

使用深度學習演算進行 Sentinel-2 影像之土地利用 和土地覆蓋分類

呂明倫^{1*}

摘要

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

關鍵詞：遙測、卷積神經網路、隨機森林、製圖

1. 前言

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

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

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

¹ 農業部生物多樣性研究所 副研究員

* 通訊作者, E-mail: alan@tbri.gov.tw

收到日期：民國 113 年 09 月 30 日

修改日期：民國 113 年 12 月 12 日

接受日期：民國 113 年 12 月 30 日

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

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

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

2. 材料與方法

2.1 研究區概述

埔里鎮位於台灣中部，面積約 162 km²，境內平原面積占 26%，丘陵面積占 74%，海拔介於 380~700 m，全鎮由中央山脈、合歡山與雪山山脈所包圍，最高峰位於東北部的關刀山 (1,924 m)，為典型的盆地地形。土壤方面，東部以黏土為主，北部、南部和西部地區以黃土為主 (Wu *et al.*, 2014)。根據中央氣象局的埔里氣象站 2016 到 2023 年資料顯示，該區年平均的雨量為 2141 mm、降水日數約 132 日、相對濕度超過 80%、氣溫為 22.6°C，屬亞熱帶溫潤氣候。

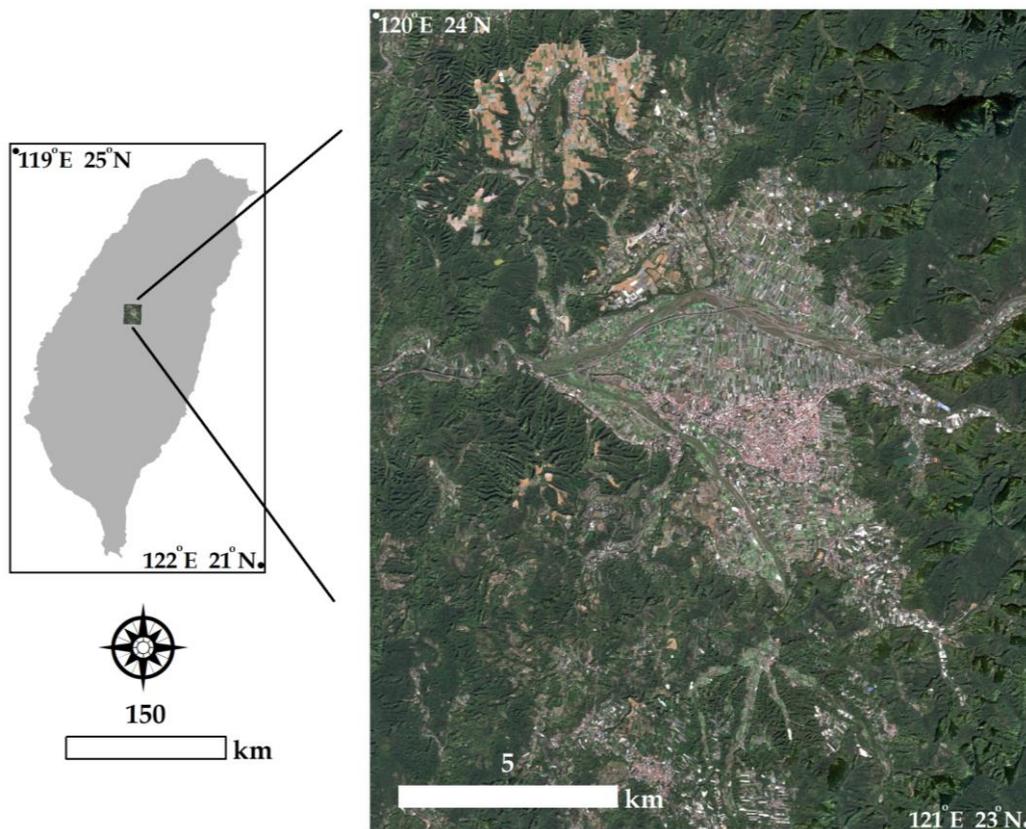


圖 1 研究區位置圖 (背景為 Sentinel-2 的 RGB 影像)

2.2 蒐集衛星影像及地面資料

Sentinel-2 為歐洲太空總署 (European Space Agency, ESA) 發射之衛星，掃描寬度廣達 290 km，光譜資訊涵蓋可見光、近紅外、紅邊及短紅外光範圍，共切割成 13 個波段影像 (表 1)。研究區的 Sentinel-2 影像從 browser.dataspace.copernicus.eu 下載，篩選少雲層覆蓋且清晰的影像，選定的影像屬 Level-2A 處理等級的產品，即地表反射率經過大氣校正，拍攝日期為 2021 年 1 月 15 日 (圖 1)，屬雨量稀少的乾燥季節。由於 60 m 的波段影像，主要功能為雲霧過濾與大氣相關的應用，故本研究僅用到第 2 到 8、8A、11 和 12 等 10 個波段影像，透過 ESA 專為處理 Sentinel 影像資料所開發的免費軟體：Sentinel Application Platform (eo4society.esa.int/resources/snap)，以最近相鄰法 (nearest neighbor) 進行 10 m 空間解析力的像元重取樣。

表 1 Sentinel-2 的波段影像描述

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

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

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

2.3 卷積神經網路

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

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

表 2 各 LULC 類型的樣本分配與定義

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

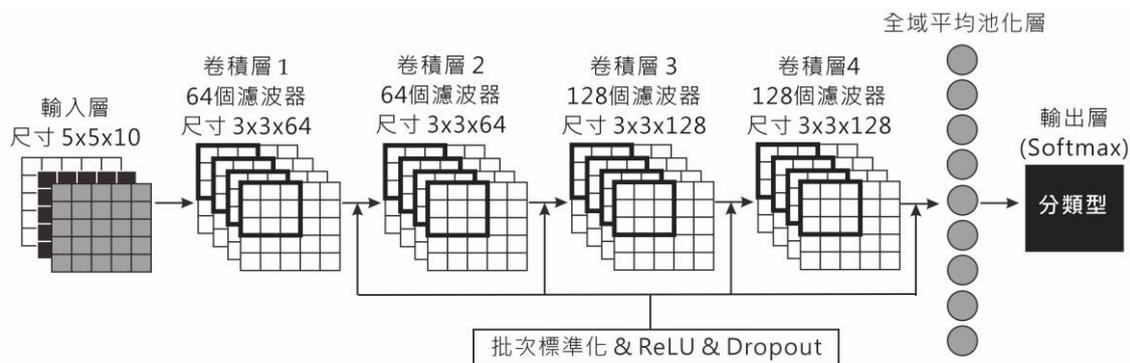


圖 2 本研究使用之卷積神經網路架構

2.4 模型性能比較

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

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

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

3. 結果與討論

3.1 分類準確度

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

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

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

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

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

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

3.2 LULC 製圖結果

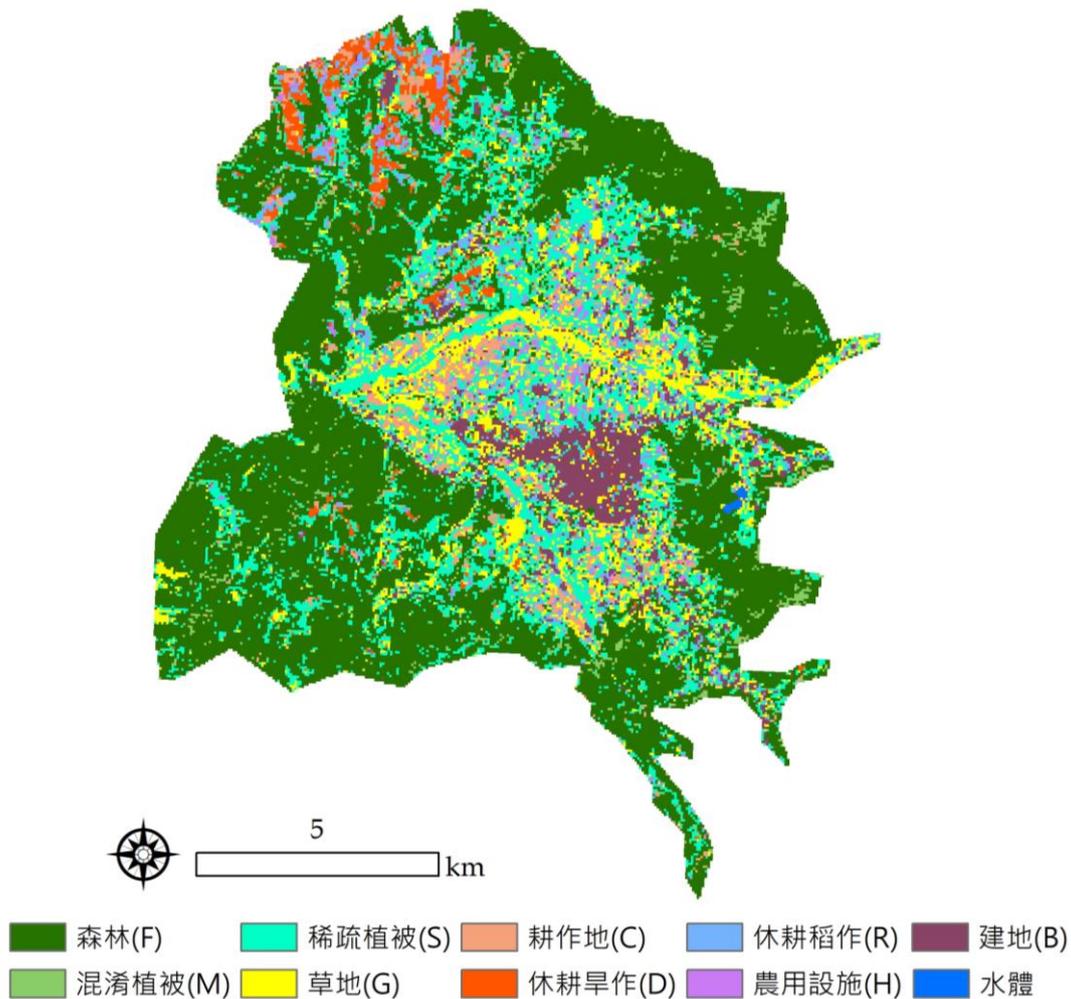
根據CNN模型進行製圖，並與人工標記的水體類型整合，研究區的LULC空間分佈如圖3，由於研究區四面環山，故以F的面積占大多數，並與一些小面積的M共存，S則大多座落在山區與平原的過渡帶。以B為主的城市地區位於盆地中心，環繞在其周邊的景觀結構複雜，尤其是分類有待改善的G、R與H，在此地區呈現零碎且彼此鑲嵌的景觀，是導致各類間混淆的原因。北面的農業區是由C、D與R所組成，這些類型呈現相對均質的區塊型態，因此，該區分類的效果相對較佳。

表 4 隨機森林模型產生之誤差矩陣表

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

表 5 卷積神經網路模型產生之誤差矩陣表

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



4. 結論

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

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

參考文獻

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

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

- Management, 45(4): 427-437, DOI: 10.1016/j.ipm.2009.03.002.
- Song, H., Kim, Y., and Kim, Y., 2019. A patch-based light convolutional neural network for land-cover mapping using Landsat-8 images, *Remote Sensing*, 11(2): 114, DOI: 10.3390/rs11020114.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R., 2014. Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, 15: 1929-1958.
- Teluguntla, P., Thenkabail, P.S., Oliphant, A., Xiong, J., Gumma, M.K., Congalton, R.G., Yadav, K., and Huete, A., 2018. A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform, *ISPRS Journal of Photogrammetry and Remote Sensing*, 144: 325-340, DOI: 10.1016/j.isprsjprs.2018.07.017.
- Wang, Y., Sun, Y., Cao, X., Wang, Y., Zhang, W., and Cheng, X., 2023. A review of regional and Global scale Land Use/Land Cover (LULC) mapping products generated from satellite remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 206: 311-334, DOI: 10.1016/j.isprsjprs.2023.11.014.
- Wu, C.F., Lin, Y.P., Chiang, L.C., and Huang, T., 2014. Assessing highway's impacts on landscape patterns and ecosystem services: A case study in Puli Township, Taiwan, *Landscape and Urban Planning*, 128: 60-71, DOI: 10.1016/j.landurbplan.2014.04.020.
- Yang, D., Chen, J., Zhou, Y., Chen, X., Chen, X., and Cao, X., 2017a. Mapping plastic greenhouse with medium spatial resolution satellite data: Development of a new spectral index, *ISPRS Journal of Photogrammetry and Remote Sensing*, 128: 47-60, DOI: 10.1016/j.isprsjprs.2017.03.002.
- Yang, D., Fu, C.S., Smith, A.C., and Yu, Q., 2017b. Open land-use map: A regional land-use mapping strategy for incorporating OpenStreetMap with earth observations, *Geo-spatial Information Science*, 20(3): 269-281, DOI: 10.1080/10095020.2017.1371385.
- Yıldırım, Ö., Baloglu, U.B., and Acharya, U.R., 2020. A deep convolutional neural network model for automated identification of abnormal EEG signals, *Neural Computing and Applications*, 32(20): 15857-15868, DOI: 10.1007/s00521-018-3889-z.

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

Ming-Lun Lu ^{1*}

Abstract

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

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

¹ Associate Researcher, Taiwan Biodiversity Research Institute, Ministry of Agriculture

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

Received Date: Sep. 30, 2024

Revised Date: Dec. 12, 2024

Accepted Date: Dec.30, 2024