

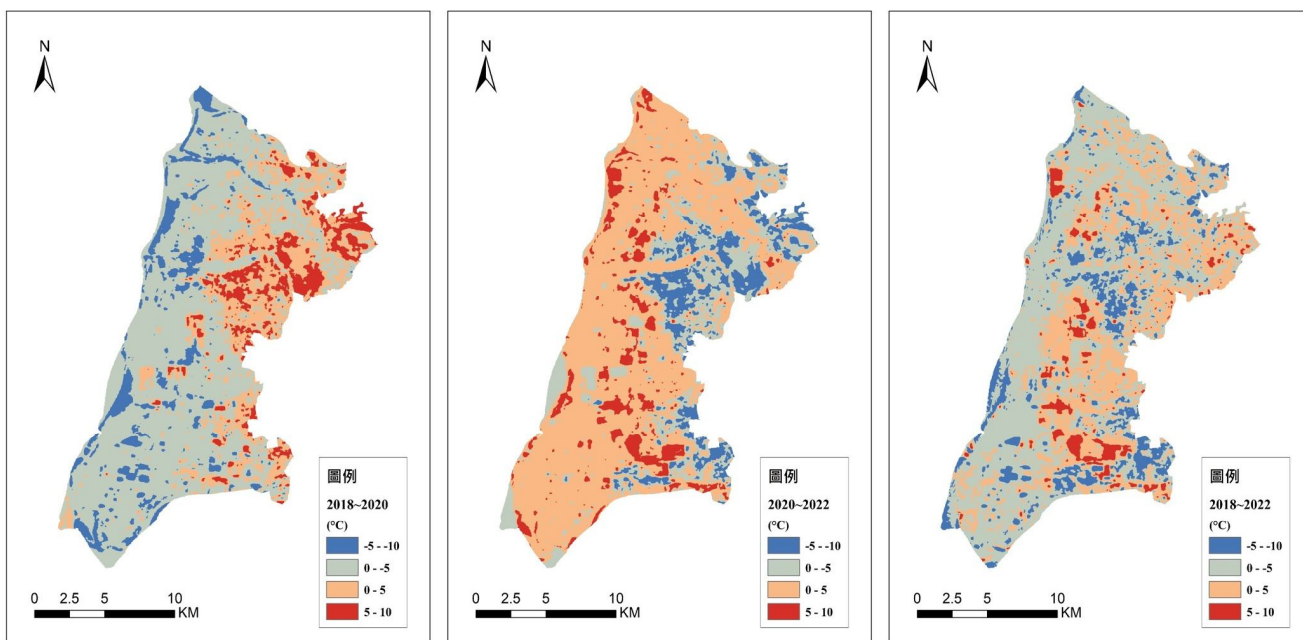
第三十一卷第二期  
中華民國一五年六月

ISSN 1021-8661  
DOI: 10.6574/JPRS



# 航測及遙測學刊

中華民國航空測量及遙感探測學會出版



Journal of Photogrammetry and Remote Sensing

Volume 31 No.2

June

2026

Published by Chinese Society of Photogrammetry and Remote Sensing

# 航測及遙測學刊

## Journal of Photogrammetry and Remote Sensing

發行人：蔡富安

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)

林玉農 (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)

曾國欣 (國立中央大學)

黃倬英 (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: Fuan Tsai

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)

K.H. Tseng (National Central University)

C.Y. Huang (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

2018 至 2020 年間，研究區東側呈現增溫趨勢，對照土地利用分類變遷圖與地表增溫的位置發現，原因可能與 58.77 km<sup>2</sup> 的植生地轉為裸露地，受比熱性質影響，裸露地白天升溫較植生地顯著；同期西側則多為降溫。2020 至 2022 年情況反轉，東側轉為降溫，其關鍵在於 58.28 km<sup>2</sup> 的裸露地轉為植生地，因為植生地的地表溫度在白天時會低於裸露地的地表溫度，所以會有降溫的情形發生。

# 運用遙測技術探討光電板對於地表溫度的影響： 以臺南地區為例

陳瑋竣<sup>1\*</sup> 王素芬<sup>2</sup>

## 摘要

光電板發電為臺灣綠色能源轉型的主要方式，尤其臺南市更多次成為全臺光電板發電量第一名，然而光電板是否對於周圍地表溫度造成影響，至今仍存在諸多爭議。因此本研究旨在利用遙測技術反演地表溫度。透過探討不同時期土地利用與地表溫度的關係進而了解光電板設置對地表溫度的影響。結果顯示地表溫度隨著距光電板距離增加而降低，且距離光電板約 25m 處地表溫度下降幅度最大。此外，從植生地與水體轉換成裸露地或光電板會造成溫度增加，不同區域同時期之裸露地相較於光電板溫度高約 1~2°C。

**關鍵詞：**光電板、土地利用變遷、地表溫度反演

## 1. 前言

### 1.1 研究動機

國家發展委員會於 2022 年正式公布「臺灣 2050 淨零排放路徑及策略總說明」，其中關於光電能源轉型的部分，透過土地多元化的運用管理方式，擴大光電覆蓋的面積，期望於 2030 年達到 30GW、2050 年達到 40~80GW 的發電目標(行政院國家永續發展委員會，2022)。

Piyatadsananon(2016)指出在淨零碳排的趨勢下，太陽能發電量的多寡，攸關這座城市是否有能力承接大型的活動，因此光電板的選址尤為重要。為了大規模且快速達到能源轉型目的，政府透過變更土地地目的方式，將原本屬於農田、魚塢的區域，配合農電共生與漁電共生政策，轉作為光電板的設置區域，不過此舉受到在地居民與農民的反彈，如臺南北門區居民認為光電會使溫度增高且破壞原有生態環境(楊語芸，2024)。賴偉銘(2022)認為在 2017 年以前，臺灣光電板的設置使得農地產生細碎化，

更影響鄉村傳統的自然景觀。若以政策面來說，可以優先選擇未使用或閒置中的魚塢作為優先區，因其不會與其他土地利用產生競合關係，故可以更容易設置光電板而未遭受地方阻攔。

國外對於光電板是否會造成該區域的溫度升高，研究結果不一，Zhang & Xu(2020)利用 MODIS 衛星的熱紅外光波段，評估全球前二十大光電設置場域與地表溫度的影響，研究結果發現裝設光電板後的地表溫度較控制區降低了 0.53°C，但 Barron-Gafford *et al.* (2016)透過溫度計每三十分鐘獲取一筆氣溫資料，以建立三種不同環境下的氣溫模型，以探討都市熱島效應(UHI)與光電熱島效應(PVHI)，研究表明夜間光電板的地表溫度會高於沙漠的地表溫度約 3~4°C。然而在水面上設置則如 Chen *et al.* (2025)利用 Landsat-8 衛星研究中國十五座水面型光電板對於周遭水與是否存在升溫的情況，該研究將每個水面型光電的水域分為近距區(0 ~ 120 m)與遠距區(120 ~ 240 m)，比較水面型光電板建設前後的年平均水面溫度(WST)。研究結果發現建設水面型光電板後會顯著提高鄰近水域的水面溫度，年均溫

<sup>1</sup> 國立彰化師範大學地理學系 碩士

<sup>2</sup> 國立彰化師範大學地理學系 教授

\* 通訊作者, E-mail: cigma520@gmail.com

收到日期：民國 114 年 07 月 15 日

修改日期：民國 114 年 10 月 15 日

接受日期：民國 115 年 03 月 10 日

升高約 1.05K，整體升溫的影響範圍約於 120 m 內。

臺灣地狹人稠，光電板等相關綠設施與居民生活、生產的空間重疊性高，充份了解光電板設置與溫度變化的關係，可以提供綠能政策重要的科學依據，故應用多時期遙測資料探討光電板對地表溫度影響至關重要。

## 1.2 研究目的

過往國外在探討光電板與地表溫度之間關係的文獻，大多實際前往現地設置氣象觀測儀器，此優點是能夠不分晝夜測量連續性的溫度資料，但其限制也非常明顯，如無法觀測過往的歷史溫度、僅適用於小範圍的樣區觀測、觀測成本過高，消耗人力以及物力、無法獲取研究區全面性的溫度資料等。因此，本研究擬利用遙測技術能同時且大範圍觀測地表溫度，了解地表溫度空間分布的特點，研究中使用 SPOT-7 衛星影像進行監督式分類，將土地利用分為植生地、水體、裸露地、建成地與光電板，並且運用 Landsat-8、9 衛星影像中的熱紅外線波段進行地表溫度反演，進而探討光電板的多時期地表溫度變化。基於上文所述，本研究目的的主要分為以下四點：

- (1) 以 SPOT-7 衛星影像分類建立臺南光電板主要設置區土地利用變遷圖資。
- (2) 透過 Landsat-8、9 進行地表溫度反演，建立臺南地區地表溫度圖資。
- (3) 比較不同土地利用間溫度的變化。
- (4) 了解光電板設置對地表溫度的影響。

## 2. 研究方法

### 2.1 研究區域

由於臺南市太陽能光電的發電裝置容量自 109 年起已連續五年為全臺第一名(臺灣電力公司，2024)，更在民國 108 年達到 1GW 的設置目標量，到了民國 110 年底，整體年發電量已達 33 億度，整體容量已佔全國 16.8%，並且有著相對其他縣市公開的光電資料與網站可供民眾查詢。北門區、學甲區、將軍區與七股區位於臺南沿海地區，自古以來

具有農田與魚塭的土地利用方式，光電板的設置則多為地面型與水面型，內陸地區較無法水面型的光電板設置方式，因此在探討光電板與地表溫度之間的關係，可以有更多元的比較結果。

本研究區位於臺南曾文溪口以北的沿海地區，由北到南分別為北門區、學甲區、將軍區與七股區，總面積約為 250.22km<sup>2</sup>，約占臺南市整體總面積的 11%。研究區東側與鹽水區、下營區、麻豆區、佳里區、西港區為界，西臨臺灣海峽，北側隔著八掌溪與嘉義縣為界，南側隔著曾文溪與安南區為界(圖 1)。

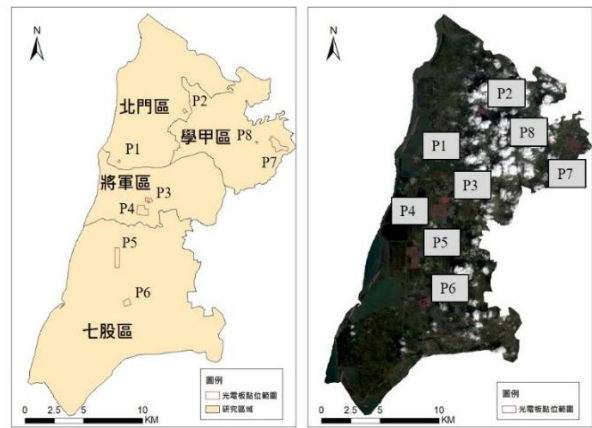


圖 1 研究區與實測點位地圖

### 2.2 研究材料

本研究衛星影像是用於反演地表溫度並找出光電板設置與地表溫度之關係，因此衛星影像選用的時間點尤為重要。以臺灣發展光電時間沿革，2017 年《電業法》三讀通過，正式開放綠電市場、2018 年政院通過《再生能源發展條例》修正草案、2020 年行政院核定「能源轉型白皮書」(經濟部能源局，2020)。並且參考前人研究得知，若選用時間於夏季，由於連日高溫之影響則地表的熱儲量不易隨時間消散，故在衛星影像中會出現整體研究區高溫之現象，不易反映出不同地物間的溫度差異，若為冬季會出現整體研究區受冷氣團低溫影響，地表的熱儲量不易儲存，故在影像溫度數據上不易反映出光電板溫度之差別。因此，本研究衛星影像選用時間將以春季與秋季為重點，最後選取 2018、2020、2022 年秋季衛星影響之緣故為：

- (1) 時間：時間為秋季時兩種衛星週期均為兩年為

一週期。

(2) 溫度：三個年段之當日平均最高溫與最低溫皆位於 $\pm 1.5^{\circ}\text{C}$ 內。

選用之衛星影像資料需先經過中央氣象署之氣候資料服務系統，利用臺南氣象測站資料進行當日最高溫及最低溫查詢，以避免該日受到極端天氣現象影響，以維護多時序衛星影像之天氣狀況穩定性，對於衛星影像地表溫度之反演更具樣本一致性。其衛星資料使用分為兩個步驟，首先利用多時序 SPOT-7 衛星影像，進行監督式分類，得到臺南地區土地利用變遷地圖。為了達成此目的，本研究衛星影像篩選標準，時間訂為 2018 年至 2022 年，篩選結果如表 1 所示。其次，利用 Landsat-8、9 衛星影像第 10 波段，透過溫度反演得出臺南地區地表溫度變遷地圖，再與 SPOT-7 衛星影像之臺南地區土地利用變遷地圖做疊合，以找出土地利用與地表溫度之間關係，並著重於探討光電板設置與地表溫度之關係。其衛星影像篩選標準，時間訂為 2018 年至 2022 年，篩選結果如表 2 所示。

並且本研究為驗證衛星遙測反演溫度之準確性，於 2022 年 10 月至 11 月期間，選定 8 處光電場址進行現地觀測。利用 SATO 阿斯曼通風乾溼度計記錄光電板周邊之溫度數值，作為後續與衛星反演溫度對比驗證之基準。此外選定這兩日是由於本研究利用 Landsat-8、9 衛星反演地表溫度的日期也是選定於 10 月中至 11 月中時間，若太早地表熱能可能難以散失，反之太晚則會受到東北季風影響。

## 2.3 研究方法

### 2.3.1 影像分類指標與方法

本研究利用最大概似法進行分類，參考前人研究中常見土地使用分類，本研究將臺南地區土地使用分為五類：植生地(Vegetation)、水體(Water)、建成地(Building)、裸露地(Barren Land)、與光電板(PV)設置地。

最大概似法為監督式分類中的一種方法，本研究選定五種不同的訓練樣區，各個訓練區的已知影像像元分別記載著不同的光譜值，最大概似法即透過已知去推算未知像元的光譜值，若最符合某特定分類的機率，則該未知像元即被歸類在該特定類別。

本研究利用監督式分類中的最大概似法進行土地利用分類，原因為以下兩點：

- (1) 先備知識：本研究區位於臺南沿海，該區主要的土地利用為水體(魚塢及海洋)、裸露地以及植生地，少許聚落以及光電板設置區。因此在進行分類時，可以精確圈選訓練樣區，進而提高精度。
- (2) 影像大小：研究區整體面積約  $250\text{km}^2$ ，區域內植生地多為農地為主，但由於臺灣地物邊界細碎且光譜呈現高度異質，容易產生混合像元與類別混淆。在此情境下，若僅採非監督式分類，常因自動分群受初始條件與光譜相似性限制而難以對應實際土地利用類別。

表 1 SPOT-7 影像選用表

日期	雲覆率(%)	圖號	最高溫( $^{\circ}\text{C}$ )	最低溫( $^{\circ}\text{C}$ )
2018/11/03	12	CSR_A0003551	30.6	21.3
2020/10/26	50(雲覆不影響)	CSR_A0010650	31.4	23.7
2022/10/12	25	CSR_A0020087	30.5	21.5

表 2 Landsat-8、9 影像選用表

日期	雲覆量(%)	圖號	最高溫( $^{\circ}\text{C}$ )	最低溫( $^{\circ}\text{C}$ )
2018/11/15	11	LC08_L2SP_118044_20181115_20200830_02_T1	30.1	19.8
2020/10/19	44 (雲覆不影響)	LC08_L2SP_118044_20201019_20201105_02_T1	32.2	21.6
2022/11/18	21	LC09_L2SP_118044_20221118_20230321_02_T1	31.3	22.2

### 2.3.2 地表溫度反演

本研究利用 Landsat-8、9 衛星影像進行地表溫度反演，在地表溫度反演前必須先處理衛星影像的參數。例如，輻射強度( $L_{TOA}$ ，式(1))與亮度溫度(覃志豪等，2001)( $T_i$ ，式(2))。本研究地表溫度反演利用 Band\_10 進行演算，步驟如下(莊明軒，2020)：

(1) 輻射強度

$$L_{TOA} = M_L \times QDN + A_L \dots\dots\dots (1)$$

其中  $L_{TOA}$  為衛星接收之輻射強度； $M_L$  為衛星 Metadata 中 Radiance\_mult\_band10 之值； $A_L$  為衛星 Metadata 中 Radiance\_add\_band10 之值； $QDN$  為研究區各像元之灰階值。

(2) 亮度溫度

$$T_i = \frac{K_2}{\ln(\frac{K_1}{L_{TOA}} + 1)} \dots\dots\dots (2)$$

其中  $T_i$  為亮度溫度(克氏溫標，K)； $L_{TOA}$  為輻射強度可由式(1)求得； $K_1$ 與 $K_2$ 為定值，其所代表著衛星發射前之預設常數，可以從衛星影像 Metadata 中得知。

(3) 地表溫度

$$LST = \left[ \frac{T_i}{1 + \left(\frac{\lambda \cdot T_i}{\rho}\right) \ln(\epsilon)} \right] \dots\dots\dots (3)$$

其中 LST 為地表溫度； $\lambda$ 波長為  $10.895\mu\text{m}$ ； $\rho = \frac{h \cdot c}{\sigma}$ ， $h=6.626 \cdot 10^{-34}$ 、 $c = 2.998 \cdot 10^8$ 、 $\sigma = 1.438 \cdot 10^{-2}$ ；

$$\epsilon = 0.004 \cdot P_V + 0.986 \cdot P_V = \left( \frac{NDVI - NDVI_{min}}{NDVI_{MAX} - NDVI_{min}} \right)^2$$

利用最大概似法分類出的土地利用與 Landsat-8、9 衛星影像之地表溫度反演結合，用以得出多時期不同土地利用轉變成光電板設置區對於溫度的影響，進而了解光電板設置後對於周遭地區的溫度是否造成影響。

### 2.3.3 實測光電板溫度

本研究為了找出溫度反演所得出之光電板地

表溫度與實測光電板溫度是否具有差異兩次實測設計如下：

- (1) 實測點位：本研究區橫跨四個行政區，每個行政區各兩個點位，共八個點位。
- (2) 實測時間：為了讓地表有時間增溫，故從早上九點起至下午三點止。
- (3) 實測路線：因為橫跨四個行政區，所以交通的時間成本需進行考量，故第一次實測路線由北往南、由東向西；第二次實測路線由南往北、由西向東。
- (4) 實測方法：(a) 離地高約 1.5m、(b) 濕球溫度計使用純水、(c) 開機實測時間為 15 分鐘。

## 3. 成果討論

### 3.1 土地利用變遷分析

#### 3.1.1 土地利用與分類成果

本節將說明利用 SPOT-7 衛星影像經過監督式分類與分類成果檢核，產出多時期的土地利用變遷圖表。其中衛星影像選用的時間分別是 2018/11/3、2020/10/26、2022/10/12，監督式分類採用最大概似法(MLC)將臺南地區土地利用分成五類，分別是水體(Water)、植生地(Vegetation)、建成地(Building)、光電板(PV)與裸露地(Barren)(圖 2)，各時期的面積如表 3 所示。為使得土地利用圖具有信效度，分類完的土地利用圖使用檢核點查核地真資料，以利進行整體精度、生產者精度、使用者精度以及 Kappa 係數檢核計算並產出檢核表(表 4~ 6)，以利進行後續分析。

本研究在進行監督式分類時針對五個不同的土地利用類別，進行選取訓練樣區的方法如下：水體(Water)：該研究區內水體包含海洋、魚塭以及河川，在整體衛星影像判釋時會以 NDWI 輔助訓練，其中海洋分布在西側，在選取訓練樣區時應避免潮汐所帶來之影響，如因退潮而產生的潮埔(Tidal Flat)所帶來的誤差；魚塭則是大部份分布在研究區的西半側，在衛星影像判釋上，魚塭因深淺度與藻類多寡會呈現出不同顏色，在選取訓練樣區時則會將各

顏色之魚塭加入進行訓練；河川則是會避免選取與岸邊過近的像元，以提高訓練樣區的精度。植生地 (Vegetation)：該研究區內植生地以農地為主，在整體衛星影像判釋時會以 NDVI 輔助訓練，其中農田在判釋時僅將取樣日期有在耕作農作物的農田判釋成植生地。建成地 (Building)：該研究區內建成地以聚落、工廠與道路為主，在衛星影像判釋時則會選取白色屋頂的建物以及選取道路進行訓練。光電板 (PV)：在衛星影像判釋時，光電板多呈現矩形並且在每一列光電板之間都有通道，因此在選取訓練樣區時需要分割每個區域的光電板，以避免精度下降。裸露地 (Barren)：該研究區內裸露地可分成未種植作物農地、荒地與潮埔，因此在選取訓練樣區時三者皆要進行選取以提高裸露地判釋精度。

在研究區面積變化方面，可以發現水體面積從 2018~2022 年增減幅度並不大，佔研究區整體 35%~40%；植生地面積於 2020 年時相較於它年有明顯下降則推測是該年度植生地轉為裸露地，因此在分類方法中未種植作物之農地則會被判釋成裸露地。為了證實可能是農地種植作物間的變化，從裸露地的面積也可以間接得知，裸露地於 2020 年的面積相較於它年有明顯的上升，佔整體研究區約 41%，若將植生地與裸露地合併起來則可以看出歷年面積從 2018 年 61%略降至 2022 年 53%；建成地面積 2018~2022 年從 3%增加至 6%。從建成地面積來

看，研究區並非是人口密集區，該區的產業也以農業與養殖漁業所屬之第一級產業為主，此外從建成地面積也可以間接證實研究區並非人口移入區，因此政府在能源政策上才會將此地規劃成以大量光電板為主的再生能源區域；最後以光電板面積變化來看，則可以發現從 2018 年 0.2%增加至 2022 年 2%，尤其是從 2020 年之後光電板面積快速增加，代表在 2020~2022 年間有大量光電板落成。

綜觀土地利用分類之檢核表，本研究利用 Google Earth 進行地真檢核，檢核點的生成採取分層抽樣之方式，依照面積比例大小去產出檢核點，從檢核表中可以看出水體與植生地的判釋精度高達 90%以上同時裸露地的判釋精度也達到 85%以上，惟 2018 年因光電板佔整體研究區範圍稀少且光譜特性與水體相似，所以使用者精度僅 20%。此外，建成地於各時期判釋精度差異大，推測是因為選取白色屋頂的光譜訓練樣區較為稀少，所以判釋結果會誤分到其他四類，使得精度下降。但各時期整體精度仍達到 91%~94%、Kappa 值 0.88~0.91，Kappa 值介於 0~1 之間其數值越接近 1 則所代表分類的準確度越可信 (林世峻, 2008)。因此，雖然建成地的使用者及生產者精度以及 2018 年光電板的使用者精度未達到本研究預想標準 80%，但分類結果仍然具有相當高之精度。

表 3 各時期土地利用面積

	面積 $km^2$ (%)		
	2018	2020	2022
水體	113.18(37)	107.08(35)	120.47(39)
植生地	115.23(37)	55.00(18)	111.07(36)
建成地	7.87(3)	18.37(6)	19.21(6)
光電板	0.69(0.2)	1.96(0.6)	5.13(2)
裸露地	73.04(24)	127.60(41)	54.14(17)

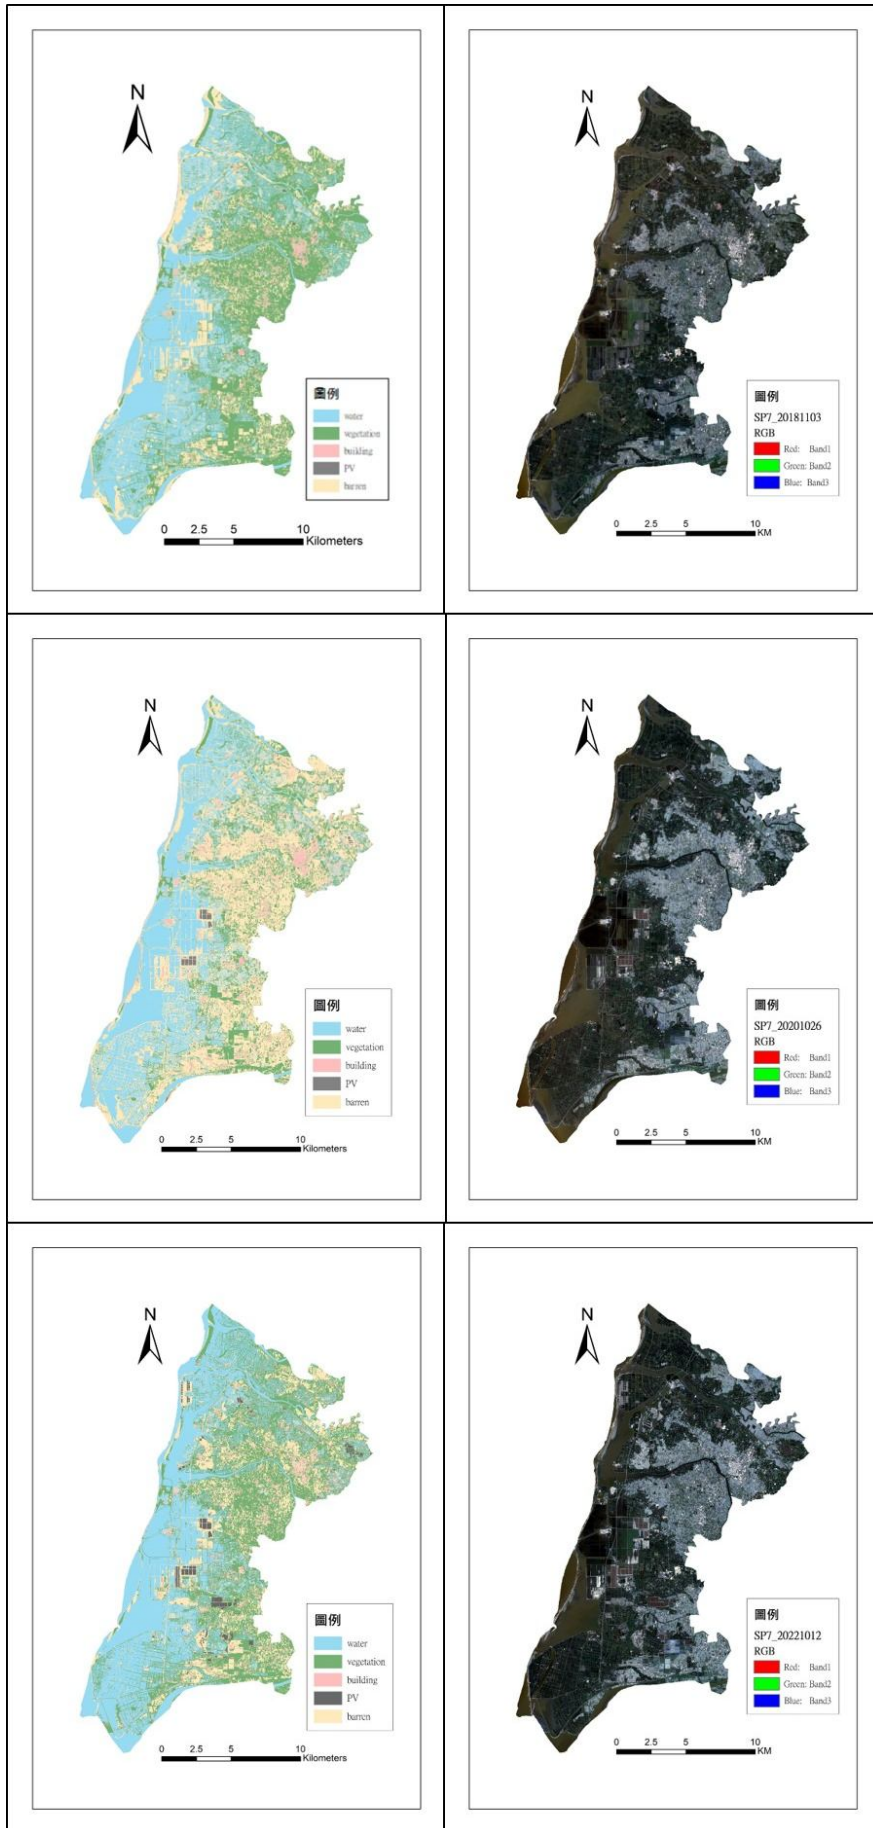


圖 2 2018、2020、2022 地物分類結果

表 4 2018 年土地利用分類檢核表

	水體	植生地	建成地	光電板	裸露地	檢核點數量	使用者精度(%)
水體	183	0	0	0	0	183	100.00
植生地	1	173	2	0	9	185	93.51
建成地	3	0	10	0	0	13	76.92
光電板	5	0	2	2	1	10	20.00
裸露地	4	1	9	0	104	118	88.14
檢核點數量	196	174	23	2	114	509	
生產者精度(%)	93.37	99.43	43.48	100.00	91.23		
總體精度(%)		92.73		Kappa			0.89

表 5 2020 年土地利用分類檢核表

	水體	植生地	建成地	光電板	裸露地	檢核點數量	使用者精度(%)
水體	173	0	0	0	0	173	100.00
植生地	1	88	0	0	0	89	98.88
建成地	4	3	20	0	4	31	64.52
光電板	1	0	1	8	0	10	80.00
裸露地	13	2	12	0	177	204	86.76
檢核點數量	192	93	33	8	181	507	
生產者精度(%)	90.10	94.62	60.61	100.00	97.79		
總體精度(%)		91.91		Kappa			0.88

表 6 2022 年土地利用分類檢核表

	水體	植生地	建成地	光電板	裸露地	檢核點數量	使用者精度(%)
水體	193	1	0	0	0	194	99.48
植生地	3	167	0	0	8	178	93.82
建成地	4	1	22	1	4	32	68.75
光電板	1	0	0	9	0	10	90.00
裸露地	0	0	7	0	80	87	91.95
檢核點數量	201	169	29	10	92	501	
生產者精度(%)	96.02	98.82	75.86	90.00	86.96		
總體精度(%)		94.01		Kappa			0.91

### 3.1.2 土地利用變遷成果

結合上述地物分類結果，本研究將進行土地利用之時空變遷分析，此分析共可分為三個時間段，分別是 2018~2020 年、2020~2022 年以及 2018~2022 年，利用上述兩個時期相減進而得出土地利用變遷地圖(圖 3)以及土地利用變遷矩陣表(表 7~9)以利觀察不同時期的變化，找出各時期不同地物分類的增減與地物間的轉換。本研究分析 2018~2020 年土地利用變遷，根據分類變遷矩陣可以發現有

14.49 km<sup>2</sup>的水體轉變成裸露地，其原因可能為蓋光電板前需要進行整地的作業，同時也有 11.19 km<sup>2</sup>的裸露地變為水體，此轉變可能跟魚塢是否放水有關係。另外植生地變成裸露地的現象，其轉變則可能跟農民的農作物收穫期程有關，因為適逢嘉南平原地區二期稻作收成時間為每年約 10 月下旬至 11 月中旬，所以 2018 年植生地有 58.77 km<sup>2</sup>轉為裸露地，在此時期植生地也有 5.65 km<sup>2</sup>成為建成地。至於裸露地也有 1.31 km<sup>2</sup>轉變為光電板，為此時期變為光電板最多的土地利用類別。

2020~2022 年土地利用變遷，從上文可以得知光電板相較於 2018~2020 年，在面積上有大量的增加，因此從分類變遷矩陣及變遷表可以發現光電板主要增加的原因是來自水體與裸露地的轉變，少部分則來自植生地。水體轉變為光電板的面積 1.15 km<sup>2</sup>；裸露地轉變為光電板的面積 1.82 km<sup>2</sup>；植生地轉變為光電板面積則 0.72 km<sup>2</sup>。此外，從中可以得知建成地轉變為光電板僅 0.1 km<sup>2</sup>，原因可能為該區域建成地多為聚落及工廠，僅工廠屋頂新設太陽能板在判釋時能夠被成功判釋出來，但聚落中民宅屋頂之光電板因面積較小之關係，利用 SPOT7 衛星影像因受限於空間解析度之關係則較難被判釋及計

算其面積。在此時間段也可以推論出二期稻作尚未收成，因為裸露地有 58.28 km<sup>2</sup> 再度轉變為植生地。

本研究綜觀分析 2018~2022 年，總共四年間土地利用之變遷，從分類結果可以發現主要有水體、植生地與裸露地為變成光電板的土地利用類別，其變遷的面積為 1.58 km<sup>2</sup>、1.55 km<sup>2</sup> 與 1.90 km<sup>2</sup>。植生地有 18.73 km<sup>2</sup> 變為裸露地，裸露地有 20.03 km<sup>2</sup> 變為植生地，光電板則較少轉作其他土地利用類別。若以整體土地利用類別面積增減可以看出植生地與裸露地皆減少，增加最多者則是建成地有 11.35 km<sup>2</sup>。

表 7 2018~2020 年土地利用變遷矩陣

		2020					LULC2018
2018	土地利用	水體	植生地	建成地	光電板	裸露地	
	水體	94.37	1.84	1.97	0.49	14.49	113.16
	植生地	1.02	49.61	5.65	0.14	58.77	115.19
	建成地	0.43	0.20	5.81	0.01	1.42	7.87
	光電板	0.13	0.02	0.13	0.02	0.38	0.68
	裸露地	11.19	3.30	4.79	1.31	52.51	73.10
	LULC2020	107.14	54.97	18.35	1.97	127.57	202.32
	面積變化	-6.02	-60.22	10.48	1.29	54.47	單位：km <sup>2</sup>

表 8 2020~2022 年土地利用變遷矩陣

		2022					LULC2020
2020	土地利用	水體	植生地	建成地	光電板	裸露地	
	水體	98.92	1.39	1.51	1.15	4.09	107.06
	植生地	0.95	46.97	2.06	0.72	4.30	55.00
	建成地	1.88	4.38	6.05	0.10	5.95	18.36
	光電板	0.41	0.03	0.02	1.33	0.17	1.96
	裸露地	18.29	58.28	9.57	1.82	39.62	127.58
	LULC2022	120.45	111.05	19.21	5.12	54.13	192.89
	面積變化	13.39	56.05	0.85	3.16	-73.45	單位：km <sup>2</sup>

表 9 2018~2022 年土地利用變遷矩陣

		2022					LULC2018
2018	土地利用	水體	植生地	建成地	光電板	裸露地	
	水體	98.95	4.52	3.29	1.58	4.83	113.17
	植生地	2.32	85.64	6.98	1.55	18.73	115.22
	建成地	0.67	0.77	3.84	0.02	2.56	7.86
	光電板	0.21	0.10	0.13	0.08	0.17	0.69
	裸露地	18.30	20.03	4.97	1.90	27.83	73.03
	LULC2022	120.45	111.06	19.21	5.13	54.12	216.34
	面積變化	7.28	-4.16	11.35	4.44	-18.91	單位：km <sup>2</sup>

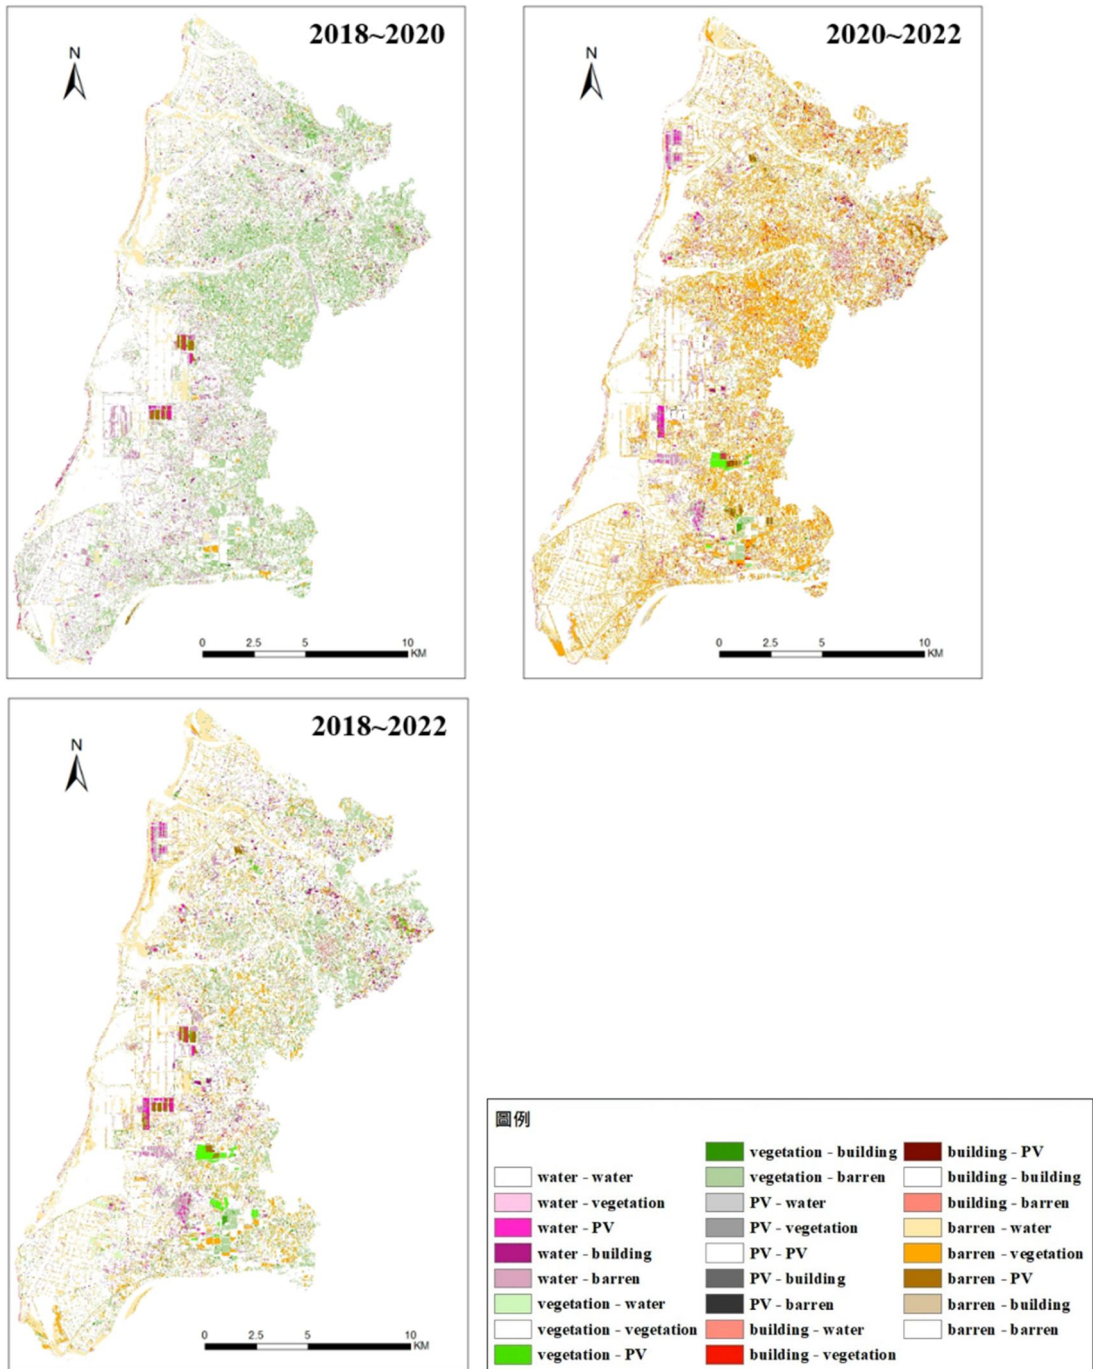


圖 3 多時期土地利用變遷地圖

### 3.2 地表溫度變遷分析

#### 3.2.1 地表溫度反演成果

本研究旨在了解光電板設置對於地表溫度 (LST) 的影響，因此本節將分析多時期地表反演溫度 (圖 4) 及各時間段地表溫度變遷成果 (圖 5)。

本研究區整體地表溫度分布情形，大致上可以分成西側與東側進行探討。研究區西側為臺灣海峽

以及魚塢為主，因為其土地利用是水體的關係，所以整體地表溫度較東側低；東側之土地利用則較為多元，如植生地、建成地與裸露地，由於建成地與裸露地比熱小之緣故，所以白天時的地表溫度較高，反之若為植生地，則地表溫度相較於上述兩者還要低。

本研究地表溫度反演與永康測站的歷史氣溫 (表 10) 對比之下可以發現，2022 年地表溫度反演之

最高溫與平均溫度與當年度氣溫之最高溫與平均溫度相比多了 2°C 與 0.8°C，顯示地表的熱能可能較大氣中的溫度不易散失，而使地表增溫現象較它年明顯，然而 2018 與 2020 年氣溫大多都高於地表溫度。

### 3.2.2 地表溫度變遷成果

本研究依據地表溫度反演結果產製出地表溫度變遷圖，2018~2020 年的地表變遷圖可以看出研究區東側有增溫的情形發生，若對照土地利用分類變遷圖與增溫的位置，其原因可能與 2018~2020 年間有 58.77 km<sup>2</sup> 的植生地轉為裸露地有關，因為裸露地的地表溫度在白天時會高於植生地的地表溫度，所以會有增溫的情形發生。另外在研究區的西側則大多呈現降溫的情形；2020~2022 年的地表變遷圖可以看出研究區東側有降溫的情形發生，若對照土地利用分類變遷圖與降溫的位置，其原因可能

與 2020~2022 年間有 58.28 km<sup>2</sup> 的裸露地轉為植生地有關，因為植生地的地表溫度在白天時會低於裸露地的地表溫度，所以會有增溫的情形發生，因此綜整 2018~2020 年與 2020~2022 年的地表溫度變遷圖，可以發現農地在收割二期稻作前後會對地表溫度產生影響，意即農地的地表溫度變化不全與光電設置直接相關，而是與耕作時序密切關聯。另外在研究區的西側造成地表溫度的增加呈現增溫的情形，原因可能為 2020~2022 年的地表溫度反演後，在最高溫、最低溫與平均溫度均有增加的情形，增加幅度分別為 2.3°C、2.4°C 與 2.3°C，增加幅度相較於 2018~2020 年來得明顯；若綜觀 2018~2022 年的地表溫度變遷圖與土地利用分類變遷圖進行比較，則可以發現植生地面積比例降低 1%，但裸露地面積比例降低 7%，因此推測出在研究區東側的農地可能會發生降溫的情況。另外建成地從 3% 提升至 6%，故在聚落的部分則呈現增溫的現象。

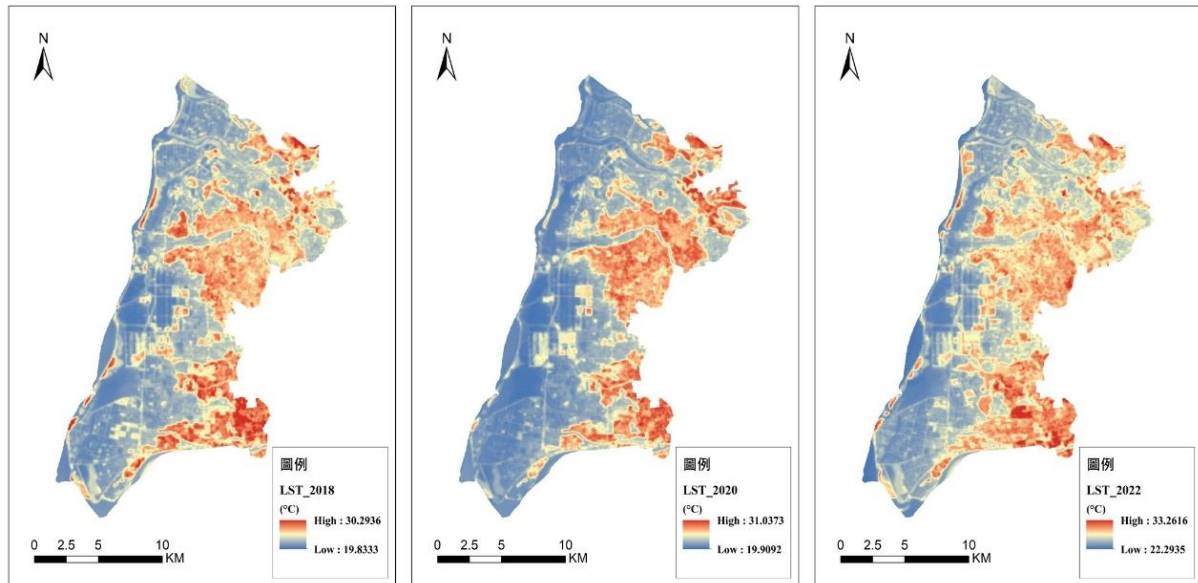


圖 4 多時期地表溫度分布圖

表 10 多時期氣溫與地表溫度整理表

日期		2018/11/15	2020/10/19	2022/11/18
最高溫	氣溫	30.1	32.2	31.3
	地溫	30.3	31.0	33.3
最低溫	氣溫	19.8	21.6	22.2
	地溫	19.8	19.9	22.3
平均溫度	氣溫	24.0	25.8	25.3
	地溫	23.4	23.8	26.1

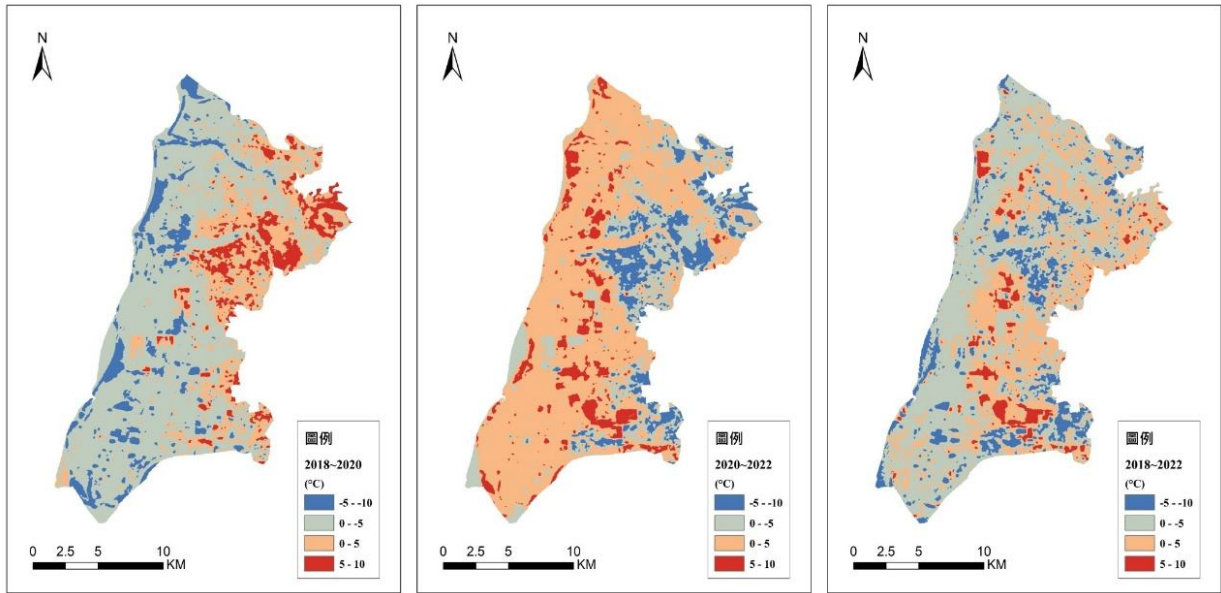


圖 5 多時期地表溫度變遷圖

### 3.3 光電板地表溫度變遷分析

#### 3.3.1 光電板與地表溫度變遷成果

本研究利用地物分類結果萃取出光電板的範圍再疊圖各時期地表溫度圖，製作出光電板地表溫度圖並將光電板的區域利用環域分析向外拓展 25m、50m、100m 與 200m 並將圖中平均溫度製作成折線圖，以利觀察光電板周邊溫度隨距離的變化(圖 6)。

本研究發現 2018 年的光電板溫度可能因為研究區光電板面積在這三個時期最少的關係，故在 0 ~ 25m 的距離下降約 0.5°C，25m ~ 200m 的距離下降約 0.2°C；2020 年的光電板溫度在 0 ~ 25m 的距離下降約 1.5°C，25m ~ 200m 的距離下降約 0.9°C；2022 年的光電板溫度在 0 ~ 25m 的距離下降約 0.4°C，25m ~ 200m 的距離下降約 0.8°C，此外 2022 年溫度明顯高於它年是由於該年的地表溫度反演的均溫相較於 2018 與 2020 年多了 2.7°C 及 2.3°C。綜上所述，本研究推論在不細究光電板周遭的土地利用是何種方式的前提下，光電板與周遭溫度的關係在 0 ~ 25m 相較於 25m ~ 200m 有明顯下降的現象產生。

#### 3.3.2 光電板溫度與實測溫度之比較

本研究將兩次實測紀錄中的濕球溫度與反演

之地表溫度(以下統稱為溫度)以及多時期實測點位土地利用結合進行分析(表 11)。其中 2024(2)由於觀測日期為 11 月，因此整體天氣受東北季風南下影響，因此有降溫之情形，所以可以先忽略不計。

首先 P1 在 2022 年以前皆為水體，溫度約為 22°C，但當 2022 年土地利用轉為光電板後，溫度持續上升至 26°C，整體增溫 4°C；P2 從 2018 年起為植生地加上裸露地後於 2020 年轉為裸露地加上光電板，因為有裸露地之緣故，所以整體溫度皆維持在 27°C，當裸露地完全變為光電板時則溫度下降 0.8°C；P3 於 2020 年之前均為水體，經 2022 年為了蓋光電板而整地變為裸露地至 2024 年均為光電板，因此溫度有先升後降的現象，從約 22°C 上升至 29°C 再下降至約 28°C，該點依然增溫約 6°C；P4 於 2018 年為裸露地，而後則變為光電板，溫度從約 26°C 上升至 28°C；P5 於 2020 年前為水體及少許裸露地，2022 年後為光電板，溫度從約 24 ~ 25°C 上升至 27°C；P6 與 P3 的土地利用轉變相同，因此溫度也呈先升後降的變化，從約 21°C 上升至 28°C 再下降至約 27°C，該點依然增溫約 6°C；P7 從 2018 年起為水體加上裸露地後於 2020 年轉為裸露地加上光電板，之後則為光電板，溫度從約 23°C 上升至約 27°C 再下降至約 26°C；P8 於 2020 年前為植生地加上裸露地至 2022 後變為光電板，溫度約 27°C 上升至約 28°C 再下降至 27°C。

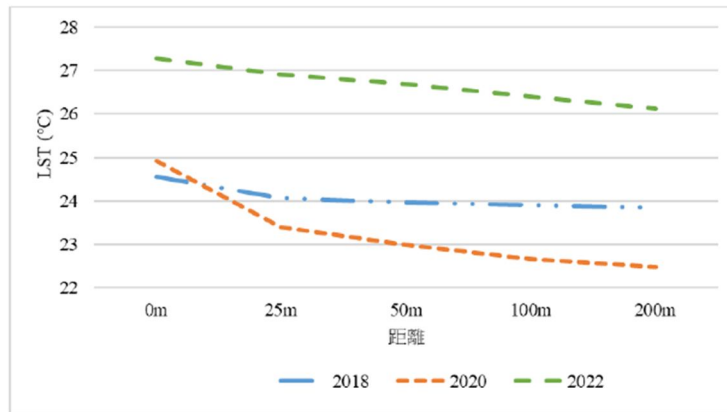


圖 6 各時期光電板周邊溫度與距離關係圖

表 11 多時期點位土地利用變遷與溫度表

	土地利用					
	2018	2020	2022	2024(1)	2024(2)	
	地溫(°C)			氣溫(°C)		
點位	P1	水體 (21.8)	水體 (22.2)	光電 (26.2)	光電 (26.7)	光電 (22.3)
	P2	植生+裸露 (27)	裸露+光電 (27.5)	光電 (27.6)	光電 (26.8)	光電 (22.8)
	P3	水體 (22.3)	水體 (22.6)	裸露 (29.4)	光電 (27.5)	光電 (22.4)
	P4	裸露 (26.2)	光電 (26.6)	光電 (28.7)	光電 (27.2)	光電 (22.4)
	P5	水體+裸露 (25.4)	水體+裸露 (24.2)	光電 (27.4)	光電 (27.3)	光電 (21.8)
	P6	水體 (21.6)	水體 (21.3)	裸露 (28.3)	光電 (27.1)	光電 (21.5)
	P7	水體+裸露 (22.8)	裸露+光電 (27.5)	光電 (27.4)	光電 (26.5)	光電 (23)
	P8	植生+裸露 (26.5)	植生+裸露 (27.8)	光電 (28.4)	光電 (26.8)	光電 (23)

綜上所述，本研究由溫度與土地利用之關係歸納出以下三點：

- (1) 裸露地是影響該區域溫度的最大因子，若是植生地、水體轉為裸露地則溫度都有所增加。
- (2) 若一地為混合式土地利用(如：水體加上裸露地)，則該區域溫度受裸露地的影響會最大。
- (3) 同一區域多時期土地利用為植生地或水體轉變為光電板時皆會使溫度增加；不同區域同時期土地利用為裸露地或是光電板時，光電板溫度較裸露地低約 1 ~ 2°C。

### 3.4 討論

衛星影像於特定土地利用分類判釋精度之問題：

由於本研究區範圍為 250.22 km<sup>2</sup>，因此在衛星影像的選擇上需要將分類精度與像元大小間作取捨，以避免檔案容量過大難以分析的情形產生，加上本研究區有土地利用破碎化的情形發生，故整體判釋會更加困難。又或者水體與光電板的反射光譜太過相近，研究區中的魚塢會因為其深淺、菌種不同造成顏色不同，導致 2018 年土地利用分類圖中有魚塢錯判成光電板的情形發生；聚落屋頂與海上之浪裂線在影像判讀上皆為白色，故在分類中也會將水體判釋成建成地，導致誤判的情形發生。

另外本研究並未探討風速對於地表溫度之關係，因為風會帶走地表的熱能，因此風速越大地表熱能散失越多，例如：本研究在第二次實測氣溫時，因東北季風南下、平均風速大與雲量覆蓋多之原因，所以相較於第一次觀測整體氣溫下降約 5°C。在實地測量氣溫的同時，本研究發現光電板周圍會留有維修可以通行之通道，這些通道的土地利用多為裸露地，因此依本研究之結論，裸露地與光電板會造成溫度上升，所以地表溫度會高於植生地或是水體。

## 4. 結論與建議

### 4.1 結論

本研究首先利用 SPOT-7 影像結合最大概似法進行臺南地區多時期土地利用的影像判釋，影像分類後的總體精度達 90% 以上，分類結果顯示研究區西側大多為魚塢與海洋等水體的土地利用；東側則以植生地與裸露地為主的農田以及聚落的建成地為主要的土地利用，因為衛星影像拍攝日期約於 10 月中至 11 月中，與嘉南平原農民二期稻米收割時期相符，故從多時期的土地利用可以發現植生地與裸露地之間面積變化約 60 km<sup>2</sup> 相較於他者土地利用來說最為明顯。另外光電板的範圍從 2018 至 2022 年占整體研究區 0.2% 增加至 2%，其中轉變為光電板的土地利用大多來自裸露地與水體兩者，從現地調查樣區中也可以看出光電板下方的土地多為裸露地以及水體等土地利用，因此在整體研究區以地面型與水面型光電為主，屋頂型光電為輔。

其次為取得整體研究區之地表溫度，因此本研究利用 Landsat-8、9 衛星影像反演地表溫度，從地溫變遷結果可以發現不同土地利用之間的變遷，會導致地表溫度的上升或是下降。例如：因為二期稻米收割的緣故，所以從植生地變為裸露地就會造成地表溫度的增加；因為受到潮汐的影響，所以從水體變為潮埔(裸露地)也會造成地表溫度的增加。

最後本研究透過土地利用與地表溫度的反演找出光電板對於周遭區域是否具有影響，以光電板為中心向外拓展 25m、50m、100m 與 200m，本研究發現在僅以距離作為唯一變數的情況下，離光電

板越遠溫度會越低。此外，若運用實測溫度與地表溫度結合去探討光電板興建前後期不同土地利用之間對溫度的影響，可以發現同一區域多時期土地利用為植生地或水體轉變為光電板時皆會使溫度增加；不同區域同時期土地利用為裸露地或是光電板時，光電板溫度較裸露地低約 1~2°C。

### 4.2 建議

本研究係利用 Landsat-8、9 衛星影像反演地表溫度，惟受衛星取樣時間與週期限制，無法全時進行監測，本研究為補足此缺口已實際至研究區測量氣溫，但受限於人力、物力、財力，仍無法進行全盤性的監測，尤其是研究夜間溫度的變化，建議未來可以設置溫度自動監測儀器，以更全面性的說明光電板對地表溫度是否具有影響。再者，前人研究多以 Landsat 系列衛星影像一併完成地物分類與地表溫度反演，本研究為求分類精準度，因此地物分類利用 SPOT-7 影像其優點為空間解析度為 6m，地表溫度反演則沿用 Landsat-8、9 衛星影像其空間解析度 120m，因此本研究利用 Arcgis 中 Resampling 方法將空間解析度同樣降為 6m，以利後續疊圖分析。惟因農地破碎化與研究區中屋頂型光電板面積範圍小之緣故，故較難以進行精確的分類，期待後續研究能利用解析度更佳之衛星進行小範圍長時間的研究以補足研究缺口。

此外，在光電板周遭若有聚落的存在，風向是否會將光電板產生之熱能吹往聚落，加上聚落本身之熱島效應，有可能使聚落溫度明顯增加。因此，未來相關研究可以結合都市熱島效應議題，利用熱島效應相關計算公式，從光電板著手研究光電板是否會造成熱島效應等議題。

## 參考文獻

行政院國家永續發展委員會，2022。臺灣 2050 淨零排放路徑，<https://ncsd.ndc.gov.tw/Fore/nsdn/about0/2050Path>，引用 2025/3/11。[National Council for Sustainable Development, Executive Yuan, 2020. Taiwan's Pathway to Net-Zero Emissions by 2050,

- Available at: <https://ncsd.ndc.gov.tw/Fore/nsdn/about0/2050Path>, Accessed March 11, 2025. (in Chinese)]
- 林世峻、莊智璋、何世華、林昭遠，2008。植生指標對影像分類準確度影響之研究，水土保持學報，40(2)：181-193。[Lin, S.C., Chuang, C.W., Ho, S.H., and Lin, C.Y., 2008. Effect of the vegetation index on the accuracy of image classification, *Journal of Soil and Water Conservation*, 40(2):181-193. (in Chinese)]
- 莊明軒，2020。台中地區土地利用與都市熱島效應之時空變遷之分析，國立臺灣師範大學地理學系碩士論文。[Chuang, M.-S., 2020. Multi-temporal land use land cover change and urban heat island effect analysis in Taichung, Master Thesis, National Taiwan Normal University. (in Chinese)]
- 覃志豪，Zhang, M.H., Arnon, K., Pedro, B., 2001。用陸地衛星 TM 6 數據演算地表溫度的單窗算法，地理學報，56(4)：456 - 466，DOI：10.11821/xb200104009。[Qin, Z.H., Zhang, M.H., Arnon, K., and Pedro, B., 2001. Monowindow algorithm for retrieving land surface temperature from Landsat TM6 data, *Acta Geographica Sinica*, 56(4):456-466, DOI:10.11821/xb200104009. (in Chinese)]
- 楊語芸，2024。鹽田夕照變「光電海」，台北門 33 公頃欲開發光電，雲嘉南風管處：濕地鹽田珍貴，不應開發，<https://www.newsmarket.com.tw/blog/210936/>，引用 2025/3/12。[Yang, Y.Y., 2024. Salt field sunsets become a “sea of solar panels”: 33 hectares in Beimen, Tainan planned for solar development; Southwest Coast National Scenic Area Administration says valuable wetland salt fields should not be developed, Available at: <https://www.newsmarket.com.tw/blog/210936/>, Accessed March 12, 2025. (in Chinese)]
- 經濟部能源署，2020。能源轉型白皮書，[https://www.moeaea.gov.tw/ECW/populace/content/Content.aspx?menu\\_id=13178&sub\\_menu\\_id=13180](https://www.moeaea.gov.tw/ECW/populace/content/Content.aspx?menu_id=13178&sub_menu_id=13180)，引用 2025/3/11。[Bureau of Energy, Ministry of Economic Affairs, 2020. Energy Transition White Paper, Available at: [https://www.moeaea.gov.tw/ECW/populace/content/Content.aspx?menu\\_id=13178&sub\\_menu\\_id=13180](https://www.moeaea.gov.tw/ECW/populace/content/Content.aspx?menu_id=13178&sub_menu_id=13180), Accessed on March 11, 2025. (in Chinese)]
- 臺灣電力公司，2024。再生能源台灣電力公司-購入電力概況，[https://www.taipower.com.tw/2289/2363/2380/2385/10625/normalPost#block\\_06455604-b745-4a9d-a21b-765acfae158a](https://www.taipower.com.tw/2289/2363/2380/2385/10625/normalPost#block_06455604-b745-4a9d-a21b-765acfae158a)，引用 2025/3/12。[Taiwan Power Company, 2025. Renewable Energy – Overview of Power Purchases by Taipower, Available at: [https://www.taipower.com.tw/2289/2363/2380/2385/10625/normalPost#block\\_06455604-b745-4a9d-a21b-765acfae158a](https://www.taipower.com.tw/2289/2363/2380/2385/10625/normalPost#block_06455604-b745-4a9d-a21b-765acfae158a), Accessed March 12, 2025. (in Chinese)]
- 賴偉銘，2022。探討漁電共生發展與區域土地利用政策之空間關聯—以臺南市沿海養殖漁業場域為例，逢甲大學都市計畫與空間資訊學系碩士論文。[Lai, W.M., 2022. Exploring the spatial relationship between the development of fishery and electricity symbiosis and regional land use policies - A case study of Tainan coastal aquaculture, Master Thesis, Feng Chia University. (in Chinese)]
- Barron-Gafford, G.A., Minor, R.L., Allen, N.A., Cronin, A.D., Brooks, A.E., and Pavao-Zuckerman, M.A., 2016. The photovoltaic heat island effect: Larger solar power plants increase local temperatures, *Scientific Reports*, 6(1): 35070, DOI: 10.1038/srep35070.
- Chen, D., Peng, Q., Lu, J., Huang, P., Liu, Y., and Peng, F., 2025. Assessing effect of water photovoltaics

- on nearby water surface temperature using remote sensing techniques, *Advances in Space Research*, 75(1): 138-147, DOI: 10.1016/j.asr.2024.08.040.
- Piyatadsananon, P., 2016. Spatial factors consideration in site selection of ground-mounted PV power plants, *Energy Procedia*, 100: 78-85, DOI: 10.1016/j.egypro.2016.10.135.
- Zhang, X., and Xu, M., 2020. Assessing the effects of photovoltaic power plants on surface temperature using remote sensing techniques, *Remote Sensing*, 12(11): 1825, DOI: 10.3390/rs12111825.

## Using Remote Sensing to Investigate the Impact of Photovoltaic Panels on Surface Temperature – A Case Study of Tainan City

Wei-Jyun Chen <sup>1\*</sup> Su-Fen Wang <sup>2</sup>

### Abstract

Photovoltaic (PV) power generation has become a key strategy in Taiwan's transition to green energy, with Tainan City repeatedly ranking as the leading municipality in PV electricity generation. However, the impact of solar panels on surrounding land surface temperature (LST) remains highly controversial. This study employs remote sensing techniques to examine the influence of PV installations on LST. By analyzing temperature variations across different land use types and time periods, the research aims to assess the thermal effects associated with PV deployment. The results reveal that LST decreases with increasing distance from PV panels, with the most significant temperature drop occurring approximately 25 meters away. Additionally, the conversion of vegetated or aquatic areas into bare land or PV-covered land tends to elevate in surface temperature. In some regions, bare land exhibited a temperature increase of approximately 1 to 2 °C compared to PV-covered surfaces during the same period.

**Keywords: Photovoltaic Panels, Land Use Change, Land Surface Temperature**

---

<sup>1</sup> Master, Department of Geography, National Changhua University of Education

<sup>2</sup> Professor, Department of Geography, National Changhua University of Education

\* Corresponding Author, E-mail: cigma520@gmail.com

Received Date: Jul. 15, 2025

Revised Date: Oct. 15, 2025

Accepted Date: Mar. 10, 2026

# 品質資訊導向的光學點雲測繪框架

莊芷瑄<sup>1</sup> 趙鍵哲<sup>2\*</sup>

## 摘要

近年來，點雲已成為多維度空間資訊獲取與應用中不可或缺的資料形式。然而，「品質」在點雲測繪流程中長期遭到忽略——現有研究多將品質視為事後驗證或成果評分的附屬要素，鮮少探討其對操作判斷、策略選擇與成果採用的影響。本文旨在揭開品質之於點雲測繪技術進步的重要性，品質不僅關乎成果可信度，更牽動整個測繪流程的運作。透過從資料特性、測繪流程與測繪工具等多面向的討論，說明品質如何在不同層次中形成風險、限制或決策依據。透過建立系統性的品質認知框架，為後續品質導向測繪流程與決策支援方法的發展奠定問題意識與研究基礎。

**關鍵詞：**光學點雲、品質資訊、測繪困難區、誤差分析

## 1. 前言

### 1.1 研究背景

#### 1.1.1 傳統測繪方法的基石：立體測圖技術與光學影像

傳統光學影像式空間向量資訊的獲取任務主要依賴立體測圖技術。立體測圖技術係指從兩張不同角度拍攝之影像重現場景空間幾何樣貌，利用立體觀測於立體模型中進行測繪。

然而立體測圖需要配備專業的測圖儀器及相關軟體，如圖 1 所示，作業人員必須具備一定的立體觀測能力、判讀專業和純熟的立體測繪操作技術。過往的測繪任務，針對各式地類地物的空間位置偏重於俯視輪廓的萃取，三維訊息(例如地形圖)的收集在此種作業模式下雖具品質及高可靠度，但二維影像相較於經過整合的三維模型，存在深度資訊不完整的限制，因影像受限於單一觀測角度，導致其在處理複雜場景的三維結構時表現不夠直觀，進而影響資料的應用效率。同時，影像的品質、拍攝角度以及影像的重疊率也對後續的資料處理結果產生直接影響。




圖 1 立體測圖環境專業設備(資料來源：3D PluraView)

#### 1.1.2 從傳統到現代：密匹配技術產製點雲的進步

隨著電腦視覺(Computer Vision)技術的迅速發展，密匹配(Dense Matching)技術在傳統攝影測量基礎上取得了重大突破，特別是逐像元匹配(Pixelwise Matching)的引入，由二維影像可生成高密度點雲。例如，Hirschmüller(2008)提出的半全域匹配法(Semi-Global Matching, SGM)，通過多組像對的成功匹配之共軛點進行空間前方交會，生成高密度的三維點雲。本文將此類經由光學影像產製之點雲稱為光學點雲，在以下內容也多處簡稱為點雲。

相較於僅仰賴有限視角影像對(Image Pair)的傳

<sup>1</sup> 國立臺灣大學土木工程學系 計畫研究專員

<sup>2</sup> 國立臺灣大學土木工程學系 副教授

\* 通訊作者, E-mail: jejaw@ntu.edu.tw

收到日期：民國 115 年 01 月 08 日

修改日期：民國 115 年 04 月 10 日

接受日期：民國 115 年 04 月 13 日

統立體測圖方式，高密度點雲能更完整且真實地描述目標場景之三維幾何結構，提供具連續性與高解析度的空間資訊，特別適用於地形測量與建物模型建置等需精細幾何表現的測繪任務。隨著空間資訊需求由二維圖資逐步轉向三維圖資，以建物為例，測繪任務已不再僅關注建物屋頂，而需完整描述立面與周邊空間關係，建模複雜度顯著提升，點雲因具備較完整及全面場景資料，能較有效支援現代測繪任務，已成為現代空間資訊萃取與三維測繪中不可或缺的關鍵資料。

### 1.1.3 點雲的優勢與應用價值

圖 2 展示了點雲相對於二維影像在描述真實三維場景時的優勢。傳統立體測圖在兩張影像組成的立體模型中僅能觀測有限的範圍，對完整場景的測繪需選用多組立體模型並組合測繪成果，作業效能不彰。

相較之下，經由多視角密匹配產製的點雲為目標物體的觀測提供了更簡便且高效的方式，不僅減少了影像挑選與拍攝限制對特徵表達的影響，其靈活性與直觀性更在三維場景和物體分析中展現出強大的應用價值，測繪人員可以在視覺化介面中直接縮放目標位置，並通過旋轉進行幾何形態與細節的全面觀察。如圖 2(b) 所示，點雲能清晰呈現建物屋頂的結構，而立體測圖則須結合不同視角(圖 2(a))之多幅影像對才能完整描述目標物，這突顯了點雲在立體幾何觀測中的效率與直觀性。

以內政部近年所推展之多維度資料建置為例，當遇到建物彼此緊鄰或共用牆面的情形，影像較難

以準確區分個別建物的獨立幾何特徵與高程資訊，因此多僅有繪製建物最外圍輪廓，如圖 3(a)及(b)所示(內政部國土測繪中心，2020)。相較之下，點雲資料能夠直接反映建物的真實三維結構，更容易辨識並萃取各棟建物的結構線，提高三維建物模型的精細度與建置效率。

點雲能夠直接、快速地獲取大範圍剖面上連續分布的三維坐標據以分析剖面高程資訊。如圖 4 所示，透過平台的分析功能，可即時產生沿剖面線方向的高程變化曲線，清楚呈現地物表面的起伏特徵與幾何形態，迅速提供完整且連續的高程相關資訊。

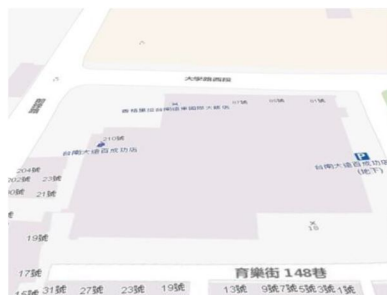


(a) 不同視角之二維影像



(b) 三維點雲

圖 2 不同視角影像對比於點雲描述真實場景差異



(a) 台灣通用電子地圖建物框



(b) 三維建物模型



(c) Google 街景

圖 3 三維近似化建物模型樓高與現況差異比較圖(內政部國土測繪中心，2020)

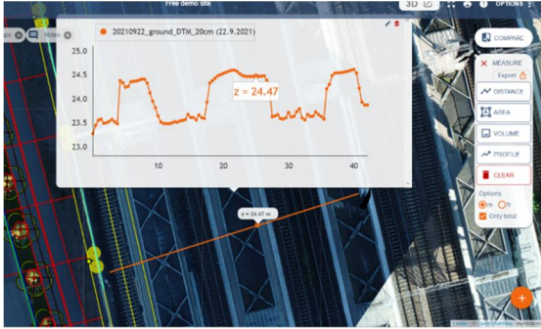



圖 4 快速取得地形剖面(高程)資料(截圖自 Point scene)

點雲亦能通過自動化或半自動化方法快速生成如建物輪廓(圖 5 (a))以及道路邊界及標線(圖 5 (b))等空間資訊，為各類三維場景自動產製任務奠定基礎。顯然地，這種基於三維空間的觀測模式顯著提升了測繪任務的效率與便利性。



(a) 建物結構線萃取(內政部國土測繪中心，2019)



(b) 道路標線萃取(Pix4D Survey)

圖 5 點雲於三維圖資產製之實際應用

### 1.1.4 點雲的測繪的挑戰

然而，在實際測繪應用中，點雲所展現的優勢往往伴隨著多層次的限制與不確定性，使其測繪成果的可靠性與一致性面臨挑戰。這些挑戰並非僅源自資料本身精度，而是同時受到資料特性、人工判斷、測繪工具設計以及自動化方法適用性的共同影


響。以下將從上述四個面向，說明點雲測繪現今所面臨的挑戰：

#### (1) 資料特性：點雲資料的雜訊型態

在點雲生成過程中，因多重點匹配或錯誤觀測值的累積，可能導致模型的幾何變形或結構失真(Yang *et al.*, 2023b)。同時，受點雲雜訊之干擾，即便在不同視角下，仍會影響測繪人員對特徵點的精確判斷(如圖 6 所示屋角頂點處)，不僅影響特徵萃取的準確性，還增加了後續資料處理的負擔。



(a) 原始影像



(b) 不同視角的點雲屋角頂點

圖 6 點雲雜訊影響

一般而言，雜訊對所測繪標的具干擾作用，其型態可視資料生產方式及特性再予細分。光學點雲的雜訊來源主要可分為(1)影像匹配以及(2)前方交會兩大面向。在影像匹配方面，光影變化、紋理重複性高表面、均質區域(如圖 7)、陰影遮蔽(如圖 8 紅框範圍)以及高反射材質等，都會造成輻射資訊不穩定，進而導致匹配產生誤差(包括隨機誤差及錯誤)，以及均質區域的失敗匹配；在前方交會方面，內外方位參數品質決定前交點位誤差(包括隨機誤差、局部扭曲以及系統性誤差)。總體而言，光學點雲的雜訊可分為隨機雜訊、錯誤、局部性幾何扭曲以及系統性偏移，是影響重建品質的一大因素。



(a) 原始影像



(b) 點雲

圖 7 均質區域(Yang *et al.*, 2023b)



圖 8 陰影區域(Yang *et al.*, 2023b)

點雲點位屬離散型，密度常呈不均勻樣態，點密度低的區域有可能是匹配失敗造成的點雲破洞(如圖 9)；錯誤匹配會扭曲場景幾何，這些樣態都會增加測繪困難及挑戰。

## (2) 主觀判斷：點位選擇對量測不確定性的影響

由於點雲描述的是三維空間結構，僅從單一觀測角度檢視模型時，往往無法完整呈現點位的實際空間位置，不同觀測角度可能導致對建物角點位置的判斷產生差異(圖 10)。此一角點判讀差異進一步反映於量測結果中，即使針對同一目標點位，在多視角條件下進行重複量測，所得結果仍可能存在偏差(圖 11)，使得點雲點位量測具有一定程度的不確定性，且易受觀測視角與局部幾何條件影響。

而量測場景或目標物表面能否被清楚辨識，受到點雲模型的幾何形狀、表面材質、色彩對比與光照條件影響。以下展示即使來自同一組點雲資料，位於相近高程的屋頂區域，仍可能因物體表面的材質特性影響匹配成果，而在視覺可辨識度上產生顯著差異。當目標物表面具有明顯的色彩對比且紋理清晰時，屋頂邊界與角點結構較易被辨識(圖 12)；反之，若表面顏色不明顯且受雜訊干擾，則會造成結構模糊與邊界不連續(圖 13)，使特徵角點的判讀難度提高。

最後，點密度對量測的影響也不可忽視。點位密集區域雖提供了更多選擇，但也增加了誤選的風險，特別是由於雜訊的存在(圖 14)，這可能會干擾精確的點位選擇。而在點位稀疏的區域(圖 15)，缺少必要的特徵點可能會導致測繪人員不得不選取周圍的點位，從而增加量測結果和實際標的位置之

間的差異。

## (3) 測繪工具：量測平台對資料潛力發揮的限制


軟體平台的操作友善性與工具設計也對量測效率與成果可靠性產生影響。現行常用之點雲測繪軟體各具其代表性優勢，例如 Pix4D Survey 針對測繪人員設計，具備直觀的量測介面，並支援多角度同步檢視，有助於提升點位判讀與向量編輯的效率；PointScene 以網頁式平台形式提供即時量測功能，能隨操作動作即時顯示斜距、角度及體積等資訊，適合快速分析與成果展示；CloudCompare 作為開源軟體，支援多種點雲與網格模型格式，並提供豐富的點雲處理與分析工具，廣泛應用於學術研究與實務任務；以高效能網頁式點雲顯示著稱的 Potree Viewer，適合大型點雲的快速瀏覽；而 Global Mapper 提供物件偵測與分類等自動化功能。

整體而言，這些軟體多各自聚焦於特定功能取向，形成「功能分散」的發展現況，尚難在單一平台中同時兼顧資料格式彈性、即時量測效率、多視角操作、進階處理能力與良好的互動效能。部分軟體雖操作友善，卻在資料編輯或品質分析功能上有所限制；部分工具功能完整，卻因介面複雜或效能負擔，使實際操作流程不夠流暢。因此，在實務測繪作業中，測繪人員往往需搭配多套軟體以完成不同階段的工作，並主要依賴個人經驗判斷量測結果的可靠性。此一現象顯示，現階段點雲測繪軟體平台仍處於持續發展階段，尚未能在單一平台上全面滿足測繪作業需求。更重要的是，現行平台的互動設計多以成果產製與編輯為核心，普遍缺乏將點雲品質資訊納入量測與判斷流程的輔助機制。



(a) 原始影像 (b) 點雲

圖 9 點雲破洞



(a) 第 1 次選點 (b) 第 2 次選點

圖 10 不同觀測角度影響角點判斷



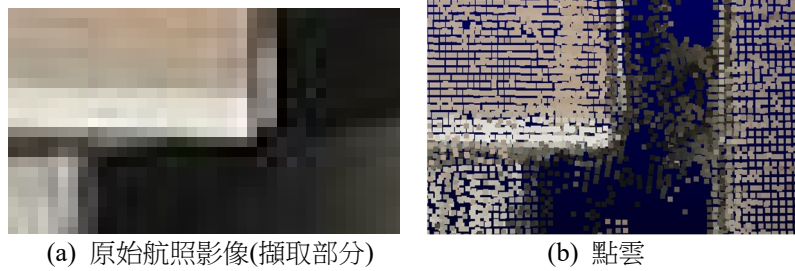


圖 11 點雲點位量測不確定性




(a) 原始航照影像(擷取部分) (b) 點雲

圖 12 色彩對比明顯的屋頂角點




(a) 原始航照影像(擷取部分) (b) 點雲

圖 13 受雜訊影響的屋頂角點



(a) 原始航照影像(擷取部分) (b) 點雲

圖 14 點密度高但過於雜亂



(a) 原始航照影像(擷取部分) (b) 點雲

圖 15 點密度低以致資訊不夠完整

#### (4) 自動化方法：效率提升與可靠性之間的取捨

現有點雲測繪軟體雖已導入部分自動化功能，如表面平面萃取與顏色分類等，在一定程度上提升了資料處理效率，然而在面對幾何結構複雜或資料品質不佳的場景時，自動化工具仍難以同時兼顧結果的正確性與處理穩定性。由於現階段自動化技術尚未成熟，仍無法全面取代人工進行高精度的品質判讀與控管，人工量測、檢查與編修在實務測繪中依然是不可或缺的關鍵環節，其結果亦直接影響最終測繪成果的準確性與可靠性。

在 Li & Wu(2021)的研究中指出，點雲資料缺陷與建物結構複雜性影響建物模型之自動化萃取結果。如圖 16(a) 上半部兩張圖片所示，紅色區域為

錯誤匹配點所造成的過度估計，這些點可能位於航空影像的視線死角；而圖 16(a)下半部兩張圖片中的藍色區域則顯示垂直牆面完全缺失時，因資料不足造成建物表面無法被正確萃取，導致模型表面無法完整重建，顯示自動化方法在實際應用中對點雲缺陷具有敏感性且仍需人工介入。

在點雲測繪的領域中，自動化已成為不可或缺的趨勢。然而，要實現從點雲蒐集到空間資訊產製的整個過程全面自動化，仍需要一段時間的努力和技術突破。因此，在這一願景實現之前，如何在測繪平台中適當引入自動化作業，使其能實質輔助人工判讀、降低作業負擔，並同時維持成果品質與可靠性是值得關注的重要議題。




圖 16 建物模型重建錯誤區域，(a)2 維(XY)展示重建模型與人工數化之地真資料差異、(b)人工數化之地真資料套疊正射影像、(c)建物模型重建錯誤或缺失之點雲、(d)所構建之建物模型(Li & Wu, 2021)

## 1.2 研究動機與目的

從上述說明，事實上反映現有點雲測繪流程普遍存在一個共同缺陷，即缺乏對測繪結果品質資訊的反饋，在多種因素相互作用下，影響測繪效率與成果可靠性，並導致點雲資料之潛在效益未能充分發揮。在現有平台中，空間資訊生成後往往直接進入後續應用，而缺乏品質控制機制來及時發現並修正錯誤，若未引入有系統的品質評估，點雲測繪可能難以突破發展初期的局限和應對未來測繪技術的進一步要求。

在本研究中，品質指的是點雲資料及測繪成果在空間位置準確性、幾何結構穩定性與應用可靠性等面向上所具備的可信程度，並應是一種可被檢視與參考的資訊，用以輔助後續判讀與決策。具體而言：空間位置準確性係指測繪資料及結果在三維空間中的正確性；幾何結構穩定性是指正常匹配的點雲應能穩定表達目標建物的幾何結構，包含點位排列均勻等特徵，當出現雜訊或點位缺失時，即代表該區域點雲的幾何結構呈現不穩定狀態；應用可靠性則強調透過品質評估策略與相應的品質資訊，為測繪資料及成果提供客觀的評判標準與「品質標

籤」，讓測繪人員能夠明確了解點雲資料及測繪成果精度範圍，進而判斷其適用的精細程度與整體可靠性。

以下從資料層、流程層與決策層三個層面(統整說明如表 1)，說明為何品質資訊必須成為點雲測繪過程的核心部分：

### (1) 資料層面：從品質未知到品質可知

點雲品質在空間上高度不均勻，遮蔽、曲面、邊界及低密度區皆為量測風險來源。然而，現行測繪流程缺乏對這些空間品質變異的系統性評估機制，測繪人員無法預先識別哪些區域存在高風險。具體而言，現況無法事先判斷點雲資料在不同空間位置的可靠度差異，遮蔽區、低密度區等測繪困難區未被明確標示，且缺乏客觀指標來描述資料的穩定度、不確定性與一致性。可能導致測繪人員在不可靠的資料上進行測製。

### (2) 流程層面：從事後驗證到即時回饋

現行測繪流程中，品質通常在量測完成後才受檢驗，缺乏即時品質回饋機制。這種先做再查的流程模式，使得測繪人員在作業過程中如同盲目前行，缺乏品質控制機制來及時發現並修正錯誤，無法即時感知資料品質變化或立即調整處理順序、參數設

定或操作策略。多數測繪作業假設點雲品質無虞，當發現問題時往往已完成大量作業，修正成本高昂且耗時，更可能導致大量無效作業的累積。

### (3) 決策層面：從憑經驗判斷到有依據決策

在成果決策的階段，測繪人員面臨難以客觀判斷量測結果是否可信的困境，主要依賴個人經驗與主觀判斷，無法識別哪些區域需要策略性補測或重新量測，且缺乏明確的品質標準來決定測繪成果是否可用、是否需補測或修正，同時也無法保證建置成果的可靠度。

總結來說，品質資訊應該成為測繪過程的一部分，而非事後附加物。唯有從資料層建立品質感知能力、在流程層實現即時回饋機制以及於決策層提供客觀依據，才能從根本上突破現行點雲測繪的限制，應對日益複雜的多維度空間資料建置需求並確保測繪成果在多樣化場景中的穩定性和可靠性。本研究不著重於開發全新平台，也非與傳統方法比較精度差異，而是從現有作業流程切入，補足長期受到忽略的品質資訊層面，建立品質意識與輔助判斷機制，示意圖見圖 17。

## 2. 文獻回顧與課題形塑

### 2.1 點雲於多元空間資訊萃取任務之測繪進展

近年來，隨著光學測繪、行動量測與感測技術的發展，點雲已成為三維空間資訊萃取中最重要的資料形式之一，並已廣泛應用於智慧城市、災害監測、基礎設施健康監測、自動駕駛、高精地圖與文化資產保存等領域(圖 18)(Yang *et al.*, 2023a)。顯露度即為對空通視度，無法通視的區域即為遮蔽。針對多種既有的顯露度或遮蔽角測量方法，以下介紹

及分析三類較具實用性的作業方式。

然而，Mirzaei *et al.* (2022)指出，點雲本身屬於高度非結構化資料，普遍存在點分布不均、雜訊干擾、遮蔽效應嚴重以及缺乏語意資訊等問題，使其難以直接支援測繪與工程應用。在實際的大尺度測繪環境中，點雲資料處理流程仍仰賴大量人工介入(鄭錦桐等, 2021)，無論在效率或成果穩定性上皆存在限制，顯示點雲測繪技術尚未成熟為可全面取代人工立體測圖的方法。點雲測繪技術的瓶頸並不在於資料取得本身，而在於缺乏具備品質可控性與可解釋性的處理與判斷策略，使得測繪成果的可靠性與適用性難以一致評估。

在實務應用層面，為改善點雲於視覺化、檢索與幾何理解上的困難，不少業界嘗試引入三維網格模型(Mesh Model)等結構化表示方式，網格模型相較於原始點雲更易於觀測整體形態與表面變化(Xu *et al.*, 2021)。網格模型的品質與其生成流程與參數設定高度相關，不同軟體或平台所採用的建模策略差異，往往導致成果呈現顯著不一致，如 Sorgente *et al.*(2023)針對網格模型的特徵保留能力分析，其中一項關鍵評估指標是在不同演算法計算下的網格邊緣是否能夠準確地再現目標物體的特徵線(Feature Line)，如圖 19 所示。許展祥等(2022)的研究顯示，三維網格模型之製圖精度除了承襲傳統攝影測量的誤差來源外，亦受到密點雲匹配誤差與網格建模流程誤差之影響，在高精度測繪應用情境下，例如一千分之一地形圖繪製，現階段網格模型尚難以滿足既有精度規範要求，亦不宜作為正式測繪成果的唯一依據(Jhuang & Jaw, 2024)。

點雲於多元空間資訊萃取任務中的應用已展現高度潛力，但其測繪流程仍面臨品質不確定性高、處理策略不一致以及成果可靠性難以量化等問題。

表 1 品質資訊缺乏對點雲測繪流程各層級之影響

層級	層級定義	對測繪流程造成的影響
資料層	描述點雲、影像或衍生幾何本身之品質特性，如誤差、不確定性與一致性	測繪人員無法預先識別高風險區域，如同在品質未知狀態下進行作業，難以避開測繪困難區
流程層	在測繪流程進行中即時產生、更新或回饋之品質資訊，用以影響操作與處理策略	問題往往於事後才被發現，修正成本高，易累積大量無效或重複作業
決策層	提供測繪人員或系統進行成果採用、取捨與控管之品質依據	資源配置效率不佳，成果可靠性與一致性難以保證，不同操作者間判斷差異大

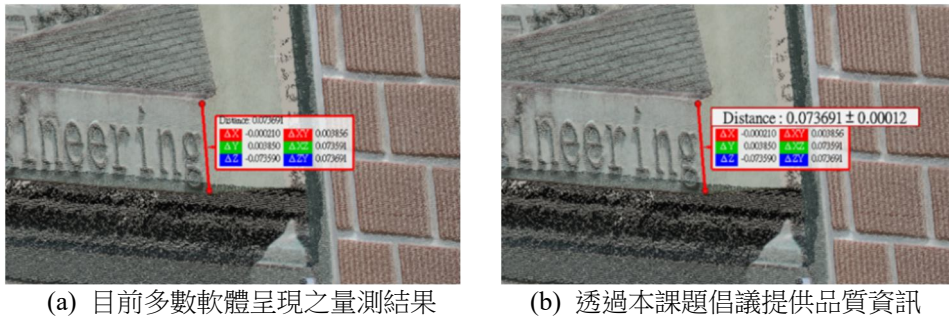


圖 17 幾何資訊量測示意圖

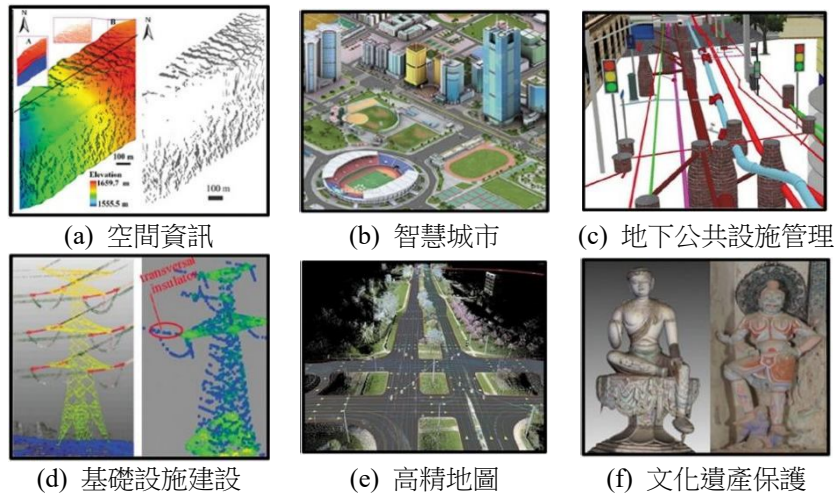


圖 18 點雲於科學研究和工程的應用(修潤自 Yang et al.(2023a))




圖 19 不同演算法影響模型邊緣線表示 (Sorgente et al., 2023)

## 2.2 點雲的品質獲取

從品質評估理論架構來看，點雲品質指標可進一步區分為全參考(Full-Reference, FR)、部分參考(Reduced-Reference, RR)與無參考(No-Reference, NR)三種類型。FR 方法透過比較原始點雲與經處理後點雲之差異進行品質評估，而 RR 方法則是在無法取得完整參考資料的情況下，利用局部幾何特徵或期望值進行比較。FR 與 RR 方法皆需仰賴參考點雲作為基準，而在實際測繪環境中，地面真值往往難以取得，在缺乏參考模型的情境下，仍亟需更具普適性的品質指標(Alexiou & Ebrahimi, 2017、da Silva Cruz et al., 2019)。

不少研究著重於以人類視覺為基礎的主觀品質評估，常透過 MOS(Mean Opinion Score)彙整多位

受試者對三維模型視覺品質的主觀評分，以作為品質判斷依據(Javaheri et al., 2022)。然而，此類方法需投入大量人力與時間成本，難以應用於實際自動化或即時測繪任務中。

隨著無參考品質評估的需求增加，相關研究開始嘗試以點雲本身的幾何與顏色特徵建構客觀品質指標。例如，Zhang et al. (2022)提出一套無參考彩色點雲品質評估方法，結合多種幾何特徵與顏色特徵，並透過自然場景統計與機器學習模型推估整體視覺品質分數，或建構大規模點雲資料集，並發展學習式的無參考品質評估模型(Liu et al., 2023)。

多數研究以整體點雲模型作為品質評估單元，然而實際上，同一組點雲資料於不同區塊中，往往因幾何複雜度、遮蔽程度與點密度差異，而呈現截

然不同的品質狀態。部分研究已嘗試透過局部幾何特徵進行更細緻的分析，例如以法向量計算相應點與點之間的角度，作為品質差異的量化依據 (Alexiou & Ebrahimi, 2018)，或利用主成分分析 (Principal Component Analysis, PCA) 為基礎的幾何描述性指標，評估點雲在結構表現上的穩定性 (Alexiou *et al.*, 2024)。然而，既有文獻多著眼於資料表現形式或演算法改進，對於如何在測繪流程中系統性地引入品質資訊，並作為策略調整與決策判斷之依據，仍有進一步探討之必要。

## 2.3 小結

從相關研究可知，點雲於多元空間資訊萃取任務中具備高度潛力，惟其測繪流程與成果仍受限於資料品質不均、處理策略不一致及品質難以量化等問題。既有文獻多著重於成果層級的品質評估或演算法改進，較少將品質資訊視為可影響測繪流程運作與決策判斷的核心要素。因此，如何以品質導向的觀點，將點雲品質資訊系統性導入測繪流程中，作為操作判斷與策略調整的依據，成為本研究之主要關注重點。

## 3. 品質資訊設計及演算

為填補上述不足，本研究設計一系列整合性導入品質資訊的測繪策略架構，包含：(1)系統性誤差檢查；(2)測繪困難區偵測；(3)影像倒投影；(4)重複量測及品質計算。同時，為展示此策略理念，本研究設計一簡易平台進行資料處理及效果演示。以下逐一說明四項品質內容。

### 3.1 系統性誤差檢查

在點雲測繪中，系統性誤差常因具累積性偏移 (圖 20)，對整體模型準確性造成潛在影響，並且難以從重複量測或倒投影誤差中辨識。這是因為資料內部的幾何與投影參數通常能彼此配合，滿足整體物像對應關係，使測繪結果看似合理，卻可能在絕對空間中產生一致性的偏移。因此，唯有藉由與外部獨立資料的比對，才能揭露其是否存在一致性偏移的系統性誤差。




圖 20 點雲與既有向量圖資偏移示意圖

本研究設計一套檢查流程，以欲測繪的點雲資料與既有圖資(如地形圖，本文以 DXF 代表向量圖資)進行對照為例，分析兩者在空間上的一致性。此檢查流程的策略透過共軛點的量測，從坐標差異中識別可能的系統性誤差型態，包括平移、尺度與旋轉等。

檢查流程首先從點雲資料與既有圖資中選取對應的共軛點，透過坐標相減的方式，計算共軛點對間的觀測偏移量，如式(1)，當多數共軛點對的偏移量( $\Delta x, \Delta y, \Delta z$ )在方向與量值上趨於一致時，可推論可能存在整體平移誤差，此類誤差通常由坐標系未統一或基準轉換錯誤所引起。

$$\begin{aligned}\Delta x &= x_{pointcloud} - x_{DXF} \\ \Delta y &= y_{pointcloud} - y_{DXF} \dots\dots\dots (1) \\ \Delta z &= z_{pointcloud} - z_{DXF}\end{aligned}$$

當共軛點對間的偏移量呈現明顯變異時，表示兩資料間可能存在其他系統性變形，此時需進一步透過共軛點對形成的共軛線段進行尺度與旋轉誤差分析。在尺度檢查方面，透過計算共軛線段的長度差異及比例來判別是否存在尺度縮放問題。若線段長度差異顯著，則可能存在資料間的尺度差異，此類問題可能與比例參數設置錯誤有關。在旋轉檢查方面，透過計算兩組資料中共軛線段的夾角  $\theta$  來判別是否存在旋轉變形。夾角計算公式如式(2)。

$$\theta = \arccos\left(\frac{\overline{V_{pointcloud}} \cdot \overline{V_{DXF}}}{|\overline{V_{pointcloud}}| \times |\overline{V_{DXF}}|}\right) \dots\dots\dots (2)$$

其中  $\overline{V_{pointcloud}}$  和  $\overline{V_{DXF}}$  分別為點雲與 DXF 圖資的共軛線段向量。若存在明顯夾角，則可能存在旋轉誤差，此類問題通常與坐標系軸向或影像姿態參數偏移有關。

從數學層面來看，當旋轉參數及尺度參數都具

顯著性時，應利用轉換公式(例如空間相似七參數轉換)解算系統性參數，不過此階段品質檢查旨在查驗有或無系統性誤差供作品質查驗要項，嚴密系統性參數解算並非任務需求。當點雲資料與既有圖資幾何近似時(亦即沒有顯著旋轉及尺度差異)，為了判別觀測到的偏移量是否屬於系統性誤差，本研究採用誤差傳播定律計算理論容許誤差值。根據兩類資料及其固有精度特徵，包括點雲精度和 DXF 精度(向量圖資的數化精度與坐標精度)，理論容許誤差值 $\sigma_{total}$ 的計算公式為：

$$\sigma_{total} = \sqrt{\sigma_{pointcloud}^2 + \sigma_{DXF}^2} \dots\dots\dots (3)$$


其中 $\sigma_{pointcloud}$ 為點雲精度， $\sigma_{DXF}$ 為 DXF 圖資精度。

基於此理論容許誤差值，可建立誤差性質的判別準則。若所觀測偏移量大於理論容許誤差值(或大於理論容許誤差值的 n 倍，n 由檢驗方設定)，則判定為系統性誤差；若所觀測偏移量小於或等於容許

誤差，則判定為隨機誤差。然而若僅在局部區域發現顯著誤差，則可能由場景變遷(如建物拆除或新建)引起，而非真正的系統性誤差。

圖 21 及圖 22 展示在本研究中系統性誤差檢查相關資訊。圖 21 顯示綜合分析結果，平台分析各點對在 X、Y、Z 三軸向的偏移量，並計算相關統計參數，包含平移向量、標準差、最大偏差、最小偏差及平均偏差等指標(圖 21 (a))，此設計支援在隨機選取的五個區域中進行共軛點量測，比較點雲與 DXF 向量的空間差異，判斷誤差是否具有系統性特徵，例如因坐標系統轉換(TWD67 vs. TWD97)導致的高程偏差或者是坐標系旋轉及尺度問題(圖 21 (b))。

圖 22 進一步提供系統性誤差分析圖表，包含平移誤差向量圖、偏移量大小分布直方圖、尺度因子分析散佈圖及旋轉誤差分析圖等視覺化呈現方式。



(a) 平移誤差統計報表 (b) 尺度與旋轉誤差統計報表  
圖 21 系統性誤差綜合分析結果

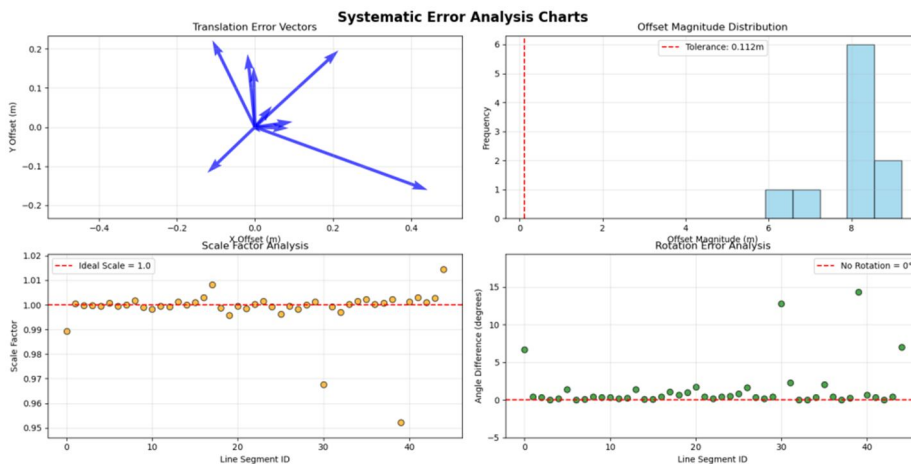


圖 22 系統性誤差分析圖表

如前已述，此比對機制的設計重點並非執行系統性誤差的自動校正或資料重構，而是著重於測繪任務開始前即提供系統性誤差的視覺報導與數值，協助測繪人員在任務初期即掌握資料的空間位置品質風險，作為後續作業或資料使用前的判讀參考基礎。至於偏差成因的追溯與資料重建修正，屬於資料產製端的作業範疇，需回溯調整參數與流程。

### 3.2 測繪困難區偵測


當點雲點位呈現幾何複雜或資料空缺，前者無法或難以經由基本點線面幾何特徵描繪或擬合；後者則無資料內容可資辨識，要不無法辨認及測繪，便是只能以推測(Inference)方式進行，是測繪挑戰的另一極致。此兩種類型點雲樣態均可歸類為測繪困難區。除此之外，點雲資料樣態中也不乏幾何複雜區中混雜著部分資料空缺，同樣帶來難以辨識及完整測繪的挑戰。

透過研究進行中對光學點雲不同場景樣態的分析與歸納，測繪困難區雖然成因各異，但可系統性地分為兩大類型：

#### (1) 幾何複雜區

此類區域的測繪困難原因主要來自環境干擾所造成額外的複雜性，如大量雜訊的存在會干擾特徵邊界的準確判定(圖 23)，或是目標本身具有高度幾何複雜性，例如植被覆蓋區的樹冠與灌木叢，其

不規則表面和多層次結構使得點雲呈現高度幾何變異；建物的雕刻以及浮雕等裝飾元素，包含大量細緻的幾何細節；或是交錯之管線以及支架結構等基礎設施(圖 24(a))，其空間關係錯綜複雜。這些因素相互疊加，不僅大幅增加了人工判讀的難度與不確定性，更使得自動化演算法在特徵提取以及分類等任務上容易產生誤判或參數估算偏差。



(a) 原始影像 (b) 點雲  
圖 23 雜訊影響

#### (2) 破洞與缺漏區

此類區域為點缺失或出現明顯破洞特徵(沒有點)或點缺漏狀況(點極度稀疏)(圖 24 (b))。造成這類問題的原因可分為影像獲取(Image Acquisition)階段的限制與資料處理過程的缺陷。在影像獲取方面，視角的遮蔽是最常見的原因，包括建物的自遮蔽效應或物體間的相互遮擋；此外，某些表面材質的特殊光學性質，如高反射的玻璃或同調區(圖 25(a))，都容易造成匹配失敗而形成點雲的破洞與缺漏區(圖 25(b))。



(a) 結構複雜 (b) 破洞與缺漏區

圖 24 點雲測繪困難區示意圖



(a) 原始影像 (b) 點雲

圖 25 高反射材質導致匹配失敗

本研究不以定義各類型測繪困難區樣態為目標，而是著重於分析點雲之幾何排列與分布特性，以判斷目標區域的測繪難易程度。由於不同類型的測繪困難區在成因與表現上具有顯著差異，單一處理方法難以有效應對各種情境。因此，本研究提出具針對性的偵測策略：對於幾何複雜區域，採用 PCA 量化點雲局部幾何變異程度，並依據各項 PCA 幾何特徵之特性加以整合，設計「幾何複雜困難度分數」(以下簡稱困難度分數, Difficulty Score)，以量化其幾何複雜程度，相關演算式詳於 3.2.1 節；對於破洞與資料缺漏區，則透過基於奇異值分解 (Singular Value Decomposition, SVD) 的切平面估計，結合最大角度差準則，進行資料缺失邊界的偵測。透過此種分類式的處理架構，不僅能更準確地辨識不同類型的測繪困難區，亦能為後續測繪與處理策略提供明確且具體的指引。幾何複雜區以及破洞與缺漏區偵測方法設計說明如下。

### 3.2.1 幾何複雜區偵測

透過點雲點位局部鄰域方差-協方差矩陣，本研究參考 Alexiou *et al.* (2024) 提出之 PCA 衍生特徵，取得三個主成分特徵值  $\lambda_1 \geq \lambda_2 \geq \lambda_3$ ，並由此衍生出多項具有明確幾何解釋意義的特徵指標，特徵指標名稱、定義與其說明整理如表 2。

以下為 PCA 特徵指標的初步計算成果分析，圖

26 展示了 (b) Omnivariance 特徵指標在偵測幾何複雜性的同時，也對建物邊緣的線型結構產生高值反應。圖 26 (c) Linearity 特徵指標計算結果清楚標示出這些線型邊界區域，主要集中在建物輪廓線、屋頂邊緣和立面分界線等明顯的線型幾何特徵。透過 Linearity 特徵指標的線性度門檻值設定，可以有效排除 Omnivariance 特徵指標所偵測出的過於規則的線型邊緣區域，確保最終的 Difficulty Score 計算能有效指引真正具有三維幾何複雜性挑戰的區域，而非單純的二維邊界線型特徵。

相較於 Curvature Gradient (圖 27(b))，Omnivariance 特徵指標除了強化幾何差異的表徵，似乎也更具破洞與缺漏區表達能力 (圖 27(c))。

圖 27 (c) 展示於屋頂面 Omnivariance 特徵指標呈現大量的橙紅色高值區域，這些高值分布並非來自真實的幾何複雜性，而是受到點雲的雜訊影響。此現象說明在使用 Omnivariance 進行幾何複雜度分析時，必須謹慎處理雜訊干擾問題。過度敏感的特性雖然能夠偵測細微的幾何變化，但同時也容易將測量雜訊誤判為幾何複雜區，影響分析結果的可靠性。因此，在實際應用中宜在測繪任務前消除雜訊，或透過適當的門檻值設定和其他特徵指標的組合使用，來平衡偵測靈敏度與抗雜訊能力，確保 Difficulty Score 計算的準確性即可靠性。




圖 26 Omnivariance 與 Linearity 特徵表現差異




圖 27 Curvature Gradient 與 Omnivariance 特徵指標表現差異

表 2 PCA 特徵指標名稱、定義及說明(修潤自 Alexiou *et al.*, 2024)

名稱	定義	說明
Scattering (散射性)	$\frac{\lambda_3}{\lambda_1}$	測量點雲在鄰域內沿三個主方向的分散程度，用於辨識角點特徵
Planarity (平面性)	$\frac{\lambda_2 - \lambda_3}{\lambda_1}$	衡量最大與中等特徵值之間的差距，用於辨識平面特徵
Linearity (線性度)	$\frac{\lambda_1 - \lambda_2}{\lambda_1}$	衡量最大特徵值相對於其他特徵值的延展程度，用於辨識線型特徵
Entropy (熵)	$-\sum_{v=1}^3 \lambda_v \cdot \ln \lambda_v$	描述鄰域內特徵值分布的混亂程度，並評估表面的不確定性
Curvature (曲率)	$\frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3}$	估計點雲表面彎曲的程度，用於反映曲面變化情況
Omnivariance (全向變異性)	$\sqrt[3]{\lambda_1 \cdot \lambda_2 \cdot \lambda_3}$	以三個特徵值的幾何平均數評估點雲特徵的多維延展維度
Anisotropy (異向性)	$\frac{\lambda_1 - \lambda_3}{\lambda_1}$	強調最大與最小特徵值之間的相對變化，用於反映方向性差異
Roughness (粗糙度)	$ (p_i - \bar{p}) \cdot e_3 $	衡量標的點與鄰域質心連線向量沿局部平面法向量的投影長度，越大代表越粗糙
Parallellity X / Y / Z (平行性)	$1 -  u_x \cdot e_3 $ $1 -  u_y \cdot e_3 $ $1 -  u_z \cdot e_3 $	法向量與空間軸平行程度，用於特徵方向分析(如牆面、水平方向)
Textural Entropy (紋理熵)	$-\sum_{v=1}^3 \lambda_v^t \cdot \ln \lambda_v^t$	結合不同光譜的熵值以描述場景紋理多樣性與混亂程度

綜合前述特徵指標分析及事例探討(莊芷瑄, 2025), 本研究透過結合互補性特徵及排除衝突性特徵, 設計一測繪困難區量化演算法, 其量化數值稱為 Difficulty Score, 公式如下:

$$Difficulty\ Score = Omnivariance \times W_{Om} + Curvature\ Gradient \times W_{CG} + Entropy \times W_E \dots\dots\dots (4)$$

其中:  $W_{Om}$ 、 $W_{CG}$  及  $W_E$  分別為 *Omnivariance*、*Curvature Gradient* 及 *Entropy* 特徵指標的權, 而所有特徵指標都經過正規化處理(數值介於 0~1)。當滿足以下任一條件時, 則 Difficulty Score 強制為 0:

$$Linearity > \theta_{threshold\ linearity} \dots\dots\dots (5)$$

$$Omnivariance, Curvature\ Gradient < \theta_{threshold}$$

其中:  $\theta_{threshold\ linearity}$  為 *Linearity* 門檻值;  $\theta_{threshold}$  為 *Omnivariance* 及 *Curvature Gradient* 之共同門檻值。

現階段因尚未實現依點雲規模與空間分布自適應調整之機制, 各特徵指標之門檻值依據經驗法則手動設定, 僅篩除特徵指標數值明顯偏低、確定不具幾何複雜性之點位: *Linearity* 門檻值設為 0.9,

*Omnivariance* 與 *Curvature Gradient* 門檻值同設為 0.1。

*Difficulty Score* 的演算實質整合多特徵、加權及篩選機制, 能較有彈性反應變化多端場景之複雜度。圖 28 展示 *Difficulty Score* 計算結果, 可以觀察到高數值區域成功將點雲多紊亂的區域篩選出來。

### 3.2.2 破洞與缺漏區偵測

雖破洞與缺漏樣態不同, 但在成因和資料呈現上, 均可視為破洞。本研究以 Cui *et al.* (2021) 提出的平面擬合角度差法為理論基礎, 該方法透過 SVD 計算局部切平面, 並以最大角度差作為邊界點判別準則。其理論原理在於破洞邊界點具有明顯的幾何不連續性特徵, 表現為局部鄰域內點雲分布的非均勻性。透過建立局部切平面並投影至二維空間, 計算相鄰點間的角度分布, 當最大角度差超過所設定門檻時, 即可判定該點為潛在的破洞候選點。

如圖 29 所示, 原始流程包含破洞偵測和修補兩個階段。然而, 考量到本研究僅聚焦於破洞的偵測而非修補, 因此僅採用上半部的破洞偵測部分。

同時，由於 Cui *et al.* (2021)處理對象為對稱物件，與本研究目標點雲性質不同，本研究在此基礎上增補多項(如偏轉角度連接、建物邊緣與破洞分類)約制條件，建立了更完整的破洞偵測流程。

具體而言，本研究建立的破洞偵測流程包含五個主要階段：首先進行統計去雜訊前處理，移除點雲中的離群點與雜訊(此處因應破洞偵測效果，所濾除之雜訊為較屬於錯誤之雜訊及離群點)；接著基於 SVD 切平面計算與最大角度差別進行破洞候選

點偵測；第三階段透過點位分群與群組合併，將離散邊界點聚類(Clustering)並合併相近群組；第四階段使用方向準則連接同群組內的邊界點形成封閉邊界；最後透過三平面(XY、YZ 及 XZ)投影的線性度、跨度比(Span Ratio)與點密度指標區分真實破洞與建物邊緣(莊芷瑄, 2025)。透過此多階段的處理流程，有效提升了邊界點偵測的準確性與穩定性，並能準確區分真正的破洞缺陷與正常的建物邊緣特徵，偵測成果如圖 30 所示。

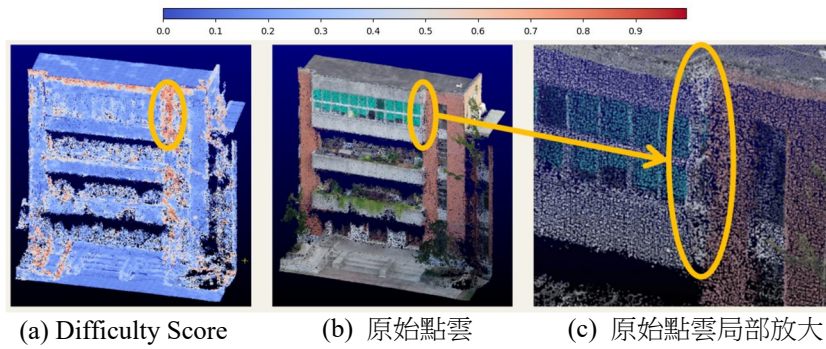


圖 28 Difficulty Score 計算成果

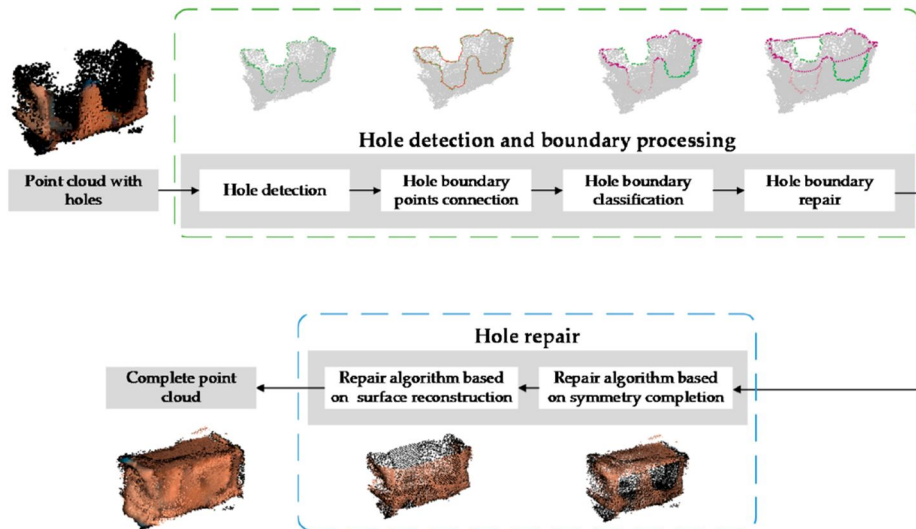


圖 29 Cui *et al.* (2021)的破洞偵測與修補完整流程圖



圖 30 破洞與缺漏區偵測結果(顏色線條標示處)

### 3.3 影像倒投影

本研究影像倒投影(Image Reprojection)是指利用共線方程式，依其物點三維坐標仿透視投影成像對應到影像的像點。共線方程式建立了物空間與像平面之間的幾何關係，引用完整相機參數(內方位、外方位、相機透鏡畸變參數)以確保倒投影的準確性。為了簡化求解共線方程式的計算複雜度，整個過程分為兩個主要步驟：

- (1) **無畸變影像產製**：對原始影像進行透鏡畸變差修正(包括輻射透鏡畸變差和離心透鏡畸變差)，產生無畸變影像，使像元坐標符合理想針孔相機模型的假設。
- (2) **無畸變影像上的倒投影**：使用共線方程式，將三維物點投影至無畸變影像上。除此之外，可結合參數誤差進行誤差傳播分析以量化位置的不確定性。

為加速資料演算效能，產製無畸變影像是較佳的策略，因為包含畸變修正的共線方程式會使影像坐標同時出現在方程式的兩側，需要迭代求解像點坐標。透過先產製無畸變影像，可以免除非線性解算繁複的過程，簡化倒投影演算程序並提升資料處理效能。

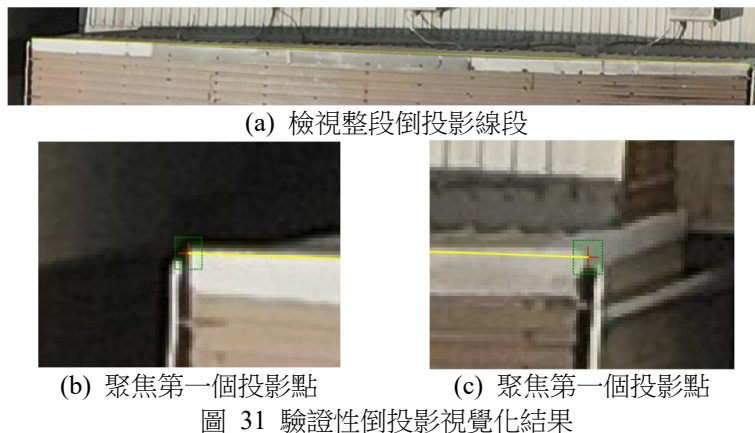
此外，更進一步基於品質資訊策略的考量，本研究將影像倒投影應用區分為診斷性(Diagnostic)與驗證性(Verificative)兩個層面：

(1) **診斷性影像倒投影 (Diagnostic Image Reprojection)**：主要針對點雲處理過程中偵測出的測繪困難區，透過將此區域位置倒投影回原始影像，使測繪人員能夠檢視究竟是匹配失敗抑或資料缺失導致測繪困難區的生成，以利後續採取適當的處理策略。

(2) **驗證性影像倒投影 (Verificative Image Reprojection)**：則著重於測繪結果的精度驗證，結合誤差傳播分析計算像點位置的標準差，建立以一倍或兩倍標準差為基準的容許誤差區間，形成明確的容差範圍判定機制，確保最終測繪成果的可信度與精度要求。

驗證性影像倒投影效益範例可見圖 31，將點雲測繪成果之建物屋頂面角點或邊緣線經過倒投影至影像可查視線條與影像之套合狀況，並可量化偏差量，如圖 31 (b)與(c)中矩形範圍表示由兩坐標分量標準差框出矩形範圍，提供直觀的誤差界限表示和差異品質資訊(圖 32)。

診斷性影像倒投影平台架構建立於前述困難區偵測成果之上，形成完整的問題診斷工作流程。在點雲中選擇需要進一步確認的問題點位，平台隨即自動擷取該選點的三維坐標資訊投影回原始影像中，讓測繪人員能夠在多張影像(包含垂直和傾斜影像)中確認目標點在原始影像資料上的真實樣態(圖 33)(其中紅色十字標示位置為倒投影點)，釐清造成點雲測繪困難的問題根源。



選取點: (2436.2, 280.6) | 到點1距離: 42.3px | 到點2距離: 45.0px | 到線段距離: 20.0px

圖 32 畫面即時選點與投影點距離統計




圖 33 診斷性影像倒投影詳細檢視成果

### 3.4 重複量測及品質計算

本研究針對測繪作業易受環境變化與操作影響所產生的不確定性，提出一套重複量測與即時品質評估的解決方案。測繪人員在三維場景中對同一目標點進行多次獨立觀測，平台可利用這些三維坐標值計算目標點位的坐標最或是值。接著，根據每個量測點與最或是值在 X, Y, Z 三個方向上的改正數(Residual)，計算出這些分量的標準差( $\sigma_x, \sigma_y, \sigma_z$ )和總體標準差( $\sigma_{total}$ )。平台將自動比對該點之歷次量測紀錄並即時顯示各改正數向量與總體標準差。透過視覺化表現，測繪人員可一面觀察品質變化趨勢，一面進行量測值的判讀與修正，作為確認點位品質是否符合需求之依據。

圖 34 展示此品質面向的資料量測及資訊呈現的實作及效果，在重複量測模組能夠在三維點雲視窗中，以紅色標記呈現同一控制點在多次觀測中的實際量測位置，並以綠色標示其根據所有量測結果所計算出的幾何中心，直觀地反映各次測量的空間離散情形。測繪人員在量測過程中，只要點擊同一位置，系統便會自動擷取當前坐標並以紅、藍色分別標示負值與正值改正數，同時在點雲畫面中更新紅點，以便於即時觀察改正數方向與大小。

對應地，圖 35 中的統計介面則將每次量測的 X、Y、Z 坐標以及相對中心點的偏差  $\Delta X$ 、 $\Delta Y$ 、 $\Delta Z$ ，以直觀的色彩標示呈現；紅色代表改正數為負

值、藍色代表改正數為正值，表格下方則自動計算出各軸向的標準差  $\sigma_x = 0.027m$ 、 $\sigma_y = 0.030m$ 、 $\sigma_z = 0.018m$ ，以及總體標準差 $\sigma_{total} = 0.044m$ ，這些數值反映出在本研究場景中，此量測案例能達到不超過 5 cm 的重複量測精度。透過此即時可視化與自動化統計功能，測繪人員不僅可以在點雲中清楚看到量測點的離散分布，還能隨時掌握量測品質，進而對可能的誤差來源(如環境干擾或操作誤差)進行快速排查與校正，顯著提升測繪流程的可靠性與效率。




圖 34 三維空間中重複量測點分布

Point	X	Y	Z	$\Delta x$	$\Delta y$	$\Delta z$
1	304421.931	2767916.477	57.365	0.0317	-0.0017	0.0290
2	304421.877	2767916.476	57.325	-0.0223	-0.0027	-0.0110
3	304421.879	2767916.421	57.337	-0.0203	-0.0577	0.0010
4	304421.889	2767916.517	57.312	-0.0103	0.0383	-0.0240
5	304421.943	2767916.505	57.352	0.0437	0.0263	0.0160
6	304421.877	2767916.476	57.325	-0.0223	-0.0027	-0.0110
Center	304421.899	2767916.479	57.336			
	$\sigma_x$	$\sigma_y$	$\sigma_z$			
	0.0272	0.0303	0.0179			
Total $\sigma$			0.0444			

圖 35 重複量測即時統計介面

## 4. 品質資訊導入點雲測繪流程之體現

本章從整體系統設計角度，統整本研究中所有與「品質」相關策略的設計概念與機制。透過品質於測繪流程中的角色定位、品質資訊在操作平台中的實際呈現樣態，以及品質策略於不同階段(資料層、流程層與決策層)之分工，本研究意圖將原本抽象的品質概念，轉化為可即時獲取、操作與引用的測繪資訊。藉由此整體視角，更具體闡明品質參與測繪流程的運作方式與決策邏輯。

### 4.1 品質資訊在平台中的可視化樣態

本研究所擬定方法，就圖資生產面而言，包含品質指標的提供及對資料的查驗及問題追蹤；而就資料屬性擴充而言，增列點雲特徵屬性，豐富點雲資訊量。此兩部分功效參見圖 36 及表 3。

圖 36 將本研究其中三大品質策略(除了系統性誤差)同時呈現在一張畫面上，並用不同顏色的框線標示出它們各自的對應區域：

#### (1) 重複量測及品質計算

在圖 36 左上方，可以看到「Point 1 = (304681.142, 2768123.894, 35.688) ( $\sigma_{Total} = \pm 0.044$  m)」以及「Distance =  $9.43 \pm 0.05$  m」這兩組

標註。這正是對單點與線段進行多次獨立量測後，計算其位置與距離的統計標準差，用以量化測繪結果的精度與不確定度。

#### (2) 測繪困難區偵測

A.幾何複雜區：在建物立面上，PCA 特徵值被映射成由藍到紅的色彩梯度，顏色越偏紅代表該區域的點雲結構越複雜、幾何變化越大。這讓我們能辨識出哪些區域因幾何複雜而造成量測困難。

B.破洞與缺漏區：右側以及左下角局部都有以紅色框線圈出來的邊界線，這些就是透過破洞偵測所標定的「破洞點」邊緣，圈選出資料缺漏的位置，方便後續針對性補洞或重拍。

#### (3) 影像倒投影

A.診斷性倒投影：在左下角的淺藍色框中，將標出的破洞區域倒投影回原始影像，畫面下方以放大視窗展示了倒投影後的位置。透過這種方式，可以直接比對影像與點雲中缺失點的對應，診斷破洞形成的原因(如遮蔽或影像模糊)。

B.驗證性倒投影：在畫面中央偏下的位置，量測所得的線段(粉紫線)倒投影回影像，上面疊加紅色的實際對應點。這一步驟可用來檢驗點雲量測與影像觀測之間的吻合程度，確保量測誤差在可接受範圍內。




圖 36 多策略點雲品質資訊與可視化示意圖

表 3 點雲與圖資屬性擴充總覽表

	原始資料	新增屬性
點雲	1. X, Y, Z 2. RGB	1. Difficulty Score：困難度數值評分 2. Hole Flag (T/F)：是否落於破洞範圍
圖資	1. Point 2. Line 3. Polygon	1. Point Std：點位坐標標準差 2. Line Length Std：線段長度標準差 3. Repeat Count：重複測量次數 4. Reprojection Error：倒投影誤差(pixels)

從表 3 看到經過本研究品質資訊策略設計，在點雲和向量圖資的資訊上能新增一些屬性資料。在點雲資料部分，原本僅包含每個點在三維空間中的坐標(X、Y、Z)與對應的色彩資訊(RGB)。經過本研究的處理流程，我們為每一個點額外計算並附加了「困難度數值評分」(Difficulty Score)與「破洞範圍標記」(Hole Flag)。

在圖資部分，原測繪成果屬性資料包括三種類型：單一位置的點(Point)、連接兩點之間空間關係的線段(Line)，以及描述封閉區域範圍的多邊形(Polygon)。本研究對這些圖資要素新增了四項屬性：首先，對單獨測量點計算「點位坐標標準差」(Point Std)，以及對線段計算「線段長度標準差」(Line Length Std)，用以量化重複測量的一致性；同時記錄「重複測量次數」(Repeat Count)，以反映統計結果的可靠度；最後，在將點或線段倒投影回原始影像時，計算其在像元層級上的「倒投影誤差」(Reprojection Error)，從而客觀評估影像與點雲之間的吻合程度。

## 4.2 品質策略的協同作用與資訊傳遞

本研究旨在解決光學點雲測繪中品質資訊不足的問題，通過整合品質導向的策略，建立一套具系統性以及可操作的決策流程架構。圖 37 統整說明每個階段能夠得到的品質資訊，建立整體的決策流程架構，正是本研究的核心貢獻。首先，光學點雲輸入後便與外部資料(如地形圖)進行比對，執行系統性誤差檢查。如果發現顯著偏移，平台會量化偏移量，告訴測繪人員「資料可信度」以及「是否

需校正」。此步驟確保點雲在絕對空間中的準確性。

若判斷無系統性誤差，流程進入測繪困難區偵測階段。平台能夠分類資料中的「幾何複雜區」和「破洞與缺漏區」。並為每個區域計算 Difficulty Score 和幾何穩定性指標(亦即破洞位置資訊)。這為測繪人員提供「潛在風險區域」及「可靠度等級」的預警資訊，協助在測繪前選擇適當的處理策略。

影像倒投影策略分為診斷性和驗證性兩種應用，首先利用診斷性倒投影將測繪困難區投影回原始影像，分析誤差成因，回答「為什麼此區域有問題」，並根據結果調整測繪模式，調整測繪模式的具體策略包括：當問題源於密匹配失敗或目標幾何結構過於複雜時，可採協作方式透過影像前方交會獲取目標點位坐標或回到立體測繪模式填補所需測繪標的物；當遇到因遮蔽導致的資料缺失區域時，則可將該區域標註為「不可靠」區域。經過測繪步驟獲取之成果還可以再利用驗證性倒投影計算像點標準差和容差區間，提供幾何一致性的量化品質指標，讓測繪人員清楚掌握「測繪結果與原始影像的吻合程度」。

而重複量測及品質計算功能則可針對目標點位進行多視角量測，計算觀測量標準差及總體精度指標，提供「內部一致性」資訊，幫助測繪人員評估「點位量測穩定度」。同時，粗差偵測機制可有效排除顯著偏差的觀測值。

整套設計流程中實現『圖資測繪 + 品質資訊』的同步輸出。不僅解決了傳統點雲測繪缺乏品質評估的問題，更提供了系統性的決策支援機制。這套框架的價值在於：它不只告訴你「測繪結果是什麼」，更重要的是告訴你「測繪結果的可信度」，以及「需

謹慎處理的情境」，從而提升測繪成果的可靠度與應用價值。

最終以圖 38 說明四項品質策略在不同階段中所扮演的角色與其品質資訊的傳遞方式。圖中左側流程代表點雲測繪與成果產出程序，由資料取得(資料層)、處理分析(流程層)至最終決策(決策層)逐步推進(詳見表 1)；其中，深綠色且尺寸較大的圓點表示該品質策略在該流程階段中發揮主要功能，而淺綠色且尺寸較小的圓點則表示其於該階段中具有輔助或間接影響的角色。透過此視覺化方式，可清楚呈現各品質策略並非僅作用於單一階段，而是以不同程度貫穿整體測繪流程。

雖然各項品質策略在流程中的主要作用階段不同，但其所產生之品質資訊皆會持續傳遞並最終匯入決策層，作為成果採用與否的重要依據。此設計強調品質資訊並非僅用於事後驗證，而是可在測繪任務進展中不斷累積與回饋，形成一種具連續性的品質導向作業模式。

其中，「影像倒投影」在本研究中扮演一個較為特殊且關鍵的角色。影像倒投影本身並不屬於標準點雲測繪流程中的既定步驟，然而當點雲資料存在不確定性、局部品質不佳或出現疑似測繪困難區時，影像倒投影可動態地引入流程中，作為一項輔助性

參考機制。透過將點雲位置回溯至原始影像資料檢視，不僅可協助釐清誤差來源，亦能支援測繪人員判斷資料品質是否可接受，進而決定是否需調整策略或重新處理。圖 38 中所示之橘色箭頭則代表當流程中偵測到品質問題時，可進行策略轉換或流程回溯的可能方向。這些箭頭象徵測繪流程可依據品質資訊的回饋結果，在不同策略之間進行切換或補強，體現一種以品質資訊為引導的彈性測繪流程規劃。

### 5. 結論

綜合本文內容，當前點雲測繪技術所面臨的關鍵限制，並非單純來自演算法能力或資料取得效率，而是源於「品質資訊在測繪流程中長期缺位」所造成的系統性問題。

首先從資料層、流程層與決策層三個層面切入，凸顯品質資訊不僅代表最終輸出的精度，實際上深刻參與了整體測繪流程的運作。

為回應上述問題，本研究設計一系列導入品質資訊的光學點雲測繪策略，包含系統性誤差檢查、測繪困難區偵測、影像倒投影以及重複量測與品質計算等四項，系統性地產製測繪過程中的品質資訊。

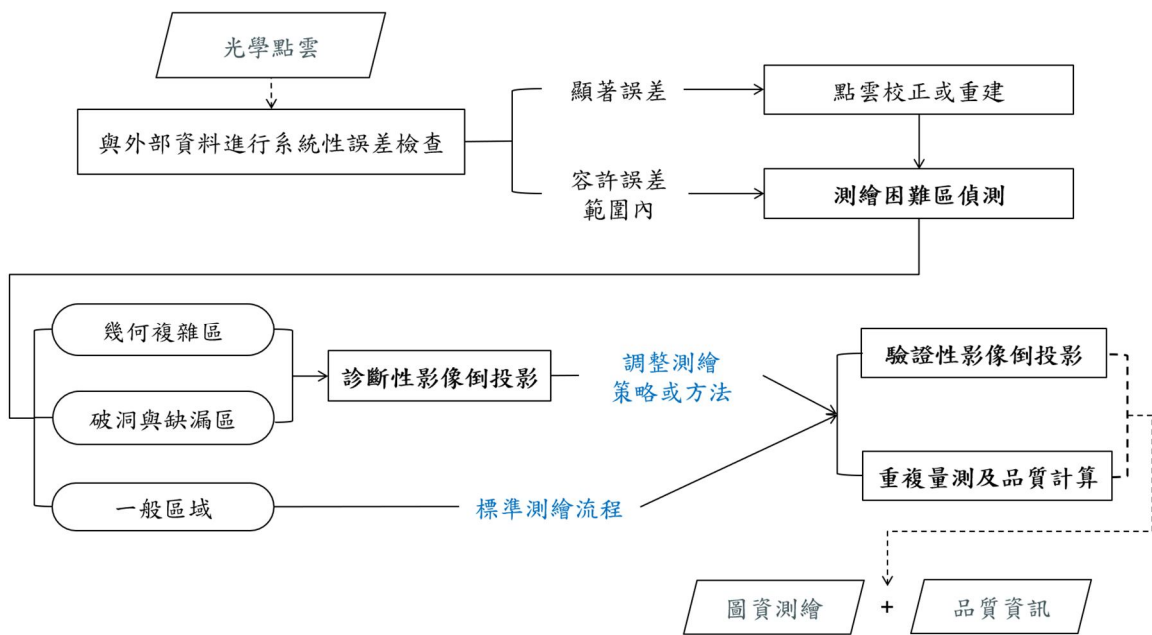


圖 37 測繪任務中的決策流程圖

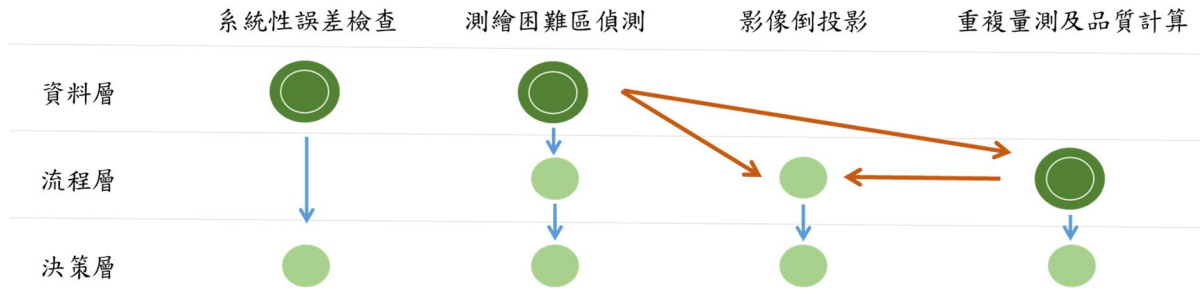


圖 38 品質策略在點雲測繪工作流程中的應用

為使這些品質資訊能真正應用於測繪流程，本研究進一步提出「品質資訊導入點雲測繪流程之整體設計概念」，透過視覺化呈現、屬性化儲存與流程回饋機制的設計，將品質資訊轉化為可被感知、操作與引用的測繪資訊，使其在不同測繪階段中提醒潛在問題、支持策略轉換，最終提升成果的可靠度與應用價值。

本研究重新定義「品質」在點雲測繪中的角色：品質不僅是數值或評分結果，而是能夠跨越資料、流程與決策層次的關鍵資訊。透過提供一套可操作的品質導向框架，未來研究者與實務工作者可參考本研究所提出的品質資訊產製策略與流程設計概念，發展適用於不同測繪情境的品質管理機制。期望本研究能引發對點雲測繪品質議題的進一步關注，並作為未來發展品質導向測繪技術的重要參考。

## 誌謝

本研究承蒙國家科學及技術委員會專題研究(計畫編號 MOST 114-2121-M-002-005) 以及中華民國航空測量及遙感探測學會業務二部經費補助，得以順利推展；2 位審查委員給予文章內容諸多建設性修潤意見，謹此致謝。

## 參考文獻

內政部國土測繪中心，2019。108 年度三維近似化建物模型建置工作總報告。[National Land Surveying and Mapping Center, Ministry of the Interior, 2019. The annual report on the construction of 3D building model with simulation texture. (in Chinese)]

內政部國土測繪中心，2020。運用區塊建物框細緻化技術精進三維建物模型之研究報告書。[National Land Surveying and Mapping Center, Ministry of the Interior, 2020. The annual report on the research of dividing aggregate 3D building model into individual ones. (in Chinese)]

莊芷瑄，2025。光學點雲測繪導入品質資訊與互動式策略-以建物為例，國立臺灣大學土木工程學系碩士論文，DOI: 10.6342/NTU202504227。[Jhuang, J.S., 2025. Integrating quality information and interactive strategy for building measurement in photogrammetric point cloud, Master Thesis, National Taiwan University, ROC, DOI: 10.6342/NTU202504227. (in Chinese)]

許展祥、林鷺均、王敏雄，2022。利用三維網格模型繪製一千分之一地形圖之精度評估，國土測繪與空間資訊，10(2)：219-240。[Hsu, C.H., Lin, L.C., and Wang, M.S., 2022. Evaluation of the accuracy of 1/1,000 topographic mapping using a 3D mesh model, Taiwan Journal of Geoinformatics, 10(2): 219-240. (in Chinese)]

鄭錦桐、黃梓育、王選仲、林玉梅、鄧澤揚、黃意筌、賴穎萱、王禹翔，2021。人工智慧與高精地圖於道路資產管理之實務應用，土木水利 48(2)：4-14，DOI：10.6653/MoCICHE.202104\_48(2).0002。[Zheng, J.T., Huang, Z.Y., Wang, X.Z., Lin, Y.M., Deng, Z.Y., Huang, Y.Q., Lai, Y.X., and Wang, Y.X., 2021. Practical applications of AI and HD map in road asset management, Journal of the

- Chinese Institute of Civil and Hydraulic Engineering, 48(2): 4-14, DOI: 10.6653/MoCICHE.202104\_48(2).0002. (in Chinese)]
- Alexiou, E., and Ebrahimi, T., 2017. On subjective and objective quality evaluation of point cloud geometry, in Proceedings of the Ninth International Conference on Quality Of Multimedia Experience (QoMEX), Erfurt, Germany, DOI: 10.1109/QoMEX.2017.7965681.
- Alexiou, E., and Ebrahimi, T., 2018. Point cloud quality assessment metric based on angular similarity, in Proceedings of the IEEE International Conference on Multimedia and Expo (ICME), San Diego, CA, USA, DOI: 10.1109/ICME.2018.8486512.
- Alexiou, E., Zhou, X., Viola, I., and Cesar, P., 2024. PointPCA: Point cloud objective quality assessment using PCA-based descriptors, EURASIP Journal on Image and Video Processing, 2024(1): 20, DOI: 10.1186/s13640-024-00626-3.
- Cui, L., Zhang, G., and Wang, J., 2021. Hole repairing algorithm for 3D point cloud model of symmetrical objects grasped by the manipulator, Sensors, 21(22): 7558, DOI: 10.3390/s21227558.
- da Silva Cruz, L.A., Dumić, E., Alexiou, E., Prazeres, J., Duarte, R., Pereira, M., Pinheiro, A., and Ebrahimi, T., 2019. Point cloud quality evaluation: Towards a definition for test conditions, in Proceedings of the Eleventh International Conference on Quality of Multimedia Experience (QoMEX), Berlin, Germany, DOI: 10.1109/QoMEX.2019.8743258.
- Hirschmüller, H., 2008. Stereo processing by semiglobal matching and mutual information, IEEE Transactions on Pattern Analysis and Machine Intelligence, 30(2): 328-341, DOI: 10.1109/TPAMI.2007.1166.
- Javaheri, A., Brites, C., Pereira, F., and Ascenso, J., 2022. Joint geometry and color projection-based point cloud quality metric, IEEE Access, 10: 90481-90497, DOI: 10.1109/ACCESS.2022.3198995.
- Jhuang, J.S., and Jaw, J.J., 2024. Mesh models as enhancements to point cloud-based surveying and mapping, in Proceedings of the 45th Asian Conference on Remote Sensing (ACRS), Colombo, Sri Lanka.
- Li, Y., and Wu, B., 2021. Relation-constrained 3D reconstruction of buildings in metropolitan areas from photogrammetric point clouds, Remote Sensing, 13(1): 129, DOI: 10.3390/rs13010129.
- Liu, Y., Yang, Q., Xu, Y., and Yang, L., 2023. Point cloud quality assessment: Dataset construction and learning-based no-reference metric, ACM Transactions on Multimedia Computing, Communications and Applications, 19(2s): 80, DOI: 10.1145/3550274.
- Mirzaei, K., Arashpour, M., Asadi, E., Masoumi, H., Bai, Y., and Behnood, A., 2022. 3D point cloud data processing with machine learning for construction and infrastructure applications: A comprehensive review, Advanced Engineering Informatics, 51: 101501, DOI: 10.1016/j.aei.2021.101501.
- Sorgente, T., Biasotti, S., Manzini, G., and Spagnuolo, M., 2023. A survey of indicators for mesh quality assessment, Computer Graphics Forum, 42(2): 461-483, DOI: 10.1111/cgf.14779.
- Xu, Y., Tong, X., and Stilla, U., 2021. Voxel-based representation of 3D point clouds: Methods, applications, and its potential use in the construction industry, Automation in Construction, 126: 103675, DOI: 10.1016/j.autcon.2021.103675.
- Yang, B., Haala, N., and Dong, Z., 2023a. Progress and perspectives of point cloud intelligence, Geo-

- spatial Information Science, 26(2): 189-205, DOI: 10.1080/10095020.2023.2175478.
- Yang, Y.C., Chiou, Y.P., and Jaw, J.J., 2023b. Topographic features in photogrammetric point clouds, in Proceedings of the International Symposium on Remote Sensing (ISRS), Jeju, Korea.
- Zhang, Z., Sun, W., Min, X., Wang, T., Lu, W., and Zhai, G., 2022. No-reference quality assessment for 3d colored point cloud and mesh models, IEEE Transactions on Circuits and Systems for Video Technology, 32(11): 7618-7631, DOI: 10.1109/TCSVT.2022.3186894.

# A Quality-Information-Oriented Framework for Measurement in Photogrammetric Point Cloud

Jhih-Syuan Jhuang<sup>1</sup> Jen-Jer Jaw<sup>2\*</sup>

## Abstract

In recent years, point clouds have become indispensable data for producing multi-dimensional spatial information. However, "Quality" has long been overlooked in point cloud surveying and mapping workflows because, in practical applications, it is often treated as an end-stage validation or an auxiliary indicator for evaluating results, with little attention to its influence on operational decisions, strategic planning, and the adoption of survey products.

This paper aims to demonstrate the critical importance of quality for advancing point cloud surveying technology, arguing that quality not only governs the credibility of survey outputs but also fundamentally shapes the entire surveying workflow; through multifaceted examinations, how quality forms risks, constraints, or decision-making references at different levels is thoroughly elaborated; and most importantly, a systematic conceptual framework for quality awareness with a clear problem consciousness and research foundation for the subsequent development of quality-oriented point cloud surveying workflows and decision-support methodologies has been established.

**Keywords: Photogrammetric Point Cloud, Quality Information, Surveying and Mapping Difficulty Areas, Error Analysis**

---

<sup>1</sup> Research Associate, Department of Civil Engineering, National Taiwan University

<sup>2</sup> Associate Professor, Department of Civil Engineering, National Taiwan University

\* Corresponding Author, E-mail: jejaw@ntu.edu.tw

Received Date: Jan. 08, 2026

Revised Date: Apr. 10, 2026

Accepted Date: Apr. 13, 2026

# 整合無人機與深度學習之瀝青鋪面裂縫自動檢測研究

劉鎧銘<sup>1\*</sup> 高書屏<sup>2</sup> 王豐良<sup>3</sup> 林志憲<sup>4</sup>

## 摘要

本研究結合無人機與深度學習物件偵測模型 YOLOv9，針對道路瀝青鋪面裂縫進行自動化檢測與分析。利用無人機高機動性與高解析度影像獲取能力，可快速覆蓋大面積道路區域並減少人工巡檢所需時間與成本。研究中首先以公開鋪面裂縫資料集 CrackForest 進行 YOLOv9 模型訓練，經過 100 個訓練週期後，模型在測試集上達成 mAP50 為 0.891 及 mAP50-90 為 0.550 的檢測精度，顯示其在小物體辨識與道路裂縫檢測上的優勢。最後，透過影像正射化與幾何校正，將檢測結果套疊於真實坐標，並進行裂縫寬度量分析，驗證本系統裂縫寬度量測精度優於約為 0.16mm，可作為道路維護決策與管理之有效工具。

**關鍵詞：**無人機、YOLOv9、裂縫檢測、鋪面裂縫、深度學習

## 1. 前言

道路為連結城市與鄉村、促進人流與物流的重要基礎設施，其使用狀況亦反映國家整體發展與治理效率。道路品質更常常被世界銀行視為衡量國家經濟發展程度的指標之一(Ragnoli *et al.*, 2018)。隨著全球都市化進程加快，車輛擁有率與使用頻率持續上升，鋪面長期承受高載重壓力，加以極端氣候與環境變化的影響，使得道路損壞與裂縫情形日益嚴重。一旦鋪面破損未及時修復，將可能導致交通事故風險升高與運輸效率下降，對社會經濟活動造成實質性損失。目前道路常見的損害類型包括裂縫與坑洞，其中多數路面劣化皆起始於微細裂縫，隨時間推移與車流重壓逐漸擴展，最終演變為大面積剝離及結構性破壞。若能及早發現裂縫並進行維修，不僅可有效抑制鋪面進一步劣化，亦能節省後續高額的整修成本與人力資源，延

長瀝青路面之使用壽命。因此，定期執行鋪面裂縫巡檢已被證實為維持路面品質最經濟有效的方法之一(Gavilán *et al.*, 2011)，裂縫之及時檢測與

養護亦成為道路管理維護中的核心課題。

隨著道路使用強度不斷提高，鋪面劣化問題日益嚴重。早期的裂縫檢測多仰賴人工目視巡檢，然而，該方式不僅效率低下，且檢測結果高度仰賴人員經驗與主觀判斷，容易導致誤判或遺漏。此外，作業人員需在車流中行走亦存在安全風險，限制了人工巡檢在高交通流量區域的可行性。為解決上述限制，車載影像系統應運而生。此類方法通常結合高解析度攝影機與雷射光達等感測設備，搭配電腦影像處理演算法，能在車輛行進間自動捕捉並辨識路面裂縫，提升效率與準確性。Chambon *et al.*(2009)使用馬可夫隨機場模型，以及 Tsai *et al.*(2010)採用 Otsu 閾值法，皆在複雜背景下達成穩定辨識表現。Gavilán *et al.*(2011)更藉由車載系統成功分類多種不同的道路，顯示該技術具備處理不同背景的能力。然而，此類系統建置成本高昂，且於實地操作時可能干擾交通流量，使其在高使用率道路上的應用受到限制。近年無人機(UAV)技術的成熟為裂縫檢測帶來新契機。無人機具備低成本、快速部署與高機動性的特性，可於不影響交通情況下取得大面積、

<sup>1</sup> 國立中興大學土木工程學系 碩士

<sup>2</sup> 國立中興大學土木工程學系 教授

<sup>3</sup> 健行科技大學應用空間資訊系 助理教授

<sup>4</sup> 國立中興大學土木工程學系 博士

\* 通訊作者, E-mail: daniel1900513@gmail.com

收到日期：民國 114 年 09 月 03 日

修改日期：民國 114 年 10 月 15 日

接受日期：民國 115 年 02 月 25 日

高解析度之道路影像，顯著提升資料蒐集效率。為克服高空拍攝導致的解析度下降與背景複雜問題，研究者開始結合影像處理與深度學習演算法以提升辨識準確度。Zhou *et al.*(2014)融合道路顏色與邊界資訊進行形態學處理，有效提升裂縫辨識率；Zhu *et al.*(2022)則透過調整無人機飛行參數，優化影像解析度與辨識品質。綜上所述，UAV 搭配先進影像演算法已成為目前裂縫自動檢測的重要趨勢，兼具高效率、低干擾與良好辨識能力，極具實務應用潛力。然而要處理大量的高解析度影像，若是運用人工去處理這些資料的話可能也會導致檢測人員在長時間的工作下產生視覺疲勞，進而影響判斷能力，故利用自動判別是必須的，它可以有效的降低資料處理速度，並減少人工辨識的主觀性。目標偵測深度學習技術分為單階段演算法和雙階段演算法，單階段的檢測方法主要包含了 YOLO(You Only Look Once)系列和 SSD(Single Shot MultiBox Detector)兩者，輸入影像後可立即得到影像辨識的成果。雙階段演算法包含了卷積神經網路(Convolutional Neural Network, CNN)，是採用區域提議網路(Region Proposal Network, RPN)進行物件的框選後再進行辨識。然而 Cha *et al.*(2017)提出基於 CNN 之影像級與像素級裂縫檢測方法，顯著提升辨識準確率與自動化程度，雖然雙階段的演算法在一開始就有較高的精度，但因為需要先進行區域選擇在判別，故辨識速度上面會相對的較久，需要速度快的道路巡檢可能較不適用。

所以本研究以無人機結合影片拍攝的方式，能全面性地捕捉需要修補的裂縫位置；加上訓練一套單階段的目標偵測模型運用在瀝青道路裂縫檢測上的適用性，並利用該模型能快速且自動的辨識出地面上的裂縫，降低人為的誤差和主觀性，進而在提高道路檢測速度與準確性的同時，後續再透過裂縫量化分析，有效掌握裂縫的發展狀況與變化趨勢，為道路檢測和維護提供新的思路與解決方案。

## 2. 研究方法

### 2.1 研究流程

本研究預計要結合無人機與深度學習技術的瀝青道路裂縫檢測系統，整體流程分為模型建立與應用兩大部分，如圖 1 所示，詳細步驟說明如下：

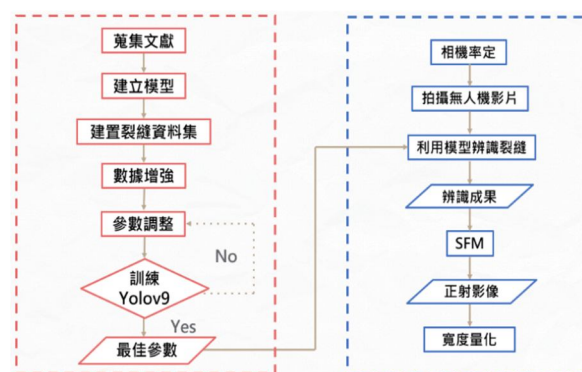


圖 1 研究流程圖

本研究首先進行相關文獻探討，根據目前路面裂縫偵測技術的發展現況，並分析常見之物件偵測模型與應用情境，基於這些以及文獻探討，選擇 YOLOv9 做為後續研究使用模型。第二部分會先用相機率定後消除相機所帶來的光學誤差，再利用影片拍攝的方式獲取研究標的數據，捕捉所需要修補的裂縫位置。利用訓練好的 YOLOv9 模型快速且自動的辨識裂縫，捕捉其位置，再將後續辨識成果較佳的影片提取有裂縫的幾幀影像，做後續量化使用。然而收集的無人機影像可能因無人機的姿態失真導致後續量化的精確性，故先利用 SfM 的技術將影像恢復成正射影像後，再用此影像做後續寬度量化，以確保其精確性，並提供道路養護一個可靠的評判標準。

### 2.2 研究資料收集與處理

#### 2.2.1 數據集介紹

本研究所使用的訓練資料集是使用 Crack Forest 的公開鋪面裂縫資料集，總共影像共有 10400 張，其影像大小為 600x600 像素，其鋪面裂縫為高解析度的車載拍攝路面裂縫，而它的裂縫標註形式如圖 2 所示，為利用許多 YOLO 訓練框所框出裂縫的輪廓。

10400 張裂縫影像依照 7:2:1 的比例隨機分配給訓練、驗證和測試，做後續模型訓練使用，訓練的

張數約為 7280 張，驗證的張數約為 2080 張，測試的張數約為 1040 張。




圖 2 裂縫資料集標註形式示意圖

### 2.2.2 測試數據

本研究測試影像由無人機 DJI Mavic 2 Pro 搭載攝影機 L1D-20c 進行拍攝。要進行實驗區域選擇前，首先要先知道目前道路裂縫檢測的規定為何，根據交通部公路總局所頒布的養護手冊規定(中華民國交通部，2020)，裂縫平均寬度在小於等於 6mm 時會被分為 L 級，其中在平均寬度大於 3mm 時會進行填封處理，故在選擇拍攝的實驗道路需要含有大於寬度 3mm 之裂縫，並預計選擇一塊背景相對乾淨的道路路面做研究使用，經挑選後選擇雲林縣的科工十六路，拍攝時間為 2025 年 4 月 4 號 14:00，此區域含有 3mm 寬度的裂縫，並且裂縫密集程度也較高。圖 3 為研究區域位置，框為所選擇的道路範圍。



圖 3 研究區域圖

## 2.3 物件偵測網路

YOLO 模型為單階段偵測的物件偵測模型，其與二階段偵測的模型最大的不同為少了區域提議網絡(Region Proposal Network)技術。二階段偵測是採用區域提議網絡的技術，會先生成包含檢測目標的先驗框，然後以分類器判斷每個先驗框是否包含檢測目標及目標類別的信心值，調整信心的高低以防止低的誤判區域，然後得到檢測的結果。雖然生成候選區域再進行檢測的方式擁有較高的檢測精度，但檢測速度較慢。一階段架構直接於卷積神經網路生成特徵圖並進行預測框回歸並分類，雖然檢測精度會不如 RPN 的效果，但能大幅度的降低模型推論時間。而物件偵測的流程如圖 4 所示。

目標偵測模型的運作流程一般可分為四個主要階段，分別為 Input、Backbone、Neck 與 Head。首先，在 Input 階段，根據各模型架構需求，輸入統一尺寸影像作為分析資料。接著於 Backbone 層中，利用卷積神經網路對影像進行多層次特徵萃取，以保留影像中的關鍵語義與結構資訊。Neck 層則負責對來自 Backbone 的特徵進行進一步整合與壓縮，透過多尺度特徵融合機制提升模型對不同大小目標的辨識能力。最後，於 Head 層將融合後的特徵進行物件類別分類與邊界框回歸，以產出具定位資訊的預測結果。根據輸出策略不同，目標偵測模型可區分為 密集預測(Dense Prediction)與 稀疏預測(Sparse Prediction)。一階段模型如 YOLO 模型採用密集預測架構，於影像網格上設定大量錨點，並對每個網格進行同時的物件存在性與邊界框預測。相較之下，二階段模型如 Faster R-CNN 則透過 RPN 先選出潛在目標區域，再進行分類與精細定位，因此屬於稀疏預測方式，具有較高的準確性但推論速度較慢。




圖 4 物件偵測網路架構圖

### 2.4 YOLO 模型架構

首先 YOLO 最一開始的是由 Redmon *et al.* (2016)發表的論文，它的辨識流程如圖 5 所示是根據先將整張輸入影像會被劃分為一個  $S \times S$  的網格。每一個格子被指派負責偵測其中心點所落入的物件。每個格子會預測兩樣東西，一個是邊界框(bounding boxes)和信心值(confidence)，預測邊界框會先得知每個框包含位置座標(x, y, w, h)而信心值會給出每個一邊界框裡是屬於哪一個類別的可能性最高，其公式如式(1)。

$$\text{confidence} = p(\text{object}) * IOU_{pred}^{truth} \dots\dots (1)$$

$p(\text{object})$ 為物體存在的機率， $IOU_{pred}^{truth}$ 表示預測邊界框與地面真實邊界框，接下來加上邊界框和信心值的搭配顯示出機率分布圖。最後將這些系統將這些預測結果進行融合與非極大值抑制(Non-Maximum Suppression, NMS)，產生出最終的物件偵測框與其類別。

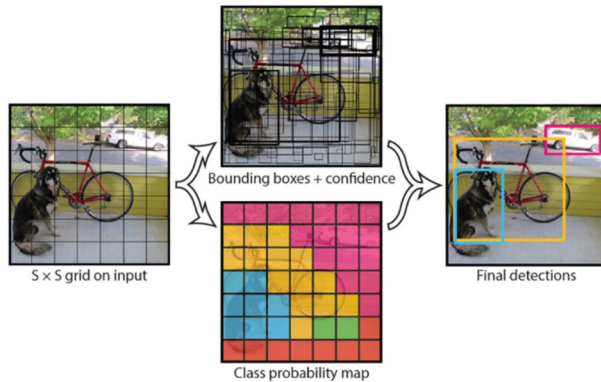


圖 5 YOLO 模型物件偵測圖

而由 Wang *et al.* (2024)發表 YOLOv9 是 YOLO 模型有國際期刊認證的最新模型，與 YOLOv7 的是同一位作者發表的，故在程式碼的邏輯大部分與 YOLOv7 是相同的，YOLOv7 已經可以達到相當高的精度了，所以 YOLOv9 提出方法解決深度神經網路，通过整合可程式梯度資訊(Programmable Gradient Information, PGI) 和多功能廣義高效層聚合網路(GELAN)架構，YOLOv9 不僅增強了模型的學習能力，確保了在整個檢測過程中保留關鍵信息，實現卓越的準確性和性能，解決訓練時遺失的許多

原始資訊。

圖 6 為 YOLOv9 的架構圖，採用由深至淺的模組化設計，其架構可分為 Backbone、Neck 與 Detection Head 三大部分。輸入影像首先透過一系列卷積層與可重參數化模組 RepNCSPeLan4 進行特徵提取，強化局部與全局資訊的捕捉，構成主幹網路(Backbone)。接著引入 GELAN 上下採樣結構以融合不同層級特徵，Neck 部分則整合語意與細節資訊，進一步強化特徵表達能力。偵測頭(Head)設有三個輸出尺度(P3、P4、P5)，對應於不同大小物件之偵測任務，每一路徑皆包含邊界框回歸(conv-reg)與分類(conv-cls)分支。另於 Backbone 中段引入 CBLIner 與 CBFuse 模組進行通道壓縮與特徵融合，兼顧模型表達力與運算效率。整體而言，YOLOv9 融合輕量化、多尺度與模組化設計，展現優異的即時目標偵測性能。

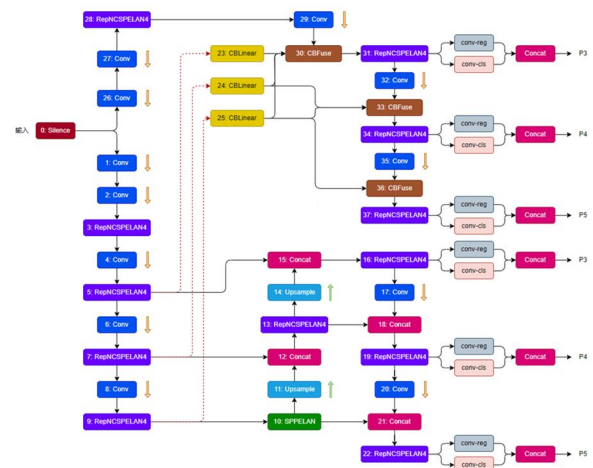


圖 6 YOLOv9 架構圖

目前 YOLOv9 運用在醫學和農業上，以 Chien *et al.* (2024)利用 YOLOv9 模型應用到骨折偵測任務中，作為電腦輔助診斷，幫助放射科醫師和外科醫師解讀 X 光影像，mAP50-95 值提升了 3.7%，可以有有效的幫助一些缺乏豐富經驗的醫生提早熟悉並解讀 X 光影像。而農業則是以 Vo *et al.* (2024) 用 YOLOv9 檢測成熟的番茄，相較於其他模型有較佳的表現，說明了對相對小的目標的可用性。故本研究也將運用此模型於鋪面裂縫檢測上。

### 2.5 模型性能評估指標

評估模型的指標為混淆矩陣，其示意圖如圖 7 所示，它是評判模型好壞的一個重要指標其中它將情況分為實際現地的情形和模型訓練完成所產生的情形，而這兩個經過排列組合可以分為 4 種不同的情況，分別為真陽性(True Positive, TP)、偽陽性(False Positive, FP)、真陰性(True Negative, TN)以及偽陰性(False Negative, FN)。利用這四種不同的情形可以去算出以下指標，分別為精確率(Precision)、召回率(Recall)、平均精確度(Mean Average Precision)。

混淆矩陣 (Confusion Matrix)	實際○	實際×
預測○	TP (True Positive)	FP (False Positive)
預測×	FN (False Negative)	TN (True Negative)

圖 7 混淆矩陣示意圖

精確率表示在所有被模型判定為正類的樣本中，實際為正類的比例，反映模型在正向預測中的準確程度。其計算方式為 TP 與預測為正類總數 TP + FP 之間的比值，如式(2)所示。

$$Precision = \frac{TP}{(TP+FP)} \dots\dots\dots (2)$$

召回率又稱為查全率，用以衡量模型對實際正類樣本的識別能力。其定義為真正例 TP 與實際正類總數 TP + FN 之間的比值，亦即在所有實際為正類的樣本中，被正確預測出來的比例，如式(3)所示。

$$Recall = \frac{TP}{(TP+FN)} \dots\dots\dots (3)$$

平均精確率為各類別平均精度 (Average Precision, AP) 之加權或非加權平均，用以綜合評估模型在多類別偵測任務中的整體性能。AP 則是指

由精確率與召回率所構成曲線下的面積，代表在不同召回率下模型的精準表現，其計算方式如式(4)。

$$AP = \int_0^1 p(r)dr \dots\dots\dots (4)$$

公式中變數 r 沿著精確率(Precision)曲線所進行之積分，亦即計算 Precision-Recall 曲線下之面積。

而 mAP 則是將所有類別所對應之 AP 值進行加總後取平均，反映模型在整體偵測任務中的平均表現，其計算方式如式(5)所示。

$$mAP = \frac{1}{k} \sum_i^k AP_i \dots\dots\dots (5)$$

其中，k 為類別的數量。

## 2.6 相機率定

相機率定(Camera Calibration)是計算相機在拍攝影像時，其內部幾何與光學參數以及相機與世界坐標系之間空間關係的過程。透過率定，可以將影像中的像素座標轉換為實際空間中的位置，並消除鏡頭造成的幾何畸變，使影像更符合真實世界的幾何特性。

因為本研究是利用影片的方式去拍攝道路，故利用影片方式率定，以確保後續研究拍攝時的像素等參數會是一致的。在把影片每 30 幀擷取一張影像，總共有 183 張影像。因為無人機的相機會自動追蹤物體，尤其在無人機做上下移動時特別明顯，故在拍攝時不適合上下移動無人機去拍攝率定板，故將影片分為三組去拍攝，利用上、中和下的拍攝角度以確保率定時有不同方位的拍攝角度去涵蓋，藉此提高率定的精度，圖 8、圖 9、圖 10 是率定拍攝不同角度的示意圖。

表 1 為率定完成的畸變差參數。



圖 8 由上往下拍攝示意圖




圖 9 置中拍攝示意圖




圖 10 由下往上拍攝示意圖

表 1 畸變差參數表

畸變差參數	
輻射畸變差 (k1, k2, k3)	(-0.0013, 0.0191, -0.0002)
偏心畸變差 (p1, p2)	(-0.0011, 0.0439)

## 2.7 SfM

運動回應結構(Structure from Motion, SfM)是一種基於多視角 2D 影像之計算機視覺技術，能在無需事先率定的情況下自動推估每張影像拍攝當下之相機內外方位參數，進而重建場景的三維結構。SfM 整合了特徵點偵測、特徵匹配、相機姿態估計與三維點雲重建等關鍵步驟，透過視差分析與幾何反算，實現由影像至模型的立體重建流程。其基本原理如圖 11 所示。




圖 11 SfM 演算法示意圖(楊明德&蔡慧萍, 2018)

在 SfM 中每張輸入影像需先透過特徵擷取技術偵測出具代表性的關鍵點。其中，Lowe(2004)提出的 SIFT(Scale-Invariant Feature Transform)演算法，因其對平移、旋轉與尺度變化的強大不變性及對光照與視角變形的容忍力，成為 SfM 中最具代表性的

特徵點擷取技術之一，它的步驟如下所示，分為四個步驟：

- (1) 尺度空間極值偵測：建立影像之尺度空間，並以高斯差分(DoG)逼近拉普拉斯運算，用以尋找不同尺度下之極值點，其公式如式(6)所示。

$$D(x,y,\sigma)=[G(x,y,k\sigma)-G(x,y,\sigma)]\times I(x,y) \\ =L(x,y,k\sigma)-L(x,y,\sigma) \dots\dots\dots (6)$$

- (2) 透過泰勒展開精細估算位置與尺度，並剔除邊緣或低對比特徵點，以提升匹配穩定性。
- (3) 為了讓特徵點具備旋轉不變性，SIFT 演算法會根據每個關鍵點鄰域內像素的梯度方向與強度來指定其主方向，其公式如式(7)、式(8)所示。

$$m(x,y) = \sqrt{L_x^2 + L_y^2} \dots\dots\dots (7)$$

$$\theta(x,y) = \tan^{-1}\left(\frac{L_y}{L_x}\right) \dots\dots\dots (8)$$

其中 $\theta(x,y)$ 為在位置 $(x,y)$ 的像素灰階變化的方向角度。 $\frac{L_y}{L_x}$ 為 y 與 x 方向上的灰階差比值。

- (4) 為了進一步強化特徵的不變性，SIFT 在每個關鍵點周圍建立一個 16x16 的區域，並將其劃分為 4x4 的子區塊。每個子區塊中會計算一組 8

個方向的梯度直方圖，最終將所有子區塊的直方圖組合為一個長度為 128 的特徵向量。此描述子具備平移、旋轉與尺度的不變性，並對光照變化與仿射變形具備良好魯棒性，有助於進行準確且穩定的特徵匹配。

## 2.8 U-net

U-Net 是由 Ronneberger *et al.* (2015)提出的一種卷積神經網路架構，針對 FCN 架構進行優化，使其在保持高精度定位的同時，更有效地提取影像的上下文資訊。特色是其能在訓練資料量有限的情况下，仍展現出優異的分割效能，提升模型對細微結構的辨識能力。圖 12 為 U-Net 的模型架構圖，它主要分為三個部份。

### (1) 編碼器(Encoder)：

位於 U-Net 架構的左側，編碼器功能類似於卷積神經網路中的特徵提取器，由多層卷積層、非線性激活函數、池化層與下採樣操作所組成。其目的為逐步壓縮輸入影像的空間尺寸，並提取高層次抽象特徵。隨著層數增加，特徵圖的解析度降低、通道數增加，能有效捕捉全局語意資訊與關鍵區域特徵。

### (2) 解碼器(Decoder)：

解碼器位於網路右側，負責將經過編碼器壓縮後的特徵圖逐層恢復至原始影像尺寸。解碼過程中通常採用上採樣或反卷積操作，並在每一層結合來自編碼器對應層的特徵，逐步重建空間細節。此機制有助於提升模型在邊界與小區域的分割準確性。

### (3) 跳躍連接(Skip Connections)：

U-Net 最大的特點在於其引入跳躍連接機制，將編碼器中各層的特徵圖直接傳遞至解碼器對應層。此設計能有效補償下採樣過程中損失的空間細節，使得解碼器在重建過程中能同時參考高階語意特徵與原始解析度特徵，進而提升分割結果的精確性與邊界還原能力。

## 3. 研究成果與分析

### 3.1 模型環境與超參數

本研究使用 Anaconda 建置環境去訓練 YOLOv9 模型，利用的環境與電腦配備參數如表 2、表 3 所示。

表 2 電腦配備表

電腦配備	
作業系統	Windows 10 專業版
處理器(CPU)	Intel® Core™ i7-8700K CPU@3.70GHz 3.70GHz
顯示卡(GPU)	NVIDIA GeForce GTX 1060 6GB
記憶體(RAM)	40.0 GB
tqdm	4.66.5

表 3 模型訓練環境參數表

環境參數	
套件項目	版本
CUDA	11.6
Matplotlib	3.7.5
Numpy	1.24.4
Pillow	9.5.0
Python	3.8.19
Opencv-python	4.10.0.84
Spyder	5.5.1
Torch-gpu	1.13.0+cu116
Torchvision	0.14.0+cu116
tqdm	4.66.5




圖 12 U-Net 模型架構圖

在機器學習與深度學習模型中，超參數 (Hyperparameters)是在訓練過程開始前所設定的參數，其值不會透過模型學習自動調整，而是需透過經驗或實驗進行手動設置或調參。這些參數對模型的學習效率、收斂速度與最終準確度具有顯著影響。而表 4 是本研究訓練 YOLOv9 所使用的超參數表。

表 4 模型訓練超參數表

超參數	值
Initial learning rate 初始學習率	0.02
Final learning rate 最終學習率	0.02
Batch size 批次大小	2
Momentum 動量	0.937
Weight_decay 權重衰減	0.0005

### 3.2 飛行航高比較

本研究所需要偵測的裂縫寬度最小值為公路局養護手冊所頒佈 3mm 大小，然而為了需要有效的觀測到路面上的裂縫，必須要控制無人機的飛行高度讓相機所拍攝的影片有足夠的解析度，故利用公式(9)推導極限航高。

$$GSD = \frac{H \times p}{f} \dots\dots\dots (9)$$

其中 GSD(Ground sample distance)是地面採樣距離，為衡量解析度的指標， $H$  為航高、 $p$  為感光元件大小、 $f$  為鏡頭焦距。然而相機出場後感光元件大小可能會有失真等誤差存在，根據 Bandini *et al.* (2017)的算法，利用鏡頭視角來計算所需偵測的寬度，故本研究依照此參數來替代感光元件以計算極限航高，公式如(10)所示。

$$H = \frac{W \times GSD}{2 \times \tan \frac{HFOV}{2}} \dots\dots\dots (10)$$

因為要捕捉 3mm 的裂縫寬度，故設定其在影像上需要最少有 1 pixel，故 GSD 為 3(mm/pixel)，而 HFOV 為鏡頭視角，也就是本研究使用的相機規格表所得出的 77°， $W$  為影像寬度，其大小為 5472pixels，經計算後可得到極限航高大約為 10.32 m，後續選取道路上在裂縫上的白色石頭，上面最寬的裂縫，現實寬度約為 10.5mm 的裂縫，將影像展圖在小畫

家上並找出其位置，可以發現他約為 3.5 個 pixels，說明這組航高計算是可以當捕捉 3mm 裂縫寬度的極限航高使用。




圖 13 裂縫影像示意圖

然而 10.32m 為可以辨識到研究所需的裂縫最小值，但是此解析度可能在 YOLO 模型裡的辨識率可能會相當不好，故本研究選取了三組航高去比較航高對於道路檢測的效率和辨識率。選取了三組航高包含了 10m，也就是極限航高，然後在選取了 7m 和 8.5m，其中因台灣有些道路有電線縱橫交錯的關係，7m 的航高剛好約為 2 層樓，可以高過路邊電線以防無人機被電線擋住路線造成道路巡檢時的安全疑慮。在 7m 和 10m 的中間取一個中間值確保兩者比較的值是有可信的，而非人為或是模型的表現浮動所導致的。然後將這三組航高所拍攝的影片進行全幅的影像拼接，對三組航高進行影像提取，以每十幀擷取一張影像以保持地面的資訊，7m 的航高總共擷取了 90 張影像，8.5m 的為 66 張影像，10m 的總共有 109 張影像，這些影像都是 3840x2160 的 jpg 檔，拼接的成果圖如圖 14 所示。




圖 14 全幅影像圖

為了要比較模型與實際辨識裂縫的準確性，首先要先找出真值以做比較，故利用全幅影像進行人工的裂縫標註，將人眼能辨識的裂縫框選出來，圖 15 則是人工框選後的結果。




圖 15 人工標註的全幅影像圖

利用影片所有出現的候選框與上列三組航高進行 IOU 的計算，得到不同航高所得到的成功辨識率，將所有影片以及圖 15 成果進行候選框重疊率進行計算，其中以 7m 的航高所得到的影片的辨識率是最高的，為 85%，比 10m 航高的準確率高了 12%，而 8.5m 的為 75%，故後續選擇 7m 航高做後續的研究。

### 3.3 YOLOv9

以下為 YOLOv9 模型經過 94 小時訓練 100 個 epoch 的損失圖，其損失函數與效能指標如圖 16 所示。

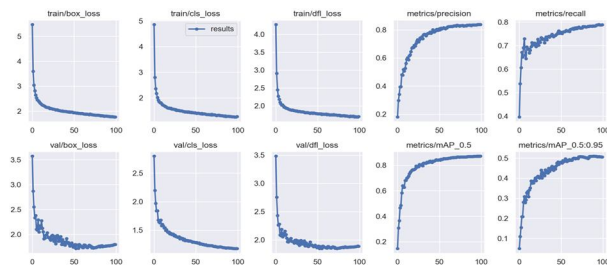


圖 16 YOLOv9 訓練損失圖

模型經過 100 個 epoch 的訓練，從損失曲線可觀察到，無論是訓練或驗證階段，box\_loss(邊界框損失)、cls\_loss(分類損失)與 dfl\_loss(分佈式 Focal Loss)皆呈現穩定下降趨勢，顯示模型在空間定位與

類別預測上均具良好收斂性。在評估指標方面表現如表 5 所示。

表 5 模型訓練指標表

Precision	Recall	mAP50	mAP50-95
0.845	0.815	0.891	0.55

Precision(準確率)與 Recall(召回率)皆隨訓練輪數增加而穩定上升，最終分別穩定於約 0.85 與 0.80，顯示模型在降低誤檢的同時，亦能有效涵蓋多數裂縫目標。mAP50 達到約 0.89，代表在 IoU 門檻為 0.5 時，模型已能準確定位裂縫之邊界框。然而，mAP50-95 進一步綜合評估模型在多個 IoU 門檻(0.5 至 0.95，每 0.05 一階)下的整體偵測表現，其數值穩定提升並收斂至約 0.55，顯示模型不僅能成功偵測裂縫位置，亦具備一定程度的邊界框定位穩定性。考量瀝青鋪面裂縫本身形狀細長且邊界不規則，高 IoU 門檻下對邊界框重疊要求更為嚴格，因此 mAP50-95 相較 mAP50 略低屬合理現象，亦反映模型在實際道路場景中仍能維持良好且穩定的整體偵測能力。

後續選取一塊鋪面進行模型的測試，圖 17 裡的一幀影片辨識，可以看到大多數的裂縫都有被辨識出來，說明模型的可行性。



圖 17 實驗區域辨識成果圖

### 3.4 SfM

為了評估對整體為確定後續量化精度準確性，本研究採用 Structure from Motion 技術進行三維重建與正射影像產製，其主要流程可分為以下四個。

#### (1) 特徵點選取

由多張 UAV 影像中提取局部不變特徵點，使

用 SIFT 演算法。每張影像的特徵資料儲存為 .pkl 格式，記錄了每一幀影像中關鍵點的描述子資訊，為後續匹配與重建提供基礎。

#### (2) 特徵匹配與稀疏點雲重建

透過跨影像特徵匹配，並利用兩兩影像進行相對姿態估計與三角測量，逐步擴展場景點雲，產生稀疏三維模型。如圖 18 所示。




圖 18 粗點雲示意圖

```

frame_0000
R:
1.00000000 0.00000000 0.00000000
0.00000000 1.00000000 0.00000000
0.00000000 0.00000000 1.00000000
t:
0.00000000 0.00000000 0.00000000

frame_0001
R:
0.99999981 0.00010334 0.00060415
-0.00010318 0.99999996 -0.00025445
-0.00060418 0.00025439 0.99999979

frame_0002
R:
-0.99999997 -0.00016789 0.00015287
0.00016811 -0.99999998 0.00141554
0.00015263 0.00141537 0.99999899

frame_0003
R:
-0.99999853 -0.00031956 -0.00168644
0.00031463 -0.99999367 0.00292482
-0.00168737 0.00292429 0.99999430

frame_0004
R:
-0.99999983 -0.00020272 -0.00055204
0.00020136 -0.99999697 0.00245468
-0.00055254 0.00245457 0.99999683

frame_0005
R:
-0.99999966 -0.00023517 -0.00079270
0.00023343 -0.99999757 0.00219359
-0.00079322 0.00219340 0.99999728

```

圖 19 相片外方位參數圖



圖 20 正射影像圖

#### (3) 相機外方位參數估算

在 SfM 過程中，同步求解每一張影像的外部參數(旋轉矩陣  $R$  與平移向量  $t$ )，建立全域相機位置與姿態資訊，如圖 19 所示，這些參數為後續多視角幾何建模與正射影像糾正提供依據。

#### (4) 正射影像生成

結合已校正的相機姿態與三維點雲，將原始影像重新投影至平面座標系中，生成無透視變形的正射影像成果，如圖 20 所示。此成果可用於後續量測、比對與分析，具備高解析與幾何精度。

### 3.5 寬度量化

經過 YOLOv9 快速辨識後，可以得到他的類別 (crack) 和置信分數(小數點)，可以快速的抓出有裂縫的區域，將不重要的背景去除，留下裂縫的區域做後續量化之研究。圖 21 為擷取後的裂縫區域。




圖 21 裂縫辨識區域圖

擷取完後將辨識框進行去除，把完整的道路裂縫呈現出來後，然後進行 U-net 模型的遮罩提取，以利於做裂縫寬度量化，但是此圖所擷取出來的裂縫因為範圍太少讓模型無法找到影像上下文的資

訊，會使裂縫區域偵測不出來，導致輸出成全黑的遮罩圖，所以本研究將裂縫區域擷取的擴大了左右的圖片擷取，讓模型有足夠的影像大小去讀取上下文的資訊，能夠順利的產出遮罩圖，後續再利用遮罩圖去算平均裂縫寬度大小。圖 22 為擴大後的影像，圖 23 為 U-Net 所得出的遮罩圖。



圖 22 擴大後裂縫擷取圖




圖 23 U-net 辨識完遮罩圖

將裂縫的輪廓遮罩擷取出來之後，本研究參考 Miao & Srimahachota (2021) 提出的算法進行裂縫寬度的計算，該方法首先於裂縫骨架中選定一觀測點  $P$ ，並以此點為中心，向前後各取固定長度建立局部鄰域範圍。如圖 24，透過鄰域內的骨架點進行線性回歸分析，以獲得該區域裂縫的主要延伸方向，並建立一條擬合直線。接著，構建一條垂直於擬合線  $l$  的法線，並尋找此法線與裂縫邊緣的交點。最終，將兩點間的垂直距離作為該處裂縫寬度之估計值。

其中  $S$  為裂縫輪廓， $\delta$ 、 $\delta$  為鄰近值距離， $l$  為擬合線， $l'$  為法線， $P$  和  $P'$  為法線方向到裂縫輪廓距離。

然而根據此算法會算出各個節點的寬度 pixels 數，然而一條裂縫可能會有寬度大小不一的情形，

這會導致節點過少的話在計算平均寬度的時候漏掉裂縫的極端數據，造成寬度量化的不精確。過多的擷取節點也會造成資料過於冗餘，故本研究將選取三個節點數，分別為 25、50 和 75 個節點去分析同樣長度的裂縫他們計算平均裂縫寬度與真值的比值，評估出最適合的一個節點選取數量。圖 25 為五十個節點在裂縫上的示意圖。




圖 24 Miao & Srimahachota(2021)提出寬度量化方法示意圖




圖 25 五十個節點示意圖

表 6 為 50 個節點所算出來的寬度量化表。

表 6 50 個節點寬度量化表

編號	坐標 (x,y)	pixels	編號	坐標 (x,y)	pixels
1	(72,24)	1	26	(84,142)	2
2	(75,28)	1	27	(85,146)	1
3	(78,32)	3	28	(85,151)	2
4	(79,36)	3	29	(85,156)	2
5	(80,41)	3	30	(84,161)	5
6	(80,46)	2	31	(83,165)	3
7	(80,51)	2	32	(82,170)	1
8	(80,56)	2	33	(83,175)	2
9	(80,62)	2	34	(84,179)	2
10	(80,67)	2	35	(86,184)	4
11	(82,71)	3	36	(86,189)	3
12	(84,75)	1	37	(86,194)	3
13	(84,80)	3	38	(86,199)	2
14	(83,85)	3	39	(86,204)	2
15	(81,89)	3	40	(87,209)	4
16	(80,94)	1	41	(88,213)	3
17	(79,99)	1	42	(88,218)	2
18	(78,103)	2	43	(88,224)	2
19	(78,108)	3	44	(88,229)	3
20	(80,113)	4	45	(88,234)	2
21	(81,118)	3	46	(88,239)	3
22	(81,122)	1	47	(87,244)	1
23	(82,127)	1	48	(87,249)	2
24	(83,132)	1	49	(87,254)	3
25	(83,137)	1	50	(87,258)	2

經過 3 組不同節點所算出來的各節點裂縫寬度量化之結果,其中 25 節點的總裂縫寬度為 53 pixels, 平均裂縫寬度大小為 2.12 pixels; 50 節點的總裂縫寬度為 113 pixels, 平均裂縫寬度大小為 2.26 pixels; 75 節點的總裂縫寬度為 168 pixels, 平均裂縫寬度大小為 2.24 pixels。計算飛行航高 10.32m 的時候 GSD 為 3mm/pixel, 故飛行 7m 的時候 GSD 為 2.034mm/pixel, 將平均裂縫寬度乘上 GSD 後就可以得到所算出來的裂縫寬度實際大小,如表 7 所示。

表 7 各節點精度表

已知值(mm)	節點數	pixels	寬度(mm)	絕對誤差(mm)
4.76	25	2.12	4.31	0.45
	50	2.26	4.60	0.16
	75	2.24	4.55	0.21

根據上面的數據,可以得到 25 個節點與真值的絕對誤差為 0.45 mm, 50 個節點為 0.16mm, 75 個節點的為 0.21mm, 其中三組資料算出來的結果皆是相當的。

## 4. 結論與建議

### 4.1 結論

本研究首先利用 UAV 結合 YOLOv9 對路面先進行裂縫辨識,在選取最佳航高後,再利用 U-net 對裂縫進行寬度的量化以掌握整體裂縫生長。在研究裡可以發現 YOLOv9 在鋪面裂縫辨識上展現極佳效能,本研究導入 YOLOv9 模型進行瀝青鋪面裂縫辨識,透過 CrackForest 公開資料集訓練後,模型於 mAP50 達 0.891, mAP50-95 達 0.55,顯示模型在辨識精度與多尺度適應性上表現優異。YOLOv9 引入的 PGI 與 GELAN 主幹架構,使其在小裂縫與紋理背景較為複雜的場景下仍具良好辨識力,證實其作為高效輕量級檢測架構的可行性。

而飛行高度對辨識率有顯著影響,探討不同飛行高度對模型辨識結果的影響。考量無人機飛行穩定性與視野覆蓋範圍後,實驗結果顯示 7 m 航高可達成最佳的準確率,約為 83%的準確率,1pixel 約為 2.034mm,同時保留兩線車道畫面,為後續大範圍鋪面巡檢提供實用參考依據。

最後利用不同節點數去計算平均裂縫寬度,可以得到 25 個節點與已知值的絕對誤差為 0.45 mm, 50 個節點的絕對誤差為 0.16mm, 75 個節點的絕對誤差為 0.21mm, 其中以 50 個節點精度最好且不會造成過多的資料,說明此長度下進行裂縫寬度計算時三個節點數的擷取所算出來的誤差值都是相對小的,可以根據需求去選取。

### 4.2 建議

- (1) 增加多樣化的實景訓練資料以提升泛化能力建議未來可擴增資料來源,包括不同氣候、路況、照明條件下的鋪面影像,使模型具備更佳的適應性與魯棒性。尤其應涵蓋夜間、潮濕路面、起伏坡度與遮蔽陰影等複雜情境,以應對實際巡檢多變條件。
- (2) 推進系統化航線規劃與自動化調度能力,為實現完整無人巡檢任務,建議整合航線規劃模組與影像觸發控制器,使無人機能根據路網資訊自動規劃巡航軌跡,並依據飛行高度、鏡頭視角動態調整拍攝策略,以減少重疊冗餘並提升涵蓋效率。也可以利用更高解析度的機載相機去捕捉影片,探討更高的不同航高的影響與可行性。
- (3) 因為本研究僅針對公路局所頒布的養護手冊針對裂縫的寬度去做量化,後續也可以針對裂縫的長度進行量化,已對整體裂縫的走向以及發展有更進一步的了解和控制,為整體道路裂縫檢測提供一個更完善的流程。

### 參考文獻

- 中華民國交通部, 2020。交通部公路總局公路養護手冊。[Ministry of Transportation and Communications, 2020. Highway Maintenance Manual by the Directorate General of Highways, Ministry of Transportation and Communications. (in Chinese)]
- 楊明德、蔡慧萍, 2018。無人飛行載具發展現況與未來趨勢, 土木水利, 45(3): 23-29, DOI: 10.6653/MoCICHE.201806\_45(3).0004。[Yang,

- M.D., and Tsai, H.P., 2018. An analysis of the development status and future trajectories of Unmanned Aerial Vehicle, *Civil and Hydraulic Engineering*, 45(3): 23-29, DOI: 10.6653/MoCICHE.201806\_45(3).0004. (in Chinese)]
- Bandini, F., Jakobsen, J., Olesen, D., Reyna-Gutierrez, J. A., and Bauer-Gottwein, P., 2017. Measuring water level in rivers and lakes from lightweight Unmanned Aerial Vehicles, *Journal of Hydrology*, 548: 237-250, DOI: 10.1016/j.jhydrol.2017.02.038.
- Cha, Y.J., Choi, W., and Büyüköztürk, O., 2017. Deep learning-based crack damage detection using convolutional neural networks, *Computer-Aided Civil and Infrastructure Engineering*, 32(5): 361-378, DOI: 10.1111/mice.12263.
- Chambon, S., Subirats, P., and Dumoulin, J., 2009. Introduction of a wavelet transform based on 2D matched filter in a Markov random field for fine structure extraction: Application on road crack detection, in *Proceedings of the SPIE Vol. 7251, Image Processing: Machine Vision Applications II*, San Jose, CA, USA, pp. 87-98, DOI: 10.1117/12.805437.
- Chien, C.T., Ju, R.Y., Chou, K.Y., and Chiang, J.S., 2024. YOLOv9 for fracture detection in pediatric wrist trauma X-ray images, *Electronics Letters*, 60(11): e13248, DOI: 10.1049/ell2.13248.
- Gavilán, M., Balcones, D., Marcos, O., Llorca, D.F., Sotelo, M.A., Parra, I., Ocaña, M., Aliseda, P., Yarza, P., and Amírola, A., 2011. Adaptive road crack detection system by pavement classification, *Sensors*, 11(10): 9628-9657, DOI: 10.3390/s111009628.
- Lowe, D.G., 2004. Distinctive image features from scale-invariant keypoints, *International Journal of Computer Vision*, 60: 91-110, DOI: 10.1023/B:VISI.0000029664.99615.94.
- Miao, P., and Srimahachota, T., 2021. Cost-effective system for detection and quantification of concrete surface cracks by combination of convolutional neural network and image processing techniques, *Construction and Building Materials*, 293: 123549, DOI: 10.1016/j.conbuildmat.2021.123549.
- Ragnoli, A., De Blasiis, M.R., and Di Benedetto, A., 2018. Pavement distress detection methods: A review, *Infrastructures*, 3(4): 58, DOI: 10.3390/infrastructures3040058.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., 2016. You only look once: Unified, real-time object detection, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, pp. 779-788, DOI: 10.1109/CVPR.2016.91.
- Ronneberger, O., Fischer, P., and Brox, T., 2015. U-net: Convolutional networks for biomedical image segmentation, in *Proceedings of the Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015*, Navab, N., Hornegger, J., Wells, W., and Frangi, A. (eds), *Lecture Notes in Computer Science*, Springer, Cham, vol. 9351, pp. 234-241, DOI: 10.1007/978-3-319-24574-4\_28.
- Tsai, Y.C., Kaul, V., and Mersereau, R.M., 2010. Critical assessment of pavement distress segmentation methods, *Journal of Transportation Engineering*, 136(1): 11-19, DOI: 10.1061/(ASCE)TE.1943-5436.0000051.
- Vo, H.T., Mui, K.C., Thien, N.N., and Tien, P.P., 2024. Automating tomato ripeness classification and counting with YOLOv9, *International Journal of Advanced Computer Science and Applications*, 15(4): 1120-1128.
- Wang, C.Y., Yeh, I.H., and Mark Liao, H.Y., 2024. Yolov9: Learning what you want to learn using programmable gradient information, in *Proceedings of the European Conference on*

- Computer Vision (ECCV), Leonardis, A., Ricci, E., Roth, S., Russakovsky, O., Sattler, T., Varol, G. (eds) , Lecture Notes in Computer Science, Springer, Cham, vol. 15089, DOI: 10.1007/978-3-031-72751-1\_1.
- Zhou, H., Kong, H., Wei, L., Creighton, D., and Nahavandi, S., 2014. Efficient road detection and tracking for unmanned aerial vehicle, IEEE Transactions on Intelligent Transportation Systems, 16(1): 297-309, DOI: 10.1109/TITS.2014.2331353.
- Zhu, J., Zhong, J., Ma, T., Huang, X., Zhang, W., and Zhou, Y., 2022. Pavement distress detection using convolutional neural networks with images captured via UAV, Automation in Construction, 133: 103991, DOI: 10.1016/j.autcon.2021.103991.

# Automatic Detection of Asphalt Pavement Cracks Using Unmanned Aerial Vehicles and Deep Learning

Kai-Ming Liu <sup>1\*</sup>    Szu-Pyng Kao <sup>2</sup>    Feng-Liang Wang <sup>3</sup>    Jhih-Sian Lin <sup>4</sup>

## Abstract

This study integrates Unmanned Aerial Vehicles (UAVs) with the deep learning object detection model YOLOv9 to conduct automated detection and analysis of cracks in asphalt pavement. Leveraging the high mobility and high-resolution imaging capabilities of UAVs, the system can rapidly cover large road areas and significantly reduce the time and labor costs associated with manual inspections. The YOLOv9 model was initially trained using the publicly available CrackForest dataset for pavement cracks. After 100 training epochs, the model achieved a detection accuracy of  $mAP50 = 0.891$  and  $mAP50-95 = 0.550$  on the test set, demonstrating strong performance in small object detection and pavement crack identification. Finally, through orthorectification and geometric correction, the detection results were projected onto real-world coordinates for crack width quantification. The results verify that the proposed system can serve as an effective tool for road maintenance decision-making and management.

**Keywords:** UAV, YOLOv9, Crack Detection, Pavement Crack, Deep Learning

---

<sup>1</sup> Master, Department of Civil Engineering, National Chung Hsing University

<sup>2</sup> Professor, Department of Civil Engineering, National Chung Hsing University

<sup>3</sup> Assistant Professor, Department of Applied Geoinformatics, Chien Hsin University of Science and Technology

<sup>4</sup> Ph.D., Department of Civil Engineering, National Chung Hsing University

\* Corresponding Author, E-mail: daniel1900513@gmail.com

Received Date: Sep. 03, 2025

Revised Date: Oct. 15, 2025

Accepted Date: Feb. 25, 2026

# 應用 YOLOv8 與 NCC 協助鹽倉影像三維建模之 控制點坐標量測

陳律志<sup>1\*</sup> 饒見有<sup>2</sup> 洪慶忠<sup>3</sup>

## 摘要

本研究針對大型圓柱形鹽倉，提出一套整合攝影測量與深度學習之自動化三維建模流程，以提升惡劣環境下之建模效率與量測精度。於鹽倉中央懸臂吊車架設雙工業相機，取得高重疊影像，並以 CLAHE 進行影像增強。利用 YOLOv8 偵測地面控制點標靶位置，結合 Normalized Cross-Correlation 進行次像素精度定位。為提升空中三角測量品質，採用 LightGlue 進行特徵匹配與影像篩選，並透過 Metashape Python 腳本自動完成空三解算與稠密點雲建構。實驗以 401 筆 GCP 為基礎，結果顯示定位誤差約為 2%，證明本方法具良好穩定性與精度，可有效降低人工量測負擔並提升鹽堆體積估算效率。

**關鍵詞：**攝影測量、正規化互相關、深度學習、三維建模

## 1. 前言

隨著工業製程與儲運需求的提升，工業鹽在化工、能源與製造業中扮演關鍵角色，大型鹽倉成為其主要儲存與流通設施。傳統對鹽堆體積與庫存量的測量方式多仰賴目視估算或人工標記，面對昏暗光線、高粉塵、堆疊不規則等複雜環境條件，常造成測量結果不穩定，甚至伴隨安全風險。雖然地面雷射掃描(Terrestrial Laser Scanning, TLS)能提供高精度量測結果，但操作需動員大型設備與人力，且無法涵蓋鹽堆背面陰影區域，導致資料缺損或建模不完全。

### 1.1 研究背景

本研究旨在解決傳統鹽倉量測方式存在的人工干預高、效率低與資料不完整等問題，提出一套融合深度學習與攝影測量技術的全自動化三維建模流程，以提升建模品質並降低現場作業風險。

本研究的具體目的如下：(1)發展一套自動化 GCPs (Ground Control Points)偵測與定位流程：透過

CLAHE (Contrast Limited Adaptive Histogram Equalization)提升影像品質，使用 YOLOv8 偵測倉壁標籤，再以 NCC 執行次像元精度比對，取得高準確度的 GCP 影像坐標。(2)應用深度特徵匹配以優化影像選取策略：利用 LightGlue 自動分析影像間重疊程度，剔除過度重疊影像以穩定 SfM 結果。(3)建構可穩定應用於鹽倉內部之自動建模流程：整合上述流程於 Metashape 腳本中，完成影像導入、相機定位、誤差剔除、模型生成與體積推估。(4)驗證該流程於惡劣環境條件下的可行性與精度表現：針對實際拍攝的鹽倉影像，評估 YOLOv8、NCC 的準確率與整體建模成果，提供作業自動化之量化依據。最終目標是建立一套可應用於封閉或危險工業空間(如鹽倉、煤堆、料場)的低成本、高效率自動量測系統，促進三維建模在實務工程與盤點管理中的推廣應用。

### 1.2 研究動機與目的

在大宗物料的儲存與管理作業中，三維建模技術已成為重要的數位工具，不僅能用於建立完整的

<sup>1</sup> 國立成功大學測量及空間資訊學系 碩士

<sup>2</sup> 國立成功大學測量及空間資訊學系 教授

<sup>3</sup> 乾坤測繪科技有限公司 總經理

\* 通訊作者, E-mail: p66131082@gs.ncku.edu.tw

收到日期：民國 114 年 07 月 15 日

修改日期：民國 115 年 01 月 21 日

接受日期：民國 115 年 03 月 23 日

場域模型，亦可進行如體積計算、變形分析、空間規劃與結構監測等延伸應用 (Kraus, 2007)。尤其在工業用鹽的儲存場域，例如鹽倉、鹽堆或臨海堆場，其物理形狀受限於堆積方式與場地幾何，且可能隨著時間產生不規則變化，因此倚賴準確的三維模型來執行庫存盤點與物流預測，是當前產業管理之重要課題。然而傳統的鹽倉測量方式，例如使用全站儀手動標記 GCP、運用 GPS 量測表面特徵點，或直接目視估算堆高，均面臨諸多限制與挑戰。在實務操作中，鹽倉內部常具有如下特性：

- (1) 光線微弱或分佈不均：光線自屋頂通氣孔或側牆，照度低且無法補光。
- (2) 粉塵濃度高：鹽堆裝卸與移動過程產生大量粒子，影響視線與感測。
- (3) 作業環境封閉、潮濕且具腐蝕性：影響儀器壽命與操作者安全。

上述特性不僅導致傳統測量需大量人力進場，還可能因視距受阻或測量盲區而造成資料缺漏或重建失真。部分單位雖已導入地面雷射掃描 (Terrestrial Laser Scanning, TLS)，但 TLS 雖可提供高精度資料，仍需耗費大量時間進行站點佈設，且在鹽堆背側、吊車遮蔽區或臨邊地形等位置，容易形成資料遺失 (Westoby *et al.*, 2012)，使得模型完整性與安全性受限。

在近年來發展中，以攝影測量為基礎的 SfM (Structure from Motion) 技術因成本低、靈活性高，逐漸成為室內或受限場域建模的替代方案。然而，SfM 技術要能產出具備工程級精度的三維模型，其關鍵在於必須引入高精確度的地面控制點 (Ground Control Points, GCPs) 進行絕對方位 (Absolute Orientation) 與尺度定義。若控制點在影像中的像點坐標 (Image Coordinates) 量測產生誤差，將導致後續空三平差 (Aerial Triangulation) 的模型產生整體扭曲或比例尺錯誤，進而嚴重影響最終的體積計算結果。因此，如何在鹽倉高粉塵、低照度且標籤易受遮蔽的惡劣環境下，自動且精確地提取控制點坐標，成為本研究亟欲解決的核心問題。

針對此一需求，本研究採用 YOLOv8 (You Only Look Once version 8) 系列模型作為核心偵測

工具。自 (Redmon *et al.*, 2016) 提出 YOLO 架構後，憑藉其端對端的一階物件偵測能力，YOLOv8 在速度與準確度之間取得優異平衡，已廣泛應用於工業場域之標籤辨識 (Jocher *et al.*, 2023)。透過深度學習模型，系統能快速在複雜背景中定位 GCP 編號，大幅改善傳統依賴人工標記的低效率流程。近年亦有研究將 YOLO 架構應用於 UAV 測量影像中的 GCP 自動偵測，顯示深度學習在控制點辨識上的可行性與潛力 (Naufal *et al.*, 2024)。

為進一步達成高精度定位需求，確保控制點量測精度達到次像素 (Sub-pixel) 等級，本研究在 YOLOv8 初步偵測後，輔以 NCC (Normalized Cross-Correlation) 方法進行模板匹配。模板匹配技術在機器視覺中常被用於邊緣與形狀之精細辨識，在光照變化或部分遮蔽情況下仍具有良好穩定性 (Heo *et al.*, 2010、Zhang *et al.*, 2017)。近年研究亦指出，模板匹配方法可有效應用於影像邊緣與形狀辨識任務 (Zhao *et al.*, 2024)，因此適合用於對 GCP 進行圖樣辨識與精細定位。

此外，為解決影像重疊過高導致相機姿態解算不穩的問題，本研究引入 LightGlue 特徵點匹配演算法。LightGlue 透過 Transformer 架構進行特徵匹配，能有效提升局部特徵點匹配效率與可靠性，並改善傳統特徵匹配方法在複雜場景中的匹配品質 (Lindenberger *et al.*, 2023)。傳統影像特徵點方法如 SIFT (Lowe, 2004) 雖具尺度與旋轉不變性，但在高粉塵與低對比環境中仍可能出現匹配失敗的情形。近年亦有研究利用深度學習方法學習影像特徵點，例如 SuperPoint (DeTone *et al.*, 2018)，顯示深度特徵在影像匹配任務中的潛在優勢。

綜合而言，本研究旨在建立一套自動化建模系統，透過解決惡劣環境下控制點坐標精確量測之瓶頸，提供一種低人力需求、高一致性且高精度的替代建模策略，進一步推動深度學習與攝影測量於工業空間中的融合應用，並為相關領域之三維建模流程自動化提供具體可行的參考框架。

## 2. 研究方法

## 2.1 研究流程

本研究旨在建立適用於鹽倉環境之自動化三維建模系統，整體處理流程如圖 1 所示。各步驟與本章節之技術架構具有對應關係，茲分述如下：

- (1) 資料獲取(對應第 2.3 節)：流程始於實驗設備及資料收集 (2.3 節)。此階段包含相機規格與佈設方式 (2.3.1 節) 的選定，以及現場控制點設置與量測 (2.3.2 節)，以確保後續建模具備真實坐標系基準。
- (2) 影像特徵篩選(對應第 2.4 節)：取得原始影像序列後，系統執行影像過濾策略 (2.4 節)。本研究採用 SuperPoint (2.4.1) 進行特徵點提取，並透過 LightGlue (2.4.2 節) 進行特徵匹配。此處設有一判斷機制(圖 1 菱形框)：
  - A.判定為 True (保留)：若相鄰影像間的特徵匹配數量充足且幾何分布良好，則保留該影像進入下一階段。
  - B.判定為 False (剔除)：若影像重疊率過高導致資訊冗餘，或特徵點過少導致幾何解算不穩定，系統將自動剔除該影像，不納入後續運算，以提升整體建模效率。
- (3) 控制點自動化識別(對應第 2.5 節)：經篩選之有效影像將進入控制點偵測 (2.5 節) 模組。首先進行 影像增顯 (2.5.1 節) 以克服現場低照度問題；接著利用 YOLOv8 模型 (2.5.2 節) 進行控制點標籤區域偵測；最後，針對偵測到的標籤範圍，執行 控制點精細匹配搜尋 (2.5.3 節)，利用 NCC 演算法取得次像素等級的精確中心坐標。
- (4) 三維重建與優化(對應第 2.6 節)：系統將二維影像特徵與三維控制點資訊結合，執行光束法平差。為確保模型精度，此過程包含自動化的剔除差錯機制 (2.6.1 節)，迭代移除高誤差點位，最終完成模型建立 (2.6.2 節)，產製出具備真實尺度之三維點雲與數值模型。

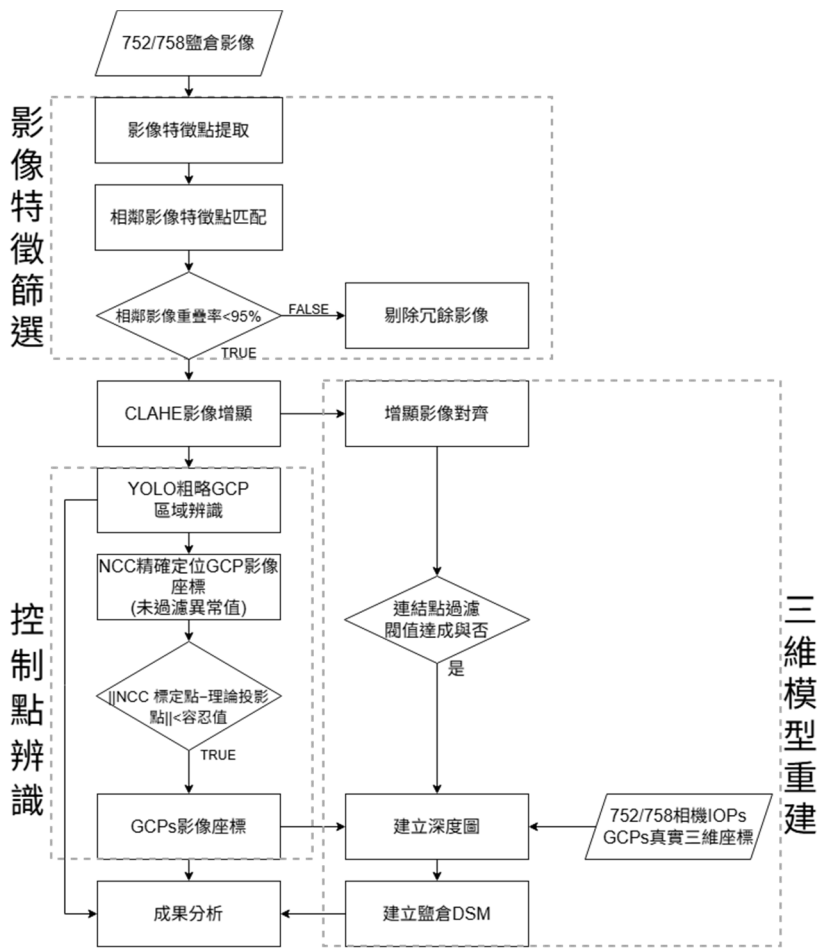


圖 1 研究流程圖



## 2.3 實驗設備及資料收集

### 2.3.1 相機規格與佈設方式

本研究採用兩台 FLIR 工業級數位相機，安裝於鹽倉中央懸臂吊車下方，垂直向下固定拍攝，隨吊臂旋轉環繞倉內取得多角度影像。相機搭載 6mm 焦距鏡頭，視野角(Field of View)為  $99^\circ \times 81^\circ$ ，影像解析度為  $4096 \times 3000$  像素(約 1200 萬畫素)，依鹽堆高度估算空間解析度約 1~2 cm。兩台相機分別命名為 752 與 758，拍攝間隔固定並具備同步快門功能，資料傳輸經網路傳至中央處理主機。為確保影像品質與後續處理穩定性，所有影像經 CLAHE 增強後才進行特徵分析與控制點偵測。

### 2.3.2 控制點設置與量測

為建立建模空間與實際場域間之尺度關係，本研究於鹽倉內壁依據方位角每隔 20 度設置一組人工控制點。標籤編號由 0N、20N 遞增至 340N，全場域共計佈設 18 組實體控制點。每組標記包含數字標籤與垂直黑條，其右上角對應位置作為 GCP 點位。

控制點三維坐標由乾坤測繪科技以全站儀量測，原始資料採 TWD97 平面坐標系與正高。為簡化處理與比對，本研究將坐標轉換為以鹽倉中心為原點的局部坐標系統(Local-E, Local-N, Local-H)，其中高程參考值以設計圖所示倉底 6m 為基準進行修正。

此轉換後之坐標除提升與模型的對齊準確性外，亦作為 YOLOv8 與 NCC 自動標記成果之精度驗證依據。需說明的是，雖現場與模型訓練定義之標籤類別共 18 類，然受限於測試資料集之隨機抽樣與部分視角遮蔽影響，後續章節(如表 3)之精確度驗證將針對其中有效觀測之 15 類樣本進行統計分析。

## 2.4 影像過濾策略

由於本研究採用固定路徑自動拍攝，所獲得影像具有極高重疊率，若不進行過濾，將導致 SfM 解算過程中出現基線過短、視差不足等問題，進而影響相機姿態與建模穩定性。

為解決此問題，本研究設計重疊率跳片策略，以每張影像為基準，透過深度學習模型 SuperPoint 擷取特徵點，再由 LightGlue 進行配對與移動量分析，依據平均特徵位移與匹配點分佈，自動判斷是否與前一張主影像過於重複。若重疊率過高則將該影像跳過，反之則視為新主影像納入建模流程。此策略可有效篩除冗餘資料，並保留空間分布良好的影像組合，提升建模效率與 SfM 解算穩定性。

### 2.4.1 SuperPoint

SuperPoint 為一種端對端的深度學習特徵點提取網路，能同時產生影像中的角點(keypoints)與其描述子(descriptors)，具備對光照變化與低品質影像的高度魯棒性。相較於傳統方法(如 SIFT)Scale-Invariant Feature Transform)、ORB(Oriented FAST and Rotated BRIEF))，SuperPoint 更適用於本研究中光線昏暗且粉塵較重的場域。每張輸入影像經適當縮放後，透過 SuperPoint 模型輸出稠密且可學習的影像特徵，作為後續匹配的基礎資料。

### 2.4.2 SuperPoint

在完成影像特徵擷取後，本研究使用 LightGlue 進行特徵點匹配與影像過濾。LightGlue 採用 Transformer 架構，透過自注意力與交叉注意力機制實現動態配對，可有效排除低信度匹配點，並搭配 RANSAC 進行幾何驗證以濾除離群值，確保每對影像間的匹配結果具有空間一致性。

為控制參與建模的影像品質與數量，本研究設計「動態主影像選擇機制」，每次以目前主影像為基準，與下一張候選影像進行特徵點比對，依平均位移判斷是否保留或跳過。若候選影像與主影像之特徵點平均位移過小，表示過度重疊，則略過該影像；否則將其視為新主影像。判斷條件如下：

$$\bar{d} = \frac{1}{N} \sum_{i=1}^N \|x_i - x'_i\| \dots \dots \dots (1)$$

其中  $\bar{d}$  為候選影像與主影像之特徵點平均位移(以像素為單位)； $N$  為有效匹配點數； $x_i$ 、 $x'_i$  分別為第  $i$  個匹配點在主影像與候選影像上的坐標位置。若  $\bar{d} < T$ ，其中  $T$  為預設閾值(如影像寬度的 5%)，則該影

像視為過度重疊，將被跳過；反之則保留，並更新為新的主影像。

圖 4 顯示使用 LightGlue 進行配對的特徵點結果。綠點為偵測特徵，綠線為有效匹配對，分布於鹽堆與倉壁區域。此結果顯示 LightGlue 可在高重疊影像間建立穩定的幾何對應。

## 2.5 控制點偵測

### 2.5.1 影像增顯

儘管主流攝影測量軟體 Agisoft Metashape 已內建自動標誌點(Marker)偵測功能，其原理主要採用基於幾何特徵匹配(Geometric Feature Matching)與灰度梯度閾值(Grayscale Gradient Thresholding)的傳統電腦視覺演算法，但在鹽倉高粉塵與光照不均的環境下，標籤常因髒汙或陰影遮蔽導致邊緣模糊，造成傳統演算法識別失敗或誤判。為此，本研究改採 YOLOv8 深度學習模型，不同於依賴硬性幾何規則的傳統方法，YOLOv8 透過卷積神經網路提取深層語義特徵，對於物件尺度變化、局部遮蔽與低信噪比影像具備極高強健性，能有效解決惡劣環境下的控制點漏判問題。

由於鹽倉內部光線微弱且分布不均，部分控制點標籤常處於陰影或低對比區域，導致後續辨識困難。為此，本研究在 YOLOv8 與 NCC 偵測前，先對原始影像套用 CLAHE (Contrast Limited Adaptive Histogram Equalization) 進行對比度增強處理 (Zuiderveld, 1994)。

實作上，本研究首先將原始影像由 RGB 色彩空間轉換至 CIE  $L^*a^*b^*$ (CIELAB)色彩空間。在此色彩模型中， $L^*$  表示亮度分量，而  $a^*$  與  $b^*$  分別代表綠-紅與藍-黃之色度分量。為避免 RGB 色彩空間中的藍色通道(Blue channel, B)與 CIELAB 色彩空間中的色度分量( $b^*$ )在符號上產生混淆，本文統一以  $L^*$ 、 $a^*$ 、 $b^*$  表示 CIELAB 各分量。

在影像增強過程中，本研究僅針對亮度分量  $L^*$  應用 CLAHE 演算法，以提升影像之局部亮度對比，同時保留原始影像之色度資訊( $a^*$  與  $b^*$  通道數值維持不變)。CLAHE 透過將影像劃分為多個局部區塊並分別進行直方圖均衡化處理，以強化低對比區域之亮度細節；同時藉由設定 clip limit 限制直方圖高度，避免對比過度增強而導致影像雜訊放大，處理完成後將強化後之  $L^*$  通道與原始  $a^*$ 、 $b^*$  通道重新合併，並將影像轉換回 BGR(Blue-Green-Red)色彩空間輸出，以符合 OpenCV 影像處理函式庫之預設格式，供後續 YOLOv8 物件偵測與 NCC 模板匹配程序使用。

透過上述影像增強流程，可顯著提升黑白控制點標籤邊緣之局部對比度，使標籤之幾何邊界更加清晰，進而提高 YOLOv8 偵測與 NCC 次像元定位之成功率。

圖 5 為 CLAHE 處理前(左)與處理後(右)之影像對照。由圖可見，處理後影像之整體亮度與局部細節皆明顯提升，特別是在控制點標籤區域(如倉壁刻度)之黑白對比邊緣更加清晰，利於後續標籤辨識與次像元定位。




圖 4 LightGlue 影像匹配示意圖。綠色點為特徵點，線段為配對結果，顯示影像間具有連續且穩定的匹配關係




圖 5 增顯影像對比，(左)CLAHE 處理；(右)CLAHE 處理後

## 2.5.2 控制點標籤區域偵測

### 2.5.2.1 YOLOv8 模型

YOLOv8(You Only Look Once)為一種即時目標偵測架構，能於單一網路中同時預測物件的邊界框與類別，相較於傳統兩階段式方法(如 R-CNN)，YOLOv8 具備推論速度快、結構簡潔的特性，特別適用於需處理大量影像的自動化場域。

本研究採用 Ultralytics 發表的 YOLOv8 架構，屬於 YOLOv8 系列最新版本，其主要特色為 anchor-free 設計、輕量化骨幹結構，以及支援多任務(偵測、分類與分割)訓練。YOLOv8 整體由四大模組構成，分別說明如下：

#### (1) Backbone(特徵提取網路)

YOLOv8 採用改良後之 CSPDarknet 結構，透過 C2f 模組(cross-stage partial fusion)取代傳統 ResBlock，有效降低參數數量並保留語義資訊。整體網路自影像輸入後依序通過多層卷積與降採樣模組，提取由淺至深的多層特徵圖，作為後續辨識依據。最末端並接上一層 SPPF 模組，用以增強多尺度上下文特徵。

#### (2) Neck(多尺度特徵融合)

Neck 結構由 FPN(Feature Pyramid Network)與 PAN(Path Aggregation Network)組成。FPN 自深層特徵圖反向傳遞語義資訊至淺層，而 PAN 則由底部補回高解析空間資訊，使融合後的特徵兼具精細定位與語意辨識能力。此結構透過上採樣、下採樣與多層 C2f 強化模組完成特徵整合。

#### (3) Head(解耦式預測模組)

YOLOv8 採用解耦式 head 結構，於三個不同解析度的特徵圖上分別執行分類與邊界框預測，涵蓋大、中、小等不同尺寸的目標偵測任務。每一輸出層預測包含位置  $[x,y,w,h]$ 、物件置信度(objectness)與各類別機率。

#### (4) 損失函數(Loss Function)

YOLOv8 所用的損失函數結合三個分項：框選誤差(CIOU + DFL 分布式回歸)、目標置信度誤差(Binary Cross Entropy)與分類誤差(BCE 或 focal loss)。最終損失為三者加權總和，並透過動態 loss 平衡自動調整三者權重，以提升收斂穩定性與偵測準確率。

YOLOv8 整體流程如圖 6 所示：輸入影像經由 backbone 模組提取深淺特徵後，透過 neck 架構進行語義與空間資訊的多尺度融合，最終由 head 模組在三層特徵圖上進行獨立預測。此設計能同時兼顧不同尺寸與特徵層級之物體，為本研究於鹽倉環境中進行控制點標籤偵測提供高效率且穩定的解決方案。

### 2.5.2.2 鹽倉資料集

為提升 YOLOv8 模型於鹽倉場域中控制點標籤之偵測準確度，本研究自建一套專屬資料集，並結合多種資料增強方法進行監督式訓練。原始影像取自懸臂吊車繞行鹽倉過程中同步拍攝所得，經 CLAHE 處理後再進行標註。最終標註資料集包含 9716 張訓練影像、2513 張驗證影像與 178 張測試影像，涵蓋 18 類標籤(每 20 為一類，數值從 0 至 340，加上字母 "N")，均依 YOLOv8 格式標示類別與相對坐標。

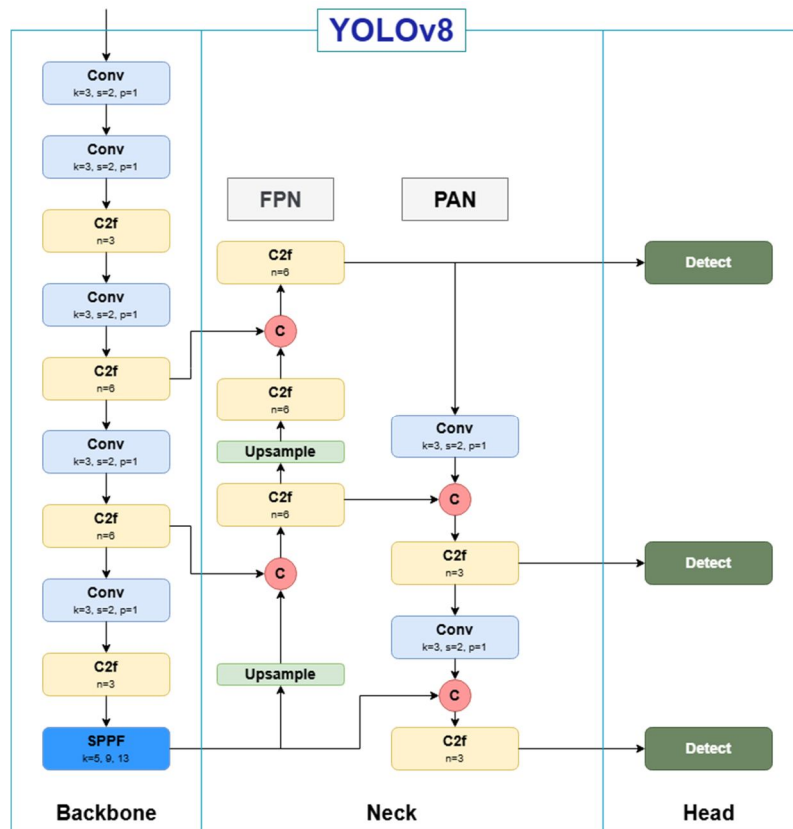


圖 6 YOLOv8 網路架構圖

為提升模型對不同光照與拍攝角度的適應性，本研究設計數種增強策略，包含：(1)影像旋轉 180°：模擬吊臂翻轉情境；(2)亮度與對比調整：強化陰暗區標籤可見性；(3)局部區域亮度校正：將候選區域亮度與模板進行匹配，調整增益與偏移值，以降低誤判；(4)同步標註修正：確保增強後標註與影像對齊。訓練過程中以 validation loss 與 mAP 為主要監控指標，並自動儲存最佳模型結果。最終模型用於鹽倉影像中標籤編號之初步定位與子影像裁切，供後續 NCC 進行亞像素級匹配。

### 2.5.2.3 子影像裁切

YOLOv8 偵測後系統會讀取每張影像的標籤預測結果，排除不合法類別(如 999)，並根據邊界框資訊裁切對應子影像作為 NCC 輸入。裁切邏輯依據框中心與大小計算左上與右下角坐標，若裁切區域超出影像邊界則自動略過。

裁切後的子影像會經灰階轉換與亮度標準化處理，調整平均值至 128、標準差至 32，以提升 NCC 對比穩定性。所有子影像依格式 {類別}\_{影像編

號}.jpg 命名，並儲存於指定資料夾供後續批次處理。

### 2.5.2.4 模型評估指標

為量化 YOLOv8 模型在控制點標籤偵測上的效能，本研究採用物件偵測領域通用之評估指標，包含精確率(Precision)、召回率(Recall)以及平均精度均值(mean Average Precision, mAP)。各指標定義如下：

- (1) 精確率 (Precision, P)：代表模型預測為正樣本的結果中，實際為正樣本的比例。計算公式如式 (2)：

$$P = \frac{TP}{TP+FP} \dots\dots\dots(2)$$

- (2) 召回率 (Recall, R)：代表在所有實際正樣本中，被模型正確預測出的比例。計算公式如式 (3)：

$$R = \frac{TP}{TP+FN} \dots\dots\dots(3)$$

其中，TP (True Positive) 為正確偵測之標籤數，FP (False Positive) 為誤判之標籤數，FN (False

Negative) 為漏判之標籤數。

(3) 平均精度均值 (mAP)：mAP 為衡量模型整體性能之綜合指標。首先計算單一類別的平均精度 (Average Precision, AP)，即 P-R 曲線 (Precision-Recall Curve) 下之面積；mAP 則為所有類別 AP 值之平均。本研究採用 mAP 0.5 (IoU 閾值設為 0.5 時的 mAP) 作為主要評估依據。

### 2.5.3 控制點精細匹配搜尋

為達成高精度控制點定位，本研究於 YOLOv8 粗略定位後導入 NCC (Normalized Cross-Correlation) 進行模板匹配，從子影像中尋找與既定標籤模板最相似的區域。NCC 為一種常用於影像對位的匹配方法，具有遮罩不敏感、尺度不變性強等特性，特別適合應用於固定格式之標籤辨識，匹配過程如下：對於子影像 I 與模板 T，於滑動視窗中計算下列 NCC 分數：

$$NCC(u, v) = \frac{\sum_{x,y} [I(x+u, y+v) - \bar{I}_{uv}] \cdot [T(x, y) - \bar{T}]}{\sqrt{\sum_{x,y} [I(x+u, y+v) - \bar{I}_{uv}]^2 \cdot \sum_{x,y} [T(x, y) - \bar{T}]^2}} \dots\dots\dots (4)$$

其中 u、v 為模板在子影像上滑動的偏移量； $\bar{I}_{uv}$  為子影像中與模板對應區域的平均值； $\bar{T}$  為模板平均值；分子為對應像素的乘積總和 (衡量相似性)；分母為各自標準差乘積 (做正規化)。

為求定位精確，NCC 目標模板設定為 51x51 像素 (奇數以定義幾何中心)，搜尋視窗則採用 YOLOv8 偵測之候選範圍。針對鹽倉內角度傾斜與照明不均等變異，本研究建構包含 76 幅不同旋轉與明暗狀態之「動態模板庫」。透過「多模板匹配 (Multi-template Matching)」策略，計算候選影像與全數模板之相似度並取最佳值，藉此克服非正射視角與局部遮蔽干擾，顯著提升坐標量測之強健性與成功率。

## 2.6 建模流程整合

為將前述自動標記成果應用於三維模型生成，本研究整合 Metashape Python API 建立一套全自動的建模流程。該流程自動導入控制點、進行相機定位與誤差篩選，最終完成模型生成與成果輸出。

### 2.6.1 剔除差錯機制

控制點標記完成後，系統將 NCC 所得之影像點坐標與實際 GCP 三維坐標進行關聯，並執行光束法平差 (Bundle Adjustment)。此程序之目的不僅在於求解相機之外方位參數 (Exterior Orientation)，亦同時進行待測物三維坐標的聯合最佳化求解。然而，受現場光影變化與局部遮蔽影響，部分 NCC 匹配結果可能偏離標籤真實中心，形成幾何上的「粗差 (Outliers)」。為避免這些錯誤觀測值汙染模型精度，本研究設計了一套基於重投影誤差 (Reprojection Error) 的自動化迭代剔除機制。

具體作法為計算每一觀測點在當前相機參數下，其「NCC 偵測位置」與「三維點反投影位置」之歐氏距離，定義為重投影誤差  $e_i$ ：

$$e_i = \|p_i^{NCC} - p_i^{proj}\| \dots\dots\dots (5)$$

其中  $e_i$  為第 i 張影像上的誤差； $p_i^{NCC}$  為第 i 張的 NCC 標定點； $p_i^{proj}$  為該控制點依目前相機模型反投影之理論位置，單位為像素。若該值大於設定容忍值，則認定該控制點於該影像上標記失敗，將其自動移除。為提升穩定性，此步驟會進行最多五輪迭代，此限制係基於實驗經驗設定：一般而言，粗差點在前三輪迭代即可有效收斂並剔除，設定五輪上限可防止系統因追求極小誤差而過度刪除有效控制點，導致幾何結構解算發散或過度擬合，從而在計算效率與模型強健性之間取得最佳平衡。

### 2.6.2 模型建立

完成 GCP 自動篩選後，系統自動觸發建模流程。操作包含：(1) 建立稀疏點雲與相機內外方位參數；(2) 建立影像深度圖；(3) 重建表面模型。建模過程中，Metashape 將自動依據輸入控制點進行空間對位與誤差最小化調整，並在地理坐標系統中輸出具備真實尺寸與方向之模型。整體建模流程可於全自動條件下完成，省去人工標記與調整流程，同時具備 GCP 精度管控與幾何穩定性，為鹽倉內部環境提供一套高效率、可重複的數位建模方案。

### 3. 實驗成果

#### 3.1 影像過濾成效分析

受限於現場硬體設備之觸發機制，相機拍攝作業僅能採用「固定時間頻率」連續擷取，無法配合吊車移動速度進行等距觸發。此限制導致原始影像序列在相鄰畫格間存在極高之重疊率，若全數投入運算將造成空三平差資源浪費與計算效率低落。因此，本研究提出一套基於特徵匹配之關鍵畫格 (Keyframe) 篩選機制。

本機制引入 LightGlue 深度學習特徵匹配技術，透過計算連續兩張影像間之特徵點平均像素位移量，作為判斷視角變化之依據。篩選邏輯設定為：當影像間之特徵位移過小 (即換算重疊率高於 95% 之過濾門檻) 時，系統視其為冗餘資料予以剔除；僅當位移量超過門檻，顯示視角已有顯著改變，方保留該影像作為新的基準畫格。

同時，為驗證深度學習模型在鹽倉惡劣環境下之優勢，本節將以傳統 SURF (Speeded Up Robust Features) 演算法作為對照分析之基準 (Baseline)。SURF 具備尺度與旋轉不變性，為廣泛應用之特徵偵測器。本研究將統計並比較 LightGlue 與 SURF 在不同重疊率條件下之匹配點對數量與篩選效能，詳細數據分析如表 1、表 2 所示。表中之『平均相對旋轉角』係指保留之相鄰影像間的拍攝視角變化量。其計算方式為：利用特徵匹配所得之連結點 (Tie Points)，解算相鄰兩張影像間的旋轉量與平移量，進而推算出相機姿態的旋轉角度變化。

LightGlue 保留影像張數顯著高於 SURF，同一

組影像中其通過率大多落在 90%~99%，顯示出匹配範圍與容錯性明顯較高。752 相機在 2023/10/12 的資料中，原始 1356 張影像中有 1340 張保留，平均方位角僅 0.18 度一張，顯示大多數連續影像皆通過 LightGlue 的匹配條件。相較之下，SURF 僅保留 105 張，平均間隔為 3.43 度，說明其匹配較為保守。

758 相機在多組資料中保留張數略低，推測與拍攝視角偏離倉儲中心、部分區域特徵不足有關，例如 2023/10/26 的影像中僅保留 1327 張 (占原始 3520 張的 37.7%)，但其平均方位角為 2.55 度，仍遠低於 SURF 的 6.92 度，匹配結果較為連續穩定。

LightGlue 在 2023/12/20 與 2024/01/10 的拍攝資料中也顯示出穩定性，在 758 相機中平均每張角度落在 1.83 至 1.84 度之間，未見明顯跳動，752 相機則保持在 0.6 至 1.88 度。整體而言 LightGlue 可維持高密度的影像匹配，有助於三維重建時獲得更完整且連續的模型輸入。

在 2023/10/26 的資料中影像保留率相對偏低，經檢視該批影像後發現，部分影像之拍攝視角偏離倉儲中心，且部分區域受鹽塵與光照不均，造成可辨識之穩定特徵點數量不足，LightGlue 在進行特徵匹配時會依據匹配品質與幾何一致性進行篩選，因此當影像之特徵匹配品質較低或視角差異過大時，系統會自動將該類影像排除。儘管該資料組之通過率較低但保留下來的影像仍維持良好的連續性，其平均相對旋轉角為 2.55°，顯示經篩選後的影像仍可提供穩定的幾何關係，對後續三維重建流程並未造成明顯影響。

表 1 SURF 過濾影像成效統計

日期	相機代號	原始影像拍攝張數	過濾後影像張數	平均相對旋轉角 (°)
2023/10/12	752	1356	105	3.43
	758	1361	50	7.20
2023/10/26	752	3521	132	2.73
	758	3520	52	6.92
2023/12/20	752	589	146	2.47
	758	1811	56	6.43
2024/01/10	752	472	107	3.36
	758	1470	66	5.45

表 2 LightGlue 過濾影像成效統計

日期	相機代號	原始影像拍攝張數	過濾後影像張數	平均相對旋轉角 (°)
2023/10/12	752	1356	1340	0.18
	758	1361	1218	2.23
2023/10/26	752	3521	1332	0.42
	758	3520	1327	2.55
2023/12/20	752	589	513	0.14
	758	1811	1518	2.12
2024/01/10	752	472	454	1.52
	758	1470	1397	1.84

### 3.2 控制點標記準確度分析

#### 3.2.1 YOLOv8 偵測成果

##### 3.2.1.1 模型精度評估

本研究首先評估 YOLOv8 模型在測試資料集上的基礎指標表現，透過 F1-Confidence 曲線、Precision-Recall 曲線及正規化混淆矩陣進行綜合分析。




圖 7 YOLOv8 模型各類別控制點之 F1 分數與信心閾值(Confidence Threshold)關係圖，藍色曲線為全類別平均結果

F1-Confidence Curve 呈現 YOLOv8 模型於不同信心閾值下之分類效能變化，橫軸為信心閾值，縱軸為對應之 F1 分數。可觀察到各類控制點之 F1 分數大多於 0.75 至 0.80 閾值區間達最高，代表模型在分類任務中具有良好之精準率與召回率平衡。整體而言，於信心閾值設為 0.778 時可達平均 F1 分數 0.99，提供實務部署時之參考門檻依據。

Precision-Recall Curve 比較各類控制點在不同分類閾值下之精確率(Precision)與召回率(Recall)表現。本研究之模型於所有控制點標籤的分類結果，

其中對角線方格為正確分類率，非對角線區塊則代表誤分類比例。整體分布顯示模型分類準確性高，且誤判大多發生於相鄰編號之間，如標籤 20 與 40、320 與 340。此結果顯示模型在實際應用中能精準辨識標籤類別，且具良好容錯能力。




圖 8 YOLOv8 模型各類控制點之 Precision-Recall 曲線，藍色粗線為 macro average，對應 mAP 0.5 值為 0.993

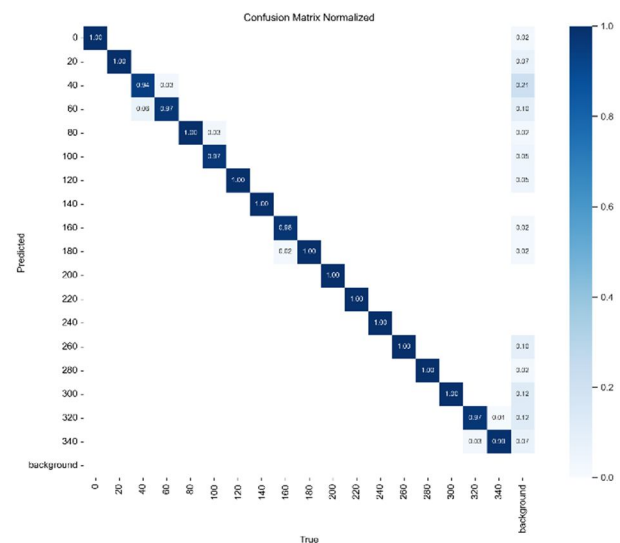


圖 9 YOLOv8 模型於測試資料集之分類結果所生成之正規化混淆矩陣(Normalized Confusion Matrix)

Normalized Confusion Matrix 顯示 YOLOv8 模型於所有控制點標籤的分類結果，其中對角線方格為正確分類率，非對角線區塊則代表誤分類比例。整體分布顯示模型分類準確性高，且誤判大多發生於相鄰編號之間，如標籤 20 與 40、320 與 340。此結果顯示模型在實際應用中能精準辨識標籤類別，且具良好容錯能力。

綜合上述分析，本研究所訓練之 YOLOv8 模型於建立之客製化 GCP 標籤資料集中展現出極高的分類準確性與穩定性。其於多數類別皆可達成 F1 分數 0.99、精確率與召回率皆接近 1.0，且整體 mAP0.5 為 0.993，顯示該模型具備高度實用性。即便在倉內光照不均與影像重疊度高等惡劣條件下，模型仍能有效分辨各類控制點標籤，並提供可靠之粗略定位資訊，作為後續 NCC 精配處理之依據。此結果驗證本研究所訓練之 YOLOv8 模型適用於鹽倉特殊環境中之自動化標記任務。

### 3.2.1.2 偵測成果展示

為提升影像中控制點標籤的自動辨識效率與

準確性，本研究採用 YOLOv8 作為目標偵測架構，負責從 CLAHE 增強後的影像中標註 GCP 位置與類別。YOLOv8 模型輸出之每筆預測包含標籤編號、邊界框坐標與信心水準(Confidence score)，其中數值代表模型對該偵測結果之預測信心。例如「120 0.9」即表示 YOLOv8 判定該區域為標籤編號 120 的機率為 90%。透過模型訓練與最佳化，本研究期望能實現高準確率、低誤判率的標籤初步自動化偵測。圖 10 與圖 11 分別對應於標籤代號為 120 與 100，以及 80 與 60 的影像片段，呈現模型在不同倉壁位置與光照條件下的辨識穩定性與準確性。

綜合圖 10 與圖 11 所示結果可得，YOLOv8 模型於本研究所建構之鹽倉場域資料集中展現出良好之偵測穩定性與準確性。無論控制點標籤位於高亮、背光、或鹽堆遮蔽區域，模型皆能準確辨識，且於多標籤同框情境下亦未出現明顯誤判。此結果反映本研究在影像前處理、資料增廣與模型訓練策略之有效性，亦驗證 YOLOv8 架構適用於大型室內場域控制點偵測任務之可行性與實用價值。



圖 10 YOLOv8 偵測結果展示(一)：標記 120 與 100 的偵測情形



圖 11 YOLOv8 偵測結果展示(二)：標記 80 與 60 的偵測情形

### 3.2.2 NCC 偵測成果

NCC(Normalized Cross-Correlation)為本研究用於標籤精定位的演算法，負責從 YOLOv8 粗略預測的區域中，以模板匹配方式找出次像元的精準對應點。圖 12 顯示部分 NCC 偵測成果，其中上半為配對準確之範例，下半為配對錯誤之案例。圖中紅點代表 NCC 偵測到的最佳對應位置。

上半部為配對正確範例，紅點位置與標籤中心對齊；下半部為配對錯誤範例，紅點明顯偏離標籤。由圖 12 可見在控制點標籤對比明顯、背景紋理不干擾的情況下，NCC 可穩定輸出接近標籤中心的結果，顯示其對於局部區域紋理變化具有良好適應性。然而，當影像遭受嚴重遮蔽、模糊或標籤油漆脫落時，NCC 可能錯判高紋理區為最佳位置，導致誤差。觀察錯誤案例可發現，其中數張存在光斑、標籤傾斜或數字變形現象，為造成配對偏移的主因。因此雖 NCC 在大多數情況下可精準定位，但仍須透過後續判別條件(如匹配信度、位置穩定性)加以篩選以確保成果品質。

### 3.2.3 YOLOv8 辨識與 NCC 匹配精確度分析

為評估 YOLOv8 與 NCC 於控制點標記任務中的實際辨識表現，本研究統計各標籤類別在測試資料集中之總數量、YOLOv8 預測結果與 NCC 精配成果，並計算各自之錯誤率(誤標或錯配比例)。YOLOv8 的任務為從原始全景影像中快速偵測出候選標籤區域，NCC 則進一步於此區域內尋找次像元的最適對應位置。

由表 3 中可見，在 401 筆控制點樣本中，YOLOv8 共成功預測 393 筆，僅有 8 筆錯漏，整體辨識錯誤率為 2%，展現出良好的初始定位能力。進一步由 NCC 進行精配處理後，總誤配件數為 9 筆，整體錯誤率亦為 2%。觀察錯配樣本可發現，錯誤多集中於標籤代碼為 180、220 與 300 等少數類別，推測其因影像模糊、遮蔽、或標籤書寫模糊所致。

在多數標籤類別中，NCC 成功率近乎 100%，顯示其對於標籤樣式穩定的類別具有高度穩定性。

反觀錯配類別，多為數量較少、或影像中位處邊緣之樣本，易受光影干擾影響匹配品質。整體而言，本研究設計之 YOLOv8 + NCC 二階段辨識架構，在維持自動化速度優勢的同時，也能有效兼顧標定精度，顯示其於鹽倉場域控制點定位應用中具有良好潛力。

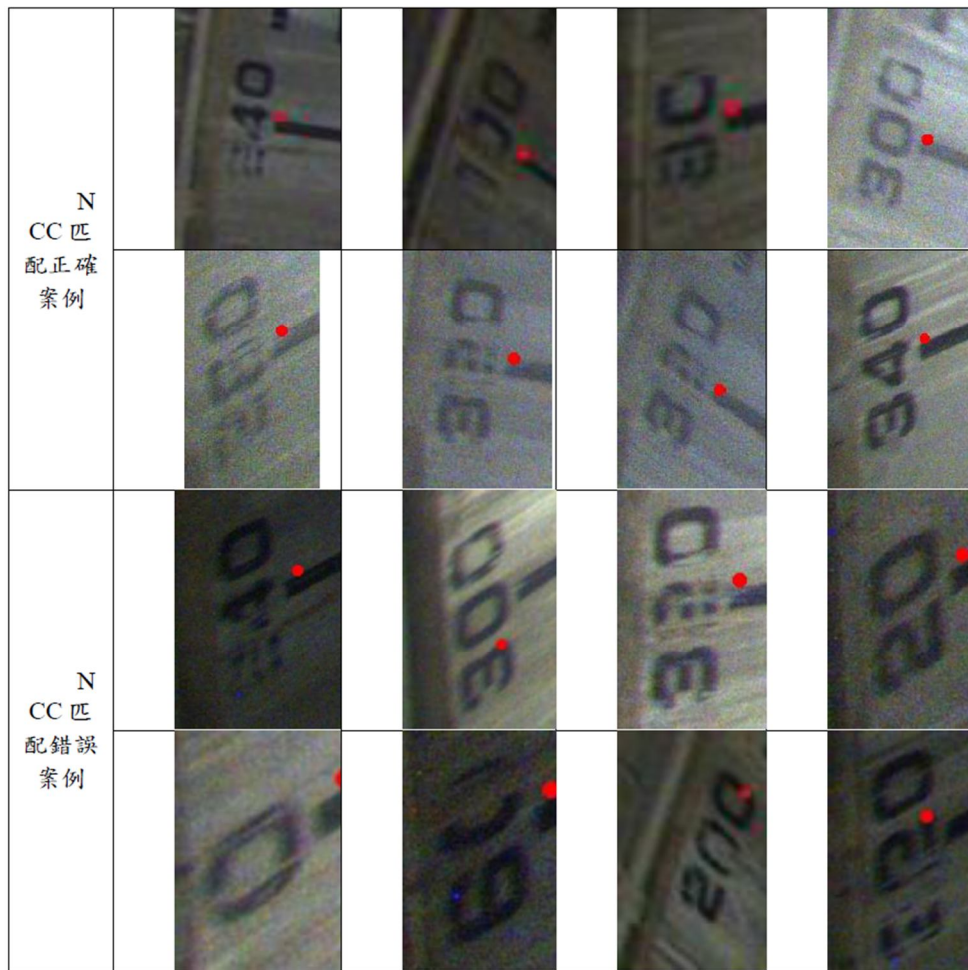


圖 12 NCC 正確與錯誤匹配案例

表 3 YOLOv8 與 NCC 於測試集上的辨識準確度統計表

標籤代號	總標籤數 (張)	YOLOv8 偵測失敗數 (張)	誤差 (%)	NCC 匹配失敗數 (張)	誤差 (%)
0	45	0	0%	1	2%
20	36	0	0%	2	6%
40	23	0	0%	0	0%
60	21	0	0%	0	0%
80	20	0	0%	0	0%
100	16	0	0%	0	0%
120	20	2	10%	0	0%
140	19	2	10%	0	0%
160	28	0	0%	0	0%
180	20	6	30%	0	0%
220	20	0	0%	3	15%
240	22	0	0%	0	0%
260	27	0	0%	0	0%
300	41	0	0%	3	7%
340	43	0	0%	0	0%
合計	401	8	2%	9	2%

### 3.3 三維建模成果與品質分析

#### 3.3.1 稀疏點雲篩選與優化策略

本研究將經 LightGlue 篩選之影像導入空三平差運算後，針對稀疏點雲(Sparse Cloud)執行了嚴格的品質檢核。在幾何結構方面，系統僅保留由大交會角構成且具備「多視角冗餘 (Multi-view Redundancy)」之特徵點，確保每一連結點至少獲得 2 張以上影像的幾何約束，有效排除單一視角誤判風險。在定位精度方面，經迭代優化後，最終留存之連結點其重投影誤差(Reprojection Error)均收斂至 0.5 像素以內。此結果證實，絕大多數三維點位經反投影回二維影像後，與原始觀測點的偏差皆小於半個像素，顯示本研究流程在惡劣環境下仍能維持次像素等級(Sub-pixel level)的高精確度匹配品質。

#### 3.3.2 建模成果

本研究透過自動控制點標記流程與高重疊率影像篩選策略，成功建立鹽倉內部完整的三維模型。圖 13 顯示模型重建後的頂視視角，可觀察倉內鹽堆形貌、堆積區及倉壁細節皆有良好重現，整體而言本研究建構之三維模型不僅具備高度完整性與細節保留，亦成功反映鹽倉內部複雜之地形變化與結構特徵，為後續進行體積估算與時間序列變化分析提供穩定基礎。

然而圖 13 中左下方區域(約 160N 至 280N 之間)出現部分控制點缺失之情形，經檢視原始影像與現場狀況，主因為該區域之牆面標籤受鹽份腐蝕嚴重，導致漆面剝落與特徵損毀 YOLOv8 無法正確框選完整標籤，且 NCC 模板匹配亦因相關係數低於閾值而判定失敗，為避免將錯誤定位的控制點強制納入計算而拉扯模型幾何，自動剔除此區域之低信賴度控制點。儘管該區缺乏控制點約束，但受惠於周圍高重疊率影像之連結點牽制，整體模型之相對精度仍維持在容許範圍內。




圖 13 2024/01/10 三維模型成果(頂視)

### 3.3.3 體積估算精度驗證

為驗證建模精度，本研究以採集之地面光達 (TLS) 點雲數據為基準真值。透過將光達產製之數值地表模型 (DSM) 與本研究攝影測量 DSM 進行差分運算，計算兩者在相同圓形場域內的體積差異，其高程差異分佈情形如圖 14 所示。由圖中可見，兩者模型在絕大部分區域之高程差極小，顯示空間分佈具備高度一致性。進一步計算兩者在相同圓形測試範圍內之體積差異，結果顯示光達基準體積為  $58,056.9 \text{ m}^3$ ，本研究計算之體積為  $58,960.3 \text{ m}^3$ ，兩者差異量為  $903.4 \text{ m}^3$ ，換算相對誤差僅 1.56%，證實本研究提出之自動化建模流程已具備實務應用所需之高準確度。




圖 14 2024/01/10 攝影測量與地面光達 DSM 相減之假色圖

## 4. 結論

本研究針對高粉塵、低光源與封閉空間等惡劣環境條件下之大型鹽倉場域，建立了一套結合深度學習與攝影測量的自動化三維建模流程。整體流程涵蓋影像前處理、控制點標記、影像過濾與模型生成四大模組。在影像篩選方面，實測顯示引入 LightGlue 機制後，可保留 90% 以上之有效影像，且相鄰影像之平均方位角間隔介於  $0.14^\circ$  至  $2.6^\circ$  之間，顯著優於傳統 SURF 方法，有效提升了 SfM

解算之幾何穩定性。在控制點識別方面，透過整合 CLAHE 影像增顯、YOLOv8 標籤偵測與 NCC 次元匹配技術，系統在測試資料中展現了 98% 的高匹配準確率，成功克服了現場標籤汙損與光照不足的挑戰。

在三維重建成果方面，本研究成功重現了鹽倉內部之倉壁標籤分佈、鹽堆堆積形狀與輸送帶結構。針對部分區域出現之點雲浮空或重影 (Ghosting) 現象，主要歸因於吊車視角單一與現場照度不足所造成之特徵匹配模糊。為進一步提升模型完整性，建議未來在硬體設備上可進行以下改進：(1) 改良取像載台：增設多角度鏡頭模組或使用可旋轉雲台 (Gimbal)，以獲取更完整的側向紋理，減少視線死角；(2) 優化照明系統：加裝與快門同步之高流明主動式補光燈 (Strobe Light)，以降低陰影干擾並提升特徵點清晰度。

在體積估算精度驗證上，以地面光達 (TLS) 數據為基準真值進行比對，本研究方法之體積計算誤差僅為 1.56% (約  $903.4 \text{ m}^3$ )。相較於傳統作業模式——即依賴全站儀進行稀疏佈點測量，或僅憑經驗進行目視估算，傳統方法常因取樣點不足或人為判斷導致體積估算誤差波動極大 (通常大於 5% 甚至更高)。本研究提出之自動化流程不僅將誤差控制在極低範圍內，且具備全場域覆蓋之特性，證實其足以取代高風險的人工測量作業，滿足工業倉儲盤點對高精度與高效率之實務需求。

綜上所述，本研究建構之自動化建模流程已證實可穩定應用於高遮蔽、高粉塵與照度不均之大型鹽倉。未來可進一步整合點雲語意分割與變異檢測技術，推進模型應用於構件辨識、結構監測等多元場景，最大化三維空間資訊於實務操作中之價值。

## 參考文獻

- DeTone, D., Malisiewicz, T., and Rabinovich, A., 2018. SuperPoint: Self-supervised interest point detection and description, in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Salt

- Lake City, USA, pp. 224–236, DOI: 10.1109/CVPRW.2018.00060.
- Heo, Y.S., Lee, K.M., and Lee, S.U., 2010. Robust stereo matching using adaptive normalized cross-correlation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(4), pp. 807–822, DOI: 10.1109/TPAMI.2010.136.
- Jocher, G., Chaurasia, A., and Qiu, J., 2023. Ultralytics YOLOv8, Available at: <https://github.com/ultralytics/ultralytics>, Accessed 20 May 2024.
- Kraus, K., 2007. *Photogrammetry- Geometry from Images and Laser Scans*, 2nd edition, Walter de Gruyter: Berlin, Germany, pp. 78–120.
- Lindenberg, P., Sarlin, P.-E., and Pollefeys, M., 2023. LightGlue: Local Feature Matching at Light Speed, in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, Paris, France, pp. 17627–17638, DOI: 10.1109/ICCV51070.2023.01616.
- Lowe, D.G., 2004. Distinctive image features from scale-invariant keypoints, *International Journal of Computer Vision*, 60(2): 91–110, DOI: 10.1023/B:VISI.0000029664.99615.94.
- Naufal, C., Solano-Correa, Y.T., and Marrugo, A.G., 2024. YOLO-based multi-scale ground control point detection in UAV surveying, in *Proceedings of the IEEE Colombian Caribbean Conference (C3)*, Barranquilla, Colombia, DOI: 10.1109/C358072.2023.10436290.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., 2016. You only look once: Unified, real-time object detection, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, USA, pp. 779–788, DOI: 10.1109/CVPR.2016.91.
- Westoby, M.J., Brasington, J., Glasser, N.F., Hambrey, M.J., and Reynolds, J.M., 2012. Structure-from-Motion photogrammetry: A low-cost, effective tool for geoscience applications, *Geomorphology*, 179: 300–314, DOI: 10.1016/j.geomorph.2012.08.021.
- Zhang, H., Wang, X., and Li, Y., 2017. A map-based normalized cross correlation algorithm using dynamic template for vision-guided telerobot, *International Journal of Distributed Sensor Networks*, 13(9): 1687814017728839, DOI: 10.1177/1687814017728839.
- Zhao, Q., Yan, R., and Xia, L., 2024. Research on edge shape template matching algorithm based on machine vision, in *Proceedings of the 17th International Conference on Digital Image Processing (ICDIP 2025)*, Haikou, China, SPIE, Vol. 13709, DOI: 10.1117/12.3073033.
- Zuiderveld, K., 1994. Contrast limited adaptive histogram equalization. In: Heckbert, P.S. (Ed.), *Graphics gems IV*, Academic Press Professional, Inc., San Diego, CA, USA, pp. 474–485.

# Applying YOLOv8 and NCC to Assist GCP Measurement for 3D Modeling of Salt Warehouses

Lu-Chih Chen <sup>1\*</sup>      Jiann-Yeou Rau <sup>2</sup>      Ching-Jung Hung <sup>3</sup>

## Abstract

This study proposes an automated 3D modeling workflow for large cylindrical salt warehouses by integrating photogrammetry and deep learning techniques, aiming to improve modeling efficiency and measurement accuracy under harsh environmental conditions. Two industrial cameras are mounted on a central overhead crane to capture high-overlap images, which are enhanced using Contrast Limited Adaptive Histogram Equalization. Ground control point targets are detected using YOLOv8, followed by subpixel localization through Normalized Cross-Correlation. To improve the quality of aerial triangulation, LightGlue is employed for feature matching and redundant image filtering. A Metashape Python script is then used to automate bundle adjustment, error evaluation, and dense point cloud generation. Experiments conducted with 401 GCP samples show that the positioning error is approximately 2%, demonstrating the stability and accuracy of the proposed approach. The results indicate that the method effectively reduces the need for manual field measurements and improves the efficiency of salt pile volume estimation.

**Keywords:** Photogrammetry, Normalized Cross-Correlation, Deep Learning, 3D Modeling

---

<sup>1</sup> Master, Department of Geomatics, National Cheng Kung University

<sup>2</sup> Professor, Department of Geomatics, National Cheng Kung University

<sup>3</sup> General Manager, Chien Kun Surveying & Mapping Technology Co., Ltd.

\* Corresponding Author, E-mail: p66131082@gs.ncku.edu.tw

Received Date: Jul. 15, 2025

Revised Date: Jan. 21, 2026

Accepted Date: Mar. 23, 2026

## 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](mailto: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<sup>1,2,...</sup>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](mailto: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 <sup>1, 2, ...</sup>.
7. Abstract: The abstract should be shorter than 250 words and typed using font size of 10pt..
8. Keywords: Keywords (no more than 5 words) should be given and placed below the abstract (using font size of 12pt, Bold).
9. Sections and Sub-sections: Section heading (using font size of 18pt, Bold) should be centered and numbered in 1, 2... etc. Sub-sections (using font size of 14pt, Bold) are justified to the left in 1.1, 1.2, 1.1.1, 1.1.2...etc.
10. Paper length: Published papers are limited to 22 pages.
11. Equations: Type formulae and equations clearly in black and numbered in curved brackets. All symbols in equations should be clearly defined when they firstly appear in the manuscripts.
12. Figures and Tables: Figures and tables are numbered and described in short. When papers are accepted, original figures, tables, and photographs are expected for reproduction. Color figures and tables are acceptable in digital version, but they will be printed in gray levels in hard copies.
13. References: Only works cited in the text will be included. References should be cited in the text by giving the last name of the author(s) and the year of publication of the reference, such as Yang and Su (2014) or (Yang and Su, 2014). With three or more names use the form “Yang *et al.* (2016) or (Yang *et al.*, 2016)” in the text. When two or more references have the same text identification, please distinguish them by appending “a”, “b”, etc., to the year of publication. References should include the complete title(s), the number of the volume and the page(s) of the information cited. References should be listed in alphabetical order, according to the last name of the first author, at the end of the paper.

**Volume 31 No. 2**

**J u n e 2 0 2 6**

# **Journal of Photogrammetry and Remote Sensing**

## **CONTENTS**

### **Regular Papers**

- Using Remote Sensing to Investigate the Impact of Photovoltaic Panels on Surface Temperature – A Case Study of Tainan City  
(Wei-Jyun Chen, Su-Fen Wan) ..... **63**
- A Quality-Information-Oriented Framework for Measurement in Photogrammetric Point Cloud  
(Jhih-Syuan Jhuang, Jen-Jer Jaw)..... **79**
- Automatic Detection of Asphalt Pavement Cracks Using Unmanned Aerial Vehicles and Deep Learning  
(Kai-Ming Liu, Szu-Pyng Kao, Feng-Liang Wang, Jhih-Sian Lin) ..... **103**
- Applying YOLOv8 and NCC to Assist GCP Measurement for 3D Modeling of Salt Warehouses  
(Lu-Chih Chen, Jiann-Yeou Rau, Ching-Jung Hung) ..... **119**

# 航測及遙測學刊

## 目錄

### 學術論著

- 運用遙測技術探討光電板對於地表溫度的影響：以臺南地區為例  
(陳瑋竣、王素芬) ..... 63
- 品質資訊導向的光學點雲測繪框架  
(莊芷瑄、趙鍵哲) ..... 79
- 整合無人機與深度學習之瀝青鋪面裂縫自動檢測研究  
(劉鎧銘、高書屏、王豐良、林志憲) ..... 103
- 應用 YOLOv8 與 NCC 協助鹽倉影像三維建模之控制點坐標量測  
(陳律志、饒見有、洪慶忠) ..... 119