

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。

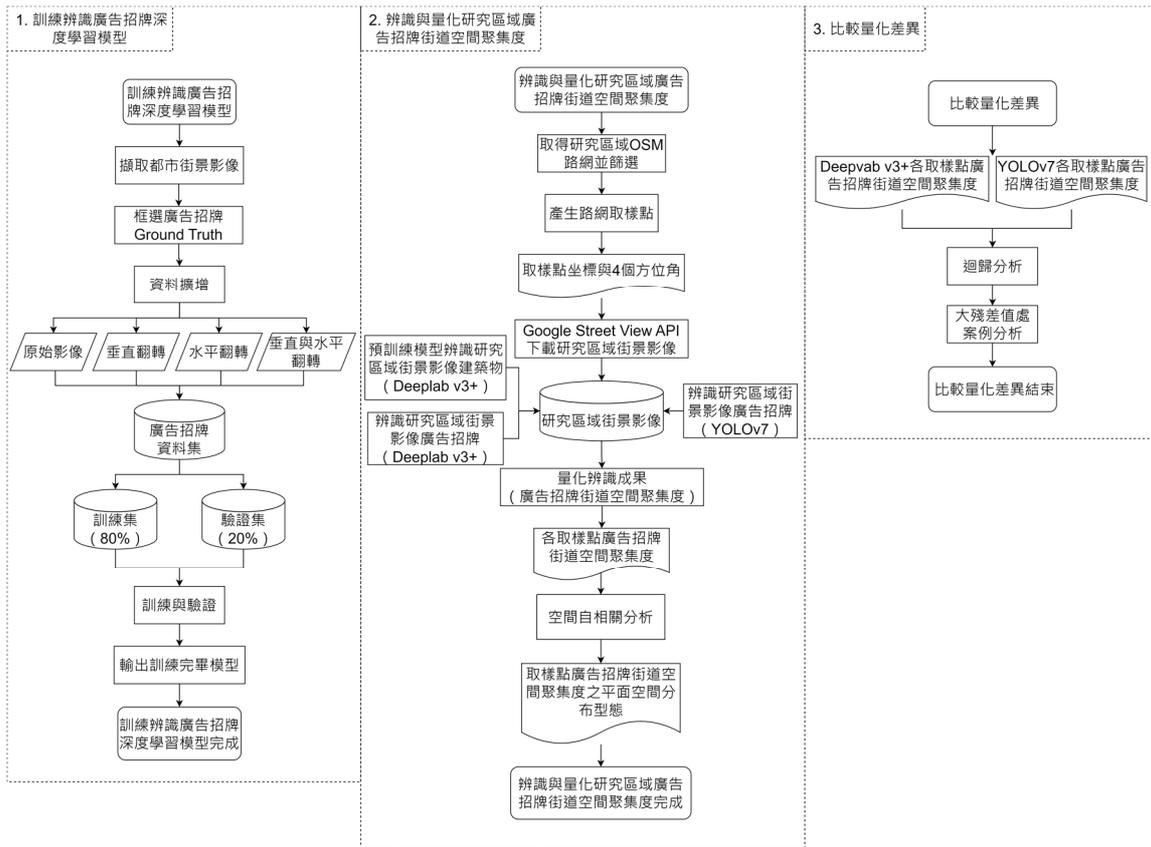


圖 1 研究流程圖

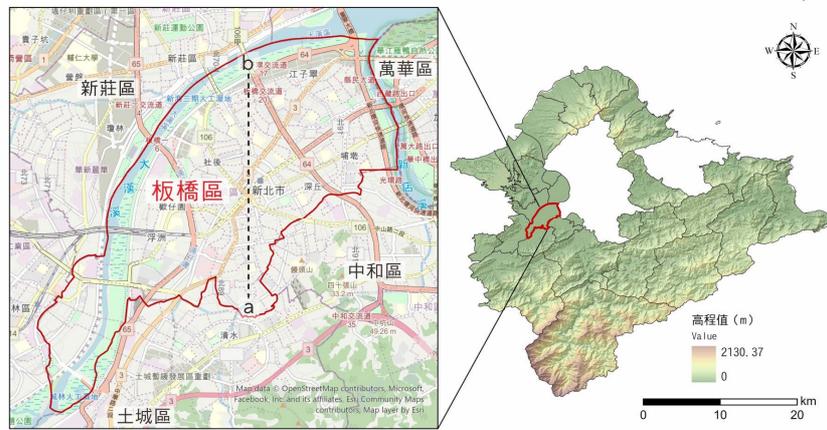


圖 2 研究區域—新北市板橋區

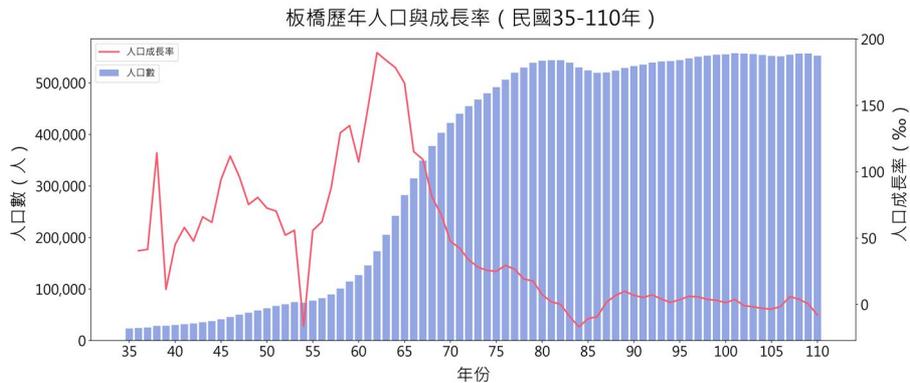


圖 3 板橋歷年人口與成長率 (民國 35 - 110 年)

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。

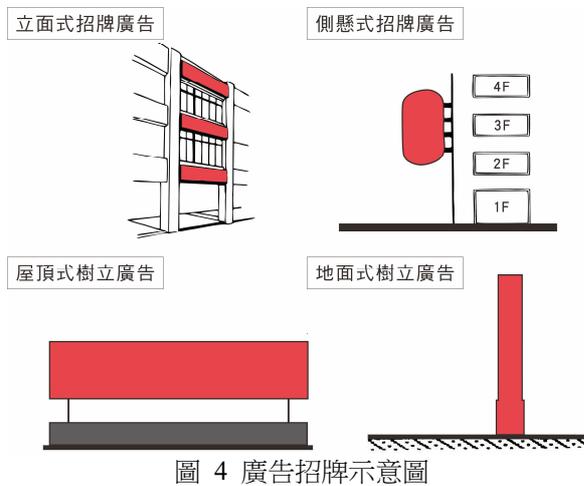


圖 4 廣告招牌示意圖

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

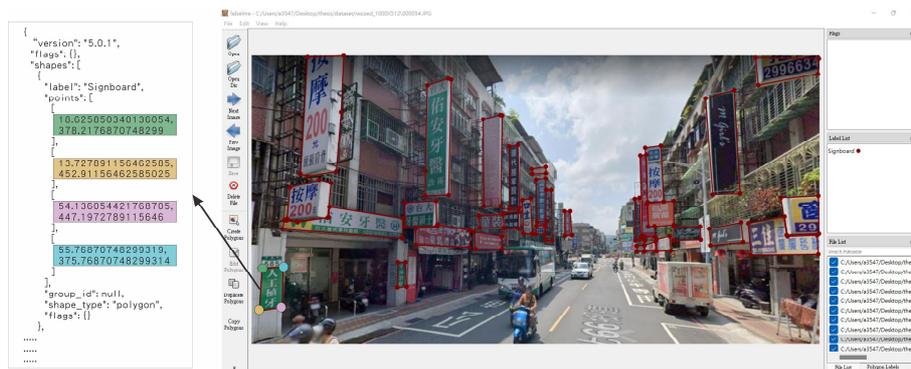


圖 6 Labelme 軟體操作介面與廣告招牌框選之 JSON 檔結構

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

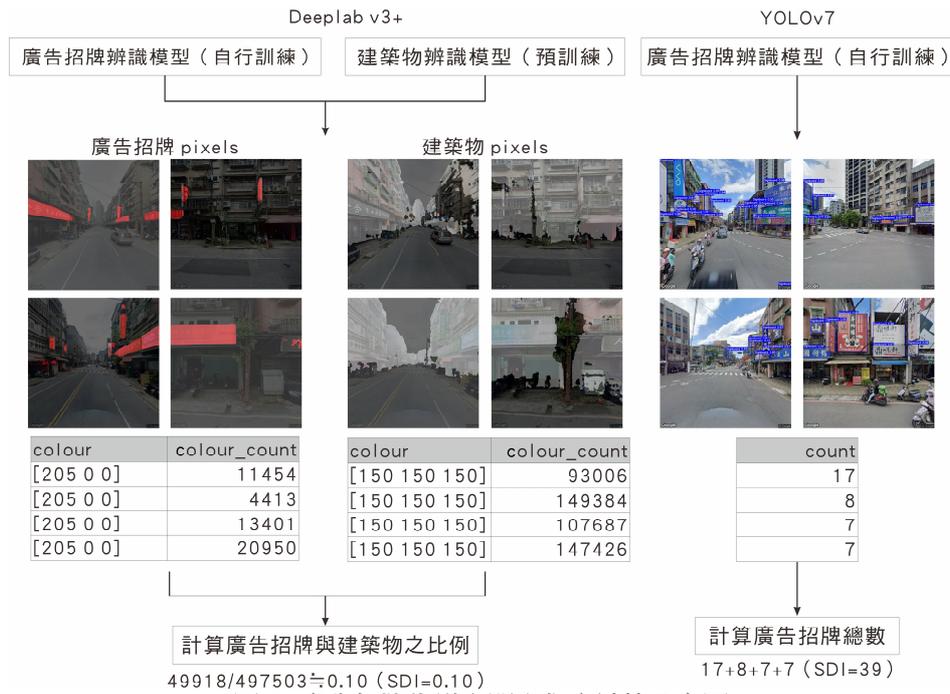


圖 8 廣告招牌街道空間聚集度計算示意圖

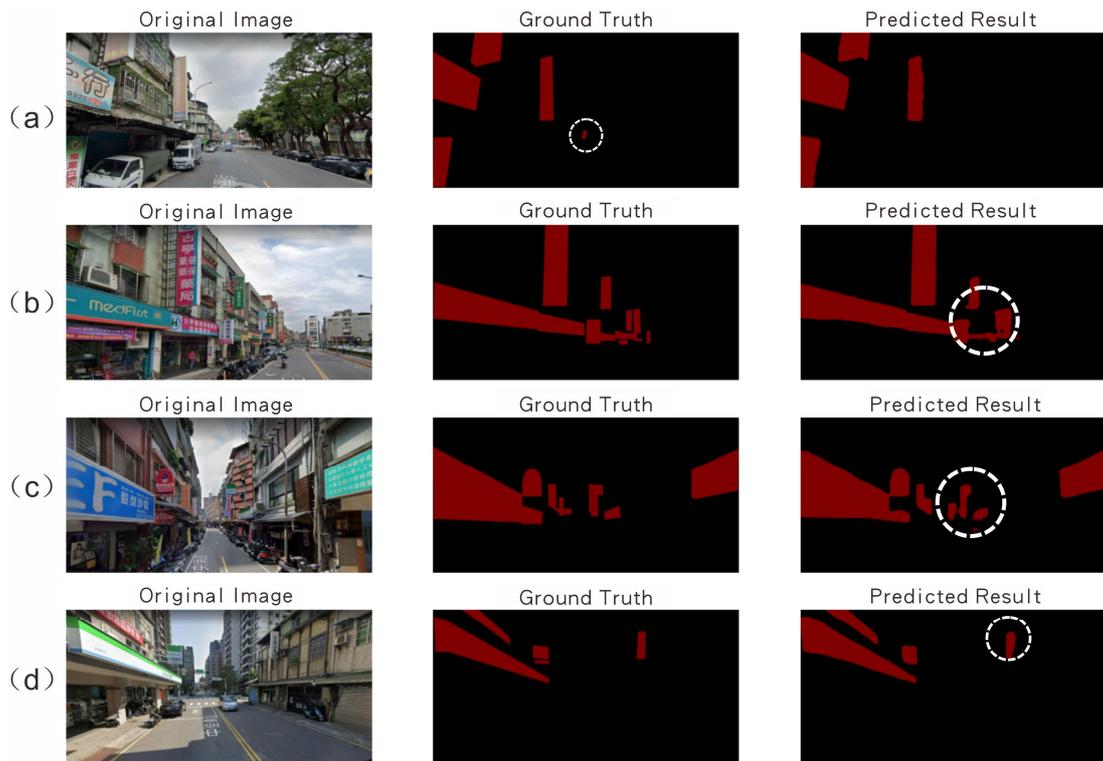


圖 9 Deeplab v3+之驗證集之高 IoU 值視覺化成果範例

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。

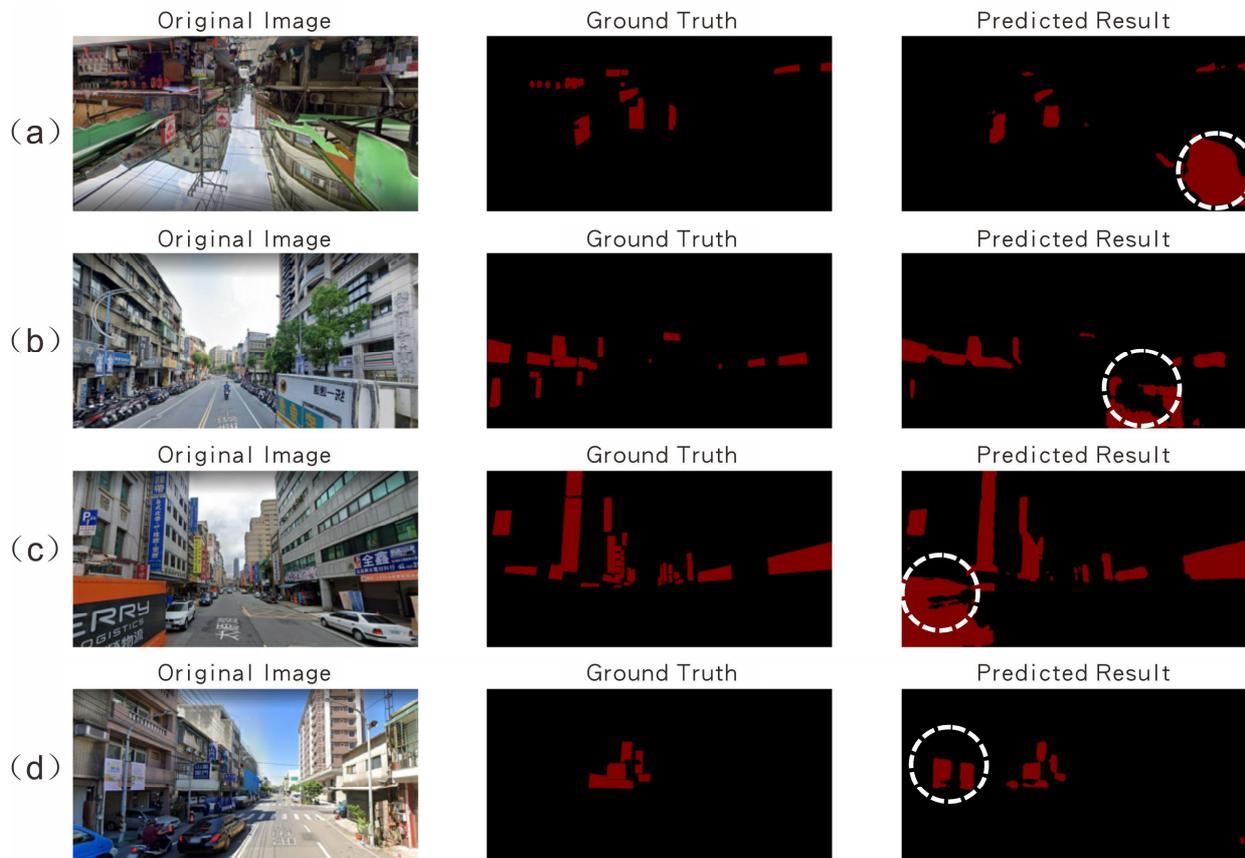


圖 10 Deeplab v3+ 之驗證集之低 IoU 值視覺化成果範例

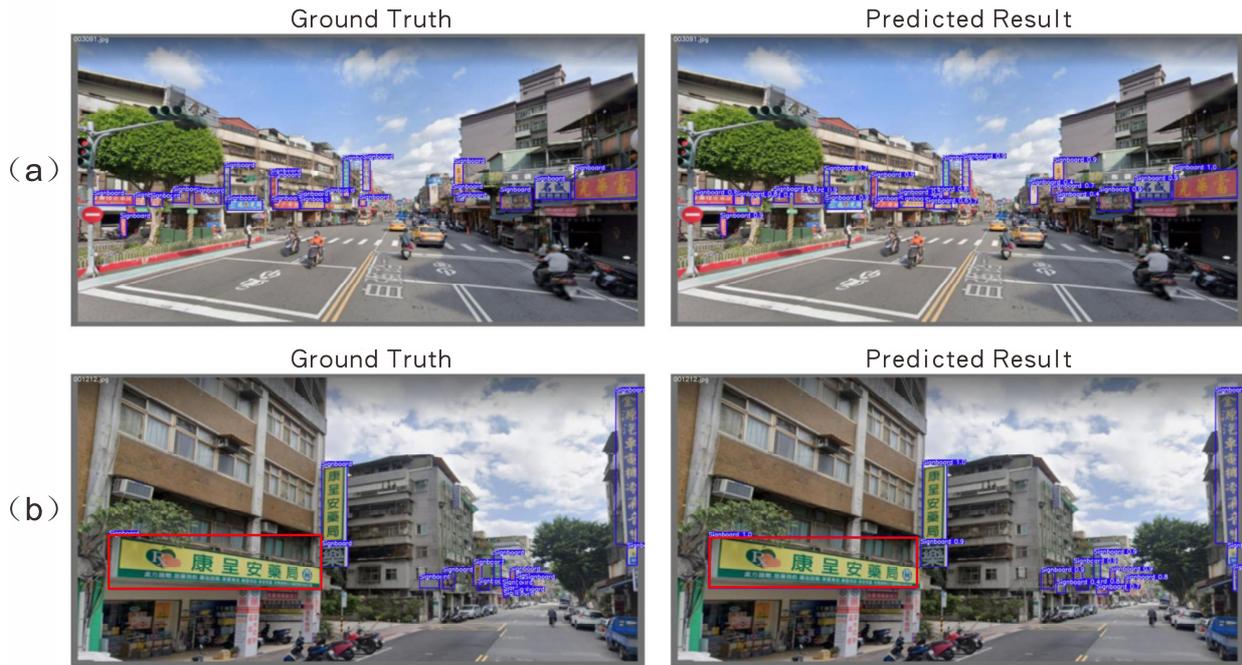


圖 11 YOLOv7 之驗證集視覺化成果範例

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。

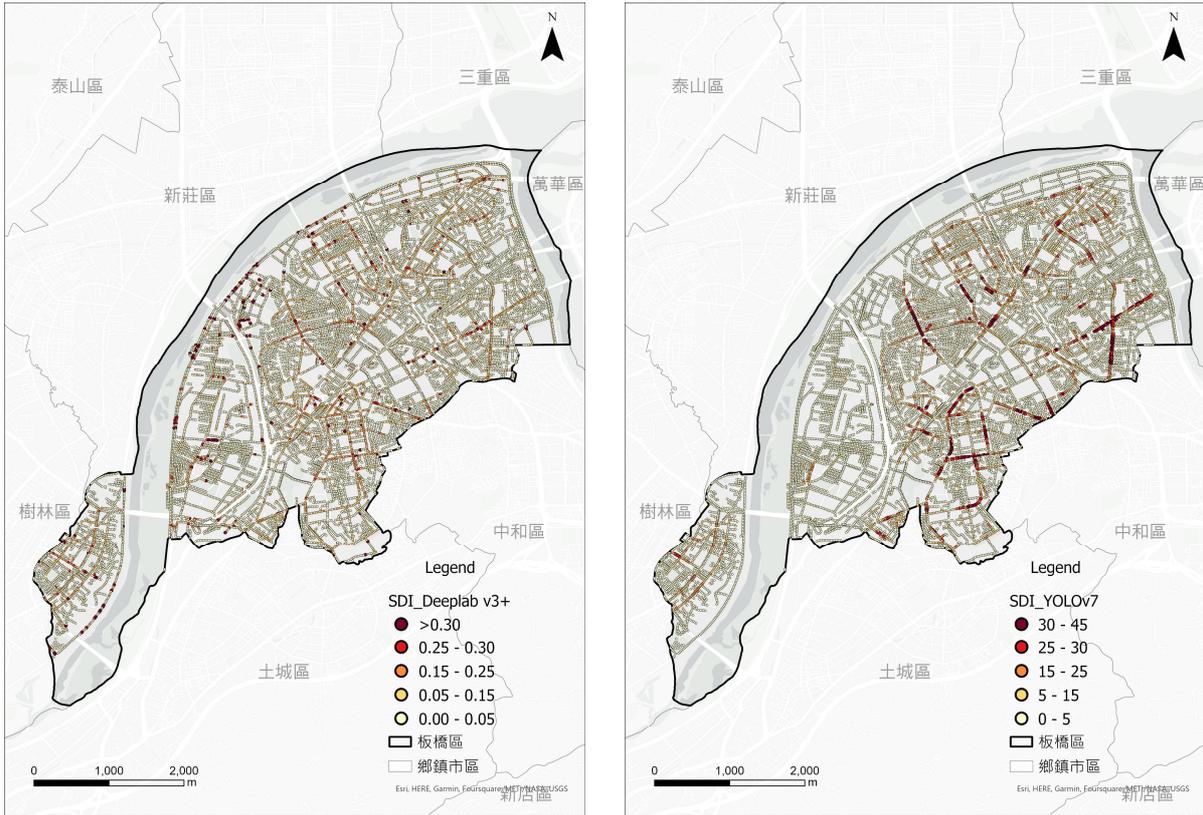


圖 12 Deeplab v3+ (左) 與 YOLOv7 (右) 取樣點 SDI 分布

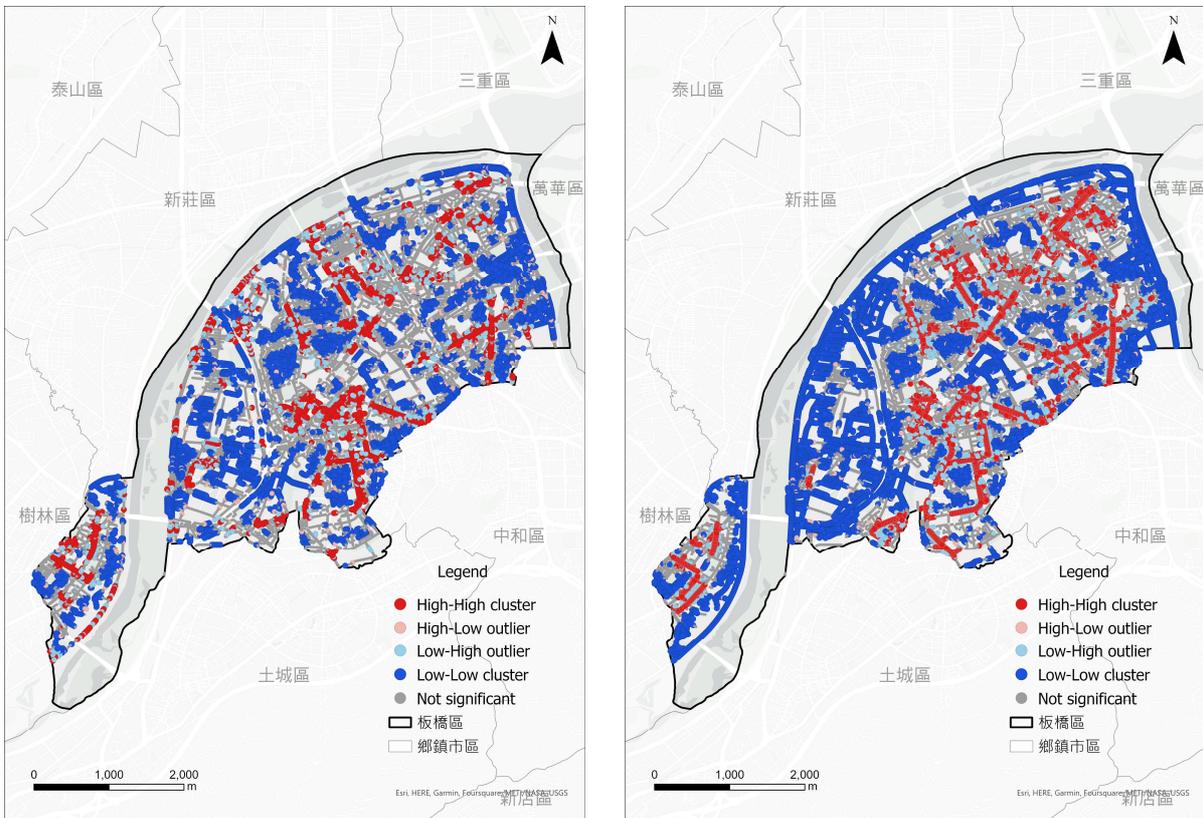


圖 13 Deeplab v3+ (左) 與 YOLOv7 (右) 取樣點 SDI 局域空間自相關

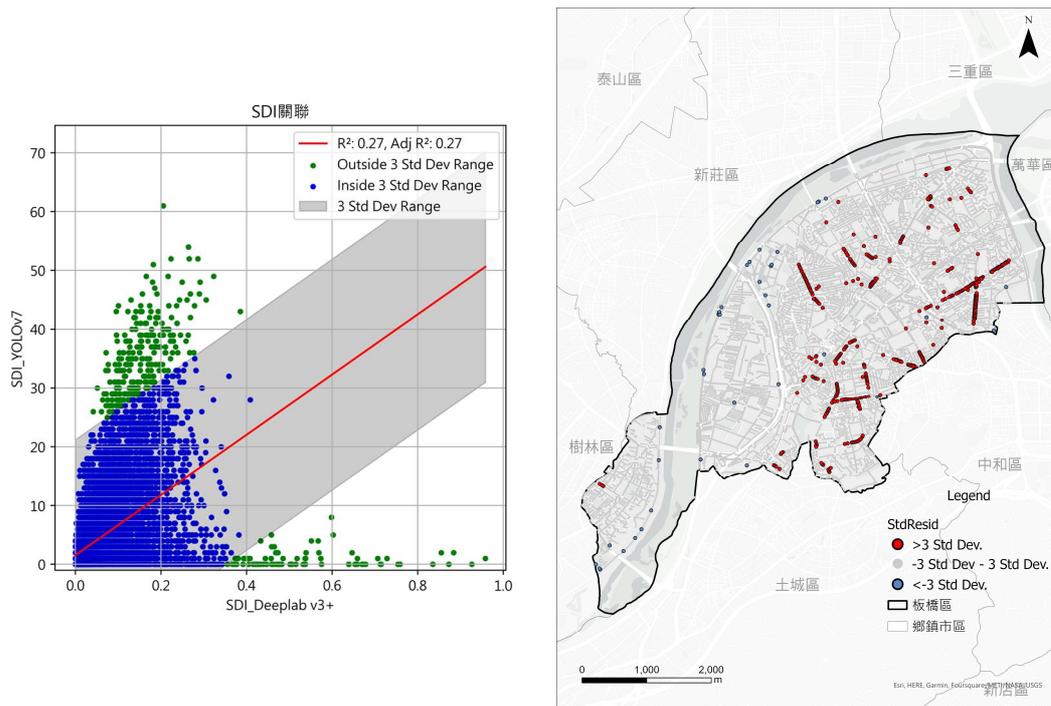


圖 14 DeepLab v3+與 YOLOv7 之 SDI 殘差逾 3 個標準差關聯圖 (左) 與分布 (右)

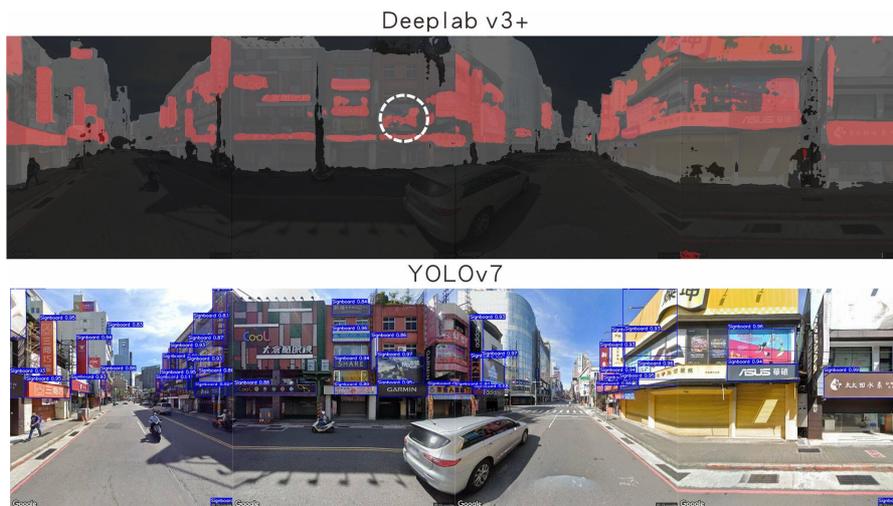


圖 15 Deeplab v3+與 YOLOv7 SDI 殘差大於 3 個標準差之案例

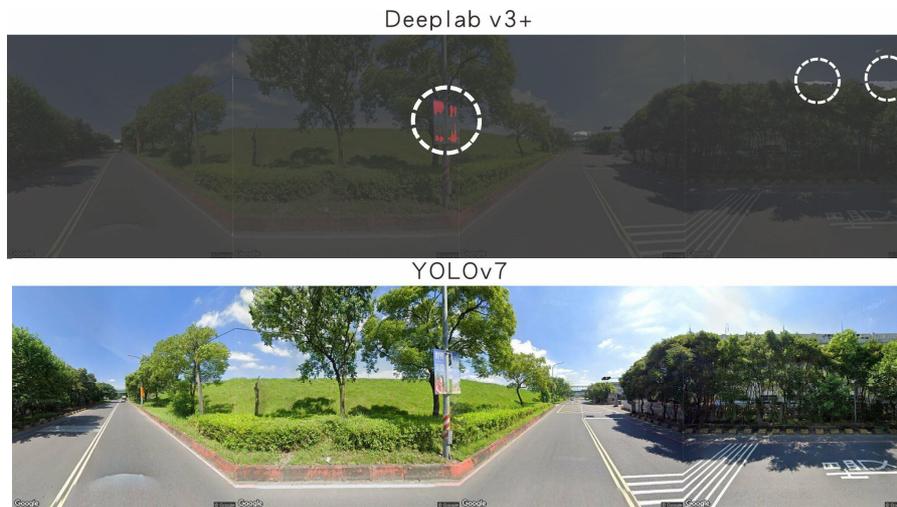


圖 16 Deeplab v3+與 YOLOv7 SDI 殘差小於 3 個標準差之案例

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。新北市政府升格 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