



航測及遙測學刊

中華民國航空測量及遙感探測學會出版

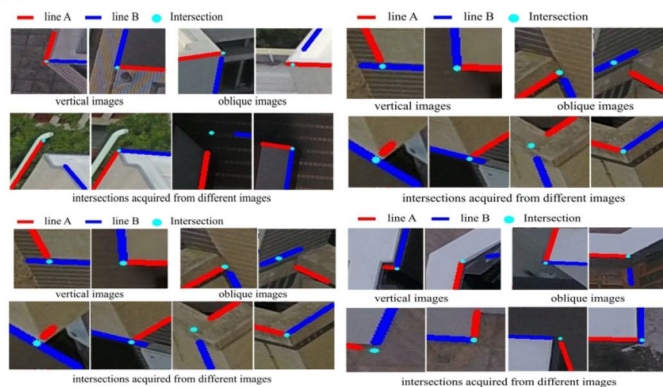
(a) 多視角無人機影像




(b) 多視角建物角點特徵偵測




(c) 建物角點特徵萃取



(d) 點線面位像關係及虛擬角點重建



(e) 建物三維線框模型成果



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

本研究提出一種基於多視角無人機影像的自動化三維建物線框模型重建策略，結合深度學習技術，生成包含側向幾何資訊的三維線框模型。透過角點特徵偵測模型與角點萃取演算法，準確定位建物角點，並基於曼哈頓世界假設及適用於曲線幾何的原則，設計出一套位向重建策略。同時，藉由虛擬角點演算法，有效減少遮蔽與缺失問題的影響。此方法強調無人機影像的快速獲取、低成本與自動化優勢，並具有輔助 LoD3 建物模型建置的潛力。

三維建物線框模型之無人機影像自動重建

黃郁翎¹ 莊子毅^{2*}

摘要

三維建物圖資在智慧城市規劃、管理和能源評估中扮演著重要角色。然而，由於作業繁瑣且自動化不足，針對既有建物構建精確的三維模型依然充滿挑戰。本研究提出基於多視角無人機影像的演算策略，生成具備側向幾何細節的三維線框模型，可做為進行既存建物三維房屋模型建置之基礎，提升作業效率並降低成本。演算程序運用預訓練的角點檢測模型及提出的角點萃取演算，採用「由粗到細」的策略實現角點定位。同時，運用虛擬角點重建策略來降低都市 UAV 影像中無可避免的遮蔽與數據缺失影響。實驗結果顯示，演算策略可適應具曲線形之建築結構，建築角點平均精度約為 30 cm，並可達到 98% 的線框重建完整度。

關鍵詞：多視角無人機影像、影像建模、自動化建物線框重建、線框模型、深度學習

1. 前言

1.1 研究動機與目的

三維空間資訊作為智慧國土的重要元素，可藉由豐富的時空數據協助決策者更全面地理解、規劃與利用環境資源。其中，三維建物模型更可扮演重要的資訊交換與分析平台，可運用於都市規劃、城市管理、能源估算及定位輔助等多個範疇。為實現智慧國土的目標，我國推行的三維國家底圖建置工作，採取「先全面建置，後精進細緻」的策略，基於既有的臺灣通用電子地圖，結合千分之一地形圖及數值地形模型以建構三維圖資。目前能提供符合開放地理空間協會 (Open Geospatial Consortium, OGC) 細緻度標準 (Level of Detail, LoD) 的 LoD1 與 LoD2 三維建物模型，對於重要地標則採用 LoD3 標準進行建置。由於建物模型品質會對後續分析和應用造成直接的影響，並恐於數據整合時產生衝突，因此，如何可靠且高效地產製高精度建物三維模型仍為關鍵研究課題。目前針對 LoD3 規格之三維建物模型製程仍缺乏自動化的作業程序，導致建置成

本高昂且耗時。有鑑於此，本研究採用無人機 (Unmanned Aerial Vehicle, UAV) 對目標建築進行約 45 度角的傾斜拍攝及 90 度角的垂直拍攝，獲取適合三維建築重建的影像數據。同時，本研究以此多視角影像作為唯一的數據類型，提出結合深度學習演算法的自動化處理策略，建置具有側向幾何資訊的建物三維線框模型，可作為既存建物 LoD3 模型建置的基礎模型，在符合精度需求的前提下，獲得降低人工與時間成本的效益。

現行的重建策略多採取結合不同來源與類型的數據，以資訊互補的方式逐步重建房屋模型。然而，不同類型數據的整合往往需要額外處理以妥善和應對數據品質及收集時間的差異性。此外，相較於運用三維點雲為基礎的演算方式，影像資料在資料量、技術發展成熟度及演算複雜度方面相對具有優勢，因此，許多研究著重於運用衛星及航空影像進行大規模的房屋模型重建，但受到影像視角的限制，模型成果無法提供建物的側向幾何資訊，難以滿足高精度和高細緻度的需求。反之，無人機具備高度機動性與作業彈性，並可採用垂直或傾斜拍攝配置提供高解析度影像。儘管如此，實際作業仍不可避

¹ 國立陽明交通大學土木工程學系 碩士

² 國立陽明交通大學土木工程學系 副教授

* 通訊作者, E-mail: jtychuang@nycu.edu.tw

收到日期：民國 113 年 08 月 14 日

修改日期：民國 113 年 09 月 09 日

接受日期：民國 113 年 09 月 11 日

免遭遇目標物被遮蔽之挑戰。如何針對遮蔽區域進行補償以提升重建完整性亦是待改善之課題。

本研究旨在提高 LoD3 建物模型重建任務時的自動化程度，提出基於深度學習的自動化三維線框模型建置演算策略，以此作為輔助 LoD3 建物建模任務的基礎模型，減少人工在幾何判識或檢核操作中的介入。受益於深度學習技術的發展，本研究利用深度學習模型自動偵測建物角點區域，並結合相應的角點萃取演算法，採用「由粗到細」的方式精確定位建物角點位置。同時，透過影像特徵描述元進行特徵點描述並進行多像幅的特徵匹配程序。同時，透過多像幅之共軛點光束交會，估計建物各角點之三維坐標。除此之外，本研究進一步提出了針對描述建物外觀幾何的三維角點的位相關係重建策略，恢復建物外觀的線面關係，從而形成三維線框模型。值得注意的是，為了解決運用無人機影像進行建物重建任務經常遇到的目標遮蔽問題，研究中提出了虛擬角點重建演算程序，重建真實存在於空間中但因為遮蔽或重建程序失敗等因素而缺失之建築物角點。研究假設在建物僅有部分角點缺失的情況下，基於曼哈頓世界假設 (Manhattan World Assumption)，以虛擬角點的形式補全線框模型中的缺失點位，針對結構物主體生成符合 LoD3 精度標準且具側向幾何資訊的三維線框模型。與既有方法相比，本研究具有以下特點：

- (1) 結合深度學習，自動化偵測建物角點特徵，並設計了精確定位角點的演算法。
- (2) 提出角點位相關係重建策略，包括建置虛擬點位，以降低目標物遮蔽及自動化重建過程失敗所導致的缺失。
- (3) 以無人機多視角影像作為唯一數據資料，實現三維建物線框模型的自動化重建演算，生成具側向幾何資訊如陽台、雨遮或曲面特徵的高精度建物線框模型。

1.2 相關研究

1.2.1 自動化建物模型重建策略

本研究的主要目標是結合深度學習模型，自動

化重建具側面幾何資訊的三維建物線框模型。該線框模型將作為 LoD3 建物模型建置過程中的基礎模型，從而提升其自動化水平。為達成此目標，本研究將重點回顧具側向結構的建物模型重建方法，並深入分析各現有方法的優缺點，以更全面理解在實現自動化重建目標過程中可能面臨的挑戰。

城市地理標記語言 (City Geographic Markup Language, CityGML) 對於各級細緻度的建物模型規範了其精度和簡化程度。在 LoD1 中，平面與高程的絕對精度要求為 5 m，並將平面大於 36 m² 和高程超過 3 m 的模型進行簡化，未達標準者可不予考量。LoD2 則需達到平面與高程的絕對精度 2 m，並重建平面面積大於 16 m² 以及高程超過 2 m 的特徵。LoD3 的精度要求更為嚴格，平面與高程的絕對精度需小於 0.5 m，並處理平面面積大於 4 m² 以及高程超過 1 m 的特徵。LoD4 則需達到平面與高程的絕對精度 0.2 m，並呈現所有結構和開口的細節。這些精度和細緻度的分類與定義提供了關鍵標準，使建物模型能夠更有效地共享、比較和分析，確保模型的精度和一致性。儘管本研究並非直接重建 CityGML 規範下的建物模型，這些標準仍可作為線框模型品質的參考依據。

現行建物模型重建的方法可分為兩大方式：模型導向 (Model-driven) 和資料導向 (Data-driven)。模型導向方法基於資料庫，並根據調整的參數進行建模。此方法對於幾何形狀簡單的建築物 (如平頂屋或山形屋) 非常有效。然而，由於現實世界中的建築外型多樣，資料庫難以涵蓋所有可能的建築形式，造成此方法具有一定的局限性。相較之下，資料導向方法基於建物表面及其位相約制進行重建，更適合處理複雜的細節。其處理流程通常包括三個主要步驟：萃取建物的原始表面特徵、重建建物表面的位相關係，以及構建建物模型 (Ma, 2005)。理論上，資料導向方法能更全面地重建現實世界中各種形狀的建築物。根據處理的數據資料類型，可進一步細分為雷射掃描資料、影像資料和地圖資料。雷射掃描資料主要來自空載雷射掃描儀 (Airborne Laser Scanner, ALS) 和地面雷射掃描儀 (Terrestrial Laser Scanner, TLS)，以點雲形式儲存。相似地，影

像資料根據載具的不同可分為衛星影像、航照影像和無人機影像。經過處理後，影像資料同樣能夠生成點雲資料。不同資料來源各具優缺點，如表 1 所示。為了彌補各自的不足，許多研究採用多種資料來源進行重建 (Flamanc *et al.*, 2003、Gui & Qin, 2021、Wen *et al.*, 2019)。本研究嘗試以無人機影像作為唯一的數據來源，以獨棟建築為目標進行三維線框模型重建。由於無人機具有以高彈性、機動性獲取高解析度影像的優勢，便於掌握和控制所獲得的影像資料，尤其有利於取得側向結構資訊 (Klimkowska *et al.*, 2022) 進行高精度的建物線框模型重建 (Malihi *et al.*, 2016)。

透過整合不同類型資料的優勢，Wen *et al.* (2019) 將點雲萃取的平面特徵與傾斜影像中的邊界約束相結合，實現半自動化的高精度建物模型重建。Chen *et al.* (2014) 則使用 ALS 點雲作為資料來源，採用改良的隨機抽樣一致算法 (RANDOM SAMPLE CONSENSUS, RANSAC) 來分割屋頂平面，並在約束條件下萃取邊緣以構建位相關係，進而優化邊界形狀，自動生成大範圍的建物模型。與之不同，Wang *et al.* (2016b) 聚焦於建物立面結構的重建，通過點雲資料提取立面結構的幾何特徵和約束條件，能快

速且大規模地建置建物立面模型，然而，此方法僅適用於網格狀的基礎立面。此外，Pu & Vosselman (2009a) 同樣以立面結構為重點，透過先驗資訊重建受遮蔽區域，成功克服了資料不足的挑戰。

鑒於上述方法成本較為高昂，為了降低成本並同時獲取高精度資料，近年來無人機影像資料逐漸受到重視 (Murtiyoso *et al.*, 2020)。其中，由於重建細節與獲取坐標資訊的需求，多數研究偏向使用基於影像生成的點雲作為資料來源。McClune *et al.* (2016) 結合正射影像、數值地表模型與影像生成的點雲，通過邊緣線偵測與線擬合，萃取屋頂角點，並利用位相關係完成 LoD2 精度的房屋線框模型自動化重建。然而在處理複雜屋頂幾何時仍有進步空間。Wang *et al.* (2023a) 基於點雲資料與從中萃取的屋頂輪廓，通過演算法將立面抽象化為規則線段，進行二維型態的重建並拉升為三維模型。除此之外，Huang *et al.* (2020) 則是將無人機影像生成之點雲與預設模型資料庫進行整合，運用模型導向的方式完成 LoD3 建物模型重建。近年伴隨著人工智慧技術的發展，三維建物模型重建引入了全新的思維與方法，不僅顯著減少了人工作業的介入，還克服了傳統演算法所面臨的諸多挑戰，大幅提升了資料處

表 1 不同資料類型於建物模型建置之優缺點

| 資料類型 | 優點 | 缺點 |
|------|--|--|
| 雷射掃描 | <ol style="list-style-type: none"> 1. 高精度的幾何資料，尤以地面雷射掃描表現最佳 2. 捕捉建築物細節和結構 3. 適用大範圍和複雜環境 | <ol style="list-style-type: none"> 1. 成本較高，特別是空載雷射掃描 2. 需專業設備和技術 3. 處理和分析大量點雲資料可能耗時較長 |
| 影像資料 | <p>衛星影像</p> <ol style="list-style-type: none"> 1. 覆蓋範圍最廣 2. 定期更新 3. 長時間序列 | <ol style="list-style-type: none"> 1. 相對於其他影像，解析度較低 2. 受雲層影像 3. 有限的高程感測 |
| | <p>航照影像</p> <ol style="list-style-type: none"> 1. 解析度適中 2. 相對於衛星影像，受天氣、雲層影像較小 3. 可控制航高 4. 覆蓋範圍次之 | <ol style="list-style-type: none"> 1. 局部覆蓋 2. 成本較高 3. 影像更新時間不穩定 |
| | <p>UAV 影像</p> <ol style="list-style-type: none"> 1. 高解析度 2. 具高彈性與高機動性 3. 即時性 4. 較易獲取側向結構與細節 | <ol style="list-style-type: none"> 1. 飛行時間有限 2. 覆蓋範圍小 3. 法規限制 |
| 地圖資料 | <ol style="list-style-type: none"> 1. 提供地理和地形資訊 2. 適合用於城市規劃和區域規劃 | <ol style="list-style-type: none"> 1. 缺乏建築物具體細節 2. 地圖更新速度較慢 3. 有限的結構資訊 |

理的自動化程度。Pantoja-Rosero *et al.* (2022) 運用了運動恢復結構 (Structure from Motion, SfM) 技術從影像中生成點雲，並利用這些點雲擬合出建物的平面結構。通過深度學習技術進行語意分割 (Semantic Segmentation)，自動分離出建物的開口處，如門窗，以實現 LoD3 建物模型的重建，成果如圖 1 所示。然而，其成果顯示山形屋頂的滴水線結構未能成功重建。此外，鑒於建物立面結構多數具有高度對稱性，如門窗等矩形結構，Liu *et al.* (2020) 採用了深度學習模型，並結合適用於高度對稱矩形結構的損失函數，成功提高了深度學習模型的預測精度，從近景影像中分割出立面中的元素。



圖 1 結合點雲平面擬合與語意分割技術所建置之 LoD3 建物模型 (Pantoja-Rosero *et al.*, 2022)

此外，運用衛星、航照影像或無人機影像進行建物分割的研究在大範圍的影像處理技術上亦獲得顯著的成果 (Buyukdemircioglu *et al.*, 2022)。衛星與航照影像因涵蓋範圍廣泛，適用於大規模地重建 LoD1 與 LoD2 的建物模型。多數研究往往透過萃取建物屋頂的外框輪廓與多邊形輪廓，結合立體像對解算所得的屋頂高程與數值表面模型 (Digital Surface Model, DSM) 數據，藉以進行建物模型的抬升重建 (Yu *et al.*, 2021、Zhang *et al.*, 2022a)。其中，全卷積網路 (Fully Convolutional Network, FCN) 因其適用於影像分割而廣泛應用。透過 FCN 架構，輸入影像的每個像素皆可產生相應的輸出，應用於建物分割時，能夠精確描繪建物的邊緣。利用專為建物分割設計的 MA-FCN 架構，結合正規化演算法來處理初始多邊形，可大規模且高效地從航照影像中萃取結構化的建物外框 (Wei *et al.*, 2020)，如圖 2 所示。此方法可處理矩形及圓形幾何，展現出較高的適應性。然而，大範圍的高解析度影像往往包含大

量的遮蔽物與干擾物，例如樹木、交通工具或陰影等，這些因素會增加建物分割的難度。為此，Abdollahi *et al.* (2020) 利用生成對抗網路 (Generative Adversarial Network, GAN) 模型，結合 SegNet 的編解碼架構，提升在複雜背景下的分割效能，增強模型抵抗雜訊的能力。此外，Schuegraf & Bittner (2019) 應用 U-Net 架構，訓練出可同時處理多光譜與 DSM 資訊的建物外框萃取模型，即便在低解析度的光譜影像中仍可獲得不錯的性能。然而，由於資料拍攝視角的限制，研究多僅能產製 LoD2 之建物模型。




圖 2 利用影像分割結合正規化演算法萃取航空影像中的建物外框 (Schuegraf & Bittner, 2019)。其中，第一列為原始影像；第二列為標記影像 (真值)；第三列為萃成果

1.2.2 無人機影像建物模型重建

影像建模首先需要對大量高重疊影像進行影像外方位解算，此過程包括相機姿態估計、影像特徵點萃取、特徵匹配以及方位解算，最終生成密集點雲數據。為獲得良好的資料處理成果，必須仰賴影像中準確可靠的幾何特徵，然而，在存在遮蔽物、光照變化或缺乏紋理的情況下，可能導致解算失敗。此外，獲取精確的影像外方位參數初始值也是影像建模中的一項挑戰 (Aharchi & Ait Kbir, 2020)。近年來，運動恢復結構 (Structure from Motion, SfM) 技術作為一種類似的資料處理方法，能夠從大量無序影像中自動恢復場景的幾何結構。SfM 強調線性解算步驟，並具有與攝影測量方法相似的資料處理步驟，包括特徵點萃取、八點演算法以及結合 RANSAC 的基本矩陣估計等 (Wang, 2013)。但是

SfM 同樣依賴影像中的特徵資訊進行解算，因此會仍面臨相同的資料處理挑戰。

現行的影像房屋模型重建策略除了針對影像生成之點雲進行處理外，直接從影像中萃取角點和邊緣線對也是常見的方法 (Faugeras *et al.*, 1998、Pu & Vosselman, 2009b)。其中，Wang *et al.* (2023b) 利用 Mean Shift 演算法對影像進行內容分割，以獲取建物範圍，並使用尺度不變特徵轉換 (Scale-Invariant Feature Transform, SIFT) 定位角點周圍，進而萃取出建物的近似邊界，最後使用霍夫轉換優化線段成果。在邊緣線偵測方面，Zhu *et al.* (2015) 將傾斜影像作為輸入數據可以獲取屋頂甚至立面的邊線資訊。通過從影像生成網格數據並萃取邊界線，結合平行、正交與對稱等幾何特性，構建線段間的位相關係，如圖 3 所示。將影像中偵測到的二維線段投影至三維模型中，進一步精煉線段結構，以處理遮陽板、滴水線等外凸區域。高重疊影像的優勢在於影像對之間具有較高的紋理相似性，可提高影像匹配的成功率，並提供更多交會觀測，有助於生成高精度數據。此外，Rau & Chen (2003) 利用建物邊緣線重建三維建物模型，提出了「分割—合併—成型」(Split-Merge-Shape, SMS) 演算法。該演算法通過將現有建物線段分割為多個房屋單元，並根據位向關係判斷是否需要進一步合併，最後對共面的部分進行處理，完成建物模型的成型。此方法能有效且快速地重建線段間的位相關係，其特點在於能處理不完整的線段，對於重建受遮蔽的建物具有一定的穩健性。




圖 3 建物外框線的位相精煉規則，包括平行、正交、對稱及高度相等條件 (Zhu *et al.*, 2015)

1.2.3 建物側向幾何重建

有別於 LoD2 建物模型僅需重建屋頂面結構，在實現更高細緻度與真實性的結構重建中，側向幾何尤其具有挑戰性。目前著重於側向結構的建物模型重建策略，仍然多依賴於多種遙測數據和載具平台的整合，藉以獲取優勢互補的數據資料進行建物模型重建。以點雲作為基礎，可透過整合 ATS 與 TLS 點雲資料補足資料幾何缺失部分。面對側向障礙與遮蔽的挑戰，仍多採用人工精練的濾除程序。相比之下，利用多視角無人機影像生成的點雲可以以較低成本獲取相對完整的幾何細節資訊，通過點雲聚類和特定幾何條件，可以重建特定性質的側向結構，如屋簷、屋頂窗和窗戶等。此外，Wang *et al.* (2016b) 利用模型資料庫作為先驗知識，結合語意分割技術對點雲進行分類，並進行模型導向建物模型重建。這類方法能在屋頂面和側面生成視覺化效果出色的模型，然而，細節結構將受限於資料庫內容。點雲和影像資料各有其優缺點，混合使用可以產生互補效果。例如，將點雲資料與傾斜影像結合使用，可彌補點雲在低紋理結構中表現不佳的問題，並且影像還可提供幾何形狀的約束條件。若進一步利用光譜影像與立面紋理特徵，可更精確地偵測出建物和開口位置 (Gruen *et al.*, 2019)。例如，Zhang *et al.* (2022b) 以既有的含紋理之 LoD2 建物模型作為輸入，針對紋理中的窗戶結構進行重建。該方法使用深度學習模型進行語意分割，對窗戶進行分群與對齊，並以幾何特性進行優化，最終將結果整合回原先的建物模型。然而，該方法目前僅能處理窗戶結構。而 Gadde *et al.* (2018) 開發了應用於影像資料與點雲的立面分割方法。類似研究除了常用的語意分割與聚類技術外，亦引入幾何約束規則於立面重建 (Mesolongitis & Stamos, 2012、Neuhausen & König, 2018)。

1.2.4 小結

綜上所述，本研究旨在以多視角無人機影像作為唯一資料來源，實現單棟建物的三維線框模型自動化重建，重點在於精確重建側向幾何資訊。研究

中採用學習式物件偵測模型來自動偵測建物的角點，並作為建物角點準確定位的初始資訊。此外，考量影像資料在實際收集過程中可能遇到的建物可視性限制及資料處理中的不合格角點，研究提出基於曼哈頓世界假設的虛擬角點重建演算法，以應對資料缺失問題。值得注意的是，此研究旨在基於低作業成本的條件下，僅使用無人機影像進行建物三維線框模型的自動重建，並確保線框模型滿足 CityGML 的 LoD3 精度規範，為後續的加值應用提供基礎模型。

2. 研究方法與架構

本研究提出的演算策略包含五個主要處理程序，資料前處理、角點特徵偵測模型、角點萃取演算法、角點三維坐標重建及位相關係重建。資料前處理程序乃通過影像方位解算來獲取影像的內、外方位參數，使用的資料包括垂直及傾斜拍攝的多視角無人機影像，為後續的空間坐標解算奠定基礎。角點特徵偵測模型旨在自動偵測建物角點位置區域，將角點特徵限制於特徵邊界框內，提高後續角點萃取的精度。後續的角點萃取演算法則是基於標界框中的角點特徵，運用提出的角點萃取演算法，自動定位角點的影像坐標。待經過多像幅的角點特徵匹配後使用多光束交會計算建物角點的三維坐標。最後，位相關係重建程序乃根據影像和幾何條件，建立角點之間的點線面關係，即位相關係。同時，為解決角點缺失問題，研究提出虛擬角點重建演算法，自動建置缺失的角點，以確保線框模型的合理性。演算程序最終將產生一組完整的建物三維線框模型，為後續應用提供基礎模型。圖 4 呈現本研究的資料演算流程。

2.1 資料前處理

本研究採用無人機影像作為數據來源，分為垂直拍攝與傾斜拍攝兩類資料。無人機的優勢包括低成本以及對氣象變化的高機動性，且普遍配備了直接定位系統，如衛星導航系統 (Global Navigation Satellite System, GNSS) 和慣性測量單元 (Inertial Measurement Unit, IMU)，能提供載具一定程度的三

維坐標和姿態初始值。為了獲得更可靠的方位參數，本研究利用立體視覺技術進行序列影像方位估計，並結合地面控制點，儘可能修正原始偏差，從而優化影像方位解算結果。

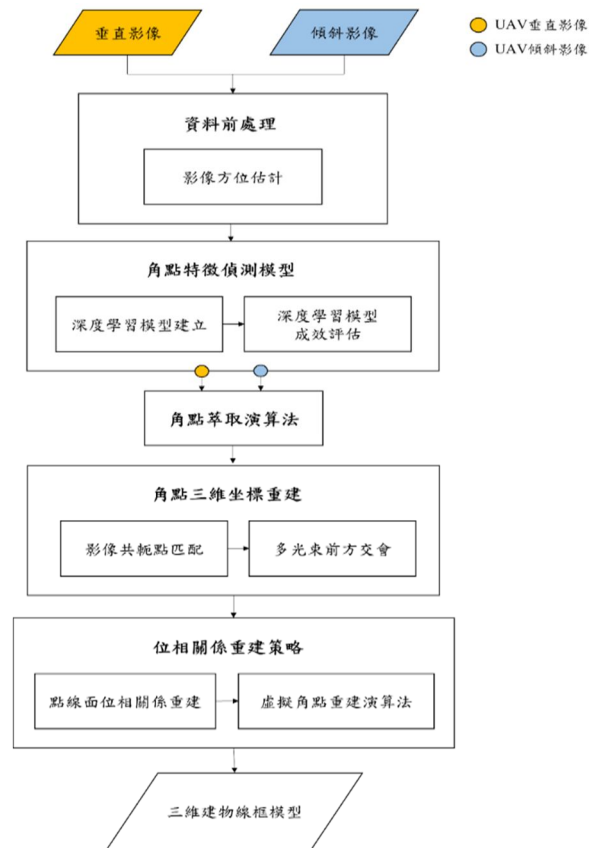


圖 4 演算流程架構圖

2.2 角點特徵偵測模型

影像辨識技術在電腦視覺領域取得了顯著突破，並持續有新演算法和架構被提出。著名的深度學習模型包括 Faster R-CNN、YOLO、SSD、Co-DETR 以及 EVA 等。本研究選擇深度學習影像物件辨識技術，以實現建物特徵角點區塊的自動化偵測，並致力於建立一個兼具精度、運算效率與穩健性的模型架構。因此，本研究將採用 YOLOv4 (Bochkovski *et al.*, 2020) 架構進行進一步的訓練和處理。值得注意的是，本研究不涉及對不同演算法的效能比較，所採用的模型可被更先進的演算法所替代。本研究採用微軟建置的 Common Objects in Context (COCO) 數據集進行模型預訓練，作為初始權重，旨在排除基礎常見物件的干擾，並提高模型

對於自定義物件的識別能力。在模型訓練之前，對收集的無人機影像資料進行了標註。本研究的深度學習模型訓練專注於建物角點特徵區塊的偵測，與大多數以整棟建築物為目標的深度學習模型不同。本研究將角點幾何轉折處作為邊界框的中心，如圖 5 所示，以便準確定位角點特徵區塊。




圖 5 建物角點特徵區塊作為標的物示意圖

深度學習模型的訓練過程中，使用了 1511 張 UAV 影像資料，共標註了約 19,082 個建物角點特徵區塊的邊界框，包括不同角度的重複角點特徵。為了確保模型的泛化能力，訓練、測試及驗證資料按 8:1:1 的比例進行分配。為統一影像尺寸並減少硬體負荷，影像被縮放至 608×608 像素。此外，考慮到航拍過程已規劃多視角拍攝，無需對影像進行旋轉處理，但為了增加資料的多樣性，採用資料擴增技術對影像的飽和度、曝光度及色調進行隨機調整。經過多次實驗，確定了 YOLOv4 模型的局部最佳超參數設定。在記憶體限制內，每批次 (Batch) 大小設為 8，使用二元交叉熵(Binary Cross-Entropy) 和完全交併度 (Complete IoU, CIoU) 作為損失函數，分別計算分類、可信度和位置的誤差。在誤差反向傳播 (Backward Propagation) 過程中，採用 SGD 優化器進行權重與偏差的調整，動量 (Momentum) 和衰減率 (Decay) 分別設定為 0.949 和 0.0005，初始學習率 (Learning Rate) 設為 0.001。為避免過度擬合 (Overfitting)，在第 80 和 90 個 Epoch 時，學習率將以 0.1 的比率進行衰減。本研究針對深度學習模型成效進行評估，使用三種常用於深度學習物件偵測的指標作為評估標準，包括陽性預測率 (Positive Predictive Value, PPV) 或稱精確率 (Precision)、召回率 (Recall) 及平均精確率 (Average Precision, AP)。模型性能評估基於預先分

類的測試資料作為真值，主要目的是評估角點特徵偵測在建物角點特徵區塊中的位置精度及物件類別分類的品質。此外，本研究將針對不同的 IoU (Intersection over Union) 閾值進行 AP 的評測，以全面評估模型在各種情境下的偵測效能。

2.3 角點萃取演算法

儘管影像處理領域已有多種基於影像灰階梯度變化的角點偵測元於。然而，由於缺乏幾何約束，這類演算法通常會偵測出多個點，難以將其準確定位於單一點上，難以滿足本研究的需求。為解決此問題，本研究引入了影像線段特徵萃取技術，並提出一套新的角點萃取演算法，演算法通過幾何約束條件來萃取出最佳的建物外邊角點位置，專注於從角點特徵區塊中確定唯一的建物角點幾何轉折處。演算流程架構如圖 6 所示。

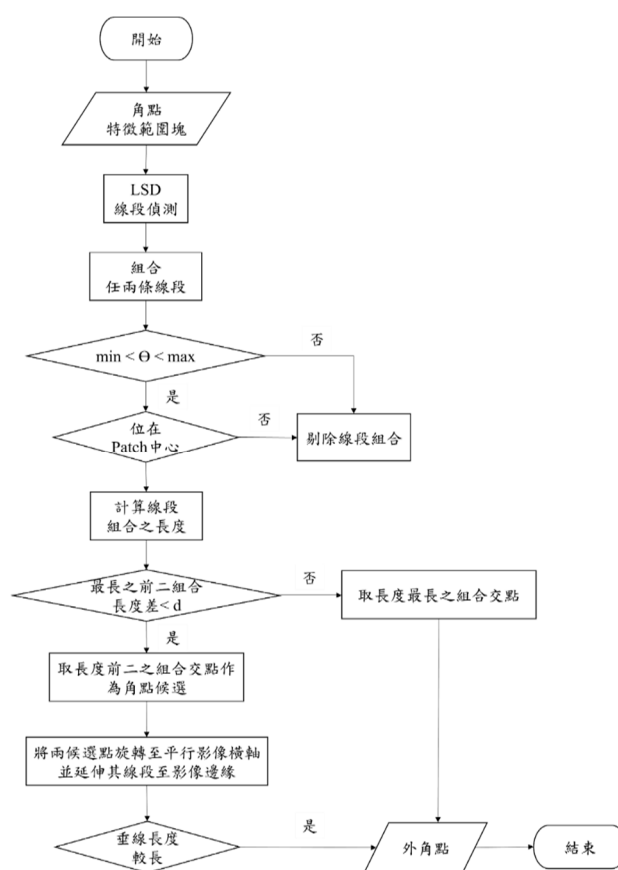


圖 6 角點萃取演算法之演算架構

角點萃取的演算策略中，利用深度學習角點特徵偵測模型所預測的角點區域作為偵測單位，進行

精細化處理。圖 7 與圖 8 分別展示了角點萃取演算法的示意圖與相應的虛擬碼。圖 7(a) 部分顯示了經由 Line Segment Detector (LSD) (Von Gioi *et al.*, 2012) 線段偵測元所萃取出線型特徵；圖 7(b) 部分展示了在角點區域中心(即黃色區域)中，選取夾角在核可範圍內的最長兩組線段組合，並由此交會出角點候選點，其中 w 為女兒牆寬度；圖 7(c) 部分則示意將這兩個候選點旋轉至平行於影像橫軸，並進行垂線長度的比較，選擇垂線較長者作為最終角點；圖 7(d) 部分展示了最終角點的示意圖，最終獲得的外側角點為單一像元。

使用 LSD 線段偵測元提取角點區域周圍的線型特徵。針對篩選出的線型特徵，進行兩兩交會並計算其之間的夾角。這些夾角必須符合預設的閾值才能保留該組線段組合。角點的閾值設置在垂直影像和傾斜影像中有所不同。在垂直影像中，大部分建物的角點夾角接近九十度，而傾斜影像則需要使用較寬的閾值進行篩選。此閾值為可調變參數，可根據待重建的建物型態進行設定。由於深度學習模型預測的角點特徵範圍應以角點轉折處為中心，

本研究將角點位置限縮於影像中心範圍內。如果線段組合所形成的角度符合規範，但其交會點不在中心範圍內，則會剔除該組合。此外，考慮到某些建物屋頂具有女兒牆結構，本演算策略針對內外牆部分進行判斷。研究主要關注整體建物的線框模型，並基於外側角點進行建構。在演算中，將保留外側角點並捨棄內部角點。在方法上，將兩組最長的線段組合的各別交會點視為候選點，並將這兩個候選點旋轉至平行於影像橫軸。隨後，從影像邊緣向候選點垂直投射，並依據外角的垂線比內角長的原則來判斷出外側角點。然而，角點萃取演算法在處理內凹結構時仍存在侷限性，難以準確獲得外側角點。針對內凹的女兒牆外牆結構，本研究提出了一種特殊的角點標籤方法以克服此問題，如圖 9 所示。具體而言，此特殊標籤方法並不以建物轉折處為中心，而是在標籤過程中，將女兒牆內側角點置於角點萃取演算法中的位置核可範圍外。透過這種方法，限縮了角點特徵區域的範圍，確保角點萃取演算法在處理過程中，不會將內側角點歸納為候選點。




圖 7 角點萃取演算法之示意圖

Algorithm Corner Extraction Algorithm

```

1: Function extractCorners(image)
2:   cornerFeatures = deepLearningCornerDetection(image)
3:   lineSegments = LSD(image)
4:   for each segment1 in lineSegments
5:     for each segment2 in lineSegments
6:       intersectionPoint = calculateIntersection(segment1, segment2)
7:       if isWithinCenterRegion(intersectionPoint, image) And
8:         meetsAngleThreshold(estimateAngle(segment1, segment2), image) And
9:         isOuterCorner(segment1, segment2)
10:        addCornerToResult(intersectionPoint)
11:       end if
12:     end for
13:   end for
14: end Function

```

圖 8 角點萃取演算法之虛擬碼



圖 9 內凹女兒牆結構之角點標籤方式

為評估角點萃取演算法的性能，研究中選擇了均方根誤差 (Root Mean Square Error, RMSE) 作為量化精度的指標。由於無人機影像具有高重疊率，因此處理的角點特徵範圍影像會產生大量數據。為了有效評估，本研究採用隨機取樣方法，對實驗區域中十分之一的角點影像的點位坐標進行人工判釋，並將這些數據視為真值。隨後，將角點萃取演算法獲得的點位坐標視為預測值，據此計算 RMSE，以評估演算法的精度。

2.4 角點三維坐標重建

經過前述演算程序可成功獲得建物角點的二維影像坐標。為了將這些影像角點轉換為三維絕對坐標系中的表示，本研究採用基於多影像的多光束前方交會法進行角點的三維坐標計算。針對在多視角高重疊序列影像中偵測到的建築角點，結合電腦視覺技術，逐一構建以角點為中心的特徵描述元。此程序的優勢在於所需建立的特徵描述元數量較少，並且在匹配和後續解算過程中能顯著減少計算量。隨後，通過對角點局部特徵進行影像特徵匹配 (Distance Ratio Matching)，建立影像間角點特徵的共軛關係，從而進一步執行空間前方交會，實現角點三維絕對空間坐標的精確估計。

多光束前方交會乃基於共線條件構成數學模型，如圖 10 所示。在假設光線直線傳播的情況下，影像的透視中心、像點與物點之間可建立共線條件方程式 (式 1)。利用多個共軛點及其外方位參數，可形成多組共軛光束的非線性方程式，從而解算角點的物空間坐標，其解算方程如式(2) 至式(5) 所示。理論上，相較於傳統的兩光束方法，多光束交會方法更具優勢，因為多組共軛光束能提供更多的觀測約束，有助於減少誤差並提高交會點位的精度，亦

能補償短基線造成的高程精度下降。在先前步驟中，已獲取所需的參數，包括內外方位參數及共軛點的影像坐標。由於共軛點坐標位於影像坐標系中，因此在解算之前，需將其轉換至像片坐標系，以確保在相同坐標框架下進行計算。




圖 10 多光束前方交會示意圖(Chuang & Sung, 2020)

$$\begin{aligned} x - x_0 &= -f \frac{m_{11}(X-X_L) + m_{12}(Y-Y_L) + m_{13}(Z-Z_L)}{m_{31}(X-X_L) + m_{32}(Y-Y_L) + m_{33}(Z-Z_L)} \\ y - y_0 &= -f \frac{m_{21}(X-X_L) + m_{22}(Y-Y_L) + m_{23}(Z-Z_L)}{m_{31}(X-X_L) + m_{32}(Y-Y_L) + m_{33}(Z-Z_L)} \end{aligned} \quad (1)$$

其中， f 為焦距； x 、 y 為像片坐標； X_L 、 Y_L 、 Z_L 為透視中心坐標； X 、 Y 、 Z 為點位之物空間坐標； $m_{11} \sim m_{33}$ 為由拍攝當下之姿態角構成的旋轉矩陣 $M_\kappa M_\phi M_\omega$ 計算而得之參數。點位之物空間坐標可利用最小二乘法中的附有參數之條件平差進行解算：

$$A\xi + (y + e) = d, e \sim (0, \Sigma = \sigma_0^2 P^{-1}) \dots \dots (2)$$

其中 y 、 e 、 d 、 ξ 及 P 代表觀測量向量、誤差向量、常數向量、未知參數及權矩陣。 A 為針對未知數偏微分之係數矩陣。式(2)可再改寫為式(3)：

$$A\xi + e = w \dots \dots (3)$$

其中，未知參數 ξ 可通過式(4)求得，而 $w = d - y$ 代表差異向量；式(5)則可用於計算後驗單位權方差作為平差模式之正確性檢核。 r 代表多於觀測數目。

$$\xi = (A^T P A)^{-1} A^T P w \dots \dots (4)$$

$$\hat{\sigma}_0^2 = e^T P e / r \dots \dots (5)$$

研究中使用密匹配技術取得高密度的點雲數據，並以人工方式進行點雲平面擬合。透過將擬合的平面進行交會獲得交會角，以此作為本研究之檢核點，視其為真值角點坐標。在精度評估分為平面

精度、垂直精度、點位精度等面項，其中點位精度是表示結合了平面與垂直精度的整體精度，三項精度皆採用 RMSE 作為精度指標，並以擬合平面所交出之點為作為檢核點。

2.5 位相關係重建

本研究採用幾何規則與拓撲約束規則的方法，通過三維角點的幾何資訊與二維影像中的線段特徵，構建建物的幾何結構，其中包括對弧形結構的處理。通過引入幾何規則，可確保所構建的建物線框模型在空間中的相對位置及形狀具備合理性。此外，針對可能發生的遮蔽現象與角點重建失敗問題，本研究設計虛擬角點重建演算法，該方法可在必要時補充缺失的角點，從而確保整體線框模型的完整性。以下分別說明重建線面關係、虛擬角點重建演算法與完整性評估等三個步驟。

2.5.1 點線面位相關係重建

如圖 11 所示，點與點之間的位相關係重建方法乃針對垂直與傾斜之二維原始影像進行 Canny 邊緣偵測與霍夫轉換，以萃取房屋影像邊緣線。接著，將已有的三維角點坐標反投影至對應的二維影像，以此重建三維角點之間的線段關係。在線段偵測過程中，由於房屋邊緣線可能呈現不完整的線段，本研究將對偵測到的每一條線段進行延伸。此外，由於反投影過程中的誤差及三維角點本身的偏差，反投影後的角點可能未落在影像中的建物轉折處。為此，本研究在判斷線段關係時設置了偏差容許範圍，並對延伸線進行兩側加寬。此偏差容許範圍根據影像品質和三維角點的精度進行設定。如此，可通過判斷延伸線段是否穿過任意兩個角點來確定角點之間的連線關係。

然而，在某些情況下，延伸線可能穿過超過兩個角點，如圖 12 所示。圖 12(a) 為示意圖，在本研究策略中，P1 與 P2 將被視為一條線段，而 P3 與 P4 將被視為另一條線段。圖 12(b) 則展示了一個實例案例。針對此情況，本研究僅為最接近原始線段的兩個角點賦予連線關係。此外，在反投影過程中，由於建物高度和遮蔽的影響，部分點位可能無法在

特定拍攝視角的影像中準確呈現。為了解決此問題，本研究設置了基於高程的評判條件，即針對可連成水平線段的點位，角點間的高程差異不可超過一定的門檻值。該門檻值除了依據三維角點的品質設定外，亦取決於欲重建之建物類型。例如，在山型屋頂的建物中，此門檻值應設置為較高。




圖 11 點與點的位相關係重建方法

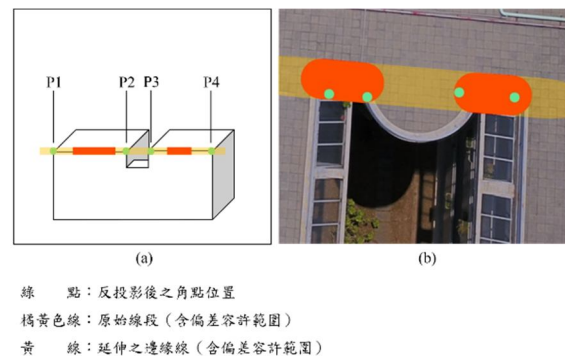


圖 12 延伸線上具有兩個以上角點之示意圖與案例

為了豐富可處理的幾何形態，本研究除了針對基礎的直線結構進行探討外，亦對弧形結構進行偵測，以重建弧形結構之房屋形態，如圖 13 所示。圖中，A 與 B 為位於霍夫圓偵測所得之圓形內的角點。通過距離轉換方法，可從像素分布中判別弧形的朝向。綠色點表示具有連貫性的像素，而藍色點則表示不具連貫性，故以綠色點較多的方向判定為弧形的朝向。P 點為 AB 線段以圓心 O 為中心，沿弧形朝向繪製鉛錘線後所形成的交點；a 與 b 則分別表示該圖形的半長軸與半短軸。




圖 13 弧形結構偵測策略

在此過程中，運用 Canny 邊緣偵測與霍夫圓偵測技術，旨在於二維影像中識別出圓形分布。霍夫圓偵測演算法允許設置篩選圓的大小，參考 CityGML 中對 LoD3 平面細緻度的規範，本研究將可被重建的弧形結構預設為長軸大於 2 m。同樣地，將三維角點反投影至二維影像中，針對已識別出的弧形進行進一步判斷，以確認是否存在兩個角點位於該弧形周圍。此周圍的範圍可設置偏差容許值。若弧形周圍的角點數量超過兩個，則篩選出最接近弧形直徑的兩個角點。接著，將這兩個角點的連線之中點視為圓心，並以圓心向弧形的朝向劃設鉛錘線。鉛錘線與圓形的交點即為該弧形的弧頂，圓心與該交點的距離及兩角點距離的一半將分別作為弧形的半短軸與半長軸。其中，弧形朝向的判定是利用距離轉換 (Distance Transform) 方法，通過影像中的像素差異來確定該弧形結構在圓形中的位置。最終，將保存兩個角點、圓心、弧頂的坐標，以及弧形的半長軸與半短軸資訊。

在初步建立線段資訊後，下一步驟是重建線與線之間的關係。所形成的平面將用於判斷體閉合狀態，並作為後續虛擬角點建置的依據。在此過程中，首先整理各線段相接的線段編號，並通過深度優先搜尋演算法 (Depth-First-Search, DFS) (Tarjan, 1972)，以樹狀結構的形式遍歷所有線段節點的連接關係。此階段通過編號進行搜尋，識別由線段節點所形成的閉合面。本研究期望獲得的面為平面，因此，對於具有多組法向量的面將不予紀錄。在執行策略中，

透過線段編號回推相關節點，即角點坐標，並運用三維角點坐標資訊，針對每一個閉合面計算其平面方程式，以判斷其是否為單一法向量平面。另一方面，若線段連結的終點位於一既有平面上，同樣視為閉合，此情況多見於具女兒牆結構的建物類型。如圖 14 所示，其中，黃色和綠色各為一單位閉合面，儘管在進行 DFS 時，兩者會被歸納為一組閉合面，但由於其發生轉折等因素，使得法向量不唯一，則會被拆分為不同面。



圖 14 單位閉合面之示意圖

2.5.2 虛擬角點重建演算法

在完成初步的線與面重建後，將進入虛擬角點重建演算法的環節，其演算流程如圖 15 所示。在本研究中，虛擬角點定義為在現實空間中實際存在，但因遮蔽或在先前過程中重建失敗而未被記錄的點位。虛擬角點重建演算法基於對稱性和點線面連結性原則，通過推論創建虛擬角點，以補充實際存在但重建失敗或被遮蔽的點位。該演算法的主要設計原則是用於補足建物底部以及陽台後側的不足，其實際應用情境如圖 16 所示。其中，圖 16(a) 之建物底部角點受樹木之遮蔽，導致無法呈現於照片中；圖 16(b) 則是受到視角與其他人為造物影響，導致部分陽台後側點位無法被自動識別。

在虛擬角點重建演算法中，多數程序遵循曼哈頓世界假設，即假定三維空間中的所有物體、牆壁、地板等皆由垂直與水平的直線構成，因此空間中的物體均符合直角幾何。虛擬角點重建演算法將持續迭代，直至實現體閉合才會結束。

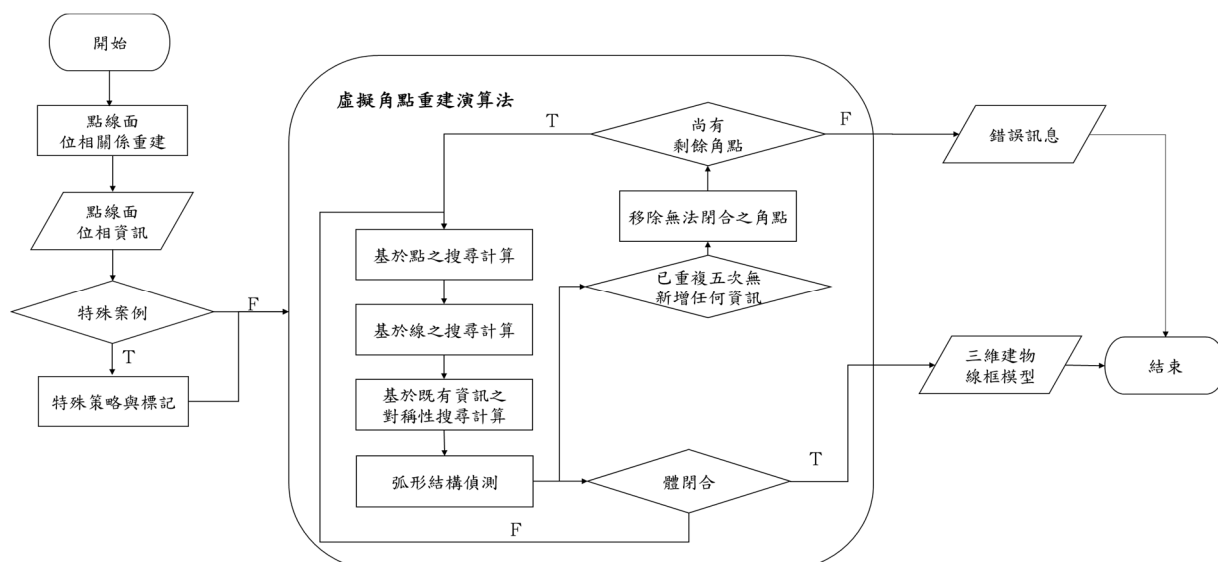


圖 15 虛擬角點重建演算法流程圖



圖 16 建物幾何角點受遮蔽之影像示意圖

演算流程依序進行基於點、基於線面、及基於既有資訊對稱性的搜尋。首先利用既有點重建合理的線段，並通過新生成的線段與既有線面及對稱性資訊進行後續重建。在基於線面搜尋的階段，會先運用圖 18 中的判斷式，隨後再執行圖 19 中的判斷。如果任一點無法達成閉合，則該點將自動被刪除，以完成體閉合並建構出閉合的線框模型(Watertight Wireframe Model)。具體規則與策略如下所述：

(1) 基於點之搜尋

- A. 基於曼哈頓世界假設
- B. 以任一點至少可以連結成兩條線為原則
- C. 目的在於重建線段資料
- D. 在線資料內搜索僅使用到一次或沒有跟任何點連成線段之點，並尋找與之最鄰近之面。針對僅使用到一次的點資料，將計算其線段與最鄰近之面邊緣線是否具平行關係，若在誤差容許範圍內，則對其進行線面重建，如圖 17 之

Case A 所示，在此過程中不會產生新的虛擬點，而是新增線段與面資料。若為單一點的情況，則計算該點與最鄰近面之最鄰近點是否可形成一條與最鄰近面垂直之線段，若可，則在此新增一條新的線段資料，如圖 17 之 Case B 所示。

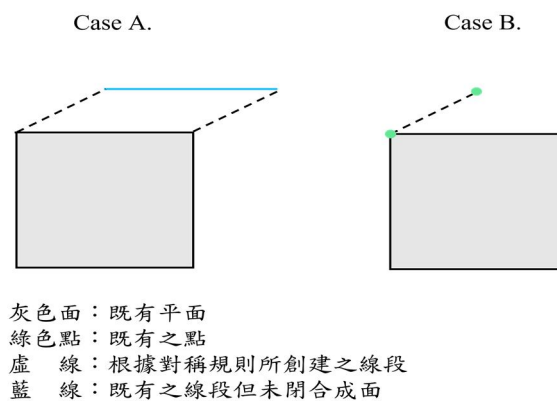


圖 17 基於點搜尋之線段重建示意圖

(2) 基於線面之搜尋

- 以所有線段皆具有鄰邊為假設；基於曼哈頓世界假設。
- 以任一線段至少可組成兩個面為原則。
- 目的在於重建虛擬點資料。
- 在面資料內搜索僅使用到一次的線段，暫稱此單一為 F1，於目標線段之轉折處，規劃一垂直於 F1 之平面 F2。若 F2 於其對稱方向已存在既有之面，則根據其對稱面之高程坐標以及目標線段之平面坐標賦予缺失點坐標，如圖 18 之 Case A 所示。若無，則將 F2 視為垂直於地平面之面，以參數最低起算高程之值作為其缺失點高程坐標，其餘則以對稱目標線為原則建置，如圖 18 之 Case B 所示。
- 使用上述 DFS 演算法，找出已連結部分卻未閉合之線段組合。首先，判定未閉合之兩端點連結是否可形成一對稱面，若是，則可徑直補足最後一條線段，添增一個面，如圖 19 之 Case A 所示。若否，則將既有之線段產生相互之對稱線段，並組成一面，如圖 19 之 Case B 所示。




圖 18 基於線段僅被單一面使用之角點重建示意圖




圖 19 基於未閉合之線段組合之角點重建示意圖

(3) 基於既有資訊之對稱性搜尋

- 不限於矩形面之假設，但僅限於水平方向面之線段組，且其實際之三條邊線關西需為兩條互相平行，並且各與第三條垂直。
- 既有之未閉合線段組僅有一組解可達到對稱，其狀況如圖 20 所示。
- 目的在於重建特殊對稱形狀之幾何。
- 在方法上將鎖定垂直之兩條邊線，分別取其中點劃設延伸之鉛錘線，並計算鉛錘線兩側之既有點到鉛錘線之距離與點數，若扣除缺少之點數後，兩側點到鉛錘線之距離皆相等，則以該鉛錘線為對稱性，重建出虛擬點。




圖 20 基於既有資訊之對稱性重建角點之示意圖

在特定情況下，以上規則及策略將不適用，包括具女兒牆的建物頂樓內側與山型屋屋頂與底面之連接，如圖 21 所示。由於這些結構的特殊性，於進入虛擬角點建置環節前，將針對這兩種情況先行進行自動化判斷。首先，是否為具女兒牆之建物頂樓內側，將透過內外側面積比較及角點位置的相近程度進行判斷。針對該區域，本研究設定允許其以單一面形式存在，不需要透過其他線或面進行搜尋與整合，且內外牆皆不受限於單一法向量之面約束。山型屋的判斷則基於該區域最高高程的面結構之斜率。山型屋頂並不採用將屋頂角點直接向下連結以生成線面的方案。若真實的底面角點已被重建，則將其直接向上連接至屋頂平面，並在相交處建立一個屬於屋頂平面與底面連接之虛擬角點。若資料中未包含底面角點資訊，則依據屋頂角點的位置，向內縮一定距離，並結合最低起算高程參數，創建虛擬角點。隨後，將底部角點向上連接至屋頂平面，並賦予一虛擬角點以完成線段連結。




圖 21 虛擬角點重建演算法中之特殊案例。其中，(a)箭頭處示意具女兒牆之建物頂樓內側、(b)箭頭處示意山型屋之滴水線結構

3. 測試驗證

3.1 獨棟建物三維線框模型重建

為了驗證本研究提出方法之成效，實驗中針對四棟建築物進行重建並分析其成果表現。包括國立陽明交通大學工程二館、苗栗縣大湖鄉台三線之白色民宿、苗栗縣大湖鄉南湖國中的健行館及育賢館，如圖 22 所示，以下將分別稱之為建物一至建物四。

此測試使用 DJI Mavic Pro 無人機進行資料蒐集，建物一的資料蒐集配置為採用 4.73 mm 之焦距分別以 50 m 及 45 m 之航高進行垂直及傾斜拍攝，對應之地面取樣距離為 0.017 m 及 0.022 m。其中，垂直拍攝之前後與左右重疊率為 80% 及 70%；建物二之資料蒐集配置為採用 4.76 mm 之焦距分別以 40 m 及 30 m 之航高進行垂直及傾斜拍攝，對應之地面取樣距離為 0.013 m 及 0.013 m。其中，垂直拍攝之前後與左右重疊率為 90% 及 80%；建物三與建物四則採用 6.09 mm 之焦距分別以 45 m 及 25 m 之航高進行垂直及傾斜拍攝，對應之地面取樣距離為

0.012 m 及 0.014 m。其中，垂直拍攝之前後與左右重疊率為 80% 及 80%。

針對與角點獲取相關的前三項程序，包括角點特徵偵測模型預測、角點萃取演算法與角點三維坐標重建進行成果分析，其對應成果列於表 2 至表 4。角點特徵偵測模型預測的成果如圖 23 所示。

可以發現使用整棟建物的所有影像進行預測時，成果表現更加出色。儘管整棟建物的複雜度較高，但標準且清晰的建物角點占整體建物的比例較高，這有助於提升整體的精確率與召回率。同理，表 3 在角點萃取的結果中，若角點特徵區域清晰且無干擾，則其成果相對會有所提升；而建物三、四，其特色在於鐵皮屋頂、條狀紋理及周圍環繞的水管，這些特徵匯集了許多干擾因素，導致角點萃取演算法較易發生錯誤偵測，故其精度相對較低。從表 4 中可以發現，建物三與建物四的平均點位精度相對較差，其中建物三的最差精度甚至達到 40 cm。

經由位相關係重建程序後，建物線框模型的成果如圖 24 與所示。其中，圖 24(a) 為線框模型上視圖；圖 24(b) 為線框模型側視圖；圖 24(c) 與 (d) 分別為線框模型上視圖與側視圖之對照影像；圖 24(e) 為線框模型檢核上視圖；圖 24(f) 為線框模型檢核側視圖。而圖 24 中之藍色點為一般點；紅色點為虛擬點；綠色點為女兒牆內部平台之點。類似地，圖 25(a) 為線框模型上視圖；圖 25(b) 為線框模型側視圖；圖 25(c) 與 (d) 分別為線框模型上視圖與側視圖之對照影像；圖 25(e) 為線框模型檢核上視圖；圖 25(f) 為線框模型檢核側視圖，藍色點為一般點；紅色點為虛擬點。



交大光復校區工程二館
(建物一)

苗栗縣大湖鄉台三線之民宿
(建物二)

苗栗縣大湖鄉南湖國中
(建物三與建物四)

圖 22 實現建物影像

表 2 角點特徵偵測模型用於預測整棟建物之表現

| | 角點特徵偵測模型 | | | | | |
|-----|-----------|--------|------|------------------|------------------|------------------|
| | Precision | Recall | AP | AP ₅₀ | AP ₇₅ | AP ₉₀ |
| 建物一 | 0.99 | 0.95 | 0.56 | 0.96 | 0.79 | 0 |
| 建物二 | 1.00 | 0.96 | 0.48 | 0.92 | 0.60 | 0 |
| 建物三 | 0.98 | 0.88 | 0.51 | 0.94 | 0.72 | 0 |
| 建物四 | 0.99 | 0.91 | 0.53 | 0.94 | 0.76 | 0.02 |




圖 23 角點特徵偵測模型預測結果

表 3 角點萃取演算法成果精度

| | RMSE (px) |
|-----|-----------|
| 建物一 | 6.3 |
| 建物二 | 5.7 |
| 建物三 | 11.1 |
| 建物四 | 8.0 |

表 4 角點三維坐標重建成果精度

| 單位：m | 建物一 | 建物二 | 建物三 | 建物四 |
|-----------|------|------|------|------|
| 平面精度 | 0.17 | 0.15 | 0.19 | 0.17 |
| 高程精度 | 0.18 | 0.15 | 0.21 | 0.21 |
| 點位精度 | 0.25 | 0.21 | 0.28 | 0.27 |
| 精度最高之平面精度 | 0.07 | 0.06 | 0.04 | 0.05 |
| 精度最高之高程精度 | 0.04 | 0.07 | 0.08 | 0.06 |
| 精度最高之點位精度 | 0.08 | 0.09 | 0.09 | 0.08 |
| 精度最低之平面精度 | 0.24 | 0.18 | 0.31 | 0.24 |
| 精度最低之高程精度 | 0.24 | 0.24 | 0.28 | 0.23 |
| 精度最低之點位精度 | 0.34 | 0.30 | 0.42 | 0.33 |

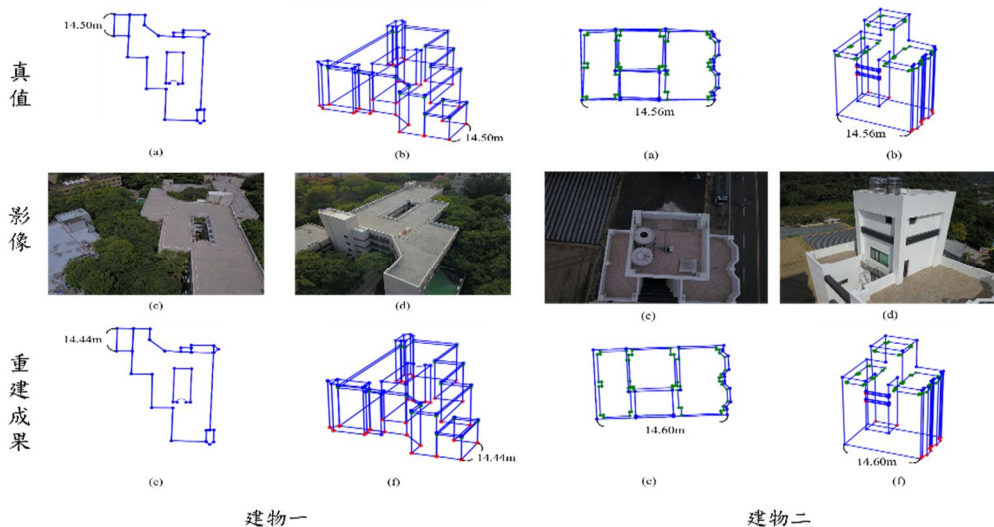


圖 24 建物一與二之線框角點偵測成果對照圖，(a)與(c)為上視圖；(b)與(d)為側視圖

建物模型的等角圖則如圖 26 所示，而位相關係重建的完整性記錄於表 5 中。本次實驗中，對於近水平面進行了高程平差，使得結果更加合理。從表中的數據可以看出，整體線段重建效果極佳。在一般點與虛擬點部分，虛擬點有效地彌補了一般點的缺失，使得重建出的線框模型具有更高的完整性。其中，建物一的線段匹配率 (MR) 為 0.01。未能重建出的線段均位於五邊形幾何形狀內，由於受最大閉合面運算影響而被移除。

點特徵範圍預測和角點萃取方面表現優異。這主要歸因於整體建物中標準且乾淨的角點數量足夠，使得角點特徵偵測模型可獲得良好的精確率和召回率。在角點萃取結果以建物一與建物二的表現較佳，可歸因於這兩個建物的特徵區域較為清晰且無雜訊。相對而言，建物三和建物四的資料具有挑戰性，其條紋狀鐵皮屋頂和周圍的水管等特徵容易引起角點萃取演算法的誤偵測，導致較低的精度。除此之外，位相關係重建的結果顯示一般點和虛擬點的重建獲得了實際效用，成功地填補了缺失點位，使最終的線框模型更加完整。

3.2 成果討論

依據實驗成果可以觀察到整體建物的重建在角

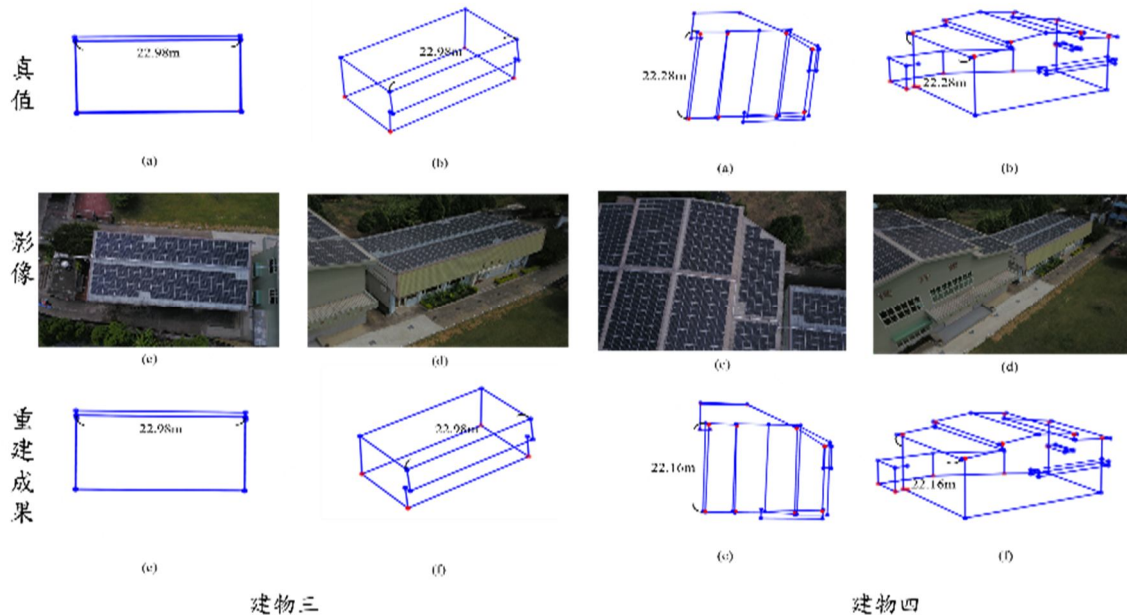


圖 25 建物三與四之線框角點偵測成果對照圖，(a)與(c)為上視圖；(b)與(d)為側視圖




圖 26 建物三維線框模型重建成果，(a)至(d)為建物一至建物四

表 5 建物線框模型完整性評估

| | 一般點 | | | 虛擬點 | | | 整體點 | | | 線段 | | |
|-----|------|----------------|------|------|----------------|----|------|----------------|----|------|----------------|------|
| | 總檢驗數 | F ₁ | MR | 總檢驗數 | F ₁ | MR | 總檢驗數 | F ₁ | MR | 總檢驗數 | F ₁ | MR |
| 建物一 | 63 | 0.99 | 0.02 | 38 | 1.00 | 0 | 100 | 1.00 | 0 | 137 | 0.99 | 0.01 |
| 建物二 | 113 | 0.98 | 0.04 | 20 | 1.00 | 0 | 128 | 1.00 | 0 | 157 | 1.00 | 0 |
| 建物三 | 8 | 1.00 | 0 | 4 | 1.00 | 0 | 12 | 1.00 | 0 | 17 | 1.00 | 0 |
| 建物四 | 44 | 0.99 | 0.02 | 15 | 1.00 | 0 | 58 | 1.00 | 0 | 62 | 1.00 | 0 |

總體而言，所重建的模型在精度上符合 LoD3 的要求，平均精度約為 30 cm，最佳點位的精度可達到 10 cm 內。與其它研究相比，本研究的優勢主要體現在以下幾個方面：

- (1) 具側向結構物：大多數自動化重建研究中，立面結構的重建主要集中於如門窗等開口的偵測，而本研究提出的框架則針對整體建物的結構進行重建，這為後續細緻的 LoD3 建物模型搭建提供了不同的貢獻。
- (2) 對複雜建物的適應性：本研究處理的建物型態包括山型屋頂、具女兒牆的建物、弧形結構及側向結構（如陽台、水泥雨遮等）。在紋理方面，研究涵蓋了條狀鐵皮、條紋狀牆面與格狀地板。儘管每一項都有進步空間，但研究確實能成功自動化重建多種複雜建物，且平均精度達到 30 cm。
- (3) 虛擬角點重建演算法：為達到自動化建模的穩健性，本研究提出了一套虛擬角點重建演算法，以增強所建構之建物線框模型的合理性與穩健性。
- (4) 保留原始結構型態：本研究旨在盡可能保留建物原有型態，減少水平平面的簡化，僅對高程進行平差，最大限度地保留弧形結構、五邊型屋頂、複雜的女兒牆結構等非矩形特徵。

4. 結論

本研究提出基於多視角無人機影像的建物線框模型自動化處理框架。有別於多數現行研究，聚焦於使用單一資料源，基於無人機影像數據進行建物重建，強調資料獲取迅速、成本較低、精度適中、演算高度自動化等優勢。研究提出的演算策略結合深度學習模型自動偵測建物角點特徵，並提出精確定位角點之演算法，實現具側向結構建物的自動化重建。整體平均精度達到 30 cm 內，符合 LoD3 的精度要求，且整體點線重建完整性超過 98%。研究成果有助於協助 LoD3 或更精細建物模型的建置任務，提升作業效率。

儘管本研究實現了具側向幾何資訊的建物模型自動化重建，演算方法上仍存在限制和挑戰，需在後續研究進行探討和解決。本研究的建物線框模

型建置框架在很大程度上依賴於影像中的特徵資訊。與大多數研究相似，採用影像資料將不可避免地面臨陰影、反光及覆蓋物的影響，這些因素會影響角點的精度，甚至影響模型的完整性。為此，研究過程中只能盡量避免遮蔽嚴重的區域。若僅為部分遮蔽，尚可依賴虛擬角點重建演算法進行處理；然而，若遮蔽超過一定比例或關鍵點缺失，本方法將難以有效適用。另一方面，本研究提出的虛擬角點重建演算法多基於曼哈頓世界假設，因此虛擬重建出的幾何形態多為矩形。針對影像中未被拍攝或無法拍攝的區域，除非進行現地考證，否則無法驗證其是否真為矩形。因此，本研究所產製的線框模型僅可作為建物的基礎模型，對於掌握度較低的建物，仍需依賴人工進行後續檢核與修正。同時，鑑於三維模型細緻度的需求，在實務操作中，要在城市尺度下實現自動化的三維建物模型重建仍然面臨諸多挑戰。現行上多針對具特殊意義之建築進行 LoD3 等級的建模。如何在資料收集、資料運算策略及演算效能方面，實現大規模且高精度、高細緻度的自動化模型建置，依然是有待解決的課題。

參考文獻

- Abdollahi, A., Pradhan, B., Gite, S., and Alamri, A., 2020. Building footprint extraction from high resolution aerial images using Generative Adversarial Network (GAN) architecture, *IEEE Access*, 8: 209517–209527, DOI: 10.1109/ACCESS.2020.3038225.
- Aharchi, M., and Ait Kbir, M., 2020. A review on 3D reconstruction techniques from 2D images, Presented at the Innovations in Smart Cities Applications Edition 3: The Proceedings of the 4th International Conference on Smart City Applications 4, Springer, pp. 510–522, DOI: 10.1007/978-3-030-37629-1_37.
- Bochkovskiy, A., Wang, C.-Y., and Liao, H.-Y.M., 2020. Yolov4: Optimal speed and accuracy of object detection, arXiv preprint arXiv:2004.10934, DOI: 10.48550/arXiv.2004.10934.

- Buyukdemircioglu, M., Kocaman, S., and Kada, M., 2022. Deep learning for 3D building reconstruction: A review, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B2-2022: 359–366, DOI: 10.5194/isprs-archives-XLIII-B2-2022-359-2022.
- Chen, D., Zhang, L., Mathiopoulos, P.T. and Huang, X., 2014. A methodology for automated segmentation and reconstruction of urban 3-D buildings from ALS point clouds, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7: 4199–4217, DOI: 10.1109/JSTARS.2014.2349003.
- Chuang, T.Y., and Sung, C.C., 2020. Learning and SLAM based decision support platform for sewer inspection, *Remote Sensing*, 12(6): 968, DOI: 10.3390/rs12060968.
- Faugeras, O., Robert, L., Laveau, S., Csurka, G., Zeller, C., Gauclin, C., and Zoghiani, I., 1998. 3-D reconstruction of urban scenes from image sequences, *Computer Vision and Image Understanding*, 69(3): 292–309, DOI: 10.1006/cviu.1998.0665.
- Flamanc, D., Maillet, G., and Jibrini, H., 2003. 3D city models: An operational approach using aerial images and cadastral maps, *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 34: 53–58.
- Gadde, R., Jampani, V., Marlet, R., and Gehler, P.V., 2018. Efficient 2D and 3D facade segmentation using auto-context, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40: 1273–1280, DOI: 10.1109/TPAMI.2017.2696526.
- Gruen, A., Schubiger, S., Qin, R., Schrotter, G., Xiong, B., Li, J., Ling, X., Xiao, C., Yao, S., and Nuesch, F., 2019. Semantically enriched high resolution LoD 3 building model generation, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42: 11–18, DOI: 10.5194/isprs-archives-XLII-4-W15-11-2019.
- Gui, S., and Qin, R., 2021. Automated LoD-2 model reconstruction from very-high-resolution satellite-derived digital surface model and orthophoto, *ISPRS Journal of Photogrammetry and Remote Sensing*, 181: 1–19, DOI: 10.1016/j.isprsjprs.2021.08.025.
- Huang, H., Michelini, M., Schmitz, M., Roth, L., and Mayer, H., 2020. LOD3 building reconstruction from multi-source images, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43: 427–434, DOI: 10.5194/isprs-archives-XLIII-B2-2020-427-2020.
- Klimkowska, A., Cavazzi, S., Leach, R., and Grebby, S., 2022. Detailed three-dimensional building Façade reconstruction: A review on applications, data and technologies, *Remote Sensing*, 14(11): 2579, DOI: 10.3390/rs14112579.
- Liu, H., Xu, Y., Zhang, J., Zhu, J., Li, Y., and Hoi, S.C., 2020. DeepFacade: A deep learning approach to facade parsing with symmetric loss, *IEEE Transactions on Multimedia*, 22(12): 3153–3165, DOI: 10.1109/TMM.2020.2971431.
- Ma, R., 2005. Building model reconstruction from LIDAR data and aerial photographs (Ph.D.), ProQuest Dissertations and Theses, The Ohio State University, United States.
- Malihi, S., Valadan Zoej, M., Hahn, M., Mokhtarzade, M., and Arefi, H., 2016. 3D building reconstruction using dense photogrammetric point cloud, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41: 71–74, DOI: 10.5194/isprs-archives-XLI-B3-71-2016.
- McClune, A.P., Mills, J.P., Miller, P.E., and Holland, D.A., 2016. Automatic 3D building reconstruction

- from a dense image matching dataset, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41: 641–648, DOI: 10.5194/isprs-archives-XLI-B3-641-2016.
- Mesolongitis, A., and Stamos, I., 2012. Detection of windows in point clouds of urban scenes, in *proceedings of the 2012 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, Providence, USA, pp. 17–24, DOI: 10.1109/CVPRW.2012.6238910.
- Murtiyoso, A., Veriandi, M., Suwardhi, D., Soeksmantono, B., and Harto, A.B., 2020. Automatic Workflow for roof extraction and generation of 3D citygml models from low-cost uav image-derived point clouds, *ISPRS International Journal of Geo-Information*, 9(12): 743, DOI: 10.3390/ijgi9120743.
- Neuhausen, M., and König, M., 2018. Automatic window detection in facade images, *Automation in Construction*, 96: 527–539, DOI: 10.1016/j.autcon.2018.10.007.
- Pantoja-Rosero, B.G., Achanta, R., Kozinski, M., Fua, P., Perez-Cruz, F., and Beyer, K., 2022. Generating LOD3 building models from structure-from-motion and semantic segmentation, *Automation in Construction*, 141: 104430, DOI: 10.1016/j.autcon.2022.104430.
- Pu, S., and Vosselman, G., 2009a. Knowledge based reconstruction of building models from terrestrial laser scanning data, *ISPRS Journal of Photogrammetry and Remote Sensing*, 64: 575–584, DOI: 10.1016/j.isprsjprs.2009.04.001.
- Pu, S., and Vosselman, G., 2009b. Building facade reconstruction by fusing terrestrial laser points and images, *Sensors*, 9: 4525–4542, DOI: 10.3390/s90604525.
- Rau, J.-Y., and Chen, L.-C., 2003. Robust reconstruction of building models from three-dimensional line segments, *Photogrammetric Engineering & Remote Sensing*, 69: 181–188, DOI: 10.14358/PERS.69.2.181.
- Schuegraf, P., and Bittner, K., 2019. Automatic building footprint extraction from multi-resolution remote sensing images using a hybrid FCN, *ISPRS International Journal of Geo-Information*, 8(4): 191, DOI: 10.3390/ijgi8040191.
- Tarjan, R., 1972. Depth-first search and linear graph algorithms, *SIAM Journal on Computing*, 1(2): 146–160, DOI: 10.1137/0201010.
- Von Gioi, R.G., Jakubowicz, J., Morel, J.-M., and Randall, G., 2012. LSD: A line segment detector, *Image Processing On Line*, 2: 35–55, DOI: 10.5201/ipol.2012.gjmr-lsd.
- Wang, F., Zhou, G., Hu, H., Wang, Y., Fu, B., Li, S., and Xie, J., 2023a. Reconstruction of LoD-2 building models guided by Façade structures from oblique photogrammetric point cloud, *Remote Sensing*, 15(2): 400, DOI: 10.3390/rs15020400.
- Wang, J., Xu, Y., Remil, O., Xie, X., Ye, N., Yi, C., and Wei, M., 2016a. Automatic modeling of urban facades from raw LiDAR point data, *Computer Graphics Forum*, 35(7): 269–278, DOI: 10.1111/cgf.13024.
- Wang, M., Yuan, S., and Pan, J., 2023b. Building detection in high resolution satellite urban image using segmentation, corner detection combined with adaptive windowed hough transform, in *proceedings of the 2013 IEEE International Geoscience and Remote Sensing Symposium - IGARSS*, Australia, pp. 508–511, DOI: 10.1109/IGARSS.2013.6721204.
- Wang, Q., Yan, L., Zhang, L., Ai, H., and Lin, X., 2016b. A semantic modelling framework-based method for building reconstruction from point clouds, *Remote Sensing*, 8(9): 737, DOI: 10.3390/rs8090737.

- Wang, R., 2013. 3D building modeling using images and LiDAR: A review, *International Journal of Image and Data Fusion*, 4: 273–292, DOI: 10.1080/19479832.2013.811124.
- Wei, S., Ji, S., and Lu, M., 2020. Toward automatic building footprint delineation from aerial images using CNN and regularization, *IEEE Transactions on Geoscience and Remote Sensing*, 58: 2178–2189, DOI: 10.1109/TGRS.2019.2954461.
- Wen, X., Xie, H., Liu, H., and Yan, L., 2019. Accurate reconstruction of the LoD3 building model by integrating multi-source point clouds and oblique remote sensing imagery, *ISPRS International Journal of Geo-Information*, 8(3): 135, DOI: 10.3390/ijgi8030135.
- Yu, D., Ji, S., Liu, J., and Wei, S., 2021. Automatic 3D building reconstruction from multi-view aerial images with deep learning, *ISPRS Journal of Photogrammetry and Remote Sensing*, 171: 155–170, DOI: 10.1016/j.isprsjprs.2020.11.011.
- Zhang, C., Cui, Y., Zhu, Z., Jiang, S., and Jiang, W., 2022a. Building height extraction from GF-7 satellite images based on roof contour constrained stereo matching, *Remote Sensing*, 14(7): 1566, DOI: 10.3390/rs14071566.
- Zhang, X., Chen, K., Johan, H., and Erdt, M., 2022b. A semantics-aware method for adding 3D window details to textured LoD2 CityGML models, in *proceedings of the 2022 International Conference on Cyberworlds (CW)*, Japan, pp. 63–70, DOI: 10.1109/CW55638.2022.00018.
- Zhu, Q., Jiang, W., and Zhang, J., 2015. Feature line based building detection and reconstruction from oblique airborne imagery, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40: 199–204, DOI: 10.5194/isprsarchives-XL-4-W5-199-2015.

Automatic UAV Image Reconstruction for 3D Building Wireframe Models

Yu-Ling Huang¹ Tzu-Yi Chuang^{2*}

Abstract

3D building data is vital in smart city planning, management, and energy assessment. However, constructing accurate 3D models for existing buildings remains challenging due to the labor-intensive processes and insufficient automation. This study proposes an algorithmic strategy based on multi-view UAV imagery to generate 3D wireframe models with detailed lateral geometric features, serving as a foundation for constructing 3D building models of existing structures. This approach aims to improve operational efficiency and reduce costs. The algorithm employs a pre-trained corner detection model and a novel corner extraction algorithm, utilizing a "coarse-to-fine" strategy to achieve precise corner localization. Additionally, a virtual corner reconstruction strategy is employed to mitigate the inevitable occlusion and data loss in urban UAV imagery. Experimental results demonstrate that this algorithmic strategy adapts well to buildings with curved architectural structures, achieving an average corner localization accuracy of approximately 30 cm and up to 98% completeness in wireframe reconstruction.

Keywords: Multi-View UAV Imagery, Image Modeling, Automated Building Wireframe Reconstruction, Wireframe Models, Deep Learning

¹ Master, Department of Civil Engineering, National Yang Ming Chiao Tung University

² Associate Professor, Department of Civil Engineering, National Yang Ming Chiao Tung University

* Corresponding Author, E-mail: jytschuang@nycu.edu.tw

Received Date: Aug. 14, 2024

Revised Date: Sep. 09, 2024

Accepted Date: Sep. 11, 2024

結合溫室氣體排放、綠蔽度衛星影像與土地利用資料的環境溫度機器學習預測模型開發

張皓庭¹ 陳映融² 柳婉郁^{3,4} 吳治達^{5,6,7*}

摘要

本研究綜合考量了溫室氣體、環境和人為活動相關變數，以利用大數據與五種機器學習演算，包含：隨機森林 (RF)、梯度提升 (GBR)、輕量梯度提升 (LGBMR)、類別提升 (CBR) 和極限梯度提升 (XGBoost) 來建立兩種溫室氣體 CO₂ 和 CH₄ 推估環境溫度的模型，其中 LGBMR 模型在 CO₂ 方面表現最佳，而 XGBR 模型在 CH₄ 方面效果較好。CO₂ 和 CH₄ 推估環境溫度模型的表現，R²值分別為 0.993 和 0.999。SHAP 值的分析確認了溫室氣體濃度、濕度、風速等因素對預測的關鍵影響。本研究成果為溫室氣體減排策略提供了新的評估方法，並為全球氣候變化研究與政策制定提供了重要參考，凸顯了跨學科合作的重要性。

關鍵詞：環境溫度、二氧化碳、甲烷、機器學習預測模型、機器學習演算法

1. 前言

面對全球暖化日益嚴峻的挑戰，深入理解並有效控制溫室氣體排放已成為一項急迫且至關重要的任務。自工業革命以來，我們見證了煤炭和石化燃料的大量使用不僅大幅增加了二氧化碳 (Carbon Dioxide, CO₂) 的排放量，還導致其他溫室氣體，如甲烷 (Methane, CH₄) 和氧化亞氮 (Nitrous oxide, N₂O) 等，大量進入大氣層。這些溫室氣體的累積不僅加劇了溫室效應，而且顯著推動了全球暖化現象，進而引發了一連串的環境、社會經濟，以及公共健康問題 (IPCC, 2022、World Health Organization, 2021)。

在全球性挑戰下，國際社會已經積極行動起來。從 1992 年聯合國氣候變遷綱要公約 (United Nations Framework Convention for Climate Change, UNFCCC) 的通過開始，全球各國一直在共同努力

減少溫室氣體排放。特別是在 2015 年的巴黎協定 (Paris Agreement) 確立之後，各國紛紛制定了更加明確和具體的減排目標 (UNFCCC, 2015)。臺灣在這全球共同應對氣候變化的大背景下，也積極參與其中，不僅制定了「溫室氣體減量及管理法」，而且進一步修訂為「氣候變遷因應法」，銘記著到 2050 年達到淨零排放的宏偉目標。

然而，目前的減排努力主要集中在控制排放源上，而尚未直接針對溫室氣體在環境中的實際濃度進行深入研究。考慮到溫室氣體在大氣中的長期存在及其對環境的深遠影響，迫切需要一種能直接評估減排策略對大氣中溫室氣體濃度影響的方法。因此，本研究旨在運用先進的大數據分析和機器學習技術，建立一個機器學習預測模型，以深入探究溫室氣體濃度與環境溫度之間的相互關係。相對於過去的研究，本研究更進一步考慮了溫室氣體、環境，以及人為活動相關的變數，以建立更全面的模型，

¹ 國立成功大學測量及空間資訊學系 博士後研究員

² 國立成功大學測量及空間資訊學系 研究助理

³ 國立中興大學森林學系 特聘教授

⁴ 國立中興大學永續農業創新發展中心 特聘教授

⁵ 國立成功大學測量及空間資訊學系 教授

⁶ 國家衛生研究院國家環境醫學研究所 兼任研究員

⁷ 國立中興大學永續農業創新發展中心 兼任教授

* 通訊作者, E-mail: chidawu@mail.ncku.edu.tw

收到日期：民國 113 年 02 月 26 日

修改日期：民國 113 年 05 月 09 日

接受日期：民國 113 年 05 月 31 日

用以推估環境溫度的變化。我們致力於捕捉模型中的溫室氣體監測資料，以及與環境和人為活動相關的多項資料，進一步揭示它們與環境溫度之間的潛在趨勢。研究的目標在於實現對臺灣環境中溫室氣體濃度對環境溫度變化的準確預測。在建模過程中，將運用 SHAP 值深入研究溫室氣體與環境溫度之間的相關性。這項研究的重要性不僅體現在對臺灣應對氣候變化的理論和實踐層面的貢獻，同時也為全球氣候變化策略提供了有價值的參考。透過深入了解溫室氣體與環境溫度之間的複雜關係，有望為制定更有效的環境政策和氣候變遷適應策略提供具體的科學基礎。本研究的成果將有助於推動全球範圍內更可持續的發展和氣候變化防控工作。

2. 材料及方法

本研究計畫旨在結合過去在空氣污染模擬方面的豐富經驗，融合土地利用迴歸、機械學習和集成學習等多元方法學，旨在開發一套創新的溫室氣體濃度估計環境溫度的機器學習預測模型。圖 1 展示了本研究的整體流程，其中涵蓋了以下關鍵階段：(1) 資料庫準備 (Database preparation)；(2) 運用自動機器學習 (AutoML) 技術構建預測模型 (Leveraging SHAP values to choose variables and AutoML to streamline algorithm enhancement and model development)；(3) 進行模型的驗證與評估 (Assessment of algorithm effectiveness and outcome confirmation in machine learning models)。接下來，將詳細介紹每個階段的具體操作流程。

2.1 資料庫準備

本研究運用了 ArcMap 10.8 軟體的核心功能，即環域 (buffer) 空間分析，以進行溫室氣體排放源與溫度的深入探究。具體而言，研究團隊計算了測站周圍方圓 50 m 至 5000 m 的 14 個不同環域範圍內，溫室氣體排放與溫度相關的空間排放源分佈密度。此外，本研究還涵蓋了測站與這些排放源之間的最短距離、測站所處的海拔和地形等重要的地理環境特徵。研究總共收集了約四百多個與空間排放源相關的變數，為後續的分析工作提供了豐富的數

據基礎。關於這些變數和資料庫的詳細圖示和介紹，將在接下來的研究材料部分展示。此外，為了建立完整的模型並進行測試和驗證，我們對收集到的研究資料進行了時間段分割，涵蓋 2000 年至 2019 年。將 2000 年至 2018 年的資料分為訓練集 (Training dataset) 和測試集 (Testing dataset)，其中 80% 作為訓練集用於模型開發，20% 作為測試集用於模型初步測試。2019 年的測量數據則作為獨立的外部數據 (External dataset) 來驗證模型的性能，不會納入模型構建過程中。

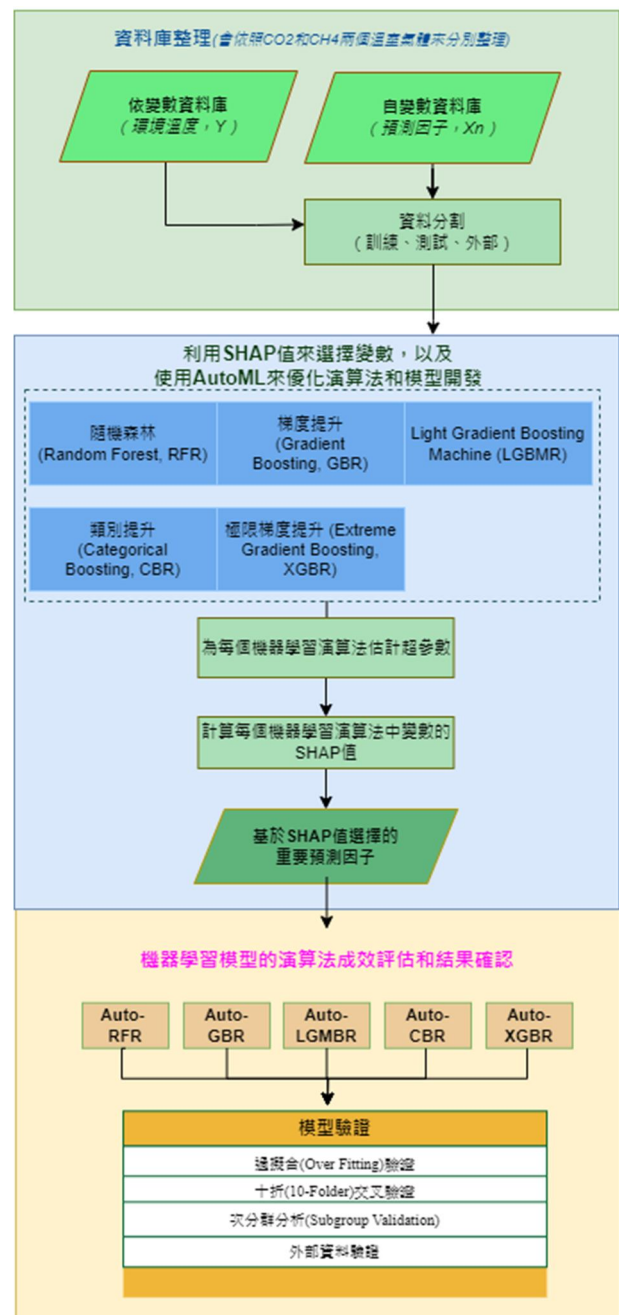


圖 1 研究流程圖

2.1.1 溫室氣體與氣象監測資料庫

環境部於臺灣本島設立了約 76 個空氣品質監測站，這些站點不僅專注於空氣品質的監控，同時也追蹤溫室氣體濃度的變化。具體來說，目前有 6 個和 37 個監測站分別對 CO₂ 和 CH₄ 濃度進行持續的監測和記錄（詳見圖 2）。除 CH₄ 外，這些監測站還對各種空氣污染物（例如：細懸浮微粒、懸浮微粒、氮氧化物等）和氣象因素（如：溫度、降雨量、相對濕度等）進行追蹤。本研究搜集公開溫度數據（涵蓋 2000 年至 2019 年），以及相同時段的 CO₂（2000 年至 2019 年）和 CH₄（2002 年至 2019 年）日平均監測數據，作為研究建模的基礎。

另外，根據既往研究，溫度、其他氣象因子、空氣污染與溫室氣體濃度分布之間有顯著關係 (Ramanathan & Feng, 2009)。因此，本研究將利用研究團隊以往使用土地利用迴歸和 XGBoost 演算法估算出的臺灣 PM_{2.5}、NO₂ 和 O₃ 濃度分布 (Hsu *et al.*, 2019、Wong *et al.*, 2021a、Wong *et al.*, 2021b) 作為解釋變數。這些方法在估算臺灣全島 PM_{2.5}、NO₂ 和 O₃ 的時空變異時，準確度分別達到了 94%、91% 和 92%，經過多次驗證後，模型的穩定性和可靠性得到了證實。至於氣象資料，包括相對濕度、風速、風向、降雨量和紫外線等，則是來自中央氣象局的資料庫，這些數據經過普通克利金法處理後，研究使用溫室氣體監測站的點位萃取出的氣象數值，這些數據能夠反映全臺灣氣象狀況的分布，為研究接下來溫室氣體推估模型的分析提供了有力的數據支持。此外，本研究根據臺灣的地理座標和研究時間，額外計算和整理了太陽天頂角和太陽赤緯角等變數。

2.1.2 MODIS 衛星觀測之環境綠蔽度資料庫

鑑於全球環境變遷的重要性，美國國家航空暨太空總署 (National Aeronautics and Space Administration, NASA) 運用先進的遙測技術和衛星資源，建立了地球觀測系統 (Earth Observing System, EOS)。該系統致力於長期監測地球的大氣

層、水圈、生物圈以及植被等關鍵地表參數的變化。這些珍貴的資料由在美國地質調查所 (The U.S. Geological Survey, USGS) 整理後，為全球學者和專家提供了重要的學術研究資源。本研究將利用 EOS 系統中的 MOD13Q1 第 6 版全球植被監測資料庫，來估算區域環境的綠蔽度。這些資料基於 Moderate Resolution Imaging Spectroradiometer (MODIS) 衛星的紅光 (645 納米) 和近紅外光 (858 納米) 波段，進行常態化植生差異指標 (Normalized Difference Vegetation Index, NDVI) 的計算，空間解析度為 250 m×250 m。自 2000 年 2 月起，每 16 天生成一次的全球綠蔽度監測資料，已被 NASA 和 USGS 透過多時期的地表觀測驗證，確保了第 6 版 NDVI 產品的準確性，可靠地支持學術發表 (USGS, 2020)。考慮到植物和森林在減少溫室氣體排放、碳固定與受溫度影響方面的關鍵作用，本研究根據兩種溫室氣體監測數據庫的時間軸，來準備相對應時間長度的環境綠蔽度資料庫。此外，本研究利用 ArcGIS Pro 提供的“最近鄰取樣”函數，將 250 m 空間分辨率的 NDVI 放大至 50 m。這種重新取樣技術是在影像處理中使用的，其目的是識別原始資料的最近值 (Brandsma & Können, 2006)。該技術的優點在於保持原始值，同時避免在資料之間進行插值，確保了原始值在重新取樣後的資料中被保留。通過在放大後保持準確性，該函數在重新取樣的資料中盡可能地複製了原始值。

2.1.3 全國土地利用調查資料

本研究利用由內政部國土測繪中心進行的第三次全國土地利用調查數據，目的在於收集與溫度、溫室氣體排放等相關的土地利用資料。該調查的土地分類系統採用層次化樹狀結構，分為三個層級。例如，在第三次調查中，第一級分類涵蓋了農業、森林、交通、建設、公共設施、休閒娛樂、採礦、鹽業以及其他土地使用等 9 大類；第二級對這些大類進一步細化為 61 小類；而第三級則基於第二級，進行更細分的劃分，如稻田等 101 個細分類別。本研究選取其中具有代表性的類別，如住宅區、國際機場、畜牧業、水稻農田、垃圾掩埋場、鐵路、道

路、製造業、污水處理設施、水體等，作為預測變數，並整合實驗的數據庫。此外，與環境綠覆率密切相關的土地利用類型，如植被、森林、公園綠地等，也被納入考量，作為估計環境綠蔽度的第二種指標。

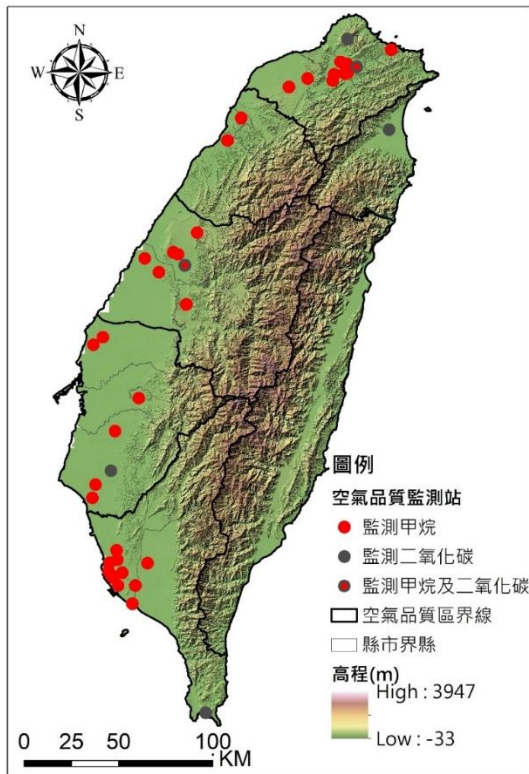


圖 2 環境部甲烷及二氧化碳測站空間分佈圖

2.1.4 地理標記資料庫

本研究所採用的地標數據資源，主要來自於勤崙國際科技股份有限公司建立的 Point of Interest (POI) 地標資料庫，以及環境部所提供的全臺灣焚化爐煙囪位置資料。POI 資料庫，作為 Google Earth 和 Google Map 中的重要地標資訊來源，不僅豐富了地圖的內容，也提供了實時的地理參考資訊。這個資料庫每季更新一次，並且按照三個層次組織：主要分類、次要分類和具體細項。為了與本研究的時間範圍相符，研究特別選用了 2004 年、2006 年、2008 年及 2010 年的 POI 數據。在主分類中，包括政府機構、公共事業、金融證券等 12 至 14 個大類，進一步細分為 119 至 160 的次分類，以及 920 至 1,350 的具體細項。本研究將從 POI 資料庫

中提取寺廟、中式餐廳、火力發電廠等特定地標的座標信息。另外，關於焚化爐煙囪的資料，則是從環境部在政府開放資料平臺 (MOI Open Data) 上所發布的官方開放數據中獲得。

2.1.5 路網數值圖

鑒於能源相關活動，如煤炭燃燒、石油使用和交通運輸，是溫室氣體排放和改變溫度的主要來源之一，本研究計劃利用交通部運輸研究所提供的 2010 年和 2015 年全臺灣 1/5000 比例尺的 GIS 路網數值圖，以收集交通排放相關的關鍵數據，用於建立模型。這些路網數據根據其特性，將臺灣的道路分類為國道、省道、縣道及鄉道等八大類別。本研究使用這些路網數值圖，將道路進行更精細的分類：主要道路（包括國道、省道、縣道及市區快速道路）、地方道路（包括市區道路、鄉道、產業道路及無名道路）以及所有類型的道路，從而提供各類道路的密度資訊，以支持我們的研究分析。

2.1.6 數值地形模型資料

本研究中使用的數值地形模型 (Digital Terrain Model, DTM) 是將臺灣地區細致劃分成一系列規則的網格，並在這些網格的每一點記錄相應的海拔高度。這些數據被儲存於 GIS 系統中，以便進行深入的地形分析。考慮到地形特徵，如：海拔高度，可能與溫室氣體排放源或是與溫度改變之間存在關聯，並可能對溫室氣體濃度或溫度的變化產生影響，本研究選擇採用由中華民國農業部航測的最新數據，該數據提供了 20 m×20 m 解析度的全臺灣數值地形模型。通過這些數據，本研究將收集測站周圍地區的海拔、坡度、坡向等關鍵地形資訊，以支持使用溫室氣體來估算溫度的研究分析。

2.1.7 工業區綜合資料庫

自 1970 年起，經濟部工業局致力於引領與促進臺灣工業的全面發展，其職責範圍涵蓋了制定工業發展策略、管理工業區開發，以及處理工業環境污染問題等重要任務。為了深入研究工業活動對環境的影響，本研究引入了經濟部工業局所提供的

2010 年與 2015 年臺灣各主要加工出口區與科學園區的地理資訊系統 (Geographic Information System, GIS) 數據。這些數據將協助研究精確地分析工業區分布對環境因素的相互作用及其可能的影響。

2.1.8 溫室氣體排放清冊資料庫

本研究依據環境部依據溫室氣體減量及管理法 (溫管法) 第 13 條之規定，以及聯合國政府間氣候變化專門委員會 (Intergovernmental Panel on Climate Change, IPCC) 在 2006 年發布的《國家溫室氣體清冊指南》(2006 IPCC Guidelines for National Greenhouse Gas Inventories) 所採納的統計方法，進行了詳實的資料整合。環境部每年更新並發布《中華民國國家溫室氣體清冊報告》，詳細記錄自 1990 年起我國溫室氣體排放及吸收的趨勢。

本研究主要分析我國最新版的《中華民國國家溫室氣體排放清冊報告 (2021 年版)》，該報告綜合了全臺灣各年度的溫室氣體排放數據。此外，亦從各縣市政府的溫室氣體管制執行方案中搜集資料，整合各地區的溫室氣體排放量，以建立一個全面且精確的溫室氣體排放清冊資料庫。這些資料將為研究建立溫室氣體濃度推估溫度模型提供關鍵支持，助研究更深入了解和應對氣候變化的挑戰。所有上述的空間資料及相關資訊已整合於表 1 中。表格內容包括：資料來源 (例如資料庫)、變數、單位、地理統計格式 (例如網格大小)、以及時間解析度或時間點。

2.2 運用自動機器學習技術構建預測模型

本研究以 CO₂ 和 CH₄ 兩種溫室氣體為基準，分別建立轉換環境溫度的模型。模型的依變數為環境溫度，自變數包括溫室氣體 (CO₂、CH₄)、環境綠蔭度資料、國土地利用調查資料、地理標記資料、路網數據、數值地形模型資料以及工業區綜合資料。為了建立模型，採用了五種不同的機器學習演算法：隨機森林 (Random Forest, RF)、梯度提升 (Gradient Boosting Regressor, GBR)、輕量梯度提升 (Light Gradient Boosting Machine Regressor, LGBMR)、類

別提升 (CatBoost Regressor, CBR) 和極限梯度提升 (eXtreme Gradient Boosting, XGBoost)。這些演算法各具特色：隨機森林通過建立多個迴歸樹來提升計算效能；梯度提升通過迭代弱分類器來優化模型；輕量梯度提升在維持高準確度的同時，擁有更快的訓練速度和較低的記憶體需求；類別提升強化了對類別特徵的支持；極限梯度提升結合了並行與串行建樹技術，在減少過擬合的同時實現更優的預測效果。這五個演算法的公式如下：

(1) 隨機森林公式

A. 建樹：

- 對於每棵樹，從訓練集隨機抽取一個有放回的樣本子集 (bootstrap sampling)。
- 對於每個節點，隨機選擇特徵子集，基於這些特徵構建最佳分裂。

B. 集成：

- 對於分類問題，取所有樹的投票結果的多數作為最終預測。
- 對於迴歸問題，取所有樹的預測平均值作為最終預測。

(2) 梯度提升公式

A. 初始化模型 $F_0(x)$ 為常數值 (如訓練集目標值的平均)。

B. 對於每一步 $m = 1, 2, \dots, M$ ：

- 計算當前模型的殘差 $ri^{(m)} = yi - F_{m-1}(xi)$ 。
- 基於殘差訓練一個新的樹 $h_m(x)$ 。
- 更新模型 $F_m(x) = F_{m-1}(x) + \eta h_m(x)$ ，其中 η 是學習率。

(3) 輕量梯度提升公式

- ##### A. 使用直方圖算法來加速尋找最佳分裂點。
- ##### B. 使用基於葉子的增量 (Leaf-wise Growth) 來構建樹，而不是基於層的增量 (Level-wise Growth)，從而提高效率和準確性。

(4) 類別提升公式

- ##### A. 使用 Ordered Boosting 技術，在構建每個新的樹時，避免信息洩漏。
- ##### B. 使用目標編碼 (Target Encoding) 來處理類別特徵。

表 1 在模型建構中使用的可能預測變項及其數據來源

| 資料來源 (資料庫) | 變數 | 單位 | 地理統計格式 (網格大小) | 時間解析度/時間點 |
|-----------------------------------|-------------------|--------------------|------------------|-------------------------|
| 環境部 (溫室氣體、空污和環境溫度氣象監測資料庫) | CO ₂ | ppm | 網格 (50 m) | 逐時資料/2000 年至 2019 年 |
| | CH ₄ | ppm | | |
| | O ₃ | ppb | | |
| | PM _{2.5} | µg/m ³ | | |
| | NO ₂ | ppm | | |
| | 環境溫度 | °C | | |
| 中央氣象署 (氣象監測資料庫) | 溫度 | °C | 網格 (50 m) | 逐時資料/2000 年至 2019 年 |
| | 降雨量 | mm | | |
| | 風速 | m/s | | |
| | 相對濕度 | % | | |
| | 風向 | 360 度 | | |
| | 紫外線 | UVI | | |
| 自行計算 (太陽天頂角赤緯角) | 太陽天頂角 | ° | 網格 (50 m) | 逐時資料/2000 年至 2019 年 |
| | 太陽赤緯角 | ° | | |
| 美國國家航空暨太空總署 (MODIS 衛星觀測之環境綠蔽度資料庫) | 常態化植生差異指標 | - | 網格 (50 m) | 16 天/2000 年至 2019 年 |
| 內政部國土測繪中心 (全國土地利用調查資料) | 住宅區 | - | 密度/最近距離 (50 m) | 2015 年 |
| | 國際機場 | | | |
| | 畜牧業 | | | |
| | 水稻農田 | | | |
| | 垃圾掩埋場 | | | |
| | 鐵路 | | | |
| | 道路 | | | |
| | 製造業 | | | |
| | 污水處理設施 | | | |
| | 水體 | | | |
| | 植被 | | | |
| | 森林 | | | |
| 勤崙國際科技股份有限公司 (地理標記資料庫) | 寺廟 | - | 密度/最近距離 (50 m) | 2004、2006、2008 和 2010 年 |
| | 中式餐廳 | | | |
| | 火力發電廠 | | | |
| 交通部 (路網數值圖) | 主要道路 | - | 密度/最近距離 (50 m) | 2010 年和 2015 年 |
| | 地方道路 | | | |
| | 所有類型的道路 | | | |
| 中華民國農業部 (數值地形模型資料) | 海拔高度 | m | 網格 (20 m) | 2016 年 |
| | 坡度 | ° | | |
| | 坡向 | 360 度 | | |
| 經濟部工業局 (工業區綜合資料庫) | 加工出口區 | - | 密度 / 最近距離 (50 m) | 2010 年和 2015 年 |
| | 科學園區 | | | |
| 環境部 (溫室氣體排放清冊資料庫) | 溫室氣體排放量 | 千公噸 二氧化碳 碳當量 | - | 2000 年至 2019 年 |

(5) 極限梯度提升公式：

A. 初始化模型 $F_0(x)$ 為常數值。

B. 對於每一步 $m = 1, 2, \dots, M$ ：

定義目標函數： $L(m) = \sum_{i=1}^n l(y_i, F_{m-1}(x_i) + fm(x_i)) + \Omega(fm)$

其中 l 是損失函數， Ω 示正則化項。

訓練新的數 $fm(x)$ 以最小化目標函數。

更新模型 $F_m(x) = F_{m-1}(x) + \eta fm(x)$

在建模過程中，引入了自動機器學習(AutoML)技術來自動化演算法的超參數優化。接著，對每個演算法中的所有變數進行 Shapley Additive exPlanations (SHAP) 值計算，這些 SHAP 值代表了變數對模型的貢獻程度。因此，SHAP 值越大的變數在模型中越重要。在選擇模型中的變數時，首先考慮變數值的大小順序及其對模型解釋量的貢獻度；如果連續兩次新增變數的解釋增加量小於 0.01，則視為變數篩選的終點。

為了評估模型的效能，將使用相關係數 (r)、判定係數 (R^2) 以及校正後判定係數 (Adjusted R^2) 來衡量模型的準確度。同時，也將採用平均絕對誤差 (MAE)、均方誤差 (MSE) 和均方根誤差 (RMSE) 來衡量模型誤差。根據這些指標的表現，將對各演算法進行排序，並以準確度高、誤差小為原則，最終確定最合適的演算法。

2.3 進行模型的驗證與評估

在本研究中，從先前提及的五種機器學習演算法中挑選出解釋能力最佳的一種作為最終模型。為了確保所選演算法的穩定性和有效性，採用了四種不同的方法來進行模型的穩定性 (Robustness) 測試與驗證，包括：過擬合驗證 (Overfitting validation)、十折交叉驗證 (10-fold cross-validation, 10-fold CV)、次分群分析 (Subgroup validation) 以及外部資料驗證 (External validation)。這些方法的具體說明如下：

(1) 過擬合驗證：通過比較訓練集和測試集計算出的 R^2 值之間的差異來檢驗模型。如果這兩者之間的差異不超過 0.1，則可以認為模型沒有發生過擬合現象。

(2) 十折交叉驗證：這一方法旨在測試模型效能的

穩定性。將整體樣本分成十等份，每次選取其中九份作為訓練集，剩餘一份作為測試集。這個過程重複十次，以確保每一份樣本都有機會作為測試集。通過這種方式，能夠更準確地評估模型的預測準確度和穩定性。

(3) 次分群分析：這一方法評估模型在不同時間單位下的預測能力差異，包括春、夏、秋、冬四季及研究期間 2000 年至 2019 年各年的數據。將資料按不同季節和年份進行分層，然後分別計算每個分層的模型解釋力，進行比較分析。

(4) 外部資料驗證：使用 2019 年的資料來驗證基於 2000 至 2018 年資料所建立的模型。其目的是評估模型的外推能力是否良好。

通過這四種驗證方法的綜合應用，能夠全面評估所選演算法的效能，保證模型的可靠性和準確性。

3. 結果

3.1 描述性統計分析：建構溫室氣體轉換對環境溫度影響的模型變數

本研究分別針對 CO_2 和 CH_4 建立了溫室氣體轉換環境溫度的模型。模型建立時所挑選到的變數呈現於表 2。從表中可觀察到，建立 CO_2 和 CH_4 轉換環境溫度模型所使用到的樣本數依序為 23,223 與 294,475 筆。 CO_2 轉換環境溫度的模型中選到的變數 (研究期間的平均值) 除了 CO_2 (415.67 ppm) 本身，還有溫度 (22.92 °C)、濕度 (79.02%)、風速 (1.66 m/s)、雨量 (6.48 mm)、數值高程模型 (16.55 m)、NDVI (0.25)、150m 方圓範圍內佔地比建築物 (0.41)、太陽天頂角 (24.32°) 和太陽赤緯角 (0.12°)。 CH_4 轉換環境溫度的模型中選到的變數除了 CH_4 (2.01 ppm) 本身，還有溫度 (23.22 °C)、濕度 (77.7%)、風速 (1.76 m/s)、雨量 (5.58 mm)、數值高程模型 (34.42 m)、NDVI (0.24)、2500 m 方圓範圍內佔地比建築物 (0.32)、太陽天頂角 (23.91) 和太陽赤緯角 (0.13)。

表 2 建立溫室氣體轉換環境溫度模型的變數描述性統計

| Variable | CO ₂ 模型 (N=23,223) | | | | CH ₄ 模型 (N=294,475) | | | | 變數中文名稱 |
|--------------------------------|-------------------------------|-------|--------|--------|--------------------------------|-------|--------|-------|-------------------------|
| | 平均值 | 標準差 | 最小值 | 最大值 | 平均值 | 標準差 | 最小值 | 最大值 | |
| AMB_TEMP (°C) | 23.87 | 5.06 | 5.5 | 33.8 | 24.07 | 4.97 | 0.02 | 37.14 | 環境溫度 |
| CO ₂ (ppm) | 415.67 | 19.24 | 234.52 | 533.25 | - | - | - | - | 二氧化碳 |
| CH ₄ (ppm) | - | - | - | - | 2.01 | 0.27 | 0 | 8.78 | 甲烷 |
| TH01 (°C) | 22.92 | 4.95 | 4.24 | 32.57 | 23.22 | 4.91 | 3.79 | 32.79 | 溫度 (由氣象測站資料進行空間內插) |
| RH01 (%) | 79.02 | 8.02 | 34.6 | 99.78 | 77.7 | 7.58 | 28.45 | 99.84 | 濕度 (由氣象測站資料進行空間內插) |
| WD01 (m/s) | 1.66 | 0.81 | 0.06 | 12.24 | 1.76 | 0.95 | 0.02 | 13.32 | 風速 (由氣象測站資料進行空間內插) |
| PP01 (mm) | 6.48 | 20.48 | 0 | 569.85 | 5.58 | 19.03 | 0 | 642 | 雨量 (由氣象測站資料進行空間內插) |
| Dem (m) | 16.55 | 16.09 | 5 | 44 | 34.42 | 67.58 | 1 | 448 | 數值高程模型 |
| NDVI | 0.25 | 0.12 | 0.01 | 0.74 | 0.24 | 0.12 | -0.01 | 0.94 | 常態化植生差異指標 |
| LUIT_B1_B150 (Cover ratio) | 0.41 | 0.44 | 0 | 1 | - | - | - | - | 建築物 (150m 方圓範圍內佔地比) |
| LUIT_B1_B2500 (Cover ratio) | - | - | - | - | 0.32 | 0.27 | 0 | 0.93 | 建築物 (2500m 方圓範圍內佔地比) |
| Solar_Zenith (°) | 24.32 | 16.41 | 0.26 | 48.53 | 23.91 | 16.4 | 0.01 | 48.62 | 太陽天頂角 |
| Solar_Declination (°) | 0.12 | 16.43 | -23.44 | 23.44 | 0.13 | 16.45 | -23.44 | 23.44 | 太陽赤緯角 |

表 3 五個機器學習演算法建立溫室氣體轉換環境溫度模型之結果

| Outcome Algorithm | Temperature (CO ₂) | | | | | Temperature (CH ₄) | | | | | |
|------------------------------------|--------------------------------|-------|-------|--------------|-------|--------------------------------|--------------|-------|-------|-------|-------|
| | GBR | XGBR | CBR | LGBMR | RFR | GBR | XGBR | CBR | LGBMR | RFR | |
| Training dataset (80%) | R square | 0.997 | 0.989 | 0.992 | 0.993 | 0.988 | 0.985 | 0.999 | 0.979 | 0.983 | 0.992 |
| | Adjusted R square | 0.997 | 0.989 | 0.992 | 0.993 | 0.988 | 0.985 | 0.999 | 0.979 | 0.983 | 0.992 |
| | RMSE | 0.3 | 0.533 | 0.456 | 0.416 | 0.566 | 0.611 | 0.056 | 0.729 | 0.648 | 0.449 |
| | MSE | 0.09 | 0.284 | 0.208 | 0.173 | 0.32 | 0.374 | 0.003 | 0.531 | 0.42 | 0.202 |
| | MAE | 0.146 | 0.301 | 0.259 | 0.258 | 0.292 | 0.3 | 0.017 | 0.383 | 0.359 | 0.213 |
| Testing dataset (20%) | R square | 0.982 | 0.98 | 0.982 | 0.98 | 0.973 | 0.978 | 0.981 | 0.977 | 0.978 | 0.975 |
| | Adjusted R square | 0.981 | 0.98 | 0.982 | 0.98 | 0.973 | 0.978 | 0.981 | 0.977 | 0.978 | 0.975 |
| | RMSE | 0.687 | 0.717 | 0.681 | 0.716 | 0.836 | 0.742 | 0.685 | 0.761 | 0.739 | 0.783 |
| | MSE | 0.472 | 0.513 | 0.463 | 0.512 | 0.698 | 0.551 | 0.469 | 0.579 | 0.547 | 0.613 |
| | MAE | 0.366 | 0.409 | 0.383 | 0.392 | 0.467 | 0.388 | 0.327 | 0.399 | 0.399 | 0.414 |
| 10-fold cross-validation | R square | 0.981 | 0.979 | 0.981 | 0.98 | 0.973 | 0.978 | 0.98 | 0.976 | 0.978 | 0.975 |
| | Adjusted R square | 0.981 | 0.979 | 0.981 | 0.98 | 0.973 | 0.978 | 0.98 | 0.976 | 0.978 | 0.975 |
| | RMSE | 0.71 | 0.735 | 0.703 | 0.733 | 0.848 | 0.746 | 0.701 | 0.769 | 0.747 | 0.797 |
| | MSE | 0.504 | 0.54 | 0.495 | 0.537 | 0.719 | 0.556 | 0.492 | 0.591 | 0.559 | 0.635 |
| | MAE | 0.381 | 0.41 | 0.386 | 0.399 | 0.469 | 0.38 | 0.334 | 0.397 | 0.399 | 0.419 |
| External validation | R square | 0.977 | 0.974 | 0.975 | 0.979 | 0.98 | 0.981 | 0.982 | 0.983 | 0.981 | 0.979 |
| | Adjusted R square | 0.977 | 0.974 | 0.975 | 0.978 | 0.98 | 0.981 | 0.982 | 0.983 | 0.981 | 0.979 |
| | RMSE | 0.775 | 0.801 | 0.803 | 0.757 | 0.743 | 0.595 | 0.58 | 0.565 | 0.584 | 0.622 |
| | MSE | 0.601 | 0.642 | 0.645 | 0.573 | 0.551 | 0.354 | 0.337 | 0.32 | 0.341 | 0.386 |
| | MAE | 0.408 | 0.408 | 0.448 | 0.379 | 0.396 | 0.338 | 0.32 | 0.31 | 0.335 | 0.368 |
| Averaged validation MAE* | 0.394 | 0.409 | 0.417 | 0.389 | 0.433 | 0.359 | 0.327 | 0.354 | 0.367 | 0.393 | |
| Averaged validation R ² | 0.981 | 0.979 | 0.981 | 0.98 | 0.973 | 0.978 | 0.98 | 0.976 | 0.978 | 0.975 | |

3.2 五個機器學習演算法的模型建立結果

本研究採用五種不同的演算法來構建溫室氣體轉換環境溫度模型，其結果詳細列於表 3 中。對於 CO₂ 轉換環境溫度模型，從數據中明顯看出，GBR 和 LGBMR 在多個性能指標上展示出了類似且較高的準確度，特別是在訓練數據集上的 R² 值，分別高達 0.997 和 0.993。然而，RFR 在某些測試條件下表現略遜一籌，特別是在測試數據集和 10 折交叉驗證的均方誤差 (MSE) 及均方根誤差 (RMSE) 方面。綜合考量所有性能指標，LGBMR 的整體表現最為優異，特別是在平均驗證的均絕對誤差 (MAE) 為 0.389 和平均驗證 R² 值為 0.980。因此，選擇 LGBMR 演算法作為 CO₂ 轉換環境溫度的最終模型。

接下來，針對 CH₄ 轉換環境溫度的模型，XGBR 在大多數的性能指標上表現卓越，尤其是在訓練數

據集上的 R² 值高達 0.999，顯示出對數據的極高適配度。相較之下，RFR 在某些測試條件下的表現不佳，特別是在 RMSE 和 MSE 上。綜合考量，XGBR 成為 CH₄ 轉換環境溫度模型的首選演算法，不僅擁有最低的平均驗證 MAE (0.327)，還有較高的平均驗證 R² 值 (0.980)。

在深入分析溫室氣體轉換環境溫度模型之後，本研究利用 SHAP 值來揭示 CO₂ 和 CH₄ 轉換環境溫度模型中的關鍵影響因素(請參見圖 3)。SHAP 值提供了一種強大的解釋方法，能夠清晰地展示各個變數對模型預測的貢獻程度。

從圖 3 中的 CO₂ 轉換環境溫度的 LGBMR 模型和 CH₄ 轉換環境溫度的 XGBR 模型中，可以觀察到 CO₂ 和 CH₄ 對環境溫度的影響程度。具體而言，它們的平均 SHAP 值分別為第 4 名 (+0.11) 和第 6 名 (+0.52)。這意味著這兩種溫室氣體確實與環境溫度存在關聯。

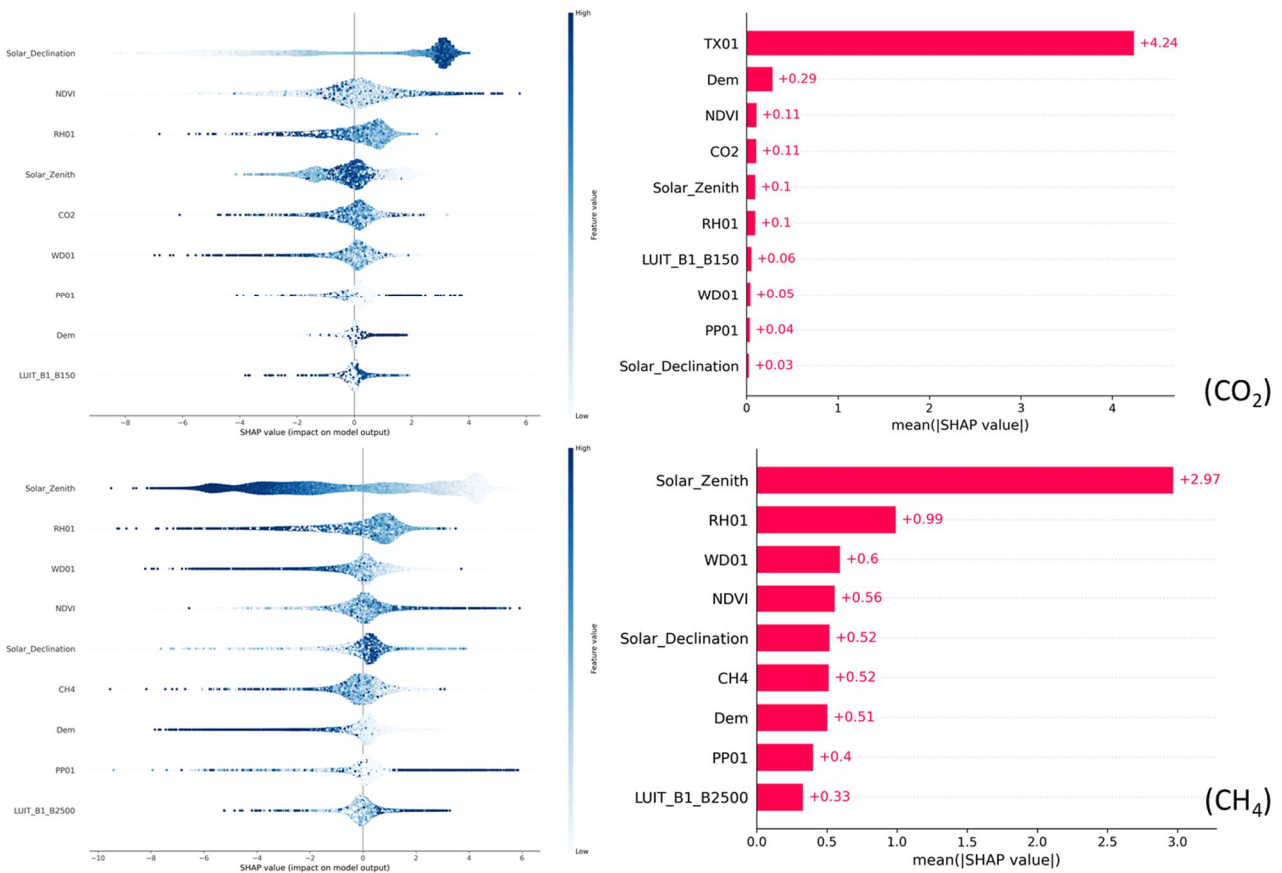


圖 3 SHAP 值解析：探索溫室氣體轉換溫度模型中關鍵變數的影響力 (上圖展示 CO₂ 轉換溫度模型的關鍵因素，下圖揭示 CH₄ 轉換溫度模型的主要影響變數)

對於 CO₂ 轉換環境溫度的 LGBMR 模型，分析結果顯示，影響該模型預測最顯著的五大因素依序為：由氣象測站資料進行空間內插的溫度、數值高程模型 (DEM)、常態化植生差異指標 (NDVI)、二氧化碳濃度、以及太陽天頂角。這些因素的排列反映了它們對預測結果的相對重要性，其中氣象測站資料進行空間內插的溫度影響最大，顯示了地理位置和即時氣溫條件對環境溫度變化有顯著的影響。

在 CH₄ 轉換環境溫度的 XGBR 模型中，最重要的五個影響因子則略有不同，分別為太陽天頂角、相對濕度、風速、NDVI、以及太陽赤緯角。這表明在預測 CH₄ 對環境溫度的影響時，太陽的位置和氣象條件尤為關鍵。特別值得注意的是，太陽天頂角和太陽赤緯角的重要性，這可能與太陽輻射對氣溫和 CH₄ 轉換率的影響有關。

綜合來看，這些分析結果不僅增進了對溫室氣體與環境溫度關係的理解，而且還為未來的氣候變化研究和策略制定提供了有價值的參考。透過深入分析這些關鍵因素，可以更有效地預測和應對氣候變化帶來的挑戰。

3.3 模型的驗證與評估

本研究針對溫室氣體轉換環境溫度模型進行了周全的驗證，其中分析了 CO₂ 與 CH₄ 轉換溫度的兩種模型，分別採用 LGBMR 和 XGBR 演算法。以下是對這兩種模型的驗證過程和結果的整理與分析。

首先，在 CO₂ 轉換環境溫度的 LGBMR 模型中，(1) 過擬合驗證中 (表 3)，模型的過擬合值僅為 0.013，這顯示了模型具有良好的泛化能力，能夠適應多變的數據條件；(2) 十折交叉驗證 (表 3)，此模型在十折交叉驗證中表現出色，R² 值高達 0.980。此外，均方根誤差 (RMSE) 為 0.733，均方誤差 (MSE) 為 0.537，平均絕對誤差 (MAE) 為 0.399，這些指標共同證明了模型的高準確性；(3) 次分群驗證中 (圖 4)，無論是根據季節還是年份進行的次分群驗證，R² 值均超過 0.97，MAE 均低於 0.05，彰顯了模型在不同條件下的高穩定性；(4) 對 2019 年的外部資料進行驗證時，MAE 稍高為 0.32，但依

然在接受範圍內。從表 3 中的數據顯示，外部資料驗證的 R² 值為 0.979，RMSE 為 0.757，MSE 為 0.573，MAE 為 0.379，進一步確認了模型的穩健性。

接著，CH₄ 轉換環境溫度的 XGBR 模型中，(1) 過擬合驗證 (表 3) 中可以看到，該模型的過擬合值為 0.018，表示在避免過度複雜化方面做得相當不錯；(2) 十折交叉驗證中 (表 3) 的模型結果同樣表現優異，R² 值達到 0.98，RMSE 為 0.701，MSE 為 0.492，MAE 為 0.334，顯示出高準確度；(3) 次分群驗證 (圖 4) 的分析結果，無論是根據季節或年份進行的次分群驗證，R² 值均超過 0.92，MAE 均低於 0.4，證明了模型在不同子集中的良好性能；(4) 外部資料驗證中 (表 3)，結果進一步展現了模型的堅實性，外部資料驗證的 R² 值為 0.982，RMSE 為 0.58，MSE 為 0.337，MAE 為 0.32。

總結來說，無論是 CO₂ 還是 CH₄ 轉換環境溫度模型，在進行多角度的驗證過程中均表現出卓越的性能。這些結果不僅證明了模型的高效性，也顯示了其在面對多樣化數據時的穩健性和可靠性。

4. 討論

在本研究的前言中，闡述了溫室氣體排放對環境溫度的潛在影響，以及這一問題的全球重要性。在結果章節中，本研究進一步展示了這些假設的實證分析。在此基礎上，本討論章節在深入解析這些研究發現，將其與現有的學術文獻和實際情況相結合，並探討其對未來研究方向的可能影響。

首先，本研究利用先進的機器學習技術，深入剖析了 CO₂ 和 CH₄ 與環境溫度之間的關係。首先，從模型中觀察到 CO₂ 和 CH₄ 與環境溫度的關係，背後可能的原因為 CO₂ 和 CH₄ 是兩種主要的溫室氣體，這兩種溫室氣體的作用是吸收地球表面向外輻射的熱能，並將部分熱能重新輻射回地球表面。這個過程類似於一個溫室，使得地球的溫度保持較高 (Al-Ghussain, 2019)。此外，從衡量溫室氣體對氣候變化影響的指標—輻射強迫，CO₂ 的輻射強迫約為每平方米 2 瓦特 (W/m²)，而 CH₄ 的輻射強迫約為 0.65 W/m²。儘管 CH₄ 的輻射強迫較低，但它的影響




圖 4 溫度轉換模型之次分群驗證

與 CO₂相當 (Etmnan *et al.*, 2016)。根據最新報告，自 19 世紀末以來，CH₄對全球變暖的貢獻約為 0.5°C，而 CO₂的貢獻約為 0.75°C (Etmnan *et al.*, 2016)。總之，CO₂和 CH₄的變化對環境溫度產生影響，需要共同努力減少它們的排放，以應對氣候變化。另外，本研究還觀察到太陽天頂角和氣象因素等關鍵變數對環境溫度具有顯著影響。這一結果與 IPCC (2022) 的研究相契合，凸顯了溫室氣體排放與氣候變化之間錯綜複雜的相互關係。另外，本研究採用了衛星遙測影像的常態化植生差異指標，以反映全台大範圍長時間的綠地生長情形。相較於小範圍的林木調查或是航拍影像，這種方法可以獲取長期且大空間尺度的資料，進一步凸顯了航遙測資料的價值。在模型建立過程中，常態化植生差異指標被選為一個影響環境溫度的重要因子，這一事實表明衛星遙測的資料確實可作為預測因子，有助於準確預測環境溫度的模型建立。此外，憑藉機器學習模型的精準預測能力，可以更深入地理解未來氣候變化的走勢，這對於擬定有效的減排策略至關重要。

本研究存在幾個限制。首先，本研究僅聚焦於溫室氣體對環境溫度變化的推估。為了增強研究成果的豐富性，建議未來研究可以考慮在不同溫室氣

體濃度排放強度下估算環境溫度的變化。此外，未將溫度的衛星影像數據納入評估資料集，因為這些影像數據中存在大量因天氣條件（如雲和雨）引起的缺失值，可能影響模型的準確性。接著，鑑於研究數據主要來自西部地區的連續監測站，可能在東部地區的預測結果上會有疑慮。因此，建議未來的研究努力納入更多監測站的數據，如果可能的話。這不僅會增加數據的樣本量，有助於更好地訓練模型，而且可能擴大數據值的覆蓋範圍，提高濃度預測的可信度。最後，研究僅檢驗了有限的土地利用資料集，且僅適用於少數時期。未來研究應考慮使用更全面和多樣化的資料集，以提高估算模型的性能。同時，分析更長時間段的數據並考慮更多影響因素，將有助於進一步提升模型的預測能力和準確性。

本研究開發的模型不僅提供了一種新的方法來評估溫室氣體減排策略的有效性，還強調了考慮地理和氣象等多重因素的重要性。這一成果為臺灣和其他地區提供了更精確的氣候模擬和政策規劃參考。特別是在臺灣這樣的島嶼地區，深入了解各種環境因素對氣候的綜合影響，對於制定有效的策略以達成 2050 年淨零排放目標至關重要。此外，研

究方法和結果展示了大數據和機器學習技術在設計減排和氣候適應策略方面的潛力，強調了跨學科合作，尤其是環境科學與數據科學結合的重要性，以便更全面地理解和應對全球暖化的挑戰。儘管本研究提供了寶貴的見解和工具，但也認識到其局限性。未來的研究應擴展數據集，涵蓋更多地理位置和不同類型的環境因素，以提升模型的普遍適用性和準確性。此外，探索該模型在不同氣候條件和地理區域的應用，將有助於提高其在全球氣候變化研究中的實用性和有效性。

總之，本研究通過創新的機器學習方法，為理解溫室氣體排放對環境溫度的影響提供了新視角。這不僅對臺灣，也對全球的氣候變化研究和政策制定提供了寶貴的參考，為未來的相關工作指明了方向。

5. 結論

本研究成功考慮了涉及溫室氣體、環境和人為活動的相關變數，以建立一個能夠推估環境溫度變化的模型。研究使用描述性統計分析和五種機器學習演算法來驗證 CO₂ 和 CH₄ 轉換環境溫度的模型。研究結果顯示，LGBMR 演算法在 CO₂ 模型中表現最佳，而 CH₄ 模型則以 XGBR 演算法為優。透過 SHAP 值的分析，研究揭示了溫室氣體、濕度、風速等關鍵因素對模型預測的顯著影響。這些模型在多重驗證過程中展現出高度的準確性和穩定性，提供了對於溫室氣體與環境溫度關係的新見解，同時也為應對氣候變化提供了實用的工具。

參考文獻

- Al-Ghussain, L., 2019. Global warming: Review on driving forces and mitigation, *Environmental Progress and Sustainable Energy*, 38(1): 13-21, DOI: 10.1002/ep.13041.
- Brandsma, T., and Können, G., 2006. Application of nearest-neighbor resampling for homogenizing temperature records on a daily to sub-daily level, *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 26(1): 75-89, DOI: 10.1002/joc.1236.
- Etminan, M., Myhre, G., Highwood, E.J., and Shine, K.P., 2016. Radiative forcing of carbon dioxide, methane, and nitrous oxide: A significant revision of the methane radiative forcing, *Geophysical Research Letters*, 43(24): 12614-12623, DOI: 10.1002/2016GL071930.
- Hsu, C.Y., Wu, J.Y., Chen, Y.C., Chen, N.T., Chen, M.J., Pan, W.C., Lung, S.C.C., Guo, Y.L., and Wu, C.D., 2019. Asian culturally specific predictors in a large-scale land use regression model to predict spatial-temporal variability of ozone concentration, *International Journal of Environmental Research and Public Health*, 16(7): 1300, DOI: 10.3390/ijerph16071300.
- Intergovernmental Panel on Climate Change, IPCC, 2022. *Climate Change 2022: Impacts, Adaptation and Vulnerability, Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, Cambridge University Press. Cambridge University Press, Cambridge, UK and New York, NY, USA, DOI: 10.1017/9781009325844.
- Ramanathan, V., and Feng, Y., 2009. Air pollution, greenhouse gases and climate change: Global and regional perspectives, *Atmospheric Environment*, 43(1): 37-50, DOI: 10.1016/j.atmosenv.2008.09.063.
- UNFCCC, 2015. *Historic paris agreement on climate change: 195 nations set path to keep temperature rise well below 2 degrees celsius*, Available at: <https://unfccc.int/news/finale-cop21>, Accessed March 15, 2023.
- USGS, 2020. MOD13Q1 MODIS/Terra Vegetation Indices 16-Day L3 Global 250 m SIN Grid.
- Wong, P.Y., Lee, H.Y., Chen, Y.C., Zeng, Y.T., Chern, Y.R., Chen, N.T., Lung, S.C.C., Su, H.J., and Wu, C.D., 2021a. Using a land use regression model

with machine learning to estimate ground level PM_{2.5}, *Environmental Pollution*, 277: 116846, DOI: 10.1016/j.envpol.2021.116846.

Wong, P.Y., Su, H.J., Lee, H.Y., Chen, Y.C., Hsiao, Y.P., Huang, J.W., Teo, T.A., Wu, C.D., and Spengler, J.D., 2021b. Using land-use machine learning models to estimate daily NO₂

concentration variations in Taiwan, *Journal of Cleaner Production*, 317: 128411, DOI: 10.1016/j.jclepro.2021.128411.

World Health Organization, 2021. Climate change and health, Available at: <https://www.who.int/news-room/fact-sheets/detail/climate-change-and-health>, Accessed March 15, 2023.

Development of an Ambient Temperature Prediction Model Using Machine Learning by Integrating Greenhouse Gas Emissions, Vegetation Index Satellite Images, and Land Use Data

Hao-Ting Chang¹ Yinq-Rong Chern² Wan-Yu Liu^{3,4} Chih-Da Wu^{5,6,7*}

Abstract

This study integrated greenhouse gases, environmental, and anthropogenic variables, utilizing big data and five machine learning algorithms, including Random Forest (RF), Gradient Boosting (GBR), Light Gradient Boosting Machine Regressor (LGBMR), CatBoost Regressor (CBR), and eXtreme Gradient Boosting (XGBoost), to establish models for estimating ambient temperatures based on two greenhouse gases, CO₂ and CH₄. The LGBMR model performed best for CO₂, while the XGBR model showed better performance for CH₄. The R² values for the CO₂ and CH₄ estimation models were 0.993 and 0.999, respectively. Analysis of SHAP values confirmed the significant influence of greenhouse gas concentration, humidity, wind speed, and other factors on predictions. The findings of this study offer new evaluation methods for greenhouse gas emission reduction strategies and provide crucial insights for global climate change research and policy-making, highlighting the importance of interdisciplinary collaboration.

Keywords: Ambient Temperature, Carbon Dioxide, Methane, Machine Learning Predictive Model, Machine Learning Algorithms

¹ Postdoctoral Research Fellow, Department of Geomatics, National Cheng Kung University

² Research Assistant, Department of Geomatics, National Cheng Kung University

³ Distinguished Professor, Department of Forestry, National Chung Hsing University

⁴ Distinguished Professor, Innovation and Development Center of Sustainable Agriculture, National Chung Hsing University

⁵ Professor, Department of Geomatics, National Cheng Kung University

⁶ Adjunct Research Fellow, National Institute of Environmental Health Sciences, National Health Research Institutes

⁷ Adjunct Professor, Innovation and Development Center of Sustainable Agriculture, National Chung Hsing University

* Corresponding Author, E-mail: chidawu@mail.ncku.edu.tw

Received Date: Feb. 26, 2024

Revised Date: May. 9, 2024

Accepted Date: May. 31, 2024

基於土地利用迴歸之機器學型模型分析新冠肺炎 三級警戒政策對臺灣工業城市細懸浮微粒之影響

蘇均珺¹ 翁佩詒² 曾于庭³ 李佳禾⁴ 吳治達^{5,6,7,8*}

摘要

COVID-19 疫情對全球帶來巨大衝擊，臺灣政府於 2021 年 5 月 19 日宣布三級警戒，限制民眾活動。本研究旨在評估警戒期間臺灣工業城市 $PM_{2.5}$ 濃度之變化。本研究以代表性的工業城市高雄市為研究區域，蒐集 1994 至 2020 年的空污觀測數據和地理變量，利用土地利用迴歸和逐步變量選擇建立模型、選取重要變數，再使用不同機器學習演算法建立模型，其中結果以 Random Forest (RF) 演算法的模型表現最佳， R^2 達 0.95；推估成果顯示封鎖期間空氣品質改善，高雄市平均 $PM_{2.5}$ 濃度為 $18.1\mu g/m^3$ ，低於警戒前 $19.9\mu g/m^3$ 。Paired t-test 結果顯示差異達到統計顯著水準 (p 值 <0.001)，各土地利用區域 (居住區、工業區、街道和綠地) 亦呈現一致結果。

關鍵詞：空氣污染、細懸浮微粒物 ($PM_{2.5}$)、基於土地利用的機器學習模型、COVID-19、三級警戒

1. 前言

新冠肺炎 (COVID-19) 疫情對全球人類的生活帶來了前所未有的巨大影響，讓各個國家和地區都感到措手不及。病毒的傳播速度之快以及其高度傳染性使得政府、醫療機構和社會各個層面都面臨了重大挑戰。人們的日常生活、工作、旅行和社交習慣都發生了巨大的變化，許多國家實施了緊急應對措施，如封鎖、社交距離和口罩規定，以遏制病毒的傳播。而為了應對這種情況，臺灣政府於 2021 年 5 月 19 日發布了三級警戒，限制民眾外出和工作，迫使多的公司和工廠停止生產運作。有鑑於空氣汙染對於人體健康會造成相當顯著之危害，其中直徑小於 2.5 微米 (micrometer, μm) 的懸浮微粒

(particulate matter, PM) $PM_{2.5}$ ，是環境中對人體健康影響最大的物質之一，不僅會造成及加劇心血管與呼吸道疾病，更被國際癌症研究署 (International Agency for Research on Cancer, IARC) 列為第一級致癌物。

從上世紀至今日，不斷有各類研究在探討懸浮微粒對於健康的影響。美國一項為期 7 年的研究表明， $PM_{2.5}$ 每減少 $10\mu g/m^3$ ，平均壽命就會延長 0.35 年 (Correia *et al.*, 2012)；在歐盟國家， $PM_{2.5}$ 使平均壽命縮短了 8.6 個月 (Orru *et al.*, 2011)；在中國的追蹤研究中， $PM_{2.5}$ 每增加 $10\mu g/m^3$ ，與心肌缺血症、出血性中風和缺血性中風的死亡風險分別增加了 9.7%、4.4%和 13.5% (Yin *et al.*, 2015)。因此評估 $PM_{2.5}$ 在空間中的濃度與分布至關重要。而由於空氣

¹ 國立成功大學測量及空間資訊學系 碩士生

² 國立成功大學測量及空間資訊學系 博士生

³ 國立成功大學測量及空間資訊學系 助理研究員

⁴ 嘉義市政府環境保護局 局長

⁵ 國立成功大學測量及空間資訊學系 教授

⁶ 國家衛生研究院國家環境醫學研究所 兼任研究員

⁷ 國立中興大學永續農業創新發展中心 兼任教授

⁸ 高雄醫學大學精準環境醫學研究中心 兼任研究員

* 通訊作者, E-mail: chidawu@mail.ncku.edu.tw

收到日期：民國 113 年 02 月 27 日

修改日期：民國 113 年 04 月 12 日

接受日期：民國 113 年 06 月 24 日

汙染主要源自於人類的各種活動，我們預期在封鎖期間的空氣品質會較於先前有所改善。

本研究旨在利用基於土地利用迴歸之機器學習模型，評估封鎖政策對臺灣工業城市 PM_{2.5} 濃度的影響。目前關於 COVID-19 與空氣汙染之間關係的研究主要集中在醫學方面，探討空氣汙染與 COVID-19 感染風險或死亡率之間的關聯。對於政策是否會影響 COVID-19 期間空氣中污染物的濃度和分佈，國際間已有部分研究，例如中國的研究發現，封鎖城市的空氣品質指標 (Air quality index, AQI) 相較於對照組下降了 19.84 $\mu\text{g}/\text{m}^3$ (PM_{2.5} 下降了 14.07 $\mu\text{g}/\text{m}^3$) (He *et al.*, 2020)；美國的研究顯示，NO₂ 顯著下降，PM_{2.5} 在 COVID-19 期間也有所降低，並且在城市縣和早期實施非必要業務關閉的州的縣中的減少是統計顯著的 (Berman & Ebisu, 2020)；印度的研究表明，PM_{2.5}、NO₂ 和 SO₂ 的平均質量濃度顯著下降，尤其是在封鎖的第一階段 (主要是 NO₂)，空氣污染物的減少更為顯著 (Pratap *et al.*, 2021)，然而國內相關研究仍然不足。本研究旨在填補這一空白，探討三級警戒對地區空氣汙染的影響，為未來的醫學研究提供有價值的洞察。

過往已發展出許多推估二維空間大範圍空氣汙染的方法，例如土地利用迴歸 (Land Use Regression, LUR) 模型，在環境研究中被廣泛應用於預測空氣污染物的濃度，是一種基於多變量線性回歸的實證建模方法，它將污染監測資料與由地理資訊系統 (Geographic Information System, GIS) 中所獲得的空間變量相結合，最終產製出一個線性推估模型 (Bitta *et al.*, 2018)。過去有許多應用 LUR 模型的研究，透過地理資訊系統以及遙感探測等空間資訊技術獲取測站周邊的土地利用資訊，進而建立 LUR 模型，並得到穩定的模型結果來推估國內高屏空品區 PM_{2.5} 的時空分布 (曾芷琳等, 2019) 以及北部空品區 PM_{2.5} 的時空分布 (曾于庭等, 2018)。此外，還有研究結合克里金空間內插 (Kriging Interpolation) 發展出混合模型來推估臨海石化工業區 PM₁₀ 的濃度 (吳昭儀等, 2020)。總結來說，LUR 模型結合 GIS 和遙感探測技術，已在臺

灣的多個地區和不同空氣污染物的時空分布推估中展現了其穩定性和可靠性。

然而，基於 LUR 的機器學習 (Machine Learning, ML) 模型近年來嶄露頭角，成為一種具有潛力的替代方法，因為它們具有更低的誤差和更強的解釋能力。與 LUR 模型相比，基於 LUR 的機器學習模型可以融入更廣泛的預測變量和非線性關係，從而能夠提供更準確和細緻的預測。此外，基於 LUR 的機器學習模型在處理缺失資料和異常值方面更為有效 (Basu *et al.*, 2019)。過去便有結合 LUR 與極限梯度提升演算法建立推估模型以推估高雄都會區二氧化氮，且模型具有高度預測與解釋力 (翁佩詒等, 2021)。這些優勢使得基於 LUR 的機器學習模型成為環境研究領域的一項有前景的進展。

本研究收集了 1994 年至 2020 年的每日 PM_{2.5} 觀測數據和地理變量，用於模型的建置。地理變量資料主要基於航遙測技術產製，包括土地利用資料、NDVI、DEM 和 DTM 等。其中，土地利用資料的產製其除了國土利用調查的現場勘查外，亦利用航空測量攝影影像、遙感探測影像、地籍圖、地形圖及電子地圖等圖資，並使用影像判釋進行土地覆蓋調查，從而掌握現況地景環境的分布及規模，包括植被、水體、建物及裸露地等，全面了解土地的使用樣態。這些豐富的地理變量資料經過逐步變量選擇程序 (Stepwise) 結合土地利用迴歸 (LUR) 模型，確定了影響 PM_{2.5} 變異性的重要因素。本研究所建置之模型基於不同的機器學習演算法，包括梯度提升機 (Gradient Boosting Machine, GBM)、隨機森林 (Random Forest, RF) 和 CatBoost (Categorical Boosting) 等等。最終的模型推估了高雄市所有鄉鎮的 PM_{2.5} 濃度，藉此研究分析了三級警戒前後 PM_{2.5} 濃度的變化，以及不同土地利用類型之間的差異。透過本研究的成果，不僅實現了對 PM_{2.5} 濃度的準確預測，還展示了航遙測技術在環境監測和公共衛生研究中的巨大潛力。這一貢獻不僅擴展了航遙測資料在公共衛生等領域的應用廣度，還為航遙測技術在不同領域中的廣泛應用提供了新的視角和方法，促進了其在公共衛生、環境保護和城市規劃等方面的發展。

2. 材料及方法

研究流程基本上可以分為五個部分：資料庫建置、篩選重要變數、建立推估模型、模型驗證以及最後的 PM_{2.5} 濃度分布推估與分析 (圖 1)。

2.1 研究地區

高雄市位於臺灣的西南邊，是一個擁有大量石化產業的城市，在其都市地區內具有相當稠密的人口與可觀的交通流量，工商業活動蓬勃發展；此外，高雄市的沿海地區坐擁著臺灣最大且最繁忙的貨運港口。此港口不僅是臺灣主要的貿易門戶，還扮演著國際貨物運輸和物流的關鍵角色，它承載了大量的進出口貨物，促進了該地區的經濟活動。在這一帶，工業區亦繁忙發展，擁有各種規模的製造和生產設施。這些工業區域涵蓋了多個產業領域，包括石化、製造、化學和重工業等，為當地提供了大量的就業機會，但也伴隨著相應的環境挑戰，如廢氣排放和廢水處理等。再者，這個地區還擁有一座重要的火力發電廠，為高雄市及其周邊地區提供電力供應。然而，這種發電方式通常伴隨著空氣污染風險，因為它釋放出二氧化硫、氮氧化物和微粒物質等污染物質，對當地空氣質量造成了一定的不利影響。綜合以上各項區域因素，對高雄市的空氣品質造成了複雜的影響，也成為本研究的重要研究對象。

2.2 研究資料

本研究從以下四個資料庫蒐集 1994 年至 2020 年之資料：

(1) 環保署空氣污染監測數據庫

行政院環境保護署在全臺灣，包括離島地區，共設有 77 個空氣品質監測站，這些監測站的功能包括數據收集，資料涵蓋了多種空氣污染物，如細懸浮微粒、氣體污染物，以及周圍的氣象因素，這些數據的時間尺度可達每小時的平均值。本研究蒐集研究試區測站之 PM_{2.5} 監測值，作為本研究之依變量。

(2) 土地利用數據庫

本研究使用之土地利用資料庫來自網路及本系實驗室提供之資料，包含：

- A.內政部國土測繪中心之國土利用調查資料
- B.經濟部工業局工業區範圍資訊 (含工業區、加工出口區、科學園區等)
- C.勤崴國際科技股份有限公司之地標資料庫 (如寺廟、中式餐飲等)
- D.Google Earth/Google Map 地標資料庫 (如全臺火力發電廠位置資訊)
- E.行政院環境保護署全臺焚化爐煙囪分布資訊
- F.內政部與交通部共同發行之臺灣地區交通路網數值圖

其中國土利用調查資料之土地使用分類系統為三層式之樹狀結構類。本研究參考其中之工商 (人工構造物、工業、商業建築)、水利 (水體、水利設施等)、森林 (含農業)、交通 (交通道路、鐵路、機場等) 等四大類型之土地利用位置資訊；幾項地標資料庫則被用以獲取各類地標與特徵土地利用點位之分布及位置資訊，包含透過工業區資料庫中之工業區、加工出口區、科學園區；勤崴資料庫中之寺廟、中式餐飲、Google Earth / Google Map 資料庫之火力發電廠，以及環保署全臺焚化爐煙囪分布資訊。路網數值資料則係使用 2020 年交通部運輸研究所全島 1/5000 比例尺之 GIS 路網數值圖。該資料將全臺之道路分為國道、省道、縣道以及鄉道等 8 種類型。本研究透過該資料庫再將其合併為三大類，包含主要道路 (國道、省道、縣道 以及市區快速道路)、地方道路 (市區道路、鄉道、產業道路以及無路名) 和所有道路。上述土地利用類型在計算後，將做為後續空污建模之解釋變數。本研究使用之土地利用空間變數如表 1 所示。

(3) MODIS NDVI 圖像數據庫

本研究使用 NASA (National Aeronautics and Space Administration) 所拍攝，並由美國地質調查所 (The U.S. Geological Survey, USGS) 校驗計算後提供之常態化植生差異指標 (Normalized Difference Vegetation Index, NDVI)，以代表植生綠度分布情形，並自其 Earth Data 網站取得監測日期下研究試區 NDVI 數值，搭配國土利用調查資訊中的森林、綠

地等土地利用，代表研究試區之植生狀態及指標，作為模擬懸浮微粒濃度變異之解釋因子之一。

(4) 氣象數據庫

交通部中央氣象署 (Central Weather Administration, CWA) 是臺灣的地球科學 (含氣象、氣候、海象、地震、天文) 專責機構，負責上述項目之觀測及預報業務。除了向公眾發布氣象預報、

海象測報與地震報告之外，也是災害性天氣預報 (颱風警報、豪雨特報、強風特報、低溫特報等) 發布、以及中華民國《氣象法》法定氣象事業督導之機關。本研究配合研究時期，將自大氣水文資料庫平台下載對應時間之平均降雨量、溫度、濕度、風向以及風速等氣象資料，供後續模式之用。




圖 1 研究流程圖

表 1 土地利用空間變數

| 資料來源 | 變數 | 資料描述 | 圖資型態 | 單位 |
|-----------------------|--------|-----------------|-------|-----------|
| 交通部運輸研究所 路網數值圖 | 當地道路 | 鄉村、城市、工業和無路名道路 | 體積、比例 | $m^3, \%$ |
| | 主要道路 | 國道、省道、縣道、城市高速公路 | 體積、比例 | $m^3, \%$ |
| | 全部道路 | 當地道路+主要道路 | 體積、比例 | $m^3, \%$ |
| 經濟部工業局 工業區資料庫 | 工業園區 | 科學園區、加工出口區及工業園區 | 體積、比例 | $m^3, \%$ |
| | 純住宅 | - | 體積、比例 | $m^3, \%$ |
| | 混合住宅 | 商業住宅+工業住宅 | 體積、比例 | $m^3, \%$ |
| 內政部國土測繪中心 國土利用調查資料 | 所有住宅 | 純住宅地+混合住宅地 | 體積、比例 | $m^3, \%$ |
| | 稻田 | - | 體積、比例 | $m^3, \%$ |
| | 旱田 | - | 體積、比例 | $m^3, \%$ |
| | 果樹 | - | 體積、比例 | $m^3, \%$ |
| | 水體 | - | 體積、比例 | $m^3, \%$ |
| | 公園綠地廣場 | - | 體積、比例 | $m^3, \%$ |
| | 森林用地 | - | 體積、比例 | $m^3, \%$ |
| | 工業 | 所有製造業 | 體積、比例 | $m^3, \%$ |
| | 鐵路 | - | 體積、比例 | $m^3, \%$ |
| | 地標資料庫 | 寺廟 | - | 點資料 |
| 中式餐廳 | | 中式餐廳和夜市 | 點資料 | count |

2.3 使用機器學習和土地利用數據處理開發和驗證 PM_{2.5} 推估模型

2.3.1 土地利用資料前處理

為獲取研究區內土地利用空間資訊，本研究參考了先前研究的估算和模擬案例 (Wong *et al.*, 2021)，使用 ArcGIS Pro 2.6 軟體將研究區域內的各種土地利用排放源和空間變數轉換成 50 m×50 m 的網格數據；並計算了兩種空間分布資料：每個網格中心點從 25 到 5000 m 半徑的緩衝區，以及每個網格中心點到研究區域內每個土地利用空間變數的歐幾里德距離，以此獲得研究區域內土地利用排放變數的空間密度分布。最後在每個監測站點處提取了點位所在之土地利用密度值，並將其添加到資料庫中，以供後續變數選擇和機器學習推估使用。

2.3.2 土地利用迴歸模型建置

本研究使用傳統的土地利用迴歸和克利金/土地利用迴歸混合模型 (Hybrid Kriging/Land-use Regression) 來建立初步模型，並選擇重要的空間解釋變數來預測 PM_{2.5} 濃度。土地利用迴歸的本質為多元線性迴歸，在此步驟基於測站之濃度資訊為依變數、各項土地利用空間變數為解釋變數進行線性模型建置，並且搭配逐步變數篩選 (Stepwise Variable Selection) 方法，以 p 值小於 0.1、大於 0.3 作為變數納入以及移除之標準，同時於模型建置過程中判斷選入之變數與預測對象之相關性方向是否正確 (如人工覆蓋物比例與空氣污染微粒應呈正相關；環境綠蔽度、植被涵蓋比則應與空氣污染呈現負相關)。此外，為避免共線性造成模型參數估計上之誤差，故同時利用變異數膨脹係數 (Variance Inflation Factor, VIF) 為標準，排除 $VIF > 3$ 之變數，以完成重要土地利用變數篩選以及土地利用迴歸模型建立。

其中克利金/土地利用迴歸混合模型的原理在於結合 Ordinary Kriging 空間內插法和土地利用迴歸的優勢，以提高模型對濃度的準確估算。而混合

模型的核心思想是，即使在沒有真正濃度值的情況下，如果在相同的時間點附近有監測資料的點位，那麼這些附近點位的監測濃度值與欲評估地點的濃度值之間必定存在某種關聯性。當兩地之間的距離越近，這種關聯性就越能代表未監測地區空氣污染程度，這比周圍的土地利用和污染源更具代表性。因此，將周邊點位的濃度信息納入土地利用迴歸模型中，可以提高模型的解釋能力 (Lung *et al.*, 2004)。基於這一理念，本研究通過 Leave-one-out Kriging 方法估算了每個未知濃度點位的 Kriging PM_{2.5} 污染估算值，並將其納入統計模型中作為解釋變數，其餘步驟皆與土地利用迴歸模型相似，並於最終建立混合式推估模型。

2.3.3 整合機器學習之推估模型

為了降低資料的維度並確保所選的變數在統計上具有意義，本研究以模型篩選出的變數為基礎，運用 Python 中的 AutoML 套件，精心挑選了五種機器學習算法，包括隨機森林、梯度提升、極限梯度提升 (Extreme Gradient Boosting, XGBoost)、Light Gradient Boosting Machine (Light GBM) 和 CatBoost 等，進行模型超參數的自動調整，並打造了不同機器學習算法為基礎的混合式土地利用集成學習模型。

每個機器學習演算法都擁有其獨特的優勢，隨機森林以同時建立多個迴歸樹來提升計算效能，確保模型的穩定性和可靠性。XGBoost 進一步精煉了模型，降低了過度擬和的風險，同時兼具並行建樹和串行建樹的特性，使得預測結果更加優化。而 LightGBM 則在 XGBoost 的基礎上進行了進一步的優化，特別在快取速度方面取得了巨大的改進，有助於縮短模型訓練的時間。這些演算法的選用，使研究能夠更好地滿足各種不同的建模需求，並提高了模型的預測性能。

至此，包含以統計為基礎之：(1) 土地利用迴歸、(2) 克利金/土地利用迴歸混合模型、機械學習為基礎之(3) 隨機森林、(4) 梯度提升、(5) 極限梯度提升、(6) Light Gradient Boosting Machine 及 (7) CatBoost，共使用七個模型來推估研究區之空氣污

染分佈。本研究以利金/土地利用迴歸混合模型為基礎，結合隨機森林、梯度提升、極限梯度提升、Light Gradient Boosting Machine 及 CatBoost 五種機器學習演算法，比較五種方法之預測成果。

2.3.4 模型驗證

在模型表現能力之驗證方面，本研究透過數種方法以驗證模型穩定度 (Robustness) 以及模型是否具有過擬合 (Overfitting) 之問題，包含：

(1) Data Split 驗證法

將總樣本資料的 80% 作為訓練樣本進行模型建立，並以其餘 20% 樣本作為測試樣本，並將測試樣本帶入模型當中與模擬之結果進行比較。

(2) 十折交叉驗證法 (10-Fold Cross Validation)

每次以總樣本數中 90% 資料做為訓練樣本，扣除訓練樣本後剩餘之 10% 資料做為測試樣本，整個過程重覆十次，以訓練樣本建立模型後，據以進行預測試樣本之預測，並計算其與測試樣本真實值之相關性。

(3) 外部資料驗證 (External Data Validation)

預先進行一次採樣，其結果不納入建模，利用其餘資料建立模型進行預測後，與未納入模型之資料 (真實值) 比較之。

至於在模型表現能力之評估指標方面，本研究將採用 R^2 與 Adjusted R^2 代表模型的準確度；平均絕對誤差 (Mean Absolute Error, MAE)、均方誤差 (Mean Square Error, MSE) 及均方根誤差 (Root Mean Square Error, RMSE) 用以代表模型誤差。

2.3.5 $PM_{2.5}$ 濃度分布推估

這項研究的主要目標是通過製作並比較兩張高雄市 $PM_{2.5}$ 濃度地圖，深入瞭解高雄市政府宣布實施三級警戒前後 (分別為 2021 年 5 月 1 日至 19 日和 2021 年 5 月 20 日至 31 日) 的 $PM_{2.5}$ 之濃度及其於空間中分佈狀況。研究中特別關注不同土地利用區域 (如圖 3 所示) 的濃度分佈情形，並使用配對 t 檢定以確定在不同類型的土地利用地區是否存在明顯的濃度變化趨勢。研究成果不僅有助於更了解環境改善和城市政策實施的效果，還具有重要的

政策參考價值，可以為改善城市空氣質量、制定相關政策和採取措施提供實際指導，特別是在應對環境變遷挑戰並提高城市居民的生活品質方面。

3. 結果

3.1 重要變數

表 2 顯示了從傳統土地利用迴歸與逐步迴歸分析中所獲得的 8 個模型預測變數。在此過程中，本研究對每項加入模型之變數係數和 R^2 改變量進行了檢查，以確定它們與 $PM_{2.5}$ 濃度之間的關係是否顯著並合理。結果顯示，水體 1500 m (緩衝區) 和天然/人工森林 750 m (緩衝區) 的變數與 $PM_{2.5}$ 濃度呈負相關，這表示當周圍有水體或天然/人工森林的情況越多時， $PM_{2.5}$ 濃度通常越低；而其他變數則與 $PM_{2.5}$ 濃度呈正相關，即當這些變數的值越高時，則通常伴隨著較高的 $PM_{2.5}$ 濃度。這可能是由於水體和森林有助於 $PM_{2.5}$ 濃度的分散和減少；另一方面，其他變數，如鐵路、港口和其他土地利用等區域，對 $PM_{2.5}$ 濃度的正向影響較為顯著，這意味著這些區域可能更容易產生或累積污染物，導致較高的 $PM_{2.5}$ 濃度。

表 2 顯示所列所有變數之 p 值皆小於 0.05，表明這些變數在推估模型中具有統計學上的顯著性；此外，每個變數的 R^2 變化值皆大於 0.001，顯示它們在解釋 $PM_{2.5}$ 濃度變異性方面都有顯著的貢獻。這些結果的統計顯著性進一步強調了所選變數的重要性，並確保了我們建立的模型的可信度。

表 2 土地利用逐步迴歸變數篩選

| 變數 | coefficient | p-value | R^2 change |
|--------------------|-------------|-----------|--------------|
| 截距 | 41.331 | 2.63E-12 | |
| $PM_{2.5}$ Kriging | 0.967 | 0 | |
| 鐵路 150m | 0.016 | 8.53E-142 | 0.007 |
| 商港與漁港 2000m | 0.007 | 1.20E-67 | 0.009 |
| 水體 1500m | -0.004 | 1.34E-141 | 0.005 |
| 寺廟 1250m | 4276490.417 | 0 | 0.003 |
| 兼工業使用住宅 1250m | 0.015 | 0 | 0.004 |
| 天然/人工林 750m | -0.031 | 2.15E-111 | 0.002 |
| 果樹 1500m | 0.009 | 2.29E-62 | 0.001 |

3.2 土地利用迴歸模型表現

表 3 展示了土地利用迴歸模型結合克利金空間內插後在預測 PM_{2.5} 濃度方面的表現。該模型呈現了相當不錯的預測能力，其 R² 值達到 0.91，顯示其在估算 PM_{2.5} 濃度方面的有效性。此外，我們也可以看到該模型的表現令人滿意，這可以從 MAE、MSE 和 RMSE 的數值中看出，分別為 3.10、33.30 和 5.77。測試數據的 R² 值與訓練數據相近，這說明了該模型並未出現過度擬合的情況。而模型的外部驗證結果則獲得了 0.84 的 R² 值，進一步確保了模型的穩健性。綜合來看，這些結果強烈表明了該模型在預測 PM_{2.5} 濃度方面的可靠性。

表 3 土地利用迴歸模型表現

| Statistic/Data | train | test | external |
|-------------------|-------|-------|----------|
| r square | 0.91 | 0.92 | 0.84 |
| adjusted r square | 0.91 | 0.92 | 0.84 |
| MAE | 3.10 | 3.15 | 3.12 |
| MSE | 33.30 | 31.66 | 21.47 |
| RMSE | 5.77 | 5.63 | 4.63 |

3.3 基於土地利用迴歸之機器學習模型推估表現

進一步探討機器學習對於提升模型表現的關鍵作用，本研究運用了五種不同的機器學習模型，並深入評估它們的性能。其中，隨機森林(RF) 模型表現出眾，擁有最高的 R² 值，達到 0.95，這意味著它在預測 PM_{2.5} 濃度方面具有卓越的能力。此外，該模型的 MAE、MSE 和 RMSE 值也均優於其他模

型，分別為 3.14、19.78 和 4.45，顯示其預測準確性和誤差控制方面的卓越表現。值得一提的是，XGBoost 模型在計算速度方面表現出色，僅需 26.81 秒即可完成模型訓練，這對於處理大規模數據集至關重要。研究進一步對測試數據的 R² 值和 10 折交叉驗證結果進行比較，結果表明，這五個基於 LUR 的機器學習模型均未受到過度擬合的影響，確保了模型的穩健性和可靠性。在外部驗證方面，所有五個機器模型均表現出色，這進一步證實了它們對於預測外部數據的能力。

表 4 為各種不同的機器學習土地利用迴歸模型在訓練集上的表現。明顯地，傳統土地利用迴歸模型相較於加入機器學習演算法的模型，在模型解釋力方面較差 (R² 值為 0.91，是所有模型中最低的)，並伴隨較高的誤差。而以隨機森林演算法為基礎的模型表現最為優越，其模型解釋力最高 (R² 值達 0.95)，同時具有較低的 MAE (0.95)、MSE (19.78) 以及 RMSE (4.45)，誤差表現優於所有其他模型。這些結果強調了加入機器學習演算法對土地利用迴歸模型的改進效果，尤其是基於隨機森林的模型在預測方面表現卓越。

表 5 呈現了隨機森林演算法模型在測試和驗證上的結果，可以觀察到測試集和驗證集之間的 R² 值差異小於 0.05，這表明該模型無過擬合的問題。因此，本研究決定在後續的 PM_{2.5} 濃度地圖製作中，採用基於隨機森林機器學習演算法的土地利用迴歸模型。

表 4 傳統 LUR 模型以及機器學習模型表現

| | Hybrid LUR | LUR based ML Model | | | | |
|-------------------------|------------|--------------------|-------|---------|----------|----------|
| | | RandomForest | GBM | XGBoost | LightGBM | CatBoost |
| R ² | 0.91 | 0.95 | 0.92 | 0.93 | 0.92 | 0.92 |
| adjusted R ² | 0.91 | 0.95 | 0.92 | 0.93 | 0.92 | 0.92 |
| MAE | 3.10 | 3.14 | 3.83 | 3.75 | 3.81 | 3.83 |
| MSE | 33.30 | 19.78 | 29.30 | 27.60 | 29.16 | 29.30 |
| RMSE | 5.77 | 4.45 | 5.41 | 5.25 | 5.40 | 5.41 |

表 5 隨機森林演算法模型成果

| Statistic/Data | 10-fold | External | |
|-------------------------|---------|----------|-----------------|
| | | 20% Data | External (2020) |
| R ² | 0.92 | 0.92 | 0.91 |
| adjusted R ² | 0.92 | 0.92 | 0.82 |
| MAE | 3.87 | 3.84 | 3.68 |
| MSE | 30.00 | 28.73 | 22.57 |
| RMSE | 5.48 | 5.36 | 4.75 |

3.4 隨機森林模型推估圖

本研究針對兩個時間段的平均 $PM_{2.5}$ 濃度進行了推估：2021 年 5 月 1 日至 19 日（三級警戒實施前），以及 2021 年 5 月 20 日至 31 日（三級警戒期間）。如圖 2 所示，清晰呈現了警戒期間 (b) 的 $PM_{2.5}$ 濃度低於警戒實施前 (a)，與原先的預期一致。通過將警戒前後的濃度進行相減比較 (c)，可以看出於西南方整體呈現藍色（負值），尤其以南方顏色最深，代表 $PM_{2.5}$ 濃度下降最為顯著。圖 2 亦展示了 $PM_{2.5}$ 濃度的分佈，特別是在高雄市的西南部，包括人口稠密的都市地區和沿海地區，顯示出較高的濃度。都市地區的濃度較高，由於人口密度和交通流量大，而沿海地區的工業區域則是該地區濃度較高的主要原因。

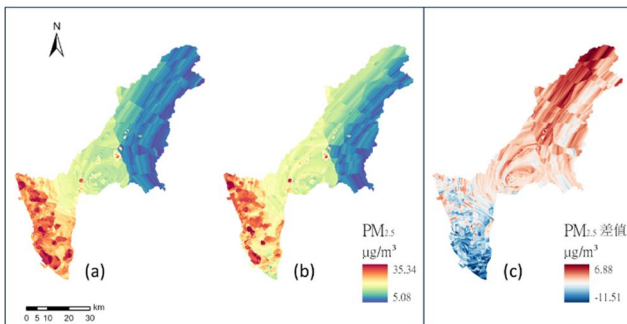


圖 2 高雄市三級警戒前 (a)與三級警戒期間；(b) $PM_{2.5}$ 濃度推估圖；(c)警戒後與警戒前相減

3.5 配對 t 檢定

根據模型估算結果，高雄市在實施三級警戒期間的平均 $PM_{2.5}$ 濃度為 $18.1 \mu g/m^3$ ，低於警戒前 ($19.9 \mu g/m^3$)。研究選取了特定土地利用分類地區來進行配對 t 檢定以確定是否存在明顯的濃度變化趨勢，土地利用類型分別為：工業區、純住宅地區、森林綠地、街道以及港口 (如圖 3 所示)。

如表 6 所示，配對 t 檢定的結果明確驗證了在警戒期間，不同土地利用區域的 $PM_{2.5}$ 濃度皆有顯著差異 (p 值 < 0.001)，尤其以沿海的工業區以及港口最為顯著。具體而言，警戒期間 $PM_{2.5}$ 濃度在所有土地利用中一致呈現下降的趨勢。尤其以高雄市西南沿海地區的港口和工業區最為顯著。

在警戒期間，由於 COVID-19 疫情的嚴重性，各國的海上運輸活動受到了巨大的制約，臺灣亦同；此外，許多工業區域也實施了工作限制和防疫措施，導致工業生產活動的減少或暫停。所有這些因素的共同作用下減少了空氣汙染排放的活動，有助於解釋為什麼港口和工業區域的 $PM_{2.5}$ 濃度下降得更加明顯，並在配對 t 檢定中呈現顯著的差異。

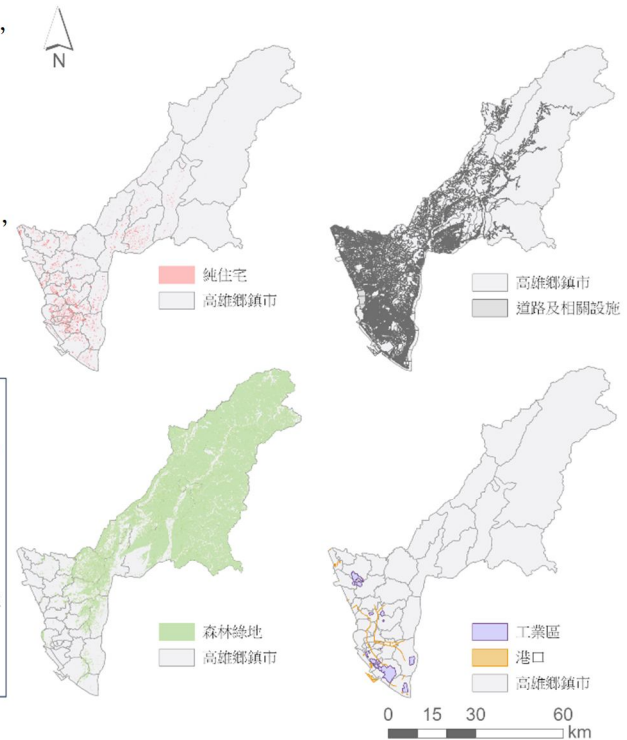


圖 3 土地利用變數之空間分布示意圖

表 6 依據不同土地利用進行三級警戒前後 $PM_{2.5}$ 濃度的配對 t 檢定 ($\mu g/m^3$)

| | 警戒前 | 警戒期間 | 差異 | P-value |
|------|-------|-------|-------|---------|
| 鄉鎮市區 | 19.94 | 18.15 | -1.80 | <0.001 |
| 工業區 | 24.99 | 21.43 | -3.56 | |
| 住宅區 | 21.29 | 18.70 | -2.59 | |
| 綠地 | 15.06 | 14.88 | -0.17 | |
| 街道 | 18.41 | 17.47 | -0.93 | |
| 港口 | 23.57 | 20.45 | -3.12 | |

4. 討論

綜上研究結果可見，傳統的土地利用迴歸模型結合克利金空間內插後，在預測 $PM_{2.5}$ 濃度方面已經相當出色；然而，透過引入機器學習 (ML) 技術

後，研究成功地將模型的性能提到了更高的水準。這些 ML 模型呈現出多重優點，有助於增強研究成果。

首先，這些 ML 模型展現出更低的誤差，意味著它們能夠更準確地推估 PM_{2.5} 濃度。其次，這些模型具有更強的解釋能力，能夠更清晰地揭示不同因素對 PM_{2.5} 濃度的影響，有助於更深入地理解空氣污染的來源和變化。最重要的是，這與先前研究的發現一致，進一步鞏固了它們在土地利用回歸領域的卓越性 (Wong *et al.*, 2021)。

本研究亦觀察到，透過模型推估之成果，以及配對 t 檢定的證實，在三級警戒前與警戒期間前後不同時期的空氣污染物濃度確實存在顯著差異。此外，這些結果在不同的土地利用情況下，包括居住區、工業區、繁忙街區和綠地等，都得到了一致性的成果，進一步說明了在三級警戒期間高雄市的 PM_{2.5} 濃度確實較警戒前有所減少。圖 2 展示了不同時期的 PM_{2.5} 在高雄市中的空間分佈與濃度變化，提供了兩時期差異的視覺呈現。

與其他國際間的研究結果相比 (如表 7 所示)，高雄的 PM_{2.5} 亦為顯著下降，只是下降幅度遠小於其他各國。而根據過往研究大多都以一段期間內 PM_{2.5} 下降或上升 10 µg/m³ 為單位進行研究分析其與人體健康效益的關聯性，顯示高雄市 PM_{2.5} 在三級警戒期間短期內的輕微下降可能無法產生與其他地區相當的顯著健康效益。

表 7 不同國家地區 PM_{2.5} 濃度在封鎖與封鎖前之差異

| | 臺灣 高雄市 | 美國 | 印度 德里 | 中國 |
|--------------------------------|-----------|-------|----------|-------|
| 平均下降 濃度(µg/m ³) | 1.80 | 1.44 | 21.29 | 14.07 |
| 下降百分比 | 9.05% | 18.6% | 27.35% | 24% |

5. 結論

綜上所述，臺灣工業城市實施的三級警戒政策對環境中 PM_{2.5} 濃度產生了顯著的影響，在此期間，空氣品質明顯的改善。本研究凸顯了政府政策、公共健康和環境問題之間的錯綜複雜關係，並強調了

需要採取綜合方法來應對這些相互關聯的挑戰。

這些研究成果在環境政策制定、公共健康保護和城市規劃等方面具有重要的應用價值。研究顯示，透過實施類似的警戒措施，不僅可以有效控制病毒傳播，還能在短期內顯著改善空氣質量，進而減少相關健康風險。此外，本研究引入的機器學習技術展示了其在提高模型預測精度和解釋能力方面的優勢。未來的研究可以進一步探討更多的空間變量和更長期的數據，以持續提升模型的準確性和穩定性。最後，未來的研究應該更多地關注不同環境政策在不同地區和城市的效果比較，以及其對長期健康效益的影響。通過綜合考慮各種因素並採取有力行動，可以更有效地應對公共健康和環境保護的雙重挑戰，實現可持續發展的目標。

參考文獻

吳昭儀、吳治達、陳裕政、許金玉、陳穆貞，2020。

應用克利金／土地利用迴歸混合模式推估林園臨海石化工業區懸浮微粒之時空分布，航測及遙測學刊，25(1)：11-23，DOI：10.6574/JPRS.202003_25(1).0002。 [Wu, J.Y., Wu, C.D., Chen, Y.C., Hsu, C.Y., and Chen, M.J., 2020. Estimate particulate matter concentrations variations in a petrochemical parks area using a hybrid kriging/land-use regression model, Journal of Photogrammetry and Remote Sensing, 25(1):11-23, DOI: 10.6574/JPRS.202003_25(1).0002. (in Chinese)]

曾于庭、吳治達、龍世俊，2018。應用土地利用迴歸模式推估北部空品區細懸浮微粒之時空分布，航測及遙測學刊，23(3)：191-204，DOI：10.6574/JPRS.201809_23(3).0004。 [Yu-Ting Zeng, Y.T., Wu, C.D., and Lung, S.C.C., 2018. Spatial-temporal variability of fine particulate matter in northern air quality zone of Taiwan using land use regression, Journal of Photogrammetry and Remote Sensing, 23(3): 191-204, DOI: 10.6574/JPRS.201809_23(3).0004. (in Chinese)]

- 曾芷琳、蕭雅萍、曾于庭、陳穆貞、龍世俊、吳治達，2019。整合空間資訊技術與土地利用迴歸模式推估高屏空品區細懸浮微粒之時空分布，航測及遙測學刊，24(2)：79-87，DOI：10.6574/JPRS.201906_24(2).0001。[Zeng, C.L., Hsio, Y.P., Zeng, Y.T., Mu-Jean Chen, M.J., Lung, S.C.C., and Wu, C.D., 2019. Integrate geospaital information technologies and land-use regression to estimate the spatial-temporal variability of fine particulate matter in kaohsiung-pingtung air quality zone, *Journal of Photogrammetry and Remote Sensing*, 24(2):79-87, DOI: 10.6574/JPRS.201906_24(2).0001. (in Chinese)]
- 翁佩詒、吳治達、蘇慧貞，2021。結合土地利用迴歸與極限梯度提升演算法發展高雄都會區二氧化氮之推估模型，航測及遙測學刊，26(1)：1-12，DOI：10.6574/JPRS.202103_26(1).0001。[Wong, P.Y., Wu, C.D., and Su, H.J., 2021. Development of an integrated model for NO₂ variation prediction in kaohsiung metropolis using land-use regression and XGBoost, *Journal of Photogrammetry and Remote Sensing*, 26(1): 1-12, DOI: 10.6574/JPRS.202103_26(1).0001. (in Chinese)]
- Basu, B., Alam, M.S., Ghosh, B., Gill, L., and McNabola, A., 2019. Augmenting limited background monitoring data for improved performance in land use regression modelling: Using support vector regression and mobile monitoring, *Atmospheric Environment*, 201: 310-322, DOI: 10.1016/j.atmosenv.2018.12.048.
- Berman, J.D., and Ebisu, K., 2020. Changes in U.S. air pollution during the COVID-19 pandemic, *Science of The Total Environment*, 739: 139864, DOI: 10.1016/j.scitotenv.2020.139864.
- Bitta, J., Pavlíková, I., Svozilík, V., and Jancík, P., 2018. Air pollution dispersion modelling using spatial analyses, *ISPRS International Journal of Geo-Information*, 7(12): 489, DOI: 10.3390/ijgi7120489.
- Correia, A., Pope, C., Dockery, D., Wang, Y., Ezzati, M., and Dominici, F., 2012. Effect of air pollution control on life expectancy in the United States: An analysis of 545 US counties for the period from 2000 to 2007, *Epidemiology*, 24(1): 23-31, DOI: 10.1097/EDE.0b013e3182770237.
- He, G., Pan, Y., and Tanaka, T., 2020. The short-term impacts of COVID-19 lockdown on urban air pollution in China, *Nature Sustainability*, 3(12): 1005-1011, DOI: 10.1038/s41893-020-0581-y.
- Lung, S.C.C., Guo, K.J., Chen, P.Y., Tsai, P.F., and Chen, P.C., 2004. Participants' exposure to PM_{2.5} and gaseous/particulate polycyclic aromatic hydrocarbons during the Ma-tsu Goddess parade, *Journal of Exposure Science and Environmental Epidemiology*, 14(7): 536-543, DOI: 10.1038/sj.jea.7500372.
- Orru, H., Maasikmets, M., Lai, T., Tamm, T., Kaasik, M., Kimmel, V., Orru, K., Merisalu, E., and Forsberg, B., 2011. Health impacts of particulate matter in five major Estonian towns: Main sources of exposure and local differences, *Air Quality, Atmosphere & Health*, 4(3-4): 247-258, DOI: 10.1007/s11869-010-0075-6.
- Pratap, V., Tiwari, S., Kumar, A., and Singh, A.K., 2021. COVID-19 lockdown induced air pollution reduction over India: A lesson for future air pollution mitigation strategies, *Journal of Earth System Science*, 130(4): 230, DOI: 10.1007/s12040-021-01722-y.
- Wong, P.-Y., Su, H.-J., Lee, H.-Y., Chen, Y.-C., Hsiao, Y.-P., Huang, J.-W., Teo, T.-A., Wu, C.-D., and Spengler, J.D., 2021. Using land-use machine learning models to estimate daily NO₂ concentration variations in Taiwan, *Journal of Cleaner Production*, 317: 128411, DOI: 10.1016/j.jclepro.2021.128411.

Yin, P., Brauer, M., Cohen, A., Burnett, R.T., Liu, J., Liu, Y., and Zhou, M., 2015. Ambient fine particulate matter exposure and cardiovascular mortality in China: A prospective cohort study, *The Lancet*, 386: S6, DOI: 10.1016/S0140-6736(15)00584-X.

Impacts of the Level 3 Alert Brought by COVID-19 on Fine Particulate Matter of an Industrial City in Taiwan Using a Land-Use Based Machine Learning Model

Jun-Jun Su¹ Pei-Yi Wong² Yu-Ting Zeng³ Chia-Ho Lee⁴
Chih-Da Wu^{5,6,7,8*}

Abstract

The COVID-19 epidemic has brought significant changes to human activities worldwide, including in Taiwan. On May 19, 2021, the government announced a level 3 alert to restrict public movement. This study aims to assess the impact of the lockdown policy on PM_{2.5} concentrations in Taiwan's industrial city, Kaohsiung. Daily PM_{2.5} observations and geographic data from 1994 to 2020 were collected. A land-use regression model, combined with stepwise variable selection, was used to identify important factors affecting PM_{2.5} variability. These predictors were used to develop machine learning models with algorithms such as Random Forest (RF), which showed the best performance with an R² of 0.95. Paired t-tests indicated that PM_{2.5} levels were significantly lower during the alert (18.1 µg/m³) compared to before (19.9 µg/m³), with consistent results across residential, industrial, street, and green areas ($p < 0.001$).

Keywords: Air Pollution, Fine Particulate Matter (PM_{2.5}), Land-Use Based Machine Learning Model, COVID-19, Level 3 Alert

¹ Master Student, Department of Geomatics, National Cheng Kung University

² Ph.D Student, Department of Geomatics, National Cheng Kung University

³ Assistant Researcher, Department of Geomatics, National Cheng Kung University

⁴ Director, Environmental Protection Bureau of Chiayi City

⁵ Professor, Department of Geomatics, National Cheng Kung University

⁶ Adjunct Researcher Fellow, National Institute of Environmental Health Sciences, National Health Research

⁷ Adjunct Professor, Innovation and Development Center of Sustainable Agriculture, National Chung Hsing University

⁸ Adjunct Researcher Fellow, Research Center for Precision Environmental Medicine, Kaohsiung Medical University

* Corresponding Author, E-mail: chidawu@mail.ncku.edu.tw

Received Date: Feb. 27, 2024

Revised Date: Apr. 12, 2024

Accepted Date: Jun. 24, 2024

運用生成對抗網路產製超解析衛星影像之先期評估

張庭韶¹ 蔡富安^{2*}

摘要

本研究探討使用生成對抗網路 (GAN) 模型提升衛星影像的空間解析度，以解決因拍攝角度、天氣狀況及感測器限制導致的解析度下降問題。研究使用中、高及超高分辨率影像進行降解析處理，並透過 GAN 進行訓練生成超解析影像。GAN 訓練過程中，生成器負責將低解析度影像重建為高解析度影像，判別器則區分生成影像與真實影像的差異。研究亦使用 VGG-19 預訓練模型進行特徵提取，提升生成影像品質。結果顯示，隨訓練次數增加，影像細節變得更為清晰及銳利化，且在結構相似性指標上優於傳統方法。然而，影像生成過程中出現色彩偏移及偽影現象。為改善此問題，建議進行更深層次訓練或使用後處理技術，並優化模型架構，如移除 Batch Normalization。綜上所述，GAN 模型具有提升衛星影像解析度的潛力，惟仍尚有影像色彩偏移及偽影問題，未來可針對模型穩定性和影像後處理進行優化。

關鍵詞：超解析、衛星影像、生成對抗網路、深度學習

1. 前言

衛星影像判讀可應用於追蹤特定目標及災損評估等議題，對於特定事件從事精準判釋及分析而言，除須仰賴分析師自身經驗及熟悉事件相關背景知識外，關鍵在於是否能於短時間內獲取多幅衛星影像，影像是否可清晰呈現目標細節。對於超高分辨率衛星影像而言 (例如：Maxar WorldView 系列影像、Airbus Pleiades 影像)，影像最佳解析度均小於 1 m，惟影像於偵照時，可能受限於拍攝傾角過大或天氣狀況不佳等因素，影像空間解析度可能會降低至 1 m (或以上)，導致無法清晰呈現微小目標之特徵細節。另囿於衛星軌道設計，上述星種均於太陽同步軌道運行 (Boain, 2004)，因此重返週期較長，單一星種需經過 1-2 天後方可針對相同地點執行偵照，無法於短時間內獲取大量影像。在另一方面，部分新興微衛星群 (例如：Planet Labs 公司所屬 SkySat 衛星、Dove 衛星)，衛星在軌數量較多，因此重返週期短，可於短時間內重複偵照同一目標 (Kim *et al.*, 2022)，但影像空間解析度通常相較於超

高分辨率影像略顯遜色。部分衛星影像應用需於特定日期偵照特定目標 (例如：監控非法走私船艦)，並進行目標判釋 (Aiello *et al.*, 2019)，因此若能提升原始衛星影像解析度，將可幫助分析師正確判釋目標。

目前深度學習技術已廣泛運用遙測領域，物件偵測 (Object Detection) 及影像分類 (Classification) 應用實例屢見不鮮 (Li *et al.*, 2017)。現今亦有多項神經網路模型應用於影像超解析 (Super resolution)。本研究嘗試運用生成對抗網路 (Generative Adversarial Network) 深度學習技術 (Goodfellow *et al.*, 2014)，透過生成器 (Generator) 盡可能模仿訓練集中真實樣本之各種特徵，生成和高分辨率影像非常相似之超解析影像。研究中透過判別器 (Discriminator) 區分超解析及高分辨率影像，並將鑑別結果回饋給生成器，在兩組神經網路不斷對抗情形下，透過持續訓練機制，當判別器將超解析影像判定為高分辨率影像時，表示生成器已有足夠能力產製高品質超解析影像，所產製之超解

¹ 國立中央大學土木工程學系 碩士

² 國立中央大學太空及遙測研究中心 教授

* 通訊作者，電話：03-4227151 轉 57619, E-mail: ftsai@csrnr.ncu.edu.tw

收到日期：民國 113 年 04 月 22 日

修改日期：民國 113 年 06 月 26 日

接受日期：民國 113 年 09 月 25 日

析衛星影像於視覺上將會更銳利化，目標細節亦可更被清楚呈現。

2. 相關研究

傳統超解析方法主要運用內插技術提升影像解析度 (Khaledyan *et al.*, 2020)，例如：雙三次插值 (bicubic interpolation)。惟此方法用於重建影像複雜紋理及邊緣細節時，效果表現不佳。近年來，伴隨深度學習技術蓬勃發展，影像超解析技術有顯著的突破，生成對抗網路即為一重要方法，透過生成器及判別器相互對抗，並交替訓練，可依據原始影像紋理特徵，有效重建並生成更高解析度影像，且該影像具備更多的細節及真實感。儘管生成對抗網路模型可有效提升影像解析度，但該模型仍存有一些問題，例如：訓練過程不穩定、生成影像有偽影產生、生成影像過於平滑及遺失部分紋理特徵等。因此，為解決前述問題，近期有許多研究針對生成對抗網路模型進行調整，並探討訓練資料的多樣性及模型架構是否與生成圖片的品質有關。期間經不斷修改模型架構及調整參數後，研究者們陸續提出改進版本，其中 ESRGAN 及 Real ESRGAN 係為以 SRGAN 為基礎研改之模型，與 SRGAN 模型相比，前述 2 個模型均將生成對抗網路內之生成器架構由殘差網路 (ResNet) 改為密集卷積網路 (Dense Net)，以提升模型學習影像特徵能力，另於密集卷積網路內移除 Batch Normalization，解決影像內隨機產生偽影情形 (Wang *et al.*, 2018、Wang *et al.*, 2021)，後續更有研究者依據 Real ESRGAN 模型進行修改，提出 StarSRGAN (Vo & Bui, 2023)，針對模型內的判別器架構由 U-Net 改為多尺度注意力 U-Net，其中多尺度可提升重建影像紋理及邊緣細節能力，注意力機制則可使模型聚焦於影像基本特徵，以整體強化影像超解析能力。

除了生成對抗網路外，其他基於卷積神經網路 (CNNs) 架構的深度學習方法亦於影像超解析上有顯著卓越的成果，例如：SRCNN、EDSR 及 VDSR 等 (Dong *et al.*, 2016、Lim *et al.*, 2017、Kim *et al.*, 2016)。這些方法主要探討如何運用殘差網路

(ResNet) 改善深度學習梯度消失問題，並可使模型構建深層的神經網路，以獲取影像內的複雜特徵，進而獲取超解析的成果 (He *et al.*, 2016)。

3. 研究方法

本研究主要使用三組衛星影像資料，第一組為中解析度衛星影像，空間解析度約 3 m；第二組為超高解析度衛星影像，空間解析度約 31 cm；第三組資料包含高解析度及超高解析度衛星影像，空間解析度介於 31 cm 至 6 m。主要流程首先為運用衛星影像訓練生成對抗網路模型，先將原始解析度之衛星影像進行 4 倍降解析 (Downsampling)，後續將 80%降解析度影像及其對應之原始解析度影像做為訓練資料，匯入模型從事訓練；待模型訓練完成後，匯出權重，並將剩餘 20%降解析影像資料匯入模型內，產製超解析 (Super resolution) 衛星影像。後續運用峰值訊噪比 (Peak signal-to-noise ratio, PSNR) 及結構相似性 (Structural Similarity Index, SSIM) 針對超解析影像及原始解析度影像進行比對，以評估超解析影像品質，本研究整體流程圖如圖 1 所示。

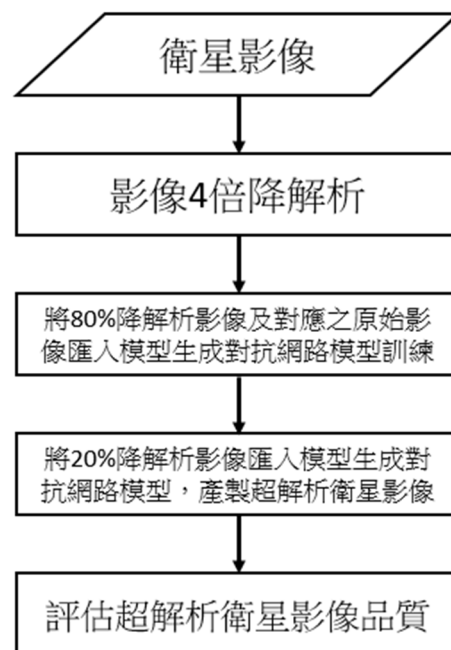


圖 1 整體研究流程

3.1 深度學習模型

利用深度學習模型進行分析主要目的為提升衛星影像空間解析度，以強化目標特徵細節。在將訓練資料輸入模型前，需對原始影像進行前處理，處理完成後，方可匯入模型訓練。本研究運用生成對抗網路提升衛星影像解析度流程包含 4 個步驟，分別為影像前處理、訓練生成對抗網路模型、產製超解析影像及超解析衛星影像品質評估，詳細說明分述如后。

3.1.1 影像前處理

(1) 裁切影像圖塊 (Image Patches)

由於深度學習模型的訓練和推理過程涉及大量的數學運算，包括矩陣乘法、卷積、激活函數等，現今常見深度學習模型框架，例如：Tensorflow 及 Pytorch，均支援在圖形處理單元 GPU 上執行深度學習模型，以從事加速運算。然而在處理大型模型和資料情況下，GPU 可能會有記憶體不足問題。因此，本研究若直接將整幅衛星影像輸入模型，將會導致記憶體不足而無法訓練，因此必須先行將整張影像裁切為多張影像圖塊，再匯入模型進行訓練，期可更順利處理大型、高解析度或不統一尺寸的影像，同時提升訓練效率和模型性能。

(2) 影像降解析 (Downsampling)

「降解析」為將原始高解析度影像轉換為低解析度版本，而「超解析」則是試圖從低解析度影像中重建出近似高解析度的影像，因此本研究透過先將原始高解析影像從事降解析處理，以獲取低解析度影像，並匯入生成對抗網路模型進行訓練。藉由影像內局部上下文 (Relative global contextual information) 關係，模型可根據低解析度影像中的結構和模式，更有效地預測高解析度影像中的細節，並在超解析過程中嘗試恢復丟失的細節。影像前處理流程，如圖 2 所示。

3.1.2 訓練生成對抗網路模型

生成對抗網路模型架構主要分為生成器 (Generator) 及判別器 (Discriminator) 組成 (Xiong

et al., 2020)，以下將模型各模組功能及訓練方式簡述如后。

(1) 生成器 (Generator)

生成器負責將低解析度影像轉換為高解析度影像，該模組使用卷積神經網路學習如何生成逼近於原始高解析度影像的圖像。

(2) 判別器 (Discriminator)

判別器是生成對抗網路中的另一個模組，亦由卷積神經網路構成，目標為區分原始高解析度影像及生成的超解析影像。

(3) VGG-19 預訓練模型

為訓練判別器，本研究運用預訓練的 VGG-19 網路萃取影像的特徵。這些特徵可用於衡量生成影像和原始影像間的差異，以利指導生成器生成更加真實的影像。判別器藉由該模型獲取影像特徵後，可計算生成的超解析影像和原始高解析度影像之間的感知損失 (Perceptual Loss)，故能更加客觀地評估 2 張影像於人眼視覺上的差異 (Ledig *et al.*, 2017)。此感知損失在訓練過程中將逐漸被最小化，並不斷回饋給生成器，將有助於生成器生成更逼近原始影像的超解析影像。

(4) 模型訓練方式

A. 訓練生成器

首先將低解析度影像輸入生成器，獲得生成的超解析影像，後續運用預訓練好的 VGG-19 網路提取生成的超解析影像和原始高解析影像的特徵，以計算感知損失，並衡量生成的超解析影像和原始高解析影像間的差異。本研究以特徵之間的均方誤差 (Mean Square Error, MSE) 作為感知損失，並在逐漸最小化感知損失的過程中，持續更新生成器的參數，以利生成器生成更逼近原始影像的超解析影像。

B. 訓練判別器

接續運用原始高解析度影像和生成的超解析影像訓練判別器，並計算對抗損失 (Adversarial Loss)；此損失目的為使判別器分辨生成的超解析影像和原始高解析度影像的特徵。本研究運用二元交叉熵 (binary cross-entropy) 衡量對抗損失，在訓練過程中，嘗試逐漸最小化對抗

損失，並持續更新判別器參數，以利判別器能夠更好地區分生成的超解析影像和原始高解析度影像。

C.交替訓練：

交替訓練生成器和判別器，於每個訓練步驟中，先更新生成器，再更新判別器，依循上

述方法重複訓練，並即時調整超參數 (Hyperparameter)，例如：學習率 (Learning Rate)，以利模型收斂並獲取更佳品質之超解析影像。簡而言之，生成器負責產製超解析衛星影像，判別器負責區分高解析度影像與超解析影像。訓練生成對抗網路模型流程，如圖 3 所示。

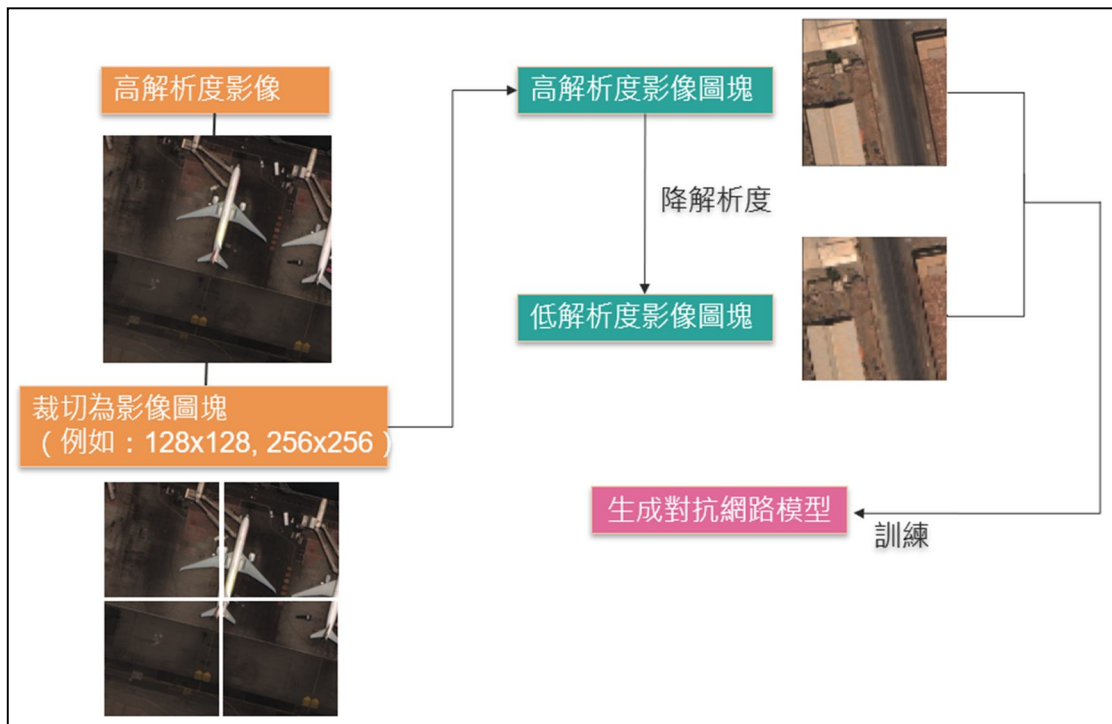


圖 2 影像前處理

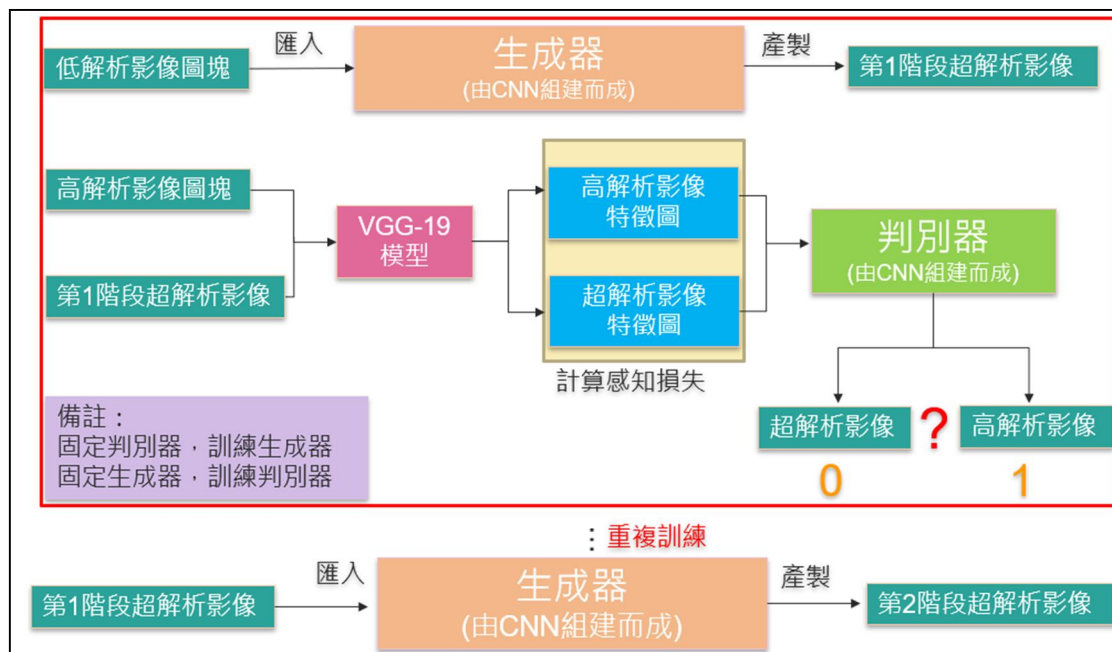


圖 3 訓練生成對抗網路模型流程

3.1.3 超解析影像品質評估

本研究採用 2 種量化分析指標評估超解析影像品質，分別為峰值訊噪比 (PSNR) 及結構相似性 (SSIM)，以下將此 2 種評估指標運算方式及評估方法 (Alain & Djemel, 2010) 簡述如后。

(1) 峰值訊噪比

為一常用於衡量影像品質的指標，用來量化原始影像和重建影像之間的差異，該指標計算方式基於影像的均方誤差 (MSE)，即重建影像和原始影像之間每個像素的差異平方的平均值，單位為分貝 (dB)，值愈高表示重建影像與原始影像之間的相似度越高，惟該指標存在部分局限性。例如：無法完全捕捉到人眼針對影像的失真型態。

(2) 結構相似性

主要考慮影像的亮度、對比度和結構等特徵，以更貼近人眼感知的方式評估影像的相似度，該指標值的範圍在 -1 到 1 之間，當值越接近 1，表示兩張影像越相似，也就是說，較高的 SSIM 值意味著重建影像與原始影像的結構、對比度和亮度等方面更相似。

3.1.4 神經網路模型

本研究運用的神經網路模型為 SRGAN (Super Resolution Generative Adversarial Network)，該模型主要由生成器及判別器建構而成，其中本研究所使用之生成器由 16 個殘差塊 (Residual Block)、2 個向上採樣模塊 (Upsampling Block)、卷積層 (Convolution Layers) 及輸出層組成；每個殘差塊內包含各 2 個卷積層及 Batch Normalization 層、1 個激活函數。殘差塊內的卷積層用於提取影像的特徵，Batch Normalization 層則可將每一層輸入的數據進行常態化，使數據分佈控制於特定範圍內，以有效改善梯度消失或爆炸問題，並加速模型收斂 (Shibani *et al.*, 2018)。每個殘差塊間均使用跳過連接 (skip connections) 保留低解析度影像的細節，如此一來有助於生成器學習低解析度到高解析度的映射，同時保留影像的結構。另向上採樣模塊運用 Pixel Shuffle 方法，透過重新排列像素，將低解析度

的特徵圖轉換為高解析度的影像。至於判別器組成，本研究先行構建判別器模塊 (discriminator block)，每個判別器模塊由卷積層、Batch Normalization 層及 LeakyReLU 激活函數 (Activation Function) 組成。判別器整體由 8 個判別器模塊、各 2 個全連接層 (Dense layer) 及激活函數組成 (第一個為 LeakyReLU、第二個為 Sigmoid)，其中卷積層用於提取影像特徵，激活函數放在卷積層後對影像特徵執行非線性處理，以利判別器學習更複雜的特徵。另全連接層則位於判別器的倒數第二層，主要用於將最終特徵表示映射為輸出分數，透過該分數判定輸入之影像是生成的超解析影像還是真實高解析度影像。SRGAN 生成器及判別器架構，如圖 4。

4. 研究成果及分析

4.1 研究資料

4.1.1 深度學習資料集訓練設定

本研究分別運用中解析度、超高解析度及混合高解析度及超高解析之衛星影像圖塊作為訓練資料集，以測試生成對抗網路模型對於不同資料來源之通用性，以下謹將各資料集詳細資訊分述如后 (詳如附表 1)。

(1) 中解析度衛星影像

本資料集係採用中解析度衛星影像 4000 張做為訓練及測試資料集，偵照區域位於美國舊金山灣 (San Francisco Bay) 及聖佩德羅灣 (San Pedro Bay)，每張影像大小均為 80×80 。影像均已透過融合演算法處理 (Pansharpened)，其波段包含紅光、綠光及藍光等 3 個波段，空間解析約 3 m，其中 1000 張影像內包含各式小型船隻，另 3000 張影像則未包含任何船隻。本研究先行將上述 4000 張影像尺寸調整為 128×128 ，後續再對該批影像進 4 倍降解析處理，故每張低解析度影像之尺寸為 32×32 。本研究隨機挑選 3600 張低解析度影像做為訓練樣本 (Training Set)，其餘 400 張做為測試樣本 (Testing Set)，每次迭代取 6 張影像 (6 Batch Size)，整個訓練過程將進行 30 輪 (30 Epochs) 計算。

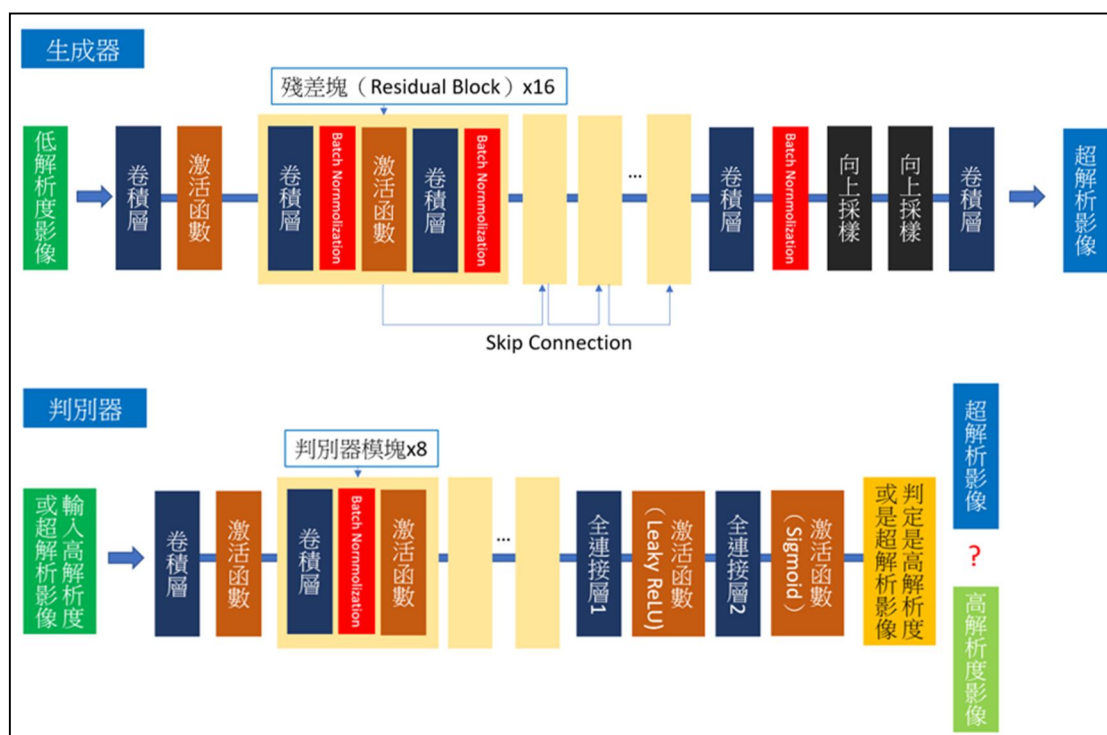


圖 4 SRGAN 生成器及判別器架構

表 1 影像資料集

| | 中解析度衛星影像 | 超高解析度衛星影像 | 高解析/超高解析度衛星影像 |
|------------|-----------|-----------|----------------|
| 空間解析度 | 約 3 m | 約 31 cm | 介於 31 cm 至 6 m |
| 影像張數 | 4000 張 | 2719 張 | 1275 張 |
| 原始解析度之影像大小 | 128 × 128 | 256 × 256 | 512 × 512 |
| 低解析度之影像大小 | 32 × 32 | 64 × 64 | 128 × 128 |
| 影像訓練張數 | 3600 張 | 2447 張 | 1147 張 |
| 影像測試張數 | 400 張 | 272 張 | 128 張 |
| 訓練次數 | 30 epochs | 50 epochs | 70 epochs |

(2) 超高解析衛星影像

本資料係採用超高解析度衛星影像 2719 張做為訓練及測試資料集，空間解析度均約 31 cm，影像均已透過融合演算法處理，其波段包含紅光、綠光及藍光等 3 個波段。此影像資料集內包含多種地景地貌特徵，例如：機場、城市、山地、港口及海岸等，另本研究亦調整訓練影像之尺寸，將上述 2719 張影像尺寸調整為 256 × 256，後續再對該批影像進 4 倍行降解析處理，故每張低解析度影像之影像尺寸為 64 × 64。本研究隨機挑選 2447 張低解析度影像做為訓練樣本 (Training Set)，其餘 272 張做為測試樣本 (Testing Set)，每次迭代取 1 張影像 (1 Batch Size，受限於硬體因素影響)，整個訓練過

程將進行 50 輪 (50 Epochs) 計算。

(3) 混合高解析及超高解析度衛星影像

本資料係採用混合高解析超高解析度衛星影像共 1275 張做為訓練及測試資料集，影像空間解析度介於 31 cm 至 6 m，影像波段包含紅光、綠光及藍光等 3 個波段。本研究先行將上述 1275 張影像尺寸調整為 512 × 512，後續再對該批影像進 4 倍降解析處理，故每張低解析度影像之影像尺寸為 128 × 128。本研究隨機挑選 1147 張低解析度影像做為訓練樣本 (Training Set)，其餘 128 張做為測試樣本 (Testing Set)，每次迭代取 1 張影像 (1 Batch Size，受限於硬體因素影響)，整個訓練過程將進行 70 輪 (70 Epochs) 計算。

4.2 成果分析與討論

4.2.1 成果分析

對於中解析度衛星影像，本研究將 3600 張影像匯入生成對抗網路模型訓練共計 30 輪，並分別輸出訓練 10 輪、20 輪及 30 輪之模型權重，後續分別將上述權重及測試樣本 400 張衛星影像匯入生成對抗網路模型。對於超高解析度衛星影像，本研究將 2447 張影像匯入生成對抗網路模型訓練共計 50 輪，並分別輸出訓練 10 輪、30 輪及 50 輪之模型權重，後續分別將上述權重及測試樣本 272 張衛星影像匯入相同模型。另對於混合高解析度及超高解析度衛星影像資料集，本研究將 1147 張影像匯入生成對抗網路模型訓練共計 70 輪，並分別輸出訓練 10 輪、30 輪、50 輪及 70 輪之模型權重，後續分別將上述權重及做為測試樣本之 128 張衛星影像匯入相同模型，以產製超解析衛星影像。

實驗結果顯示不論運用前述任何一種資料集做為訓練資料，生成對抗網路模型產製之超解析影像，於人眼視覺效果上，均能夠更加清晰呈現船艦或建物之特徵細節，且伴隨訓練次數增加，對於影像內的目標，其細節亦會更加清晰及銳利。惟目前遭逢問題為超解析影像均有色調偏移 (Color Drift) 現象；另以混合高解析度及超高解析度衛星影像作為訓練資料，所產製之超解析影像，影像內偶含有雜訊或偽影。上述問題須透過影像後處理或調整模型架構等方法進行改善，於問題討論章節將進行更細部探討。除運用人眼視覺直觀評估影像品質外，本研究亦以運用量化分析指標「峰值訊噪比」及「結構相似性」2 種指標評估超解析影像重建品質。實驗結果發現訓練愈多輪，結構相似性數值愈高，代表模型透過更深層學習，超解析影像與原始高解析度影像在結構上之相似程度會逐漸提升。惟在峰值訊噪比方面，發現訓練至特定輪數後，超解析影像之數值可能不升反降，顯示峰值訊噪比可能無法完全客觀評估超解析影像重建品質，另相比於運用 Bicubic Interpolation 所產製之超解析影像，於「結構相似性」指標方面，發現運用生成對抗網路產製之超解析影像效果較佳，惟於「峰值訊噪比」部分，

則發現 Bicubic Interpolation 產製之超解析影像的品質比生成對抗網路產製之超解析影像效果佳，造成前述 2 個指標的差異可能係為「峰值訊噪比」係用來衡量原始影像與失真影像之間的相似度，主要評估像素強度的差異，故當影像色調發生偏移時，像素的色彩分佈會與原始影像有所不同，導致兩者的像素值差異增大，因此「峰值訊噪比」的值會變小；「結構相似性」則以亮度 (luminance)、對比度 (contrast) 和結構 (structure) 評估影像相似性，當影像色調發生偏移時，可能會影響亮度或對比度，但對於影像的結構 (如邊緣或紋理) 沒有明顯變化，故色調偏移對「結構相似性」指標的影響較小，綜上所述，相較於 Bicubic Interpolation 產製之超解析影像，生成對抗網路產製之超解析影像於結構上會與原始影像更相近，故影像的邊緣及紋理可於視覺上更清楚呈現。

圖 5 所示為中解析度衛星影像產製之超解析影像比較；圖 6 則為超高解析度衛星影像產製之超解析影像比較；圖 7 為混合高解析度及超高解析度衛星影像產製之超解析影像比較。經綜整上述實驗結果，顯示生成對抗網路模型產製之超解析影像可明顯提高影像的細節，增進判讀成效，惟影像色彩偏移及偶有雜訊或偽影產生，仍為須持續改善議題。

4.2.2 問題討論

(1) 影像色調偏移

相比於原始影像，本研究生成之超解析影像均有色調偏移現象。經檢視模型架構，發現生成器內有向上採樣模塊，當影像進行向上採樣時，由於影像尺寸擴大，需要透過內插生成新的像素值，而此插值方法可能導致像素值間產生微小變化而影響影像整體色彩。實驗結果發現，若將模型進行更深層訓練，將有助於減輕影像色調偏移情形，其可能係因模型可從原始高解析度影像中學習到更深層次特徵，故對於低解析影像進行超解析處理時，可更佳保留原始低解析影像色調及紋理細節，所產製超解析影像之色調及特徵細節，將會更接近原始高解析影像。除前述方法外，透過影像後處理亦可減輕色調偏移現象，可將原始低解析影像及超解析影

像進行直方圖匹配 (Histogram Matching), 使超解析影像色調可接近原低解析影像色調, 縱然無法完全一致, 但仍可有效改善色調偏移情形, 圖 8 為比較低解析度影像、原始超解析影像及經直方圖匹配處理後之超解析影像, 圖 9 為前述影像於紅光、綠光及藍光波段之影像直方圖分布。

(2) 改善影像內含雜訊或偽影相關方法

本研究混合高解析度及超高解析度影像作為訓練資料, 每張影像大小為 512×512 , 實驗結果發現生成之超解析影像內偶有大量雜訊或偽影, 以下為改善影像內含雜訊或偽影相關方法。




圖 5 中解析度衛星影像產製之超解析影像比較




圖 6 超高解析度衛星影像產製之超解析影像比較




圖 7 混合高解析度及超高解析度衛星影像產製之超解析影像比較




圖 8 比較低解析度影像、原始超解析影像及經直方圖匹配處理後之超解析影像




圖 9 低解析度影像、原始超解析影像及經直方圖匹配之超解析影像於紅光、綠光及藍光波段之影像直方圖分布

A. 縮小訓練資料尺寸，減少模型運算資源

相比於中解析度及超高解析度衛星影像資料集，每張影像大小分別為 128×128 及 256×256 ，運用該資料集所生成的超解析影像未有大量雜訊或偽影。因此研判係因較大尺寸影像需消耗更多計算資源和記憶體，將可能導致模型無法有效地學習並生成完整超解析影像，故建議於模型訓練前，需考量硬體設備情況，彈性調整訓練資料之影像大小。

B. 調整生成對抗網路模型架構

為改善影像上隨機出現偽影情況，首先可針對模型架構進行調整，ESRGAN (係由 SRGAN 做為基底改進之模型) 於 2018 年被提出 (Wang *et al.*, 2018)，文獻指出 SRGAN 模型內係使用 Batch Normalization 於訓練中利用批量數據的均值和方差來對影像特徵進行歸一化處理，而在測試階段則使用整個訓練數據集的估計均值和方差。惟當訓練數據和測試數據間的統計特性差異較大時，特別於生成對抗網路 (GAN) 模型框架下，Batch Normalization 更容易產生不穩定的偽影，且偽影在不同的訓練迭代和設置中會隨機出現，導致訓練過程不穩定，限制模型的泛化能力，故於文獻中作者選移除 Batch Normalization，以提升模型訓練穩定度及提升泛化能力，另移除 Batch Normalization 可有效減少模型計算複雜度，有效降低顯卡內存使用量，實驗結果發現運用 SRGAN 模型產製之超解析影像確實於影像內偶有雜訊或偽影，經參考上述方法，未來可嘗試於模型內移除 Batch Normalization 作為後續研究方向，驗證是否可有效改善影像上隨機出現雜訊或偽影問題。

C. 使用單一解析度影像作為訓練資料

本研究使用三種不同組合的訓練資料，主要嘗試運用不同解析度的影像，測試是否能讓不同解析度的影像達到超解析效果。例如：使用解析度 30 cm 的 WorldView-3 超高解析度衛星影像作為訓練資料，期可提升高解析度影像 (如福衛 5 號影像) 的解析度；本研究亦探討將高解析度和超高解析度衛星影像混合作為訓練資料，以期進

一步提升中解析度影像的解析度 (如 Planetscope Dove 影像)；此外亦將解析度 3 m 之中解析影像作為訓練資料，期可提升中低解析度影像的解析度 (如 Sentinel-2 影像)，惟本次僅將測試資料進行降解析，再依模型訓練後的權重，執行超解析處理，以利運用量化指標評估超解析的效果，實驗結果顯示，發現若使用單一解析度影像執行訓練，測試影像上不會產生偽影或雜訊，惟若將混合超高解析度/高解析度影像匯入模型進行訓練，於測試影像發現會隨機產生偽影或雜訊，其可能原因包含本身模型架造成訓練不穩定，再者訓練樣本的解析度差異較大，造成訓練時梯度不穩定，模型在嘗試將這些不同解析度的影像學習到相同的超解析度邏輯時，可能會難以統一學習特徵，導致模型不易收斂或收斂速度變慢，最終造成生成結果不穩定，故為改善此問題，建議將訓練樣本的解析度調整更相近，或根據解析度差異進行分層訓練，從而幫助模型更好地學習不同解析度下的特徵。

5. 結論

本研究希望能透過運用生成對抗網路模型，有效提升多種衛星影像之空間解析度，以利後續目標偵測、辨識、和影像判讀等應用。實驗結果顯示，模型透過三個不同的資料集上進行訓練，所生成的超解析影像已經有效地強化目標物的特徵細節。此外，在視覺上，整體影像呈現出更明顯的清晰度和銳利度。綜上顯示，該模型呈現出色的通用性、適應性和泛化能力，使其能夠適用於多種不同來源的影像，進行高品質的超解析處理。然而，所生成的超解析影像均顯示出色調偏移情形，研判起因於生成對抗網路模型在生成超解析影像時需要進行插值和估算，惟為提升影像解析度，向上採樣係為必要的步驟，故導致色調偏移無法避免。儘管如此，本研究可透過更深層的神經網路訓練或進行影像後處理，嘗試改善色調偏移的情況。總體而言，生成式對抗網路深度學習可有效達成衛星影像的超解析處理，提高影像的空間細節，有利於目標偵測、辨識及影像判讀等應用；惟超解析影像的色彩偏移

則不利於光譜相關的處理與分析。

參考文獻

- Aiello, M., Vezzoli, R., and Gianinetto, M., 2019. Object-based image analysis approach for vessel detection on optical and radar images, *Journal of Applied Remote Sensing*, 13(01): 014502, DOI: 10.1117/1.JRS.13.014502.
- Alain, H., and Djemel, Z., 2010. Image quality metrics: PSNR vs. SSIM, *Proceedings of the 20th International Conference on Pattern Recognition*, Istanbul, Turkey., pp.2366-2369, DOI: 10.1109/ICPR.2010.579.
- Boain, R.J., 2004. A-B-Cs of sun-synchronous orbit mission design, *Proceedings of the AAS/AIAA Space Flight Mechanics Conference*, AAS04-108, Hawaii, USA.
- Dong, C., Loy, C.C., He, K., and Tang, X., 2016. Image super resolution using deep convolutional networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(2): 295-307, DOI: 10.1109/TPAMI.2015.2439281.
- Goodfellow, I.J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y., 2014. Generative adversarial nets, *Proceedings of the Advances in Neural Information Processing Systems 27 (NIPS 2014)*.
- He, K., Zhang, X., Ren, S., and Sun, J., 2016. Deep residual learning for image recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, NV, pp.770-778, DOI: 10.1109/CVPR.2016.90.
- Khaledyan, D., Amirany, A., Jafari, K., Moaiyeri, M.H., Khuzani, A.Z., and Mashhadi, N., 2020. Low-cost implementation of bilinear and bicubic image interpolation for real-time image super resolution, *Proceedings of the IEEE Global Humanitarian Technology Conference (GHTC)*, Seattle, USA, DOI: 10.1109/GHTC46280.2020.9342625.
- Kim, J., Lee, J.K., and Lee, K.M., 2016. Accurate image super resolution using very deep convolutional networks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, USA, pp. 1646-1654, DOI: 10.1109/CVPR.2016.182.
- Kim, M., Park, S., Sampath, A., Anderson, C., and Stensaas, G.L., 2022. System characterization report on Planet SkySat, Chapter E of System Characterization of Earth Observation Sensors, U.S. Geological Survey Open-File Report 2021-1030-E, DOI: 10.3133/ofr20211030E.
- Ledig, C., Theis, L., Huszar, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z., and Shi, W., 2017. Photo-realistic single image super resolution using a generative adversarial network, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, USA, pp. 105-114, DOI: 10.1109/CVPR.2017.19.
- Li, J., Qu, C., and Shao, J., 2017. Ship detection in SAR images is based on an improved faster R-CNN, *Proceedings of the SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA)*, Beijing, China, DOI: 10.1109/BIGSAR DATA.2017.8124934.
- Lim, B., Son, S., Kim, H., Nah, S., and Lee, K., 2017. Enhanced deep residual networks for single image super resolution, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Honolulu, HI, USA, pp.1132-1140, DOI: 10.1109/CVPRW.2017.151.
- Shibani, S., Dimitris, T., Andrew, I., and Aleksander, M., 2018. How does batch normalization help optimization?, *Proceedings of the Conference on Neural Information Processing Systems (NeurIPS 2018)*, Montréal, Canada, DOI: 10.48550/arXiv.1805.11604.

- Vo, K.D., and Bui, L.T., 2023. StarSRGAN: Improving real-world blind super-resolution, Proceedings of the International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision 2023 (WSCG 2023), Czech Republic, pp.62-72, DOI: 10.24132/CSRN.3301.9.
- Wang, X., Xie, L., Dong, C., and Shan, Y., 2021. Real-ESRGAN: Training real-world blind super resolution with pure synthetic data, Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) Workshops, pp. 1905-1914, DOI: 10.1109/ICCVW54120.2021.00217.
- Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Qiao, Y., and Loy, C.C., 2018. ESRGAN: Enhanced super-resolution generative adversarial networks, Proceedings of the European Conference on Computer Vision (ECCV) Workshops, pp 63-79, DOI: 10.1007/978-3-030-11021-5_5.
- Xiong, L.F., Guo, S.X., Chen, J.S., Deng, X.P., Sun, L.Y., Zheng, X.R., and Xu, W.N., 2020. Improved SRGAN for remote sensing image super resolution across locations and sensors, Remote Sensing, 12(8): 1263, DOI: 10.3390/rs12081263.

The Preliminary Evaluation of Generating Super-Resolution Satellite Images Using Generative Adversarial Networks

Ting-Shao Chang ¹ Fuan Tsai ^{2*}

Abstract

This study explores the use of Generative Adversarial Networks (GAN) to enhance the spatial resolution of satellite images, addressing resolution degradation caused by factors such as off-nadir angles, weather conditions, and sensor limitations. The research utilizes medium, high, and very-high-resolution images, applying downsampling and training the GAN to generate super-resolution images. During GAN training, the generator reconstructs low-resolution images into super-resolution ones, while the discriminator distinguishes between generated and real images. The study also utilizes the VGG-19 pre-trained model for feature extraction to improve image quality. Experimental results show that image details become sharper as training progresses, and the GAN outperforms traditional methods in terms of structural similarity. However, issues like color shifts and artifacts emerged during image generation. To address these problems, the study recommends deeper training, post-processing techniques, and model optimizations such as removing Batch Normalization. Overall, while GAN models show potential for enhancing satellite image resolution, further improvements are needed to resolve color shifts and artifacts, focusing on model stability and post-processing.

Keywords: Super Resolution, Satellite Imagery, Generative Adversarial Network, Deep Learning

¹ Master, Department of Civil Engineering, National Central University

² Professor, Center for Space and Remote Sensing Research, National Central University

* Corresponding Author, Tel: 886-3-4227151 ext. 57619, E-mail: ftsai@csrsr.ncu.edu.tw

Received Date: Apr. 22, 2024

Revised Date: Jun. 26, 2024

Accepted Date: Sep.25, 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.

Journal of Photogrammetry and Remote Sensing

CONTENTS

Regular Papers

- Automatic UAV Image Reconstruction for 3D Building Wireframe Models
(Yu-Ling Huang, Tzu-Yi Chuang)..... 129
- Development of an Ambient Temperature Prediction Model Using Machine Learning by Integrating Greenhouse Gas Emissions, Vegetation Index Satellite Images, and Land Use Data
(Hao-Ting Chang, Yinq-Rong Chern, Wan-Yu Liu, Chih-Da Wu) 151
- Impacts of the Level 3 Alert Brought by COVID-19 on Fine Particulate Matter of an Industrial City in Taiwan Using a Land-Use Based Machine Learning Model
(Jun-Jun Su, Pei-Yi Wong, Yu-Ting Zeng, Chia-Ho Lee, Chih-Da Wu)..... 165

Short Papers

- The Preliminary Evaluation of Generating Super-Resolution Satellite Images Using Generative Adversarial Networks
(Ting-Shao Chang, Fuan Tsai)..... 177

航測及遙測學刊

目錄

學術論著

- 三維建物線框模型之無人機影像自動重建
(黃郁翎、莊子毅) 129
- 結合溫室氣體排放、綠蔽度衛星影像與土地利用資料的環境溫度機器學習預測模型開發
(張皓庭、陳映融、柳婉郁、吳治達) 151
- 基於土地利用迴歸之機器學型模型分析新冠肺炎三級警戒政策對臺灣工業城市細懸浮微粒之影響
(蘇均瑀、翁佩詒、曾于庭、李佳禾、吳治達) 165

技術短文

- 運用生成對抗網路產製超解析衛星影像之先期評估
(張庭韶、蔡富安) 177