

以卷積神經網路從 Sentinel-2 資料測繪 外來種植物之入侵分佈

Mapping distribution of invasive alien plant species from Sentinel-2 data using convolutional neural networks

呂明倫

Ming-Lun Lu

農業部生物多樣性研究所 552005 南投縣集集鎮民生東路 1 號

Taiwan Biodiversity Research Institute, Nantou, Taiwan

通訊作者：alan@tbri.gov.tw

Corresponding authors: alan@tbri.gov.tw

摘要

具入侵性的外來種植物擴散能力強，不僅會威脅生物多樣性，也對農業造成巨大的經濟損失，銀合歡 (*Leucaena leucocephala* (Lam.) de Wit) 是世界百大外來入侵物種之一，現已嚴重威脅到臺灣恆春半島的生態系。遙測影像可觀測大範圍的地表資訊，具潛力進行銀合歡入侵分佈的測繪工作，本研究以恆春半島為研究區，整合 Sentinel 2 影像資料與卷積神經網路 (convolutional neural network, CNN)，建立可預測銀合歡覆蓋率的深度學習模型，進而測繪銀合歡的入侵程度並估算分佈面積。研究結果顯示，運用 CNN 所建立的 IPNet 模型在準確度指標上 (R^2 約為 0.78)，比其他經過測試的深度學習模型表現更好。依據覆蓋率高低分為 5 種入侵

程度，推估屬銀合歡入侵嚴重的面積計有 4,442 ha，占全區約 11%。總結而言，本研究所開發的 IPNet 模型是一種低成本、高效率的測繪方法，並且為銀合歡的入侵問題，提供了明確的空間分佈資訊。

關鍵詞：生物多樣性、銀合歡、遙測、恆春半島、深度學習

Abstract

Invasive alien plant species have a strong spreading ability, which not only threatens biodiversity but also causes substantial economic losses in agriculture. *Leucaena leucocephala* (Lam.) de Wit is one of the top 100 alien invasive species in the world, and they have been seriously threatening the ecosystem of the Hengchun Peninsula. Remote sensing imagery can provide a wide range of surface information with a potential for mapping the distribution of *L. leucocephala* invasion. This study focused on the Hengchun Peninsula, integrating Sentinel-2 data with a convolutional neural network (CNN) to develop a deep learning model capable of predicting the cover fraction, mapping the degree of invasion, and estimating the distribution of *L. leucocephala*. The results indicate that the proposed IPNet model using CNN was significantly better than the other tested deep learning models in terms of the accuracy metrics ($R^2 \doteq 0.78$). The invasion was categorized into five degrees based on the cover fractions, with severe invasion estimated to cover an area of 4,442 hectares, accounting for approximately 11% of the entire region. In conclusion, the IPNet model developed in this study is a low-cost with high-efficiency mapping method that provides clear spatial distribution information on *L. leucocephala* invasion.

Key words: biodiversity, *Leucaena leucocephala*, remote sensing, Hengchun Peninsula,

deep learning

收件日期：2024 年 6 月 4 日

Received: June 4, 2024

接受日期：2024 年 12 月 6 日

Accepted: December 6, 2024

緒言

具入侵性的外來種植物 (invasive alien plant species, IAPS) 擴散能力強，所帶來的影響往往是負面的，不僅會威脅生物多樣性，也對農業造成巨大的經濟損失 (Marbuah *et al.* 2014; Diagne *et al.* 2021)。有效地掌握 IAPS 的空間分佈資訊，對於防治作業的成功與否至關重要 (Sofaer *et al.* 2018; Bradley *et al.* 2019)，過去的作法是依賴人工實地調查，然而，這種方式經常受制經費及勞動力的短缺，無法獲取完整的資訊，故有必要尋找另一種高效又準確的替代方案。

遙測影像富含豐富的光譜反射資訊，可觀測大面積及多時段的地貌，遙測產品的種類繁多，如無人機、雷達、光達及光學衛星等影像，其中，光學衛星的普及性高，常見的 Sentinel

2 或 Landsat 等系列衛星，被認為是有效掌握 IAPS 分佈的重要資料之一 (Bradley 2014; Thamaga and Dube 2018; Vaz *et al.* 2018)，此外，這兩種衛星都有提供免費的影像供應平台，可透過網路下載取得。目前機器學習為分析遙測影像資料的主要方法，也是測繪地景要素常用的技術，在眾多的機器學習演算法中，人工神經網路 (artificial neural network, ANN) 仿人腦功能的運作，利用大量的神經元聯結進行演算，組成一個高度複雜且互聯的多層次網路，並以梯度下降法 (gradient descent) 搜索最佳模型，演算過程中，神經元的資訊可透過一個或多個隱藏層，從輸入層向前傳播到輸出層，預測結果再利用反向傳播更新權重，可有效應用於衛星影像的資料分析 (Kanellopoulos and Wilkinson

2010)。

拜人工智能快速發展所賜，ANN 可產生更深的隱藏層，故深度學習應運而生，其中，專司影像處理的卷積神經網路 (convolutional neural network, CNN) 不若 ANN 沒有考慮到影像上的空間特徵，即所有像元都做為獨立向量來處理，CNN 則明確地關注影像的空間脈絡，並透過參數共享概念，自動提取像元的光譜和局部紋理特徵，也克服了 ANN 常見的過度擬合問題，可精確地辨識各種植被、作物及土地利用類型 (Sharma *et al.* 2017; Kussul *et al.* 2017; Kattenborn *et al.* 2021; Rodríguez-Garlito *et al.* 2023)。CNN 可執行的任務，大致可分為分類與迴歸兩種，由於自然界中的植被景緻，大多會呈現出漸層式的變化，尤其是 IAPS 入侵原生棲地後，常導致影像產生混合像元，因此，連續性的覆蓋率資訊更適合描述植被生態議題，此外，就經營管理面而言，量化 IAPS 的覆蓋率，有利於判定不同的入侵程度，以及決定防治的優先性 (Vilà *et al.* 2011; Kattenborn *et al.* 2020; Preston *et*

al. 2023)，由此可知，藉由 CNN 迴歸模型測繪 IAPS 覆蓋率，可為防治作業提供更豐富的參考資訊。

源自於中美洲一帶之銀合歡 (*Leucaena leucocephala* (Lam.) de Wit)，是世界百大外來入侵物種之一，因其入侵性強，又具排他性，儼然威脅到臺灣的生物多樣性，最嚴重的地區為全臺最南端的恆春半島 (Lu *et al.* 2013)，該區四處可見到大片的銀合歡純林或與原生樹種共生的混濁林。近年由農業部林業及自然保育署大力主導，建構跨機關合作平臺，共同針對銀合歡入侵問題進行大規模的防治作業，有鑑於此，建構 CNN 迴歸模型來測繪恆春半島的銀合歡入侵分佈，為本研究的主要目標，目前國內外似乎尚未有相關的研究報告。基於以上目標，本研究的工作項目包含：一、藉由光學衛星影像資料建立可預測銀合歡覆蓋率的 CNN 模型；二、比較不同神經網路架構的模型性能；三、測繪銀合歡的入侵程度並估算分佈面積。




圖 1 研究區位置圖 (背景為 Sentinel 2 的 RGB 影像)。

Fig. 1 Location of the study area (background shows the RGB imagery of Sentinel 2).

材料與方法

一、研究區概述

研究區位於恆春半島，範圍及地理位置如圖 1 所示，地形以低山與丘陵台地為主，最高峰里龍山海拔高度為 1,062 m。據中央氣象局恆春測候站氣象資料可知，本區年溫差不大，1 月最冷，平均氣溫為 20.5°C；7 月最熱，平均氣溫為 28.3°C。年降雨量在 2,000–3,500 mm 之間，分布於 5 至 10 月，11 月起因受東北季風影響，平均降雨量逐漸下降 (100 mm 以下)，至翌年 4 月氣候較為乾燥，因此，本研究區域內 (尤其西半部)，可明顯區分乾、濕兩種季節，屬熱帶季風型氣候。根據呂等 (2008) 的研究，乾季時的銀合歡葉子會大量枯落，留下深褐色的成熟莢果，其所表現出的光譜特徵，有利於與其他優勢植群做區別。

二、研究方法

(一) 蒐集衛星影像及地面資料

Sentinel 2 為歐洲太空總署 (European Space Agency, ESA) 發射之衛星，掃描寬度廣達 290 km，光

譜資訊涵蓋可見光、近紅外、紅邊及短紅外光範圍，共切割成 13 個波段影像，具備 3 種空間解析力，其中第 2、3、4 和 8 等 4 個波段的為 10 m，第 5、6、7、8A、11 和 12 等 6 個波段為 20 m，第 1、9 和 10 等 3 個波段為 60 m。研究區的 Sentinel 2 影像從 browser.dataspace.copernicus.eu 下載，篩選少雲層覆蓋且清晰的影像，選定的影像屬 Level-2A 處理等級的產品，即地表反射率經過大氣校正，拍攝日期為 2020 年 3 月 1 日 (圖 1)。由於 60 m 的波段影像，主要功能為雲霧過濾與大氣相關的應用，故本研究僅用到第 2 到 8、8A、11 和 12 等 10 個波段影像，透過 ESA 專為處理 Sentinel 影像資料所開發的免費軟體：Sentinel Application Platform (eo4society.esa.int/resources/snap)，以最近相鄰法 (nearest neighbor) 進行 10 m 空間解析力的像元重取樣，再將每一像元值進行標準化，重新調整到 0–1 的範圍，有助於降低數據間的歧異性 (Sola and Sevilla 1997)。

使用 5 × 5 像元大小為一區塊，

將 Sentinel 2 影像分割成 50×50 m 的網格圖，另一方面，參考國土利用現況調查成果圖 (maps.nlsc.gov.tw/S09SOA)，以森林、農地、建地與裸地等 4 類主要土地覆蓋型做為分層，隨機抽取 250 個，共計 1,000 個區塊做為樣本，再依各分層劃分 60% 做為訓練集，20% 為模型擬合過程中的驗證集，剩下 20% 用於評估模型性能的測試集。以 Google Earth 影像做為地真參考，選擇趨近 Sentinel 2 影像的拍攝日期，每一樣本進行地面踏勘及人工判釋銀合歡範圍工作，並計算及標註覆蓋率。

(二) 卷積神經網路

CNN 的神經元是按照影像的高度及寬度來排列，並使用一系列的卷積和激活函數從影像中提取特徵 (如線條、邊緣、形狀和紋理等)，本研究從典型的 VGG (Simonyan and Zisserman 2014) 與 Xception 架構 (Chollet 2017) 獲得啟發，發展出的 CNN 架構簡稱為 IPNet (圖 2)，該架構計有 4 個卷積層，前兩層各由 64 個濾波器所組成，後兩層增加到 128 個，濾波器大小均為

3×3 個像元，卷積的運算過程中，每一個卷積層的輸出做為下一個卷積層的輸入，且各層之間都導入批次標準化 (batch normalization)、ReLU 激活函數與 dropout 率 (0.1) 步驟，最後一個卷積層結束後進入一個全域最大池化層，再由最終的全連接層附加 Linear 激活函數進行輸出，輸出層的結果為銀合歡覆蓋率。至於輸入層的資料維度為 4D 張量 (tensor)，包含樣本數、影像行、列及通道，其中，樣本數共有 600 個 (另有 200 個為驗證集)，影像的行與列為 5×5 個像元，通道則為 10 (10 個波段)。運算過程中，所有卷積運行的步幅設為 1，並用 0 填充確保輸出的大小與輸入相同，另由於本架構屬小區塊樣本的學習，故沒有使用池化層來簡化特徵。

IPNet 架構的演算尚需設置多種超參數，包括期數 (epoch)、批次大小 (batch size)、學習率 (learning rate)、優化器 (optimizer)、損失函數 (loss function) 等。本研究經反覆測試，設定期數為 100，批次大小為 32，學習率方面，設定 0.001 為初始




圖 2 本研究提出的卷積神經網路架構。

Fig. 2 Architecture of the proposed convolutional neural network.

值，搭配 Adam 優化器的梯度下降演算，根據驗證集的損失值變化自動調整 (最小設定 $1e-10$)，損失函數使用適用於迴歸任務的均方誤差 (mean squared error)。關於開發 CNN 架構的軟體和硬體環境，利用 R 語言介面的 TensorFlow 和 Keras 套件進行演算與測試，硬體方面仰賴工作站：Intel(R) Xeon(R) Silver 4208 CPU 及圖形處理器：NVIDIA RTX A6000。

(三) 模型性能比較

模型開發完畢後，依據 20% 的測試集 (200 個區塊樣本) 與預測結果進行性能評估，計算平均絕對誤差 (mean absolute error, MAE)、均方根誤差 (root mean square error, RMSE)、

平均絕對百分比誤差 (mean absolute percentage error, MAPE) 與決定係數 (R^2)。除本研究開發的 IPNet 架構外，另建立無卷積運算過程的深度神經網路 (deep neural network, DNN) 和 Sharma *et al.* (2017) 同樣基於衛星影像所開發的深度 CNN (Deep CNN, DCNN) 架構，用於比較不同深度學習模型的性能差異。DNN 是由 4 個隱藏層所構成，第 1 層產生 128 個神經元，第 2 層起神經元數量以兩倍遞減，至第 4 層剩 16 個，每一層輸出後都導入批次標準化、ReLU 激活函數與 dropout 率步驟；DCNN 架構則有 5 個卷積層，濾波器大小為 3×3 個像元，每層的數量從 8 到 128 以兩倍遞增，

外加 1 個由 3,200 個神經元所組成的全連接層，各層都搭配 ReLU 激活函數輸出。這兩種深度學習架構的輸入、輸出層及超參數都比照 IPNet。

結果

IPNet 的訓練過程中，訓練集的初始損失值為 2,296，之後便開始逐漸遞減，至第 40 個 epoch 以後達到收斂的效果，最低損失值為 225。從驗證集來看，初始損失值為 3,646，第 40

個 epoch 以前皆有明顯的波動，但仍呈現下降趨勢，從第 53 個 epoch 開始收斂，損失值均不超過 350，最低為 343(圖 3)。總體來看，兩種資料集的最終表現相當，顯示不存在過度擬合，因此，本研究依據驗證集的最低損失值做為最終預測模型。

表 1 列出 IPNet 與其他兩種深度學習模型的性能，總體而言，本研究建構的 IPNet 模型優於其他兩種模型，在評估誤差方面的指




圖 3 IPNet 架構的損失曲線。

Fig. 3 Loss curves of IPNet architecture.

表 1 比較 3 種深度學習模型之統計準確度指標

Table 1 Comparisons of statistical accuracy metrics among three deep learning models

Metrics	IPNet	DCNN	DNN
Mean absolute error	12.56	14.23	34.97
Root mean square error	16.47	18.41	43.56
Mean absolute percentage error (%)	62.91	75.66	71.87
Coefficient of determination (R^2)	0.78	0.72	0.66

標，MAE(12.56)、RMSE(16.47) 及 MAPE(62.91) 都達最低，評估預測與觀察值相關性的 R^2 則最高 (0.78)。相較於其他兩種模型，DCNN 的表現次之，所有的指標都指出，DNN 的表現相對較不理想，由此顯示，有經過卷積運算的 CNN 架構更勝於 DNN。

運用深度學習預測銀合歡覆蓋率的結果如圖 4，為清楚比較不同演算法間的差異，使用自然間斷法將覆蓋率分為 5 級，做為銀合歡入侵程度的觀察指標，該法是依據分組後的組內最小變異數來決定，可在 ArcGIS 軟體執行。圖中顯示 3 種演算法的預測結果，空間分佈型態相去不遠，入侵程度較高的地區都偏重於西半部，惟 IPNet 與 DCNN 預測的面積明顯大於 DNN，由此顯示，性能相對較低的

DNN 模型，低估了銀合歡的入侵範圍。從面積來看，次高及高入侵度以上屬銀合歡入侵嚴重的地區，IPNet 模型推估有 4,442 ha，占全區約 11%，DCNN 為 3,678 ha (9%)，DNN 僅有 1,968 ha (5%)。

討論

近年來已有大量的深度學習模型被開發出來，透過深層的 CNN 自動萃取空間特徵，不僅減少了人工的操作，並證實提升了辨識 IAPS 的準確度 (Kattenborn *et al.* 2021)，然而，這些研究報告中，很大占比都是藉助無人航空載具 (unmanned aerial vehicle) 的超高影像解析力資料，其雖具辨識物種細部特徵的優勢，但可探測範圍狹小則為一大限制，目前將深度學習

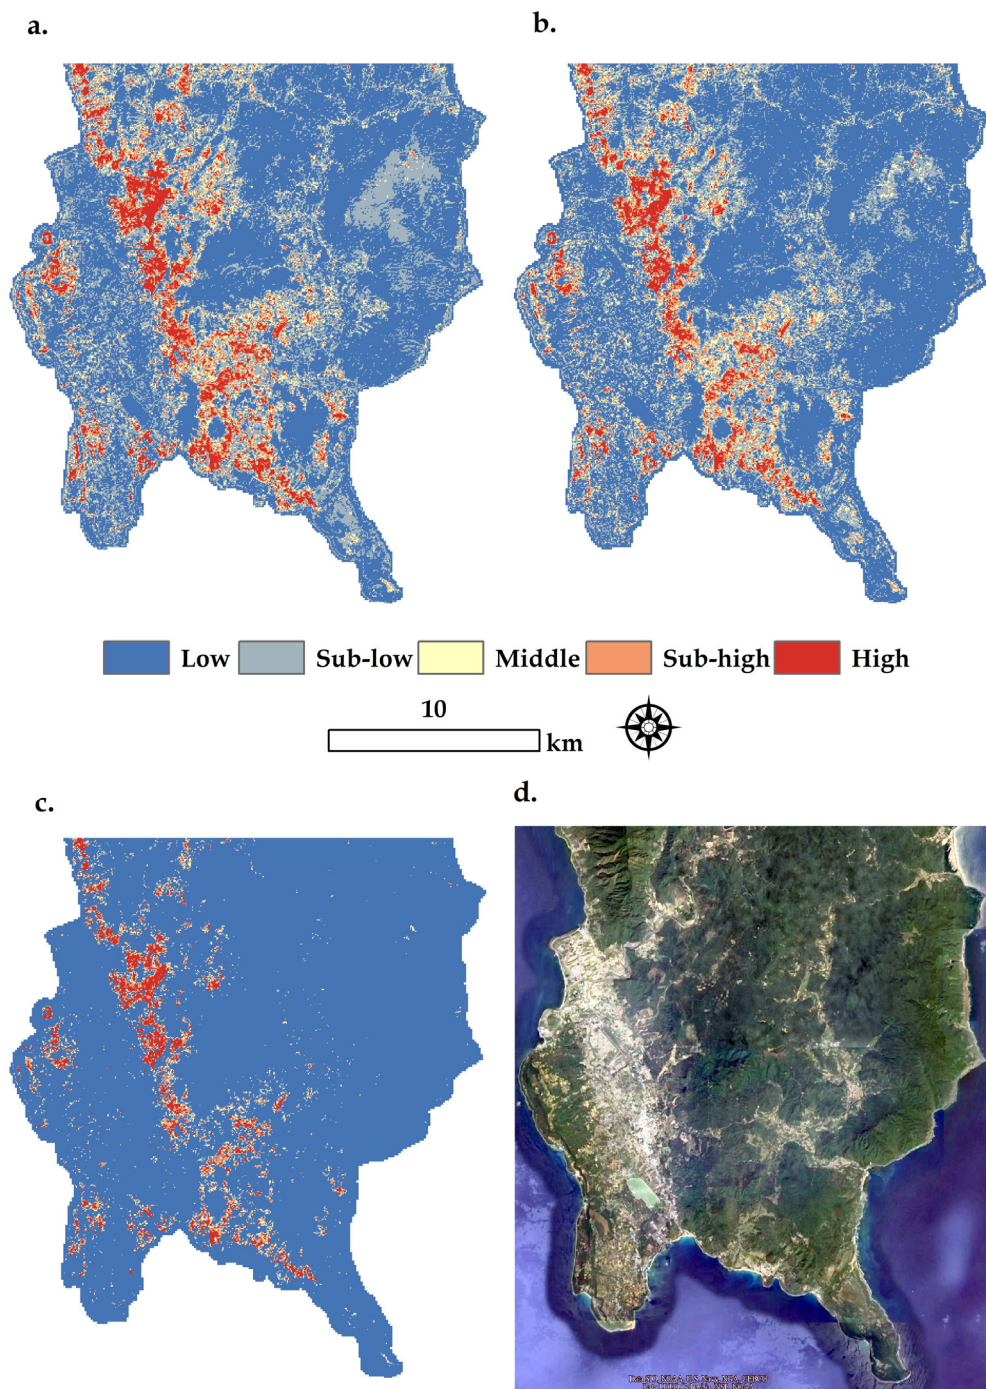


圖 4 使用不同演算法測繪出銀合歡的入侵程度 (根據自然間斷分為 5 級)，(a) IPNet、(b) DCNN、(c) DNN 及 (d) 地真資料，源自 Google Earth。

Fig. 4 Invasiveness of *Leucaena leucocephala* mapped from different algorithms: (a) IPNet, (b) DCNN, (c) DNN, and (d) real ground data adopted from Google Earth. Five levels of the invasiveness are used based on natural breaks.

表 2 根據 3 種不同演算法將銀合歡入侵程度劃分成 5 級的面積

Table 2 Areas of invasiveness for *Leucaena leucocephala* divided into five levels according to three different algorithms

Level	IPNet		DCNN		DNN	
	Area (ha)	%	Area (ha)	%	Area (ha)	%
High	2340	6.05	1680	4.34	1117	2.89
Sub-high	2102	5.43	1998	5.16	851	2.20
Middle	2879	7.44	2987	7.72	757	1.96
Sub-low	10459	27.03	9250	23.91	793	2.05
Low	20914	54.05	22778	58.87	35176	90.91

應用於大範圍 IAPS 測繪的研究案例並不多。過往的研究已證實，恆春半島的 IAPS：銀合歡，可從衛星影像上偵測重要特徵，主要方法是透過各種特徵工程，即在建模之前找尋該物種獨特的光譜反應或影像紋理做為變項，再進一步建構傳統的統計模型進行測繪 (鍾及呂 2006; Tsai and Chou 2006; Tsai *et al.* 2007)。時至今日，應用於測繪銀合歡入侵的深度學習模型仍有待開發，因此，本研究有別以往，在大尺度衛星影像的基礎上，發展可精進銀合歡辨識能力的 CNN 模型。

根據本研究的觀察，銀合歡因受氣候的影響，可從乾季的衛星影像上發現其相對獨特的光譜反應，並與其他周邊的原生植被產生差異，故有

機會測繪其入侵分佈。本研究所發展出的 IPNet 模型證實了 CNN 演算法與 Sentinel 2 影像結合，可實踐大面積測繪銀合歡的入侵分佈，儘管模型訓練初期，驗證集的損失明顯高於訓練集，最大的可能是，因使用的訓練集樣本較大，故可提供更穩定的梯度更新，反觀，驗證集樣本小，造成初期的損失波動會更大，但隨著進入中期，學習到的特徵更多，損失逐漸收斂，代表模型已經有效地掌握資料特徵。相較於其他兩種深度學習模型，IPNet 性能表現更佳，如與 Sharma *et al.* (2017) 所開發的 DCNN 相比，兩種模型的深度相當，最大差別在於 IPNet 於各卷積層的輸出都導入了批次標準化與 dropout 步驟，這兩種

常見的處理技術，不僅可加速訓練過程，也能穩定模型，減少過度擬合的問題 (Srivastava *et al.* 2014; Ioffe and Szegedy 2015)，對性能的提升有一定的幫助。至於 DNN 的架構，因沒有經過卷積層的空間演算過程，限制了提取重要特徵的能力，導致最終模型的性能表現最差，相比另外兩個 CNN 模型，預測結果明顯低估高覆蓋率及高估低覆蓋率的範圍，參考過往利用衛星影像預測植被覆蓋率的相關研究，也有發現類似的現象 (Nill *et al.* 2022; Viana-Soto *et al.* 2022)，主因應是無法有效提取混淆植被的過渡特徵。綜合以上結果顯示，CNN 在影像辨識方面確實有其優勢。

如何在有限的資源下，進行既有全面性又有系統性的 IAPS 移除或防範措施，實為一項重大挑戰，因此，提供優先處理已被入侵地區的空間分佈及未來潛在的入侵風險資訊，將有利於資源集中投入最具成本效益的防治工作 (Papeş *et al.* 2011)。本研究建立的 IPNet 迴歸模型，主要功能是預測銀合歡的覆蓋率，做為入侵程度判

定的指標，依據預測結果分成 5 種入侵程度的原則下，未來可針對各個分級制訂不同的控制策略，高入侵度無庸置疑為優先控制區，次高入侵度則為其衛星族群，這些區域應依照程度大小施予不同強度的移除工作，中入侵度範圍可視為潛在風險區或做為緩衝區，透過長期監控掌握族群的動態，以預防新生的族群入侵。

結論

本研究基於免費的 Sentinel 2 影像與 CNN 開發 IPNet 模型，為銀合歡的入侵問題，提供了明確的空間分佈資訊，就經營管理面而言，是一種低成本、高效又準確的測繪方法，所產製的入侵分佈圖，也可做為防治工作的基本參考圖。然而，為了精益求精，對於 IPNet 模型的性能表現，本研究認為應有改進的空間，主因是恆春半島的銀合歡，在不同的季節會有物候反應 (呂等 2008)，僅依靠空間維度可能會忽略掉因物候產生改變的光譜反射特徵，因此，藉由可涵蓋時間維度的 CNN 架構，如 3 維 CNN 或具

循環傳遞特性的卷積長短期記憶網路 (convolutional long short-term memory) 等演算法，分析多時段的 Sentinel 2 資料，有機會捕捉完整的時序變化特徵，是提升預測準確度的潛力方案，因此，本研究未來會在 IPNet 的架構上，持續做更多的延伸測試。

謝誌

本研究承國家科學及技術委員會之專題研究計畫 (NSTC 112-2121-M-329-001-) 之經費補助，特此致謝。

引用文獻

呂明倫、葉慶龍、鍾玉龍、謝依達。2008。墾丁國家公園四種優勢植群之地面光譜分析。航測及遙測學刊 13: 479–488。

鍾玉龍、呂明倫。2006。SPOT 衛星影像於墾丁國家公園銀合歡入侵分布之繪製。台灣林業科學 21: 167–177。

Bradley, B. A. 2014. Remote detection of invasive plants: a review of spectral, textural and phenological ap-

proaches. *Biological invasions* 16: 1411–1425.

Bradley, B. A., B. B. Laginhas, R. Whitlock, J. M. Allen, A. E. Bates, G. Bernatchez, J. M. Diez, R. Early, J. Lenoir, M. Vila and C. J. B. Sorte. 2019. Disentangling the abundance–impact relationship for invasive species. *Proceedings of the National Academy of Sciences* 116: 9919–9924.

Chollet, F. 2017. Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. pp. 1251–1258. Honolulu, Hawaii.

Diagne, C., B. Leroy, A. C. Vaissière, R. E. Gozlan, D. Roiz, I. Jaric, J. M. Salles, C. J. A. Bradshaw and F. Courchamp. 2021. High and rising economic costs of biological invasions worldwide. *Nature* 592: 571–576.

Ioffe, S. and C. Szegedy. 2015. Batch

- normalization: Accelerating deep network training by reducing internal covariate shift. In: Proceedings of the 32nd International Conference on Machine Learning 1: 448–456.
- Kanellopoulos, I. and G. G. Wilkinson. 2010. Strategies and best practice for neural network image classification. *International Journal of Remote Sensing* 18: 711–725.
- Kattenborn, T., J. Eichel, S. Wiser, L. Burrows, F. E. Fassnacht and S. Schmidlein. 2020. Convolutional Neural Networks accurately predict cover fractions of plant species and communities in Unmanned Aerial Vehicle imagery. *Remote Sensing in Ecology and Conservation* 6: 472–486.
- Kattenborn, T., J. Leitloff, F. Schiefer and S. Hinz. 2021. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 173: 24–49.
- Kussul, N., M. Lavreniuk, S. Skakun and A. Shelestov. 2017. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters* 14: 778–782.
- Lu, M. L., J. Y. Huang, Y. L. Chung and C. Y. Huang. 2013. Modeling the invasion of a Central American Mimosoid tree species (*Leucaena leucocephala*) in a tropical coastal region of Taiwan. *Remote Sensing Letters* 4: 485–493.
- Marbuah, G., I. M. Gren and B. McKie. 2014. Economics of harmful invasive species: a review. *Diversity* 6: 500–523.
- Nil, L., I. Grünberg, T. Ullmann, M. Gessner, J. Boike and P. Hostert. 2022. Arctic shrub expansion revealed by Landsat-derived multitemporal vegetation cover fractions in the Western Canadian Arctic. *Remote Sensing of Envi-*

- ronment 281: 113228.
- Papeş, M., M. Sällström, T. R. Asplund and M. J. Vander Zanden. 2011. Invasive species research to meet the needs of resource management and planning. *Conservation Biology* 25: 867–872.
- Preston, T. M., A. N. Johnston, K. G. Ebenhoch and R. H. Diehl. 2023. Beyond presence mapping: predicting fractional cover of non-native vegetation in Sentinel-2 imagery using an ensemble of MaxEnt models. *Remote Sensing in Ecology and Conservation* 9: 512–526.
- Rodríguez-Garlito, E. C., A. Paz-Gallardo and A. Plaza. 2023. Mapping Invasive Aquatic Plants in Sentinel-2 Images Using Convolutional Neural Networks Trained With Spectral Indices. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 16: 2889–2899.
- Sharma, A., X. Liu, X. Yang and D. Shi. 2017. A patch-based convolutional neural network for remote sensing image classification. *Neural Networks* 95: 19–28.
- Simonyan, K. and A. Zisserman 2014. Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556.
- Sofaer, H. R., C. S. Jarnevich and I. S. Pearse. 2018. The relationship between invader abundance and impact. *Ecosphere* 9: e02415.
- Sola, J. and J. Sevilla. 1997. Importance of input data normalization for the application of neural networks to complex industrial problems. *IEEE Transactions on nuclear science* 44: 1464–1468.
- Srivastava, N., G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov. 2014. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research* 15: 1929–1958.
- Thamaga, K. H. and T. Dube. 2018. Re-

- remote sensing of invasive water hyacinth (*Eichhorniacrassipes*): A review on applications and challenges. *Remote Sensing Applications: Society and Environment* 10: 36–46.
- Tsai, F. and M. J. Chou. 2006. Texture augmented analysis of high resolution satellite imagery in detecting invasive plant species. *Journal of the Chinese Institute of Engineers* 29: 581–592.
- Tsai, F., E. K. Lin and K. Yoshino. 2007. Spectrally segmented principal component analysis of hyperspectral imagery for mapping invasive plant species. *International Journal of Remote Sensing* 28: 1023–1039.
- Vaz, A. S., D. Alcaraz-Segura, J. C. Campos, J. R. Vicente and J. P. Honrado. 2018. Managing plant invasions through the lens of remote sensing: A review of progress and the way forward. *Science of the Total Environment* 642: 1328–1339.
- Viana-Soto, A., A. Okujeni, D. Pflugmacher, M. García, I. Aguado and P. Hostertl. 2022. Quantifying post-fire shifts in woody-vegetation cover composition in Mediterranean pine forests using Landsat time series and regression-based unmixing. *Remote Sensing of Environment* 281: 113239.
- Vilà, M., J. L. Espinar, M. Hejda, P. E. Hulme, V. Jarošík, J. L. Maron, J. Pergl, U. Schaffner, Y. Sun and P. Pysek. 2011. Ecological impacts of invasive alien plants: a meta-analysis of their effects on species, communities and ecosystems. *Ecology letters* 14: 702–708.