 國立臺灣師範大學地理學系 副教授

* 通訊作者, E-mail: sendo@ntnu.edu.tw

收到日期：民國 113 年 01 月 17 日

修改日期：民國 113 年 02 月 19 日

接受日期：民國 113 年 03 月 13 日

Papadopoulou *et al.*, 2021), 顯示事前針對不同需求進行調整, 是提升無人機影像品質的一種有效方式。若欲以事先對曙光進行預估的角度避免影像中的曙光, Frulla *et al.* (1995) 研究中整理出以光照幾何和觀測幾何關係的建立曙光預估方式, 曾被作為排除曙光標準 (Giglio *et al.*, 2003) 或是避免飛行路徑影像出現曙光的應用角度 (Mailhe *et al.*, 2004), 處理衛星影像中曙光出現的問題。

綜合前述討論, 若根據使用目的上的不同, 曙光亦可以預估、避免的概念, 開發對應時間及處理成本的避免方式, 減少曙光影像的出現並維護影像及應用成果的品質。而根據無搭載可見光以外波段感測器無人機的飛行高度以及主要的應用環境, 該高度下較不易受到大氣所產生之曙光干擾, 且在人口密集區域的使用彈性較小, 相對不易面臨地表人造物質所產生的曙光資訊。且在無人機應用中, 亦常面臨到目標區域出現水體之情況, 影像中水體的曙光成為此類無人機影像在應用上主要面臨到的威脅。故本研究希望於無人機航線規劃階段, 針對水體出現之曙光, 透過過去研究所提出, 以及研究中自行嘗試的曙光預估模式, 求出目標可飛行時段下出現最少曙光的時段。同時嘗試歸納出對飛行規劃調整時, 是否可依循特定概念可以最大程度避免曙光出現在影像中。期望透過以上概念避免飛行任務結束後出現在航照影像中的曙光總量, 降低後續去除曙光作業成本。

基於以上動機, 本研究目的可分為下列四項:

- (1) 驗證研究中之曙光預估方式是否能反映實際曙光出現情形。
- (2) 模擬外方位元素與時間之調整, 瞭解不同調整方式導致之影響。
- (3) 歸納避免曙光方式之調整通則。
- (4) 完成曙光預估模式之建立。

2. 研究方法

2.1 研究流程

本研究期望在無人機航拍前透過曙光預估模式的計算, 事先得知曙光在指定時段下之出現情形。

並瞭解是否可以透過相片外元素及時間的調整, 避免曙光的出現, 確認蒐集到的影像資訊能正確被保留。

基此, 本研究完整的研究流程如圖 1 所示。首先研究將於縣市政府允許且含有水體之飛行區域, 進行曙光影像蒐集。完成蒐集後將影像以 Pix4D Mapper 進行處理得到相機內方位與該次飛行下的攝影站外方位資訊。研究首先需驗證曙光預估模式所計算出之成果是否能符合實際狀況, 因此將使用前述處理而得之內、外方位資訊, 並搭配自開放街圖 (OpenStreetMap, OSM) 搜尋而得的水體資訊進行曙光預估之計算, 最後根據預估的曙光範圍搭配實際曙光情形進行討論, 同時模擬外方位元素改變時曙光於影像中的變動情形。下一步將設計實驗, 驗證曙光預估模式是否能搭配時間推移及外方位元素的調整帶來出現成果上的改變, 並根據設計實驗所帶來的變動, 對航線上的調整方式歸納出可依循的調整方式。最後將曙光預估模式應用於已完成之實際航拍專案中, 討論過去航拍專案在飛行前是否能以可行之對應方式進行調整, 以帶來較佳之影像品質。

以上為本次研究之整體流程。研究中曙光預估的計算和閾值設定需要經過實際驗證, 因此在流程中配合實際的原始曙光影像和設計的實驗進行處理。完成驗證後, 若計算方式或閾值設定能反映正常航拍設定下的曙光出現情形, 則本研究對曙光預估模式期望之實際操作的流程, 是在航線設計階段, 根據設定下之攝影站和飛行範圍內的水體, 進行曙光預估。在得知該階段設定下的曙光出現情形後, 再進行航線規劃或飛行時間的調整, 最終得到一組受曙光影響最少的實際影像。

2.2 研究區域

本研究主要欲探討與處理之方向為無人機影像在水體範圍下產生的曙光, 同時希望飛行之場域為縣市政府公告可進行飛行活動、航高限制為 400 呎 (120 m) 以下之空域, 因此本研究之區域設定為新北市樹林區鹿角溪人工濕地, 於此區域進行平靜水面曙光影像之蒐集。

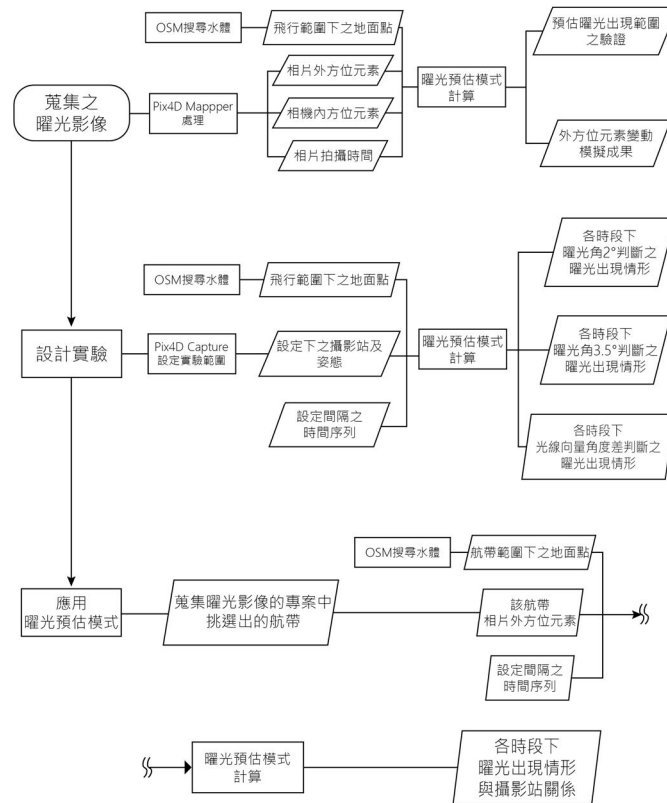


圖 1 研究流程圖

鹿角溪人工濕地位於新北市樹林區，地處大漢溪與支流鹿角溪會合處，是一由原台北縣政府河川高灘地維護管理所打造之人工濕地。濕地透過鹿角溪上游所設置之聯絡管，對鹿角溪河域之污水導入濕地中進行處理。同時由於鹿角溪豐枯流量變化大，因此濕地中亦有導入箱涵的放水流作為補助水源，以維持濕地在旱季的基本水量。該濕地透過自身濕地特性提供水生、陸生、兩棲生物棲息，並達到涵養水源、抒解附近流域豐枯季節流量變化大的現象。

透過鹿角溪人工濕地所提供面積適宜之水體，同時該處地勢平坦、海拔落差微小，利於蒐集大範圍水體影像，故選擇此區域進行曙光影像的蒐集，並進行實驗模擬之操作。

2.3 蒐集曙光影像

由於過去曙光預估模式之計算多應用於低空間解析度之影像中，此類方法應用於無人機影像時，仍未有研究歸納出不同條件下對應之判斷閾值。因此本研究以嘗試的角度，使用實際的曙光影像進行處理，尋找目標條件下可行之判斷閾值。

研究中的影像蒐集是透過 Parrot Anafi 無人機

進行飛行，該款無人機的硬體規格如表 1。所搭載之感測器僅能接收一般可見光波段，而在蒐集影像時可透過內部搭載之 GPS 及 GLONASS 兩種全球導航衛星系統 (Global Navigation Satellite System, GNSS)，在拍攝當下記錄各相片之經緯度與高程。

在該次影像蒐集之飛行規劃中，是以大漢溪左岸鹿角溪人工濕地一側之範圍內，針對濕地水體群、些許壘球場範圍及部分大漢溪河道等目標，劃設長軸為東北-西南走向之多邊型飛行區域 (圖 2)，以交叉航線、80%的前後及左右重疊率，搭配混合飛行高度的方式，在飛行時以 4 cm 與 2.85 cm 之地面採樣距離 (Ground Sampling Distance, GSD) 進行拍攝任務。曙光影像之蒐集於上午 10:00 至上午 11:30 間進行，拍攝 932 張影像。完成飛行並取得影像後，將所收集到之影像匯入 Pix4D Mapper 進行處理，求解出各攝影站之外方位元素，再自影像之 EXIF 檔擷取各攝影站之拍攝時間，完成曙光影像及其資訊之蒐集。此次蒐集之曙光影像，在研究中將使用於光線向量角度差閾值之建立，以及驗證曙光預估出現範圍的實驗中。

表 1 Parrot ANAFI 無人機身及感測器規格表

性能	規格	性能	規格
重量	320 g	感測器類型	1/2.4" CMOS
最大水平移動速度	15 m/s	感測器大小	(6.0, 4.5) mm
最大垂直移動速度	4 m/s	有效像素	5334 x 4016 pixels
最大承受風速	50 km/h	焦距	4.034 mm
最大飛行時間	25 min	像主點位移量 (x, y)	(-0.0077, 0.011) mm
最大連接範圍	4 km	鏡頭畸變差 (k1, k2)	(0.0000089012, -0.0000054908)

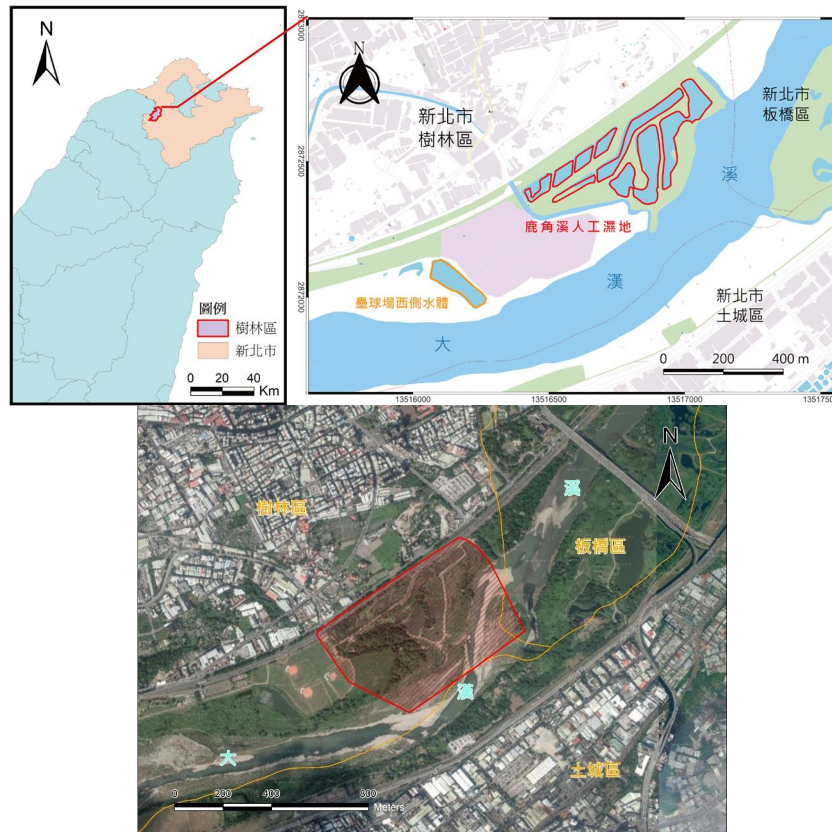


圖 2 鹿角溪人工濕地地理位置圖與蒐集曜光影像飛行範圍示意圖

2.4 建立資料輸入模式

為維持曜光預估之計算效率，故研究中將建立統一的資料輸入模式，確保當飛行區域改變時，可使用固定方式取得相同格式之資訊以利研究運算進行。而根據計算所需之資訊，將可分為攝影站與實體空間中水表之資訊。本研究將對此兩項資訊分別建立固定之取得方式。

首先，研究以 iOS 版本之 Pix4D Capture 做為無人機航拍規劃之軟體。於軟體中繪製飛行範圍並設定各項飛航任務規劃參數後，專案檔將產生前述設定下對應之航線資訊。其檔案格式類型與 JSON 相似，故可以固定方式對檔案內資訊進行擷取。因

此，透過桌上型裝置打開該專案檔後，可對專案檔中屬性名為「Location (各攝影站坐標)」與「Camera Orientation (攝影站外方位元素)」之兩項資訊進行擷取，將其進行儲存作為接下來曜光計算中攝影站部分之資訊。

當完成攝影站資訊的收集後，由於若欲對影像中水面的逐一像素依據其對應至實體空間之坐標進行曜光預估之計算，會形成大量的運算成本。故本研究以對水面進行採樣的概念，對影像中水體的部分，根據規劃之飛行高度以對應適當邊長的網格大小進行規則切割，得到水面範圍的水面點進行曜光預估之計算。因此，針對該航線規劃下飛行範圍

內所有的水體位置，可透過飛行規劃後所產生出飛行範圍的坐標資訊，以 QGIS 中的 QuickOSM 套件，透過 Overpass API 以對應的標籤下載開放街圖中的水體數據。如此便可避免航拍前若僅透過傳統航測影像或衛星影像進行水體判釋時，可能無法滿足無人機飛行尺度的水體資訊需求的問題。完成下載的水體即以 Shapefile 形式被儲存，並再根據實驗需求進行規則切割，得到點形式之 Shapefile。

完成水體資訊蒐集後，將根據不同實驗設定下的飛行範圍規模及航高，對水體以對應邊長之方格進行規則切割，來得到可用於後續計算中的對應規模水面點資訊，達到在飛行前可以以合理計算時間得到耀光出現資訊的目的。此時所得之水面點尚無高程資訊，故在研究中需進一步搭配數值地形模型 (Digital Terrain Model, DTM) 擷取該點位之高程資訊。由於網格間距小於等於 5 m 之成果為一般公務機密，因此研究中先以內政部 20M DTM 資料進行處理，得到包含高程之水面點資訊。

2.5 耀光預估之計算

預估耀光於影像中分布之討論，在過去衛星與航照影像研究中的討論多以水面波角度切入進行討論與應用；但無人機在單次航拍任務下所得之影像數量與空間解析度，皆與前者不同，同時大量的影像亦涵蓋到不同時間下環境的變量，使得此類方式若欲應用於無人機影像時，會依據影像數量涉及到對應的計算規模，創造出龐大的計算成本。因此

本次研究中假定飛行時水面為均質穩定、趨於鏡面的狀態。因此首先將根據實際攝影成果或實驗設定下所產生的對應內、外方位元素，對飛行範圍下所有水面點與各攝影站之間進行耀光預估。

將所得之水面點，根據該次航拍任務規劃出的各攝影站外方位元素，以共線方程式 (Collinearity equation) 計算出水面點在各攝影站中的成像情形後，同時得到有成像水面點於影像中之影像坐標，並再單就有成像之水面點進行耀光預估之計算。研究中耀光預估模式的計算，將利用過去研究中歸納出的耀光角概念，搭配本研究自行嘗試之光線向量角度差之計算方式來進行，並根據各計算方式下不同閾值設定之成果進行模擬及討論。

2.5.1 耀光角

本研究使用 Frulla *et al.* (1995) 所整理出之耀光角 (glint angle) 公式，進行水面點在不同時刻、不同攝影站下的耀光角角度值計算：

$$\cos \theta_g = \cos \theta_v \cos \theta_s - \sin \theta_v \sin \theta_s \cos \phi \dots\dots(1)$$

公式中各角度關係如圖 3 所示，其中， θ_g 代表地表與感測器之向量和反射向量所形成的夾角， θ_v 、 θ_s 分別代表水面點與感測器或太陽之間的天頂角角度值， ϕ 代表感測器與太陽之間的方位角差，此項參數可經 α_s 與 α_v ，即水面點與感測器和太陽間的方位角角度值計算而得。

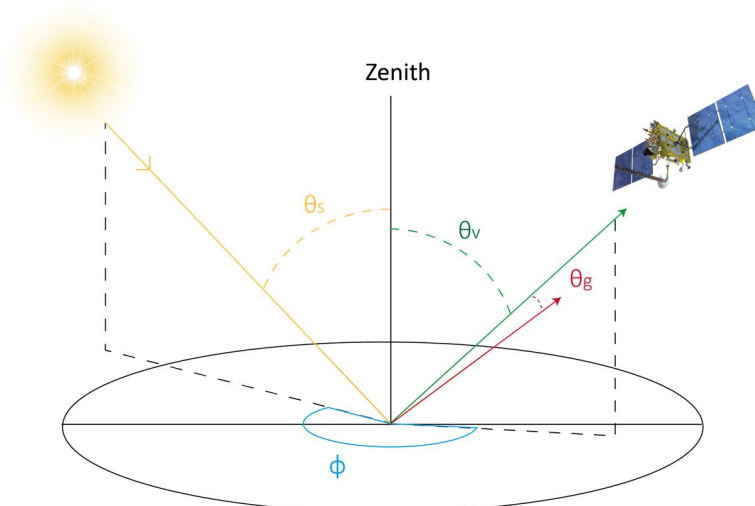


圖 3 耀光角公式中各夾角 3D 示意圖

而此模式下的各項參數的計算方式，可分為： θ_s 、 α_s 是根據美國國家海洋暨大氣總署 (National Oceanic and Atmospheric Administration, NOAA) 所提供，計算各時段下太陽方位之方式。該計算方式可計算出目標時間下，考量粗略大氣折射影響後該地點與太陽之幾何關係； θ_v 、 α_v 是以水面點坐標和攝影站坐標，依其空間關係以三角函數進行推導。最後可得各攝影站中有成像水面點之曙光角 (θ_g) 角度值，曙光角角度值越小，該水面點在影像中越有可能屬於曙光的一部份，反之則否。而判斷水面點是否為曙光的標準，將分別根據過去研究及目前實驗結果，以曙光角小於 2 度 (Giglio *et al.*, 2003) 及 3.5 度作為判斷是否為曙光之標準。

2.5.2 光線向量角度差

因本次研究假定水面趨近於鏡面狀態，因此若有一水面點和一攝影站之間的天頂角角度值 (θ_v) 於特定時間下和太陽間的天頂角角度值 (θ_s) 趨於一致；同時水面點與該攝影站之方位角 (α_v)，於該時間下和太陽間的方位角 (α_s)，兩者角度差趨近於 180° 時，該水面點在影像中應落在曙光出現的範圍下。但曙光於影像中的出現形式應為一範圍而非單一點位，故影像中曙光可能的出現範圍，可能會落在地表與太陽及攝影站所形成的天頂角角度差及方位角角度差所形成的範圍下。因此在本計算中，將對天頂角角度差與方位角角度差分別設定閾值，以兩種角度差落在多少度內的水面點，組成影像中曙光的範圍。

而關於如何此計算下兩種角度差的判斷閾值，天頂角角度差的判斷閾值為根據研究中嘗試而得之經驗，以固定數值 2° 進行判斷；方位角角度差的判斷閾值，係透過研究中建立之迴歸關係，作為曙光在影像中不同出現位置下，方位角角度差的判斷閾值。迴歸關係是透過多張曙光影像中，「曙光中心距像主點的距離」與「通過曙光中心的曙光長軸長度和像主點形成之角度」建立而成。

本研究以曙光影像中曙光中心之影像坐標，搭配影像中曙光所形成最長、並有通過曙光中心的曙光長軸長度，根據該長度與像主點建立成幾何關係

後，可得到該距像主點距離下曙光範圍和像主點所形成的角度。獲得多張曙光影像下之此兩種資訊後，將曙光中心具像主點距離作為自變數、曙光範圍與像主點所形成之角度作為應變數後，以簡單線性迴歸建立出迴歸關係，迴歸關係的示意圖如圖 4 所示。透過此迴歸關係，可以尋找一攝影站中在目標時間下與太陽天頂角達成一致的水面點，在影像中成像後和像主點之間所形成的距離。而將其輸入至迴歸式，便可得知一攝影站中，以方位角角度差為零的軸線為起點夾多少度的範圍內，可能會是曙光出現的範圍。該範圍下有成像的水面點，在影像中就會屬於曙光的一部份，形成透過方位角角度差閾值判斷而得的水面點位。

而此計算方式的完整過程，將先後對水面點與攝影站和該時間下太陽幾何所形成的天頂角角度差與方位角角度差進行計算。若兩個角度差皆落在設定的判斷閾值內，則預估該水面點在該時段、該攝影站中成像時，為曙光的一部份。

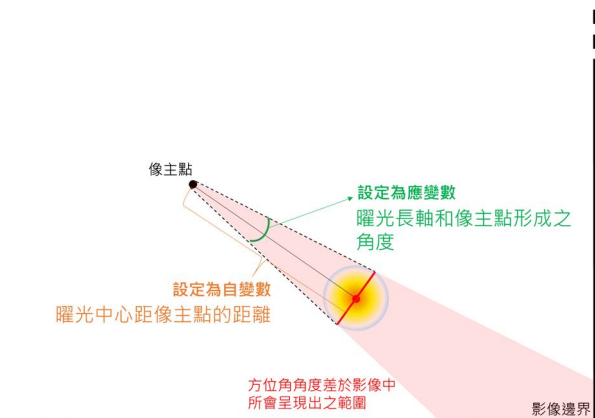


圖 4 方位角角度差判斷閾值之迴歸關係建立圖

3. 實驗成果討論

3.1 驗證曙光預估出現範圍

進行實際應用與討論曙光預估成果前，本研究將確認及驗證曙光預估成果於原始影像中所組成之範圍是否能反映實際曙光出現情形。因此本研究將挑選指定曙光影像，完成曙光預估之計算後根據判斷為曙光之水面點的影像坐標，透過 Python OpenCV 套件將預估曙光範圍投至原始曙光影像中，

觀察預測範圍與實際耀光出現範圍之差異。惟研究受限於沒有蒐集到傾斜攝影的實際耀光影像，來驗證耀光計算成果在傾斜攝影影像上的實際情形，故此節將主要以垂直攝影的實際耀光原始影像進行討論。

本次研究選擇檔名為 P3391953.jpg 之影像，搭配 1 m 網格邊長而得之水面點，以此設定模擬及驗證預測耀光出現範圍。而所呈現之耀光成果，將以耀光水面點之成果投影回原始影像上後，透過 OpenCV 中之 Convex Hull 函數，計算耀光水面點之影像坐標所形成之凸包範圍後，將凸包範圍進行繪製，所呈現出之成果即為耀光水面點在影像中之原始影響範圍。實際模擬之成果如圖 5 所示。

根據圖 5(a)、5(b)可發現耀光角 2 度與 3.5 度於的判斷成果於原始影像中呈現近似角錐截面之形狀。其中耀光角 2 度的判斷成果可以涵蓋原始影像中耀光太陽本體的部分，且無將非耀光的部分判斷為耀光；耀光角 3.5 度成果涵蓋耀光太陽本體部分以及部分耀光光暈，但耀光預估範圍有部分落在原始影像中植物部分的像素中。儘管植物下方確實為水範圍，但研究未取得植物三維高度模型，故未將此成果視為誤授。此兩種成果皆未能涵蓋至耀光外圍光暈，故其成果中仍有漏授情形發生，其中以 2 度的情形較為嚴重。同時可以觀察到兩成果判斷範圍於左下角部分有明顯不自然的直邊，該情況是因目前設定下規則切割所得的水面點無法完整涵蓋至水面範圍角落所致。而根據耀光角的兩種成果，可以得之耀光角 3.5 度可作為較保守的耀光範圍判斷閾值，在水面條件或飛行設定變動時，仍可以反映一定程度耀光出現情形。

相較於耀光角判斷成果，光線向量角度差判斷的結果在原始影像上呈現近似弧形的範圍 (圖 5(c))。判斷區域涵蓋耀光的太陽中心部分以及部分方向上的耀光光暈，然而在朝影像邊緣一側，判斷範圍未能涵蓋耀光部分太陽本體及外圍光暈的範圍，說明有漏授情形發生。判斷範圍與前一判斷成果同樣皆有部分落在影像中植物像素下，但沒有視為誤授之理由亦與耀光角 3.5 度成果相同。藉此成果可知

光線向量角度差預估成果在垂直攝影下可反應部分實際耀光出現情形。

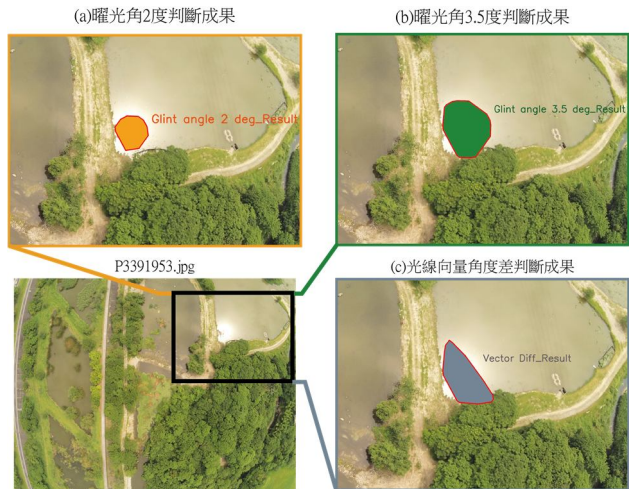



圖 5 耀光預估成果 (a) 耀光角 3.5 度、(b) 耀光角 2 度、(c) 光線向量角度差投影至實際耀光影像示意圖

表 2 模擬外方位元素變動之各元素角度範圍
外方位元素模擬角度 (單位: Degrees)

ω	$\pm 5^\circ, 10^\circ$
φ	$\pm 5^\circ, 10^\circ, 15^\circ$
κ	$\pm 5^\circ, 10^\circ, 15^\circ, 20^\circ, 30^\circ$

同時，本研究挑選 P3391953.jpg 隔壁航帶之 P3401994.jpg 影像，進一步討論當進行外方位調整或外方位元素出現一定程度之誤差時，會對同一專案中不同航帶上的影像造成何種影響。本次外方位元素模擬的角度範圍如上表 2 所示，實際模擬成果則如圖 6 所示。根據此階段模擬成果，可以觀察到在該次飛行所設定的航高下，當 ω 或 φ 在任一方產生 5 度的變化時，在兩影像中耀光中心所產生的位移量皆超過 300 個像素，大於 κ 產生 5 度變化時所造成的像素位移量。而 ω 或 φ 的變動可以較直接的反映鏡頭偏離天底的程度，因此在同樣變動角度下其所造成的耀光中心偏移量，會較 κ 變動時多。透過外方位元素偏移或誤差的模擬成果，可以得知在時間固定、太陽幾何不變的情況下，相片外方位元素的變動亦是決定耀光於影像中出現位置的重要因素。

(a) P3391953.jpg 模擬成果



(b) P3401994.jpg 模擬成果




圖 6 使用(a) P3391953.jpg 與(b) P3401994.jpg 影像，模擬外方位元素變化造成曙光中心位置改變示意圖

根據此節模擬成果得以瞭解曙光預估計算可一定程度重現平靜水面下之曙光出現情形，並得知當外方位元素出現變化，如進行傾斜攝影或改變航帶方向時，會為航拍專案中的曙光出現情形帶來不一樣的成果。

3.2 不同條件下，曙光出現情形變化之模擬成果

3.2.1 實驗區域與航帶方向模擬之設定

完成曙光預估範圍之驗證後，本研究進一步以不同於原始影像蒐集之區域進行新一輪的實驗，採用模擬而非實際收集影像的方式，以探究不同鏡頭傾斜角度和不同航帶方向下，一日內各時段曙光出現的情況。並瞭解當進行相片外方位元素調整時，航拍專案中曙光出現情形隨時間推移之變化。

本節模擬以鹿角溪濕地西南方的單塊水體為主要飛行區域。在此範圍下，首先將透過 Pix4D Capture 以矩形方式進行飛行範圍設定，設定一面積 $42,355 \text{ m}^2$ 之範圍。航帶設定為東西向，搭配 80% 的前後重疊、70% 的側向重疊，以地面解析度 4 cm 之高度進行模擬，以此作為本節模擬之設定和作為計算使用資訊。東西航向模擬設定示意圖如圖 7(a) 所示。同時，本節模擬中亦嘗試改變航帶方向後，不同鏡頭傾斜角度的曙光出現情形。故將以同樣飛行範圍大小、重疊率和航高，將航帶方向調整為西北

-東南走向後，進行第二階段之模擬。此階段模擬設定示意圖如圖 7 (b) 所示。兩階段模擬都將根據對應飛行範圍至開放街圖取得目標範圍內的水體後，對水體以 1 m 邊長的網格進行規則切割，得到本次實驗之水面點資訊。模擬之日期設定為西元 2023 年 6 月 5 日，此節將以以上設定進行該日各時段下曙光預估之計算。

本節的模擬成果，將繼續以曙光角 2 度、 3.5 度與光線向量角度差三種曙光判斷成果進行，同時以上成果將分別以「受曙光影響之攝影站數」、「被判斷為曙光之水面點數」兩種統計成果進行討論，前者顯示當航拍專案在該時段下進行飛行後，需要面對及處理的影像數多寡；後者反映整個航拍專案裡，曙光於影像中組成之規模。此類別可以以物空間角度出發，較不易因影像的地面採樣距離有劇烈變化而導致無法對影像間的曙光出現情形進行討論。

3.2.2 不同傾斜角度或航帶方向變動下，曙光出現情形隨時間推移之變化

本小節實驗中，首先嘗試觀察在未進行任何外方位元素調整，即航線設定為東西向、垂直攝影的情況下，隨時間推移所產生的曙光出現情形變化。根據實際計算後的分布，以 15 分鐘為間隔統計後製作為分時統計走勢，完整統計成果如圖 8 所示。

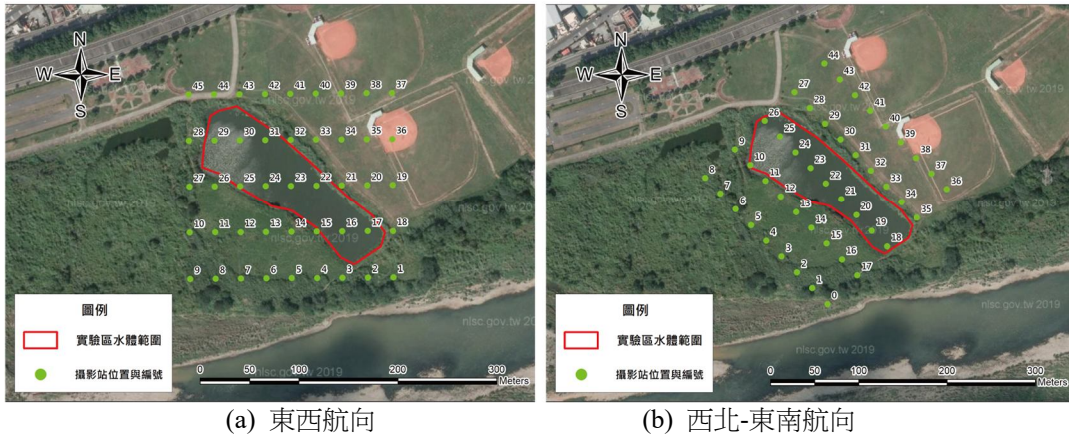


圖 7 模擬設定示意圖




圖 8 東西航帶方向設定下，(a) 曙光角 3.5 度、(b) 曙光角 2 度、(c) 光線向量角度差之判斷成果於不同鏡頭傾斜角度下，受曙光影響攝影站數與被判斷為曙光之水面點數

首先在垂直攝影階段，除 09：15 以前及 14：30 以後的時段下，各曙光預估成果受影響攝影站數會維持一定以上數量。同時，曙光水面點數量除了光線向量角度差的預估成果在 11：30 至 12：15 之間與曙光角預估成果於趨勢上出現較大落差之外，可發現數量出現的高峰時刻並不一定為太陽天頂角最小之時刻，亦顯示在未進行外方位元素調整的階段下，太陽幾何是決定曙光出現的關鍵因素。

當進行傾斜攝影後，各曙光預估成果都在原本未受曙光影響的時段開始受到曙光的影響，但出現較多受影響攝影站的時段隨傾斜角度增加而不斷縮短。直至傾斜 30 度攝影時，除太陽天頂角較小的時段外，其餘時段下受曙光影響的攝影站數量皆有明顯的減少。被判斷為曙光的水面點數成果中，隨

鏡頭傾斜角度增加，曙光角判斷出的數量尖峰時段會由早上及下午的兩個高峰，轉變為僅在中午時刻出現高峰，但需要足夠的傾斜角度才會使水面點數規模有減少趨勢；光線向量角度差的成果顯示其判斷方式會因太陽天頂角大於或小於特定範圍時，判斷出之曙光水面點數會與曙光角成果於趨勢上出現明顯落差。然而當太陽天頂角趨於極大或極小，或進行傾斜攝影時，其所判斷出的兩項統計指標皆有可能出現數量較極端的情形。

以上三種曙光判斷成果，在目前航帶方向設定為東西向的情況下，可歸納出調整鏡頭傾斜角度時需注意數項要點：

- (1) 進行傾斜攝影後，反而會導致航拍專案於更早及更晚時段下的曙光出現情形發生變化，但總體曙

光水面點數量高峰時段會逐漸集中於太陽天頂角較小的正午時段，同時高峰時段下的數量規模有減少的趨勢。

- (2)較小的鏡頭傾斜角度在太陽天頂角小的時段下，判斷成果的減少幅度並不明顯，顯示其無法於該時段有效減少曜光出現情形。
- (3)更大的鏡頭傾斜角度將不利於影像於特定目的上之利用，尚需搭配其他外方位調整方式對曜光進行處理。

實驗亦將對航帶方向的調整進行模擬，觀察此種調整是否可進一步減少曜光於航拍專案中的影響程度。根據航帶方向調整為西北-東南向的模擬成果(圖9)，可發現曜光出現時間在垂直攝影階段便與東西向航帶不同，推測是因航帶與水體平行，使早上時段有較多曜光出現範圍得以落於水體範圍內所致；而曜光出現規模之高峰時段，在垂直及各個傾斜角度下亦與東西向航帶呈現不同趨勢。儘管在進行傾斜攝影後帶來與前段實驗相似的變化，但出現無法以傾斜攝影減少特定時段下曜光出現的情況；而其餘時段為何得以透過鏡頭傾斜改變曜光水面點數規模，亦無法自此成果瞭解原因。

最後，根據 3.1 與 3.2 節中對各曜光判斷成果的討論，可以分別歸納出兩種曜光預估之計算方式在應用上會呈現的特點。曜光角可根據不同閾值設

定，預估出對應大小的曜光範圍，同時在不論垂直或傾斜攝影的情形下，所形成之預估範圍較近似於規則的幾何形狀。但其在不同 GSD 下，需要設定對應的閾值才能有較貼近實際情況的預估成果；光線向量角度差提供相對粗放的曜光預估範圍，且判斷閾值會自動隨曜光於影像中之位置變化，但在傾斜攝影下，其預估範圍會有較大幅度的變動。故目前僅能說明其在垂直攝影下，可一定程度預估曜光範圍，但在傾斜攝影下會有較不穩定的成果。因此，關於 3.2 節統計成果中未能解釋的現象，在下節中將主要以曜光角成果進行整理與解析。

3.3 以曜光水面點討論不同條件下曜光規模之變化

因統計成果無法解釋不同計算成果下曜光規模消長的原因，亦無法討論個別航帶或攝影站在不同傾斜角度、不同航向設定下的曜光變化。因此本節將主要以曜光角 3.5 度之判斷成果，搭配光線向量角度差成果進行處理，將以上成果判斷出的曜光水面點，根據統計成果中未解的現象，以點形式 Shapefile 或透過 Point to Raster 工具製作而成之圖層，整理出曜光對應於實體空間上的變化，對不同條件下的曜光模擬成果中所出現的變動情形進行解釋與討論。




圖 9 西北-東南航帶方向設定下，(a) 曜光角 3.5 度、(b) 曜光角 2 度、(c) 光線向量角度差之判斷成果於不同鏡頭傾斜角度下，受曜光影響攝影站數與被判斷為曜光之水面點數

首先關於光線向量角度差的判斷成果在數量上會隨時間有較大差異，詳細觀察可參考圖 10。透過第 24 號攝影站於 10：45 所呈現的水面點判斷成果，可以瞭解在單一攝影站下當符合「耀光於影像中出現範圍趨近影像邊緣」條件出現時，即當太陽天頂角越大，通過天頂角判斷之水面點所形成之圓形範圍越大、越靠近影像邊緣，通過判斷的基數相對較多，導致所判斷出之耀光水面點數會因目前建立之迴歸關係而產生較多判斷成果；同時，當耀光於影像中愈趨近於像主點時，亦會則使判斷出之耀光水面點數較少。

而在同樣時間下，當航帶方向調整後耀光預估成果有何種改變，可以參考圖 11 進行討論。圖 11 中三角形圖徵代表有出現耀光的攝影站，且不同航帶下的攝影站將以不同顏色進行區分。根據此圖可觀察到東西向航帶於 09：30 時耀光出現範圍還未完全出現在成像範圍內；而西北東南向航帶在同樣時段下，已有完整耀光出現在數個攝影站中。故可透過此階段成果，得知調整的航帶方向與水體長軸、太陽幾何在目標時段下達成特定關係時，亦可能會使航拍專案更早或更持續的受到耀光的影響。

另外，圖 12 中亦說明在西北-東南航向設定下，進行傾斜攝影後耀光預估成果會有何種變化。在垂直攝影成果中，09：30 的攝影成果於西北向與東南向航帶的攝影站裡皆有出現耀光。當進行傾斜 30 度攝影時，西北向航帶攝影站有因為傾斜而避開耀光出現範圍；但東南向航帶上的攝影站都持續受到耀光影響，並皆以完整形狀出現在此航帶之攝影站中，並可由第 12 號攝影站觀察到耀光出現範圍仍與成像範圍邊界有些許距離。本圖成果可得知航帶與水體平行時，會於特定時段，隨設定之影像前後重疊率產生對應數量的耀光影像，且由於攝影站與太陽位置所形成的幾何關係，造成需以更大的鏡頭傾斜角度才能達成避開耀光的目標。此部分亦顯示統計成果中，此航帶設定下早上 9 點前後的時段下為何無法透過目前傾斜角度而為耀光水面點數帶來減少的原因。

最後，本研究亦挑選蒐集耀光影像的航拍專案中，耀光影響較為嚴重的兩條航帶進行模擬，透過

耀光預估之計算驗證該時段下此兩條航帶耀光規模嚴重的原因，並探討若在同一航線規劃與日期條件下，透過現有手段調整是否可以減少航拍專案的耀光影響程度。在此次計算終將搭配以 2 m 網格邊長對進行水體規則切割而得水面點，計算自 09：00 開始至 15：00 為止每 15 分鐘為間隔的各時段耀光出現情形。該兩航帶下的各攝影站原始拍攝時間介於 10：14 至 10：16 之間。最後以耀光角 3.5 度判斷成果，根據各點耀光角角度值，以 GIS 軟體中 Point to Raster 工具製作為 Raster 形式圖層，搭配以有無受影響進行的顯示攝影站圖層，以瞭解有受耀光影響之攝影站中，其耀光出現位置是對應在實體空間中的何處。

根據計算後的統計成果與不同時段之 Point to Raster 工具製作而成的模擬成果 (圖 13)，可以在圖 13(b) 發現兩航帶在原始拍攝時段下的耀光出現範圍皆較為完整、規模較其他時段大，同時在圖 13(c)、圖 13(d) 等其他時段下，亦會因攝影站與水體分布之關係、耀光出現範圍是否落在較完整之水體範圍等因素，而在耀光規模出現不同成果，因此若是以減少該次耀光航拍專案中耀光出現面積為主要處理方向，確實可以透過時間的推移，將攝影時段推遲至 11：45，或甚是 13：15 以後的時段來達成上述目的，並可參考搭配航帶方向上的調整，以改變耀光出現之情形。

根據點形式 Shapefile 或 Raster 形式圖層的成果，得以說明在各式條件下的耀光模擬成果改變的原因。並可藉此瞭解不同調整方式可依循何種原則才能有效為耀光出現情形帶來改善。傾斜攝影於目前 S 型交叉航帶設定下，不論何種航帶方向設定皆會導致整體航拍專案於更早或更晚的時段受到耀光影響。若欲進一步避免耀光出現，本研究建議可嘗試將航帶方向與鏡頭傾斜方向分別設為統一方向，或許能更大程度的透過鏡頭傾斜的方式避免耀光範圍出現在成像範圍。而航帶的走向亦應避免與水體長軸方向平行，否則會因影像重疊率所造成的攝影站數，提高耀光於航帶中影響情形，並可能於特定時段下在平行於水體方向的航帶上會有較多無法避免的耀光出現。

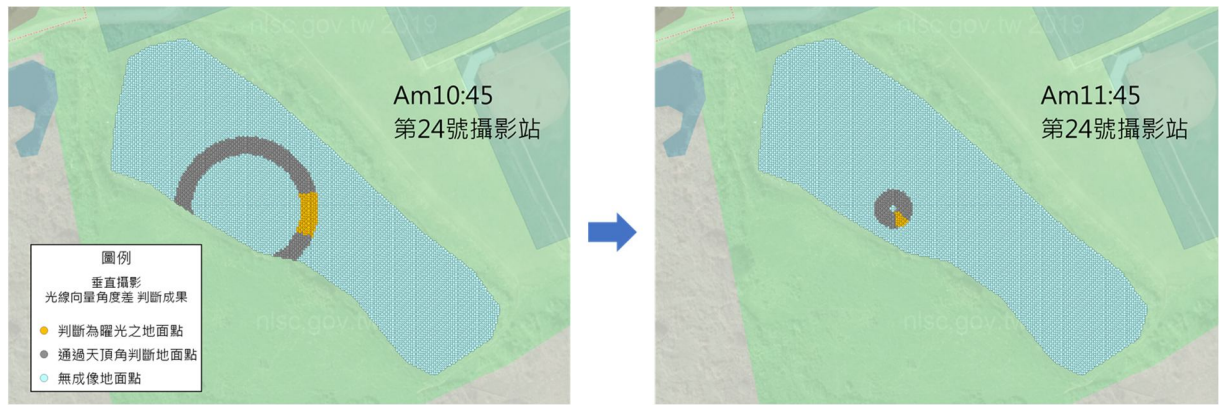


圖 10 光線向量角度差隨時間形成之判斷範圍變化

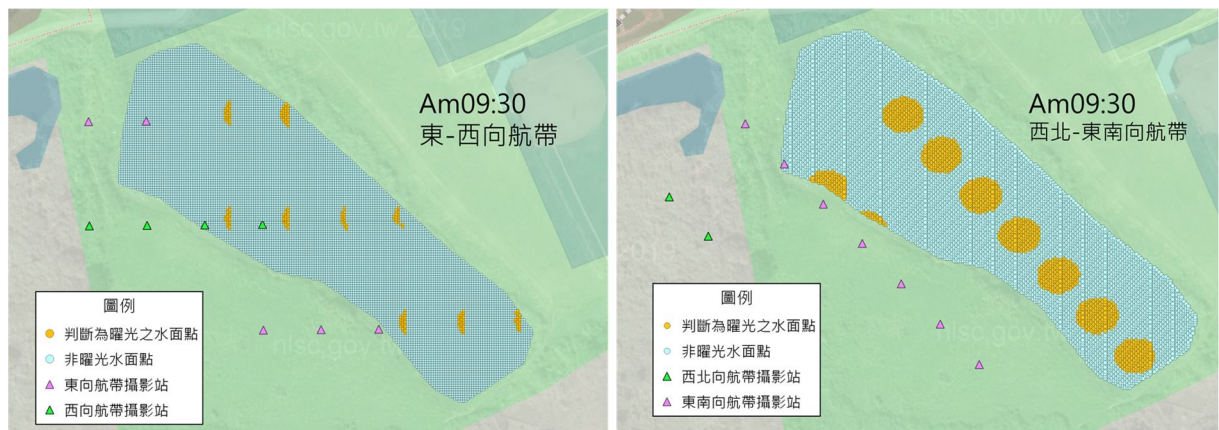


圖 11 耀光角 3.5 度成果中，不同航帶方向設定在同樣時段下之耀光出現情形

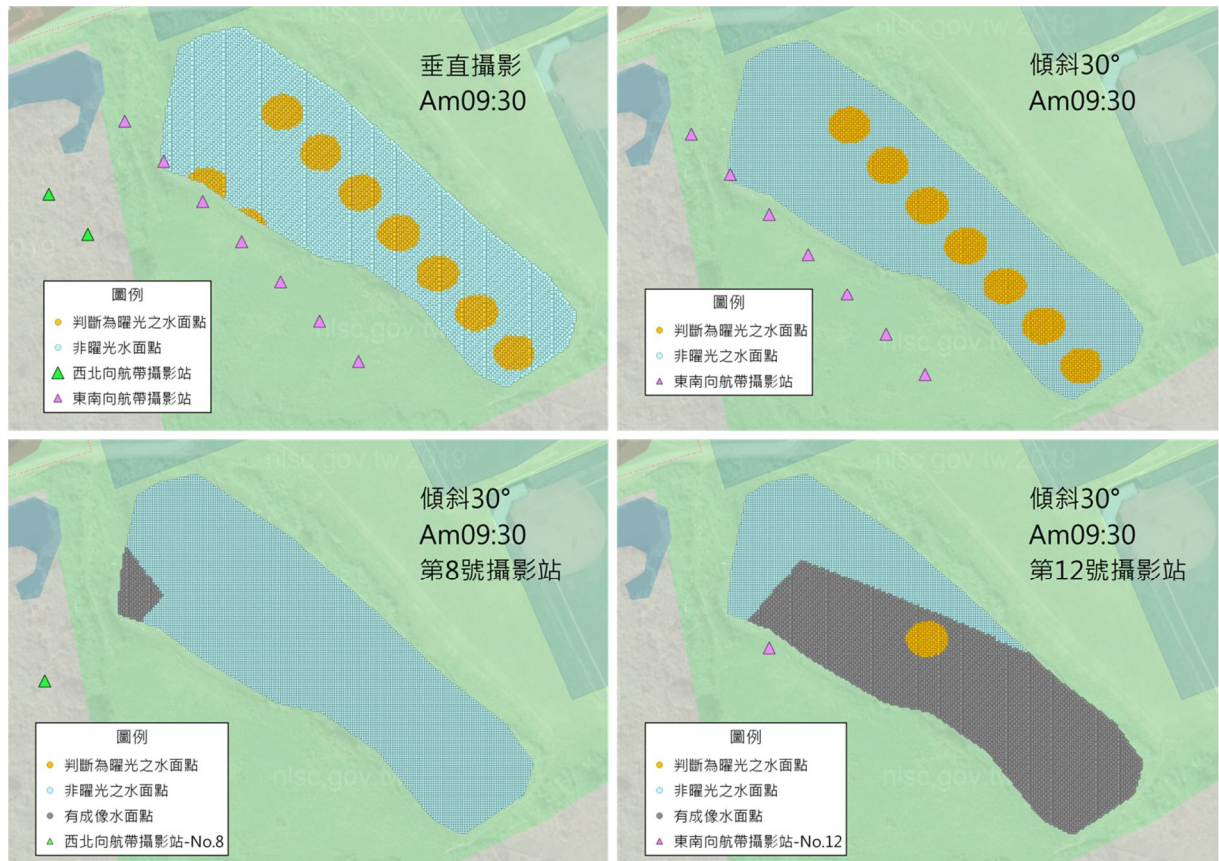


圖 12 耀光角 3.5 度成果中，西北-東南航帶方向下傾斜攝影時耀光判斷成果

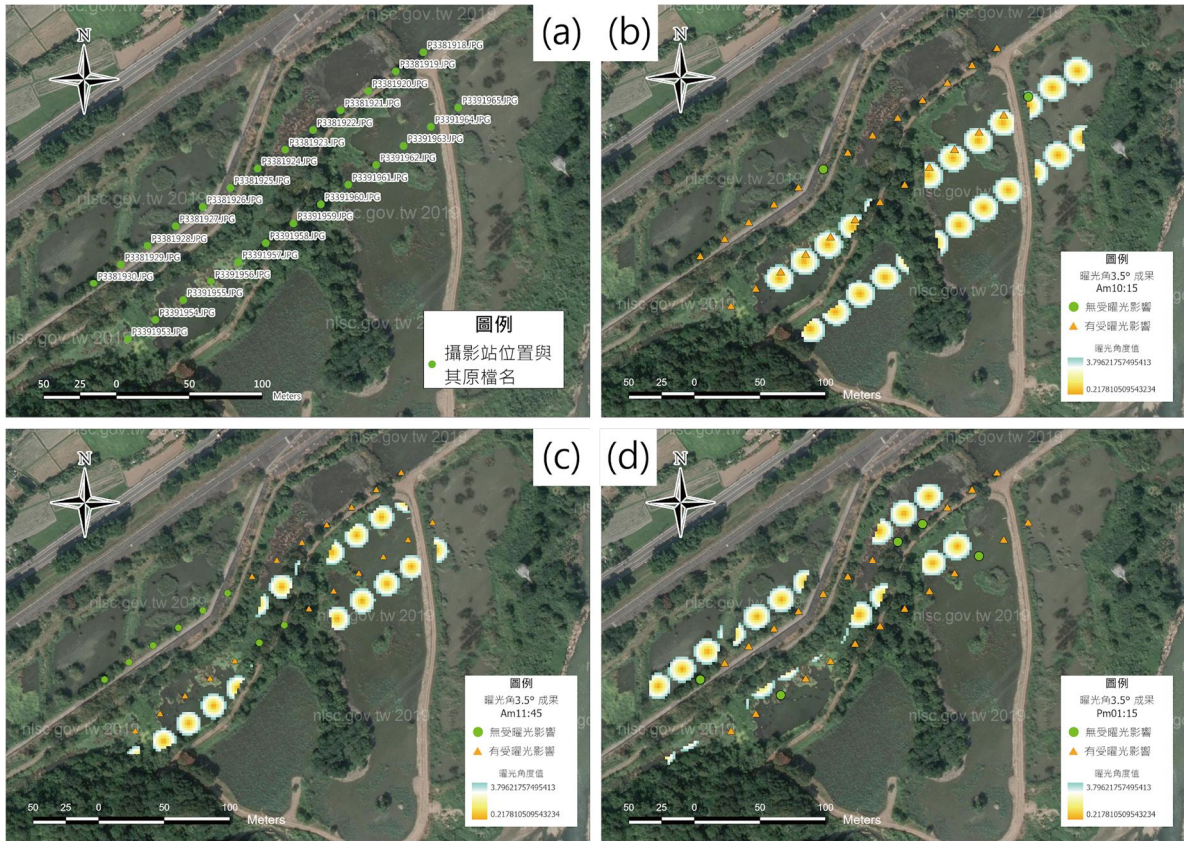


圖 13 (a) 選自耀光實際航拍專案的兩條航帶示意圖，及 (b) 10 : 15、(c) 11 : 45、(d) 13 : 15 下的耀光模擬成果

4. 結論與建議

本研究期望在進行航拍前能以合理的時間事先瞭解耀光出現情形，以避免耀光的出現而導致實際影像中的資訊遭耀光破壞。因此研究中透過耀光預估的計算，根據對應航拍規劃預估耀光出現情形，並提供給僅搭載可見光感測器的無人機使用者作為影像蒐集前的參考資訊。根據研究中耀光預估範圍投影至實際耀光原始影像之成果顯示，耀光預估模式計算出的耀光預估範圍可以協助預估平靜水面下耀光於影像中出現之情形。同時根據相片外方位元素偏移、調整之模擬成果，可以得知在太陽幾何固定的情況下，耀光於影像中的出現位置主要取決於外方位元素，說明耀光出現範圍可透過相片外方位元素之調整進行迴避。

本研究亦透過實驗模擬不同調整方式在不同時間下的耀光出現情形，整理與歸納出時間、傾斜角度與航帶方向在設定上依循的要點。若於東西向航帶設定下進行垂直攝影，可選擇太陽天頂角大的時段進行拍攝以得到最小的耀光影響；當太陽接近

正午、太陽天頂角越小，根據目前實驗的日期與實驗所處之緯度，較難透過合理的鏡頭傾斜角度與航帶方向的搭配來避免耀光出現，同時更大的鏡頭傾斜角度會限制影像於後續可應用之方向，故太陽天頂角較小的時段仍為無人機影像蒐集較不理想的時段。一般 S 型交叉航線的設定下，傾斜攝影必然會使特定航帶在更極端的時段受到耀光影響，需透過非交叉航線之設定才能更好的透過鏡頭傾斜避免耀光的出現。航帶方向的選擇需避免與水體長軸方向平行，才能減少航帶於特定時刻下的耀光出現情形。最後，本研究建立出耀光預估模式之流程可以使使用者可以根據個別航拍專案，依照本研究實驗結果中所整理出之調整原則，搭配模式下的資料獲取方式和耀光預估之計算方式，得知對應情況下，耀光於航拍專案中之出現情形。

未來的研究方向可以嘗試應用過去研究中根據水面波斜率機率分布進行的耀光計算模式，使耀光預估成果可以更符合實際氣象條件所呈現的水面情況。另關於耀光預估範圍漏授、誤授情形之討論，未能搭配影像分割或整理出混淆矩陣等形式進

行討論，應搭配前述更穩健的驗證方式與評估標準進行。同時由於目前是以「被判斷為曜光的水面點數量」此統計類別進行討論，應可將曜光水面點根據其影像坐標計算出各影像中「曜光影響範圍佔影像總體之比例」，較能對曜光範圍在影像中的影響情形進行討論。另外，受限於使用軟體之限制，目前僅能嘗試傾斜攝影的外方位調整方式，無法透過自行編輯航線規劃專案檔，重新讀入現有的航線規劃軟體中。應可自行設計程式將目前計算模式整合航線規劃功能，根據曜光預估成果自動對航線進行調整，根據該調整成果建立為新的航線規劃專案檔後進行飛行，以得到理想之實際影像成果。

參考文獻

- Anggoro, A., Siregar, V.P., and Agus, S.B., 2016. The effect of sunglint on benthic habitats mapping in Pari Island using worldview-2 imagery, *Procedia Environmental Sciences*, 33: 487-495, DOI: 10.1016/j.proenv.2016.03.101.
- Cox, C., and Munk, W., 1954. Measurement of the roughness of the sea surface from photographs of the sun's glitter, *Josa*, 44(11): 838-850, DOI: 10.1364/JOSA.44.000838.
- Dhanda, A., Remondino, F., and Santana Quintero, M., 2018. A metadata based approach for analyzing UAV datasets for photogrammetric applications, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42: 297-302, DOI: 10.5194/isprs-archives-XLII-2-297-2018.
- Doukari, M., Batsaris, M., and Topouzelis, K., 2021. UASea: A data acquisition toolbox for improving marine habitat mapping, *Drones*, 5(3): 73, DOI: 10.3390/drones5030073.
- Frulla, L.A., Milovich, J.A., and Gagliardini, D.A., 1995. Illumination and observation geometry for NOAA-AVHRR images, *International Journal of Remote Sensing*, 16(12): 2233-2253, DOI: 10.1080/01431169508954553.
- Giglio, L., Descloitres, J., Justice, C.O., and Kaufman, Y.J., 2003. An enhanced contextual fire detection algorithm for MODIS, *Remote Sensing of Environment*, 87(2-3): 273-282, DOI: 10.1016/S0034-4257(03)00184-6.
- Giles, A.B., Davies, J.E., Ren, K., and Kelaher, B., 2021. A deep learning algorithm to detect and classify sun glint from high-resolution aerial imagery over shallow marine environments, *ISPRS Journal of Photogrammetry and Remote Sensing*, 181: 20-26, DOI: 10.1016/j.isprsjprs.2021.09.004.
- Goodman, J.A., Lee, Z.P., and Ustin, S.L., 2008. Influence of atmospheric and sea-surface corrections on retrieval of bottom depth and reflectance using a semi-analytical model: A case study in Kaneohe Bay, Hawaii, *Applied Optics*, 47(28): F1-F11, DOI: 10.1364/AO.47.0000F1.
- Harmel, T., Chami, M., Tormos, T., Reynaud, N., and Danis, P.-A., 2018. Sun glint correction of the Multi-Spectral Instrument (MSI)-SENTINEL-2 imagery over inland and sea waters from SWIR bands, *Remote Sensing of Environment*, 204: 308-321, DOI: 10.1016/j.rse.2017.10.022.
- Hochberg, E.J., Andréfouët, S., and Tyler, M.R., 2003. Sea surface correction of high spatial resolution Ikonos images to improve bottom mapping in near-shore environments, *IEEE Transactions on Geoscience and Remote Sensing*, 41(7): 1724-1729, DOI: 10.1109/TGRS.2003.815408.
- Hodgson, A., Kelly, N., and Peel, D., 2013. Unmanned aerial vehicles (UAVs) for surveying marine fauna: A dugong case study, *PloS One*, 8(11): e79556, DOI: 10.1371/journal.pone.0079556.
- Hossain, M.S., Bujang, J.S., Zakaria, M.H., and Hashim, M., 2015. The application of remote sensing to seagrass ecosystems: An overview and future research prospects, *International Journal of Remote Sensing*, 36(1): 61-114, DOI:

- 10.1080/01431161.2014.990649.
- Kay, S., Hedley, J.D., and Lavender, S., 2009. Sun glint correction of high and low spatial resolution images of aquatic scenes: A review of methods for visible and near-infrared wavelengths, *Remote Sensing*, 1(4): 697-730, DOI: 10.3390/rs1040697.
- Lyzenga, D.R., Malinas, N.P., and Tanis, F.J., 2006. Multispectral bathymetry using a simple physically based algorithm, *IEEE Transactions on Geoscience and Remote Sensing*, 44(8): 2251-2259, DOI: 10.1109/TGRS.2006.872909.
- Mailhe, L.M., Schiff, C., and Stadler, J.H., 2004. Calipso's mission design: Sun-glint avoidance strategies, *AAS/AIAA Space Flight Mechanics Conference*, No.AAS-04-114.
- Manconi, A., Ziegler, M., Blöchliger, T., and Wolter, A., 2019. Technical note: Optimization of unmanned aerial vehicles flight planning in steep terrains, *International Journal of Remote Sensing*, 40(7): 2483-2492, DOI: 10.1080/01431161.2019.1573334.
- Mermelstein, M.D., Shettle, E.P., Takken, E.H., and Priest, R.G., 1994. Infrared radiance and solar glint at the ocean-sky horizon, *Applied Optics*, 33(25): 6022-6034, DOI: 10.1364/AO.33.006022.
- Monzon, C., Forester, D.W., Burkhart, R., and Bellemare, J., 2006. Rough ocean surface and sunglint region characteristics, *Applied Optics*, 45(27): 7089-7096, DOI: 10.1364/AO.45.007089.
- Muslim, A.M., Chong, W.S., Safuan, C.D.M., Khalil, I., and Hossain, M.S., 2019. Coral reef mapping of UAV: A comparison of sun glint correction methods, *Remote Sensing*, 11(20): 2422, DOI: 10.3390/rs11202422.
- Ottaviani, M., Stamnes, K., Koskulics, J., Eide, H., Long, S.R., Su, W., and Wiscombe, W., 2008. Light reflection from water waves: Suitable setup for a polarimetric investigation under controlled laboratory conditions, *Journal of Atmospheric and Oceanic Technology*, 25(5): 715-728, DOI: 10.1175/2007JTECHA1049.1.
- Overstreet, B.T., and Legleiter, C.J., 2017. Removing sun glint from optical remote sensing images of shallow rivers, *Earth Surface Processes and Landforms*, 42(2): 318-333, DOI: 10.1002/esp.4063.
- Papadopoulou, E.-E., Vasilakos, C., Zouros, N., and Soulakellis, N., 2021. DEM-based UAV flight planning for 3D mapping of geosites: The case of olympus tectonic window, Lesvos, Greece, *ISPRS International Journal of Geo-Information*, 10(8): 535, DOI: 10.3390/ijgi10080535.
- Shaw, J.A., and Churnside, J.H., 1997. Scanning-laser glint measurements of sea-surface slope statistics, *Applied Optics*, 36(18): 4202-4213, DOI: 10.1364/AO.36.004202.
- Stow, D., Nichol, C.J., Wade, T., Assmann, J.J., Simpson, G., and Helfter, C., 2019. Illumination geometry and flying height influence surface reflectance and NDVI derived from multispectral UAS imagery, *Drones*, 3(3): 55, DOI: 10.3390/drones3030055.
- Wang, M., and Bailey, S.W., 2001. Correction of sun glint contamination on the SeaWiFS ocean and atmosphere products, *Applied Optics*, 40(27): 4790-4798, DOI: 10.1364/AO.40.004790.
- Windle, A.E., and Silsbe, G.M., 2021. Evaluation of unoccupied aircraft system (UAS) remote sensing reflectance retrievals for water quality monitoring in coastal waters, *Frontiers in Environmental Science*, 9: 674247, DOI: 10.3389/fenvs.2021.674247.
- Zhang, H., and Wang, M., 2010. Evaluation of sun glint models using MODIS measurements, *Journal of Quantitative Spectroscopy and Radiative Transfer*, 111(3): 492-506, DOI: 10.1016/j.jqsrt.2009.10.001.

Establishing Sun-glint Estimation Model for Unnamed Aerial System Image through Photogrammetry

Chi-Jui Li ¹ Sento Wang ^{2*}

Abstract

Nowadays, Unmanned Aerial System (UAS) imagery products also suffer from blurring and degradation caused by sun glint effects. Various techniques, including detection methods and specialized algorithms, are used to minimize sun glint's impact in aerial or remote sensing imagery. However, it remains uncertain whether the processing techniques used for low spatial resolution images can effectively be applied to images with high spatial resolution.

By establishing the spatial relationships between the ground, sun, and sensor, a threshold for determining the presence of sun glint was established based on previously captured images, specifically for this research model. The findings of the results are presented from statistical, image-based, and physical spatial perspectives to identify the time period with the least sun glint during the target flight. This finding helps in reducing the effort required for sun glint removal. The key outcome of this approach is that employing photogrammetric techniques to establish a sun glint prediction model allows users to understand the distribution of sun glint throughout the entire image acquisition process during the planning phase. By adjusting the timing, it becomes feasible to plan flight schedules during periods of the day that offer higher efficiency in capturing useful images.

Keywords: Sun Glint, Unnamed Aerial System, Photogrammetry, Flight Planning

¹ Master, Department of Geography, National Taiwan Normal University

² Associate Professor, Department of Geography, National Taiwan Normal University

* Corresponding Author, E-mail: sendo@ntnu.edu.tw

Received Date: Jan. 17, 2024

Revised Date: Feb. 19, 2024

Accepted Date: Mar. 13, 2024

結合深度學習與街景影像建構街道廣告招牌之空間 聚集指標

羅章秀¹ 林柏丞^{2*}

摘要

近年來許多研究透過深度學習建構都市量化指標，作為後續相關議題結合應用。基於臺灣廣告招牌密度高、樣式多元，本研究旨在應用常見深度學習 (Deep Learning) 之語義分割 (Semantic Segmentation) 以及物件偵測 (Object Detection) 方式，量化街景影像中廣告招牌街道空間聚集狀態，並探討研究區域空間分布型態。成果顯示，Deeplab v3+模型訓練平均交併比 (Mean Intersection over Union, MIoU) 值可達 83%；YOLOv7 模型精確率 (Precision) 與召回率 (Recall) 分別可達 91.7%與 87.1%，顯示有一定辨識成效，亦可與實際分布情形相符合。本研究可為後續廣告招牌進一步應用與探勘，以及相關領域結合應用之契機。

關鍵詞：深度學習、語義分割、物件偵測、街景影像、空間分析

1. 前言

街景影像係透過陸上載具、人力背負等方式取得，已是生活中了解一區域不可或缺工具。常見地圖服務平臺中，提供全球性全景街景服務的商業地圖平臺包含 Google Street View (GSV) 和 Microsoft Bing Maps Streetside (Kopf *et al.*, 2010)，以及僅有局部地區全景街景服務之 Baidu 和 Tencent (Long & Liu, 2017、Williams *et al.*, 2019)。此外，亦有以自願者 (Volunteer) 提供自身拍攝街景影像的 Mapillary 和 OpenStreetCam (現 KartaView) (Alvarez Leon & Quinn, 2019)。其中，以 GSV 涵蓋範圍最廣闊。從 2007 年起始街景服務以來，街景影像拍攝張數已達到超過 2,200 億張，涵蓋國家、地區與領土計有 100 個，總路程超過 1,600 萬 km (Google, 2022a)。

基於影像拍攝成果，我們可以透過人類視覺角度，以描述都市景觀 (Kang *et al.*, 2020)，加上現有街景影像資料豐富性、使用彈性以及擁有全景影像等優勢，故衍生許多研究。例如 Rundle *et al.* (2011)

比較現場和 GSV 調查兩種不同方式評估鄰里環境，有一定程度之一致性。Cohen *et al.* (2020) 藉由 GSV 觀察不同食品零售業態於 2008 年與 2017 年之間的家數變化，並以街景影像取得之地理坐標展示不同業態空間熱區分析結果，探討不同業態商店分布與其他社會經濟狀態關聯性，可為長期研究之應用。除此之外，街景影像也可以彌補因遙感探測或航空攝影於土地利用調查無法完全地反映建築物的社會功能與分辨土地利用類型 (Li *et al.*, 2017)，以及後續需要花費較多調查人力費用 (Griew *et al.*, 2013) 等問題，可為補助調查工具。

隨著深度學習 (Deep Learning) 於電腦視覺 (Computer Vision) 發展，已可達到輸入影像，即可得到辨識成果之端至端 (End-to-End) 成效，大幅提升影像處理與擷取特定物件效率。而近年來，於都市研究中，基於語義分割 (Semantic Segmentation) 技術之像元 (Pixel) 輸出成果，已有許多研究透過影像中個別物件視覺比例，建構相關街道空間特性指標，如街道綠化 (Cai *et al.*,

¹ 國立臺北大學 不動產與城鄉環境學系 碩士

² 國立臺北大學 不動產與城鄉環境學系 助理教授

* 通訊作者, E-mail: bclin@gm.ntpu.edu.tw

收到日期：民國 112 年 12 月 12 日

修改日期：民國 113 年 01 月 17 日

接受日期：民國 113 年 01 月 31 日

2018)、街道天空可視指標 (Gong *et al.*, 2018)、街道可步行指標 (Ma *et al.*, 2021), 以及河景指標 (Luo *et al.*, 2022) 等。此外, 物件偵測 (Object Detection) 則基於特定物件框選輸出成果, 亦常用於辨識街道交通標誌 (Campbell *et al.*, 2019)、路面裂痕 (Maniat *et al.*, 2021)、排水系統 (Boller *et al.*, 2019) 以及塗鴉 (Tokuda *et al.*, 2019) 等, 可於後續計算各物件數量與分布。

本研究認為臺灣街道廣告招牌樣式與顏色多元, 透過觀察廣告招牌除可了解是否有商業使用外, 也可作為推估街道商業發展程度之依據。利用具有空間坐標街景影像與可達到端至端辨識、定位與描述物件輪廓之深度學習方式, 可以快速、大規模地擷取一區域廣告招牌, 亦可進一步了解其分布概況, 為一大應用契機, 惟較少研究探討之。此外, 不同辨識任務於廣告招牌之大範圍探勘成效與差異, 亦為本研究進一步探討之處。因此, 本研究研究目的如下: (1) 建構臺灣都市廣告招牌影像資料集, 訓練語義分割之 Deeplab v3+ 和物件偵測之 YOLOv7 廣告招牌辨識模型, 並以指標與實際案例評估成效; (2) 分別以兩模型辨識成果, 建置「廣告招牌街道空間聚集度」(Signboard Density Index, SDI) 指標, 並以板橋區研究區域, 了解其分布概況; (3) 透過迴歸分析 (Regression Analysis) 比較 Deeplab v3+ 和 YOLOv7 廣告招牌街道空間聚集度關聯程度。

2. 研究設計

本研究經由資料集建構、驗證, 並以新北市板橋區為研究區域, 藉此探討所建構之模型應用於實際街道成效。圖 1 為研究流程。

2.1 研究區域

本研究以新北市板橋區為研究區域, 如圖 2 所示。新北市板橋區位於大臺北盆地西南側、淡水河以西, 為新北市政治、經濟與文化中心, 行政區南北狹長, 面積約 23.14 km² (板橋區公所, 2020), 以大漢溪為界, 與樹林區、新莊區、三重區相鄰; 以新店溪為界, 與臺北市萬華區相鄰; 東南與南側則

與土城區和中和區相接。整體而言, 全區地形平坦, 並無明顯起伏, 惟其微地形之分布, 以東南側較高, 約 10 m, 漸向西北側降低至 6 m (板橋市公所, 1988)。

新北市板橋區主要歷經了衛星城鎮、副都心與政經中心發展定位。民國 50 至 70 年代時, 因鄰近臺北市, 交通往來便利、適逢國家政策以工業發展為主軸, 以及剩餘勞動力充沛因素, 成為了臺北市的衛星城市; 後來民國 70 至 90 年代時, 因為都會活動多於臺北市, 區域發展不均現象產生, 遂逐漸去工業化, 強化商業服務機能, 扮演舒緩臺北市的副都心; 民國 90 年代至今, 則基於整體發展與人口已達一定程度, 加上都市基礎設施逐漸完備, 因此成為了淡水河西岸之政經中心 (板橋市公所, 2009)。

根據歷年的人口統計資料 (圖 3), 亦能顯示於民國 50、60 年代板橋區工業蓬勃發展之下, 吸引許多城鄉移民移入, 導致人口的急遽增長, 為都市化特色之一, 其帶來的密集性住宅, 形塑了現今都市景觀 (楊湛萍, 2000)。民國 70 年之後, 人口成長逐漸趨緩, 至民國 110 年底, 人口大約 55 萬, 為臺灣鄉鎮市區層級人口最多行政區。

人口數和人口密度高的都市地區, 土地混合使用的情形非常常見, 加上臺灣許多土地使用的類別既已存在, 以及後續分區管制之施行並未細緻劃分, 允許一定程度的土地混合使用 (黃書偉, 2008)。因此, 從商業發展進程的完善和人口數眾多之因素, 再加上土地混合使用的普遍情形, 本研究認為可以凸顯街景影像於廣告招牌調查與應用價值, 因此以新北市板橋區作為研究區域。

2.2 廣告招牌資料集

考量到廣告招牌樣式因研究操作、不同國家與地區等而有不同的規範, 分類較無一致性, 因此本研究廣告招牌樣式以我國相關規定為主。查閱內政部發布之「招牌廣告及樹立廣告管理辦法」第 2 條用辭定義, 其將廣告招牌分為: (1) 招牌廣告: 「指固著於建築物牆面上之電視牆、電腦顯示板、廣告看板、以支架固定之帆布等廣告。」; (2) 樹立廣告: 「指樹立或設置於地面或屋頂之廣告牌 (塔)、綵坊、牌樓等廣告。」兩類。

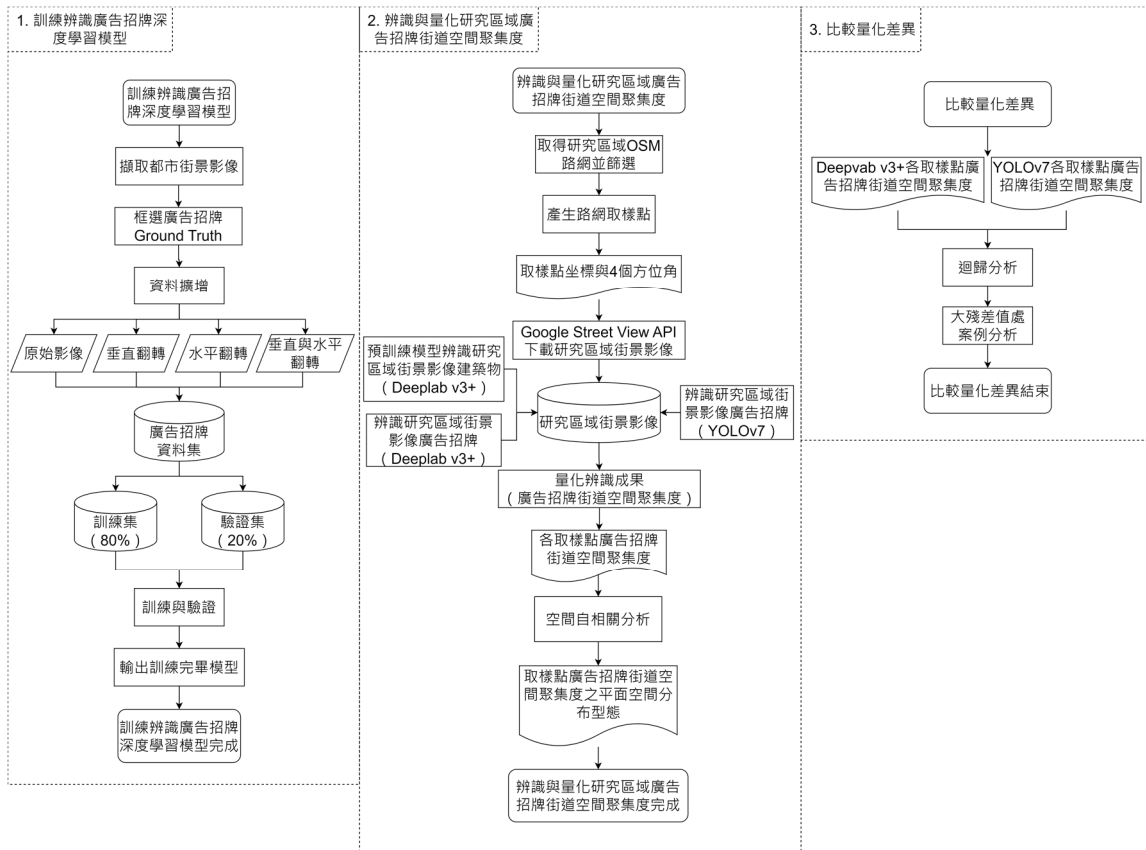


圖 1 研究流程圖

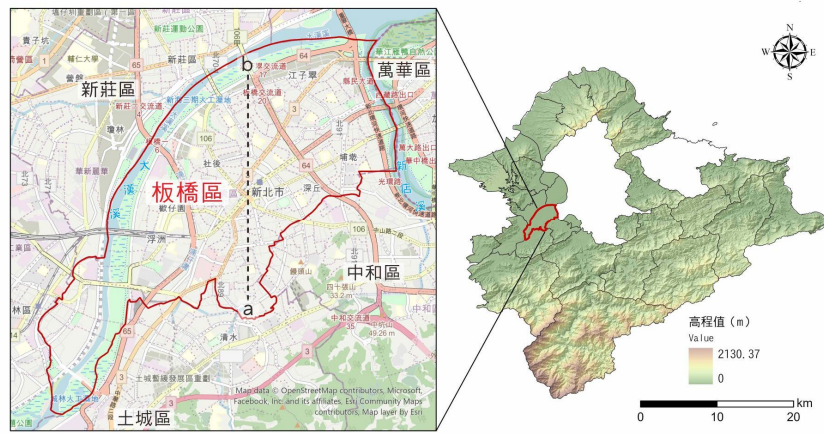


圖 2 研究區域—新北市板橋區

板橋歷年人口與成長率 (民國35-110年)

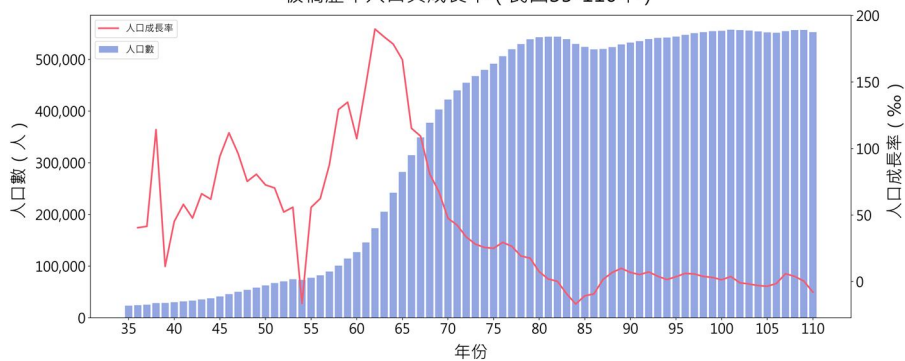


圖 3 板橋歷年人口與成長率 (民國 35 - 110 年)

接著，根據「招牌廣告及樹立廣告管理辦法」第 3 條內容，以及新北市之「招牌廣告及樹立廣告設置規格範例」，可以進一步地歸納出招牌廣告樣式，分為「正面式招牌廣告」與「側懸式招牌廣告」；樹立廣告分為「屋頂式樹立廣告」與「地面式樹立廣告」，如圖 4 所示。關於廣告招牌規範，大多縣市有其自治條例，如「臺北市廣告物管理自治條例」、「桃園市廣告物管理自治條例」與「高雄市廣告物管理自治條例」等，且多有正面、側懸、屋頂式與地面式定義。而新北市「招牌廣告及樹立廣告設置規格範例」有圖式定義，故以該範例為例。

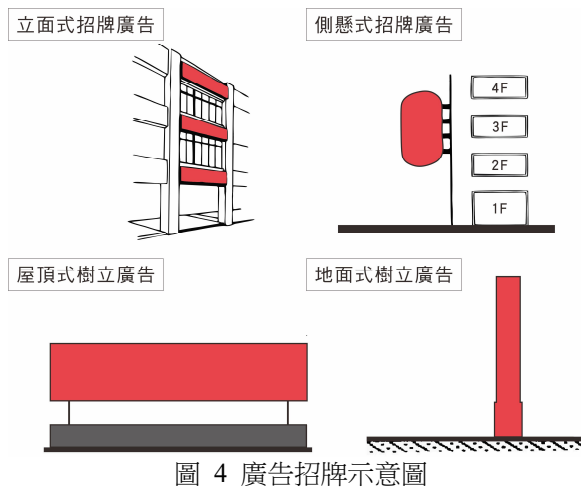


圖 4 廣告招牌示意圖

觀察臺灣各都市現有街道廣告招牌樣式，多以立面式廣告招牌、側懸式廣告招牌為主，以及些許屋頂式樹立廣告與地面式樹立廣告。由於研究內容需要蒐集街景影像中廣告招牌範圍，作為廣告招牌影像資料集的基礎。因此，本研究設定的「廣告招

牌」操作性定義 (Operational Definition)，為立面式廣告招牌、側懸式廣告招牌、屋頂式樹立廣告與地面式樹立廣告，以街景影像呈現範例如圖 5 中白色所框選範圍。

當定義完框選依據時，即可進行訓練資料集真值 (Ground Truth) 之標記。本研究資料集係取自於 Google Maps 網頁中各都市街景影像人工截圖，截圖原則以車行進方向、廣告招牌數量較多，以及樣式較複雜的都市地區為主。經由逐一截圖，取得 1342 張街景影像，以為後續標記基礎。接著，本研究利用專用標記影像開源軟體「Labelme」(<https://github.com/wkentaro/labelme>) 依據前述定義之廣告招牌類型進行真值標記，如圖 6 所示，框選完畢後，會得到一 JSON 檔案，其記錄影像中框選廣告招牌的坐標點 (points) 所構成之圖形 (shapes)。

整體而言，深度學習係奠基於大量的訓練樣本，以達到模型最佳成效 (Sun *et al.*, 2017)，或達到「泛化 (Generalization)」效果。然而，基於模型從無到有訓練與大規模資料取得、標註之困難 (Tan *et al.*, 2018)，因此於訓練時，相關研究常透過遷移學習與資料擴增方式，以解決上述問題 (Han *et al.*, 2018、Loey *et al.*, 2020)。為此，本研究透過資料擴增 (Data Augmentation) 方式增加資料集影像數量，將影像與框選標籤分別進行沿 x 軸垂直翻轉 (Vertical Flip)、沿 y 軸水平翻轉 (Horizontal Flip)，以及同時沿 x y 軸垂直與水平翻轉 (Vertical and Horizontal Flip)，共有 5,368 張街景影像。



圖 5 街景影像廣告招牌示意圖




圖 6 Labelme 軟體操作介面與廣告招牌框選之 JSON 檔結構

2.3 廣告招牌辨識模型

2.3.1 Deeplab v3+ (語義分割)

遷移學習可透過取得已於大型資料集（如 ImageNet 影像資料集）訓練之預訓練（Pretrained）模型權重，作為新訓練模型初使權重（Shorten & Khoshgoftaar, 2019），利於新任務中加速模型學習與收斂。於本研究，採用深度學習模型為 Deeplab v3+ (Chen *et al.*, 2018)，網路骨幹 (Backbone) 為 Xception-65 且經 ImageNet (Deng *et al.*, 2009)、MSCOCO (Lin *et al.*, 2014) 與 VOC 2012 (Everingham *et al.*, 2014) 資料集預訓練之「xception65_coco_voc_trainval」模型進行遷移訓練。上述預訓練模型，可於 GitHub 官方程式碼儲存庫中取得 (<https://github.com/tensorflow/models/tree/master/research/deeplab>)。

深度學習訓練過程，若有一定效能 GPU 可減少訓練時間。故本研究採用 Google 提供之基於 Python 語法「Google Colaboratory (Google Colab)」雲端平臺，只需要開啟瀏覽器即可使用，資料儲存與讀取亦可透過 Google Drive，並根據需求提供不同等級 GPU (Google, 2022b)。本研究使用 Colab Pro 方案服務，雲端 GPU 為 Tesla T4 (圖 7)。

於訓練過程中，本研究隨機選取 4,295 張影像作為訓練集、1,073 張影像作為驗證集，比例為 8 : 2，模型更動超參數 (Hyperparameter) 如表 1 所示，其餘則維持原有設定。由於資料不平衡 (Data Imbalance) 因素 (資料集的廣告招牌與背景比例)，

故將背景：廣告招牌之損失函數權重設為 0.1 : 1.0，以利於模型更加專注於廣告招牌訓練。最後，損失曲線 (Loss Curve) 為觀察訓練成效之視覺化方式，隨著訓練迭代變化，若曲線趨近收斂以及變動幅度不大，則此模型訓練成果較佳。

GPU Name		Persistence-M	Bus-Id	Disp. A	Volatile Uncorr. ECC	ECC	
Fan	Temp	Perf	Pwr:Usage/Cap	Memory-Usage	GPU-Util	Compute M. MIG M.	
0	N/A	54C	P8	11W / 70W	0MIB / 15109MIB	0%	Default N/A

GPU	GI	CI	PID	Type	Process name	GPU Memory Usage
ID	ID	ID				
No running processes found						

圖 7 Colab 環境設定與 GPU 型號

2.3.2 YOLOv7 (物件偵測)

為提供與比較不同辨識任務的深度學習模型，於物件偵測則以 YOLOv7 (Wang *et al.*, 2023) 原始模型為廣告招牌辨識模型訓練基礎。本研究採用「yolov7_training.pt」為預訓練權重，預訓練模型可於 GitHub 官方程式碼儲存庫中取得 (<https://github.com/WongKinYiu/yolov7>)。其中，訓練環境、訓練集與驗證集與 Deeplab v3+ 模型訓練相同，訓練超參數如表 2 設定。

2.3.3 模型驗證

於驗證階段，為透過未納入訓練的驗證集，評估深度學習於訓練集訓練效果。於評估指標之前，會先藉由混淆矩陣 (Confusion Matrix)，取得真實與預測關聯概況，以本研究資料為例，如表 3 所示。

表 1 本研究 Deeplab v3+模型設定之超參數

超參數 (Hyperparameter)	本研究設定
迭代次數 (steps)	30000
批量大小 (batch size)	6
預訓練權重 (model_variant)	xception_65
資料集 (dataset)	dataset_signboard
initialize_last_layer 、last_layers_contain_logits_only	False 、 True
loss weight	[0.1,1.0]

表 2 本研究 YOLOv7 模型設定之超參數

超參數 (Hyperparameter)	本研究設定
迭代次數 (epochs)	100
批量大小 (train_batch_size)	16
預訓練權重 (model_variant)	yolov7_training.pt
資料集 (dataset)	dataset_signboard

表 3 本研究分類之混淆矩陣 (Confusion Matrix) –以廣告招牌為例

	真實為廣告招牌 (Positive)	真實為背景 (Negative)
預測為廣告招牌 (Positive)	True Positive, TP 真陽性	False Positive, FP 偽陽性
預測為背景 (Negative)	False Negative, FN 偽陰性	True Negative, TN 真陰性

本研究 Deplabv3+ 評估指標為平均交併比 (Mean Intersection over Union, MIoU)，又稱為 Jaccard Coefficient，係探討真實資料與預測資料之相似 (Similarity) 程度 (Zabawa *et al.*, 2020)。該評估指標係計算每一個分類真值 (Ground Truth) 與預測值 (Predicted Value) 交集 (Intersection) 和聯集 (Union) 像元比例，並平均之。亦即真陽性 (True Positive) 所佔真陽性 (True Positive)、偽陰性 (False Negative) 和偽陽性 (False Positive) 之比例 (Garcia-Garcia *et al.*, 2017)，如式 (1)。

$$MIoU = \frac{1}{k} \sum_{i=1}^k \frac{p_{ii}}{\sum_{j=1}^k p_{ij} + \sum_{j=1}^k p_{ji} - p_{ii}} \dots\dots\dots (1)$$

其中，*k* 為分類數目 (於 MIoU 中本研究有廣告招牌和背景兩類，故 *k*=2)，*p_{ii}* 為將 *i* 類預測成 *i* 類，*p_{ij}* 將 *i* 類預測成 *j* 類，*p_{ji}* 將 *j* 類預測成 *i* 類。

MIoU 可以反映訓練綜合效果，IoU 則是可以個別聚焦不同分類的訓練效果。若以本研究為例，則如式(2)至式(4)。

$$IoU_{廣告招牌} = \frac{TP_{廣告招牌}}{TP_{廣告招牌} + FN_{廣告招牌} + FP_{廣告招牌}} \dots\dots (2)$$

$$IoU_{背景} = \frac{TP_{背景}}{TP_{背景} + FN_{背景} + FP_{背景}} \dots\dots\dots (3)$$

$$MIoU = \frac{1}{2} (IoU_{廣告招牌} + IoU_{背景}) \dots\dots\dots (4)$$

YOLOv7 評估指標為精確率 (Precision) 與召回率 (Recall)，如式(5)與式(6)。與 Deeplab v3+基於像元計算不同，其係根據辨識框為計算基礎，需要根據真值辨識框與預測辨識框重疊程度決定真陽性。故先以 IOU 指標，決定真值與預測值重疊程度，方可決定是否給予真陽性或真陰性。本研究以模型預設之 IOU=0.45 為決定基礎，即當真值與辨識成果 IOU 計算成果為 0.45，則給予真陽性。

$$Precision_{廣告招牌} = \frac{TP_{廣告招牌}}{TP_{廣告招牌} + FP_{廣告招牌}} \dots\dots\dots (5)$$

$$Recall_{廣告招牌} = \frac{TP_{廣告招牌}}{TP_{廣告招牌} + FN_{廣告招牌}} \dots\dots\dots (6)$$

最後，則為輸出訓練完畢模型，作為後續研究區域街景廣告招牌辨識之基礎。

2.4廣告招牌街道空間聚集度 (SDI)

為取得研究區域街景影像並量化廣告招牌，本

研究首先取得研究區域路網。其中，開放街圖 (OpenStreetMap, OSM) 為一使用者生成 (User-generated) 專案，依循維基百科 (Wikipedia) 共同編輯與創作概念，旨在創造可免費使用、可編輯和不受限於版權所限制之地圖 (Haklay & Weber, 2008)。至今使用者已達到 9,000,000 人次之譜 (Planet OSM, 2022)，基於許多使用者之參與編輯，尤以全球都市地區中，街道資料覆蓋已為廣闊 (OpenStreetMap Wiki, 2022)。因此，本研究將 OSM 路網擷取至研究區域範圍，以及考量街景車可及之處，故篩除腳踏車道 (cycleway)、人行道 (footway)、小徑 (path)、階梯 (steps) 以及於橋面 (bridge='T') 上之類型。後於路網中每 20 m 採一取樣點，並分別取得取樣點之車行方向、車行方向+90 度、車行方向+180 度以及車行方向+270 度之方位角，以達到全景觀測效果。

接著，本研究透過 Google Street View Static API 取得各取樣點坐標之四張街景影像。其請求網址為 <https://maps.googleapis.com/maps/api/streetview?parameter>。其中參數 (parameters) 包含：影像大小 (size)、地點 (location)、方位角 (heading)、視野 (FOV) 和仰俯角 (pitch)。於本研究中設定參數則如表 4。

當每個取樣點皆取得街景影像後，即可量化廣告招牌街道空間聚集度，於 Deeplab v3+辨識成果，首先藉由基於 Cityscapes 資料集 (Cordts et al., 2016) 的 Deeplab v3+預訓練模型辨識建築物範圍，後利用本研究廣告招牌辨識模型辨識招牌範圍，如式 (7)。

$$\text{廣告招牌街道空間聚集度(SDI)} = \frac{\sum_{i=1}^4 \text{Area}_{\text{Signboard}_i}}{\sum_{i=1}^4 \text{Area}_{\text{Building}_i}} \dots\dots\dots (7)$$

其中， $\sum_{i=1}^4 \text{Area}_{\text{Signboard}_i}$ 為每個取樣點 4 個方位角取得街景影像之廣告招牌像元數， $\sum_{i=1}^4 \text{Area}_{\text{Building}_i}$ 為每個取樣點 4 個方位角取得街景影像之建築物像元數。如圖 8 所示，廣告招牌占建築物比例約為 10%。

於 YOLOv7 辨識成果，則分別計算四個方位角街景影像辨識之廣告招牌數量，如式 (8)。

$$\text{廣告招牌街道空間聚集度(SDI)} = \sum_{i=1}^4 \text{count}_{\text{Signboard}_i} \dots\dots\dots (8)$$

其中， $\sum_{i=1}^4 \text{count}_{\text{Signboard}_i}$ 為每個取樣點 4 個方位角取得街景影像之廣告招牌數量。

3. 成果討論

3.1 訓練成果

於 Deeplab v3+模型，以驗證集驗證模型訓練成果，整體 MIoU 最後達到 83%，以分類來看，背景之 IoU 最終達到 96%；廣告招牌之 IoU 最終達到 70%；於 YOLOv7 模型，最終驗證成果 Precision 為 91.7%、Recall 為 87.1%。整體而言，兩者模型有一定預測廣告招牌能力。

3.2 模型於驗證集視覺化成果探討

根據 Deeplab v3+驗證成果，挑選案例 IoU 值較高範例，多接近街景車拍攝的廣告招牌，惟於距離較遠廣告招牌成果不佳 (白框區域)。圖 9(a)中顯示，廣告招牌與街景車距離較近以及物件較大，因此預測成果與真值相似程度較高，邊緣分割成大致良好；圖 9(b)、圖 9(c)與圖 9(d)也可發現預測成果與真值相似程度高，然距離較遠的廣告招牌，則無法達到更細緻的辨識效果。

表 4 本研究 Google Street View Static API 參數設定

參數	本研究設定
影像大小 (size)	Size = 512 × 512
地點 (location)	各取樣點坐標
方位角 (heading)	各取樣點車行方位角、車行方位角+90 度、車行方位角+180 度、車行方位角+270 度
視野 (FOV)	FOV = 90
仰俯角 (pitch)	0

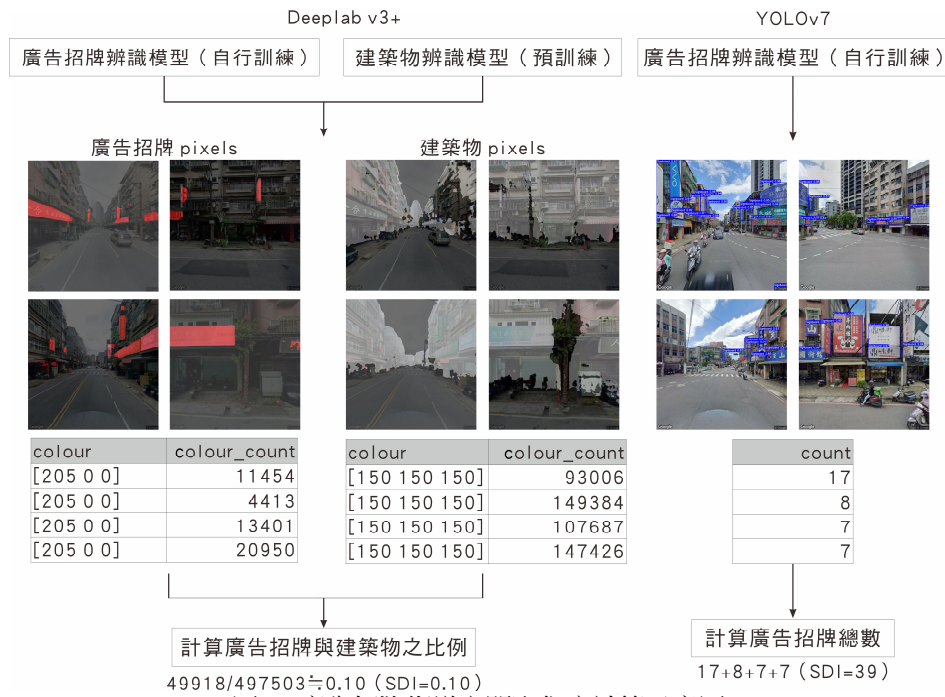


圖 8 廣告招牌街道空間聚集度計算示意圖



圖 9 Deeplab v3+之驗證集之高 IoU 值視覺化成果範例

從 IoU 值較低之範例，亦可發現較小或是距離較遠的廣告招牌，辨識效果不佳。除此之外，也發現有誤判情形 (白框所示)，於圖 10(a) 將帆布誤判成廣告招牌；圖 10(b) 與圖 10(c) 中，街景影像中有辨識到路旁之物流車，將物流車誤判成廣告招牌；圖 10(d) 則將路燈上懸掛之旗幟誤判成廣告招牌。

除了可能因為訓練資料不足因素，致使相似物件誤判情形外，上述較小物件辨識效果不佳原因，推測與模型結構相關。其中，模型中的空洞率 (Atrous Rate) 係關係著辨識物件效果，較大的空洞率，會忽略較小物件的資訊 (Chen *et al.*, 2019)。而本研究採用的空洞率為模型原始設定之 6、12、18，

或許於較遠和較小的廣告招牌之辨識有所侷限，此與 Baheti *et al.* (2020) 想法相同。該研究以印度駕駛資料集 (India Driving Dataset, IDD) 為例，認為當地實際街道環境複雜性較高，且多有較小物件之存在，故修改原本模型設定之空洞率為 4、8、12，以此辨識更細緻的物件資訊。結果顯示於街道複雜性高的 IDD 中，MIoU 提升了 3%，但是於街道複雜性低的資料集中，MIoU 反倒減少，故尚需要依個別案例調整適合之空洞率，並無一定標準。

除此之外，例如 Yang *et al.* (2018) 提出 Denscaspp 模型，透過加入更小空洞卷積與串聯 (Cascade) 多層空洞卷積層方式，以達到擷取更小物件與更多空間尺度資訊效果。Sang *et al.* (2022) 提出 Across Feature Map Attention (AFMA) 架構，藉由量化同類較大與較小物件關係，進而彌補較小物件之資訊不足 (如道路上遠近不同車輛) 問題，並納入現有常見模型中，於較小物件辨識有顯著提升。

於 YOLOv7 模型中，整體而言模型可以辨識街景中大部分廣告招牌，且透過框選方式辨識廣告招

牌，能夠避免 Deeplab v3+ 像元預測為基礎，易受到其他物件干擾，以至於產生分割不完整情形之問題，如圖 11(a)。然而，YOLO 系列模型係透過分割多個非旋轉規則網格，並計算各網格中心度以決定偵測結果 (Redmon *et al.*, 2016)，若因街景車拍攝視角、廣告招牌既有歪斜，抑或是廣告招牌為非矩形形狀，則其辨識成果會比原先廣告招牌範圍大，會交疊並擷取其於非廣告招牌範圍。如圖 11(b) 之「康呈安藥局」廣告招牌 (紅框強調所示)，無法如 Deeplab v3+ 能夠細緻地分割廣告招牌輪廓。近年來亦有如 R-YOLO (Hou *et al.*, 2022)、YOLO-3D (Ye *et al.*, 2023) 等基於現有 YOLO 模型之精進，使其能夠根據不同物件角度，更為精確地偵測其範圍，惟其偵測範圍亦以矩形為主，無法完全精準擷取輪廓。

基於兩者模型辨識成果，本研究認為後續應用時，諸如廣告招牌文字辨識、色彩分析等，若形狀多元、拍攝視角多樣化，可以使用 Deeplab v3+ 之語義分割擷取廣告招牌；形狀為規則矩形、非傾斜拍攝，則可以使用 YOLOv7 之物件偵測擷取廣告招牌。

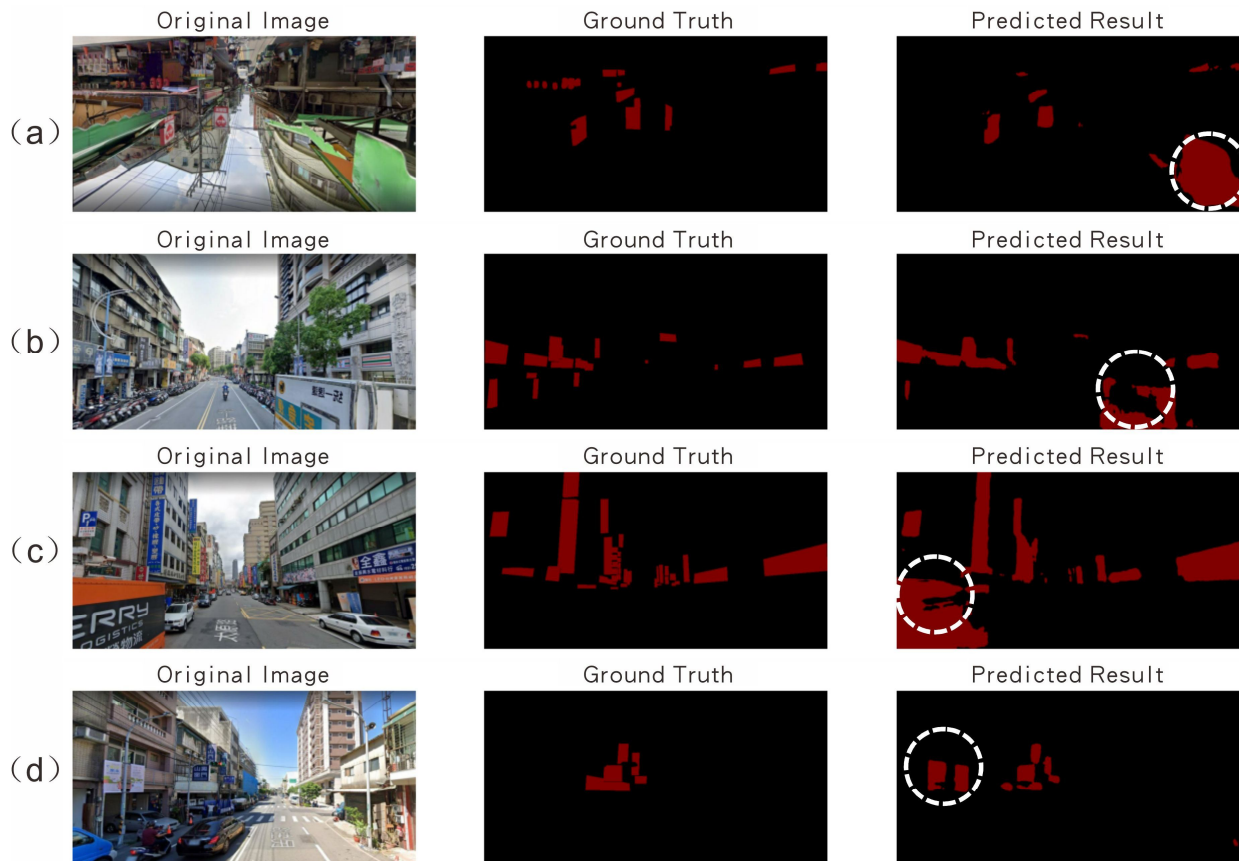


圖 10 Deeplab v3+之驗證集之低 IoU 值視覺化成果範例




圖 11 YOLOv7 之驗證集視覺化成果範例

3.3 兩模型廣告招牌街道空間聚集度比較

為了解研究區域廣告招牌整體分布概況，除了純以地理視覺化方式呈現外 (圖 12)，亦進一步透過考量空間相依 (Dependence) 之空間自相關 (Spatial autocorrelation) 方法，以了解廣告招牌街道空間聚集度高低值所在位置。以 ArcGIS Pro 之 Anselin Local Moran's I index (Anselin, 1995) (又稱 Local Indicators of Spatial Association, LISA) 功能分析後，會呈現「High-High」、「High-Low」、「Low-Low」以及「Low-High」。其中「High-High」與「Low-Low」為廣告招牌街道空間聚集度值有高值或低值之統計顯著上聚集情形，即某區域廣告招牌有較多廣告招牌聚集或較少廣告招牌聚集。故透過此方式可以全面了解研究區域廣告招牌分布概況，並作為後續解釋依據。於相鄰距離為 85 m 之取樣點局域空間自相關成果 (圖 13)，可以發現 High-High 聚集區域以主要商圈 (如府中商圈) 或街道 (如文化路) 為多；Low-Low 則以住宅區、外環道路為多。整體而言，透過空間自相關方法可呈現研究區域內廣告招牌分布之空間差異，且兩模型成果整體趨勢差異不大。

於兩模型廣告招牌街道空間聚集度比較 (圖 14 左)，兩者 Adj R^2 為 0.27，表示兩種廣告招牌街道空間聚集度成果有所差異。進一步聚焦兩者殘差逾 3 個標準差區域 (圖 15 右)，可以發現大於 3 個標準差區域，多位於廣告招牌較多區域，反之小於 3 個標準差區域，則為零星分布於外環道路。根據研究區域實際案例顯示，Deeplab v3+於廣告招牌複雜且較多處容易出現漏判，以致 SDI 值有低估 (圖 15 白框所示)，或是誤判情形 (圖 16 白框所示)；YOLOv7 成果於廣告招牌處可以完整地擷取到較遠、較小的廣告招牌，以及於廣告招牌較少處不易有誤判情形。除了模型效能外，語義分割以可見範圍面積為主，物件偵測以可見數量為主，因此會受到街景影像擷取時拍攝視角、道路寬度等影響，以致兩模型廣告招牌街道空間聚集度有所差異。

基於上述廣告招牌辨識成效，以及研究區域廣告招牌街道空間聚集度整體趨勢，本研究認為可作為土地利用調查輔助作業。尤以臺灣大多數都市兼商業使用住宅分布廣闊，透過探勘街道廣告招牌，初步以街道純視覺角度，可以找出有廣告招牌且為兼商業使用住宅與其分布位置，爾後則可著重調查其餘無廣告招牌且為兼商業使用住宅，以減少時間與人力花費。

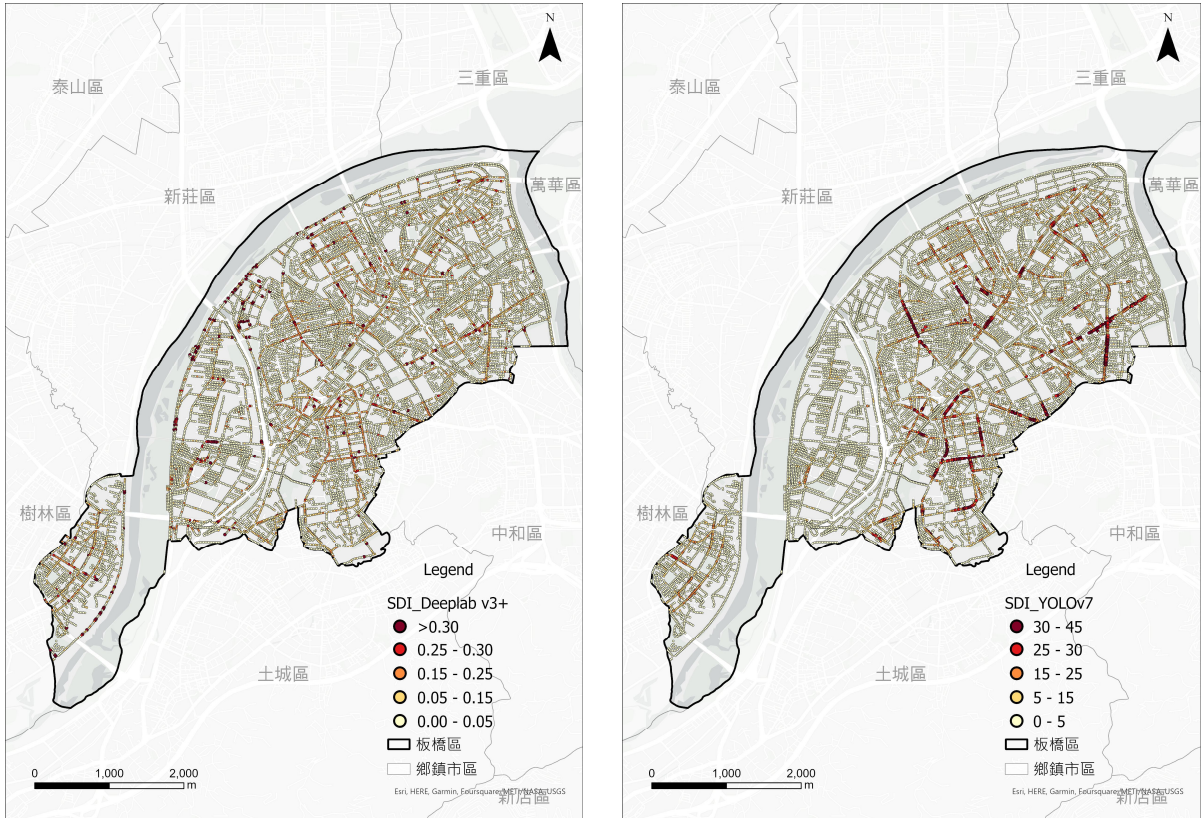


圖 12 Deeplab v3+ (左) 與 YOLOv7 (右) 取樣點 SDI 分布

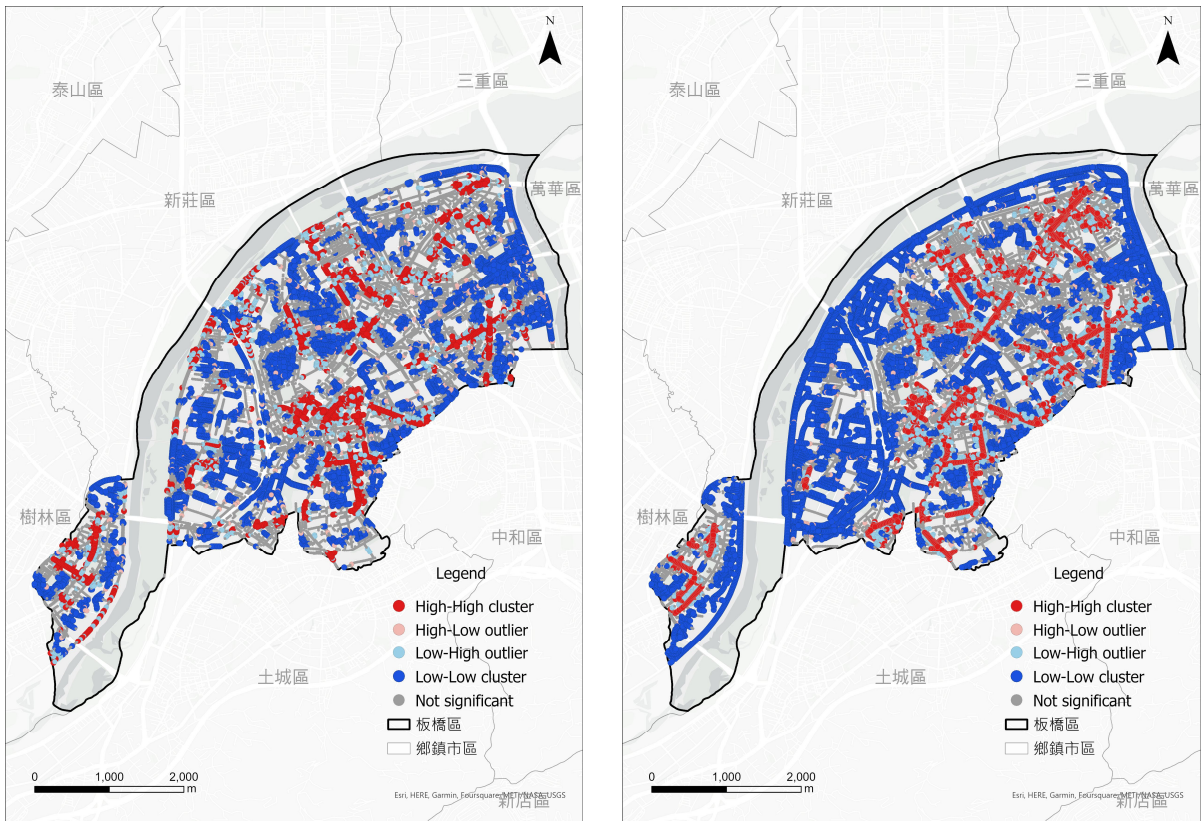


圖 13 Deeplab v3+ (左) 與 YOLOv7 (右) 取樣點 SDI 局域空間自相關

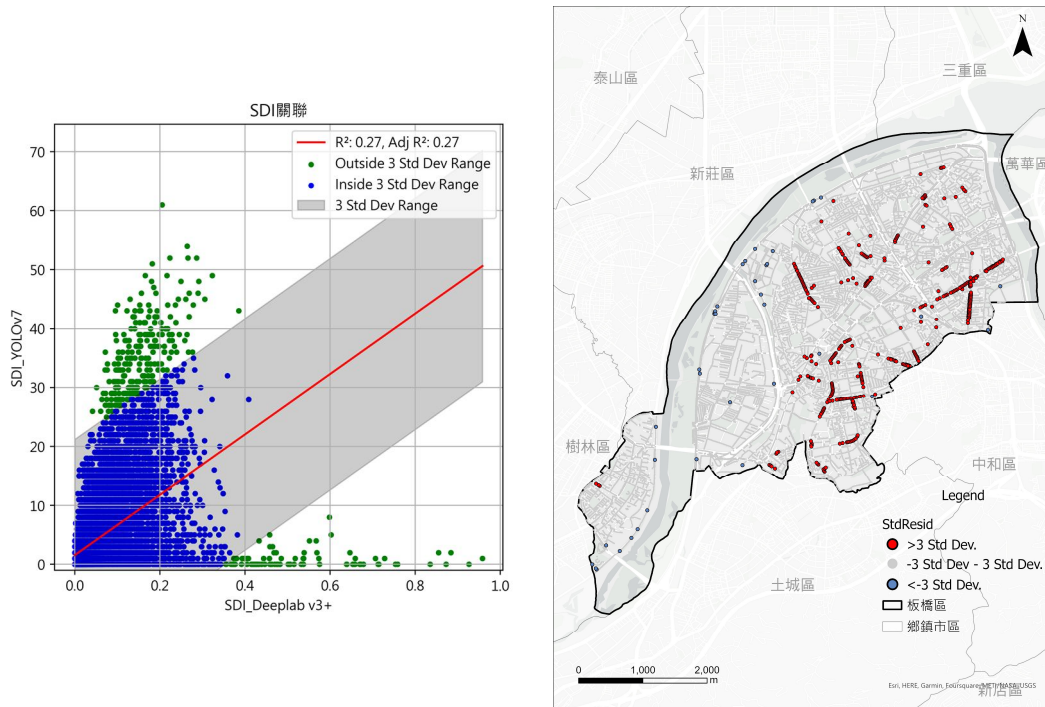


圖 14 DeepLab v3+與 YOLOv7 之 SDI 殘差逾 3 個標準差關聯圖 (左) 與分布 (右)




圖 15 Deeplab v3+與 YOLOv7 SDI 殘差大於 3 個標準差之案例




圖 16 Deeplab v3+與 YOLOv7 SDI 殘差小於 3 個標準差之案例

4. 結論與展望

本研究旨在建構廣告招牌資料集，嘗試透過深度學習之語義分割和物件偵測任務於街景影像，辨識與量化臺灣都市廣告招牌。成果顯示，透過 Deeplab v3+ 深度學習模型於本研究建置之廣告招牌訓練集，MIoU 值可達 83%；YOLOv7 模型 Precision 與 Recall 值分別可達 91.7%與 87.1%，證實兩者模型有一定辨識廣告招牌能力；以局域空間自相關分析，將廣告招牌街道空間聚集度呈現於地理空間中，於取樣點成果顯示，研究區域中廣告招牌有地區差異，如廣告招牌密集處多位於路段線性商業活動發達處，反之則多位於密集住宅區、重劃尚未建築區域，符合實際分布情形。除此之外，透過迴歸分析比較兩模型建構之廣告招牌街道空間聚集度，亦可發現兩者模型辨識任務之優劣。

於其餘應用層面，近年來已有許多應用興趣點 (Point of Interest, POI) 於都市區域之相關研究，如土地利用分類 (Xu *et al.*, 2022)、商家變遷 (Wu *et al.*, 2021) 以及產業空間分布 (Xue *et al.*, 2020) 等。然而，興趣點取得過程需要花費較多調查、判讀與檢核人力與時間 (游舜德, 2022)，儘管 OSM 之群眾模式興趣點，可以克服傳統建置劣勢，但可能會受到不同群眾特性影響，傾向於建置其自身感興趣資訊，缺乏明確標準，進而影響資料多樣性與嚴謹度 (Mullen *et al.*, 2015、Zhang *et al.*, 2022)。相較而言，深度學習與街景影像可短時間大規模探勘與取得實際客觀街道資訊，或許可以彌補興趣點既有不足，或克服既有應用之限制。

本研究建構之研究區域廣告招牌量化方式，為本研究創新與貢獻。若能夠了解一地廣告招牌分布概況，可提供輔助調查，或是都市地理學 (Urban Geography)、都市設計與規劃 (Urban Design and Planning)、政策制定 (Policy-Making) 等跨領域之應用契機。近年來 GeoAI 持續地發展之下，昔日需花費較多人力與物力，抑或是更細緻空間尺度資料，如今大規模探勘與剖析可行性已大幅提升。本研究依循 GeoAI 發展趨勢，結合深度學習與街景影像，

提出都市街道廣告招牌探勘方式，可為後續研究與應用開端。

最後，本研究成果係參考相關廣告招牌規範，納入資料擴增方式建構廣告招牌資料集，並挑選最適超參數設定訓練深度學習模型，試圖達到模型之廣泛通用性，然亦有誤判與漏判。此外，考量 GPU 效能，僅以 512×512 pixels 尺寸之街景影像分析，導致漏判較遠與較小廣告招牌情形。未來可針對廣告招牌類型多樣性、數量之加強，亦或是於影像尺寸、訓練環境以及硬體效能權衡考量間，進一步更改模型架構或挑選不同模型，以提升廣告招牌辨識能力與通用性。

參考文獻

- 板橋市公所，1988。板橋市志，國家圖書館臺灣記憶系統，
https://tm.ncl.edu.tw/article?u=006_001_0000364660，引用 2022/09/12。[Banqiao City Office, 1988. Banqiao City Chronicle, Taiwan Memory, National Central Library(Taiwan), Available at: https://tm.ncl.edu.tw/article?u=006_001_0000364660, Accessed Sep 12, 2022. (in Chinese)]
- 板橋市公所，2009。板橋市志，國家圖書館臺灣記憶系統，
https://tm.ncl.edu.tw/article?u=006_104_000182，引用 2022/09/12。[Banqiao City Office, 2009. Banqiao City Chronicle, Taiwan Memory, National Central Library(Taiwan), Available at: https://tm.ncl.edu.tw/article?u=006_104_000182, Accessed Sep 12, 2022. (in Chinese)]
- 板橋區公所，2020。新北市府升格 10 年，新北市板橋區公所編印。[Banqiao District Office, 2020. New Taipei City Government Upgraded for 10 Years, Banqiao District Office, New Taipei City press. (in Chinese)]
- 游舜德，2022。商品多樣性指標之空間資料探勘分析：以臺北市多核心商圈為例，都市與計劃，49(1)：35-70，DOI：

- 10.6128/CP.202203_49(1).0002. [You, T.S., 2022. Spatial data mining of product variety characteristics: Examples from the multiple shopping areas in Taipei City, *City and Planning*, 49(1): 35-70, DOI: 10.6128/CP.202203_49(1).0002. (in Chinese)]
- 黃書偉, 2008。土地混合使用空間型態量測與其影響因素之研究, 國立成功大學都市計劃學系博士論文。 [Huang, S.W., 2008. The analysis of measurements and factors of the spatial pattern of mixed land use, Doctoral Dissertation, National Cheng Kung University, Taiwan, ROC. (in Chinese)]
- 楊湛萍, 2000。從景觀分析與社會結構變遷探討板橋的空間性轉變, 國立臺灣師範大學地理學系碩士論文。 [Yang, J.P., 2000. Tsung jing guan fen shi yu she hwei jie gou bian chian tan tau ban chiau de kung jian shing, Master Thesis, National Taiwan Normal University, Taiwan, ROC. (in Chinese)]
- Alvarez Leon, L.F., and Quinn, S., 2019. The value of crowdsourced street-level imagery: Examining the shifting property regimes of OpenStreetCam and Mapillary, *GeoJournal*, 84(2): 395-414, DOI: 10.1007/s10708-018-9865-4.
- Anselin, L., 1995. Local indicators of spatial association—LISA, *Geographical Analysis*, 27(2): 93-115, DOI: 10.1111/j.1538-4632.1995.tb00338.x.
- Baheti, B., Innani, S., Gajre, S., and Talbar, S., 2020. Semantic scene segmentation in unstructured environment with modified DeepLabV3+, *Pattern Recognition Letters*, 138: 223-229, DOI: 10.1016/j.patrec.2020.07.029.
- Boller, D., de Vitry, M.M., Wegner, J.D., and Leitão, J.P., 2019. Automated localization of urban drainage infrastructure from public-access street-level images, *Urban Water Journal*, 16(7): 480-493, DOI: 10.1080/1573062X.2019.1687743.
- Cai, B.Y., Li, X., Seiferling, I., and Ratti, C., 2018. Treepedia 2.0: Applying deep learning for large-scale quantification of urban tree cover, in proceedings of the IEEE International Congress on Big Data (BigData Congress), San Francisco, CA, USA, pp.49-56, DOI: 10.1109/BigDataCongress.2018.00014.
- Campbell, A., Both, A., and Sun, Q., 2019. Detecting and mapping traffic signs from Google Street View images using deep learning and GIS, *Computers, Environment and Urban Systems*, 77: 101350, DOI: 10.1016/j.compenvurbsys.2019.101350.
- Chen, J., Wang, C., and Tong, Y., 2019. AtICNet: Semantic segmentation with atrous spatial pyramid pooling in image cascade network, *EURASIP Journal on Wireless Communications and Networking*, 2019: 146, DOI: 10.1186/s13638-019-1445-x.
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., and Adam, H., 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation, in proceedings of the Computer Vision – ECCV 2018, Springer, Cham, vol. 11211, pp.833-851, DOI: 10.1007/978-3-030-01234-2_49.
- Cohen, N., Chrobok, M., and Caruso, O., 2020. Google-truthing to assess hot spots of food retail change: A repeat cross-sectional Street View of food environments in the Bronx, *New York, Health & Place*, 62: 102291, DOI: 10.1016/j.healthplace.2020.102291.
- Cordts, M., Omran, M., Ramos, S., Rehfeld, T., Enzweiler, M., Benenson, R., Franke, U., Roth, S., and Schiele, B., 2016. The cityscapes dataset for semantic urban scene understanding, in proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, pp.3213-3223, DOI:

- 10.1109/CVPR.2016.350.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L., 2009. ImageNet: A large-scale hierarchical image database, in proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, USA, pp. 248-255, DOI: 10.1109/CVPR.2009.5206848.
- Everingham, M., Eslami, S.M.A., Van Gool, L., Williams, C.K.I., Winn, J., and Zisserman, A., 2014. The PASCAL visual object classes challenge: A retrospective, *International Journal of Computer Vision*, 111: 98-136, DOI: 10.1007/s11263-014-0733-5.
- Garcia-Garcia, A., Orts-Escolano, S., Oprea, S.-O., Villena-Martinez, V., and Garcia-Rodriguez, J., 2017. A review on deep learning techniques applied to semantic segmentation, *arXiv preprint arXiv:1704.06857*, DOI: 10.48550/arXiv.1704.06857.
- Gong, F.-Y., Zeng, Z.-C., Zhang, F., Li, X., Ng, E., and Norford, L.K., 2018. Mapping sky, tree, and building view factors of street canyons in a high-density urban environment, *Building and Environment*, 134: 155-167, DOI: 10.1016/j.buildenv.2018.02.042.
- Google, 2022a. Celebrate 15 Years of Exploring Your World on Street View, Available at: <https://www.google.com/streetview/anniversary/>, Accessed July 5, 2022.
- Google, 2022b. Welcome To Colaboratory, Available at: <https://colab.research.google.com/notebooks/intro.ipynb>, Accessed September 11, 2022.
- Griew, P., Hillsdon, M., Foster, C., Coombes, E., Jones, A., and Wilkinson, P., 2013. Developing and testing a street audit tool using Google Street View to measure environmental supportiveness for physical activity, *International Journal of Behavioral Nutrition and Physical Activity*, 10(1): 103, DOI: 10.1186/1479-5868-10-103.
- Haklay, M., and Weber, P., 2008. Openstreetmap: User-generated street maps, *IEEE Pervasive Computing*, 7: 12-18, DOI: 10.1109/MPRV.2008.80.
- Han, D., Liu, Q., and Fan, W., 2018. A new image classification method using CNN transfer learning and web data augmentation, *Expert Systems with Applications*, 95: 43-56, DOI: 10.1016/j.eswa.2017.11.028.
- Hou, Y., Shi, G., Zhao, Y., Wang, F., Jiang, X., Zhuang, R., Mei, Y., and Ma, X., 2022. R-YOLO: A YOLO-based method for arbitrary-oriented target detection in high-resolution remote sensing images, *Sensors*, 22(15): 5716, DOI: 10.3390/s22155716.
- Kang, Y., Zhang, F., Gao, S., Lin, H., and Liu, Y., 2020. A review of urban physical environment sensing using street view imagery in public health studies, *Annals of GIS*, 26(3): 261-275, DOI: 10.1080/19475683.2020.1791954.
- Kopf, J., Chen, B., Szeliski, R., and Cohen, M., 2010. Street slide: Browsing street level imagery, *ACM Transactions on Graphics*, 29(4): 96, DOI: 10.1145/1778765.1778833.
- Li, X., Zhang, C., and Li, W., 2017. Building block level urban land-use information retrieval based on Google Street View images, *GIScience & Remote Sensing*, 54(6): 819-835, DOI: 10.1080/15481603.2017.1338389.
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., and Zitnick, C.L., 2014. Microsoft coco: Common objects in context, in proceedings of the Computer Vision–ECCV 2014, Springer, Cham, Vol. 8693, pp.740-755, DOI: 10.1007/978-3-319-10602-1_48.
- Loey, M., Manogaran, G., and Khalifa, N.E.M., 2020. A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT radiography digital images, *Neural Computing & Applications*, DOI:

- 10.1007/s00521-020-05437-x.
- Long, Y., and Liu, L., 2017. How green are the streets? An analysis for central areas of Chinese cities using Tencent Street View, *PLoS One*, 12(2): e0171110, DOI: 10.1371/journal.pone.0171110.
- Luo, J., Zhao, T., Cao, L., and Biljecki, F., 2022. Water View Imagery: Perception and evaluation of urban waterscapes worldwide, *Ecological Indicators*, 145: 109615, DOI: 10.1016/j.ecolind.2022.109615.
- Ma, X., Ma, C., Wu, C., Xi, Y., Yang, R., Peng, N., Zhang, C., and Ren, F., 2021. Measuring human perceptions of streetscapes to better inform urban renewal: A perspective of scene semantic parsing, *Cities*, 110: 103086, DOI: 10.1016/j.cities.2020.103086.
- Maniat, M., Camp, C.V., and Kashani, A.R., 2021. Deep learning-based visual crack detection using Google Street View images, *Neural Computing and Applications*, 33(21): 14565-14582, DOI: 10.1007/s00521-021-06098-0.
- Mullen, W.F., Jackson, S.P., Croitoru, A., Crooks, A., Stefanidis, A., and Agouris, P., 2015. Assessing the impact of demographic characteristics on spatial error in volunteered geographic information features, *GeoJournal*, 80(4): 587-605, DOI: 10.1007/s10708-014-9564-8.
- OpenStreetMap Wiki, 2022. Press Kit, Available at: https://wiki.openstreetmap.org/wiki/Press_Kit#What_is_OpenStreetMap_?, Accessed September 5, 2022.
- Planet OSM, 2022. OpenStreetMap Stats, Available at: https://planet.openstreetmap.org/statistics/data_stats.html, Accessed September 2, 2022.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., 2016. You only look once: Unified, real-time object detection, in proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, pp.779-788, DOI: 10.1109/CVPR.2016.91.
- Rundle, A.G., Bader, M.D., Richards, C.A., Neckerman, K.M., and Teitler, J.O., 2011. Using Google Street View to audit neighborhood environments, *American Journal of Preventive medicine*, 40(1): 94-100, DOI: 10.1016/j.amepre.2010.09.034.
- Sang, S., Zhou, Y., Islam, M.T., and Xing, L., 2022. Small-object sensitive segmentation using across feature map attention, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp.6289-6306, DOI: 10.1109/TPAMI.2022.3211171.
- Shorten, C., and Khoshgoftaar, T.M., 2019. A survey on image data augmentation for deep learning, *Journal of Big Data*, 6(1): 60, DOI: 10.1186/s40537-019-0197-0.
- Sun, C., Shrivastava, A., Singh, S., and Gupta, A., 2017. Revisiting unreasonable effectiveness of data in deep learning era, in proceedings of the IEEE International Conference on Computer Vision (ICCV), Venice, Italy, pp.843-852, DOI: 10.1109/ICCV.2017.97.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., and Liu, C., 2018. A survey on deep transfer learning, in proceedings of the Artificial Neural Networks and Machine Learning – ICANN 2018, Springer, Cham, Vol. 11141, pp.270-279, DOI: 10.1007/978-3-030-01424-7_27.
- Tokuda, E.K., Cesar, R.M., and Silva, C.T., 2019. Quantifying the presence of graffiti in urban environments, in proceedings of the IEEE International Conference on Big Data and Smart Computing (BigComp), Kyoto, Japan, DOI: 10.1109/BIGCOMP.2019.8679113.
- Wang, C.-Y., Bochkovskiy, A., and Liao, H.-Y.M., 2023. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, in proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.

- 7464-7475, DOI: 10.48550/arXiv.2207.02696.
- Williams, S., Xu, W., Tan, S.B., Foster, M.J., and Chen, C., 2019. Ghost cities of China: Identifying urban vacancy through social media data, *Cities*, 94: 275-285, DOI: 10.1016/j.cities.2019.05.006.
- Wu, M., Pei, T., Wang, W., Guo, S., Song, C., Chen, J., and Zhou, C., 2021. Roles of locational factors in the rise and fall of restaurants: A case study of Beijing with POI data, *Cities*, 113: 103185, DOI: 10.1016/j.cities.2021.103185.
- Xu, Y., Zhou, B., Jin, S., Xie, X., Chen, Z., Hu, S., and He, N., 2022. A framework for urban land use classification by integrating the spatial context of points of interest and graph convolutional neural network method, *Computers, Environment and Urban Systems*, 95: 101807, DOI: 10.1016/j.compenvurbsys.2022.101807.
- Xue, B., Xiao, X., and Li, J., 2020. Identification method and empirical study of urban industrial spatial relationship based on POI big data: A case of Shenyang City, China, *Geography and Sustainability*, 1(2): 152-162, DOI: 10.1016/j.geosus.2020.06.003.
- Yang, M., Yu, K., Zhang, C., Li, Z., and Yang, K., 2018. DenseASPP for semantic segmentation in street scenes, in *proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, pp.3684-3692, DOI: 10.1109/CVPR.2018.00388.
- Ye, Z., Zhang, H., Gu, J., and Li, X., 2023. YOLOv7-3D: A monocular 3D traffic object detection method from a roadside perspective, *Applied Sciences*, 13(20): 11402, DOI: 10.3390/app132011402.
- Zabawa, L., Kicherer, A., Klingbeil, L., Töpfer, R., Kuhlmann, H., and Roscher, R., 2020. Counting of grapevine berries in images via semantic segmentation using convolutional neural networks, *ISPRS Journal of Photogrammetry and Remote Sensing*, 164: 73-83, DOI: 10.1016/j.isprsjprs.2020.04.002.
- Zhang, J., Liu, X., Liao, W., and Li, X., 2022. Deep-learning generation of POI data with scene images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 188: 201-219, DOI: 10.1016/j.isprsjprs.2022.04.004.

Applying Deep Learning and Street View Imagery to Create a Spatial Agglomeration Index for Urban Street Signboards

Zhang-Xiu Luo ¹ Bo-Cheng Lin ^{2*}

Abstract

In recent years, deep learning has been used to construct quantitative indicators relevant to urban areas. Given the diverse array of dense billboards in Taiwan, this study aims to utilize deep learning techniques, including semantic segmentation and object detection, in conjunction with street view imagery to quantify the spatial distribution of signboards. Moreover, this study examines the spatial distribution patterns within the research area. The results demonstrate that the MIoU value of Deeplab v3+ model achieves 83%, while the Precision and Recall of YOLOv7 model achieves 91.7% and 87.1%. The analysis of spatial distribution patterns results align well with the actual distribution of billboards. This study can serve as a foundation for further exploration and application of billboards, as well as for integration with other related fields.

Keywords: Deep Learning, Semantic Segmentation, Object Detection, Street View Imagery, Spatial Analysis

¹ Master, Department of Real Estate and Built Environment, National Taipei University

² Assistant Professor, Department of Real Estate and Built Environment,
National Taipei University

* Corresponding Author, E-mail: bclin@gm.ntpu.edu.tw

Received Date: Dec. 12, 2023

Revised Date: Jan. 17, 2024

Accepted Date: Jan. 31, 2024

藉由相隔 15 年的兩組數據探索蘇鐵蕨物種分布模型 之時間可轉移能力

郭慶津¹ 邵寶嬋² 羅南璋³ 黃凱易^{4*}

摘要

本研究旨在探討不同演算法對物種分布模型 (species distribution model, SDM) 時間可轉移能力 (transferability) 的影響，以及使用深度學習法建立 SDM 的可能性。研究以蘇鐵蕨為目標物種，獲取該物種兩組調查時間相隔 15 年之數據，以最大熵值法 (maximum entropy, MAXENT)、隨機森林 (random forest, RF)、支持向量機 (support vector machine, SVM) 和深度學習法 U-net 進行試驗。結果顯示，MAXENT 和 SVM 有最佳的時間轉移能力，而 U-net 也有機會獲得甚佳的成果。顯示深度學習具研究潛力，後續研究有必要採納更多種類的深度學習法，並持續試驗。惟在環境變數方面，單獨使用地形因子可能限制了模型的時間轉移性，需尋找與物種更具直接因果關係的生態因子提高可轉移性。

關鍵詞：時間可轉移性、深度學習、物種分布模型、蘇鐵蕨

1. 前言

物種分布模型 (species distribution model, SDM) 是一種結合遙測 (remote sensing, RS)、地球空間資訊系統 (geospatial information system, GIS)、全球衛星導航系統 (global navigation satellite system, GNSS) 及人工智慧 (artificial intelligence, AI) 的技術。其主要由三個部分組成，物種的分布數據 (主要是出現數據)、環境變數，以及估計物種對環境偏好程度的建模方法 (李國慶等, 2013)。

此技術可預測物種潛在生育地，多年來已被應用在各式領域如造林樹種選擇 (Jensen *et al.*, 2021)、預測氣候變遷對物種分布之影響 (Brzozowski *et al.*, 2022、Glad & Mallard, 2022)、劃設保護區 (Maciel *et al.*, 2021、Yousefi *et al.*, 2022) 或是入侵生物管理 (Baer & Gray, 2022、El-Barougy *et al.*, 2021、Wang *et al.*, 2022)。

理想情況下，SDM 必須要具備時間可轉移 (透

通) 性 (transferability)。所謂時間轉移性指的是模型在模擬目標物種從過去至未來可能的空間分布變化，由此便能分析某一物種可能的遷徙路徑，或是族群未來可能的擴展位置。SDM 的時間轉移性對於外來物種的防除工作至關重要，若能正確預測其高風險擴散區，防除人員便能提前部署，在其入侵的早期階段變進行移除，避免其落地生根。

氣候變遷對物種分布的影響也往往是屬於這方面的研究。近年來，全球氣候變遷對生態系造成莫大的衝擊，許多學者想藉由 SDM 來分析當氣溫或降雨量改變，物種的生育地將如何變化。Brzozowski *et al.* (2022) 便以 SDM 預測一種稀有輪藻 (*Lychnothamnus barbatus*) 於現今、過去及未來的潛在分布，並比較不同氣候情境下的預測結果，找出其未來可能的生育地。

SDM 的時間轉移性給予生態研究一個機會來觀察和分析生態系統在不同時間尺度上的變化。但此類研究往往存有極大之限制，即我們無法得知物

¹ 國立中興大學森林學系 碩士生

² 林業及自然保育署南投分署埔里工作站 技士

³ 國立中興大學農業暨自然資源學院實驗林管理處育林組 組長

⁴ 國立中興大學森林學系 教授

* 通訊作者, E-mail: kyhuang@dragon.nchu.edu.tw

收到日期：民國 112 年 10 月 02 日

修改日期：民國 112 年 10 月 29 日

接受日期：民國 112 年 11 月 27 日

種在未來的實際生存點位，因而無法即刻證實模型的時間轉移能力。

而若要回溯物種過往的分布位置，儘管可自標本館或博物館得到累積數十年的資料，但這些數據難免存有位置偏差，或者是在衛星定位技術普及前採集的，因此只能從其文本描述推斷出概略的地理位置 (Feeley & Silman, 2010)。以這些品質堪虞的數據建立與驗證模型，將損及模型性能，影響後續的決策。

若能克服上述問題，另一個要面對的即是建模方法的選擇。經過長年的發展，目前已經有許多的演算法被提出並用於建立 SDM。而不同建模方法也會影響模型的時間可轉移性，這即是本研究之探討目標之一。此外，過往的 SDM 研究幾乎都是使用機器學習法來建立模型，鮮少有應用深度學習者。此乃因山高水深、層巒聳翠的自然環境甚難實地採集資料，故樣本數少有符合此新法之需求。

且前人研究指出機器學習法在模型的空間外推表現上可能不盡理想 (陳厚昌, 2013、Su *et al.*, 2012)。陳厚昌 (2013) 探討木荷於惠蓀林場空間分布，由其相距 5-8 km 的兩大集水區以包括 MAXENT、DOMAIN、決策樹等八種機器學習法相互空間外推，其準確度評估指標 κ 與真實技術統計 (true skill statistic, TSS) 落在 0.38-0.67，前三者居前且在伯仲

之間，惟表現不甚理想。Su *et al.* (2012) 模擬預測薯豆之物種空間分布，案例架構相近，所獲之結論亦同。

而深度學習具有學習能力強及優秀的泛化能力 (generalization ability)，這正是 SDM 所需要的特性。儘管本研究探討的是時間而非空間轉移性，但這兩者皆須藉良好泛化能力的演算法才能獲得較佳之推估成果。因此本研究之另一課題即是要克服樣本數的限制，以深度學習法建立 SDM，並與常見的機器學習法比較其時間可轉移能力。

2. 資料來源與研究方法

2.1 研究區域

本研究之試驗區位於南投縣仁愛鄉，為一涵蓋中興大學蓋惠蓀實驗林場之矩形區域，面積約為 18,000 公頃 (Ha)。惠蓀林場的海拔範圍落於 449 - 2,420 m 之間，整體地勢北低南高。圖 1 顯示了林場中的主要山峰與水系。最高峰為位於林場南界的守城大山 (2,420 m)，而林場中之兩大流域為關刀溪及東峰溪，兩溪皆由南向北流，並匯入林場北界的北港溪。惠蓀林場包含了低、中高海拔的生態環境，故其植物種類眾多，約達 1,100 種以上，為台灣中部極具代表性之森林 (羅南璋等, 2011)。

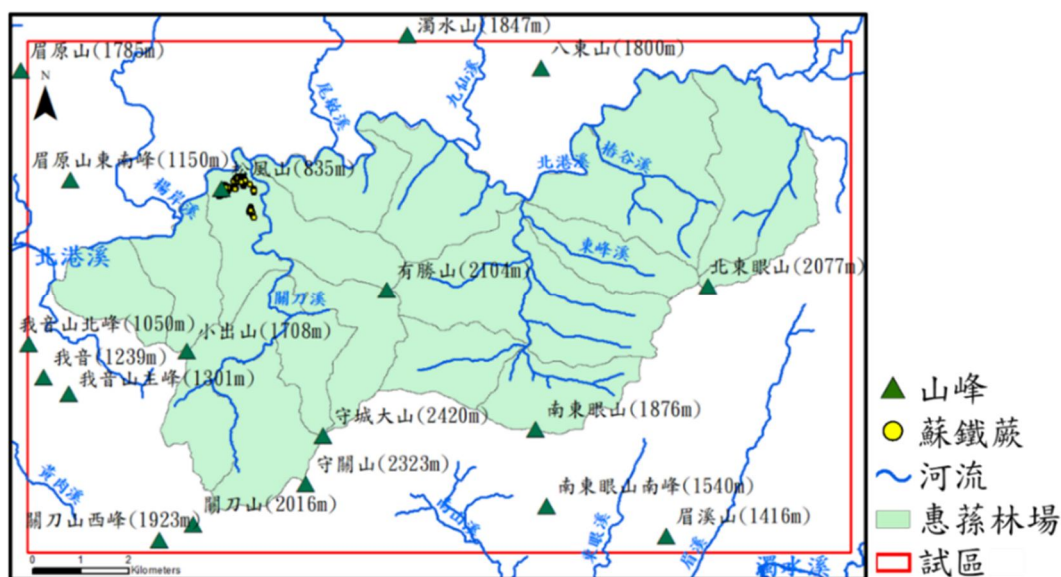


圖 1 研究區之主要水系與山峰

2.2 研究物種—蘇鐵蕨

本研究之目標物種為稀有植物蘇鐵蕨 (*Brainea insignis*)。其主要分布在台中和南投的中低海拔山區，以惠蓀林場的松風山一帶為其大本營，其他地方較為罕見 (郭城孟, 2001、許天銓等, 2019)。根據長年出入於惠蓀林場的中興大學實驗林管理處職員所觀察，若生育地環境適宜，此植物可存活至 30 年以上。

蘇鐵蕨為陽性植物，在光照良好的環境下生長旺盛，若於鬱閉處則成長受抑制。此物種是一種火燒適存植物，其頂芽具層層覆蓋之鱗片，能有效隔絕熱源，故在經歷林火後能快速復原 (蔡長宏, 1997)。而火焰的高溫能刺激其著生孢子 (呂金誠, 1990)，因此火燒是蘇鐵蕨傳宗接代的重要因子。

此外，詹雅婷、鄒裕民 (2021) 發現，蘇鐵蕨的出現與否和土壤稀土元素具密切關聯。有蘇鐵蕨生長的土壤稀土元素含量明顯高於無蘇鐵蕨分布處，而檢驗的 16 種稀土元素中以鈰 (Ce)、釹 (Nd)、鐳 (La) 為百分比含量最高，銩 (Tm)、鐳 (Lu) 為最低。惟此研究僅對惠蓀林場之族群進行分析，因此仍應當在其他蘇鐵蕨生育地做進一步的研究，充分理解和驗證蘇鐵蕨與稀土元素間的關聯性。

蘇鐵蕨樣本是本研究室歷經多年調查所獲得的資料。最早是在 2006 年於惠蓀林場內的松風山、杜鵑嶺及關刀山林道獲得 246 筆樣本，而 2021 年末和 2022 年初又分別在杜鵑嶺與松風山蒐集到 83 株蘇鐵蕨之資料。樣株的選擇方式是挑選經數年生長，已長出直立莖的植株，並以衛星定位儀測量其基部坐標。

早年調查採用的定位方式是動態後處理技術 (post processed kinematic, PPK)，使用儀器為 Trimble Pro XR GPS (簡稱 Pro XR) 並搭配 5 m 伸縮加長天線及雷射測距儀；近年調查之儀器則是使用 Trimble R12 衛星定位儀 (簡稱 R12)，並採用內政部國土測繪中心提供的 e-GNSS 即時動態定位系統 (real time kinematic, RTK)，透過無線網路連線產生虛擬參考站 (virtual reference station, VRS)，以 RTK VRS 進行定位。兩筆資料的定位誤差皆維持

在 ± 1 m 以內，具有相當可靠的位置情資 (location intelligence)，因此能有效降低位置偏差對模型的影響。而本研究將以 2006 年蒐集的樣本建立模型，並藉 2021 及 2022 年蒐集到的新樣本來驗證模型的時間可轉移性。



圖 2 蘇鐵蕨之外觀

2.3 環境變數

環境因子與各物種之間有複雜的反應關係。以植物而言，其可區分為氣候、土壤、生物及地形 (位置) 這四大類因子 (蘇鴻傑, 1987)，前三者一般可視為直接作用因子，若能作為預測變數，便有機會確保模型的透通性。然而這類資料多需藉氣象站之觀測數據或實地採集，數量遠不符所需，得再施以空間內插獲得相關網格圖層，惟其解析度仍然太低，且更含有難以預料之內插誤差。

地形因子雖屬於間接作用因子，但其是四者中唯一可憑遙測技術輕易獲取大範圍且高精度的資料，故其與物種之間的關係應是研究前期的首要核心。本研究共使用八種地形相關變數，分別為海拔、

坡度、坡向、曲率、太陽總輻射量 (global solar radiation, GSR)、地形位置指標 (topographic position index, TPI)、地形粗糙度指標 (terrain ruggedness index, TRI) 和地形濕度指標 (topographic wetness index, TWI)。這些因子皆是藉由內政部地政司衛星測量中心的 1 m 解析度空載光達數值高程模型 (digital elevation model, DEM) 求導計算而出。

2.3.1 海拔

海拔圖層係使用 DEM 所紀錄之高程資訊。一般而言，隨著海拔高度的提升，氣溫將逐漸降低。植物受其影響，植群呈垂直分布變化，低、中和高海拔地區的天然植物組成截然不同。

2.3.2 坡度、坡向與曲率

坡度 (slope) 會影響土壤水分和養分含量。坡度大的地區，土壤易被侵蝕，而在坡度較小的地區，土壤與水分相對容易積聚，環境通常顯得較為潮濕。坡向 (aspect) 為某一位置最陡下坡所面對的羅盤方向，不同的坡向，將導致溫度、日照、濕度與土壤水分出現差異 (蘇鴻傑, 1987)。以北半球而言，南向與西南向坡通常較北向與東北向坡來的溫暖乾燥。本研究參考邵寶燁 (2020) 的做法，將坡向進行八方位轉換，各類別的角度範圍如表 1 所示。

曲率 (curvature) 可判斷地表的某一部分是凸還是凹，並可描繪水流侵蝕和徑流形成的過程。曲率數值越大，代表在凸坡上，負值越小代表在凹坡上，零值則在平坦面。坡度、坡向與曲率三圖層皆是使用 ArcGIS 10.3 的空間分析模組 (spatial analyst) 分別從 DEM 求導而出。

表 1 坡向類別的代碼 (邵寶燁, 2020)

類別代碼	坡向	角度範圍
0	平坦	坡度為 0° 平坦地無坡向
1	北方	0° - 22.5°; 337.5° - 360°
2	東北方	22.5° - 67.5°
3	東方	67.5° - 112.5°
4	東南方	112.5° - 157.5°
5	南方	157.5° - 202.5°
6	西南方	202.5° - 247.5°
7	西方	247.5° - 292.5°
8	西北方	292.5° - 337.5°

2.3.3 太陽總輻射量

太陽輻射左右植物之光合作用，是植物生長過程中的重要因素之一。而到達地面之輻射量可分為直接輻射 (direct radiation) 和漫射輻射 (diffuse radiation)，這兩種輻射量之加總就是太陽總輻射量 (GSR)。本研究試使用 ArcGIS 10.3 的 Area Solar Radiation 模組自 DEM 推導出試區的 GSR 圖層。該資料的單位為瓦特小時每平方米 (Wh/m²)。

2.3.4 地形位置指標

地形位置指標 (TPI) 能夠描述某一地點之位置與當地地形起伏之相對關係，如山頂、谷底、山腰或平原。TPI 與植物的生長有密切關連，通常越接近稜線，周遭環境之土壤、養分及水分会較為缺乏，而在這些物質較易積累於山谷處，光照量則會顯得相對較少。

TPI 的計算是根據一個指定大小的核心視窗 (kernel size)，在這個視窗內，對每一個像元的高程減去所有像元高程的平均值，所得到的差值就是該像元的 TPI 值，其公式如下 (De Reu *et al.*, 2013):

$$TPI = z_0 - \bar{z} \dots\dots\dots(1)$$

$$\bar{z} = \frac{1}{n_R} \sum_{i \in R} z_i \dots\dots\dots(2)$$

z_0 為中心像元的高程； \bar{z} 是平均海拔； R 為核心視窗之半徑； n_R 是視窗內的像元總數； z_i 則是第 i 個像元的高程。如果一個地區的 TPI 值為負數，說明該地區相對於周圍環境比較低，若是正數，則該地相對高於周圍環境。而出現 0，則表示該地區與周圍環境的高度基本相等，在坡度緩的地方則為平地，但若是在坡度陡峭的山區，此值表示該地位於山腰或以上處。

此外，核心視窗的大小將大幅影響相同地點的 TPI 數值。小的視窗半徑將呈現細緻的微地形，大的視窗半徑則呈現大尺度特徵。本研究是使用 SAGA GIS 的模組進行試區 TPI 的計算，此模組還可使用與中心網格的距離作為權重，在設定時本研

究選擇距離倒數冪次加權法 (inverse distance to a power)，權重使用其預設值 1。視窗半徑的部分，本研究分別設置為 100、200 及 400 pixels，以三種 TPI 圖層 (TPI_100、TPI_200、TPI_400) 測試不同空間尺度特徵對蘇鐵蕨模型的影響性。

2.3.5 地形粗糙度指標

地形會影響濕度和陽光照射，以及侵蝕和沈積等過程，地形粗糙度指標 (TRI) 即可用於測量地形的異質性。TRI 透過計算以對應地點為中心的正方形內子網格高度的標準偏差來量化表面的粗糙度，詳細公式如下 (Zhou *et al.*, 2019)：

$$TRI = \sqrt{\frac{1}{n} \sum (H_{ij} - \bar{H})^2} \dots\dots\dots (3)$$

其中， n 表示視窗範圍內之網格數； H_{ij} 為各點之高度值； \bar{H} 則是視窗範圍內各點高度值之平均。此指標同樣是 DEM 衍伸的地形相關變數，而本研究是使用 Qgis 的 GDAL 外掛模組進行 TRI 圖層的生產。

2.3.6 地形濕度指標

土壤水分控制著環境作用與物種的分布，然而卻很難進行大範圍的實地測量與空間內插。因此從 DEM 推導出的地形濕度指標 (TWI) 通常會被作為土壤濕度與植物可用水分的替代指標 (Kopecký *et al.*, 2021)。TWI 數值較高的區域相對上會比數值低的區域來的濕潤。本研究是使用 GRASS GIS 的 r.topidx 模組進行 TWI 的運算，此指標之計算公式如下 (賴韋愷，2016)：

$$TWI = \ln\left(\frac{\alpha}{\tan\beta}\right) \dots\dots\dots (4)$$

其中， α 為該單位等高線上游集流面積； β 為該網元之坡度。上凸坡形因為位處上坡處，會因重力流入下坡而不易累積水分；下凹坡形則相反。

2.4 取樣設計

本研究獲得的兩筆蘇鐵蕨樣本調查時期相差近 15 年，因此可藉由兩種取樣設計法 (sampling design, SD) 探討模型的時間可轉移性。

SD1：訓練與測試樣本皆為 2006 年之蘇鐵蕨植株，經抽取出四倍的背景樣本後，以 70% 的資料為訓練集，剩餘的 30% 為測試集。

SD2：訓練集使用的是與 SD1 相同的數據，但測試樣本改成使用 2021 和 2022 年所獲得的資料，旨在測試 SDM 預測未來蘇鐵蕨空間分布的能力。

2.5 建模方法

本研究以最大熵值法 (maximum entropy, MAXENT)、隨機森林 (random forest, RF) 和支持向量機 (support vector machine, SVM) 這三種常見的機器學習法以及深度學習法 U-net 建立 SDM。

用於建立蘇鐵蕨 SDM 的軟體來源有四，MAXENT 使用線上免費軟體 MAXENT 3.4.4 版本進行操作，此軟體可免費自其官方網站下載 (https://biodiversityinformatics.amnh.org/open_source/maxent/)。SVM 與 RF 使用的軟體 EnMAP-Box 3 是開源 GIS 軟體 Qgis 的外掛模組，只要在 Plugins\Not installed 介面中輸入該軟體之名稱後即可下載使用。U-net 部分則是使用 ArcGIS pro 2.8 版本進行模式的建立。

2.5.1 最大熵值法

最大熵值法 (MAXENT) 的原理是在一組約束條件的限制下 (我們不完全瞭解目標物種的實際分布狀態)，通過找到最大熵的機率分布 (即最分散或最接近均勻的機率分布) 來估計目標物種可能的分布情形 (Phillips *et al.*, 2006)。此演算法對於小樣本數和應對存在數據的取樣偏差時比起其他建模方式更加具有穩健性 (robustness) (Bushi *et al.*, 2022)。也因此，其是目前使用最廣泛的 SDM 演算法之一，尤其受到林業研究者的青睞 (Pecchi *et al.*, 2019)。

在進行 MAXENT 的參數設定時，本研究僅依照主體樣本的不同調整背景樣本的數目大小，其餘參數皆使用預設值。輸出之格式選擇邏輯轉換 (logistic) 來產生物種之分布機率圖，而在轉換為二元分類圖則選取 maximum training sensitivity plus specificity 為閾值，因在測試後發現此閾值最能顯現蘇鐵蕨的潛適分布。

2.5.2 隨機森林

隨機森林 (RF) 是一種集成式學習 (ensemble learning) 的機器學習法。此演算法的主要思想是將多個決策樹 (decision tree, DT) 集成在一起，每個 DT 在一個不同的隨機樣本和特徵集上訓練。最後，將所有 DT 的預測結果進行投票，採用多數決的方式指定所屬類別。

在參數的設定上，本研究參考邵寶燁 (2020) 的作法，將決策樹數量 ($n_estimators$) 設定為 500，並調整最大樹深度 ($max\ tree\ depth$)、母節點 (parent node) 與子節點 (child node)。其餘參數皆使用預設值。

2.5.3 支持向量機

支持向量機 (SVM) 是一種無母數統計分類法，其優勢在於其不需要過多的訓練樣本即可進行運算，也能處理高維度的數據。此演算法的主要原理是在特徵空間中尋求具最大邊界的分割超平面 (hyperplane) 以區分不同的二元類別 (陳承昌、史天元, 2007)。非線性支持向量機透過核函數 (kernel function) 將原始資料轉換到另一個高維度的特徵空間中，然後在特徵空間上執行線性分類。常用的核函數有線性函數 (linear)、多項式函數 (polynomial)、放射型核函數 (radial basis function,

RBF) 及 S 型核函數 (sigmoid) (黃凱翔, 2008)。本研究是採用模組的預設值，以放射型核函數進行運算。

2.5.4 U-net

U-net 是一種全卷積神經網絡 (fully convolutional networks, FCN)，由於它能夠對輸入影像進行像元級別的分類，因此也適合用於衛星影像的分類 (Flood *et al.*, 2019)。而建立 SDM 基本上就是在進行影像分類的動作，也因此本研究選擇此演算法來模擬蘇鐵蕨的空間分布。

不同於前面三種機器學習法，U-net 是以網格式態的影像切片作為訓練樣本，因此不能直接使用蘇鐵蕨樣本 (向量的點型態) 進行模式的訓練。而本研究的作法是先以 MAXENT、SVM 與 RF 獲得蘇鐵蕨在試區的潛勢分布圖 (圖 3 (a))，接著挑選一塊包含訓練上述模式時所使用的蘇鐵蕨樣本之矩形區塊作為 U-net 的訓練區 (圖 3 (b))，當完成訓練後再將成果外推至整個研究區。

在參數設定上，本研究基本上沿用預設值，但會統一將批次大小 (batch size) 設為 4，max epochs 則在每次訓練時都進行調整，直到得到最佳訓練成果。而在訓練時僅有 90% 的樣本會用於訓練，剩下的 10% 用於驗證。

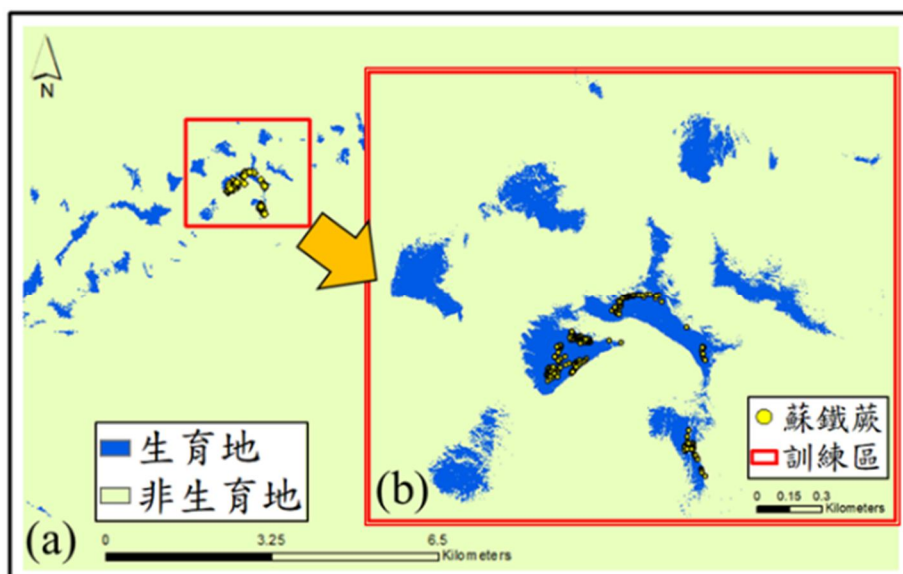


圖 3 生產 U-net 訓練樣本之示意圖 (a) 以機器學習法 (MAXENT、RF、SVM) 獲得蘇鐵蕨之潛勢分布圖、(b) 選擇出一塊矩形訓練區

2.6 模式驗證

模式的驗證非可以確認我們所構建的模型的可靠程度，以及對新樣本的預測能力。本研究採用分割樣本驗證，以 70% 的樣本用於訓練，剩餘的 30% 為測試樣本。訓練與測試樣本是完全相互獨立，因此測試結果會客觀且可靠。U-net 則與其他三種常見的機器學習法不同，一般會將數據及切割成訓練集、驗證集與測試集三個部分 (邵寶嬋, 2020)，在介紹 U-net 參數設定時有提及，訓練集與驗證集的比例為 90 : 10，測試集的部分則是選用和其他三個模式相同的測試樣本，如此一來再進行精度評估時才能有相同的比較基準。而若有測試樣點落於 U-net 的訓練區中，本研究會另外將其標記於 IGNORE_CLASSES 欄位中，避免被納為模型的訓練樣本。

本研究使用的評估指標分別是實際和預測類別相符的一致性係數之 *kappa* 值，以及真實技術統計 (TSS)。*kappa* 值的範圍是在 -1 到 1 之間，但通常會介於 0 和 1，此指標的優點包括其簡單性，以及同時考慮誤授誤差 (commission error) 與漏授誤差 (omission error) (Manel *et al.*, 2001)。

TSS 於 2006 年由 Allouche 等人所提出，該指標的一大特色是其改善 *kappa* 對盛行率 (prevalence; 即主體與背景的比例) 過於敏感的問題，但仍保有其原有的優點。也因此，TSS 被建議使用為 SDM 研究的評估指標 (陳厚昌, 2013)。TSS 的值域同樣是介於 -1 到 1，當數值為 1 時表示預測結果與實際情

形完全一致而值為 0 或小於 0 則表示性能不比隨機好 (Allouche *et al.*, 2006)。

3. 結果討論

3.1 環境因子敘述統計

表 2 為蘇鐵蕨及試區的環境因子統計值。在海拔的部分，蘇鐵蕨僅分布在惠蓀林場的低海拔地區，平均生長在海拔 763 m 之區域。由於其屬於陽性植物，故其 GSR 平均值明顯高於試區，充分展現其需光亮高的特性。也因此，TPI 顯示，其主要生長在山腰以上之區域，並且也能出現在山脊或山頂的位置。蘇鐵蕨多半出現在東南坡偏南向坡，儘管有少數生長在北向坡的植株，但這些植株之生長位置接近山脊，故仍然能接受充沛的日照。而坡度及 TRI 說明，過於崎嶇陡峭地形，導致土壤含水量及養分偏低的情況下，蘇鐵蕨可能不易生長，因 TWI 顯示，適度的水分才有助於此物種的生存。

3.2 各因子對模式之相對重要性

在執行 SDM 的運算時，各個環境變數對不同的模式將有不同的貢獻度。本研究使用 MAXENT 的折疊刀法試驗 (jackknife test) 對各變數的重要性進行評價。折疊刀法試驗會依序移除每個變數，使用剩餘變數建立模型，再單獨以每個變數建立模型，最後與納入所有變數的模型以橫條圖的方式進行比較。

表 2 蘇鐵蕨之環境因子敘述統計

DEM (1 m)	蘇鐵蕨				全區 (背景)			
	平均值	最大值	最小值	眾數	平均值	最大值	最小值	眾數
海拔 (m)	763.6	823.4	696.8	764.7	1294.3	2420.2	440.0	1735.6
坡度 (°)	32.4	58.6	2.7	39.4	38.3	76.2	0.8	48.6
坡向 (°)	4.8	8	1	4	4.8	8	1	7
曲率 (m ⁻¹)	4.7	171.0	-70.0	-2.0	0.5	370.0	-263.0	0.0
TWI	3.66	6.61	-0.36	3.07	3.84	10.07	-1.26	3.35
GSR (Wh/m ²)	1,546,422	1,732,420	643,142	1,584,920	1,362,241	1,998,860	324,450	1,401,920
TRI	0.51	1.29	0.05	0.47	0.68	3.15	0.01	0.58
TPI_100	1.32	3.43	-1.03	1.28	0.03	3.22	-4.36	0.36
TPI_200	1.57	3.52	-0.89	1.65	0.00	3.10	-3.37	0.03
TPI_400	1.54	3.12	-0.11	1.81	0.00	3.06	-2.86	0.26




圖 4 MAXENT 之折疊刀法試驗結果

圖 4 為 MAXENT 之折疊刀法試驗結果。該圖顯示，海拔是所有變數中重要性最高者，若缺少此變數，模型精度將大幅下降。而繼海拔之後，三種 TPI 將能獲得次佳的訓練增益 (training gain) 效果，其中又以 TPI_400 的貢獻度最高。其餘變數中以 GSR 的重要性較高，惟曲率和 TWI 對模型則幾乎無貢獻，因此在進行模式的運算時會移除這兩個變數。

3.3 U-net 訓練區

圖 5 為取樣設計 SD1 的 U-net 訓練區位置圖，範圍涵蓋 Pro XR 在惠蓀林場的所有樣本。此訓練區是一個 2435×2070 m 的矩形，代表在 1 m 解析度時總共有 5,040,450 個像元能作為訓練樣本。當然此訓練區無可避免的會將 R12 測量之樣點包含在內，為避免這些點被納入訓練樣本，必須將這些資料統一為單獨的類別，並標記在模型的 IGNORE_CLASSES 中。

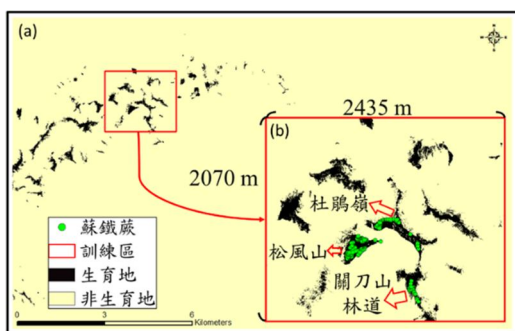


圖 5 U-net 訓練區之位置 (a) RF 預測分布圖、(b) U-net 訓練區

3.4 模型表現

3.4.1 以相同時期的資料訓練與測試模型

表 3 為取樣設計 SD1 之模式精度。當使用 2006 年調查到的所有樣本作為訓練與測試樣本時，獲得的準確度評估指標數值皆顯示模型表現相當優異，*kappa* 及 TSS 均在 0.90 以上。值得一提的是，U-net 大多能獲得良好的訓練成果。雖部分與原始的演算法相比雖有劣化，但 MAXENT 模式在經過 U-net 的深度學習後產出的 SDM 具有更高的生產者精度，故模型整體精度有所提升，因而成為所有模型中表現最佳者。證實以常見的機器學習法，提供更多的訓練樣本給深度學習進行 SDM 的構建確實可行。

圖 6 為 MAXENT_U-net 模式之預測分布圖，其推測蘇鐵蕨適合生長在試區的西北角，特別是北港溪兩側的山嶺中。而此模式幾乎都能正確預測到蘇鐵蕨在三個生育地的分布位置，僅有在杜鵑嶺北側有少許漏授樣本。

表 4 顯示了各模式預測出的蘇鐵蕨潛在生育地面積。其顯示蘇鐵蕨的生育地不會超過研究區總面積的 2%。此結果符合其為稀有植物的特徵，表明適合其生長的區域十分有限。若比較 U-net 與其他機器學習法之結果可發現，除 MAXENT_U-net 小幅增加面積之外，其餘的 U-net 模型都能夠有效減少蘇鐵蕨的預測生育地面積。由於這些模型的精度皆

相當優良，預測生育地減少表示有助縮減需要實地調查的區域，讓研究者能鎖定蘇鐵蕨的高潛勢分布地。

表 3 各模式於取樣設計 SD1 之模型精度

模式	SD1	
	<i>kappa</i>	TSS
MAXENT	0.97	0.97
RF	0.95	0.94
SVM	0.97	0.97
MAXENT_U-net	0.98	0.98
RF_U-net	0.93	0.90
SVM_U-net	0.93	0.92

表 4 各模式於取樣設計 SD1 推估出的蘇鐵蕨生育地面積

模式	面積 (ha)	試區百分比 (%)
MAXENT	176.8	1.0
RF	160.1	0.9
SVM	236.9	1.3
MAXENT_U-net	184.9	1.0
RF_U-net	145.5	0.8
SVM_U-net	185.8	1.0

3.4.2 模型的時間轉移能力

表 5 呈現了取樣設計 SD1 以及利用 R12 樣本進行驗證的結果。很明顯的，各模式的精度皆下降。雖然 MAXENT、SVM 和 MAXENT_U-net 之 TSS 值仍可保持在 0.85 以上，但 RF 下滑至 0.74，SVM_U-net 更是僅剩 0.66。因時間與資源因素，2021 及 2022 年的調查仍是在已確認有蘇鐵蕨分布的松

風山與杜鵑嶺進行樣本的採集。然而即便如此，模式的精度仍然顯著下滑，說明模型時間轉移性的不易。

對於蘇鐵蕨 SDM，造成及時間透通性不佳的原因很可能是兩期樣本的環境變數 TPI 特徵不同所造成。TPI 數值越高，表示越接近山頂，而圖 7 顯示，2006 年獲得的樣本主要分布在山腰以上至山頂之區域，僅有部分位於松風山之植株是出現在山腰。然而 15 年後，以 R12 定位的樣本雖有部分是生長在山頂之區域，但也有為數不少之植株是出現在杜鵑嶺及松風山的山腰處，甚至在杜鵑嶺更有生長在略低於山腰者。

TPI 屬於蘇鐵蕨 SDM 的重要變數，因此當演算法僅接收到 Pro XR 樣本之訊息，便無法正確拿捏蘇鐵蕨於坡面位置之分布下限，認定山腰以下之區域不適合蘇鐵蕨生長。時間轉移性表現較好者如 MAXENT (圖 7 (b)) 與 SVM 雖能多能正確預測到山腰的植株，但仍會遺漏杜鵑嶺山腰以下之樣本。至於 RF_U-net 與 SVM_U-net (圖 7 (c)) 對於分布下限的認定較為嚴格，山腰之區域多半被視為非生育地，因此在松風山東北角及杜鵑嶺東南邊出現許多遭遺漏的樣本。此現象說明單靠屬於間接作用因子的地形變數建立 SDM 時，其解釋能力可能不足夠，應尋找其他更具因果關係的因子如植生指標，才能提升 SDM 的時間通透性。

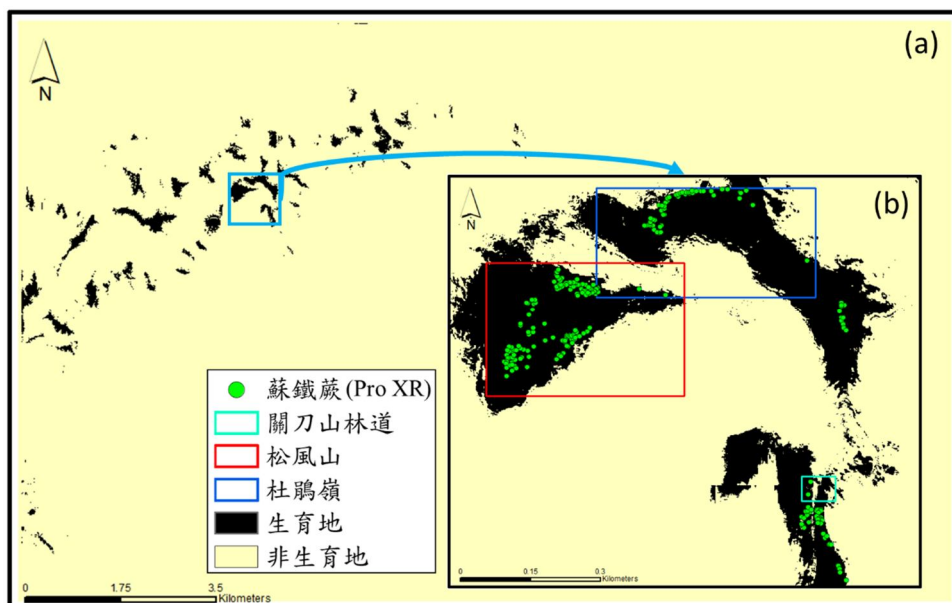


圖 6 (a) 以 MAXENT_U-net 建立的蘇鐵蕨 SDM、(b) 該模式於松風山、杜鵑嶺及關刀山林道的預測結果

至於蘇鐵蕨往山腰分布的原因，本研究推測與降水型態的改變有關。根據水利署惠蓀雨量站所紀錄 39 年來之降水資訊，雖年平均降雨並未明顯變化，但降雨型態有轉為雨季短且雨量集中、旱季長的趨勢。植物的有效降水減少造成林中枯立木明顯增加。而這種現象反倒有利於蘇鐵蕨生長，乃因此植物耐旱，能適應此種降雨特徵。枯立木的出現則增加森林的透光率，讓蘇鐵蕨能充分接收陽光的區域變多，使其族群能向山腰擴展。

隨著時間的推移，蘇鐵蕨的空間分布有逐漸朝向山腰分布的趨勢。而若只進行一次的現場調查是不可能觀察到此現象的。這即指出精良 SDM 的建立是一個迭代 (iterative) 的過程，完成首次模擬後必須重返現場，檢核第一輪模型與物種實際分布情形的相符程度，此即第二次現場驗證。當蒐集更多

的樣本後再進行第二次的模擬，並重複此流程，反覆修正直到獲得最佳模式。

本研究之成果同步證明二次現場驗證之重要性。單憑一輪的模擬容易高估 SDM 的預測性能，研究者必須由虛擬數位世界的預測成果中返回實際世界檢核模型的可靠性。若條件許可，甚至要進行更多次的現場實證。

表 5 取樣設計 SD1 和 SD2 之模型精度

模式	SD1		SD2	
	kappa	TSS	kappa	TSS
MAXENT	0.97	0.97	0.91	0.86
RF	0.95	0.94	0.82	0.74
SVM	0.97	0.97	0.91	0.86
MAXENT_U-net	0.98	0.98	0.90	0.85
RF_U-net	0.93	0.90	0.76	0.68
SVM_U-net	0.93	0.92	0.75	0.66

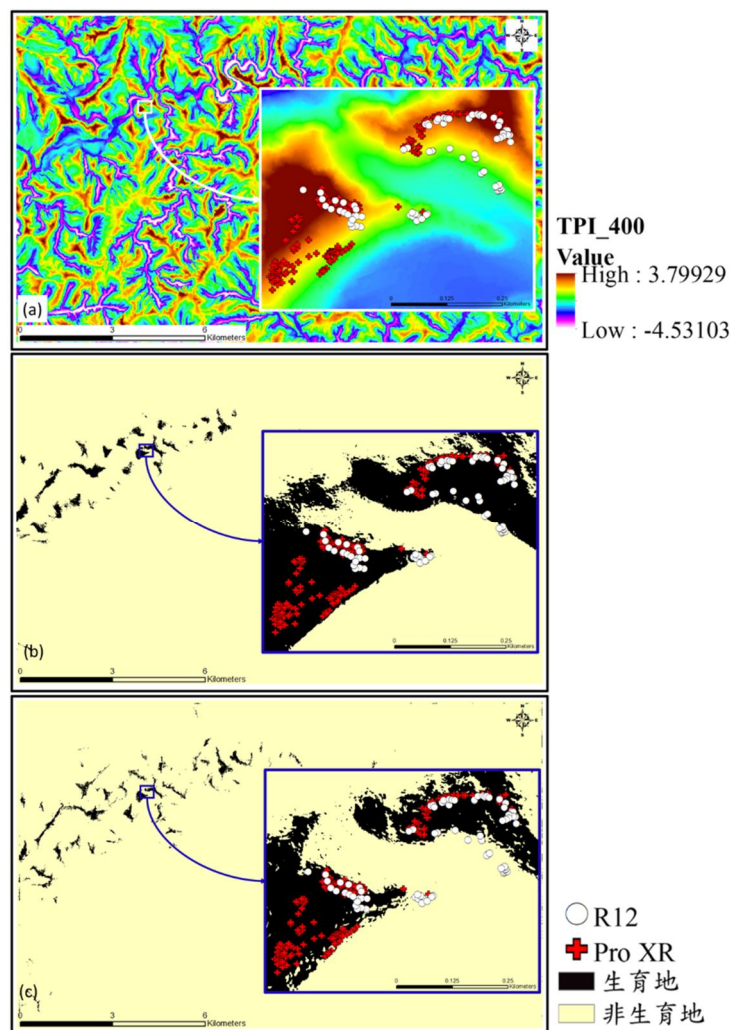


圖 7 環境變數 TPI_400 對模式在取樣設計 SD1 和 SD2 造成的影響 (a) R12 與 Pro XR 樣本於 TPI_400 之數值、(b) MAXENT 之預測分布圖、(c) SVM_U-net 之預測分布圖

4. 結論與建議

自然資源領域多需要在崇山峻嶺的環境實地採集資料，數據得來艱困且數量通常相當有限。然而藉由將機器學習與深度學習兩相結合後，本研究證實，此操作可在多數情況下成功訓練出可靠的深度學習模型，為 SDM 研究帶來新的可能性。對於建構蘇鐵蕨的 SDM，U-net 算是相當優異的演算法，其預測精度不差，推估出的潛在生育地面積又小，對於將有限的資源投入到新族群的探索有極大助益。利用深度學習建立 SDM 仍有許多值得探討的地方，本研究僅為初步嘗試，後續研究有必要採納更多種類的深度學習法，並持續進行試驗。

在本研究中，若訓練與測試樣本皆來自同一時期之調查成果，SDM 幾乎都能表現得相當優異。然而在預測 15 年後的蘇鐵蕨分布時，各模式之精度明顯下降，顯示模型的時間轉移性仍有待改善。四種演算法中以 MAXENT 和 SVM 有最佳的時間透過性，而 U-net 也有機會獲得頗佳的成果。而在環境變數方面，單靠地形因子使模式的轉移能力受限，故仍需找尋物種與環境有直接因果關係的生態因子，方有可能改善時間轉移性之困境。

可靠的 SDM 需藉由不斷的反覆迭代修正來生成。若條件許可，後續仍需多次往返虛擬預測結果與實體現場進行比對驗證，藉此提升 SDM 的應用價值，並能更好的預測未來蘇鐵蕨族群分布的變化。而未來也會將試區範圍擴大至惠蓀林場外，以測試評估深度學習法及其餘三種常用機器學習法在空間外推之效能。

參考文獻

呂金誠，1990。野火對臺灣主要森林生態系影響之研究，國立中興大學植物學系博士論文。[Lyu, J.C., 1990. Effects of wildfires on the main forest ecosystems in Taiwan, Doctoral Dissertation, National Chung Hsing University, Taiwan, ROC. (in Chinese)]

李國慶、劉長成、劉玉國、楊軍、張新時、郭柯，

2013。物種分佈模型理論研究進展，生態學報，33(16) : 4827-4835，DOI : 10.5846/stxb201212031735。[Li, G.Q., Liu, C.C., Liu, Y.G., Yang, J., Zhang, X.S., and Guo, K., 2013. Advances in theoretical issues of species distribution models, *Acta Ecologica Sinica*, 33(16): 4827-4835, DOI: 10.5846/stxb201212031735. (in Chinese)]

邵寶燁，2020。地形屏障效應對不同海拔之樹種物種分布模擬預測之影響，國立中興大學森林學系碩士論文。[Shao, B.H., 2020. The impact of the terrain-shelterbelt effects on species distribution modeling for tree species at various altitude, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]

許天銓、陳正為、Ralf Knapp、洪信介，2019。台灣原生植物全圖鑑第八卷(上)：蕨類與石松類，台北市：貓頭鷹出版社。[Hsu, T.C., Chen C.W., Knapp, R., and Hung, H.C., 2019. Illustrated Flora of Taiwan: Ferns and Lycophytes I, Owl Publishing House Co., LTD., Taiwan, ROC. (in Chinese)]

郭城孟，2001。蕨類圖鑑：台灣三百多種蕨類生態圖鑑，台北市：遠流出版公司。[Kuo, C.M., 2001. Ferns of Taiwan, Yuan-Liou Publishing Co., Ltd, Taiwan, ROC. (in Chinese)]

陳承昌、史天元，2007。支持向量機應用於水稻田辨識之研究，航測及遙測學刊，12(3)：225-240，DOI：10.6574/JPRS.2007.12(3).3。[Chen C.C., and Shih, T.Y., 2007. Rice paddy identification using the support vector machine, *Journal of Photogrammetry and Remote Sensing*, 12(3): 225-240, DOI: 10.6574/JPRS.2007.12(3).3. (in Chinese)]

陳厚昌，2013。物種分布模式預測功效影響因子之評估，國立中興大學森林學系碩士論文。[Chen, H.C., 2013. Evaluation of the factors affecting predictive performance of species distribution models, Master Thesis, National Chung Hsing

- University, Taiwan, ROC. (in Chinese)]
- 黃凱翔，2008。利用支持向量機於機載高光譜感測影像之分類，國立中興大學土木工程學系碩士論文。[Huang, K.S., 2008. Application of support vector machines to airborne hyperspectral image classification, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 詹雅婷、鄒裕民，2021。惠蓀林場蘇鐵蕨與土壤稀土元素分布之相關性，國立中興大學農業暨自然資源學院實驗林管理處補助計畫-成果報告，pp.217-233。[Chan, Y.T., and Tzou, Y.M., 2021. Rare earth elements (REEs) in soil and *Brainea insignis* at Huisun Experimental Forest Station, Project Report, National Chung Hsing University, Taiwan, ROC, pp.217-233. (in Chinese)]
- 蔡長宏，1997。關刀溪森林生態系干擾地更新之研究，國立中興大學植物學系碩士論文。[Tsai, C.H., 1997. Studies on the regeneration of disturbed sites at Guandaushi forest ecosystem, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 賴韋愷，2016。以地形濕度指標及太陽輻射指標搭配長用地形變數於首輪迭代物種分布模擬，國立中興大學森林學系碩士論文。[Lai, W.K., 2016. Modeling species distribution on an iterative basis with topographic wetness indices and solar radiation index along with common terrain variables in initial rounds, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 羅南璋、張偉顛、黃凱易，2011。應用 3S 技術及多變量統計於薯豆及卡氏槲潛在生育地之推估，林業研究季刊，33(3)：55-70，DOI：10.29898/SHBQ.201109.0005。[Lo, N.C., Chang, W.I., and Huang, K.Y., 2011. Application of 3S and multivariate statistics to predict the potential habitat of *Elaeocarpus japonicus* and *Castanopsis carlesii*, Quarterly Journal of Forest Research, 33 (3): 55-70, DOI: 10.29898/SHBQ.201109.0005. (in Chinese)]
- 蘇鴻傑，1987。森林生育地因子及其定量評估，中華林學季刊，20(1)：1-14。[Su, H.J., 1987. Forest habitat factors and their quantitative assessment, Quarterly Journal of Chinese Forestry, 20(1): 1-14. (in Chinese)]
- Allouche, O., Tsoar, A., and Kadmon, R., 2006. Assessing the accuracy of species distribution models: Prevalence, kappa and the true skill statistic (TSS), Journal of Applied Ecology, 43(6): 1223-1232, DOI: 10.1111/j.1365-2664.2006.01214.x.
- Baer, K.C., and Gray, A.N., 2022. Biotic predictors improve species distribution models for invasive plants in Western U.S. Forests at high but not low spatial resolutions, Forest Ecology and Management, 518: 120249, DOI: 10.1016/j.foreco.2022.120249.
- Brzozowski, M., Pelechaty, M., and Bogawski, P., 2022. A winner or a loser in climate change? Modelling the past, current, and future potential distributions of a rare charophyte species, Global Ecology and Conservation, 34: e02038, DOI: 10.1016/j.gecco.2022.e02038.
- Bushi, D., Mahato, R., Nimasow, O.D., and Nimasow, G., 2022. MaxEnt-based prediction of the potential invasion of *Lantana camara* L. under climate change scenarios in Arunachal Pradesh, India, Acta Ecologica Sinica, 43(4): 674-683, DOI: 10.1016/j.chnaes.2022.08.004.
- De Reu, J., Bourgeois, J., Bats, M., Zwertvaegher, A., Gelorini, V., De Smedt, P., Chu, W., Antrop, M., De Maeyer, P., Finke, P., Van Meirvenne, M., Verniers, J., and Crombé, P., 2013. Application of the topographic position index to heterogeneous landscapes, Geomorphology, 186: 39-49, DOI: 10.1016/j.geomorph.2012.12.015.
- El-Barougy, R.F., Dakhil, M.A., Halmy, M.W., Gray, S.M., Abdelaal, M., Khedr, A.-H.A., and Bersier,

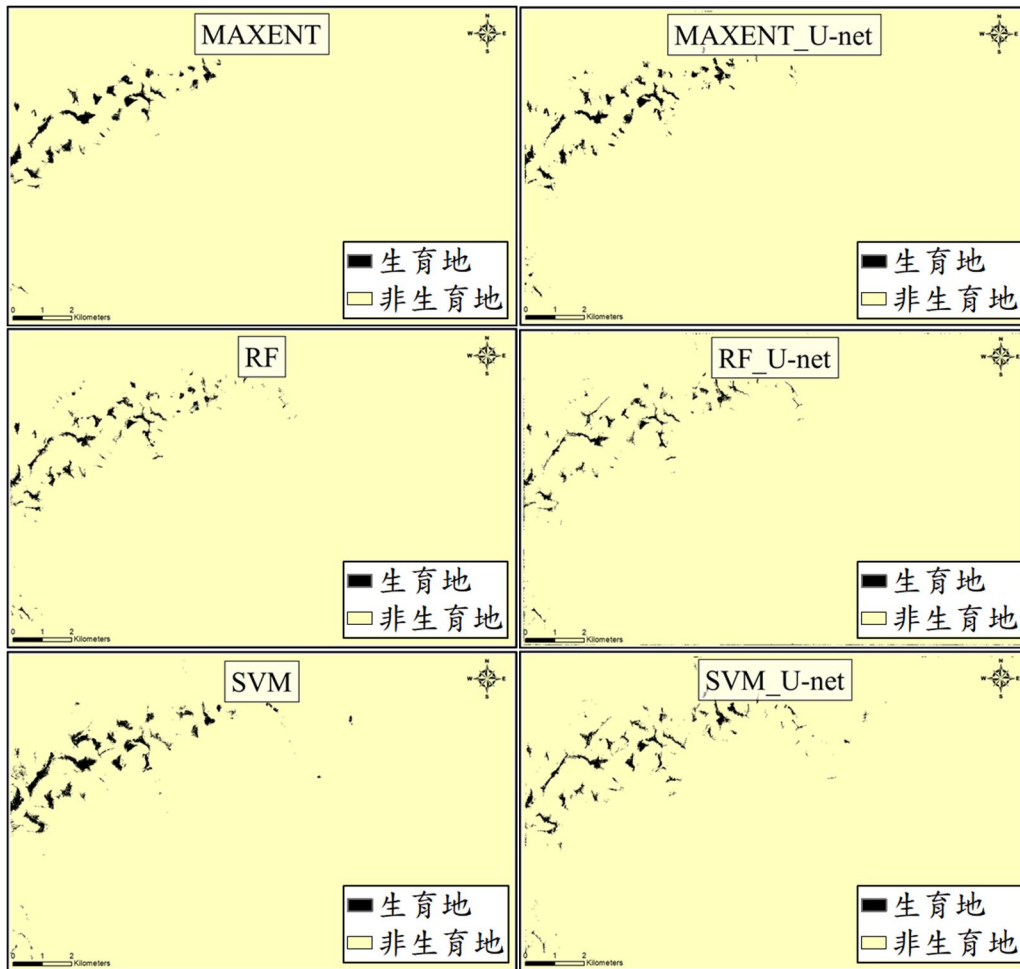
- L.-F., 2021. Invasion risk assessment using trait-environment and species distribution modelling techniques in an arid protected area: Towards conservation prioritization, *Ecological Indicators*, 129: 107951, DOI: 10.1016/j.ecolind.2021.107951.
- Feeley, K.J., and Silman, M.R., 2010. Modelling the responses of Andean and Amazonian plant species to climate change: The effects of georeferencing errors and the importance of data filtering, *Journal of Biogeography*, 37(4): 733-740, DOI: 10.1111/j.1365-2699.2009.02240.x.
- Flood, N., Watson, F., and Collett, L., 2019. Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia, *International Journal of Applied Earth Observation and Geoinformation*, 82: 101897, DOI: 10.1016/j.jag.2019.101897.
- Glad, A., and Mallard, F., 2022. Alpine marmot (*Marmota marmota*) distribution evolution under climate change: The use of species distribution models at a local scale in the western Pyrenees massif (France), *Ecological Informatics*, 69: 101646, DOI: 10.1016/j.ecoinf.2022.101646.
- Jensen, D.A., Rao, M., Zhang, J., Grøn, M., Tian, S., Ma, K., and Svenning, J.-C., 2021. The potential for using rare, native species in reforestation—A case study of yews (*Taxaceae*) in China, *Forest Ecology and Management*, 482: 118816, DOI: 10.1016/j.foreco.2020.118816.
- Kopecký, M., Macek, M., and Wild, J., 2021. Topographic Wetness Index calculation guidelines based on measured soil moisture and plant species composition, *Science of the Total Environment*, 757: 143785, DOI: 10.1016/j.scitotenv.2020.143785.
- Maciel, E.A., Oliveira-Filho, A.T., Sobral-Souza, T.S., Marimon, B.S., Cupertino-Eisenlohr, M.A., José-Silva, L., and Eisenlohr, P.V., 2021. Climate change forecasts suggest that the conservation area network in the Cerrado-Amazon transition zone needs to be expanded, *Acta Oecologica*, 112: 103764, DOI: 10.1016/j.actao.2021.103764.
- Manel, S., Williams, H.C., and Ormerod, S.J., 2001. Evaluating presence-absence models in ecology: The need to account for prevalence, *Journal of Applied Ecology*, 38(5): 921-931, DOI: 10.1046/j.1365-2664.2001.00647.x.
- Pecchi, M., Marchi, M., Burton, V., Giannetti, F., Moriondo, M., Bernetti, I., Bindi, M., and Chirici, G., 2019. Species distribution modelling to support forest management. A literature review, *Ecological Modelling*, 411: 108817, DOI: 10.1016/j.ecolmodel.2019.108817.
- Phillips, S.J., Anderson, R.P., and Schapire, R.E., 2006. Maximum entropy modeling of species geographic distributions, *Ecological Modelling*, 190(3-4): 231-259, DOI: 10.1016/j.ecolmodel.2005.03.026.
- Su, S.Y., Lo, N.J., Chang, W.I., and Huang, K.Y., 2012. Two way extrapolation and validation on ecological patterns of *Elaeocarpus japonicus* between main watersheds in Huisun of central Taiwan, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39: 357-362, Melbourne, Australia, DOI: 10.5194/isprsarchives-XXXIX-B8-357-2012.
- Wang, A., Melton, A.E., Soltis, D.E., and Soltis, P.S., 2022. Potential distributional shifts in North America of allelopathic invasive plant species under climate change models, *Plant Diversity*, 44(1): 11-19, DOI: 10.1016/j.pld.2021.06.010.
- Yousefi, M., Naderloo, R., and Keikhosravi, A., 2022. Freshwater crabs of the Near East: Increased extinction risk from climate change and underrepresented within protected areas, *Global*

Ecology and Conservation, 38: e02266, DOI: 10.1016/j.gecco.2022.e02266.
Zhou, Y., Guan, H., Huang, C., Fan, L., Gharib, S., Batelaan, O., and Simmons, C., 2019. Sea breeze

cooling capacity and its influencing factors in a coastal city, Building and Environment, 166: 106408, DOI: 10.1016/j.buildenv.2019.106408.

附錄

(1) 取樣設計 SD1 之蘇鐵蕨預測分布圖



Exploring the Temporal Transferability in the Species Distribution Model of *Brainea insignis* Using Two Sets of Data Separated by 15 Years

Ching-Jin Kuo¹ Bao-Hua Shao² Nan-Chang Lo³ Kai-Yi Huang^{4*}

Abstract

This study aims to investigate the impact of different algorithms on the temporal transferability of species distribution model (SDM) and the feasibility of using deep learning techniques to build SDM. The study focuses on *Brainea insignis* as the target species and utilizes two sets of samples collected with a 15-year interval. Experiments were conducted using the maximum entropy (MAXENT), random forest (RF), support vector machine (SVM), and U-net—a deep learning approach. The results indicate that MAXENT and SVM exhibit the best temporal transferability, while U-net also shows promising results. This highlights the research potential of deep learning, and future studies should consider incorporating a wider range of deep learning methods and continue experimentation. However, concerning environmental variables, relying solely on topographic factors may constrain the model's transferability, necessitating the identification of ecological factors with more direct causal relationships with the species to enhance transferability.

Keywords: Temporal Transferability, Deep Learning, Species Distribution Model, *Brainea insignis*

¹ Master Student, Department of Forestry, National Chung Hsing University

² Associate Technical Specialist, Pu-Li Workstation, Nantou Branch,
Forestry and Nature Conservation Agency

³ Division Chief, Silviculture Division, Experimental Forest Management Office, National Chung Hsing University

⁴ Professor, Department of Forestry, National Chung Hsing University

* Corresponding Author, E-mail: kyhuang@dragon.nchu.edu.tw

Received Date: Oct. 02, 2023

Revised Date: Oct. 29, 2023

Accepted Date: Nov. 27, 2023

應用四物候日無人機影像空間外推入侵外來種一

小花蔓澤蘭之空間型態

洪浩源¹ 郭慶津¹ 邵寶嬋² 羅南璋³ 黃凱易^{4*}

摘要

本研究以無人機獲取外來入侵種小花蔓澤蘭 (*Mikania micrantha*; bitter vine, BV) 兩試區 A 與 B 的四物候日多光譜影像，續以最大概似法、隨機森林與 U-net 空間外推 BV 的空間型態。建、驗模採兩組取樣策略：(1) 兩試區以各自訓練樣本推測本身所在地、(2) 雙向外推至另一無訓練樣本之試區。結果顯示，第一組三模型之 kappa 值皆高於 0.75。第二組由試區 A 正向外推至 B 較試區 B 反向外推至 A 成效差，乃兩區植被型態及 BV 花況不同而致，尤以 U-net 更能掌握 BV 的空間型態，外推之 kappa 值最高達 0.73。為改善此情況並更完整探討模型之效能及穩定性，後續將結合兩區樣本執行空間外推，期能改善目前外推之結果。

關鍵詞：空間外推、小花蔓澤蘭、物候、無人機

1. 前言

外來入侵物種 (invasive alien species, IAS) 為被人類有心或無意地引入到其非自然分布區域的物種。隨後，透過其之存活立足 (establishment)、擴張 (expansion)、爆發 (explosion) 和鞏固 (consolidation) 階段，加速自然生育地的喪失和破碎化速率 (Labrada, 2003)。其藉由干擾本地植群、動物棲地和土壤性質，進而改變生態系統，對生物多樣性和生態系構成嚴重威脅 (Kaushik *et al.*, 2022)。此外，隨著交通工具之革新，物種在世界各地的移動機會遽增，此一個過程增加了 IAS 擴散速度和距離，無疑是全球化的另一體現。其對環境大多數是負面的且難以挽回的影響，導致經濟損失、危害人體健康，尤有甚者，是增加野火發生的因子之一 (Brooks *et al.*, 2004、Hulme, 2021)，如何有效地管理已成為全球密切關注的重要議題。更重要的是，面對 IAS 入侵，研究者必須慎重縝密地評估其

是否會產生影響以及影響的程度。

過去傳統的現場地面調查主要局限於小範圍、短時間內進行。然而，IAS 的入侵往往是動態、廣泛且複雜的過程，涵蓋層面是長而廣闊之時空尺度，尤其是當目標物種的分布極不規則零星分散 (Shuman & Ambrose, 2003、Miller, 2004)。尤有甚者，若調查在崇山峻嶺處，不僅需要大量的人力和資源，且極難獲得足夠的樣本供分析追蹤監測之用。近年來，隨著遙測技術的發展和成熟，有效率地獲得大範圍的環境資料，甚至現場地面調查已改變其角色，作為驗證模型的「真值」。因此，必須整合地球空間資訊系統 (geospatial information system, GIS)、全球導航衛星系統 (global navigation satellite system, GNSS) 和遙感探測 (remote sensing, RS)；這 3S 偕同人工智慧 (artificial intelligence, AI)，以達成高度自動化辨識 IAS 的空間型態 (spatial patterns)，方能為相關單位提供實用的管理策略。

然而，過往至今的多數研究使用中解析度衛星

¹ 國立中興大學森林學系 碩士生

² 農業部林業及自然保育署南投分署埔里工作站 技士

³ 國立中興大學農業暨自然資源學院實驗林管理處育林組 組長

⁴ 國立中興大學森林學系 教授

* 通訊作者, E-mail: kyhuang@dragon.nchu.edu.tw

收到日期：民國 112 年 10 月 23 日

修改日期：民國 112 年 11 月 27 日

接受日期：民國 113 年 03 月 06 日

或空載系統於 IAS，不但因系統缺乏自主與機動性且因雲層霧氣遮蔽等天候因素而無法充分掌握植物稍縱即逝的物候。再者，解析度也不足以精細描繪 IAS 之特徵，因而力有未逮 (Asadzadeh *et al.*, 2022)。近年隨無人機 (drone or unmanned aerial vehicle, UAV) 發展方興未艾下，技術臻於成熟，不僅入門門檻與成本相對較低，更重要的是其具有高度自主與機動性，充分掌握植物稍縱即逝的物候。此外，UAV 貼近地面的飛行能避免雲層遮蔽影像之干擾，彌補上述兩系統所遭遇之缺失，賦予研究者無與倫比之時間、空間解析度 (鍾智昕等，2016、江秉鴻，2022、Tay *et al.*, 2018)，使得 UAV 於生態調查逐漸成為強大的「利器」。

空間外推 (spatial extrapolation) 能找尋物種未曾發現且分散隔離於四處的新族群，在生態領域具極重要的意義，自上世紀下半一直是該領域之重要課題 (羅南璋等，2011)。然而空間外推極具挑戰性，當外推至無實地調查處將因空間異質性的增加而可能使模型失去辨識物種的能力。準此，本研究以無人機獲取多光譜、多期影像，擬探討的目標為 (1) 瞭解辨識 IAS 最關鍵的物候特徵。(2) 繪製研究區域內 IAS 之空間型態。(3) 嘗試從有訓練資料的區域空間外推到沒有訓練資料的區域。

2. 材料與方法

2.1 目標物種

名列世界百大入侵種的小花蔓澤蘭 (*Mikania micrantha*; bitter vine, BV) 原產於中南美洲，臺灣最早於 1986 年於屏東萬巒即有標本採集記錄，已入侵臺灣三十餘年 (蔣慕琰等，2002)。此物種於臺灣地區常出現於低海拔地區，尤其在近山區的荒廢果園、檳榔園、道路旁等 (黃士元等，2003)，只要陽光與水分充足，皆能發現其蹤跡。由於它生長快速且具攀附纏勒植物的特性，使遭攀附者因無法行光合作用而衰弱致死，進而危害農業經濟之發展，造成生態上與經濟上的危害。根據郭耀綸等 (2002)、曾怡穎 (2011)、許謹柔 (2022) 的物候調查，此物種於五月至十月中旬皆長滿綠葉，並無其他明顯之

物候變化；十月中旬始有少數著花，此後約一個月是盛花期，植株被大量白花覆蓋；12 月下旬開始大量枯萎，植株呈乾枯狀，但並未死亡，翌年二月即又恢復生長，乾枯植株與綠葉同時出現 (圖 1)。其物候受緯度、氣候差異、採集地點不同而略有差異。

2.2 研究區域

本研究之試驗區域 (以下簡稱試區) 有二 (圖 2)。試區 A 位於南投縣竹山鎮福興里，TWD97 TM2 座標約為東距 215,956.696 m、北距 2,622,180.642 m，屬於低海拔山坡地的一處廢棄茶園，面積為 1.2 ha，海拔介於 220–224 m 之間，最大坡度低於 20°，由於屬西向坡，故日照相當充足。試區中之木本植物多為白匏子，然草本植物佔大部分，以大花咸豐草為主。試區 A 北側及東南隅為茶園，東側是竹林，西南角是作為庭園造景的真柏。

試區 B 位於試區 A 東南方約 5.1 km 處，隸屬南投縣竹山鎮瑞竹里，TWD97 TM2 座標約為東距 217,136.592 m、北距 2,617,016.480 m。海拔高度在 520–584 m 之間，坡度多在介於 30–40°，最大則達 69°，面積約為 0.76 ha 是坡向為西北的陡峭邊坡。由於試區 B 人力能及處僅佔小部份，故更需倚重使用 UAV 以探測小花蔓澤蘭的蹤跡。試區 B 以闊葉樹為大宗，草本植物以大花咸豐草為主，同時有姑婆芋、蕨類，東側及南側為林道。

2.3 資料收集

鑒於遙測已成為資料收集之主要來源，地面調查雖然僅佔小部份，卻扮演著驗證模型的重要角色，本研究以無人機為主要資料收集來源，並於地面調查以高精度儀器量測位置情資 (location intelligence, LI)，緊密連結數位「虛擬」與「實體」地球。

2.3.1 空中-無人機影像

研究使用的 UAV 機型為大疆 P4 Multispectral (P4M)，為四旋翼機型，其配有一體式多光譜成像系統，包括一個 RGB 相機、五個多光譜感測器，分別感測藍 (blue, B)、綠 (green, G)、紅 (red, R)、紅邊 (red-edge, RE)、近紅外 (near-

infrared, NIR) 波段，該成像系統安裝在三軸雲台上，成像清晰穩定。P4M 頂部整合多光譜光強感測器，可捕捉太陽輻照度並記錄在影像檔案中，進行資料處理時，太陽輻照度數據可針對影像進行光照補償，排除環境的光照對資料收集的干擾。此外，其亦配備即時動態定位 (real time kinematic, RTK) 技術，拍攝時採用內政部國土測繪中心提供的 e-GNSS 即時動態定位系統，透過無線網路連線產生虛擬參考站 (virtual reference station, VRS)，以 RTK VRS 進行定位。

本研究於 2021 年的 1 月 26 日 (試區 B)、1 月

27 日 (試區 A)、4 月 6 日、8 月 23 日與 11 月 13 日之近正午時分執行飛行任務，當天天氣皆晴朗少雲微風 (十分鐘平均風速皆小於 2.1 m/s)。由於周遭竹林生長快速，四次航線及飛行高度有略作調整。首次飛行航高設為 20 m，後續拍攝逐次提升高度至 30 m；航向與側向重疊率則分別保持 80%和 70 %，最後裁切出四期影像都完整包含且無變形之區域，並將所有影像重取樣為相同網格 (像元) 大小 2.28 cm 以進行後續分析。P4M 技術參數及其一體式成像系統之規格整理於表 1 與表 2。



圖 1 小花蔓澤蘭生命期之物候特徵

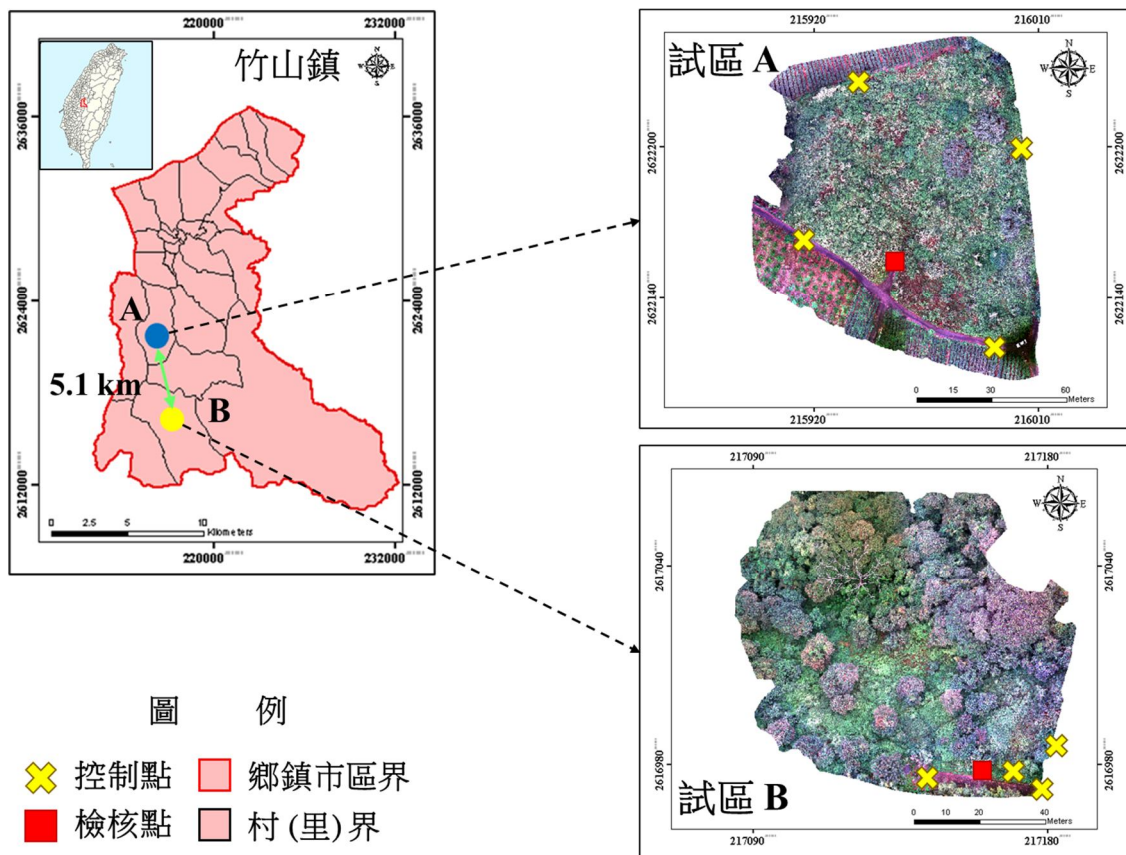


圖 2 兩研究區域及控制點分布位置圖

表 1 P4M 技術參數表

技術參數	規格
起飛重量	1,487 g
對角線軸距 (不含槳)	350 mm
續航時間	約 27 分鐘
懸停精度	啟用 RTK 且 RTK 正常工作時： 垂直： ± 0.1 m；水平： ± 0.1 m 未啟用 RTK： 垂直： ± 0.1 m (視覺定位正常工作時)； ± 0.5 m (GNSS 定位正常工作時) 水平： ± 0.3 m (視覺定位正常工作時)； ± 1.5 m (GNSS 定位正常工作時)
電池電量	15.2 V、5,870 mAh
地面取樣距離	(H/18.9) cm/pixel，H 為飛行器相對於製圖區域的飛行高度 (單位：m)

表 2 P4M 一體式多光譜成像系統技術參數表

技術參數	規格
感測波段	藍 (B； 450 ± 16 nm) 綠 (G； 560 ± 16 nm) 紅 (R； 650 ± 16 nm) 紅邊 (RE； 730 ± 16 nm) 近紅外 (NIR； 840 ± 26 nm)
FOV	62.7°
焦距	5.74 mm
光圈	f/2.2
彩色感測器 ISO 範圍	200-800
電子全域快門	1/100 - 1/20000 s (可見光)； 1/100 - 1/10000 s (多光譜)
解析度	1600×1300 (4：3.25)

2.3.2 地面-現場調查

為了進一步提升影像的位置精度，飛行前於在兩試區設置地面控制點 (ground control points, GCP) 與檢核點 (check points)，並以高精度 Trimble R12 衛星定位儀測定每一控制 (檢核) 點的座標。控制點以 50×61 cm 的黑色瓦楞紙製成，包括代表其編號之 6×6 cm 白色正方形及 6×15 cm 白色長方形，其中朝上者皆為指向北方。兩試區各設置 4 個控制點及 1 個檢核點。其中試區 B 因只

有林道可以布設控制點與檢核點，其餘地方是極難以徒步到達的陡峭邊坡，且森林鬱閉度高將使控制點及檢核點被樹冠遮蔽，故在該區的控制點擺設上盡量分散於林道。縱有 UAV 能輕便獲取大空間的影像資料，仍需進行少部分的地面現場調查以評估模型推估的可靠性，惟人力及時間考量，本研究以前述儀器進行小範圍地面調查，在兩試區內各抽一塊 BV 群落繞行周遭一圈產生多邊形，在於 ArcMap 10.3 軟體之 Sampling Design Tool 於多邊形內隨機抽點，於試區 A 與 B 分別獲得 416 個點位及 355 個點位，供後續驗模使用，緊密連接「空中」與「地面」資料，並匯入電腦化 GIS 軟體進行後續分析。




圖 3 控制點示意圖

2.4 資料前處理

UAV 拍攝的原始影像需經過正射糾正消除影像傾斜、扭曲、投影位移等畸變後方能正確呈現地覆之物理空間，且為避免多期影像有過多偏移，故再進行幾何套合處理 (楊承諭, 2018)。研究使用瑞士洛桑聯邦理工大學開發的 Pix4Dmapper 軟體將兩試區的原始影像各自拼接、糾正，分別生成兩試區之數位正射影像 (orthoimages)，並以 TWD97 TM2 座標系統為基準，於過程中匯入 GCP 矯正誤差，再以檢核點評估影像之精度 (表 3)。試區 A 四個 GCP 之東距 (X 方向) 與北距 (Y 方向) 的平均均方根誤差 (root mean square error, RMSE) 分別為 1.1 cm 與 1.0 cm，檢核點於東距和北距為 0.4 cm 與 0.7 cm。試區 B 東距和北距之 RMSE 分別為 1.6 cm 與 1.3 cm，檢核點於東距和北距則為 0.8 cm 及 0.4 cm，顯示此兩影像的位置精度相當可靠。

表 3 影像位移精度資訊表

	試區 A		試區 B	
	東距	北距	東距	北距
像元大小 (cm)	2.28			
地面控制點均方根誤差 (cm)	1.1	1.0	1.6	1.3
檢核點均方根誤差 (cm)	0.4	0.7	0.8	0.4

Jensen (2016) 指出多期遙測影像會因感測系統本身元件產生的內部 (internal) 效應，或時空差異下而造成的外部 (external) 效應如太陽高度角 (elevation)、太陽方位角 (azimuth)、觀視角、大氣效應、季節性因子、土壤溼度等變因，使感測儀所接收到的反射值無法正確呈現地覆的變化，造成後續萃取目標物種的精度下降。輻射糾正 (radiometric correction) 是將此差異消除的方法，包含絕對輻射糾正 (absolute radiometric correction) 與相對輻射糾正 (relative radiometric correction)。前者執行上相當困難且耗費甚鉅，故本研究未採用；後者則是以其中一幅影像為基準，同態化其它各期影像至與基準的輻射條件幾乎相同的過程 (潘麗慧, 2004)。再者，UAV 以低空飛行拍攝影像，使其感測到的反射值與地面實測值的差異可以忽略不計，但仍會受到儀器本身的內部效應與光照條件之影響 (Burkart *et al.*, 2014)。準此，本研究以四月影像作為參考影像，並嘗試以直方圖匹配法 (histogram matching, HM) 同態化四期影像，使像元亮度值的變化與地表真實狀況之變化有關，以利影像辨識 (潘麗慧, 2004)。

2.5 光譜類別間之距離

Jeffries-Matusita Distance (JMD) 或 JM 距離是遙測領域常使用計算類別之間可分離性的指標。該指數越接近 2，光譜類別之間的可分離性越大，分類結果越可靠，是特徵選擇的重要參考之一。其公式如下：

$$JMD (S_1, S_2) = \sqrt{\sum_{i=1}^L [\sqrt{p_i} - \sqrt{q_i}]^2} \dots\dots\dots (1)$$

其中 S_1 與 S_2 為兩個類別之光譜向量， L 是波段總數， p_i 與 q_i 則為在 l 波段中光譜向量 S_1 與 S_2 之機率密度 (Padma & Sanjeevi, 2014)。

本研究參考 Tian *et al.* (2020) 之研究，使用 ENVI 5.3 計算各地覆類別與目標物種之 JM 距離，並以此作為特徵選擇之參考。

2.6 取樣策略

因小花蔓澤蘭係一片一片呈現不規則分隔四處散布於大範圍之中卻非隨處可見，若不熟悉現場環境，往往難以找到此目標物所在。本研究位於南投竹山兩試區是由嚮導人員引領到達而看見，因此本實驗設計得牽就其散布特性嘗試從已知樣區建模，從而空間外推到未知區域，以尋找未發現之目標物種。本研究設計以下兩組取樣方法藉以測試空間外推的成效。第一組為兩試區皆有訓練樣本，各自分開執行其所在試區內的常態推測，並抽出獨立於訓練區塊之樣本供檢測之用。第二組為兩試區雙向外推，僅一試區有訓練樣本，外推至另一無訓練樣本的試區，此檢測用的獨立樣本即代表未曾發現的新族群，作為空間外推之驗證。

2.7 地覆分類

本研究依據地面調查確認試區之地覆類別，並將其分為小花蔓澤蘭、非小花蔓澤蘭 (土壤或枯落物、道路、木本植物、草本植物)。研究所用之訓練樣本是透過自正射影像上圈選成多個多邊形，其中每個多邊形內含有多株 BV 之植株，並均勻分散分布。

於機器學習模型最大似分類法 (maximum likelihood classifier, MLC)、隨機森林 (random forest, RF)，輸入每種類別之多邊形以 ArcGIS Map 10.3 之 Sampling Design Tool 隨機抽點作為訓練之用，除草本植物為 3,000 點，其餘每類別皆為 4,000 點。

於深度學習 U-net，需龐大的訓練樣本遠超過上述機器學習法。由於試區 A 標註 (label) 之訓練樣本數量為 31,895 個 GIS 網元 (grid cell)，遠多於試區 B 的 8,163 個 GIS 網元 (每株 BV 包含多個像

元)。常用機器學習所需的樣本數量不需如「深度學習」那麼龐大，因此本研究選擇精度較佳的 RF 推估出試區 B 之高潛勢分布 BV，並經過仔細將高潛勢分布中非小花蔓澤蘭的區域去除掉再併入 U-net 的樣本內用於訓練來轉用合併原有者於 U-net，以增加 U-net 的樣本，標註數量增至 31,895 個 GIS 網元，改善試區 B 樣本過少的問題，圖磚 (tile) 亦增至與試區 A 相同之 222 幅，以克服山區獲取樣本不足之窘境。

2.8 準確度評估

模型準確度評估是為了驗證影像分類之結果及瞭解模型之可靠性。本研究採獨立分割樣本驗證，2/3 的樣本用於訓練，剩餘的 1/3 為測試樣本，訓練與測試樣本是完全相互獨立，此獨立之測試樣本即代表二次現場驗證物種未曾發現的新族群，以評比預測與實際兩相是否吻合一致。

當模型進行驗證時，通常會將使用遙測求導出分類地圖中之各 GIS 網元值與地面參考實際值彙整於混淆矩陣表 (confusion matrix)，本研究以像元為單位，每類別各取 2,000 點製成二元混淆矩陣表評估模型之準確度，此 2,000 點包含 2.3.2 節所述現場地面調查所獲之點位，並將結果分成：真存 (true positive, TP)、真缺 (true negative, TN)、假存 (false positive, FP) 及假缺 (false negative, FN)，其概念如表 4 所示。本研究以 K_{hat} 一致性係數 $kappa$ 統計量與總體精度 (overall accuracy, OA) 作為評估指標，兩者是根據混淆矩陣表所計算，如下所示：

$$Kappa = \frac{N \times (TP + TN) - [(A \times C) + (B \times D)]}{N^2 - [(A \times C) + (B \times D)]} \dots \dots \dots (2)$$

$$OA = \frac{TP + TN}{N} \dots \dots \dots (3)$$

其中 N 為所有像元數， A 代表真實為小花蔓澤蘭像元總和、 B 代表實際為非小花蔓澤蘭像元總和； C 則

代表分類為小花蔓澤蘭像元總和、 D 代表分類為非小花蔓澤蘭像元總和。 $kappa$ 代表模型分類與地面參考實際資料相符合的程度，其範圍通常介於 0—1，值越高則代表分類結果越正確。此指標可以反應出誤差矩陣表對角線上的正確率，並同時考慮分類錯誤時的誤授 (commission) 與漏授 (omission)。OA 代表模型分類正確的比例，值域介於 0—1，不過因未考慮誤授與漏授而通常會有高估之偏頗 (Jensen 2016、邵寶嬋 2020)。

3. 結果討論

3.1 各地覆之光譜反射折線

由於 BV 與草本植物容易混淆，因此研究比較兩種最相似的光譜反應型樣。圖 4 為 BV 和草本植物於四物候日的灰階值折線圖。可以觀察到 BV 和草本植物在一月、四月和八月的光譜反應型樣相似，植生特性最關鍵的波段於紅邊及近紅外光，其能夠藉由此波段分離植生與人工建構物，在兩試區的人工建構物為道路，而由於 11 月 13 日清晨有飄雨，至正午 11:20 無人機拍攝時地面仍微濕，故水分的吸收使得道路的反射降低，其趨勢變化與其他月份不同。即使植生的光譜反應型樣與人造物的光譜反應型樣有很大差異，但植生間特徵之相似性可能會導致後續分類之錯誤。然而，圖 4 中植生的光譜反應型樣表現得並非如此明顯，乃因自然環境的異質性和複雜性而與城市建物或農地的均勻光譜反應型樣不同，又研究區域的多種植物之光譜反應型樣非常紊亂且複雜，這在我國中低海拔之天然混交林相當常見。值得注意的是，僅在 11 月份，BV 的灰階值明顯高於其他類別。因為 BV 於 11 月大量的白花如地毯一般覆蓋其綠葉甚至是其他植物之上。此物候特徵可以有效地從周圍地覆中辨識並萃取出 BV。這也是本研究使用無人機而非衛星和空載系統來感測 BV 的原因。無人機具有高度的自主性和機動性，讓研究者於適當的時間內掌握住有如曇花一現的關鍵物候期。

表 4 混淆矩陣表 (本研究整理)

分類結果	地面參考資料		
	小花蔓澤蘭	非小花蔓澤蘭	列加總
小花蔓澤蘭	TP	FP	$A = TP + FP$
非小花蔓澤蘭	FN	TN	$B = FN + TN$
行加總	$C = TP + FN$	$D = FP + TN$	$N = A + B = C + D$

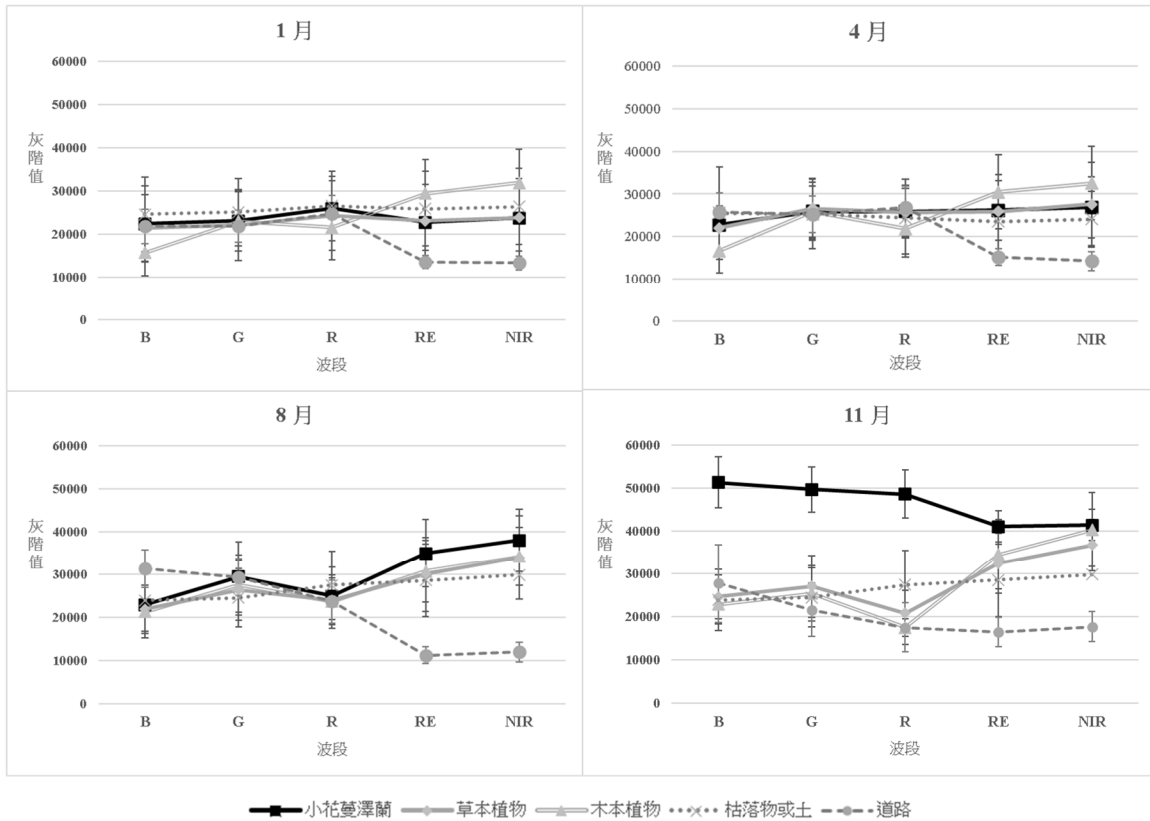


圖 4 各項地覆之光譜折線圖

3.2 光譜類別間之距離

圖 5 為 BV 於四物候日與其他類別之間的 JM 距離。道路和 BV 之間的可分離性始終維持在 1.5 以上，乃因其材質差異甚鉅。1 月和 4 月 BV 與草本植物、木本植物和土壤的 JM 距離均小於 1.0。8 月，BV 與土壤的可分離性明顯增加，而草本植物和木本植物的可分離性仍低於 1.0。當植物於枯萎狀態時，其光譜反應型樣與土壤相似。這是因葉綠素的分解導致紅光波段反射率增加，近紅外波段反射率下降。2021 年初，臺灣適逢乾旱，推估是造成植物萌芽較晚之原因。因此，BV 與草本植物、木本植物和土壤的 JM 距離較小的原因是大多數植物於 4 月仍然處於枯萎狀態。一直到 8 月，臺灣乾旱緩解，植物也萌發綠葉，使 BV 與土壤之間的 JM 距

離顯著增加。11 月，BV 大量綻放白花，JM 距離達到最大。然而，並不是所有的 BV 都開花，推測這就是為何 BV 與草本植物或木本植物之間的 JM 距離不如土壤和道路高的原因。整體而言，本小節再次強調 BV 於 11 月的盛花期是其生命週期中最關鍵的物候特徵，而唯有無人機才能更精準地攫取植物的物候和變化。

3.3 兩組取樣設計之準確度評估

第一組就自身訓練區塊所在試區推測其本身之結果如表 5、圖 6 及圖 7 所示，其中圖 6 及圖 7 為以試區中差異明顯處為例比較。三模型都具不錯的表現， $kappa$ 值皆在 0.75 以上。於試區 A 之分類結果顯示 U-net ($kappa$ 值 0.84、OA 0.92) 及 RF ($kappa$ 值 0.87、OA 0.89) 的表現相當，略優於 MLC

($kappa$ 值 0.82、OA 0.91)。然而在試區 B 之分類結果卻低於試區 A，U-net ($kappa$ 值 0.76、OA 0.88) 略優於 MLC ($kappa$ 值 0.73、OA 0.87) 及 RF ($kappa$ 值 0.74、OA 0.79)。推測可能是試區 B 植被結構較為複雜，導致模型訓練較差，進而使精度較試區 A 為低。由圖 5 中可見 U-net 所預測的 BV，漏授及誤授之狀況較 MLC 與 RF 少，後兩者將周遭其他植物之枯葉也分類為 BV；圖 6 亦有相同狀況，MLC 及 RF 之漏授及誤授狀況較 U-net 多，但三者之結果居伯仲之間。

第二組相互外推結果列於表 6、圖 8 及圖 9 所示，其中圖 8、圖 9 為以試區中差異明顯處為例進行比較。該組旨在模擬另一區為無實地調查樣本時，空間外推的成果，其測試樣本具有代表二次現場驗證過去未曾發現物種之新族群的意義。三模型精度明顯較第一組自身推測者下滑，然於轉用機器學習所推估之 BV 高潛勢分布合併原有者於 U-net 之訓練後，明顯改善其外推效能，其兩指標皆高於 MLC 及 RF，代表能更正確辨識出 BV 之空間型態。整體而言，可以發現由試區 B 外推至 A (反向) 相較於試區 A 外推至 B (正向) 成效來得佳。由於試區 A 小花蔓澤蘭的花況良好，其訓練樣本幾乎為白花，且位於廢棄茶園，植被型態相對單純；試區 B 則花況較遜，部分植株尚未成熟而未著花，訓練樣本摻雜綠葉，且植被型態較為複雜，使得模型在試區 A 正向外推至 B 外推時，致其成效較低。然而在試區 B 反向外推至 A 時，很可能由於試區 A 花況良好而單純，模型由較複雜處 (B) 外推至單純處 (A)，更能掌握此特徵而讓外推效果優於正向外推者。

再者，模型之外推性能比較方面，反向外推者以 U-net ($kappa$ 值 0.73；OA 0.86) 為最佳，RF ($kappa$ 值 0.68；OA 0.84) 居次，MLC 最差 ($kappa$ 值 0.51；OA 0.76)。圖 8 為外推之主題資訊圖，RF 所預測的小花蔓澤蘭於測試樣本紅框內較 U-net 多，然比對圖 8 (d) 之無人機影像，因其周遭植被為其誤授者明顯較 U-net 多，故其兩指標值略低於 U-net。正向外推者亦呈相同狀況，U-net ($kappa$ 值 0.69；OA 0.85) 為最佳，遠優於 RF ($kappa$ 值 0.54；OA 0.77) 及 MLC ($kappa$ 值 0.50；OA 0.75)。由圖 9 之

主題資訊地圖可發現，U-net 所推估之此物種分布於測試樣本紅框內明顯較其他兩模型完整，惟誤授較為嚴重，其犧牲誤授來提高整體之精度，因而兩指標值優於其於兩模型。

然若欲改善此種情況，須結合兩地樣本進行訓練以縮小其空間異質性，並測試不同變數的組合，使研究更加完善。此外，本研究之初步結果顯示僅使用純光譜變數自有訓練資料的區域空間外推到無訓練樣本的另一個區域具挑戰性。由於 IAS 的入侵是物種與環境相互作用的結果，因此必須深入研究 IAS 的驅動因素，並了解其在特定環境中的分布和傳播，才能更準確地掌握其空間模式。而由於降水和溫度等氣候的年度變化，同一物種在其生命週期的同一時期可能表現出不同的物候特徵 (Weisberg *et al.*, 2021)。故於起頭年須利用無人機的高度自主性和機動性，反覆探測並獲取更多期影像，掌握住 BV 的關鍵物候特徵，待分析管理者累積經驗豐富後方能逐年減少拍攝期數。

本研究乃針對兩試驗區域測試空間外推之可行性，旨在做為未來若要大範圍調查時之依據，能根據此一流程或方法來執行空間外推的任務，並將結果供決策端參考擬定處理措施，同時也建議將擴大區域在後續研究執行。而就整體大方向於實地環境之實際應用而言，是綜整這些模型於生態上應用的方法，即生態保育維護生物多樣性，若於 IAS 之上就是生物多樣性淨負影響評估並針對其制定對策；若擴展其應用而言，即為生物多樣性淨正影響評估，並應用在針對瀕危珍稀物種劃設其自然保護區或找出可重新安置於適地適種之他處人工復育區。惟要發揮其實際應用之效益，使用者不但要具備生態保育方面的專業知識，也要具備 3S (RS、GIS、GNSS) 及人工智慧 (AI) 機器學習及深度學習等之數理基礎，將兩方面專業知識結合一起，方能採集生態保育所需相關資料並操作此等演算法建立模型之軟體模組，將所採集資料輸入並運算分析，產生如 BV 或非 BV 的數據成果，並運用在因應對策之制定。此工作流程需要上述的專業知識與技能，方能發揮克竟其功。

表 5 第一組本身各自推測者之分類成效

	試區 A 各自推測		試區 B 各自推測	
	<i>kappa</i>	OA	<i>kappa</i>	OA
MLC	0.82	0.91	0.73	0.87
RF	0.87	0.89	0.74	0.79
U-net	0.84	0.92	0.76	0.88

表 6 第二組雙向推測者之分類成效

	試區 B 外推至試區 A		試區 A 外推至試區 B	
	<i>kappa</i>	OA	<i>kappa</i>	OA
MLC	0.51	0.76	0.50	0.75
RF	0.68	0.84	0.54	0.77
U-net	0.73	0.86	0.69	0.85




圖 5 BV 與各地覆之 JM 距離

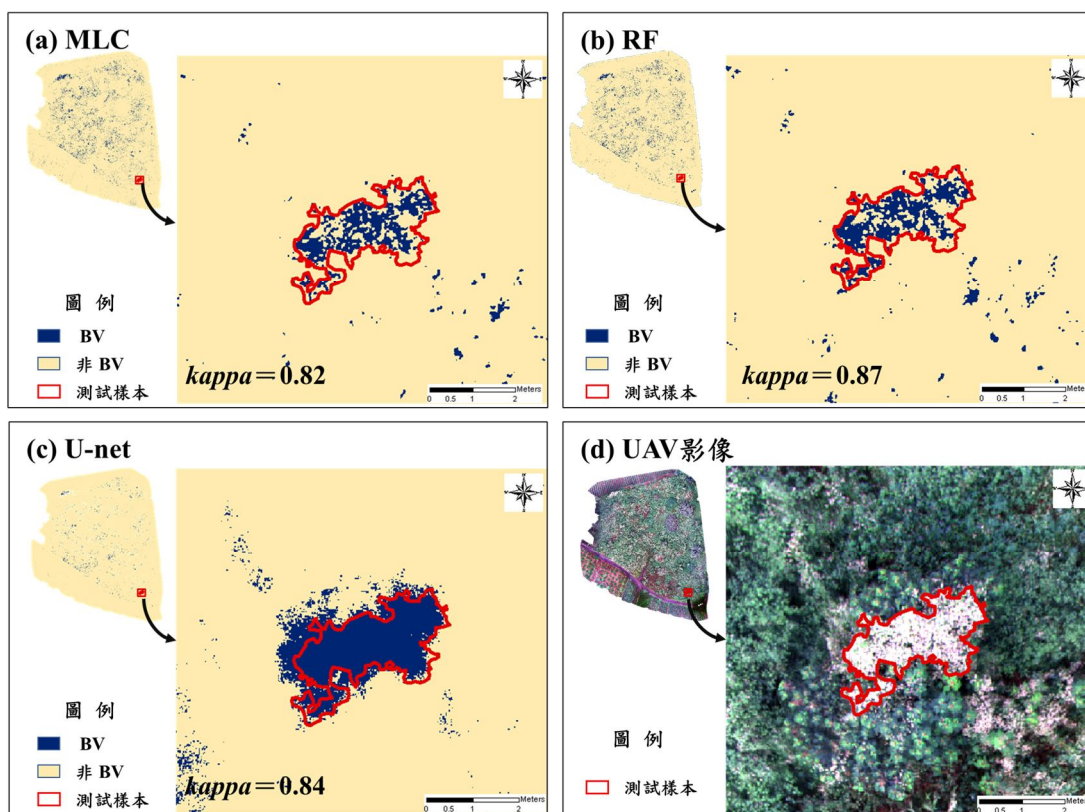


圖 6 第一組試區 A 本身各自推測小花蔓澤蘭之空間型態

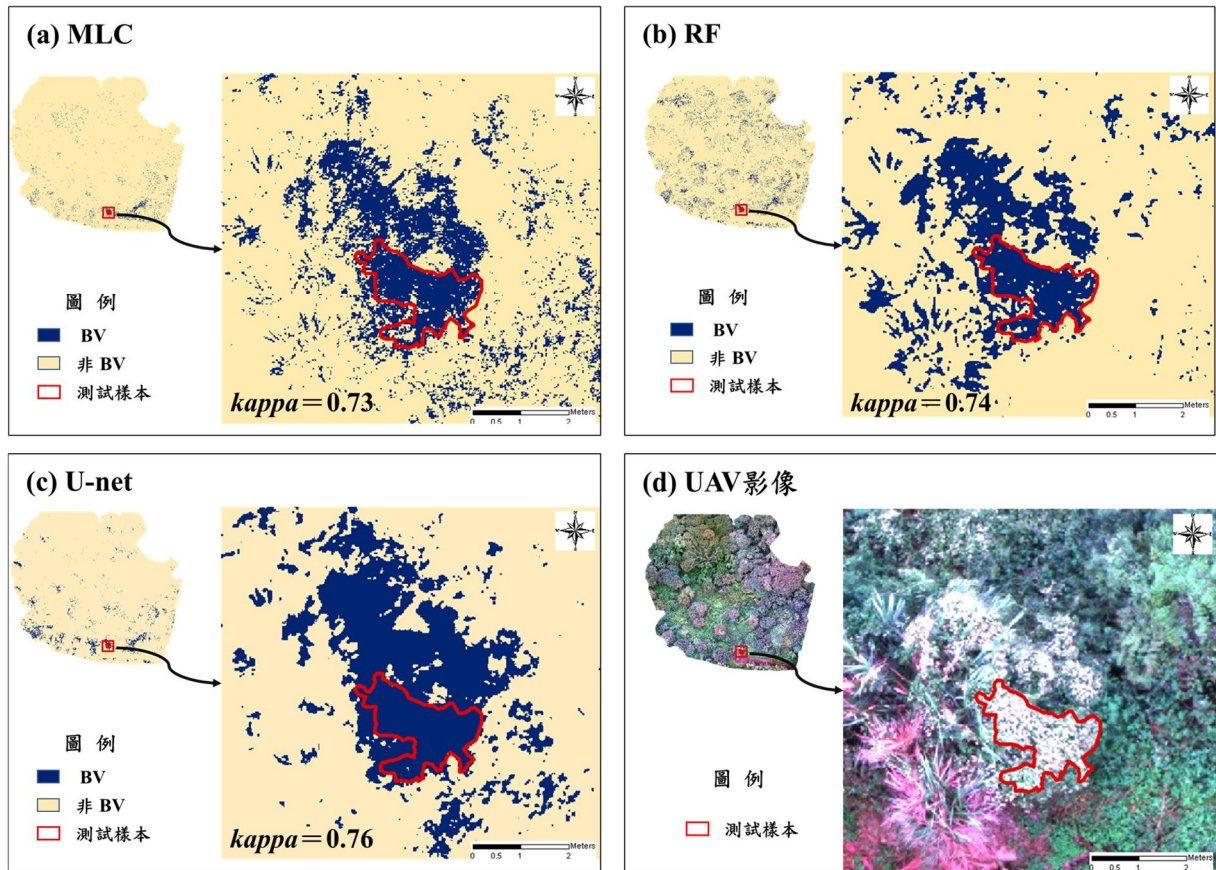


圖 7 第一組試區 B 本身各自推測小花蔓澤蘭之空間型態

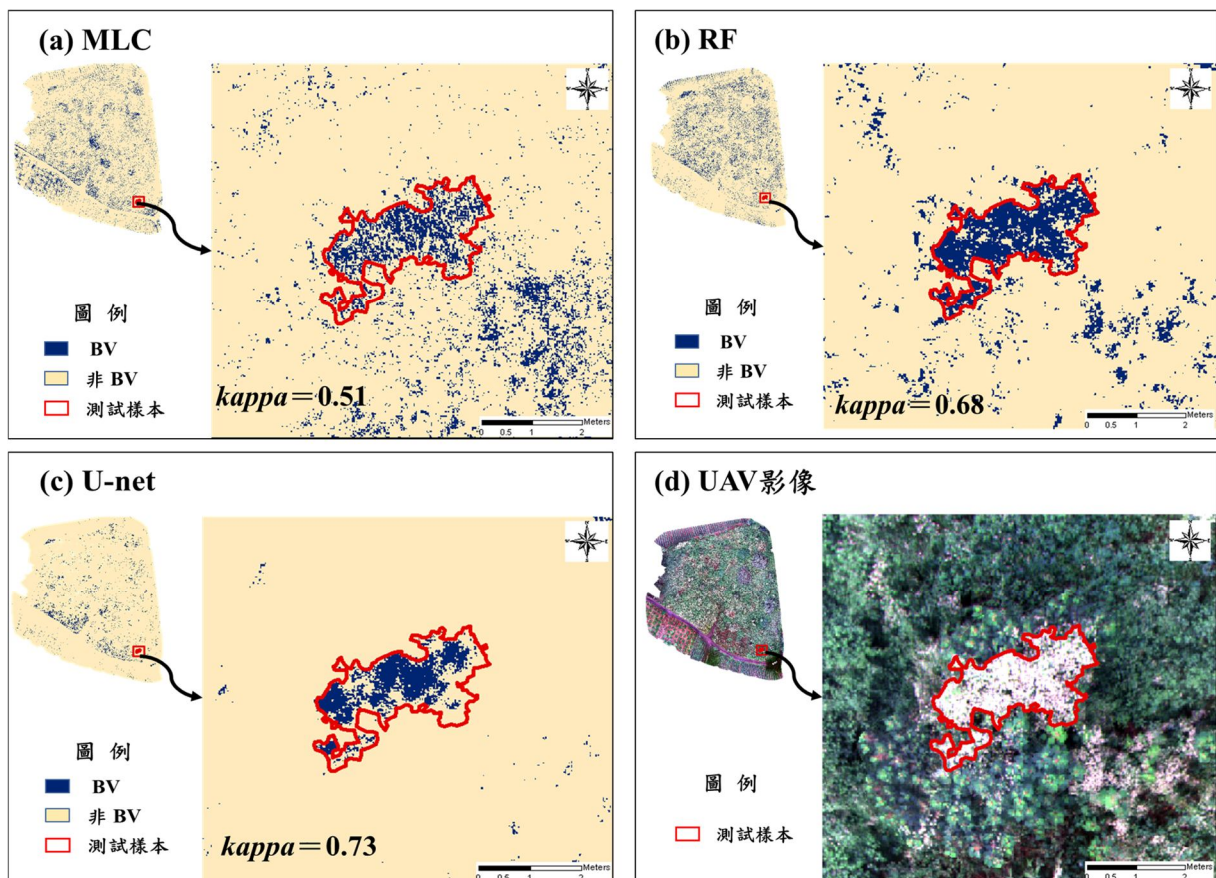


圖 8 第二組由試區 B 反向外推至試區 A 小花蔓澤蘭之空間型態

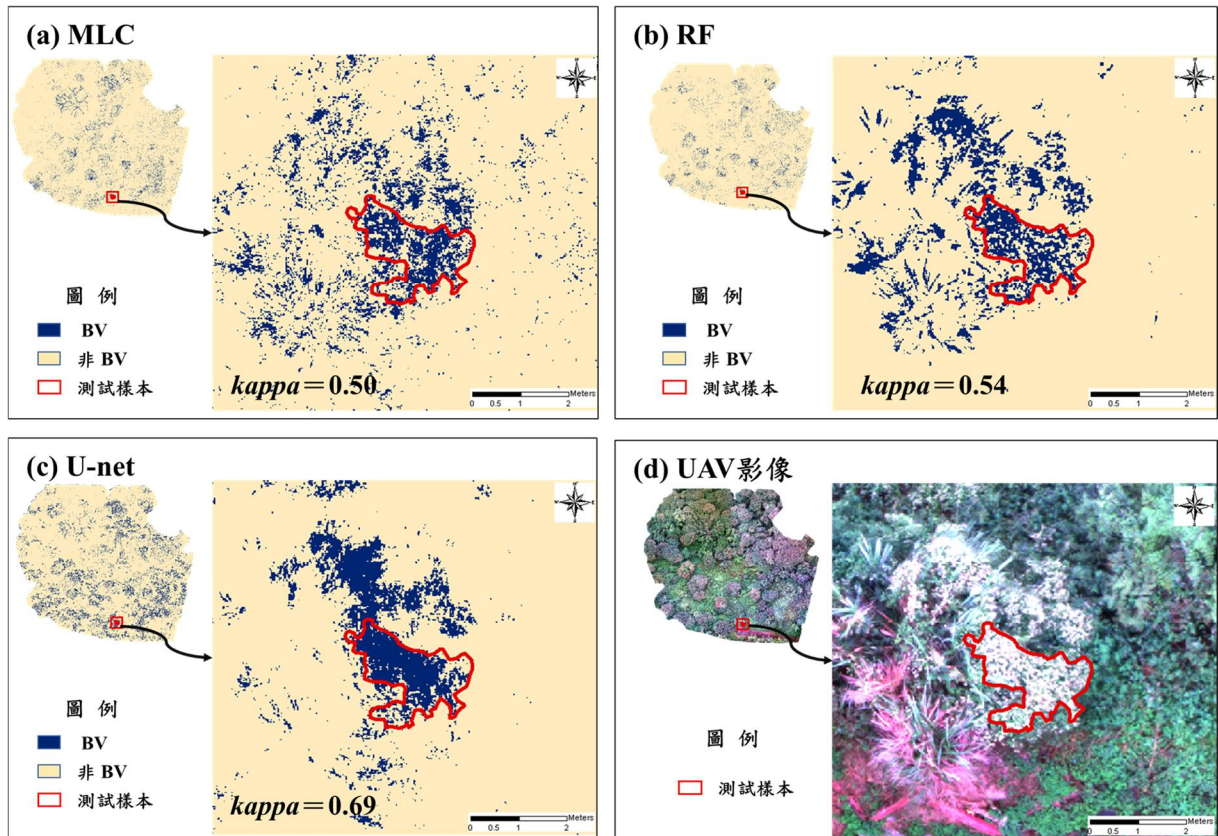


圖 9 第二組由試區 A 正向外推至試區 B 小花蔓澤蘭之空間型態

4. 結論

本研究利用無人機拍攝小花蔓澤蘭之多期、多光譜影像，利用近紅外光波更能將植生與建物分離；再利用開花時獨樹一格之光譜反射型態分離小花蔓澤蘭與其他地物，對於小花蔓澤蘭之分類亦有幫助，這也是多期、多光譜影像的優勢所在。再者，其能飛越險峻環境並充分掌握植物之物候，尤其在層巒疊翠、茂林修竹處更扮演舉足輕重之角色，此高機動與自主性遠非衛星或空載遙測系統所能比擬。此外，利用空間外推技術結合人工智慧可以找出人力難以調查處或未曾發現的物種新族群，相較於傳統目測、人工判釋更加客觀找出人眼甚易忽略的小族群。本研究初步結果顯示，U-net 於外推時之性能較 MLC 及 RF 佳，此代表其找出未曾發現之新族群能力優於兩機器學習法，更具有潛力，唯仍存難以漠視之分類錯誤。

準此，後續研究將聚焦於：(1) 結合兩試區之訓練樣本，並嘗試更多種之深度學習如卷積神經網路

(convolution neural network, CNN) 改善外推效能；(2) 使用重型無人機擴大空間尺度並獲得足夠的樣本及嘗試納入不同環境變數之組合；(3) 以 Trimble R12 搭配雷射測距儀，增加現場實地調查之樣點，同時再驗證 (revalidation) 以確認虛擬數位地球與實體地球兩相一致，冀能優化空間外推 IAS 的成效，找出更多實地調查無法發現之新族群，俾能有效伐除並遏制其蔓延和擴張，不致嚴重危害生態體系。

參考文獻

- 江秉鴻，2022。應用無人空中載具影像調查外來入侵植物小花蔓澤蘭，國立屏東科技大學森林系碩士論文。[Chiang, P.H., 2022. Study on survey technology of invasive species *Mikania micrantha* based on unmanned aerial vehicle (UAV) Images, Master Thesis, National Pingtung University of Science and Technology, Taiwan, ROC. (in Chinese)]
- 邵寶嬋，2020。地形屏障效應對不同海拔之樹種物

- 種分布模擬預測之影響，國立中興大學森林學系碩士論文。[Shao, B.H., 2020. The impact of the terrain-shelterbelt effects on species distribution modeling for tree species at various altitude, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 郭耀綸、陳志遠、林傑昌，2002。藉連續切蔓法及相剋作用防治外來入侵的小花蔓澤蘭，臺灣林業科學，17(2)：171-181，DOI：10.7075/TJFS.200206.0171。[Kuo, Y.L., Chen, T.Y., and Lin, C.C., 2002. Using a consecutive-cutting method and allelopathy to control the invasive vine, *Mikania micrantha* H.B.K., Taiwan Journal of Forest Science, 17(2): 171-181, DOI: 10.7075/TJFS.200206.0171. (in Chinese)]
- 許謹柔，2022。數位地球技術憑藉位置情資形塑地理視覺透視外來入侵種之空間型樣，國立中興大學森林學系碩士論文。[Hsu, C.R., 2022. Digital Earth technology uses location intelligence to shape geovisualization for scrutinizing the spatial pattern of invasive alien species, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 黃士元、彭仁傑、郭曜豪，2003。小花蔓澤蘭在台灣之蔓延及監測，小花蔓澤蘭危害與管理研討會專刊，花蓮，臺灣，pp.123-145。[Hwang, S.Y., Peng, J.J., and Kuo, Y.H., 2003. The spread and monitoring program for *Mikania micrantha* in Taiwan, Conference “The Harmful Effect and Field Management of *Mikania micrantha*”, Hualien, Taiwan, pp.123-145. (in Chinese)]
- 曾怡穎，2011。小花蔓澤蘭與香澤蘭反射光譜季節動態，國立屏東科技大學森林系碩士論文。[Tseng, Y.Y., 2011. Seasonal dynamic change in spectrum of *Mikania micrantha* and *Chromolaena odorata*, Master Thesis, National Pingtung University of Science and Technology, Taiwan, ROC. (in Chinese)]
- 楊承諭，2018。高美濕地雲林莞草生長範圍的影像監測及外移現象的研究，國立交通大學土木工程學系學位論文。[Yang, C.Y., 2018. Image monitoring for the growth area of *Bolboschoenus planiculmis* and investigating into its offshore migration at the Gaomei Wetland, Master Thesis, National Chiao Tung University, Taiwan, ROC. (in Chinese)]
- 潘麗慧，2004。相對輻射糾正法應用於 SPOT 衛星影像變遷偵測影響之評估－以台中縣烏石坑地區為例。國立中興大學森林學系碩士論文。[Pan, L.H., 2004. Evaluation of the effect of relative radiometric normalization on multi-date SPOT image change detection, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 蔣慕琰、徐玲明、陳富永，2002。入侵植物小花蔓澤蘭之確認，植物保護學會會刊，44：61-65。[Chiang, M.Y., Hsu, L.M., and Chen, F.Y., 2002. Confirmation on the presence of *Mikania micrantha* Kunth in Taiwan, Plant Protection Bulletin, 44: 61-65. (in Chinese)]
- 鍾智昕、邱志明、謝漢欽、陸聲山、王豫煌，2016。無人空拍機在林業上的應用，林業研究專訊，23(6)：74-78。[Chung, C.H., Chiu, C.M., Hsieh, H.C., Lu, S.S., and Wang, Y.H., 2016. Application of unmanned aerial vehicle in forestry, Forestry Research Newsletter, 23(6): 74-78. (in Chinese)]
- 羅南璋、王文巧、張偉顛、黃凱易，2011。空間尺度及資料解析度：空間外推物種生態樣式之兩難以香桂與蘇鐵蕨為例，林業研究季刊，33(2)：41-60，DOI：10.29898/SHBQ.201106.0005。[Lo, N.C., Wang, W.C., Chang, W.I., and Huang, K.Y., 2011. Spatial scale and data resolution: The dilemma of spatially extrapolating ecological pattern of species - A case study of *Cinnamomum subavenium* and *Brainea insignis*, 33(2): 41-60, DOI: 10.29898/SHBQ.201106.0005. (in Chinese)]
- Asadzadeh, S., de Oliveira, W.J., and de Souza Filho, C.R., 2022. UAV-based remote sensing for the

- petroleum industry and environmental monitoring: State-of-the-art and perspectives, *Journal of Petroleum Science and Engineering*, 208: 109633, DOI: 10.1016/j.petrol.2021.109633.
- Brooks, M.L., D'Antonio, C.M., Richardson, D.M., Grace, J.B., Keeley, J.E., DiTomaso, J.M., Hobbs, R.J., Pellant, M., and Pyke, D., 2004. Effects of invasive alien plants on fire regimes, *BioScience*, 54(7): 677-688, DOI: 10.1641/0006-3568(2004)054[0677:EOIAP0]2.0.CO;2.
- Burkart, A., Cogliati, S., Schickling, A., and Rascher, U., 2014. A novel UAV-based ultra-light weight spectrometer for field spectroscopy, *IEEE Sensors Journal*, 14(1): 62-67, DOI: 10.1109/JSEN.2013.2279720.
- Hulme, P.E., 2021. Unwelcome exchange: International trade as a direct and indirect driver of biological invasions worldwide, *One Earth*, 4(5): 666-679, DOI: 10.1016/j.oneear.2021.04.015.
- Jensen, J.R., 2016. *Introductory Digital Image Processing, A Remote Sensing Perspective*, 4th edition, Pearson Education Ltd., Essex, pp.314-325.
- Kaushik, P., Pati, P.K., Khan, M.L., and Khare, P.K., 2022. Plant functional traits best explain invasive species' performance within a dynamic ecosystem - A review, *Trees, Forests and People*, 8: 100260, DOI: 10.1016/j.tfp.2022.100260.
- Labrada, R., 2003. *Weed Management for Developing Countries*, Addendum 1, Rome: Food and Agriculture Organization of the United Nations (FAO).
- Miller, J.R., Turner, M.G., Smithwick, E.A.H., Dent, C.L., and Stanley, E.H., 2004. Spatial extrapolation: The science of predicting ecological patterns and processes, *BioScience*, 54(4): 310-320, DOI: 10.1641/0006-3568(2004)054[0310:SETSOP]2.0.CO;2.
- Padma, S., and Sanjeevi, S., 2014. Jeffries Matusita based mixed-measure for improved spectral matching in hyperspectral image analysis, *International Journal of Applied Earth Observation and Geoinformation*, 32: 138-151, DOI: 10.1016/j.jag.2014.04.001.
- Shuman, C.S., and Ambrose, R.F., 2003. A comparison of remote sensing and ground-based methods for monitoring wetland restoration success, *Restoration Ecology*, 11(3): 325-333, DOI: 10.1046/j.1526-100X.2003.00182.x.
- Tay, J.Y.L., Erfmeier, A., and Kalwij, J.M., 2018. Reaching new heights: Can drones replace current methods to study plant population dynamics?, *Plant Ecology*, 219: 1139-1150, DOI: 10.1007/s11258-018-0865-8.
- Tian, J., Wang, L., Yin, D., Li, X., Diao, C., Gong, H., Shi, C., Menenti, M., Ge, Y., Nie, S., Ou, Y., Song, X., and Liu, X., 2020. Development of spectral-phenological features for deep learning to understand *Spartina alterniflora* invasion, *Remote Sensing of Environment*, 242: 111745, DOI: 10.1016/j.rse.2020.111745.
- Weisberg, P.J., Dilts, T.E., Greenberg, J.A., Johnson, K.N., Pai, H.C., Sladek, C., Kratt, C., Tyler, S.W., and Ready, A., 2021. Phenology-based classification of invasive annual grasses to the species level, *Remote Sensing of Environment*, 263: 112568, DOI: 10.1016/j.rse.2021.112568.

Extrapolating the Spatial Patterns of Invasive Alien Species—*Mikania micrantha* Based on Four Phenological-Date Drone Images

Hao-Yuan Hung¹ Chin-Jin Kuo¹ Bao-Hua Shao² Nan-Chang Lo³
Kai-Yi Huang^{4*}

Abstract

This study utilized unmanned aerial vehicle to obtain multispectral imagery of *Mikania micrantha* (bitter vine, BV) in two study areas, Plot A and Plot B. Employing maximum likelihood classification, random forest, and U-net, the study aimed to assess the model's performance in spatial extrapolation of spatial patterns of BV, with the goal of discovering new populations of previously unidentified species. Two sampling designs were employed for model training and testing, Set 1, conducting individual plot classification using training data from it's owned; Set 2, performing spatial extrapolation from one plot with training data to another without training data, whose validation data there represent previously unidentified new populations. The results indicate that the three models performed well in Set 1. The *kappa* values for all models exceeded 0.75. However, the performance in plot B was slightly lower compared to plot A, possibly due to the more complex vegetation patterns in plot B. In Set 2, extrapolation from plot A to B showed fewer effective results compared to extrapolation from plot B to A. This discrepancy can be attributed to the differences in vegetation patterns and the flowering conditions of BV between the two areas. In terms of model performance, U-net demonstrated a better ability to capture the spatial patterns of BV, achieving the highest *kappa* value of up to 0.73 among the three models in Set 2. To comprehensively examine the model's performance in spatial extrapolation, future work will involve combining training data from both plots for extrapolation, and testing with other deep learning models such as convolution neural network (CNN) and environmental variables.

Keywords: Spatial Extrapolation, *Mikania micrantha*, Phenology, Unmanned Aerial Vehicle

¹ Master Student, Department of Forestry, National Chung Hsing University

² Associate Technical Specialist, Pu-Li Workstation, Nantou Branch,
Forestry and Nature Conservation Agency, Ministry of Agriculture

³ Division Chief, Silviculture Division, Experimental Forest Management Office, National Chung Hsing University

⁴ Professor, Department of Forestry, National Chung Hsing University

* Corresponding Author, E-mail: kyhuang@dragon.nchu.edu.tw

Received Date: Oct. 23, 2023

Revised Date: Nov. 27, 2023

Accepted Date: Mar. 06, 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，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^{1,2,...}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. 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 ^{1, 2, ...}.
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.

Volume 29 No. 1
March 2024

Journal of Photogrammetry and Remote Sensing

CONTENTS

Regular Papers

- Establishing Sun-glint Estimation Model for Unnamed Aerial System Image through Photogrammetry
(Chi-Jui Li, Sendo Wang)..... 1
- Applying Deep Learning and Street View Imagery to Create a Spatial Agglomeration Index for Urban Street Signboards
(Zhang-Xiu Luo, Bo-Cheng Lin) 17
- Exploring the Temporal Transferability in the Species Distribution Model of *Brainea insignis* Using Two Sets of Data Separated by 15 Years
(Ching-Jin Kuo, Bao-Hua Shao, Nan-Chang Lo, Kai-Yi Huang)..... 35
- Extrapolating the Spatial Patterns of Invasive Alien Species—*Mikania micrantha* Based on Four Phenological-Date Drone Images
(Hao-Yuan Hung, Chin-Jin Kuo, Bao-Hua Shao, Nan-Chang Lo, Kai-Yi Huang)..... 51

航測及遙測學刊

目錄

學術論著

- 以攝影測量方式建立無人機影像曝光模式之研究氣候變遷下美洲含羞草的空間防治優先性
(李祈叡、王聖鐸) 1
- 結合深度學習與街景影像建構街道廣告招牌之空間聚集指標
(羅章秀、林柏丞) 17
- 藉由相隔 15 年的兩組數據探索蘇鐵蕨物種分布模型之時間可轉移能力
(郭慶津、邵寶燁、羅南璋、黃凱易) 35
- 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
(洪浩源、郭慶津、邵寶燁、羅南璋、黃凱易) 51