

114-009-7D78
MOTC-IOT-113-H2CB001a

港區影像智慧辨識技術之研究(2/3)- 空間資料環境分析及優化影像檢監 測應用技術



交通部運輸研究所

中華民國 114 年 3 月

114-009-7D78

MOTC-IOT-113-H2CB001a

港區影像智慧辨識技術之研究(2/3)- 空間資料環境分析及優化影像檢監 測應用技術

著者：韓仁毓、洪維屏、李俊穎、蔡立宏、吳日騰、林之謙、甘翊萱、林育銓、王海威、江冠均、郭羽綸、馬如龍

交通部運輸研究所

中華民國 114 年 3 月

GPN : 1011400216

定價 300 元

港區影像智慧辨識技術之研究. (2/3)：空間資料
環境分析及優化影像檢監測應用技術/韓仁毓，
洪維屏，李俊穎，蔡立宏，吳日騰，林之謙，甘
翊萱，林育銓，王海威，江冠均，郭羽綸，馬如
龍著. -- 初版. -- 臺北市：交通部運輸研究所，
民 114.03

面；公分

ISBN 978-986-531-650-1(平裝)

1.CST: 港埠工程 2.CST: 環境監測 3.CST:
影像分析

443.2

114001736

港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及
優化影像檢監測應用技術

著 者：韓仁毓、洪維屏、李俊穎、蔡立宏、吳日騰、林之謙、甘翊萱、
林育銓、王海威、江冠均、郭羽綸、馬如龍

出版機關：交通部運輸研究所

地 址：105004 臺北市松山區敦化北路 240 號

網 址：www.iot.gov.tw (中文版>數位典藏>本所出版品)

電 話：(04)2658-7200

出版年月：中華民國 114 年 3 月

印 刷 者：綠凌興業社

版(刷)次冊數：初版一刷 50 冊

本書同時登載於交通部運輸研究所網站

定 價：300 元

展 售 處：

交通部運輸研究所運輸科技及資訊組•電話：(02)2349-6789

國家書店松江門市：10485 臺北市中山區松江路 209 號•電話(02)2518-0207

五南文化廣場：400002 臺中市區中山路 6 號•電話：(04)2226-0330

GPN：1011400216 ISBN：978-986-531-650-1 (平裝)

著作財產權人：中華民國(代表機關：交通部運輸研究所)

本著作保留所有權利，欲利用本著作全部或部份內容者，須徵求交通部運輸
研究所書面授權。

交通部運輸研究所合作研究計畫出版品摘要表

出版品名稱：港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及優化影像檢監測應用技術			
國際標準書號（或叢刊號） ISBN 978-986-531-650-1(平裝)	政府出版品統一編號 1011400216	運輸研究所出版品編號 114-009-7D78	計畫編號 MOTC-IOT-113-H2CB001a
本所主辦單位：交通部運輸研究所運輸技術研究中心 主管：蔡立宏 計畫主持人：李俊穎 研究人員：洪維屏 聯絡電話：04-26587193 傳真號碼：04-26560661	合作研究單位：國立臺灣大學 計畫主持人：韓仁毓 協同主持人：林之謙、吳日騰 研究人員：甘翊萱、林育銓、王海威、江冠均、郭羽綸、馬如龍 地址：臺北市羅斯福路四段一號 聯絡電話：02-3366-4347		研究期間 自 113 年 3 月 至 113 年 12 月
關鍵詞：空中無人載具、地面無人載具、影像技術、設施巡檢、CCTV			
摘要： 本計畫探討無人載具與感測器於港區環境中的整合與應用，包括空間資料建構、感測資料自動化辨識及即時影像串流技術。運用 FNN 神經網路技術預測港區風速，並利用傾斜攝影技術補足高空影像不足，展示硬體系統於不同條件下的應用效能。 在自動化辨識方面，研究結果顯示影像一致性對岸邊設施與變電箱的檢測準確度有關鍵影響，透過穩定拍攝規範與 YOLOv8 模型，準確度分別達九成與 93%。路面坑洞檢測則透過混合臺中港與臺北港數據及遷移學習，達到 82.1% IoU，但仍有部分誤判需改善。胸牆法線與錯位檢測結合 YOLOv8 與霍夫直線技術，有效檢測胸牆異常，未來將優化影像拍攝與數據量。伸縮縫檢測預測準確率為 85%，但地理定位精度仍需提升，計畫透過正射影像與人工解讀結合進一步優化；碼頭裂縫檢測顯示模型對裂縫與伸縮縫分辨力高，但誤判需透過擴充數據集改善。 此外，研究整合 CCTV 與 AI 補強無人機視角，並發展 LOD2 模型的港區光電潛力評估系統。地面無人載具導航系統透過改良避障技術，顯著增強定位與導航精度。本計畫研究成果為港口管理與監控提供技術支援，並促進港區智慧化建設。 本研究成果可進一步應用於其他港區，例如透過遷移學習技術，優化檢測模型以適應不同港區環境，提升監測系統的適用性。同時，未來可運用數位孿生技術整合多源感測數據，強化即時監測與預警能力，並結合 5G 與邊緣運算技術，提高影像分析與遠端操作的效率。			
出版日期	頁數	定價	本出版品取得方式
114 年 3 月	296	300	凡屬機密性出版品均不對外公開。普通性出版品，公營、公益機關團體及學校可函洽本所免費贈閱；私人及私營機關團體可按定價價購。
備註：本研究之結論與建議不代表交通部之意見。			

PUBLICATION ABSTRACTS OF RESEARCH PROJECTS
INSTITUTE OF TRANSPORTATION
MINISTRY OF TRANSPORTATION AND COMMUNICATIONS

TITLE: The Research on Port Area Image Intelligent Recognition Technology (2/3)-Environmental Analysis of Spatial Data and Optimisation of Imaging Surveillance Applications .			
ISBN (OR ISSN) 978-986-531-650-1 (pbk)	GOVERNMENT PUBLICATIONS NUMBER 1011400216	IOT SERIAL NUMBER 114-009-7D78	PROJECT NUMBER MOTC-IOT-113-H2CB001a
DIVISION: Center of Harbor & Marine Technology DIVISION DIRECTOR: Li-Hung Tsai PRINCIPAL INVESTIGATOR: Chun-Ying Lee PROJECT STAFF: Wei-Ping Hung PHONE: 886-4-26587126 FAX: 886-4-26560661			PROJECT PERIOD FROM Mar. 2024 TO Dec. 2024
RESEARCH AGENCY: National Taiwan University PRINCIPAL INVESTIGATOR: Jen-Yu Han Co-PRINCIPAL INVESTIGATOR: Jacob Je-Chian Lin, Rih-Teng Wu , Chun-Jia Huang PROJECT STAFF: Yi-Hsuan Kan, Yu-Chun Lin, Hai-Wei Wang ADDRESS: No. 1, Sec. 4, Roosevelt Rd., Taipei City PHONE: 886-2-3366-4347			
KEY WORDS: UAV, UGV, Imaging Technology, Facility Inspection, CCTV			
ABSTRACT : <p>This study investigates the integration and application of unmanned vehicles and sensors in the harbour environment, including spatial data construction, automatic recognition of sensory data and real-time image streaming. The FNN neural network technique is used to predict the wind speed in the harbour area, and the oblique photography technique is used to compensate for the lack of high altitude images, demonstrating the performance of the hardware system under different conditions.</p> <p>In the area of automatic identification, the study shows that image consistency has a critical impact on the accuracy of the detection of shoreline facilities and substations, with an accuracy of 90% and 93% through the steady state photography paradigm and the YOLOv8 model, respectively. The pothole inspection reached 82.1% IoU by mixing data from Taichung and Taipei ports and migration learning, but there are still some misjudgments that need to be improved. Chest wall normal and misalignment detection combines YOLOv8 and Hofstraight technology to effectively detect chest wall anomalies, and will optimise image capture and data volume in the future. The accuracy of shrinkage joint detection is 85%, but the geo-location accuracy still needs to be improved, and it is planned to further optimise it by combining orthophotography and manual interpretation. The crack detection of the quay shows that the model has a high discriminatory power between cracks and shrinkage joints, but the misjudgement needs to be improved by expanding the dataset.</p> <p>In addition, the study integrates CCTV and AI to enhance the view angle of the drone, and develops a photovoltaic potential assessment system for the harbour area using the LOD2 model. The ground-based unmanned vehicle navigation system significantly enhances positioning and navigation accuracy through improved obstacle avoidance techniques. The results of this research provide technical support for port management and monitoring, and promote the intelligent construction of the port area.</p> <p>The results of this research can be further applied to other port areas, for example, through the use of migratory learning technology to optimize the detection model to adapt to the environment of different port areas and enhance the applicability of the monitoring system. Meanwhile, in the future, the integration of multi-source sensing data by digital twinning technology can be used to enhance real-time monitoring and early warning capability, and the efficiency of image analysis and remote operation can be improved by combining 5G and edge computing technology.</p>			
DATE OF PUBLICATION March,2025	NUMBER OF PAGES 296	PRICE 300	
The views expressed in this publication are not necessarily those of the Ministry of Transportation and Communications.			

港區影像智慧辨識技術之研究(2/3)-空間資料環境分析 及優化影像檢監測應用技術

目錄

中文摘要.....	I
英文摘要.....	II
目錄.....	III
圖目錄.....	XI
表目錄.....	XXI
第一章、前言	1-1
1.1 研究動機與目的	1-1
1.1.1 研究動機	1-1
1.1.2 研究目的	1-1
1.2 文獻回顧	1-2
1.2.1 傳統巡檢	1-2
1.2.2 無人載具發展與應用(空中、地面、水下).....	1-3
1.2.3 影像技術發展與應用難度	1-4
1.3 歷年計畫成果回顧	1-4
1.3.1 臺中港(110~111 年)	1-6
1.3.2 臺北港(112 年).....	1-7
1.3.3 臺北港(113 年).....	1-8
第二章、無人載具以及感測器硬體系統分析	2-1
2.1 空中無人載具	2-1
2.1.1 載具類型分析	2-1
2.1.2 飛行里程	2-3

2.1.3 感測器分析	2-7
2.2 地面無人載具	2-9
2.2.1 載具類型分析	2-9
2.2.2 行走里程	2-10
2.2.3 感測器分析	2-11
2.3 水下無人載具	2-17
2.3.1 載具類型分析	2-17
2.3.2 航行里程	2-18
2.3.3 感測器分析	2-19
2.4 本章小結	2-20
第三章、港區高細緻空間基礎資料建構	3-1
3.1 地形資料蒐集	3-1
3.1.1 控制點測量	3-1
3.1.2 影像資料蒐集	3-2
3.1.3 數值地形模型成果	3-3
3.1.4 正射影像成果	3-5
3.2 氣象資料蒐集	3-6
3.2.1 空中無人載具抗風與防水條件定義	3-6
3.2.2 港區風速評估	3-7
3.3 空中載具適宜性評估	3-12
3.4 本章小結	3-14
第四章、地面無人載具控制邏輯方法	4-1
4.1 操作介面說明	4-1
4.2 GPS 定位	4-2

4.3 移動模式建構方法	4-3
4.4 避障測試	4-7
4.5 地圖建立方法	4-9
4.6 感測器測試(氣體、熱紅外).....	4-10
4.6.1 有毒極易燃氣體感測器	4-10
4.6.2 熱紅外感測器	4-11
4.7 本章小結	4-13
第五章、臺中港感測資料自動化辨識技術發展	5-1
5.1 舊有標的物	5-1
5.2 岸邊設施自動化辨識分析	5-1
5.2.1 舊有辨識模型	5-1
5.2.2 新模型嘗試	5-4
5.2.3 辨識流程	5-7
5.2.4 辨識結果	5-9
5.3 北提路路況自動化辨識流程	5-10
5.3.1 舊有辨識模型	5-10
5.3.2 新模型嘗試	5-12
5.3.3 辨識流程	5-14
5.3.4 辨識結果	5-15
5.4 本章小結	5-16
第六章、臺北港感測資料自動化辨識技術發展	6-1
6.1 現有標的物精進	6-1
6.1.1 岸邊設施辨識模型更新	6-2
6.1.2 岸邊設施地理位置屬性	6-7

6.1.3 變電箱辨識模型更新	6-10
6.1.4 胸牆結構線偵測模型更新	6-15
6.1.5 碼頭面伸縮縫偵測模型更新	6-23
6.2 新增標的物	6-33
6.2.1 路面坑洞偵測模型建立	6-33
6.2.2 堤面鋼筋裸露	6-40
6.2.3 碼頭面裂縫	6-45
6.3 本章小結	6-49
第七章、多來源感測資料整合	7-1
7.1 港區現有感測器種類與應用現狀	7-1
7.1.1 環境監測感測器	7-1
7.1.2 貨櫃追蹤感測器	7-1
7.1.3 車輛感測器	7-1
7.1.4 設備感測器	7-1
7.1.5 CCTV 感測器	7-2
7.2 現有岸邊設施模型與 CCTV 的結合	7-2
7.2.2 申請區域	7-2
7.2.3 選擇模型	7-3
7.3 本章小結	7-5
第八章、基於高細緻港區空間資料之環境分析	8-1
8.1 三維建物模型資料處理	8-1
8.1.1 建物模型結構萃取	8-1
8.1.2 屋頂結構模型建構	8-2
8.1.3 建物邊緣線篩除	8-3

8.2 港區日輻射資料	8-4
8.3 研究成果	8-4
8.3.1 接收日射量成果	8-4
8.3.2 系統發電量成果	8-6
8.4 本章小結	8-7
第九章、無人載具之通訊技術研析	9-1
9.1 空中無人載具	9-1
9.2 地面無人載具	9-3
9.3 本章小結	9-4
第十章、無人載具之影像即時串流建構	10-1
10.1 空中無人載具	10-1
10.2 地面無人載具	10-4
10.3 本章小結	10-5
第十一章、系統整合平台	11-1
11.1 平台架構與功能介紹	11-1
11.2 平台功能展示說明	11-2
11.2.1 基本圖層	11-2
11.2.2 量測功能	11-4
11.2.3 UAV 航線規劃	11-5
11.2.4 UAV 斜拍調查影像查詢	11-8
11.2.5 路面破損評分	11-9
11.2.6 堤面胸牆辨識成果	11-9
11.2.7 碼頭面伸縮縫辨識成果	11-10
11.2.8 變電箱狀態辨識成果	11-12

11.2.9 CCTV 設施物辨識成果	11-13
11.2.10 氣體偵測異常提示	11-15
11.3 本章小結	11-16
第十二章、實地驗證與品質評估	12-1
12.1 無人機影像品質檢核	12-1
12.1.1 原始影像解析度檢核	12-1
12.1.2 正射影像幾何精度檢核	12-2
12.1.3 數值地形模型高程精度檢核	12-2
12.2 UGV 導航路徑正確性檢核	12-3
12.3 標的物件辨識及變遷偵測信賴度評估	12-5
12.4 道路破損評分	12-6
12.4.1 裂縫分級定義	12-6
12.4.2 坑洞分級	12-8
12.4.3 評分方法原理	12-8
12.4.4 路面裂縫評估成果	12-13
12.5 本章小結	12-17
第十三章、教育訓練	13-1
13.1 活動議程	13-1
13.2 活動影像	13-1
13.3 活動回饋	13-2
第十四章、結論與建議	14-1
14.1 研究成果	14-1
14.2 後續建議	14-4
14.3 成果效益與後續應用情形	14-5

參考文獻.....	參考-1
附錄一、工作會議紀要.....	附 1-1
附錄二、期中報告審查意見處理情形表	附 2-1
附錄三、期末報告審查意見處理情形表	附 3-1
附錄四、期末審查簡報資料	附 4-1

圖目錄

圖 1.1 研究歷程圖	1-5
圖 2.1 多旋翼機安全係數 0.5 飛行面積範圍	2-5
圖 2.2 多旋翼機安全係數 0.7 飛行面積範圍	2-5
圖 2.3 定翼機安全係數 0.7 飛行面積範圍	2-6
圖 2.4 MPS 可燃氣體感測器輸出氣體分類詳細資訊	2-15
圖 2.5 航行路徑及測區示意圖	2-19
圖 3.1 臺北港 GNSS 控制點分布圖	3-1
圖 3.2 臺北港 GNSS 控制點與既有控制點分布圖	3-2
圖 3.3 航帶範圍與控制點分布圖	3-3
圖 3.4 臺北港陸域合併平均潮位高之數值地形模型圖(單位:公尺). 3-4	
圖 3.5 臺北港陸域水下地形之數值地形模型圖(單位:公尺)	3-4
圖 3.6 臺北港正射影像圖	3-5
圖 3.7 正射影像解析度展示	3-5
圖 3.8 正射影像解析度展示	3-6
圖 3.9 臺北港氣象站分布圖	3-7
圖 3.10 小綠燈塔站風速資料	3-8
圖 3.11 資料浮標風速資料	3-8
圖 3.12 觀測樁站風速資料	3-9
圖 3.13 八里站風速資料	3-9
圖 3.14 北二碼頭站風速資料	3-9
圖 3.15 FNN 架構圖	3-10
圖 3.16 本計畫風速資料訓練架構圖	3-11

圖 3.17 每個月 Training loss 成果.....	3-11
圖 3.18 每個月 MAE 成果.....	3-11
圖 3.19 FNN 風速預估成果圖.....	3-12
圖 3.20 多旋翼無人機每月可飛行天數占比	3-13
圖 3.21 定翼無人機每月可飛行天數占比	3-14
圖 4.1 RVIZ 使用者界面的示意圖	4-1
圖 4.2 GPS 軟體操作介面示意圖	4-3
圖 4.3 臺北港港區道路示意圖	4-3
圖 4.4 (a) 局部和世界成本地圖 (b) 成本地圖中的膨脹半徑	4-4
圖 4.5 基於 UGV 運動模式的 DWA Planner 路徑選擇的可視化	4-7
圖 4.6 UGV 避障參數視覺化.....	4-8
圖 4.7 避障測試結果圖	4-8
圖 4.8 有毒及易燃氣體感測器實驗.....	4-10
圖 4.9 (a) 紅外線熱像儀測試目標 (b) 使用 Flir Vue Pro 測試物體表面的溫度.....	4-12
圖 4.10 (a) Flir One Pro (b) FLir Lepton FS.....	4-13
圖 4.11 Flir Vue Pro 測試結果	4-13
圖 5.1 臺中港岸邊設施自動化辨識分析流程(單張 POI 影像為例) ..	5-2
圖 5.2 測試資料模型辨識結果(以臺中港成果為例)	5-3
圖 5.3 臺中港模型套用於臺北港影像上之不同影像分割成果	5-4
圖 5.4 臺北港岸邊設施各物件樣態	5-5
圖 5.5 Yolov8 訓練與驗證的模型效能	5-6
圖 5.6 臺北港 Yolov8 模型於驗證資料集上的混淆矩陣.....	5-6
圖 5.7 臺北港模型岸邊設施自動化辨識分析流程(單張影像為例) ..	5-7

圖 5.8 POI 影像(中間)與鄰近的影像	5-8
圖 5.9 經投影轉換後的左右鄰近影像	5-8
圖 5.10 將鄰近影像的偵測結果投影至 POI 影像上	5-8
圖 5.11 (a) 單一 POI 影像的辨識結果、(b) POI 影像與鄰近影像 合併的辨識結果	5-9
圖 5.12 基期影像投影至 POI 影像	5-10
圖 5.13 與基期比對結果	5-10
圖 5.14 U-net 架構(Ronneberger et al., 2015)	5-11
圖 5.15 本地資料集圖片與對應標註	5-11
圖 5.16 U-Net++架構	5-12
圖 5.17 臺北港正射影像，紅框處即為臺北港測試資料位置	5-13
圖 5.18 (a)、(b) 臺中港資料，(c)、(d) 臺北港資料	5-13
圖 5.19 模型預測流程	5-14
圖 5.20 圖解 intersection over union(IoU)	5-15
圖 6.1 112 年度岸邊設施模型針對新期影像的偵測結果(P-R 曲線).	6-2
圖 6.2 多張岸邊設施物件偵測結果合併同一張來提升辨識準確度.	6-3
圖 6.3 112 年度岸邊設施影像蒐集之標註與使用情況	6-4
圖 6.4 臺北港新模型的訓練結果	6-5
圖 6.5 臺北港 5 月份影像訓練的模型與融合多個月份的模型表現.	6-5
圖 6.6 臺北港 7 月份影像訓練的模型表現與融合多個月份的模型表現	6-6
圖 6.7 臺北港 5 月份影像資料訓練之模型(左)與 7 月份影像資料訓 練之模型(右)	6-6
圖 6.8 臺北港 5 月份影像(左)與其他月份影像(右)的尺寸差異	6-7

圖 6.9 臺北港 10 月份資料的預測結果，左為舊模型，右為新模型	6-7
圖 6.10 如何計算物件的實際座標之示意圖	6-8
圖 6.11 物件越遠離影像中心點其座標誤差越大	6-9
圖 6.12 岸邊設施的地理定位與巡檢邏輯流程圖	6-10
圖 6.13 113 年度新蒐集之變電箱影像	6-11
圖 6.14 112 年度變電箱影像.....	6-11
圖 6.15 YOLOv8 物件辨識(變電箱)架構圖(Aboah et al 2023)	6-12
圖 6.16 變電箱模型訓練成果圖	6-14
圖 6.17 變電箱實際成果驗證	6-15
圖 6.18 胸牆法線預測及地理定位流程圖	6-16
圖 6.19 港區資料集分布圖	6-16
圖 6.20 A 區胸牆訓練影像.....	6-17
圖 6.21 訓練樣本標記示意(堤面胸牆為紫色部分)	6-18
圖 6.22 標記類別數量統計直方圖	6-18
圖 6.23 法線側模型訓練過程	6-19
圖 6.24 胸牆法線、伸縮縫、裂縫之正規化混淆矩陣圖	6-19
圖 6.25 胸牆法線遮罩進行霍夫直線預測影像(左)胸牆法線預測遮罩 (右)霍夫直線預測.....	6-20
圖 6.26 20240529 資料集偵測影像.....	6-21
圖 6.27 胸牆在平台上 POI 及樣態呈現.....	6-21
圖 6.28 平台上影像呈現流程	6-22
圖 6.29 預測成果分類	6-22
圖 6.30 伸縮縫預測及地理定位流程圖	6-23
圖 6.31 A 區道路伸縮縫圖.....	6-24

圖 6.32 各區域伸縮縫影像(左上)(右上)(左下)A 區伸縮縫影像(左下)D 區伸縮縫影像	6-24
圖 6.33 伸縮縫標註樣態展示	6-25
圖 6.34 標記類別數量統計直方圖	6-25
圖 6.35 無人機影像對應正射底圖	6-26
圖 6.36 正射底圖(左)A 區(右)F 區	6-26
圖 6.37 SIFT 匹配無人機影像和正射影像特徵點圖(左)無人機拍攝影 像(右)正射底圖對應位置之切片	6-29
圖 6.38 SIFT 匹配異常影像	6-29
圖 6.39 預測成果展示圖(左)20240708 資料集(中)20240529 資料集 (右)20240829 資料集	6-30
圖 6.40 20240529 正確檢測影像(POI:26)	6-31
圖 6.41 伸縮縫交點預測異常影像，黑色圈圈為交點	6-31
圖 6.42 伸縮縫在平台上 POI 及樣態呈現	6-32
圖 6.43 平台上影像呈現流程	6-33
圖 6.44 臺北港正射影像，紅框處即為臺北港測試資料位置	6-34
圖 6.45 臺北港坑洞資料，上為影像下為標註	6-34
圖 6.46 臺中港坑洞資料，上為影像下為標註	6-35
圖 6.47 U-Net++架構	6-36
圖 6.48 圖解 intersection over union(IoU)	6-38
圖 6.49 坑洞模型之學習曲線	6-38
圖 6.50 坑洞模型預測成果	6-39
圖 6.51 坑洞測試(A1 道路)，(a)測試位置(紅框)，(b)測試影像	6-39
圖 6.52 坑洞模型預測成果驗證	6-40

圖 6.53 PGI 結構圖	6-41
圖 6.54 GELAN 結構圖	6-41
圖 6.55 臺北港堤面影像	6-42
圖 6.56 intersection over union (IoU) 的公式	6-43
圖 6.57 鋼筋裸露偵測模型各項指標訓練圖	6-44
圖 6.58 Precision-Recall 曲線圖	6-44
圖 6.59 鋼筋裸露偵測結果	6-45
圖 6.60 U-Net++ 結構	6-45
圖 6.61 (a)為航攝的影像，(b)為標註的影像	6-46
圖 6.62 臺北港港口影像	6-47
圖 6.63 裂縫偵測的訓練情形	6-48
圖 6.64 (a)為臺北港港口影像，(b)為偵測的影像	6-49
圖 7.1 CCTV 場域的分布位置（綠點）	7-3
圖 7.2 CCTV 的模型訓練過程	7-4
圖 7.3 CCTV 的模型在驗證資料集上的混淆矩陣	7-4
圖 7.4 不同 CCTV 視角的偵測結果	7-5
圖 8.1 CityGML 建物模型細緻度等級(LOD)示意圖	8-1
圖 8.2 臺北港 LOD2 之模型	8-2
圖 8.3 屋頂結構圖	8-3
圖 8.4 利用 canny 偵測邊緣	8-3
圖 8.5 臺北港各月接收日射量成果	8-6
圖 8.6 臺北港全年推估系統發電量	8-7
圖 9.1 無人機影像傳輸通訊技術架構	9-1
圖 9.2 無人機影像傳輸通訊技術協議設定	9-3

圖 9.3 112 年度通訊方法與本期引進靜態 ip 通訊方法比較	9-4
圖 10.1 影像串流介接功能示意圖	10-1
圖 10.2 現場筆電串流指令介面	10-2
圖 10.3 可能出現的轉播錯誤問題	10-3
圖 10.4 臺大總圖書館無人機拍攝影像串流畫面	10-4
圖 10.5 蒐集之感測器資料和數據串流流程圖	10-5
圖 11.1 系統功能架構圖	11-2
圖 11.2 國土測繪中心正射影像	11-2
圖 11.3 本計畫拍攝製作的正射影像	11-3
圖 11.4 本計畫拍攝製作的數值地形模型	11-3
圖 11.5 內政部提供的建物 3D 模型.....	11-4
圖 11.6 距離量測功能	11-5
圖 11.7 面積量測功能	11-5
圖 11.8 航線規劃成果	11-6
圖 11.9 飛行路徑規劃功能	11-6
圖 11.10 飛行點位圈繪及規劃參數輸入	11-7
圖 11.11 規劃提示視窗	11-7
圖 11.12 規劃成果列表	11-7
圖 11.13 巡檢影像查看頁面	11-8
圖 11.14 AI 辨識成果查看	11-8
圖 11.15 路面 PCI 成果	11-9
圖 11.16 堤面胸牆 POI 點位分布情形.....	11-9
圖 11.17 堤面 18 號 POI 點 6 月份之辨識成果	11-10
圖 11.18 堤面 18 號 POI 點 7 月份之辨識成果	11-10

圖 11.19 碼頭面 POI 點位分布情形	11-11
圖 11.20 碼頭面 A1 區 31 號 POI 點 5 月份之辨識成果.....	11-11
圖 11.21 碼頭面 A1 區 31 號 POI 點 9 月份之辨識成果.....	11-12
圖 11.22 變電箱 POI 點位分布情形	11-12
圖 11.23 變電箱 2 號 POI 5 月之熱影像	11-13
圖 11.24 變電箱 2 號 POI 9 月之熱影像	11-13
圖 11.25 CCTV POI 分布情形	11-14
圖 11.26 CCTV POI 東五碼頭作業區影片	11-14
圖 11.27 影片全螢幕檢視畫面	11-15
圖 11.28 氣體偵測 POI 點位分布情形	11-15
圖 11.29 氣體偵測 1 號 POI 5 月之成果	11-16
圖 11.30 氣體偵測 1 號 POI 9 月之成果	11-16
圖 12.1 原始 UAV 航拍影像	12-1
圖 12.2 檢核點坐標分布圖	12-3
圖 12.3 (a) 地面機器人路徑正確性檢核實驗地點 (b) 地面機器人 路徑記錄在 RVIZ 顯示	12-4
圖 12.4 不同拍攝角度變電箱偵測成果	12-6
圖 12.5 路面裂縫模型預測結果	12-6
圖 12.6 輕級裂縫	12-7
圖 12.7 中級裂縫	12-7
圖 12.8 重級裂縫	12-8
圖 12.9 圖解骨架正交法	12-9
圖 12.10 圖解骨幹化.....	12-10
圖 12.11 骨架化成果	12-10

圖 12.12 裂縫預測及定位之流程圖	12-13
圖 12.13 航攝影像的資訊以及正射影像之間的關係	12-14
圖 12.14 SIFT 檢測的成果	12-14
圖 12.15 (a)正射影像原圖 (b)路面分段圖 (c)放大檢視.....	12-15
圖 12.16 分段評分結果	12-15
圖 12.17 道路裂縫，坑洞及伸縮縫預測成果	12-16
圖 12.18 PCI 檢測成果	12-16
圖 12.19 A1 道路路面狀況(PCI)分級.....	12-17
圖 13.1 活動剪影	13-2

表目錄

表 1-1 112 年度計畫進度甘特圖	1-8
表 1-2 113 年度計畫進度甘特圖	1-10
表 2-1 多旋翼機載具規格表	2-2
表 2-2 定翼機載具規格表	2-3
表 2-3 多旋翼 UAV 飛行總里程(總距離)範例計算	2-4
表 2-4 多旋翼 UAV 不同安全係數最遠飛行距離計算(折返)	2-4
表 2-5 多旋翼 UAV 飛行總里程(總距離)範例計算	2-6
表 2-6 定翼機 UAV 飛行總里程範例計算	2-6
表 2-7 光學相機	2-8
表 2-8 感應相機	2-8
表 2-9 光達感測器	2-9
表 2-10 Robomaster 和 Jackal UGV 規格比較	2-10
表 2-11 Robomaster 和 Jackal UGV 安全係數比較	2-11
表 2-12 光達感測器規格	2-12
表 2-13 攝影機規格	2-13
表 2-14 氣體感測器規格	2-14
表 2-15 有毒及易燃氣體感測器	2-15
表 2-16 熱感相機	2-16
表 2-17 無人遙控載具機型	2-18
表 2-18 ROV 航行里程計算(混合型)	2-19
表 2-19 適用水下光學相機規格表	2-20
表 2-20 水下定位模組比較	2-20

表 3-1 臺北港 GNSS 控制點觀測成果表	3-2
表 3-2 影像資料蒐集基本資料表	3-3
表 3-3 蒲氏風力級數與無人機最大抗風條件表	3-6
表 3-4 多旋翼無人機每月可飛行天數占比	3-13
表 3-5 定翼無人機每月可飛行天數占比	3-14
表 4-1 測試之 GPS 種類	4-2
表 4-2 地圖建構方法比較	4-9
表 4-3 有毒及易燃氣體感測器實驗設置	4-11
表 4-4 有毒及易燃氣體感測器實驗結果	4-11
表 4-5 紅外線熱像儀實驗結果	4-12
表 5-1 過去已辨識之標的物	5-1
表 5-2 岸邊設施 Mask R-CNN 辨識模型統計於驗證資料集之效能	5-2
表 5-3 測試資料模型辨識結果統計(以臺中港成果為例)	5-3
表 5-4 舊模型的訓練細節	5-12
表 5-5 新模型的訓練細節	5-14
表 5-6 模型表現	5-15
表 6-1 現有及新增標的物辨識內容綜整表	6-1
表 6-2 變電箱模型訓練參數表	6-13
表 6-3 變電箱型訓練成果表	6-14
表 6-4 坑洞模型訓練細節	6-36
表 6-5 坑洞模型測試成果	6-38
表 6-6 模型訓練細節	6-47
表 8-1 CityGML 對於 LOD 之建議規定彙整表	8-2
表 8-2 臺北港全區推估發電量	8-7

表 10-1 直播程式串流指令	10-1
表 12-1 斑馬線影像尺寸檢核表	12-2
表 12-2 DSM 誤差精度統計表	12-3
表 12-3 坑洞分級標準	12-8
表 12-4 鋪面折減值計算	12-11
表 12-5 鋪面 CDV 計算	12-12
表 12-6 PCI 等級對照表	12-12

第一章、前言

1.1 研究動機與目的

1.1.1 研究動機

無人移動載具在近年發展成熟，其具有高度的移動性以及遠距自動導控功能，並已應用到空中、地面、室內與室外空間，能夠取代人力快速且輕易到達過去不容易接近的區域，此外，搭配現代化的感測與高速通訊技術，則可即時獲取大量的空間觀測資訊。然而，為了有效利用這些大量空間觀測數據，合適且自動化的分析技術為其重要關鍵。另一方面，人工智慧技術在近期有大幅度的發展，透過適當的訓練程序與學習策略，可針對大量數據進行快速的分析與判斷。若能有效整合無人飛行載具影像與各式空間資訊，針對特定應用標的導入適當影像辨識學習技術，並以港區實際案例進行驗證，便能有效應用這些新科技，建立智慧港區之示範管理方案。

1.1.2 研究目的

港區使用單位多且任務繁雜，相關設施之利用與管理是港區營運的重要工作之一。然而港區幅員廣大，且人力有限，如何有效率且智慧化的掌握各區域之使用狀況並妥善管理，為一重要議題。另一方面，目前各類感測技術雖可有效獲取大量現地觀測資訊，但以人工判讀耗時費力，反而降低實務應用效能，而一些特殊任務需求，在有限的管理人力下，若無適當的科技輔助，將更顯額外負擔。

本計畫目的為以臺北港為示範港區，建立一套結合無人移動載具以及現代化感測技術之港區多維度空間資訊整合與智慧化應用方案。未來此方案，將能有效且定期整合港區各式空間資料，以自動化演算邏輯進行分析判斷，定期比對港區使用狀況與環境條件，並針對特殊事件開發合適的偵測與即時分析模組，藉以達到港區自動化管理效能。本計畫研究成果，將能提供上述問題實務解決方案，在人力持續精簡的長期趨勢之下，以現代化多維度感測、即時通訊

傳輸與智慧化空間資訊分析技術，來提供港區營運管理與安全之重要參考數據。

1.2 文獻回顧

1.2.1 傳統巡檢

巡檢可以確保設備資產完整，並依據各項數據的變化或趨勢來安排後續檢查及維修保養工作，進而維繫應有效能並提升安全性，以本計畫的港區為例，不僅提供港區物流業者腹地，供其興建倉儲設施，亦搭配各國際商港港口區位，但由於腹地範圍包含陸地及部分出海口，為了管理之方便及維護各項設施的完整，巡檢工作的必要性和重要性因此備受重視。

然而，目前港區巡檢多以人工為主，透過巡檢人員攜帶巡檢紀錄表格進行巡檢作業，依據不同檢查類別，各自判定標準執行檢測診斷，而方法多為目視並依需求配合儀器進行詳細檢測，最後將結果根據量表記錄於表格上，然而，這往往會造成 20%至 30%的錯誤率(Drury & Fox, 1975)。儘管現已有相關作業平台，仍必須花費人力將巡檢紀錄結果手動輸入電腦，無形中增加誤植的機率(See, 2012)。此外，在有限的人力及預算下，無法經常性檢測各項目，而是使用定期檢測將分類依照輕重緩急，歸類為年、季、月、周及日，許多設施發生問題無法及時處理。

近年來自動化巡檢觀念的興盛，相關技術已被套用在不同領域，自動化並非意味著人力的取代，相反的是巡檢流程結構的改變，將人力資源應用於更有價值的地方，利用機器從事繁複的任務減少紀錄及判斷錯誤，研究顯示這將提高結果可靠性和準確性(See et al., 2017)，對設施的安全維護提供重要幫助，也可使巡查次數更加頻繁，及時處理突發狀況。

1.2.2 無人載具發展與應用(空中、地面、水下)

不同類型的空中、地面以及水下無人載具（Unmanned Vehicles）在各個領域的發展與應用正急速擴展。這些技術的進展帶來了無限的應用潛力，並對當前的生活和各行業產生深遠的影響。

在無人機（Unmanned Aerial Vehicles，UAVs）方面，其已在多個領域取得了重大突破。憑藉著可進行遠端操作、相對較低的成本以及高度的機動性，無人機在安全、監控、監視、災害管理、遙感、搜索和救援（SAR）、建設和基礎設施檢查、精準農業、實時交通路況監控以及自動化森林恢復等領域中得到廣泛應用。此外，無人機還有望提供新的生產模式、服務形式以及作戰方式。至今無人機系統的應用領域已擴展至農業、林業、畜牧業、工業、服務業和軍事等各個領域。

地面無人載具（Unmanned Ground Vehicles，UGVs）泛指自主車輛或機器人。與空中無人載具不同的是，它們能夠在複雜的地形中穿梭移動，並執行危險任務，而不需要將人員置於危險之中。UGVs也在自動化倉儲管理和物流方面發揮關鍵作用，透過設定路線來移動和放置貨物，進而提高生產效率。此外，並被廣泛應用於城市規劃和基礎設施維護，協助城市實現智慧城市的目標。

水下無人載具包括遙控操作載具（Remotely Operated Vehicles，ROVs）和自主操作載具（Autonomous Underwater Vehicles，AUVs）。ROV 是由遠程操作的無人載具，通常由遙控操作員控制。它們通常與水面船隻相連，透過電纜進行通訊和供電。ROV 的優勢在於可以執行高度精確和複雜的任務，因為受到操作員的實時控制，這使得 ROV 在深海探索、海底工程和油氣開發等領域中有極大幫助。AUV 則是自主操作的無人載具，不需要實時人工干預。這些載具通常根據預定的程序和內置的感測器執行各種任務，並能夠在水下環境中自主導航。AUV 在科學研究、海洋調查和環境監測等領域中非常有價值，可以長時間在水下工作，執行數據採集、地質研究、海洋生態學等任務。

1.2.3 影像技術發展與應用難度

影像測繪技術隨著時間不斷推陳出新，航空攝影測量領域也因此而受惠，記錄媒介從類比影像演進到數位元影像，許多在電腦視覺計算上的理論，也逐漸被引進到數位攝影測量應用當中。結合無人機飛行拍攝，高機動性優勢條件提供如海(岸)上構造、邊坡崩塌等不易抵達區域進行影像蒐集，Colomina and Molina (2014) 以地理定位高解析影像經正射化、點雲資訊產製有效利用於空間環境監測。然而，當時序性影像執行環境變遷比較時，歷史拍攝影像易因缺乏地理定位參考資訊，需採用人工方式逐張比對辨識，大量影像人力辨識將降低監測效益。

透過拍攝影像中顏色可觀察到目標物屬性特色，然而，外在光源條件如天氣、日夜等變化將使成像特徵顏色有所差異，因此，過去研究採用的策略大致可分為兩種，其一是以紅-綠-藍空間(RGB space)為基礎，計算目標顏色在整幅影像中的相對灰階值大小以做為二值化依據(Soheilian et al., 2013)；另一種方法為 Hearn (1986)提出以 RGB 色彩模型基礎，透過非線性轉換，建構色相-飽和度-明度空間(Hue Saturation Value, HSV)轉換模型，利用色相與飽和度對同樣顏色的穩定性，決定不受光照環境影響的門檻值(Jau et al., 2008)。

影像匹配豐富應用於各影像類別，如近距離攝影、航拍圖像及車輛辨識(Liu et al., 2011; Shan et al., 2014; Malik and Siddiqi, 2014; Li et al., 2015)，此外 Tsai and Lin (2017)和 Zhuo et al. (2017)指出現行無人機影像匹配偵測多建立於已知位置或飛行高度，其中圖像比例大小與旋轉為特徵偵測之效率產生巨大影響。因此，透過無人機影像匹配技術發展，將凸顯空間鏈接與實現時序性監測研究價值。

1.3 歷年計畫成果回顧

本計畫研究歷程如圖 1.1 所示。

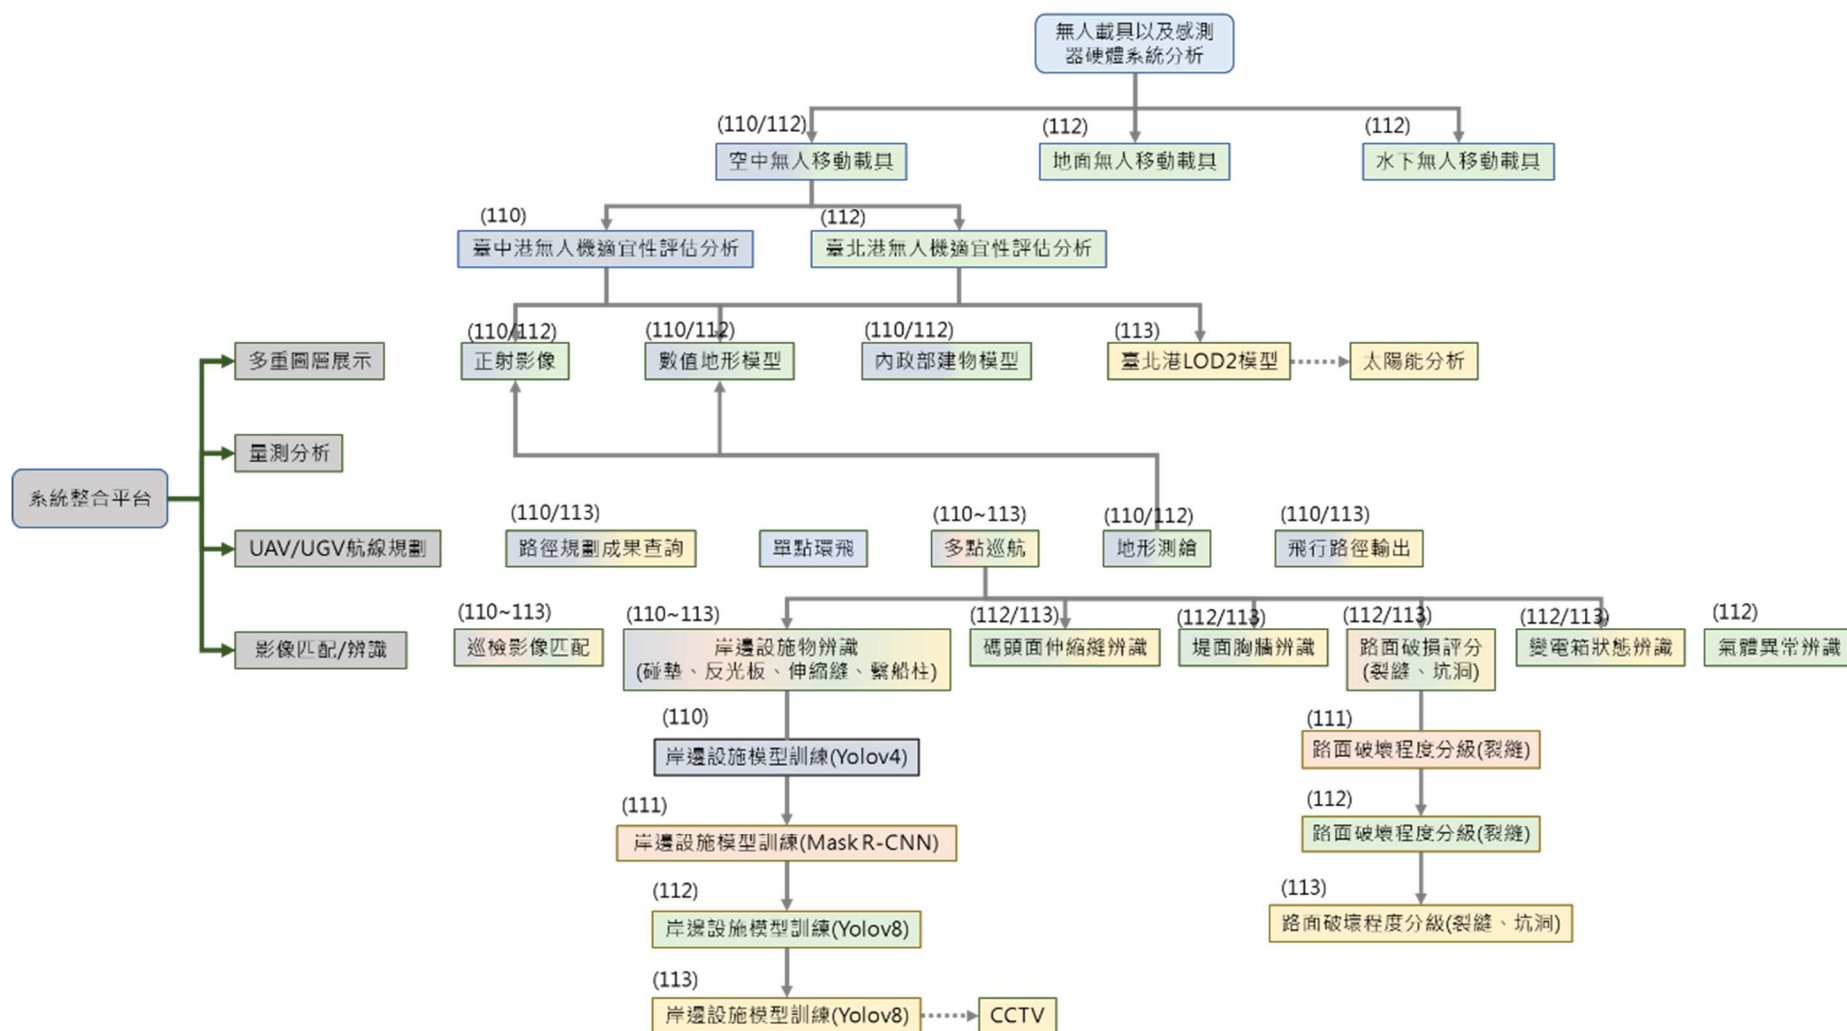


圖 1.1 研究歷程圖

1.3.1 臺中港(110~111 年)

本計畫為臺中港計畫成果之延續，在臺中港成果中，首先盤點不同種類的無人機並定義其飛行性能，針對酬載能力搭配感測器進行分析，並依據港區氣候條件劃分出最適合各區域使用的無人機類型及可飛行的月份，為未來的飛行任務提供最適依據。其次，進行了全港區高精度與高解析度的正射影像底圖與數值高程模型產製；也針對南堤進行了三期拍攝，產生三維點雲來監測構造物位移，並比較三個時期的水平與垂直位移差異；北防沙堤則進行了兩期拍攝，透過影像套疊比較兩期影像差異，顯示無人機在防砂堤監測中的應用效能。

在飛行載具取像控制邏輯的分析中，設計了 3 種飛行模式(地形測繪、多點巡航、單點環飛)，並針對各種模式設定了參數，並採用了 A-star 演算法進行航線規劃與避障，而此取像邏輯也透過相對坐標與絕對坐標的實際飛行測試。在無人機跟隨功能的測試中，無人機能穩定跟隨人或車輛，並保持固定的航高與跟隨距離，但在風速較大的港區環境下，跟隨可能會導致水平位移的影響。

在 UAV 影像變遷辨識技術上，透過無人機拍攝的影像資料，成功記錄了港區岸邊設施變遷，透過語意分割技術將感興趣區域進行實例分割，提升了辨識精度，對於大部分物件的辨識率達到了九成以上，然而，由於海水遮蔽影響，部分物件如碰墊的辨識率只有五成左右。針對北堤路的物件偵測，透過物件偵測技術有效辨識了路燈、紅綠燈及人手孔蓋等設施，雖然單張照片的辨識率只有八成，但由於連續拍攝，可以通過多張照片補充不足之處，並據此統計北堤路上的標線缺損情況，提供了量化的道路維護指標。針對如中南突堤、中碼頭及北防沙堤等關鍵區域進行多時性影像資料的蒐集與變遷分析，透過影像匹配技術對各時期影像進行比對。

最後，整合型圖台則將正射底圖與巡檢任務相結合，設立了 POI 點位，並將不同時期的影像進行匹配，以供使用者分析比對。這個平台能針對不同巡檢任務自動進行飛行模式設置與影像辨識。

此外，本計畫還對各項分析流程與軟硬體配置進行了品質評估，判定了關鍵因子，並提供了無人機在飛行範圍、作業時間、飛行穩定性等方面的評估成果。

1.3.2 臺北港(112 年)

本計畫為期 3 年，112 年主要完成無人移動載具（包含空中及地面）於臺北港的相關評估以及感測器硬體系統的分析，並根據臺北港的環境條件和任務需求，探討相關硬體規格與精度需求，並評估最適當的無人移動載具及感測器硬體組合，同時蒐集水下無人移動載具進行巡查的相關案例。接著，透過空中無人飛行載具蒐集的大量資料，建構臺北港的高細緻三維環境模型，該模型包含港區的空間幾何與屬性特徵，作為後續管理應用的基礎。此外，發展感測資料自動化辨識技術，藉由無人移動載具蒐集的資料，建立港區特定物件的辨識能力，並新增變電箱溫度、伸縮縫及胸牆歪斜等 3 項標的物的訓練樣本，運用機器學習技術進行自動化辨識技術的發展。

在品質評估與行動依據方面，針對整體工作流程所獲得的成果進行精度評估，並以實地觀測成果進行品質驗證，為後續管理決策行動提供參考依據。此外，還辦理了一場教育訓練，以推廣研究成果，並將計畫成果投稿至海洋工程研討會、地理資訊年會等研討會。112 年計畫進度甘特圖如表 1-1 所示。

表 1-1 112 年度計畫進度甘特圖

工作項目	1月	2月	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	備註
文獻資料蒐集建構分析方法													
無人移動載具（包含空中及地面、室內及室外）以及感測器硬體系統分析													
港區高細緻空間基礎資料建構													
水下無人機性能測試													
港區影像蒐集													
感測資料自動化辨識技術發展													
路面破壞評估													
整合性平台建構													
品質評估與行動依據													
期中報告													
期末報告													
教育訓練													
工作進度累進百分比(%)			25			50			75		100		
預定查核點	第 1 季: 引入新式無人載具及感測器												
	第 2 季: 飛行控制邏輯與完成影像蒐集												
	第 3 季: 無人飛行載具影像資料之空間資訊整合平台												
	第 4 季: 品質評估												

1.3.3 臺北港(113 年)

113 年為本計畫第 2 年，團隊主要工作項目及內容分述如下：

(1) 優化感測資料自動化辨識技術：

持續港區各類資料之蒐集與訓練樣本擴展，並新增 3 項標的物，以增強自動辨識之性能。

(2) 多來源感測資料整合：

研析臺北港區現有或新設之各式感測裝置資料特性，發展與無人移動載具感測資料之整合技術，以擴展港區環境資料蒐集之時空維度與範圍。

(3) 基於高細緻港區空間資料之環境分析：

透過第 1 年度完成之高細緻三維環境模型，結合港公司所提供 LOD2 模型，分析港區屋頂太陽光電潛能，做為港區管理及後續發展依據。

(4) 品質評估與行動依據：

評估上述各項工作所得成果之品質、效能以及維運成本，做為後續推廣應用與決策行動之參考依據。

(5) 辦理至少 1 場教育訓練：

藉由辦理教育訓練，推廣計畫研究成果，以增加其實用性。

(6) 計畫成果推廣：

針對計畫重要成果，製作可供展示之簡報或影片電子檔，並投稿於所內港灣季刊或運輸計劃季刊、國內外期刊、學術研討會。

(7) 113 年計畫驗收時，須提供本計畫軟體/系統平台等資訊軟體設備建置或增修開發費用。

(8) 參考「政府研究資訊系統(GRB)」之「績效指標(實際成果)資料格式」及「佐證資料格式」，就本計畫成果之特性，選填合適績效指標項目，並以量化或質化方式，說明本計畫主要研究/計畫成果及重大突破，並綜整摘要說明 112~113 年研究計畫累積成果撰寫成果報告書 1 本。

表 1-2 為 113 年本計畫進度甘特圖，執行期程共計 9 個月。

表 1-2 113 年度計畫進度甘特圖

工作項目	1月	2月	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	備註
文獻資料蒐集建構分析方法													
多來源感測資料整合													
基於高細緻港區空間資料之環境分析													
優化感測資料自動化辨識技術													
系統平台建構													
通訊技術方法分析													
即時串流方法建構													
品質評估與行動依據													
期中報告(6/28)													
期末報告(10/25)													
教育訓練													
工作進度累進百分比(%)			25			50			75		100		
預定查核點	第 1 季: 引入新式感測器												
	第 2 季: 飛行控制邏輯與完成影像蒐集												
	第 3 季: 無人飛行載具影像資料之空間資訊整合平台												
	第 4 季: 品質評估												
說明:													
(1)工作項目請視計畫性質及需要或依研究/計畫綱要說明訂定。預定進度以粗線表示其起訖日期。													
(2)「工作進度百分比」欄係為配合管考作業所需，累積百分比請視工作性質就以下因素擇一估計訂定:①工作天數②經費之分配③工作量之比重④擬達成目標之具體數字。													
(3)每季之「預定查核點」，請在條形圖上標明※號，並在「預定查核點」欄具體註明關鍵性工作要項。「預定查核點」除了標明期中/期末/期末修正定稿提送日期外，尚須具體加列其他重要工作項目，例如：工作會議、階段性成果宣導展示、專家座談會或技術移轉教育訓練等。													

第二章、無人載具以及感測器硬體系統分析

2.1 空中無人載具

2.1.1 載具類型分析

(1) 多旋翼機介紹

多旋翼機是由多個旋翼動力組件組成的飛行器，同時具備垂直起降的功能。根據承載能力和滯空能力，隨時調整飛行速度、高度和方向，具備相對較高的機動性，適用於地形起伏較大的區域。根據民航局多旋翼無人機重量和證照分級規範標準，可分為 Type1、Type2、Type3、Type4 四個類別，其規格如表 2-1 所示。Type1 重量在 250 克以下，例如，K60PRO 6K 屬於較輕型的多旋翼機，大部分 Type1 的無人機飛行時間約為 15 分鐘，飛行總里程(總距離)約 2750 公尺，常用於室外小範圍飛行或定點飛行，不適用於巡檢任務。Type2 重量在 250 克至 2 公斤之間，目前在該級別中表現最佳的是 Yuneec Typhoon H Pro，其重量雖不超過 2 公斤，但能搭載 6 個旋翼，這在同級別中相對較少見，從而提高了穩定性，並具備前置超聲波避障感應器，是目前最新型的機型。本案例中採用美國 Autel Robotics EVO II，其機身設計可靈活執行飛行任務，鏡頭可調角度範圍並為所有機型中最廣的，適合巡檢任務。此外，Type2 也屬於大眾最常使用的多旋翼機，大部分無人機飛行時間約為 25 分鐘，飛行總里程(總距離)約 4850 公尺。

Type3 重量在 2-15 公斤之間，例如，性能較好且較新型的機型是德國 Aibotix X6，它是一款 6 軸無人機，可更換多種傳感器，Type3 大部分無人機的飛行時間約為 20 分鐘。Type2 和 Type3 常被用於地形測繪和巡檢飛行。Type4 的重量在 15-25 公斤之間，是分級中最重的無人機，大部分用於農藥噴灑或其他特殊用途，例如，國產 EG2 Pro 植保機。

表 2-1 多旋翼機載具規格表

項目	Type1	Type2	Type3	Type4
重量	250 克	250 克-2 公斤	2 -15 公斤	15 -25 公斤
旋翼數量	4 槳	4 槳	4 槳 或 6 槳	4 槳 或 6 槳
最大飛行時間	15 分鐘	25 分鐘	20 分鐘	20 分鐘
總飛行距離	2750m	4850m	3800m	3800m
抗風	4 級風	6 級風	4-6 級風	4-6 級風
酬載重量	無法	200 克以下	2 公斤以下	10 公斤以下
重量	250 克	250 克-2 公斤	2 公斤-15 公斤	15 公斤-25 公斤
用途	室外小範圍定點拍攝	地形測繪巡檢飛行	地形測繪巡檢飛行	農噴或特殊用途
駕照規範 (專業高級)	Ia(未達兩公斤)	Ia	Ib	IIc

(2) 定翼機介紹

本案將固定翼飛機按重量分為 4 個類別，如表 2-2 所示分別為 Type1、Type2、Type3、Type4，並通過表 2-2 比較了不同級別無人機之間的差異。Type1 的重量範圍為 250 克至 2 公斤，屬於較輕型的固定翼飛機。在這個級別中，eBee X Fixed 是比較具有代表性的機型，具有高度穩定性且可進行投擲式飛行。在 Type1 中，大部分機型的飛行時間約為 45-60 分鐘，測繪模式下的單次飛行範圍約為 200 公頃，常用於地形測繪和巡檢飛行。Type2 的重量範圍為 2~15 公斤，例如本案中使用的 VX2300 新式固定翼混合動力無人機，採用旋翼垂直起降後變形為定翼飛行，不受地區限制。在 Type2 中，大部分機型的飛行時間約為 60-120 分鐘，測繪模式下的單次飛行範圍約為 700 公頃，可飛行高度達到 4000 公尺。Type3 的重量範圍為 15-25 公斤，例如 Quantum-Systems Tron F90+，也是一種新型固定翼混合動力無人機，其飛行時間和範圍與 Type2 相同，但抗風能力和載重能力優於 Type2。Type2 和 Type3 是目前廣泛使用的無人機，具有優秀的續航能力、載重能力和適中的體積。常見的 LiDAR 和雷達設備通常搭載在這些機型上。Type4 的重量超過 25 公斤，例如，臺灣自主研发的新型 Sky Arrow 55，具有超長飛行時間達 120 分鐘以上，可飛行高

度達到 4000 公尺。它具有最大的單次飛行範圍，並且能夠搭載較重的儀器，在抗風能力方面表現出色，常用於執行特殊任務或氣象數據收集等用途。

表 2-2 定翼機載具規格表

項目	Type1	Type2	Type3	Type4
重量	250 克-2 公斤	2 -15 公斤	15 -25 公斤	25 公斤以上
翼展	1m 以下	1.5m -2m	2m - 2.5m	2.5m - 3m
最大航高	500m	4000m	4000m	4000m
飛行時間	45 – 60 分鐘	60 – 120 分鐘	60 – 120 分鐘	120 分鐘以上
單次飛行範圍	500 公頃	1500 公頃	1500 公頃	3000 公頃
抗風	6 級風	6 級風	6-8 級風	6-8 級風
酬載重量	200 克以下	1.5 公斤以下	5 公斤以下	6 公斤以下
用途	地形測繪 巡檢飛行	地形測繪 巡檢飛行	地形測繪 大範圍巡檢飛行	地形測繪 大範圍巡檢飛行 氣象資料蒐集

2.1.2 飛行里程

(1) 多旋翼機飛行里程計算

本計畫多旋翼無人機主要用於巡檢監測任務，因此，飛行路徑將更為複雜，可能包含多個航線轉折、航高變化以及考慮港區天氣變化。另飛行面積範圍採用圓形，主要是適用於多旋翼機，因多旋翼機飛行里程較短，且多以巡檢任務為主，故以最大可觸及 buffer 來表示。飛行面積採用矩形，主要是適用於定翼機，因定翼機主要適用於地形測繪任務，故採用矩形表示可飛行最大範圍。因此，在評估電力總飛行時間時，除了一般情況下乘以 0.7 的係數外，本計畫額外引入乘以 0.5 的係數，用於不良天氣條件下的評估方式。里程計算方法，如表 2-3 所示，以 Type2 無人機為例，多旋翼機的起降需要較長的時間，因此，起降過程將導致一定的電力損耗，需要考慮在計算中。在 Type2 機型配合 0.7 的安全係數下，預估飛行總距離為 4850 公尺。根據這種計算方法，本計畫估計了不同類型無人機在不同安全係數下的單程最遠飛行距離，如表 2-4 所示，並通過圖 2.1(0.5) 和圖 2.2(0.7)對包含折返時的最遠飛行範圍，進行可視化呈現。顯然

可以看出，在安全係數為 0.5 的情況下，範圍明顯比安全係數為 0.7 時小得多，因此，在天氣狀況較不穩定時，應採取安全係數為 0.5 做為巡檢考量。

表 2-3 多旋翼 UAV 飛行總里程(總距離)範例計算

項目	數值
原廠公告飛行時間	25 分鐘
乘上 0.7 安全係數飛行時間	17.5 分鐘(1050s)
飛行航高	120m(本案最大航高)
飛行速度	5m/s(原廠最佳巡航速度)
起飛速度	3m/s(原廠預設速度)
降落速度	3m/s(原廠預設速度)
起飛時間	40s
降落時間	40s
總飛行時間	$1050s - 40s - 40s = 970s$
飛行總距離	$30m/s * 970s = 4850m$

表 2-4 多旋翼 UAV 不同安全係數最遠飛行距離計算(折返)

安全係數	Type1	Type2	Type3	Type4
× 0.5	925 m	1675 m	1300 m	1300 m
× 0.7	1375 m	2425 m	1900 m	1900 m

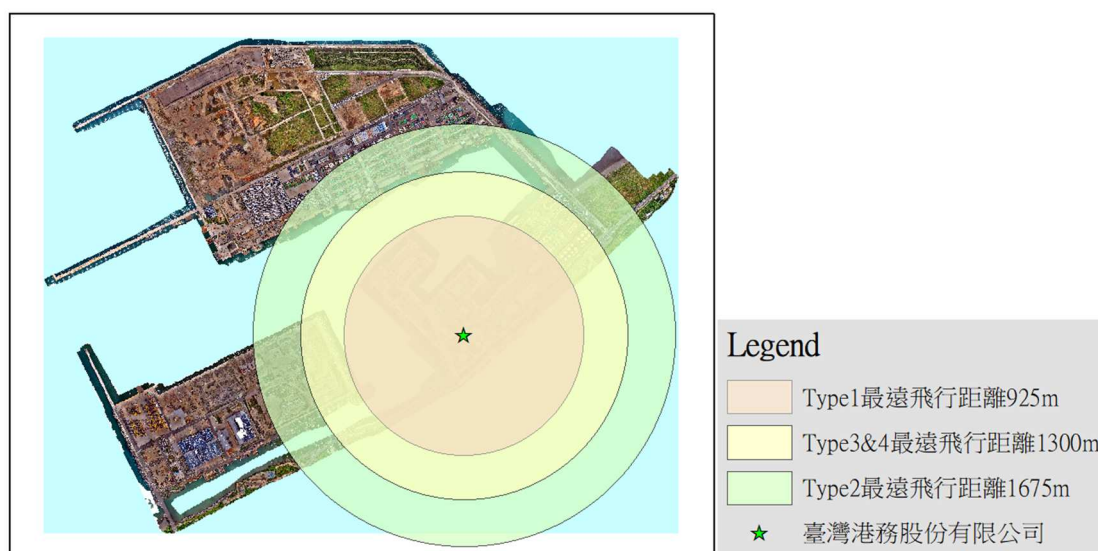


圖 2.1 多旋翼機安全係數 0.5 飛行面積範圍




圖 2.2 多旋翼機安全係數 0.7 飛行面積範圍

(2) 定翼機飛行里程計算

由於港區範圍廣闊，因此，需進一步考慮飛行器飛行里程，以便快速評估適用性。影響無人機飛行里程的主要因素為其無人電池續航時間。目前，廠家公告的無人機續航時間是在理想情況下、天氣良好時提供的飛行範圍。然而，考慮到本計畫位於氣候條件不佳的港區，需要將電力總飛行時間乘以安全係數。目前常見的安全係

數為 0.7，該係數是本計畫根據天氣條件進行調整。然後，通過總飛行時間來計算里程，如表 2-4 所示，以 Type2 為例，在考慮 0.7 的安全係數下，飛行總里程(總距離)為 113.4 公里。通過表 2-6 估計各種類型無人機在安全係數下的飛行總里程(總距離)，預估飛行範圍如圖 2-3 所示。

表 2-5 多旋翼 UAV 飛行總里程(總距離)範例計算

項目	數值
原廠公告飛行時間	90 分鐘
乘上 0.7 安全係數飛行時間	60 分鐘(3780s)
飛行航高	120m(本案最大航高)
飛行速度	30m/s(原廠最佳巡航速度)
飛行總距離	$30\text{m/s} \times 3780\text{s} = 113.4\text{km}$

表 2-6 定翼機 UAV 飛行總里程範例計算

安全係數	Type1	Type2	Type3	Type4
$\times 0.7$	38km	113km	113km	151km

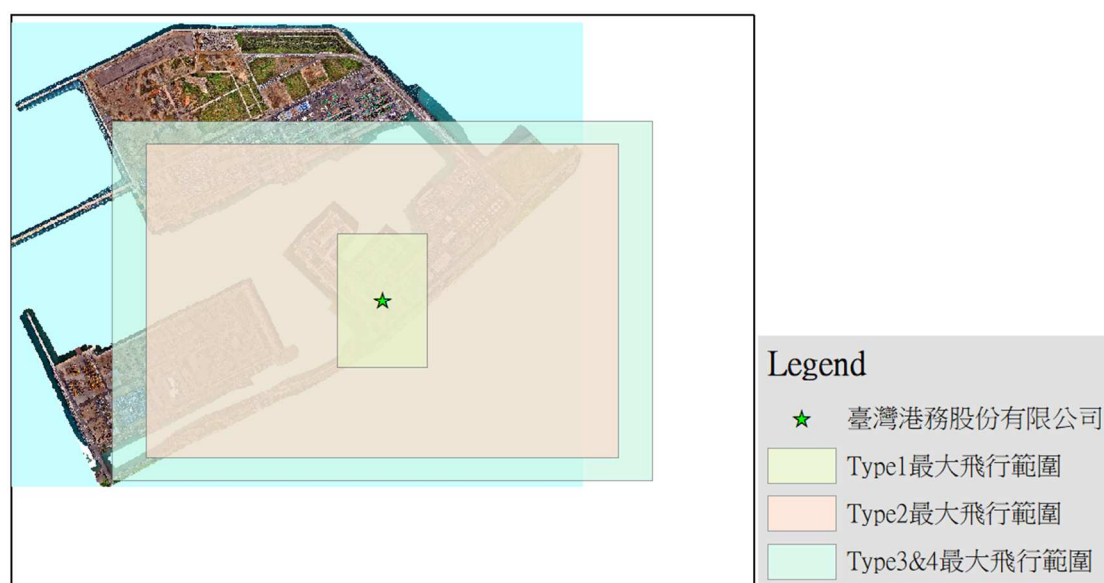


圖 2.3 定翼機安全係數 0.7 飛行面積範圍

2.1.3 感測器分析

無人機具備靈活的飛行能力，對於不同地區地形的數據蒐集具有強大的優勢，因此，可以搭載多種傳感器，包括光學相機、熱感相機和激光雷達。首先是光學相機，通常採用原廠設置鏡頭模塊做為載荷傳感器，提供較完整的系統集成，部分型號並可以更換傳感器。如表 2-7 所示，多旋翼機的主流解析度為 3840×2160，飛行高度 120 公尺時，地面解析度為 4.7 公分/像素。另外，多旋翼機與定翼機也可以搭載高解析度的模塊鏡頭，主流解析度為 5344×4016，飛行高度 120 公尺時，地面解析度為 3.8 公分/像素，這種規格已可滿足大部分監測或測繪需求。也有更高階的相機為 6000×4000，飛行高度 120 公尺時，地面解析度為 3.0 公分/像素。大型定翼機能酬載較重相機，主流解析度為 7952×5304，飛行高度 120 公尺時，地面分辨率為 3.0 公分/像素，大部分為電影製作等級的規格，另可根據需求更換定焦或變焦鏡頭。

第 2 種傳感器是熱感應相機，其型號與規格如表 2-8 所示。目前在所有型號中，較少配置模塊化鏡頭，只有一般的小型無人機具備模塊化鏡頭，通常需要另外安裝在機身上。另由於多旋翼機受限於載荷重量，無法搭載更優秀的鏡頭，主流解析度為 320×256，飛行高度 120 公尺時，地面解析度為 56.3 公分/像素。另定翼機可以安裝高級鏡頭，主流解析度為 640×512，飛行高度 120 公尺時，地面解析度為 28.1 公分/像素。

第 3 種感測器為光達，其型號與規格如表 2-9 所示。光達原理為雷射發射器所發出的脈衝雷射光，由載具主動發射出訊號至地面上，打到植生或建物後引起散射和反射。一部分光波會經由反向散射返回到載具上的接收器中，將光訊號轉變為電訊號記錄下來，例如，用於紀錄大範圍地貌三維空間資訊。如表 3-8 所示，光達依據雷射照射的範圍，可分為三種：(1)360°全視野照射，航高 120 公尺點密度為 150pts/m²(2) 46° 向下視野，航高 120 公尺點密度為 300pts/m²(3) 100°半視野，航高 120 公尺點密度為 680pts/m²。

表 2-7 光學相機

光 學 相 機			
型 號	K60PRO 6K Cam	Parrot Anafi 4K Cam	SONY A7R II
種 類	模組鏡頭&可替換式鏡頭	模組鏡頭&可替換式鏡頭	模組鏡頭&可替換式鏡頭
像 素	1200 萬畫素	2100 萬畫素	4240 萬畫素
解 析 度	3840x2160	5344 x 4016	7952 x 5304
感 光 元 件	1/2.3 英吋 CMOS	1/2.4 英吋 CMOS	1 英吋 CMOS
相 機 重 量	100 克以下	200 克以下	5 公斤以下
航 高 120m 地 面 解 析 度	4.7cm/pixel	3.8cm/pixel	3.0cm/pixel

表 2-8 感應相機

熱感應相機			
型 號	FLIR VUE	Parrot anafi usa thermal	FLIR A65
種 類	可替換式鏡頭	模組鏡頭&可替換式鏡頭	模組鏡頭
解 析 度	320x256	320x256	640x512
相 機 重 量	500 克以下	500 克以下	1 公斤以下
航 高 120m 地面 解 析 度	56.3cm/pixel	56.3cm/pixel	28.1cm/pixel

表 2-9 光達感測器



光達感測器			
型號	RIEGL miniVUX-3UAV	RIEGL miniVUX-1UAV	RIEGL VUX-120
種類	全視野	向下視野	半視野
雷射脈衝頻率	100 kHz	1.8MHz	1.8MHz
測量頻率	200,000 次/秒	1,00,000 次/秒	1,500,000 次/秒
掃描速度	100 次掃描/秒	150 次掃描/秒	400 次掃描/秒
精度	±2cm	±2cm	±2cm
FoV	360°	46°	100°
重量	1.55 公斤	2.4 公斤	2 公斤
航高 120m 點 密度	150pts/m ²	300pts/m ²	680pts/m ²

2.2 地面無人載具

2.2.1 載具類型分析

地面無人載具為一台搭載多種感測器的無人地面車輛（UGV）。根據不同任務需求，可選用具有不同適應性和耐用性之地面無人載具規格。以本計畫為例，考慮臺北港較為繁忙，UGV 需要選擇較大的尺寸，以容納多個感測器，並同時確保高其可視性。將上述因素納入考量後，本計畫選擇了 Clearpath Jackal UGV 做為為地面無人載具之地面車輛，研究初期先行使用國立臺灣大學實驗室現有改裝版 Robomaster S1 UGV 進行初步測試，即便 Robomaster S1 尺寸相對較小不適合戶外使用，但可做為一個臨時之載具平台，做為本案之實驗測試與問題解決之用。表 2-10 為 Robomaster S1 和 Clearpath Jackal UGV 規格之比較。

表 2-10 Robomaster 和 Jackal UGV 規格比較

UGV		
模組名稱	Robomaster S1	Clearpath Jackal
外部尺寸（長 x 寬 x 高）	320×240×270mm (12.6 x 9.4 x 10.6 in)	508 x 430 x 250 mm (20 x 17 x 10 in)
重量	3.5 kg (7.6 lbs)	17 kg (37 lbs)
酬載重量	10 kg (22 lbs)	20 kg (44 lbs)
最大速度	2.5 m/s (5.5 mph)	2.0 m/s (4.5 mph)
離地高度	30 mm (1.2 in)	65 mm (2.5 in)
操作環境溫度	-10 to +40° C	-20 to +45° C
電池容量	2400mAh	9800mAh
操作時間	0.5 to 1.5 hours	2.0 to 8.0 hours
連接	Wifi, Router	Wifi, Router

2.2.2 行走里程

爲了計算地面機器人的行走里程，本計畫根據以下參數做假設：

- (1) 有效負載重量之假設：本計畫假設機器人有效負載重量達到了上限，這是為了考慮機器人應對各種不同負載的能力，確保其多功能性。
- (2) 速度選擇：本計畫選擇了相對保守的速度，即 0.25 m/s，這比人類步行速度慢（ $\approx 1\text{m/s}$ ）。考慮安全性和控制，較低的速度有助於避免碰撞和提高操作的精確性。
- (3) 操作時間選擇：本計畫選擇了操作時間的中間值，以涵蓋不同應用場景中的變化。這有助於更好地反映實際應用中的多樣性，同時提供可靠的計算基礎。

- (4) 安全係數設定：本計畫設置安全係數為 0.75，以增加系統的可靠性和安全性。
- (5) 下一步，根據上述的假設，本計畫進行行走里程計算：UGV 速度操作時間安全係數，計算結果如表 2-11。

表 2-11 Robomaster 和 Jackal UGV 安全係數比較

模組名稱	Robomaster S1	Clearpath Jackal
酬載重量	10 kg (負載重量上限)	20 kg (負載重量上限)
UGV 速度	0.25 m/s	0.25 m/s
操作時間	1 hours	5 hours
安全係數	0.75	0.75
行走里程	675m (0.6 km)	3375m (3.3 km)

2.2.3 感測器分析

地面無人載具（UGV）可配備不同類型感測器，包括光達（Lidar）、攝影機、熱像儀、有毒氣體及易燃氣體感測器。這些感測器可提升 UGV 的功能，使其能夠在各種環境中，根據任務類型執行不同任務，進而發揮關鍵作用。

另外，由於 UGV 依賴 ROS1 Melodic，每個感測器都需要有相應的 ROS 驅動程式才能使用，為確保感測器與 UGV 可兼容，如果製造商未提供所需的 ROS 驅動軟體，或者在 GitHub 等平台上未有開源之軟體，則至少需要一個由 Python 或 C++ 編寫之 SDK（軟體開發工具包），才能夠建立自定義的 ROS 驅動引擎。


本小節將針對光達、攝影機、有毒氣體及易燃氣體進行說明。

(1) 光達 (Lidar)

Lidar 為 UGV 中的關鍵感測器之一，它透過發射雷射脈衝並計算光線返回的時間。Lidar 使 UGV 能夠準確測量距離，檢測物體並建立周圍環境的詳細三維地圖。這些資訊對於後續導航、避障和地形測繪至關重要。

本計畫經評估後，選用 Lidar 做為 UGV 中主要感測器，並比較 Livox Avia 和 Velodyne VLP-16 2 種不同光達規格 (如表 2-12)。Livox Avia 具有較為精細的點雲數據，同時也具有卓越的精度和擴展範圍，然而，在視野方面，相較於具有全方位 360 度水平視野 (FOV) 的 Velodyne VLP-16，Livox Avia 僅有 70 度的較窄水平 FOV。考量本計畫標的為交通繁忙的臺北港，選擇 Velodyne VLP-16 作為 UGV 所使用之感測器，透過其 360 度視野 (FOV) 的光達感測器，可以為現場工作人員及 UGV 提供更好的防護措施，全方位視野也使得道路檢測和避開障礙物具可能性，從而提升在繁忙環境中的導航和整體營運效率。

表 2-12 光達感測器規格

LiDAR		
模型	Livox Avia	Velodyne VLP-16
技術	中程 LiDAR	16 束 LiDAR
測量範圍	最高 200 公尺	最高 100 公尺
垂直視場角	77.2 度	30 度
水平視場角	70.4 度	360 度
掃描速率	240,000 點/秒	300,000 點/秒
精度	± 2 公分	± 3 公分
運作溫度	-10°C 至 50°C	-10°C 至 60°C
連接方式	以太網	以太網

(2) 攝影機

攝影機已安裝在 UGV 上，提供額外的影像數據，呈現不同的視角與 UAV。UAV 能夠捕捉更廣泛的正射影像，而 UGV 提供了更接近人類視角的視野，有助於更好地了解現場狀況。攝影機所蒐集的 RGB 影像提供操作者的導航操控便利性，並可與熱像影像進行比較，

因為每個物體表面的【光學透明性質】和【熱學透明性質】特性各不相同。目前，就 RGB 攝影機而言，本計畫使用 Stereolabs ZED 2i (規格如表 2-13)，具有高達 2208 x 1242 的解析度和 110 度的寬水平視場 (FOV)。

表 2-13 攝影機規格

光學相機	
型號	Stereolabs ZED 2i
解析度	2208 x 1242
焦距	2.12 毫米 (0.008 英寸)
光圈	f/1.8
垂直視場角	70 度
水平視場角	110 度

(3) 有毒及易燃氣體感測器

臺北港是一個繁忙的港口，對於國內和國際貿易至關重要，除了大型輪船運作時排放之廢棄氣體，許多貿易還涉及石油和其他化學物質。在這樣的環境中，有毒和易燃氣體感測器成為無人地面車輛 (UGV) 中的一個關鍵裝置。這些感測器能夠檢測有害氣體的存在，例如，有毒煙霧或易燃蒸氣，並提前發出警告，以防止事故發生或保護該區域內的工作人員。本計畫蒐集氣體感測器規格，如表 2-14。

表 2-14 氣體感測器規格

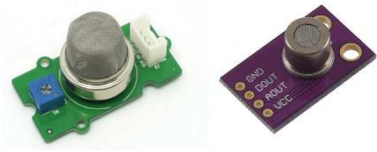

感測器種類		
模型名稱	MQ2 MS100	Nevada Nano MPS™ Flammable Gas Sensor Module
感測技術	金屬氧化物半導體 (MOS)	微機電系統 (MEMS)
目標氣體名稱	MQ2: 液化石油氣、酒精、丙烷、氫氣、一氧化碳、甲 MS100: 甲醛、甲苯、苯	包括丁烷、乙烷、氫氣、甲烷、丙烷、甲苯、二甲苯 詳情請參考表 2-13
目標氣體分類	2 類 (每個感測器 1 類)	6 類 (參考表 2-13)
校正需求	需要校正	不需要校正
測量輸出	預設輸出為布林值，表示氣體濃度是否超過閾值 若進行校正，也能提供以百萬分比 (PPM) 表示的氣體濃度	氣體類別編號 (0 ~ 6) 氣體濃度 (%LEL) 溫度 (°C) 大氣壓力 (kPa) 相對濕度 (%) 絕對濕度 (%)
精度	取決於校正精度，一般較大	± 3-12% LEL (參考表 2-13)
ROS 支援	需先接 Arduino Board，然後再接機器人的電腦，然後使用 Arduino 之 ROS Driver	有 ROS Driver

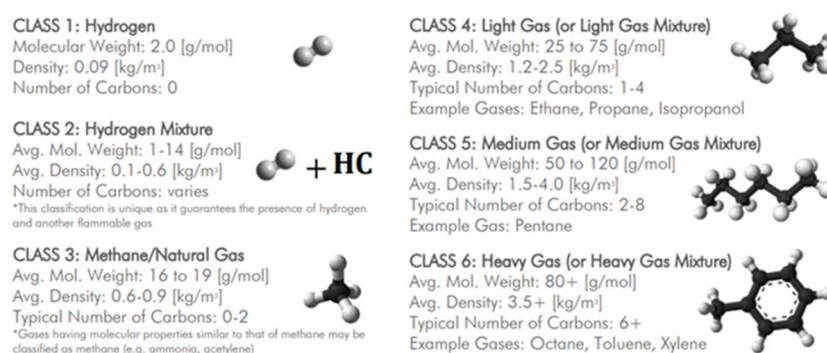
表 2-14 說明 MPS 氣體感測器的優異性能和簡易的設置。此外，根據本計畫所需，MPS 是市面上唯一具備這種能力的感測器，可確保甲烷在整個環境範圍內的準確性，而其他氣體僅在標準條件下（20°C 和 50% 相對濕度）下才能達到同樣標準。MPS 氣體傳感器所提供的讀數是以 %LEL（下限爆炸濃度）濃度表示，而不是絕對百分比體積濃度。舉例來說，甲烷屬於 Class 3 氣體，其 100%LEL 相當於 5% 體積（體積百分比濃度）。如果氣體偵測器的 Conc (%LEL) 讀數為 40，則表示為 40%LEL 或 2% 體積濃度。有關各種氣體的 %LEL 與 %體積濃度的更多資料，如表 2-15。

表 2-15 有毒及易燃氣體感測器

Gas	Formula	Class ¹	Detection Range [%LEL]	% Volume of gas at 100 %LEL (ISO 10156)	MPS Accuracy 0 to 50 %LEL (ISO 10156)	% Volume of gas at 100 %LEL (IEC60079-20-1)	MPS Accuracy 0 to 50 %LEL (IEC60079-20-1)
butane	C ₄ H ₁₀	4	0-100	1.8 %VOL	±5 %LEL	1.4 %VOL	±5 %LEL
ethane	C ₂ H ₆	4	0-100	3.0 %VOL	±5 %LEL	2.4 %VOL	±5 %LEL
hydrogen	H ₂	1	0-100	4.0 %VOL	±5 %LEL	4.0 %VOL	±7 %LEL
isobutane	HC(CH ₃) ₃	4	0-100	1.8 %VOL	±5 %LEL	1.3 %VOL	±9 %LEL
isobutylene	C ₄ H ₈	4	0-100	1.8 %VOL	±5 %LEL	1.8 %VOL	±5 %LEL
isopropanol	C ₃ H ₈ O	4	0-100	2.0 %VOL	±10 %LEL	2.0 %VOL	+20 %LEL
methane	CH ₄	3	0-100	5.0 %VOL	±3 %LEL	4.4 %VOL	±3 %LEL
MEK	C ₄ H ₈ O	5	0-100	1.4 %VOL	±5 %LEL	1.5 %VOL	+16 %LEL
pentane	C ₅ H ₁₂	5	0-100	1.5 %VOL	±5 %LEL	1.1 %VOL	±6 %LEL
propane	C ₃ H ₈	4	0-100	2.1 %VOL	±5 %LEL	1.7 %VOL	±6 %LEL
propylene	C ₃ H ₆	4	0-100	2.4 %VOL	±5 %LEL	2.0 %VOL	±5 %LEL
acetone	C ₃ H ₆ O	5	0-100	2.5 %VOL	+20 %LEL	2.5 %VOL	+24 %LEL
ethylene	C ₂ H ₄	4	0-100	2.7 %VOL	-11 %LEL	2.3 %VOL	-11 %LEL
heptane	C ₇ H ₁₆	5	0-100	1.1 %VOL	±12 %LEL	0.85 %VOL	±15 %LEL
hexane	C ₆ H ₁₄	5	0-100	1.1 %VOL	-20 %LEL	1.0 %VOL	-17 %LEL
octane	C ₈ H ₁₈	6	0-100	1.0 %VOL	±12 %LEL	0.8 %VOL	±15 %LEL
styrene	C ₈ H ₈	6	0-100	1.1 %VOL	-20 %LEL	1.0 %VOL	-17 %LEL
toluene	C ₇ H ₈	6	0-100	1.2 %VOL	±12 %LEL	1.0 %VOL	±13 %LEL
xylene	C ₈ H ₁₀	6	0-100	1.1 %VOL	±12 %LEL	1.0 %VOL	±13 %LEL

(<https://docs.allsensing.co.kr/allsensing-document/product-document/nevedanano>)

MPS 氣體感測器也具備對其他各種氣體的檢測能力，包括氨、乙炔、乙醇和甲醇。該感測器的輸出包括現有氣體的分類，能夠準確讀取超過十幾種可燃氣體的%LEL（氣體濃度對於爆炸下限之百分比）。有關氣體分類的更多訊息，請參考圖 2.4 中的氣體分類部分。



(<chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://nevedanano.com/wp-content/uploads/2021/03/SM-UM-0002-15-MPS-Flammable-Gas-Sensor-User-Manual.pdf>)

圖 2.4 MPS 可燃氣體感測器輸出氣體分類詳細資訊

(4) 紅外線熱像儀

熱感應			
相機	Flir Vue Pro	PureThermal 3 FLIR Lepton FS	Flir Boson
型號	336x256	160x120	640x512
解析度	高增益: < 135 °C (只配有高增益模式)	高增益: < 140 °C 低增益: < 350 °C	高增益: < 140 °C 低增益: < 500 °C
場景	± 5°C	± 5°C	± 5°C
動態範圍	因為熱像資料只記錄在內置的 SD 卡上，目前無法開發 ROS Driver	有 ROS Driver	有 ROS Driver

除了光達和氣體感測器外，UGV 也可配備熱像儀。這些相機能夠捕捉物體發出的紅外輻射並將其轉換為熱像。通過分析溫度變化，熱成像相機提供了寶貴的洞察力，可用於檢測異常、識別熱源以及進行火災監控、搜救行動和環境監測等任務。表 2-16 根據本案所需列出了各種熱成像相機的規格。

表 2-16 熱感相機

根據表 2-16 中提供的資訊，Flir Boson 似乎是由於其更高的解析度而成為最合適的選擇。然而，值得注意的是，Flir Boson 通常用於機械或半導體工廠，用於測量小型電子元件的溫度。對於我們的研究，涉及測量變電箱的溫度，Flir Lepton FS 提供的解析度已足夠。然而，在台灣尋找這些產品一直是具有挑戰性的。因此，在我們的研發初期，我們選擇使用 Flir Vue Pro 來收集部分數據。

Flir Vue Pro 的大限制是它主要設計用於無人飛行器（UAV）的使用。因此，所有收集的數據存儲在 SD 卡中，無法實時從地面機器人之電腦存取數據。然而，在我們研究的後期階段，我們已經開始測試 Flir Lepton FS，以滿足我們的需求。

2.3 水下無人載具

2.3.1 載具類型分析

水下無人遙控潛具(Remotely operated underwater vehicle, ROVs)是一種水下遙控無人載具，透過電纜線將載具與水面上的母船或控制站連接，來回傳遞操作指令與資訊回傳等以執行各類型水下任務，如水下設施檢查、環境監控、海底地形探索等。ROV 根據國際海事承包商協會 (International Marine Contractors Association, IMCA) 於 2021 年提出 R004. rev5 中定義 ROV 的分類，如表 2-17，主要分為機體龐大，酬載能力較高的工業級與機身輕巧，不具高酬載能的觀察級兩種類型，但隨著水下任務的複雜度與機動性，工業級 ROV 的主體大小趨向觀察級，而觀察級 ROV 的酬載能力亦逐漸提高。工業級的長、寬、高為公尺等級，如台灣海洋科技研究中心所使用的英國 Forum Subsea Technologies Triton XLX 56，其電力來源由母船經纜線提供，作業時間無任何限制，作業深度達 3000 公尺，最大酬載為 250 公斤，因較深的作業深度與持久的作業時間，此類型水下無人載具常應用於深海作業，如海底地形測繪、深海電纜埋設、離岸結構物巡檢等；觀察級以 Qysea FIFISH V6s 為例，儀器大小為 383 mm*331 mm*143 mm，電力來源由機體電池提供，作業時間為 120 至 360 分鐘，作業深度達 100 公尺，最大酬載為 100 公斤，常應用於

河川或水壩巡檢，混合級如以本計畫採用之 Chasing M2 PRO 為例，儀器大小為 480 mm*267 mm*165 mm，其電力來源亦由機體電池提供，作業時間為 240 分鐘，作業深度達 300 公尺，最大酬載為 100 公斤，常應用於水壩巡檢、岸邊結構物巡檢，以及近海作業等。

表 2-17 無人遙控載具機型

機型	工業級 ROV	觀察級 ROV	微型 ROV
機身尺寸	長、寬、高：公尺以上	長、寬、高小於 1 公尺	長、寬、高 0.5 公尺內
運行速度	6 節以上	4 節以上	2~4 節
作業環境	水下 100m~數千米	水下百米內	50 米內
常見搭載裝備	高解析度攝像機 聲納掃描 抽吸式採樣器 多組液壓式機械手臂 環境感測器(如水溫、USBL)	高解析度攝像機 聲納掃描 簡易型機械手臂 環境感測器(如水溫、USBL)	高解析度攝像機 環境感測器(如水溫、USBL) 無外加酬載能力

2.3.2 航行里程

本計畫中水下無人機承擔水下結構物之巡檢任務，飛行路徑及測區如圖 2.5，可能包含航線折返、水下深度變化以及考慮港區潮汐流速變化。因此，在評估電力總航行時間時，一般情況下(靜態水域內僅須維持機體浮力)乘以 0.6 的係數外，本計畫還額外考慮乘以 0.35 的係數，用於動態水域下的評估。里程計算方法如表 2-18 所示，以混合型無人機為例，水下無人機上浮與逆流前進時重力與水流阻力較強，因此需考慮在計算中。在混合型採 0.6 的電力損耗係數下，預估飛行總距離為 12927 公尺。根據以上計算方法，本計畫亦估計混合型水下載具在不同安全係數下的單程最遠潛行距離，如表 2-18 所示，從表中可得，在安全係數為 0.35 的情況下，其飛行路徑里程為安全係數為 0.6 的 58%，因此，在港區內應採取安全係數 0.35 做為巡檢考量。



圖 2.5 航行路徑及測區示意圖

表 2-18 ROV 航行里程計算(混合型)

項目	數值(靜態環境)	數值(動態環境)
原廠表定工作時間	4 小時(240 分鐘)	
電力損耗係數	0.6	0.35
潛水深度	17m(本案水深最深處)	
下潛速度	1.5m/s	
潛行速度	1.5m/s	
上浮速度	1.5m/s	
上(下)潛所需時間	11s	
總潛行時間	240min*60s/min*0.6-11s*2=8618s	240min*60s/min*0.35-11s*2=5018s
總潛行距離	1.5m/s*8618s=12927m	1.5m/s*8618s=7527m

2.3.3 感測器分析

水下無人載具對於不同地形與水理條件下，選用之感測設備亦不同，常見的感測器有包含光學相機、定位模組等。首先是光學相機，通常採用原廠設置的鏡頭模塊做為感測器，其提供較完整的系統，且考慮到市面上之相機防水功能皆不適合執行水下作業，故 ROV 通常以原廠鏡頭模塊為主，解析度為 4000*3000，另外為因應

任務需求，部分水下無人機會搭載 gopro 使用，gopro 與原廠鏡頭模組比較，如表 2-19 所示。

定位模組是一種利用水下聲波幾何原理的水聲學進行定位的系統，方法大致可分成有長基線(long baseline, LBL)、短基線(short baseline, SBL)及超短基線 (ultra short baseline, USBL)3 種。三者定位皆透過測量訊號的到達方位和距離，並藉由計算作業定位點與接收基站陣列間的訊號走時與相位差來獲得水下定位結果，三者差異如表 2-20。USBL 是目前進行海洋探測時的主流方式，其優點是系統及運作費用較低，操作也較其他兩種定位法簡便容易，但其定位元精度需高度仰賴研究母船上的其他設備，如電羅經、姿態感測器和深度感測器等。

表 2-19 適用水下光學相機規格表

光學相機		
種類	模組相機	Gopro 10
像素	1200 萬像素	1580 萬像素
解析度	4000*3000	5,312 *2,988
重量	100 克以下	約 150 克

表 2-20 水下定位模組比較

種類	長基線(LBL)	短基線(SBL)	超短基線 (USBL)
固定定位站距離	數十公尺至數公里	數公尺至數十公尺	公尺以內
定位精度	最佳	中等	最差(需仰賴其他儀器校正)
所需時間	最長	中等	最快

2.4 本章小結

多旋翼機和定翼機無人機在近年來已成為科技航空領域中的重要角色。兩者都具有獨特的優勢，適用於不同的任務和應用場景。從提供的資料可以明確看出，多旋翼機因其機動性和垂直起降的能力而被廣泛使用，特別是在地形複雜或需要精確定位的情境下。而定翼機則因其更長的續航時間和飛行距離，成為適用於大範圍巡檢測繪和數據蒐集的理想選擇。無論是多旋翼機或是定翼機，飛行里程的計算都是一項關鍵任務。考慮到不同的氣候和地形條件，安全係數的運用變得尤為重要。從本文中，可以看出無論是以 0.5 還是 0.7 的安全係數計算，對飛行範圍的評估都產生了很大的影響。這強調了在進行飛行任務時，根據當時的天氣和其他環境因素進行調整是多麼重要。

此外，傳感器技術的進步也使得無人機的應用更加多元。從光學相機到熱感相機，再到雷射雷達，這些工具使無人機能夠捕捉到更為詳細和精確的地面數據。尤其是在解析度上，現今的無人機相機已經能夠達到相當高的精度，滿足了多數監測和測繪的需求。無人機技術不斷進步，不只在飛行能力上，同時在數據收集和分析方面都展現了巨大的潛力。

第三章、港區高細緻空間基礎資料建構

3.1 地形資料蒐集

3.1.1 控制點測量

控制測量作業採用 GNSS 靜態量測方式獲取三維空間資訊，本計畫於臺北港區共施測 6 個地面控制點，並採用台北市 TPE-CORS 一等衛星連續追蹤站 GDH1 作為約制基準，共同聯測達 40 分鐘以上。經使用衛星定位基線解算軟體，並加入衛星精密星曆，再透過該軟體平差解算後獲得測站之高精度三維坐標成果，同時提供三維坐標後驗精度。控制點分布如圖 3.1 所示，解算成果如表 3-1。除了使用自行布設之控制點外，本案也採用了臺北港既有控制 TP188,TP189,TP276,TP304,TP324,TP358,TP422,TP574,TPS001，做為後續無人機影像解算依據，點位分布如圖 3.2 所示。

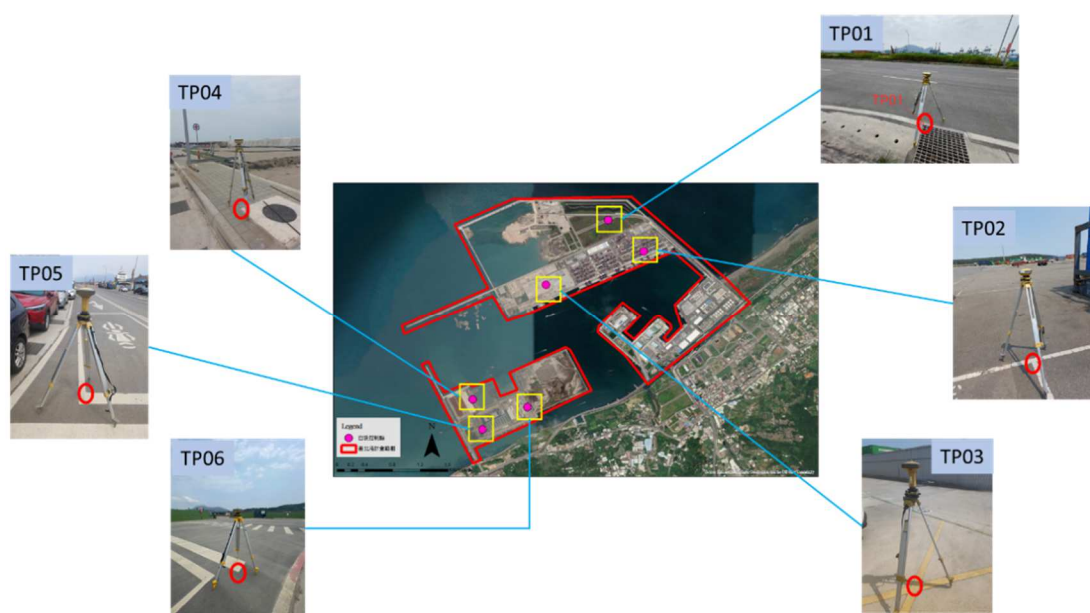


圖 3.1 臺北港 GNSS 控制點分布圖

表 3-1 臺北港 GNSS 控制點觀測成果表

點號	橫坐標(m)	縱坐標(m)	橢球高(m)	正高(m)
TP1	288782.698	2784595.513	24.209	4.683
TP2	289150.300	2784301.294	26.482	6.937
TP3	287996.740	2783642.972	23.341	3.827
TP4	286955.083	2782068.466	23.047	3.547
TP5	287767.615	2781739.004	22.323	2.784
TP6	287204.442	2781450.325	21.991	2.472




圖 3.2 臺北港 GNSS 控制點與既有控制點分布圖

3.1.2 影像資料蒐集

臺北港區幅員廣大，本次施測面積包含臺北港陸域及部分水域面積共約為 1000 公頃，以航高為 120m 進行影像資料蒐集，另外受限於桃園機場禁航區，故部分區域航高更改為 60m。此航帶涵蓋所有地面控制點，每個控制點至少涵蓋 4 條航帶以上，圖 3.3 為本計畫影像拍攝點位分布，採用多旋翼無人機進行拍攝，總計 30 次起降，拍攝 7949 張影像，單張影像原始解析度寬 5742×高 3648。影像重疊

率如圖 3.3 所示，符合縱向達 80%、橫向達 60%之標準，基本資料表如表 3-2 所示。

表 3-2 影像資料蒐集基本資料表

項目	內容
無人機	Autel Robotics EVO II
航高	120m & 60m
起降次數	30次
影像數量	7949
重疊率	縱向重疊 80% 橫向重疊 60%
單張影像大小	寬5742×高3648




圖 3.3 航帶範圍與控制點分布圖

3.1.3 數值地形模型成果

數值地形模型(Digital Terrain Model, DTM)是採用影像匹配產製點雲製作而成，以數值的形式來表示實際地形特徵的空間分布，再製作精確之數值高程模型資料，能確實反應實際地形面起伏情形，每一個影像網格皆具有高程資訊。本計畫另於數值地形模型使用 2 種水位資料。一種為水域部分使用潮汐資料，採用中央氣象署統計 2007 至 2022 年之潮位資料，平均潮位高為 0.652 公尺，相對於

TWVD2001，第一種成果空間解析度為 10cm，如圖 3.4 所示，因使用平均潮位，故所有水域高程為同一顏色(綠色)。另一種水域資料，為採用 109 年度水下地形資料進行建置，再與本計畫數值地形模型進行合併，空間解析度為 5m(圖 3.5)，因使用水下地形，故所有水域高程具有色階變化性(深綠至淺綠)。




圖 3.4 臺北港陸域合併平均潮位高之數值地形模型圖(單位:公尺)




圖 3.5 臺北港陸域水下地形之數值地形模型圖(單位:公尺)

3.1.4 正射影像成果

正射影像產製基於數值地形(DTM)三維地表變化，再根據影像幾何，由共線式描述投影中心、影像、與地面點的關係，配合數值進行正射糾正，可求得 DTM 每個一個物點(X,Y,Z)在影像上的坐標(x,y)，根據影像點上之灰度值而倒投影填入原物點網格，每一個影像網格皆具有地理坐標資訊。正射影像成果如圖 3.6 所示，影像解析度為 2.38 公分。另如圖 3.7 與圖 3.8 所示，實際量測影像與初步檢核，誤差約在 1~2 公分左右。



圖 3.6 臺北港正射影像圖




圖 3.7 正射影像解析度展示

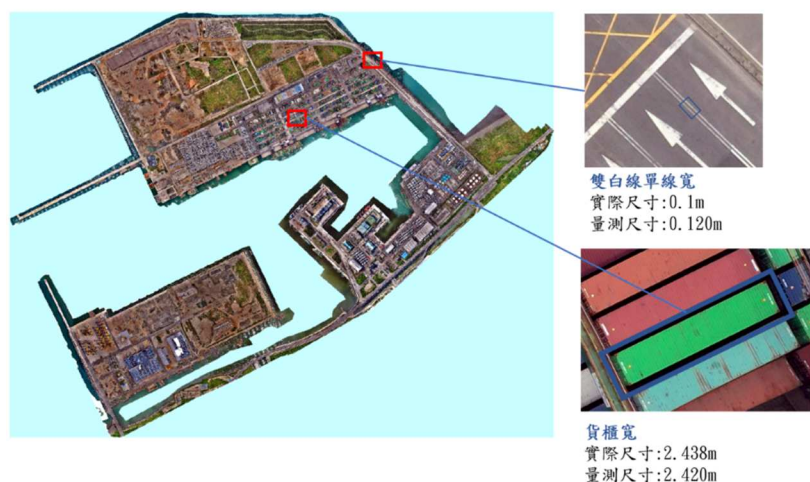


圖 3.8 正射影像解析度展示

3.2 氣象資料蒐集

3.2.1 空中無人載具抗風與防水條件定義

本計畫列出了多旋翼無人機與定翼無人機的最大抗風條件，如表 3-3 所示，各類型無人機對應至蒲氏風力級數。此外，關於無人機防水係數，目前各無人機原廠並無明確說明，但也具有一定能力的防水功能，降水量 20mm/day 的小雨情況視為可飛行，另表 3-3 提供了無人機對應風速建議之安全係數。

表 3-3 蒲氏風力級數與無人機最大抗風條件表

風級	名稱	平均風速 (公尺/秒)	建議安全係數	無人機最大抗風
0	無風	0-0.2		-
1	軟風	0.3-1.5		-
2	輕風	1.6-3.3		-
3	微風	3.4-5.4	× 0.7	多旋翼無人機Type1
4	和風	5.5-7.9	× 0.7	多旋翼無人機Type2,3,4
5	清風	8.0-10.7	× 0.5	定翼無人機Type1,2
6	強風	10.8-13.8	× 0.5	定翼無人機Type2,3
7	疾風	13.9-17.1		-
8	大風	17.2-20.7		-
9	烈風	20.8-24.4		-
10	狂風	24.5-28.4		-

3.2.2 港區風速評估

無人機能否穩定順利完成任務，最大關鍵因素為天候，若執行飛行任務時遭受到較差的天氣狀況，例如，強風、降雨等，可能會造成無人機直接墜毀，或是無法有效率執行任務，因此，天候評估是相當重要的一環。此外，港區位於海陸交界處，天候又更為多變，故本計畫蒐集臺北港周邊氣象站，包含小綠燈塔、資料浮標、觀測站樁、北二碼頭、八里站等之逐時風速資料，用以評估無人機的適用性，測站位置分布，如圖 3.9 所示。



圖 3.9 臺北港氣象站分布圖

多時期風速正規化是指使用多年度的風速資料來進行風力評估的一種方法。通常在這種正規化中，使用多個觀測點蒐集一年的風速數據，並根據這些數據進行統計分析和建模，以了解風速在不同時期的變化情況。這種正規化方法的目的是獲得一年中各個時期的風速特徵，包括風速的平均值、變異性和風速分佈等。通過對風速數據進行統計分析，可以得出各個時期的風能資源潛力。圖 3.10 至

圖 3.14 為各站風速資料，已正規化為一年份資料，並將風速根據測站高度進行調整。




圖 3.10 小綠燈塔站風速資料




圖 3.11 資料浮標風速資料




圖 3.12 觀測樁站風速資料




圖 3.13 八里站風速資料




圖 3.14 北二碼頭站風速資料

關於區域與風速之預估，本計畫風速資料採用 FNN（Feedforward Neural Network），FNN 是一種前饋神經網絡，常用於機器學習和深度學習任務，架構如圖 3.15 所示，它由多個連接的神經元層組成，資訊在網絡中單向傳遞，沒有反饋回路。FNN 的架構包括輸入層、隱藏層和輸出層。輸入層接收特徵變數作為網絡的輸入，每個特徵對應一個神經元。隱藏層位於輸入層和輸出層之間，由多個神經元組成，並通過權重與前一層的神經元連接。輸出層是網絡的最後一層，輸出神經元的數目取決於問題的性質。FNN 的訓練過程涉及權重的調整和激活函數的應用，以最小化輸出與實際目標之間的誤差。該方法在許多領域中被廣泛應用，包括圖像識別、語音辨識和自然語言處理。通過調整神經網絡的結構和參數，FNN 能夠捕捉複雜的非線性關係，並實現準確的預測和分類。它具有高度的彈性和擴展性，並在處理大量數據和複雜問題時展現出良好的性能。FNN 的發展和改進不斷推動著機器學習和人工智慧領域的進步。本計畫風速資料訓練架構，如圖 3.16 所示，將每一站的測站坐標以及每個月的風速資料輸入，再使用 FNN 進行訓練，最終預估出研究區域任意位置的風速趨勢圖。訓練精度成果如圖 3.17 與圖 3.18 所示。




圖 3.15 FNN 架構圖

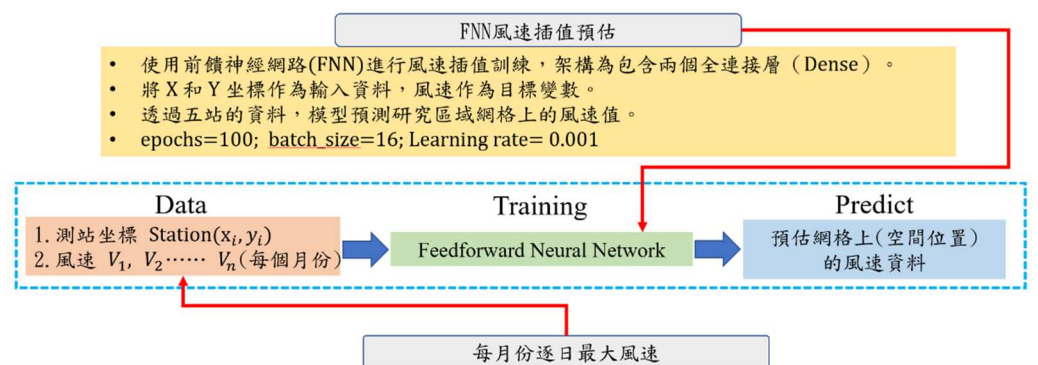


圖 3.16 本計畫風速資料訓練架構圖




圖 3.17 每個月 Training loss 成果




圖 3.18 每個月 MAE 成果

FNN 風速預估成果如圖 3.19 所示，圖中可分為 4 個分級，依據表 3-3 所定義，分為 3 級風、4 級風、5 級風、6 級風。圖中包含風速大小資料以及自動化分區成果，整合成全年 1 張成果圖，使用者可清楚得知不同分級對應適合飛行之無人機。




圖 3.19 FNN 風速預估成果圖

3.3 空中載具適宜性評估

將 FNN 的預估成果，如圖 3.19 進行量化，即可分析並得知一個月內共有幾天符合抗風條件，其中抗風條件主要是依據無人機原廠提供之抗風規格，例如，2 公斤以下最大抗風為 5 級風，並換算實際風速，再對應至臺北港風速資料進行評估。將資料標準化除以一個月的天數，即可獲得無人機可飛行天數百分比，可分析每月不同區之各類無人機(Type1~Type4)可飛行天數百分比。並將成果分成多旋翼機與定翼機 2 種。如表 3-4 與圖 3.20 所示，為多旋翼機每月可飛行天數占比，包含無人機種類與分區區域(Level3~Level6)。定翼機每月可飛行天數分析結果，如表 3-5 與圖 3-21。

表 3-4 多旋翼無人機每月可飛行天數占比

月份	Type1-LV3	Type234-LV3	Type1-LV4	Type234-LV4	Type1-LV5	Type234-LV5	Type1-LV6	Type234-LV6
一月	83.9%	100.0%	9.7%	100.0%	0.0%	16.1%	0.0%	3.2%
二月	85.7%	100.0%	10.7%	100.0%	0.0%	46.4%	0.0%	3.6%
三月	87.1%	100.0%	58.1%	100.0%	0.0%	61.3%	0.0%	41.9%
四月	76.7%	100.0%	33.3%	100.0%	0.0%	70.0%	0.0%	46.7%
五月	93.5%	100.0%	58.1%	100.0%	0.0%	96.8%	0.0%	58.1%
六月	86.7%	100.0%	60.0%	100.0%	0.0%	56.7%	10.0%	90.0%
七月	83.9%	100.0%	54.8%	100.0%	0.0%	58.1%	9.7%	83.9%
八月	90.3%	100.0%	87.1%	100.0%	0.0%	64.5%	0.0%	64.5%
九月	83.3%	100.0%	53.3%	96.7%	0.0%	50.0%	0.0%	36.7%
十月	83.9%	100.0%	12.9%	100.0%	0.0%	22.6%	0.0%	9.7%
十一月	80.0%	100.0%	20.0%	100.0%	0.0%	36.7%	0.0%	6.7%
十二月	96.8%	100.0%	3.2%	100.0%	0.0%	16.1%	0.0%	16.1%




圖 3.20 多旋翼無人機每月可飛行天數占比

表 3-5 定翼無人機每月可飛行天數占比

月份	Type12-LV3	Type34-LV3	Type12-LV4	Type34-LV4	Type12-LV5	Type34-LV5	Type12-LV6	Type34-LV6
一月	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	58.1%	100.0%
二月	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	57.1%	96.4%
三月	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	77.4%	100.0%
四月	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	76.7%	100.0%
五月	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	90.3%	100.0%
六月	100.0%	100.0%	100.0%	100.0%	86.7%	100.0%	100.0%	100.0%
七月	100.0%	100.0%	100.0%	100.0%	87.1%	100.0%	96.8%	100.0%
八月	100.0%	100.0%	100.0%	100.0%	83.9%	96.8%	90.3%	100.0%
九月	100.0%	100.0%	100.0%	100.0%	90.0%	100.0%	76.7%	96.7%
十月	100.0%	100.0%	100.0%	100.0%	83.9%	100.0%	45.2%	96.8%
十一月	100.0%	100.0%	100.0%	100.0%	96.7%	100.0%	40.0%	90.0%
十二月	100.0%	100.0%	100.0%	100.0%	77.4%	100.0%	54.8%	77.4%




圖 3.21 定翼無人機每月可飛行天數占比

3.4 本章小結

關於基礎資料蒐集，首先，港區風速環境資訊系統被建置，利用 FNN 神經網路技術能夠更準確地預估風速資料，並提供任意區域的風速成果，在自動化分區的問題上，也不需人工介入劃分，應用此技術可更精確預估風速資料，提供相關領域決策可靠依據。此外，

本計畫蒐集地面控制點測量和全港區影像資料，透過精確的地面控制點配合攝影測量原理進行影像建模。另在飛行航線以及航高也是至關重要，若某些區域因航高受限導致建模不理想，例如，航高過低導致重疊率不足，需再另外進行小區域航線規劃。或採用傾斜攝影測量進行拍攝補足物件的側面資訊。這項工作產製了高精度與高解析度的正射影像底圖和數值高程模型。每個像素在影像上皆具有精確的空間資訊，因此，這些資料在港區巡檢以及影像對位等相關任務中具有廣泛的應用價值。透過這些基礎資料的蒐集與分析，能夠全面了解港區的環境特徵、地形變化以及風速分佈等重要因素。這些資料將為港區管理和相關任務的執行提供有力支援，例如，風險評估、安全管理和基礎設施規劃等方面，確保港區的運營和發展能夠更加順利。

根據氣象資料評估，如表 3-4 與表 3-5 成果所示，多旋翼機 Type2&3&4，在每個月的 Level3 與 Level4 分區，幾乎能具備將近 100%的飛行天數。但在 Level5 與 Level6 分區因接近外海，故可明顯看出可飛行天數受到季節影響。在 4 月至 8 月才有接近 60%的可飛行天數，其餘月份因風速較大，可飛行天數低於 60%。定翼機之所有機種在 Level3、Level4 以及 Level5 分區都具備高於 80%以上的可飛行天數，而在 Level6 分區同樣受到外海強風影響在冬季，可飛行天數百分比降至 40%至 50%。整體而言，多旋翼機在臺北港建議在 3 月至 8 月巡檢，而定翼機建議在 2 月至 10 月巡檢，以達到最安全巡檢飛行之目的。

第四章、地面無人載具控制邏輯方法

為了達成無人地面載具（UGV）的自主導航，需具備三個關鍵模組：UGV 底盤、開發板和 Lidar。本計畫中，UGV 將配備 ROS1 Noetic(機器人作業系統 Robot Operating System 中的其中一個版本，官方習慣使用某種烏龜的學名來當作版本名稱，並按照字母順序排序，例如，最新一版是 Noetic Ninjemys（一種史前巨型烏龜），而前一個版本是 Melodic Morenia（一種淡水烏龜）)操作系統，該操作系統將作為 UGV 控制和導航能力的基礎。

4.1 操作介面說明

ROS 導航堆疊將 RVIZ(Robot Visualization)，是 ROS 系統內建可視化傳感器數據之工具，做為一個強大的可視化和控制工具融入其中。RVIZ 為一個 3D 可視化環境，使用者能夠即時互動並檢視機器人的行進過程。在 RVIZ 中，使用者可以將機器人的感測器數據進行視覺化，包含光達的點雲、拍攝影像和地圖。

圖 4.1 為 RVIZ 的操作界面，提供直觀的圖形使用界面（GUI），展示其在視覺化感測數據、機器人姿態和計算路徑方面的能力，顯示目前機器人的所在位置、規劃路徑和偵測到的障礙物。使用者可以自行修改和設置導航目標，監視機器人的移動，並根據需要進行彈性調整。

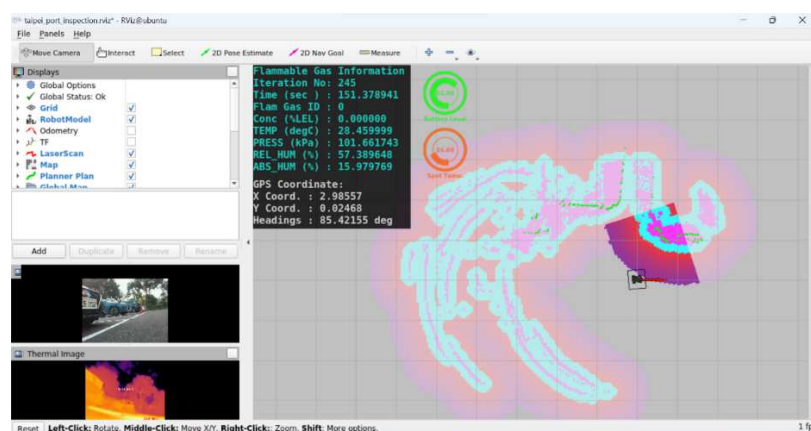


圖 4.1 RVIZ 使用者界面的示意圖

除了具備導航控制功能外，RVIZ，在 jsk_rviz_plugin 的協助下，還提供了實時可視化我們所收集數據結果的額外優勢。這包括顯示 RGB 影像、熱像影像和氣體感測器的讀數，使其成為一個全面且多功能的機器人圖形使用界面（GUI）。

4.2 GPS 定位

為了能使 UGV 順利移動到指定位置，需將 GPS 座標轉換為 UGV 可以讀取的地圖座標。因此，GPS 定位的精確性尤為重要，研究最初是透過手機內建的 GPS 接收器與 UGV 連接同一無線網路進行定位與導航。隨後，改用新採購的 SparkFun GPS-RTK 套件進行定位測試，而此 RTK GPS 接收器可以將 GPS 座標轉換為 ROS 系統可讀取的格式，進而協助 UGV 進行地圖建構與航點導航，所使用之 GPS 種類，整理如表 4-1，圖 4.2 為新 GPS 軟體操作介面示意圖。

表 4-1 測試之 GPS 種類

	內建 GPS	採購 GPS (u-blox ZED-F9P)	手機 GPS
優點	<ul style="list-style-type: none"> - 內建整合，無需額外購置模組 - 支持 NMEA sentence（國際海事電子協會定義之標準化格式，用於導航通信協議，廣泛應用於 GPS）輸出，涵蓋多種導航與感測數據 	<ul style="list-style-type: none"> - 高精度，支持 RTK 技術 - 支持多頻道與多衛星系統（GPS、GLONASS、Galileo、BeiDou） - 與 Jetson 等設備良好兼容 	<ul style="list-style-type: none"> - 易於獲取，無需額外購買 - 方便傳輸至 ROS 系統，簡化硬體連接 - 多用途，可應用於多種感測任務
缺點	<ul style="list-style-type: none"> - 定位訊號不穩定，NMEA sentence 無效率高 - 訊號接收能力差，受環境影響大 	<ul style="list-style-type: none"> - 成本較高，需額外基站支援 RTK - 資料處理需求高，需專用工具（如 ROS）進行座標轉換和應用 	<ul style="list-style-type: none"> - 定位精度較差（5-10 米） - 數據穩定性差，受限於手機天線性能 - 座標傳輸及處理流程較為複雜

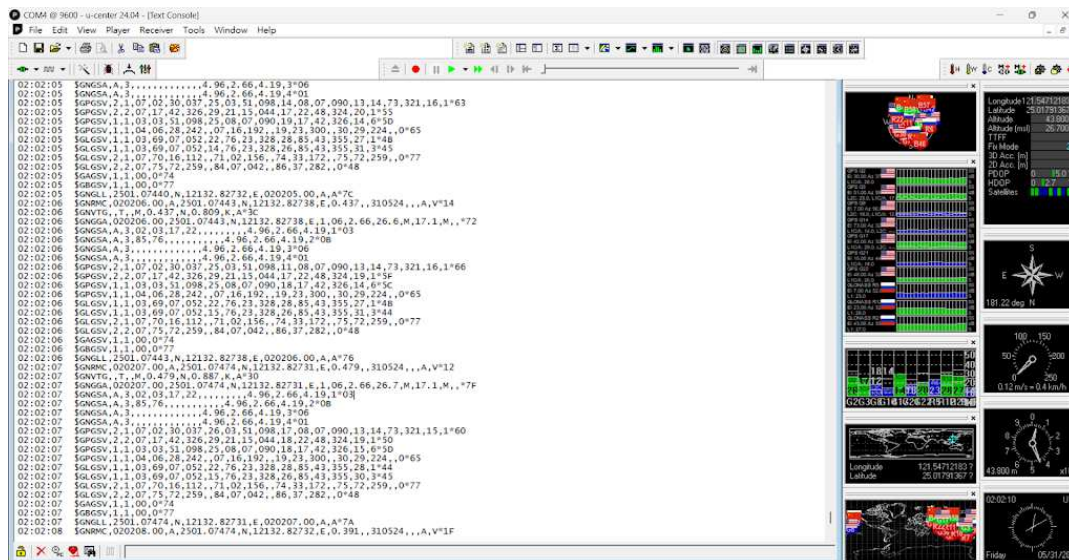


圖 4.2 GPS 軟體操作介面示意圖

4.3 移動模式建構方法

ROS 導航堆疊（ROS navigation stack）是一整組可以讓機器人或自動化載具可以在空間中穩定移動的相關程式，可在 ROS 中運行的機器人提供自主導航能力，示意圖如圖 4.3。它旨在通過整合 Lidar、里程計和 RGB-D 相機等各種感測器，使機器人能夠在動態環境中安全高效地移動。

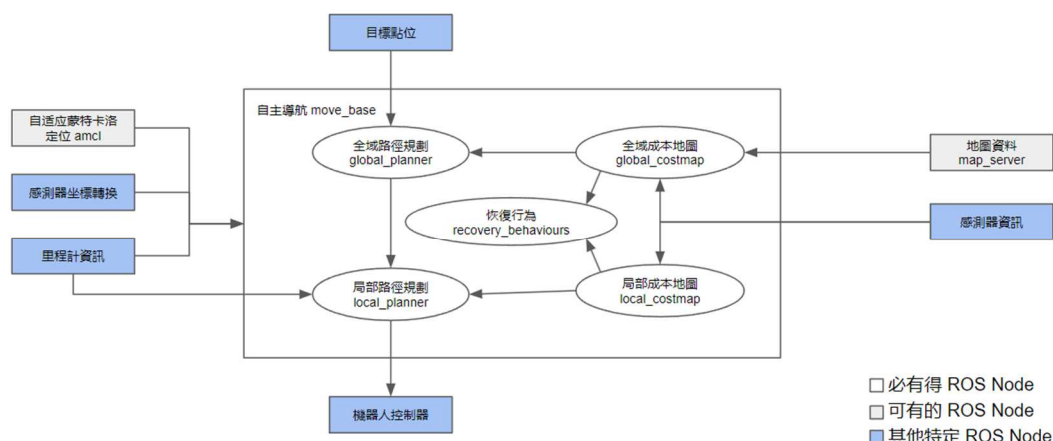


圖 4.3 臺北港港區道路示意圖

導航堆疊包括幾個關鍵組件：

(1) 目標點位

目標點位是指機器人在其環境中試圖達到的特定目標位置或姿態，包括位置（ x 、 y 、 z ）和方向（通常表示為橫滾、俯仰和偏航角度）。目標點位代表了導航任務的期望終點，機器人的主要目標是規劃並執行一條通往該目標的路徑，同時避開障礙物。

(2) 自主導航 Move_base

處理機器人的自主導航的 ROS Node，裡面會包括成本地圖、回復行為、路徑規劃。

(3) 成本地圖（Costmap）

在 UGV 的導航過程中，使用佔有網格（occupancy grid）來表示環境。空間被劃分為網格，每個網格會被賦予一個值，表示是否為障礙。這使得 UGV 能夠清楚地了解周圍的環境，並對其路徑和移動做決策。成本地圖（costmap）是一個重要的組件，根據佔有網格為每個格子分配成本值。這個成本反應了 UGV 在穿越該格子時的困難程度。

成本地圖包含兩種類型：世界成本地圖（global costmap）和局部成本地圖（local costmap），見圖 4.4 世界成本地圖提供 UGV 周圍的高級概述，而局部成本地圖則提供更詳細的視圖，顯示其即時環境。局部成本地圖的大小通常是預先確定的。




圖 4.4 (a) 局部和世界成本地圖 (b) 成本地圖中的膨脹半徑

成本地圖的兩個重要參數為縮放參數和障礙膨脹半徑。縮放參數會根據最近障礙物的距離，對成本進行縮放，以調整成本地圖對障礙物的敏感度；而膨脹半徑則用於在障礙物周圍建立一個安全緩衝區，通過增加靠近障礙物格子的成本值。這確保 UGV 避開障礙物並遵循安全的路徑。這兩個參數需要進行精細調整，以實現最佳導航和避障路徑。

(4) 路徑規劃演算法 (Path Planner)

路徑規劃演算法根據不同的需求和情境，可以分為世界（Global）和局部（Local）兩個類別。

世界路徑規劃演算法的主要功能是生成一條考慮到世界成本地圖和無人地面車輛（UGV）的目的地的路徑。這種演算法通常用於規劃長程或整體導航路徑，以確保 UGV 能夠有效且安全地到達目標點。此外，世界路徑規劃演算法還負責生成 UGV 導航的高層計劃，即確定 UGV 應該經過哪些關鍵點或路徑。

局部路徑規劃演算法的職責是生成一條考慮到局部成本地圖和 UGV 周圍環境的路徑。這種演算法通常用於處理 UGV 在實際運動中所遇到的障礙物和動態變化，以確保 UGV 可以避免碰撞並按照預定計劃安全地前進。局部路徑規劃演算法負責生成 UGV 導航的詳細計劃，包括考慮到 UGV 的物理尺寸和避免碰撞的機器人腳印（Robot Footprint）參數。這樣的參數用於確保 UGV 在實際環境中的移動是可行且安全的。

(5) 恢復行為 Recovery Behaviours

恢復行為（recovery behavior）是一項關鍵功能，可幫助機器人在面對困難或異常情況時恢復正常操作。這些情況包括機器人可能卡住、無法達到預定目標點，或者遭遇導航困難等問題。預設的恢復行為通常包括機器人在原地旋轉 360 度，以試圖解決問題。

如果即使經過旋轉嘗試後，機器人仍然無法規劃到有效的路徑或無法避開障礙物，恢復行為將自動觸發，並導致機器人中止目標點位導航任務。這樣做是為了保障機器人的安全和有效運作。

需要強調的是，恢復行為是一個自動化的過程，其觸發由機器人的控制系統根據當前情況來決定。這樣的功能確保了機器人在面對挑戰時能夠迅速適應，提高了其可靠性和自主性。

(6) 自適應蒙特卡洛定位 AMCL

AMCL(Adaptive Monte Carlo Localization)自適應蒙特卡洛定位，是機器人在二維移動過程中的定位系統，採用粒子濾波器來跟蹤已知地圖中機器人位置，對於大範圍的局部定位問題工作良好。

(7) 感測器坐標轉換

在 ROS 系統中，地圖，機器人，感測器各有自己的坐標。感測器坐標轉換用於描述如何轉換這些相對坐標系統。這個過程允許機器人理解感測器數據在環境中的準確位置和方向。這些資訊對於機器人的定位很關鍵。

(8) 里程計資訊

里程計資訊（通常 ROS Topic 名稱是"nav_msgs/Odometry"）提供機器人在移動時估計位置和方向的重要資訊。這些資料包括機器人位置的 X、Y 和 Z 坐標。這有助於機器人跟蹤其運動，對於導航、控制和定位等任務至關重要。

(9) 地圖資料 Map_server

map_server 是個 ROS Node 用於管理及提供地圖資料給全域成本地圖。map_server 可以讀取的文件格式為.jpg、.png 等圖像格式和.yaml 等 YAML 格式、但最好使用向量圖，如 .dwg，以防格網地圖和圖像像素的比例不相同（對像素圖像進行縮放和旋轉會降低像素品質）。

(10) 感測器資訊

在 ROS 導航系統中，感測器源的設置涉及整合從感測器（例如激光雷達或深度相機）獲取的所有感測器數據。根據感測器類型不同，ROS Topic 名稱也會有所不同。這些數據反映了機器人當前的環

境狀況，並在用於導航之前被轉換為成本地圖（包括局部和全局地圖）。

(11) 機器人控制器

當區域規劃已經算出一條路徑後，便會輸出一個發佈速度的 ROS Topic (名稱爲 /cmd_vel)。這個速度再透過機器人控制器轉成真正對每顆馬達輸出訊號，使馬達轉動，讓機體到達目的地。

4.4 避障測試

在路徑規劃過程中，機器人的移動軌跡（footprint）會定義機器人的物理邊界，使規劃器在產生無碰撞路徑時考慮到機器人的大小和形狀(圖 4.5)。




圖 4.5 基於 UGV 運動模式的 DWA Planner 路徑選擇的可視化

為了處理路徑規劃任務，研究中使用了動態窗口方法（Dynamic Window Approach, DWA）進行規劃。該演算法是一種為行進中的機器人所開發的避障策略，藉由考慮周圍的障礙物和 UGV 的運動學，確保產生一條安全可行的路徑。透過利用局部成本地圖提供的各項資訊，包括為每個網格內的值，DWA 演算法會計算出使用最小成本的路徑(圖 4.4(b))，同時考慮到機器人的允許線性和角速度(圖 4.6)。這可確保了在導航過程中產生的路徑在安全性和效率方面都能達到最大化。

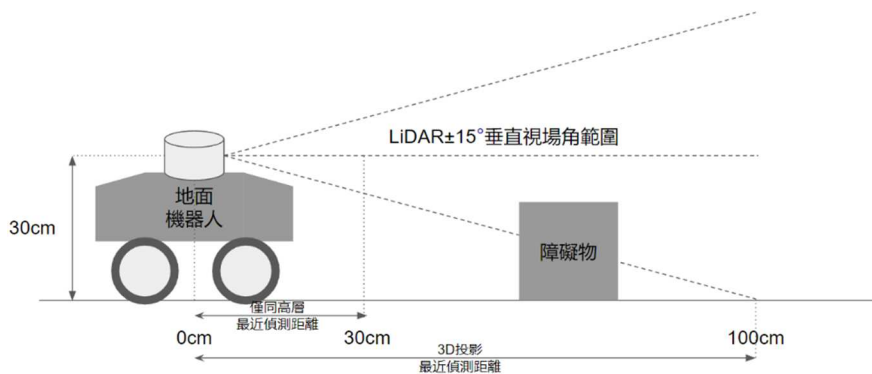


圖 4.6 UGV 避障參數視覺化

UGV（地面無人載具）能夠成功避開靜態障礙物（如圖 4.7 所示），並在動態環境中實現安全導航。UGV 主要的導航步驟如下：

- (1) 感測輸入：使用光達掃描周圍環境，並獲取障礙物位置的點雲數據。
- (2) 建立成本地圖：透過點雲數據構建 2D 或 3D 成本地圖，將環境分為網格，每個網格賦予相應的通行成本。障礙物附近的網格會有較高的成本值。
- (3) 路徑規劃：基於世界路徑規劃演算法，計算從當前位置到目標點的最佳路徑，避開已知障礙物。如果偵測到新的障礙物，則會觸發局部路徑規劃，並使用動態窗口法（DWA）重新規劃局部路徑，繞過障礙物。
- (4) 速度控制：根據路徑規劃結果計算線速度和角速度，並將指令發送至驅動馬達，以推動 UGV 前進。


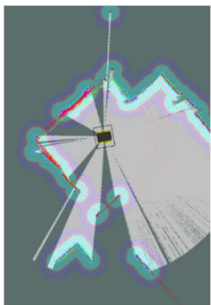



圖 4.7 避障測試結果圖

表 4-2 地圖建構方法比較

特性	Gmapping	Rtab map
地圖類型	2D	2D&3D
計算資源需求	較少	較高
適用範圍	環境變較小場景	複雜場景
構建速度	快	較慢
精度	中等	高
Sensor 類型	Lidar	Lidar & Depth camera
戶外適用性	大範圍開放空間可能無法有效建圖	戶外環境下表現佳，適合大範圍和變化較大的空間
優點	- 低計算資源需求 - 快速生成 2D 地圖	- 支持 3D 地圖構建 - 能結合多種感測器數據，提高精度
缺點	- 僅支持 2D 地圖構建	- 計算資源需求高 - 建構速度過慢
地圖格式比較		

測試結果顯示，藍色線條為 UGV 規劃的路徑，黑色區域代表感測器偵測到的障礙物。UGV 會即時更新其周圍環境資訊，並根據新的地圖和感測數據重新規劃路徑，最終成功避障並抵達目標點。

4.5 地圖建立方法

112 年研究中使用的是 RTAB MAP 做為建圖方法，此方法的優點在於可以建立 2D 或 3D 地圖，對周遭環境改變與障礙物較為敏感，較適用於大範圍的地圖，缺點則是需要耗費較多計算資源。113 年為減輕 UGV 負荷，將地圖建立方法改為 Gmapping，此方法的優點是計算速度快，計算資源量較小，缺點則是只支援 2D 地圖，兩者方法比較如表 4-2 所示。


4.6 感測器測試(氣體、熱紅外)

4.6.1 有毒極易燃氣體感測器

本計畫採 Nevada Nano MPS™ 有毒及易燃氣體感測器裝在 UGV 上。為了測試有毒及易燃氣體感測器，本研究進行了一個小型實驗。這個實驗包含了 4 種不同的情境，第一個是在開放空氣中進行測試，第二個實驗是在封閉空間中測試檢測打火機瓦斯的能力，第三和第四個實驗都涉及使用松香水。在第三個實驗中，松香水被塗抹在封閉空間的牆壁上，而在第四個實驗中，傳感器被放置在松香水瓶口前。更多實驗設置的詳細說明，請參閱圖 4.8 及表 4-3。




(a)實驗 1



(b)實驗 2



(c)實驗 3



(d)實驗 4

圖 4.8 有毒及易燃氣體感測器實驗

表 4-3 有毒及易燃氣體感測器實驗設置

實驗編號	實驗名稱	易燃氣體成分
實驗 01	無易燃氣體之空氣	---
實驗 02	打火機瓦斯	丁烷、丙烷類、石油液化氣
實驗 03	松香水	辛烷、壬烷、苯乙烷、二甲苯

表 4-4 顯示了本次小實驗的結果。總體而言，結果相當令人滿意，可與圖 4.9 做對比，但有一些需要注意的事項：

- 偵測延遲：該偵測器需要一段時間（約 3-5 秒）才能偵測到氣體的%LEL 濃度。這種延遲是正常的操作特性，需在應用中考慮到。

- Gas ID 不正確：有時偵測到的 Gas ID 可能不正確，特別是在開放空氣的情況下。有時會出現 Gas ID 2 或 3，且%LEL 濃度約為 5%LEL 左右。誤差的可能來源可能包括前一次實驗的殘留氣體或傳感器本身的 $\pm 5\%$ LEL 誤差。

表 4-4 有毒及易燃氣體感測器實驗結果

實驗編號	實驗名稱	易燃氣體成分
實驗 01	Gas ID 0 No Flammable Gas	0.00 %
實驗 02	Gas ID 4 Light Gas	39.76 %
實驗 03	Gas ID 4 Light Gas	29.79 %
實驗 04	Gas ID 5 Medium Gas	105.40 %

這些觀察結果提供了實驗性能的有用訊息，並有助於更深入地理解傳感器的行為。在實際應用中，這些特性和誤差應該納入考慮，以確保準確的氣體檢測和評估。

4.6.2 熱紅外感測器

本計畫將 Flir Lepton FS 紅外線熱像儀整合至 UGV 上(圖 4.10)。在整合至 ROS 後，驅動程序將發布熱影像，以及場景中的中心點溫度、最低溫度、平均溫度和最高溫度。熱影像中的中心點溫度將以白色（或黑色，取決於熱點溫度是否高於或低於平均溫度）標記，

藍色表示最低溫度，紅色表示最高溫度。利用這一設置，本研究進行了一項小型實驗，使用 Flir Lepton FS 測量了冷熱表面的溫度，並將其與其他熱像相機如 Flir One Pro 以及我們最初使用的 Flir Vue Pro 進行了比較。在實驗中，熱表面是電磁爐的熱表面，而冷表面則是從冷凍庫中取出的新鮮冷凍雞肉。為避免溫度在時間上發生大幅變化，盡可能迅速進行測試。表 4-5 展示了本次小型實驗的結果。




圖 4.9 (a) 紅外線熱像儀測試目標 (b) 使用 Flir Vue Pro 測試物體表面的溫度

表 4-5 紅外線熱像儀實驗結果

熱像儀型號	熱表面溫度	冷表面溫度
Flir One Pro	111.5°C	-6.9°C
Flir Vue Pro	150.3°C	-0.5°C
Flir Lepton FS	108.5°C	7.1°C

根據表 4-5、圖 4.10 與圖 4.11，不同型號的熱像儀在測試中呈現了不同的溫度測量結果。Flir One Pro 在冷表面溫度方面顯示了相對低的數值，而在熱表面測量上則有相對較高的數值。相比之下，Flir Vue Pro 在冷表面和熱表面的測量結果都較高。最後，Pure Thermal Flir Lepton FS 在冷表面和熱表面的溫度測量上顯示了相對平衡的數值。



(a)



(b)

圖 4.10 (a) Flir One Pro (b) FLir Lepton FS



圖 4.11 Flir Vue Pro 測試結果

4.7 本章小結

本計畫成功在 UGV 自主導航中應用了 ROS 導航堆疊，透過整合本地圖和路徑規劃器等多個模組，在動態環境中展現出安全高效的導航能力；在使用者介面上，RVIZ 控制器提供了直觀的視覺化工具，使感測器數據、機器人姿態及計劃路徑的控制與監測更加便捷；而隨著地圖建立方法的優化，UGV 的計算資源需求減少，反應速度

提升，同時保持原有的避障能力。此外，成功將新的高精度 GPS 接收器整合至 UGV 和 ROS 系統，並在實地測試中顯示出顯著的定位精度提升，尤其在開闊的室外環境中，能夠精確執行航點導航任務。透過地圖建立方法的改進、有效的避障技術及高精度 GPS 系統的應用，UGV 的自主導航能力在多種環境下均有顯著提升，為未來執行更複雜任務奠定了堅實基礎。

第五章、臺中港感測資料自動化辨識技術發展

5.1 舊有標的物

依照各目標特性與後續多時期比對分析所需資訊，過去針對各目標分別進行任一偵測或整合多項偵測模型進行偵測（如表 5-1）。

表 5-1 過去已辨識之標的物

標的物	方法	實施之多時期檢測邏輯	說明
道路標線	實例分割	不同時期道路標線之損壞程度	道路分向線、禁止變換車道線、行車分向線、車道線、停止線、指向線
人手孔蓋	物件偵測	不同時期物體存在與否、物體位置是否發生偏移	以北堤路設施樣式為目標
岸邊設施	實例分割	不同時期存在與否、物體損壞與否	包含車擋、反光板與碰撞墊，以 20-25 號碼頭設施樣式為目標
道路鋪面裂縫	語意分割	以裂縫數量與裂縫寬度統計出路況損壞程度	以北堤路設施樣式為目標
路燈	物件偵測	不同時期存在與否、是否發生變形偏移	以北堤路設施樣式為目標
紅綠燈	物件偵測	不同時期存在與否、是否發生變形偏移	以北堤路設施樣式為目標

5.2 岸邊設施自動化辨識分析

5.2.1 舊有辨識模型

臺中港岸邊設施自動化辨識分析流程，如圖 5.1 所示，岸邊設施辨識物件含車擋、反光板與碰墊等 3 項，偵測的樣式為臺中港 20-25 號碼頭設施樣式。

臺中港所進行之辨識模型分為 2 階段進行。必須先使用語意分割模型 FPN，將圖片區分為海與陸地兩區域，並從中找出岸邊設施的大致位置。而後再將該區域的影像分割出來，變相的將物件放大，並針對切割出來的區域，縱向切分成 4 小份後，使用實例分割模型 Mask R-CNN 進行岸邊設施的自動化偵測，最後合併結果。

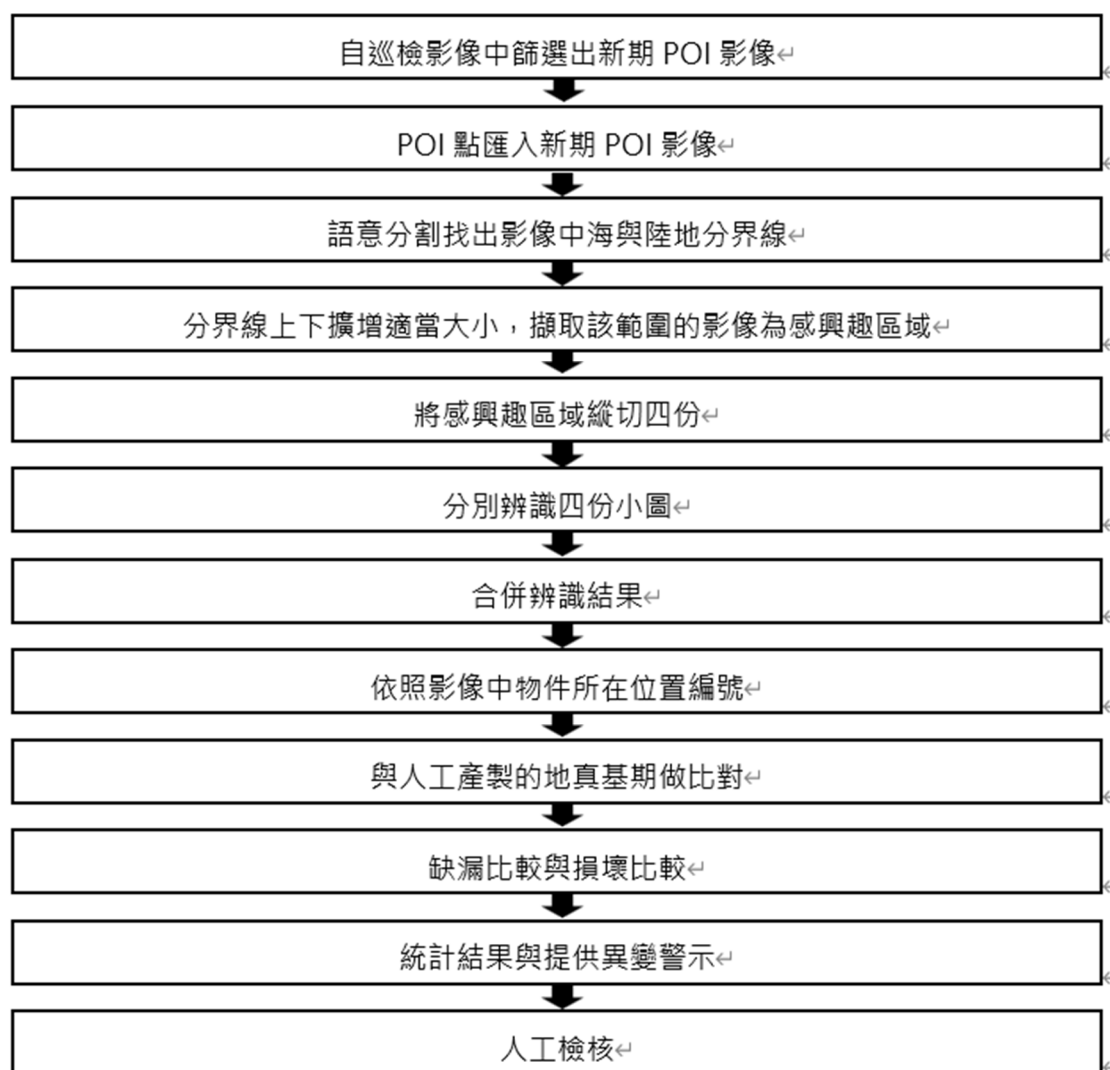


圖 5.1 臺中港岸邊設施自動化辨識分析流程(單張 POI 影像為例)

在模型效能驗證上，使用驗證資料集來進行驗證，得到結果如表 5-2，Bounding Box 的 mean Average Precision(mAP)在 IoU 條件 50%以上為正的條件下，可達到 95.44%；在物件輪廓分割的部分，同樣在 mAP@0.5 的情況下，可達到 95.35%。

表 5-2 岸邊設施 Mask R-CNN 辨識模型統計於驗證資料集之效能

項目	mAP@0.5	mAP@0.75
Bounding Box	95.44%	91.95%
Segmentation	95.35%	91.99%

在臺中港的案例中，透過此方法進行自動化辨識，雖然在驗證資料集中可達到約 90%的全物件平均準確率，但在實際應用到新期的測試影像上時，辨識準確度下降至約 70%，如圖 5.2 與表 5-3 所示，尤其是碰墊的部份，其原因經分析大致為兩點，一是物件受海水遮蔽影響，特別是碰墊在潮位線較高的時候可能一半以上受遮蔽；二是在切割後影像邊緣的物件模型辨識較不穩定，可能是在切割影像時恰好劃過物件，使物體在辨識時體積不完全。



圖 5.2 測試資料模型辨識結果(以臺中港成果為例)

表 5-3 測試資料模型辨識結果統計(以臺中港成果為例)


	各目標物數			
	碰墊	反光板	車擋	總數
實際個數	38	35	30	103
模型發現個數	19	30	25	74
準確率	50%	85%	83%	71%

將臺中港模型套用於臺北港岸邊巡檢影像上，結果如圖 5.3，不論是在語意分割或是在實例分割上，都不及在臺中港的準確，尤其在實例分割上，不同樣態的碰墊難以辨識，在樣態上較為相似的影像中，準確率也僅剩約 50%。

臺中港模型具有兩部分的模型，語意分割與實例分割，要使用在新的地區影像上時需要重新調整，在轉移與維護上較不易。且由於每張 POI 影像的海陸位置不同，兩階段的辨識模式所得到的物件影像坐標要進行整合也不容易，無法發揮 UAV 巡檢拍攝時高重疊率拍攝的優勢。



(a) 語意分割結果



(b) 實例分割結果



(c) 實例分割結果

圖 5.3 臺中港模型套用於臺北港影像上之不同影像分割成果

5.2.2 新模型嘗試

本計畫，嘗試使用近幾年新推出的模型 YOLOv8 進行岸邊設施自動化辨識作業，YOLOv8 為 2023 年 1 月份由 ultralytics 公司發布，是目前最新版的 yolo 演算法。除支援原先的物件偵測外，也提供了能進行實例分割的分支模型。

YOLOv8 其模型架構會針對圖片進行 3 種大小偵測，使模型在偵測小物件上能有更好的表現效果。藉由模型本身的架構設計，使用 YOLOv8 進行岸邊設施自動化辨識時，不再需要透過事前的語意分割找出岸邊設施的大致位置，直接將原始的 UAV 影像輸入到模型之中進行辨識，即可達到良好的辨識結果。

臺北港的岸邊設施中，並無反光板的存在，因此，臺北港的岸邊設施辨識標的物為碰墊、車擋與繫船柱 3 樣。在臺北港的測試區域中各物件的樣態，如圖 5.4 所示。



(a) 四種車擋



(b) 2 種碰墊 (左、中)、1 種繫船柱 (右)

圖 5.4 臺北港岸邊設施各物件樣態

Yolov8 的模型訓練總共使用 162 張巡檢影像，原始影像大小為 8K，標註後將其縮放為長寬 640 像素的影像，並透過模糊、旋轉與裁切進行資料擴增，最後總計有 339 張訓練影像、32 張驗證影像與 17 張測試影像。

使用 Yolov8 做為模型架構進行 100 個 epochs 的訓練，最終訓練出來的模型效能，如圖 5.5，模型損失皆能在多次的訓練後收斂，且最後在驗證資料上的準確率，能達到接近 98%的結果。

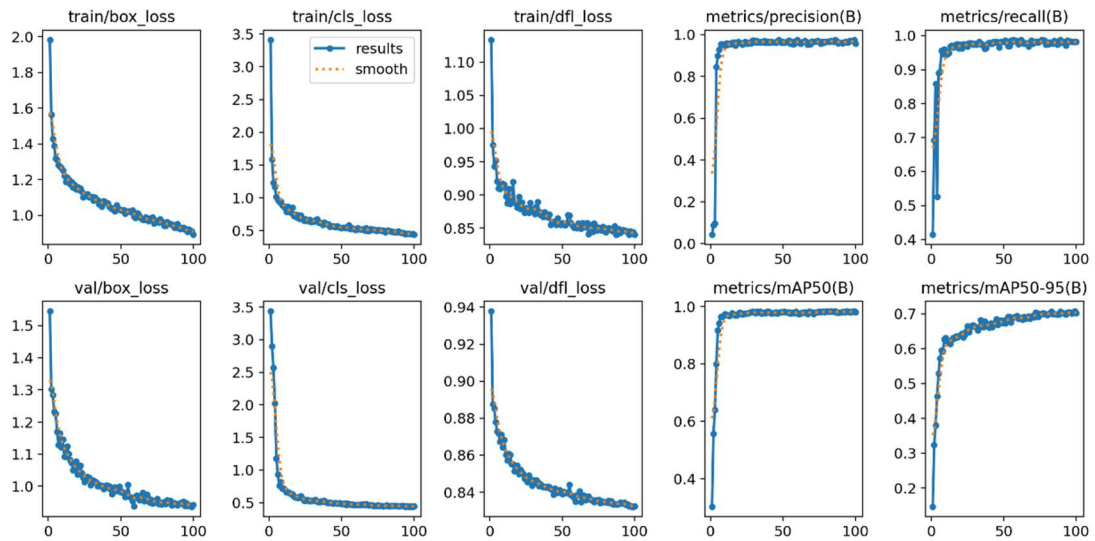


圖 5.5 Yolov8 訓練與驗證的模型效能

模型在驗證資料集中的 32 張影像共計 1044 個物件中，以 IoU 閾值設為 0.5 的全物件平均準確率(mAP@0.5)上可達到 98.4%的準確率。

各物件的辨識中，模型在 117 個繫船柱上有 96.5%的準確率；655 個車擋上有 99.5%的準確率；在 272 個上碰墊則有 99.2%的準確率。模型訓練的混淆矩陣，如圖 5.6。




圖 5.6 臺北港 Yolov8 模型於驗證資料集上的混淆矩陣

5.2.3 辨識流程

使用 YoloV8 的辨識流程，如圖 5.7 所示。

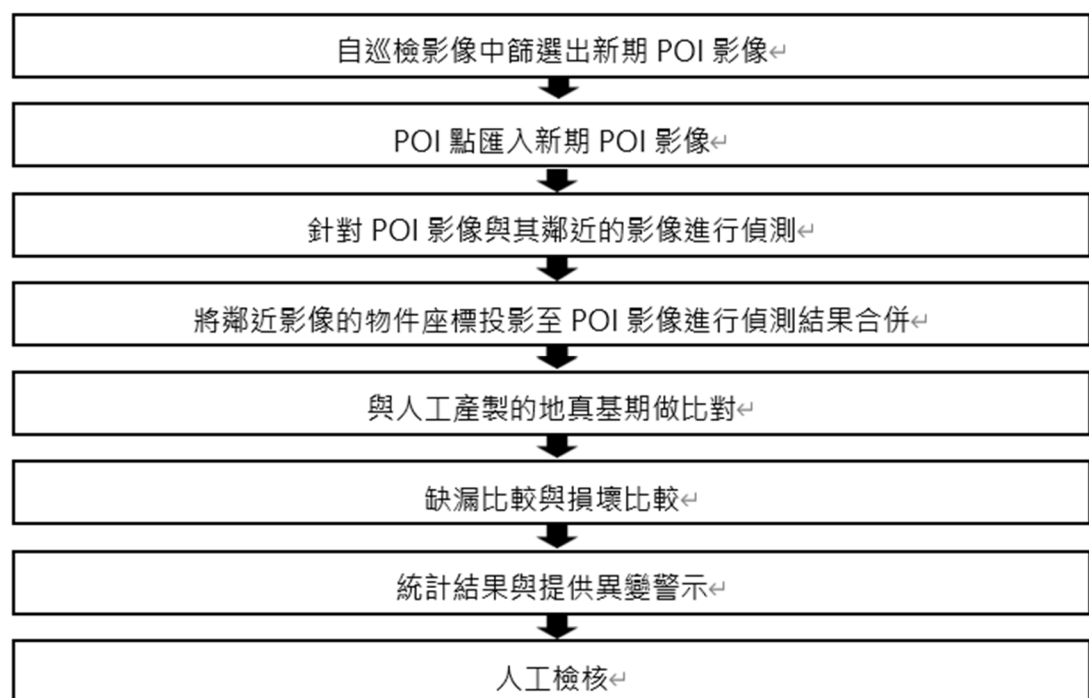


圖 5.7 臺北港模型岸邊設施自動化辨識分析流程(單張影像為例)

首先自巡檢影像中挑選出離 POI 點最近的新期影像與其左右鄰近的影像(如圖 5.8)，共 5 張進行 YOLOv8 物件偵測。而後將各自影像上的辨識結果透過投影轉換(如圖 5.9)將其物件坐標投影至 POI 新期影像上(如圖 5.10)，綠點代表辨識物件框的中心位置，可見同一物件上有多個綠點，在多張影像上被辨識到。以此來發揮 UAV 重疊率高的拍攝方法，即便在單一影像上沒有辨識到物件，只要五張影像中有任意一張影像成功辨識，該物件就能被辨識出來。而後在針對 POI 影像的合併結果與地真基期做異變比較，統計辨識結果，提供給人員檢核。




圖 5.8 POI 影像(中間)與鄰近的影像




圖 5.9 經投影轉換後的左右鄰近影像




圖 5.10 將鄰近影像的偵測結果投影至 POI 影像上

5.2.4 辨識結果

經過多張影像的辨識重疊整合，單一影像的辨識效果可獲得大幅的提升(如圖 5.11)。在各物件的辨識上，原先 28 個碰墊僅有 15 個被偵測到，透過合併後共有 24 個被偵測到，準確率從 53%提升到 85%；19 個車擋中原先 14 個被偵測到，合併後 19 個全數偵測到，準確率從 74%提升到 100%；9 個繫船柱中原先僅有 3 個被偵測到，合併後 9 個全數偵測到，準確率從 33%提升到 100%。




圖 5.11 (a)單一 POI 影像的辨識結果、(b)POI 影像與鄰近影像合併的辨識結果

後續針對地真基期影像進行比對，由於地真基期的影像與每期 POI 影像也略微不同，在比較前須要透過投影轉換將基期影像坐標投影至 POI 影像上(如圖 5.12)。而後比對基期影像的物件框上，POI

影像是否有對應的物件被偵測出來，且偵測到的影像其體積與基期相比是否減少超過閾值(50%)，物件是否作為損壞判斷。




圖 5.12 基期影像投影至 POI 影像

經比對可分析出 POI 影像裡，基期物件被偵測到、基期物件缺失，與在這一期中影像所有找到的物件(如圖 5.13)，供人工檢視。綠色框為基期物件被成功偵測；紅色框為基期物件缺失；綠色點為 POI 影像偵測到的車擋；藍色點為 POI 影像偵測到的碰墊；紅色點為 POI 影像偵測到的繫船柱。




圖 5.13 與基期比對結果

5.3 北堤路路況自動化辨識流程

5.3.1 舊有辨識模型

112 年於臺中港研究案所使用的模型架構為 U-Net，架構如圖 5.14 所示，U-Net(Ronneberger et al., 2015) 是一種基於全卷積網絡 (Fully Convolutional Networks, FCN) 架構下的類神經網路，包括編

碼器 (encoder) 和解碼器 (decoder) 部分。傳統的 FCN(Shelhamer et al., 2015) 在降維過程中容易丟失一些關鍵特徵，因此 U-Net 提出了一個解決方案。它在編碼器和解碼器之間引入了殘差連接 (如圖 5.14 中的灰色箭頭)，以確保在降維時保留所有重要特徵，從而提高了預測性能。因此，目前在語義分割領域，大多數模型都採用了 U-Net 架構。




圖 5.14 U-net 架構(Ronneberger et al., 2015)

訓練該模型使用之資料集為民國 111 年 4 月 14 日於北堤路拍的航攝影像來當作本地資料集，一共人工標記了 21 張照片，如圖 5.15，並將每張照片分割成 70 張 500*500 的小照片，因此總共有 1470 張照片來做訓練，其中 1282 張當作訓練集，143 張當作驗證集，45 張當做測試集。



圖 5.15 本地資料集圖片與對應標註

為了增加資料多樣性，本計畫對影像資料使用了資料強化 (Data Augmentation) 如圖像隨機翻轉 (Random Flip) 或隨機改變圖像對比度

及亮度 (Random Contrast, Random Brightness)，模型訓練平台為 Linux 系統，並有四個 256 GB DDR4 RAM 的 Intel Xeon E5-2620 CPU，及八個 48 GB memory 的 NVIDIA RTX Quadro 8000 GPU。其訓練細節如表 5-4。

表 5-4 舊模型的訓練細節

訓練參數	值
預訓練編碼器	MobileNetV2 (imagenet)
損失方程式	Cross Entropy
優化器	Adam
基礎學習率 (LRbase)	0.0001
學習率調整方程式	$LR = LRbase * (1 - Epochcurrent/Epochmax)^{0.9}$
最大迭代數 (Epochmax)	50
批次大小	3

5.3.2 新模型嘗試

本計畫於臺北港新嘗試的模型為 U-Net++(Zhou et al.,2018)，模型架構如圖 5.16 所示，它對傳統 U-Net 在殘差連結的方面進行了改進。U-Net++在殘差連結上新增了數個節點，以更好地處理淺層和深層之間的特徵傳遞，減少了特徵信息的流失。這種改進使得 U-Net++在檢測細微物體方面表現出色，特別適合檢測較細微的物體，如細小的裂縫等，因此，本計畫嘗試以 U-Net++增進模型表現。




圖 5.16 U-Net++架構

訓練該模型使用之資料集除了 112 年的臺中港圖資外，新增了 113 年於臺北港的航攝影像混合著進行訓練，拍攝位置如圖 5.17 所示，以期模型能夠應付不同場景的路面裂縫，並於去年臺中港的資

料集中刪除了一些非路面的影像。此外，為了因應於今年度新增的檢測目標伸縮縫，標註的種類將分為 3 種，背景、裂縫、以及伸縮縫，如圖 5.18 所示，可以發現臺北港的路面影像顏色較深，因此將 2 種資料混合訓練以強化模型的適應力(d)為新增之伸縮縫標註，此處採用灰色顯示。總共有 1144 張影像，別以 8 : 1 : 1 的比例分為訓練集，驗證集及測試集。




圖 5.17 臺北港正射影像，紅框處即為臺北港測試資料位置




圖 5.18 (a)、(b)臺中港資料，(c)、(d)臺北港資料

除了模型架構外，本年度也嘗試了將預訓練編碼器換成了較大的 Efficientnet-B6(Tan and Le, 2019)強化模型在特徵提取方面的能力，並將損失方程式多加了一個 Lovasz Loss(Maxim et al., 2018)，使訓練過程中模型的預測結果與真實標註的差距，能夠更正確的被評估，使得訓練更有效率，並一樣使用資料強化後在相同的平台上進行訓練，訓練細節如表 5 5。

表 5-5 新模型的訓練細節

訓練參數	值
預訓練編碼器 損失方程式 優化器	Efficientnet-B6 (imagenet) Cross Entropy + Lovasz Loss Adam
基礎學習率 (LRbase)	0.0001
學習率調整方程式	$LR = LRbase * (1 - Epochcurrent/Epochmax)0.9$
最大迭代數 (Epochmax)	50
批次大小	3

5.3.3 辨識流程

由於原始影像尺寸太大，模型在預測時會先將圖片分割成 480*480 的小圖再一一進行預測，最後將結果重新拼成原圖尺寸，過程如圖 5.19 所示，首先模型會將圖片切割為一張張的小圖片再一起輸入模型中，最後將結果重組成原圖的樣子。

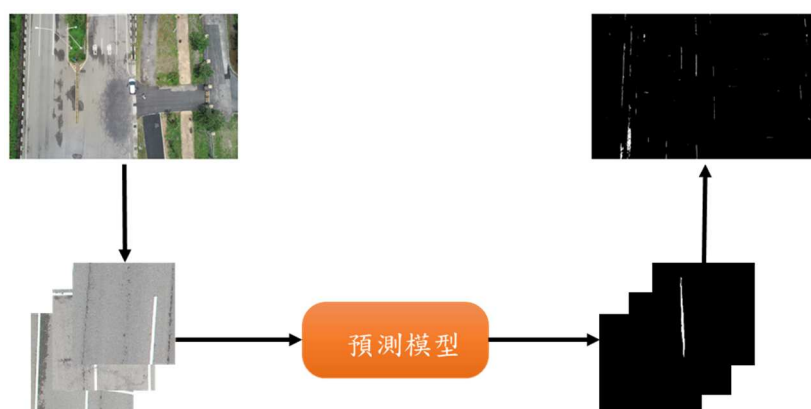


圖 5.19 模型預測流程

5.3.4 辨識結果

此節比較了新模型與舊模型在測試集上的表現，使用了 intersection over union (IoU) 指標進行評估，如圖 5.20 所示，該指標是一種常用於評估圖像分割性能的指標。其嚴謹的以像素級的方式一個一個像素的衡量模型預測的分割區域與實際分割區域之間的重疊程度，值會在 0 到 1 之間，越大則代表重疊度越高，模型預測效能越好，通常應用於物體檢測和語義分割等應用中。




圖 5.20 圖解 intersection over union(IoU)

比較結果如表 5-6 所示，因為舊模型不含伸縮縫的預測種類，因此，僅比較兩個模型在裂縫預測上的性能差異，可以看到在改了模型參數後，新模型在臺中港圖資的表現比舊模型好了 3.8%，這在 IoU 這個指標中算是一個很大的進步，後續相關研究將以新模型為預測工具。

表 5-6 模型表現

IoU(%)		
	背景	裂縫
舊模型	99	33.1
新模型	99	36.9

5.4 本章小結

本計畫將過去在臺中港的自動化辨識流程優化，在模型上使用最近發布的 YOLOv8 模型取代過去偵測使用的 Mask R-CNN 實例分割模型與前一步驟所需的 FPN 語意分割模型，將兩步驟的模型簡化為一步驟，不需再透過語意分割模型，額外切分出感興趣區域並儲存後，再輸入給實例分割模型進行偵測，直接輸入 UAV 原始影像給偵測模型即可，同時也能維持良好的辨識效果。

由於單一步驟的模型簡化輸出格式，使相近影像的結果能被合併統計，除去模型本身的提升外，針對提升辨識成功率上，我們發揮 UAV 巡檢高重疊率的優勢，將多張照片的偵測結果合併，進一步的提升在測試影像上的表現結果。

此節分析了將模型更改為新架構及調整一些訓練參數後是否能對結果有提升，而實驗結果是肯定的，在使用 IoU 的評分方式下，新模型在臺中港圖資的表現提升了 3.8%，代表模型增加了對於裂縫的辨識能力，使其對於路面品質的評估能夠更精確，且模型在訓練時新增臺北港的資料，藉此強化了模型的適應力。

第六章、臺北港感測資料自動化辨識技術發展

本章除新增 3 項標的物外，也延續過去已有標的物進行精進改善，除持續增加訓練樣本外，更針對後續應用面進行優化，整理表於下(表 6-1)。

表 6-1 現有及新增標的物辨識內容綜整表

已有標的物模型			
標的物類別	標的物	辨識模型內容	預計精進
岸邊設施	碰墊	物件偵測與辨識	地理位置定位
	反光板		
	車擋		
	繫船柱		
路面	裂縫		持續偵測並更新
	人手孔蓋		地理位置定位
	變電箱		物件辨識與溫度偵測
碼頭面	伸縮縫		結構線偵測與歪斜計算
堤面	胸牆		
新增標的物件模型(本年度 3 項)			
標的物類別	標的物	辨識模型內容	
路面	坑洞	物件偵測與辨識	
堤面	鋼筋裸露		
碼頭面	鋪面裂縫		

6.1 現有標的物精進

本計畫除持續新增樣本更新現有標的物模型外，更進一步嘗試精進現有標的物辨識成果。針對岸邊設施及路面，精進工作主要分為兩方面：（1）持續偵測並更新：隨著時間推移，臺北港岸邊設施的影像資料數量逐月遞增。透過新蒐集的樣本不斷更新資料集的訓

練資料，可使模型的表現更加穩定和準確。(2) 增加偵測物件的屬性：本期計畫預計透過無人機影像內建的攝影資訊推算出物件的真實地理坐標位置，將巡查結果從以影像為單位轉換為以物件為單位，提升巡查的精細度。此外，針對碼頭面及堤面，也修改了原有結構線偵測方法並進行法線位移判斷。

6.1.1 岸邊設施辨識模型更新

在蒐集更多岸邊設施影像資料後，本研究發現舊有的模型雖然在自有的驗證資料集中表現良好，但對未曾見過得的新期影像預測僅有約五成的準確率（圖 6.1），雖然能透過將多張影像偵測的結果合併來提升單張影像的準確率（圖 6.2），但在模型偵測這一部分，還有不少的提升空間。




圖 6.1 112 年度岸邊設施模型針對新期影像的偵測結果(P-R 曲線)




圖 6.2 多張岸邊設施物件偵測結果合併同一張來提升辨識準確度

在深度學習的訓練過程中，增加模型樣本來提升模型效能是不二法門，本計畫將 112 年所積累的岸邊設施影像全數進行標註後投入資料集中使用。

(1) 資料集

在 112 年的計畫中，使用的資料集全部即僅有 162 張影像，為 112 年 5 月所拍攝的影像資料。將 112 年的資料全數標註後加入資料集中，訓練資料集新增 745 張影像，並透過資料擴增增加到 1836 張；驗證資料集 88 張，測試資料集 64 張；且將 10 月的影像 212 張獨立出來模擬新期影像，最後測試資料集總共 276 張，如圖 6.3 所示。

月份	影像張數	標註進度	
5月	162張	<input checked="" type="checkbox"/>	} 去年度使用的訓練資料集 (共162張)
6月	141張	已完成	
7月	129張	已完成	} 今年度新增的 訓練資料集 (共745張)
8月	155張	已完成	
9月	158張	已完成	
10月	212張	已完成	
			→ 當測試資料 (模擬巡檢後新入影像)

圖 6.3 112 年度岸邊設施影像蒐集之標註與使用情況

(2) 使用模型

模型延續去年度所使用的 YOLOv8 來進行岸邊設施自動化辨識作業，YOLOv8 是 112 年 1 月份由 ultralytics 公司所發布。除支援原先的物件偵測外，也提供了能進行實例分割的分支模型。

YOLOv8 的設計中，模型會針對圖片進行 3 種不同尺寸的偵測，來提升模型在偵測小物件上的效能，相對適合於進行無人機影像的辨識任務。

(3) 訓練細節

使用預訓練模型 yolo8n 進行 50 次的 epoch 訓練，影像尺寸從 4000x3000px² 降低為 1280x960px²，訓練結果如圖 6.4 所示，在 mAP@50 的表現中，經過 50 次 epoch 後在驗證資料集中可達到 0.98 以上的準確度。

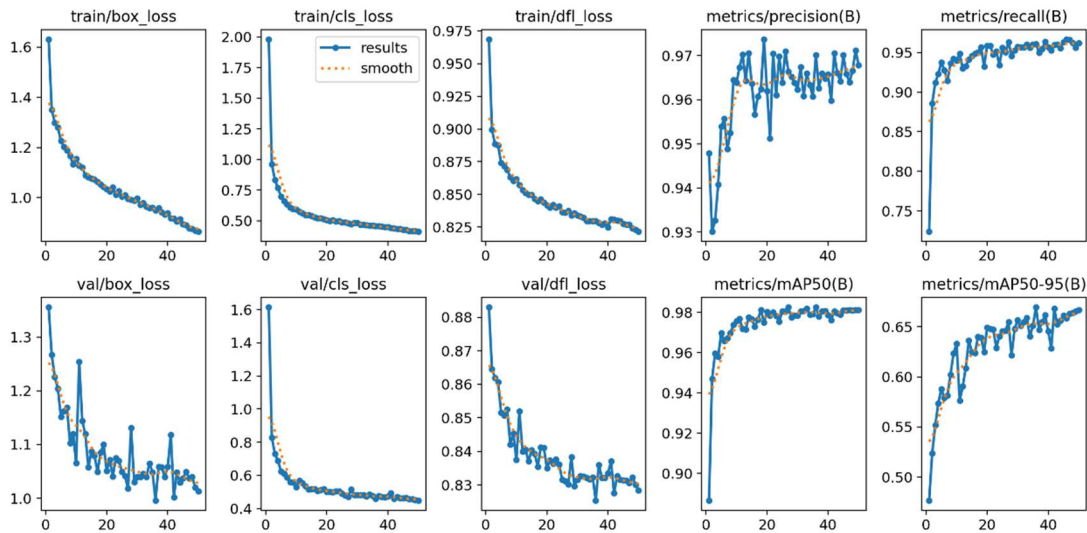


圖 6.4 臺北港新模型的訓練結果

(4) 辨識成果

在驗證資料集的辨識中，本計畫比對增加不同量的影像資料對模型表現結果的差異，融合多個月資料所訓練出來的模型表現有顯著的成長，mAP@50 從原先的 0.357 成長到 0.98 左右，不過成長上有邊際效應（圖 6.5）。



圖 6.5 臺北港 5 月份影像訓練的模型與融合多個月份的模型表現

而在實驗中，發現僅用 5 月份的資料訓練（112 年模型）的模型表現與其他模型相去甚遠。為分析是否是因為訓練張數過少時模型表現效能不佳，比照 112 年的訓練情況，單獨挑選 1 個月份的影像資料進行模型訓練，做為實驗的對照組。

單獨挑選 7 月份的影像(90 張影像)進行訓練，訓練細節比照上述，在驗證資料集上 map@50 卻有 0.867（如圖 6.6、圖 6.7），可見五月份訓練的模型其表現與影像張數較少並無關聯，而是與影像資料本身相關。




圖 6.6 臺北港 7 月份影像訓練的模型表現與融合多個月份的模型表現




圖 6.7 臺北港 5 月份影像資料訓練之模型（左）與 7 月份影像資料訓練之模型（右）

比較 5 月份資料與其他月份的差異，發現在 112 年蒐集資料的過程中，更換過一次無人機，因此，5 月份拍攝的影像的尺寸為 $7680 \times 4320 \text{px}^2$ ，而其他月份的影像尺寸皆為 $4000 \times 3000 \text{px}^2$ （圖 6.8），影像尺寸的差異儘管在人眼中並不明顯，但對於機器來說影像尺寸不同的差異是顯著的。影像尺寸的差異是導致 112 年模型在偵測新期影像上的表現較不穩定的原因，因此，將訓練資料替換成 7 月份，

與其他月份相同尺寸的資料進行訓練後，模型的表現優於 5 月份訓練的模型許多。




圖 6.8 臺北港 5 月份影像(左)與其他月份影像(右)的尺寸差異

(5) 成果驗證

將 10 月份的影像資料做為模擬的新期影像進行預測，在 112 年的舊模型上僅得到 mAP@50 為 0.548 的結果，但透過新增樣本後，新訓練的模型可得到 mAP@50 為 0.988 的結果(圖 6.9)，成長甚多。




圖 6.9 臺北港 10 月份資料的預測結果，左為舊模型，右為新模型

6.1.2 岸邊設施地理位置屬性

112 年自動化巡檢方式中，物件的定位依靠 POI 點的影像，是以影像為主的巡檢結果，因此，相鄰的 POI 點中會有物件重複的問題，雖然可以增加多餘觀測，增加偵測的精確度，但過多的多餘觀測也

會造成使用的不易。因此，今年度透過影像與 UAV 的 GPS 位置計算出偵測物件的真實地理位置，如此不同影像中重複的目標能被歸屬於同一物件，達到物件為主的巡檢結果。

在計算物件的真實地理位置上，本計畫透過正射底圖得知各岸線在世界坐標系上的線向量，而藉由 UAV 所提供的拍攝點 GPS 座標，計算出拍攝點到岸線的距離與向量，求得拍攝點垂直投影至岸線上的點座標，作為影像的中心座標，如圖 6.10 所示。




圖 6.10 如何計算物件的實際座標之示意圖

假定岸邊設施處在一垂直於岸線且法線為拍攝點至岸線的一平面上，在得知影像的中心座標後，即可藉由 Yolo 的偵測結果得知物件在影像上的影像座標，計算與影像的中心座標之差異，並透過地面採樣距離 (Ground Sample Distance, GSD) 將像素單位轉換成實際尺寸，如此可推算出物件的實際地理座標，計算公式如下：

$$\begin{aligned} \text{物件座標} &= \text{中心點座標} \\ &+ \text{GSD} \times \text{物件與中心點的水平距離} \times \text{岸線單位向量} \end{aligned}$$

由於拍攝時受風與航線影響，每次拍攝與岸線的距離並非一致，地面採樣距離並不一致，因此再計算地面採樣距離時，本計畫以物件尺寸進行反推，透過物件偵測找出影像中的繫船柱，統計其平均的像素寬度，而根據臺北港營運處所提供的資料，臺北港岸邊的繫船柱左右寬度為 90 公分，透過這兩者便可得知每張影像的地面採樣距離，進而去計算出每張影像中偵測到的物件的實際地理座標位置，在規劃的巡檢航線上，本計畫計算出的 GSD 約落在 35mm 上下。

本計畫在操作中發現距離影像中心點越遠的物件所計算出來的座標位置與實際座標差異越大(如圖 6.11 所示)，其原因是隨著離影像中心點距離越遠，地面採樣距離的誤差會被放大，導致在影像邊緣的物件與實際座標的經緯度最多可分別差至 10 公尺，而在影像中心點附近的則可以保持在 3 公尺左右的誤差。

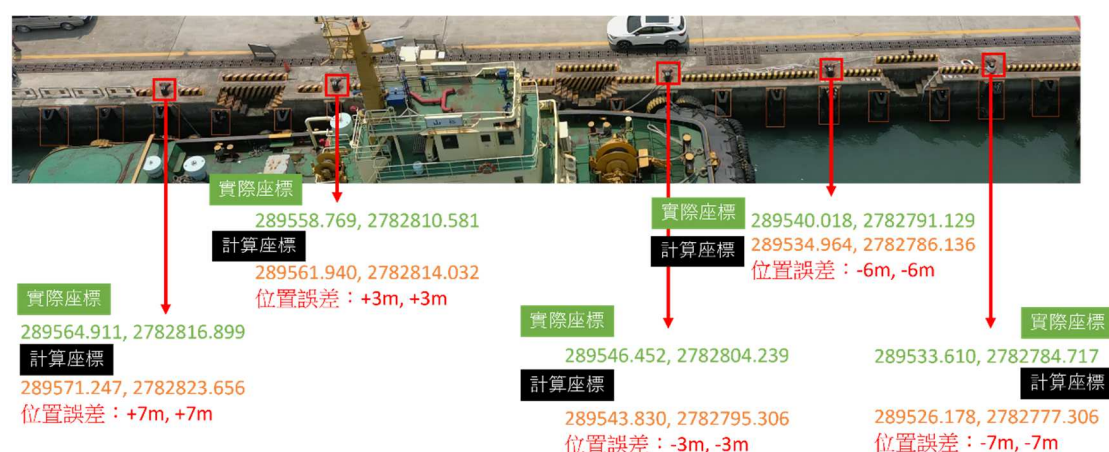


圖 6.11 物件越遠離影像中心點其座標誤差越大

根據上述的性質，在計算每張影像所得到的物件座標時，僅考慮在影像中心區域左右各 25% 的物件，來降低座標的計算誤差。而由於巡檢時是採取重疊率高於 50% 的方式拍攝，所以即便只採取每張影像的中間物件也能涵蓋到全部的物件。

將岸線 POI 點的所有影像與其偵測結果依上述方式計算物件的實際座標，並且與經由正射影像所得出的物件實際座標進行比對，若有與座標距離在 5 公尺內的物件座標被計算出，代表該次巡檢中該物件有被找到。比對全部該有的岸邊設施與全部的偵測結果後，

可統計出岸線有哪些物件並未在這次的巡檢中找到，並提供距離該物件最近的 POI 點供使用者進行 2 次檢驗，使用者只須再檢查系統所提供的 POI 點，確認該 POI 影像中的偵測結果是真的設施有缺漏或只是模型並未偵測到，就能完成巡檢任務(如圖 6.12)。

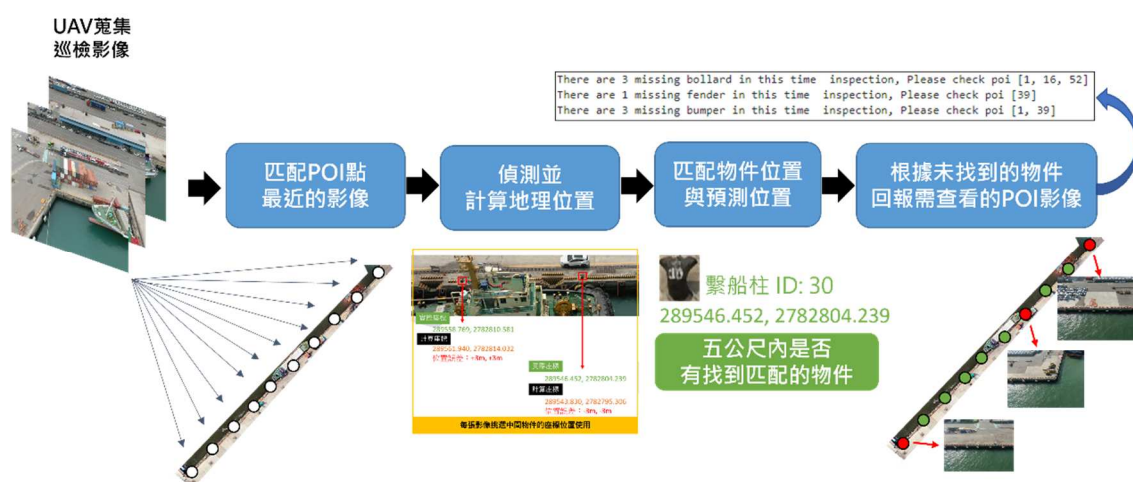


圖 6.12 岸邊設施的地理定位與巡檢邏輯流程圖

6.1.3 變電箱辨識模型更新

(1) 資料集

變電箱偵測在現代電力系統的管理和維護中扮演了至關重要的角色。這個過程不僅有助於確保供電的穩定性，還有助於減少潛在的故障和安全風險。本計畫將深入探討一個完整的變電箱偵測流程，包括影像資料蒐集、影像資料標註、模型訓練、模型偵測成果。研究流程的第一步是影像資料的蒐集。需要從實際場景中蒐集大量的變電箱影像，這些影像可能包括不同天氣和光線條件下的變電箱照片。訓練資料集為113年蒐集影像(圖 6.13)與112年蒐集影像(圖 6.14)。其中本年度蒐集了更多不同拍攝角度之變電箱熱影像。




圖 6.13 113 年度新蒐集之變電箱影像

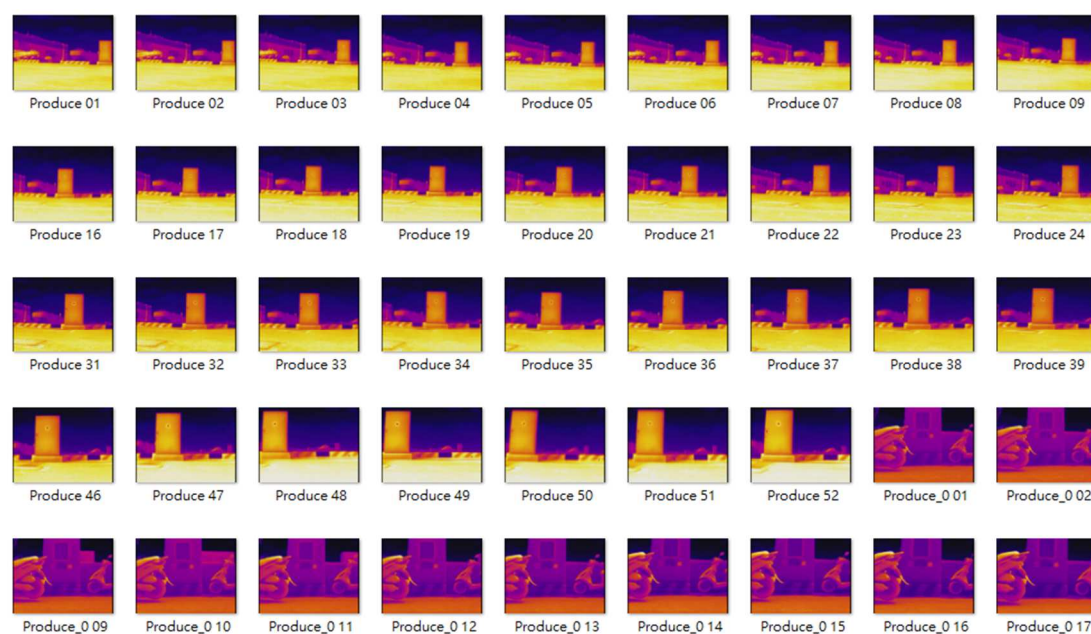


圖 6.14 112 年度變電箱影像

(2) 使用模型

本計畫的變電箱物件偵測，運用最新的深度學習技術 YOLOv8 模型。YOLOv8 採用的影像可以是不同尺寸進行訓練，使其成為廣泛應用的多功能工具。然後，影像經過神經網路的特徵提取過程。

這個網絡經過設計和訓練，擅長識別和突顯圖像中最相關的特徵。YOLOv8 的優勢在於，它不僅可以在單一尺度上檢測物體，還可以同時在不同尺度上進行物體檢測，確保能夠有效識別大大小小的物體，YOLOv8 之架構圖如圖 6.15。

YOLOv8 在物件偵測中的關鍵是其使用的 bounding boxes。這些 bounding boxes 幫助算法對特定網格單元內的物體位置和大小做出正確的預測。通過利用 bounding boxes，YOLOv8 提高了其準確性和精確性，進一步增強了對影像中物體的識別能力(Aboah et al 2023)。透過標準化的模具，幫助 YOLOv8 確定它所遇到的物體的形狀和大小，有助於更準確的預測。除了識別物體及其大小外，YOLOv8 還額外進一步對所偵測到的物體進行分類並賦予信心分數。對於每個它發現的物體，YOLOv8 提供對該物體可能是什麼的猜測（例如本案分類不同型態的變電箱），並量化了對該猜測的信心程度。

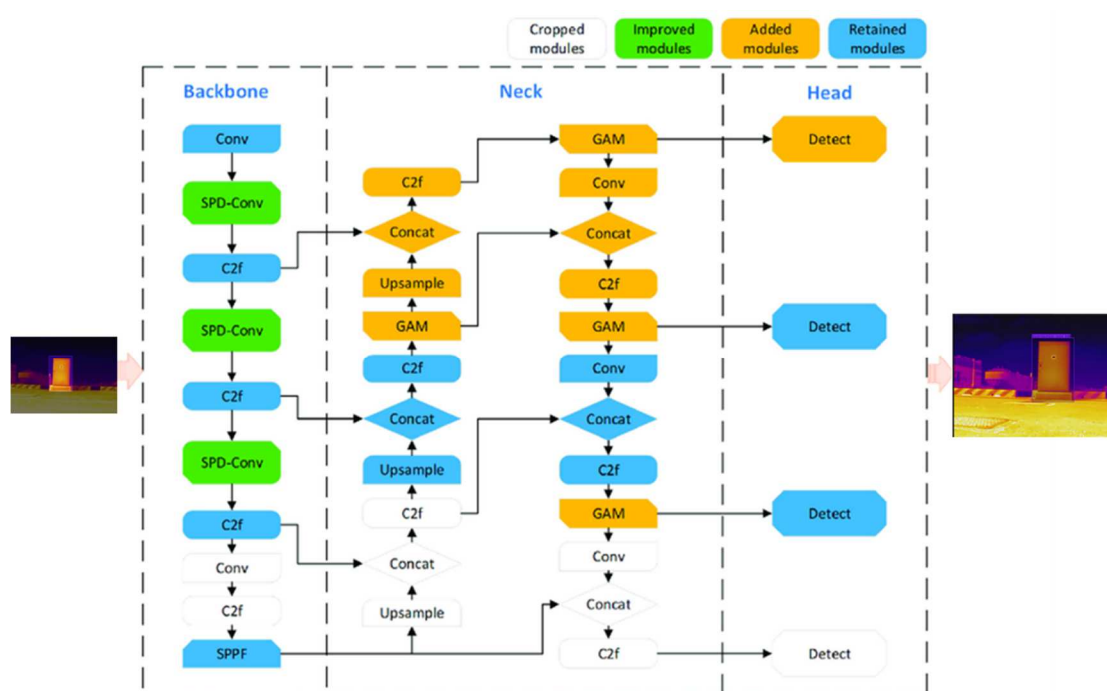


圖 6.15 YOLOv8 物件辨識(變電箱)架構圖(Aboah et al 2023)

(3) 訓練細節

本計畫採用 YOLOv8 模型進行訓練，並使用 567 張訓練影像，同時運用影像增強技術(Data Augmentation)，以擴充訓練集，提高模型的泛化性（generalization ability）。訓練資料集被分為 70%的訓練資料（Training Set）、20%的驗證資料（Validation Set）以及 10%的測試資料（Test Set）。模型的訓練參數如表 6-2 所示，包括 epochs 設定為 200，batch size 為 8，學習率為 0.0001，IoU（Intersection over Union）設為 0.5，以確保模型在訓練過程中能夠達到良好的收斂。

表 6-2 變電箱模型訓練參數表

模型參數	設置數值
Epochs	200
最大 Epochs	200
Batch Size	8
Learning rate	0.0001
IoU	0.5

(4) 辨識成果

根據提供的訓練成果(如圖 6.16 與表 6-3)，平均精度均值（mAP）高達 93%，這表示該模型在偵測變電箱方面的準確性非常高。mAP 是一個綜合性能指標，綜合考慮了模型的準確性和召回率。一個高 mAP 值代表了模型在不同情景下的穩定性，即使在各種場景中，模型也能夠保持高水準的物件偵測能力。精度（Precision）達到了 82%。這表示當模型報告某個物件存在時，有 82%是正確的，而不是誤報。最後，召回率（Recall）達到了 94%。召回率表示模型能夠成功偵測出實際存在的變電箱的能力。在這個情境下，94%的召回

率意味著模型幾乎可以找到所有存在的變電箱，僅有極少數的變電箱未被偵測到。

表 6-3 變電箱型訓練成果表

項目	mAP	Precision	Recall
變電箱	93%	82%	94%

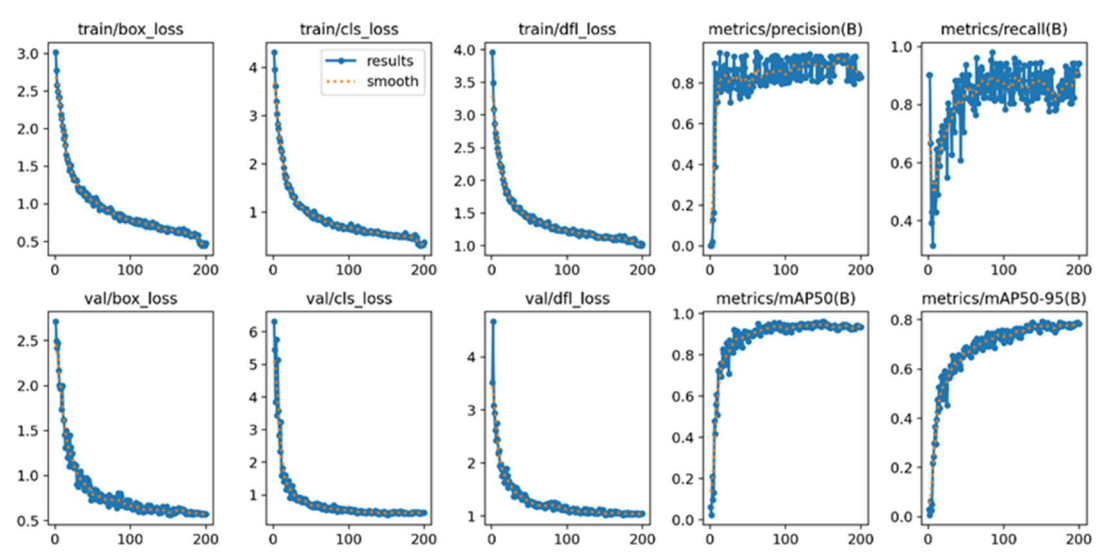


圖 6.16 變電箱模型訓練成果圖

(5) 成果驗證

在完成變電箱的辨識後，如圖 6.17 隨機選取了 4 個不同的例子，完全未參與任何模型訓練與驗證。並對其進行了熱影像的溫度偵測。結果顯示，變電箱偵測模型表現出了相當高的準確度，分別為 0.9 (90%)、0.9 (90%)、0.5(50%)和 0.3(30%)。其中可以由成果發現，在不同變電箱角度及尺度下，都能成功偵測。但在距離太近或太遠的偵測的信心指標會較低(0.5 與 0.3)。而距離適中無論任何角度都能成功偵測(0.9 與 0.9)。




圖 6.17 變電箱實際成果驗證

6.1.4 胸牆結構線偵測模型更新

112 年度的結構線偵測僅使用霍夫直線，導致結果易受影像雜訊影響，而精度不高，無法計算出準確的斜率進行判斷。為此，本年度首先更新了結構線偵測模型，並在此基礎上開發了後續的歪斜判釋等精進功能。此外，該結構線偵測模型也應用於伸縮縫法線偵測，為今年度新增的鋪面裂縫辨識奠定了基礎。

研究流程如圖 6.18 所示，首先會先取得道路拍攝的無人機影像，再經過 YOLOv8 模型取得胸牆法線的影像遮罩，接著使用霍夫直線

預測胸牆走向，再透過線性方程式，計算胸牆法線是否發生錯位，同時計算胸牆兩側距離，針對各個 POI 拍攝的影像進行保存與視覺化呈現。



圖 6.18 胸牆法線預測及地理定位流程圖

(1) 資料集

本次模型使用影像資料集分配(如圖 6.19)，分別為 112 年 10 月 A 區影像共 88 張、113 年 4 月 A 區影像 40 張、2024 年 8 月影像 74 張，共 202 張影像，影像解析度為 3000 x 4000，GSD 約為 0.67 cm/pixel，其訓練影像如圖 6.20 所示。




圖 6.19 港區資料集分布圖




圖 6.20 A 區胸牆訓練影像

(2) 使用模型

本計畫將採用基於 YOLOv5 改進的 YOLOv8 模型，與 YOLOv5 相比，具有更少的參數和更好的特徵提取，並使用多尺度特徵融合，將 backbone 不同階段的特徵圖融合增強特徵表現能力。

(3) 訓練細節

堤面胸牆裂縫的標記如圖 6.21 紫色範圍，當裂縫遇到障礙物時則會分段。在影像當中的胸牆法線所示，依照像素為單位透過 polygon 的方式進行標註，標註完成後影像資料集總共標記類別數量為 955，在訓練過程中會將影像以 7:3 的方式切割影像資料集，故標記類別數量訓練及驗證集分別為 669 與 286。在訓練集中每張影像所包含的類別數量，如圖 6.22 所示，大部分影像集中於 1 個類別數量/圖片。



圖 6.21 訓練樣本標記示意(堤面胸牆為紫色部分)




圖 6.22 標記類別數量統計直方圖

模型訓練使用 100epochs、batch_size 設定為 16、影像大小為 1024、pretrain_model 使用模型深度較輕的 YOLOv8n-seg 能夠使得模型在訓練學習過程較快速並同時保有高精度的預測表現，學習率設定 0.0001 避免模型更新過於激烈，從而提升模型穩定性與準確性、momentum 設定 0.9，訓練影像有 6862 張(70%)，驗證影像為 2941(30%)。訓練完 300 回影像後，最終成果如圖 6.23 在胸牆裂縫偵測上 mAP50 表示當物件的預測框與實際框的 IoU（交並比）大於等

於 0.5 時，模型的平均準確率預測達到 0.831，Recall 指被成功檢測到的目標數量佔總目標數量的比例為 0.763，驗證資料集 precision 為 0.85、recall 為 0.73、MAP50 為 0.784，由圖 6.24 所示在正規化混淆矩陣中，胸牆法線預測正確比例為 0.76。




圖 6.23 法線側模型訓練過程




圖 6.24 胸牆法線、伸縮縫、裂縫之正規化混淆矩陣圖

(4) 霍夫直線預測法線

為了取得胸牆在影像中的走向及變化情形，需要採用霍夫直線來進行直線預測，霍夫直線的原理是透過在影像空間坐標系當中與

影像參數坐標系之間的轉換，在影像空間坐標系的點位在參數坐標系中呈現為波函數的形式，若當複合點位存在於空間中能夠形成直線則在參數坐標系下則會有波的重複點位存在，將相交點映射到空間坐標系上則能夠預測影像在空間上存在的直線，然而在目前多數霍夫直線預測的應用上，容易受到影像當中過多的資訊干擾若未經過模型預測的過程直接對影像採用霍夫直線預測，則影像當中會出現過多的直線預測，無法提取出胸牆直線的預測成果，因此採用遮罩進行霍夫直線預測，如圖 6.25 所示，透過 YOLOv8 產製的法線遮罩能夠將影像中雜訊去除，保留目標物，再透過霍夫直線預測，獲取在影像中法線的長度、走向...等資訊。




圖 6.25 胸牆法線遮罩進行霍夫直線預測影像(左)胸牆法線預測遮罩
(右)霍夫直線預測

(5) 辨識成果

在胸牆的檢測上(圖 6.26)，目前已能正確分配各個 POI 的無人機影像，將模型預測的成果繪製於 POI 上，並能夠針對各個 POI 是否發生錯位透過霍夫直線與 YOLOv8 模型遮罩進行預測，預測成果將會由 3 個顏色顯示，分別為紅色(異常)、綠色(正常)與橘色(無偵測)，偵測成功影像會如圖 6.27 所示，綠色區域為繪製胸牆的範圍，輔助在判釋時能夠清楚看出預測成果。

經過錯位檢測過後，每張影像會保存至相對應該伸縮縫像素值的 POI 位置，因此每個 POI 會有存放 3 個資料夾，分別為 img、record 與 visualize 資料夾，預測完成果影像會存放在 img 資料夾中，並將預測成果存成 json 檔，最終會評估所有的預測影像，若是發生異常影像超過 2 張時，則會輸出異常影像，若是皆為正常影像，則輸出正常影像，若無預測的話，則輸出無預測影像，最終平台上呈現影像為 visualize 資料夾內的影像，並將該對應顏色存於對應 POI 的 ICON 中。




圖 6.26 20240529 資料集偵測影像



圖 6.27 胸牆在平台上 POI 及樣態呈現

平台上的胸牆位置如圖 6.28 所示，在 A 區(道路)共 34 個 POI。

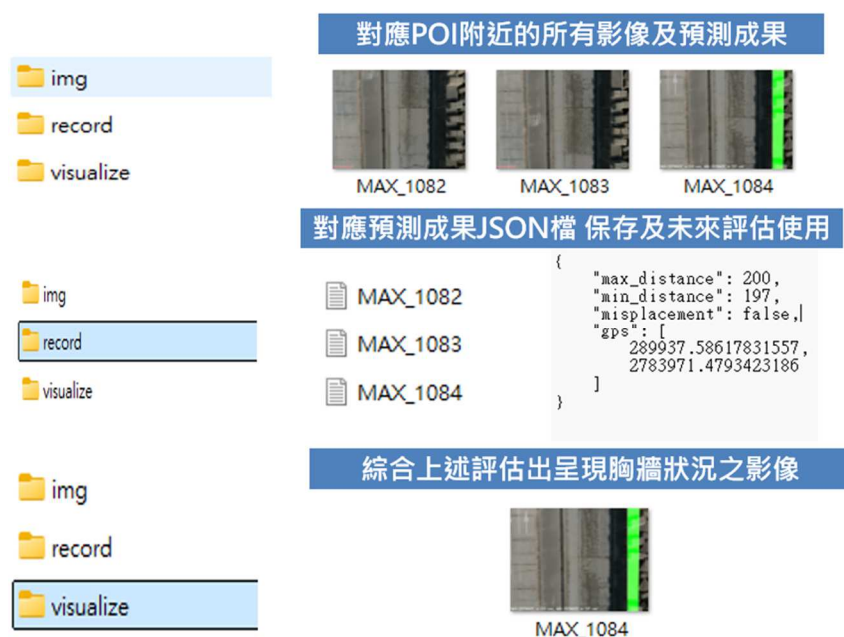


圖 6.28 平台上影像呈現流程

(6) 成果驗證




圖 6.29 預測成果分類

在目前預測成果中遇到 3 種預測狀況，分別為一般情形、無預測以及錯位，一般情形為成功檢測到兩條邊緣線並且確認沒有錯未發生，無預測為僅偵測到一條邊緣線或無偵測而錯位為偵測到有線段未重合時會分類為錯位，在目前成果中(圖 6.29)，多數胸牆皆屬於

一般情形，有少部分錯位情形，經人員查驗過後推估屬於正常情形，未來將會加入 A 區更多區域的胸牆，納入更多可能情況並加以修正。

6.1.5 碼頭面伸縮縫偵測模型更新

伸縮縫偵測模型延續胸牆法線模型流程，並加入地理定位方法，以檢測每條伸縮縫的狀態。研究流程如圖 6.30 所示，首先會先取得道路拍攝的無人機影像，再經過 YOLOv8 模型取得道路伸縮縫的影像遮罩，同時透過將拍攝區域的正射底圖範圍與無人機影像進行 SIFT 計算取得兩張影像之間的特徵點，若是在匹配過程中發生異常，則會重新調整匹配參數，再次進行匹配，直到成功匹配後將預測後的伸縮縫遮罩投影至正射底圖上，獲得預測後的伸縮縫遮罩在實際物空間的位置，接著再利用霍夫直線檢測各個 POI 下的伸縮縫是否出現相交異常的情況，並將成果紀錄於平台中。

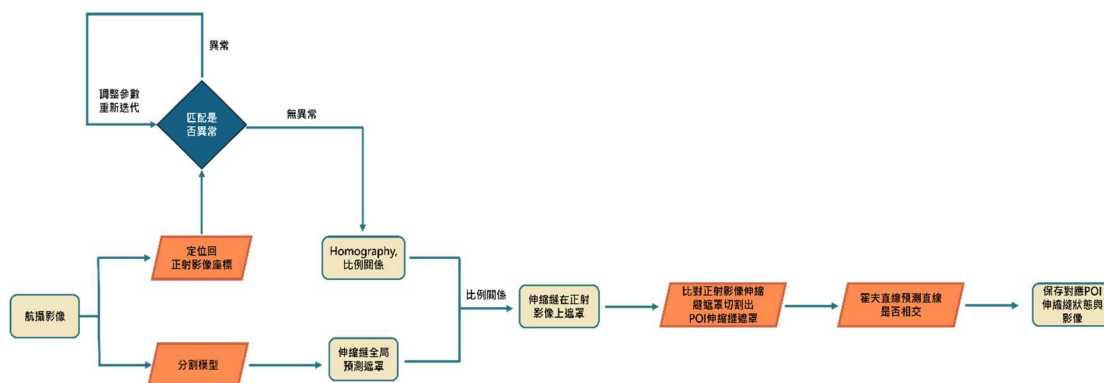


圖 6.30 伸縮縫預測及地理定位流程圖

(1) 資料集

本次模型使用影像資料集分配分別為 112 年 10 月 A 區影像共 88 張、113 年 4 月 A 區影像 40 張、113 年 5 月 D 區影像 100 張、2024 年 7 月影像 74 張、2024 年 8 月影像 74 張共 376 張影像，影像解析度為 3000 x 4000，GSD 約為 0.67 cm/pixel，該區伸縮縫影像，如圖 6.31 所示。圖 6.32 為所訓練資料集中的各樣態分布影像，不同區域的伸

縮縫特徵、顏色、區塊距離、鋪面完整度也略有不同，透過增加不同的伸縮縫樣態提高模型的泛用性。




圖 6.31 A 區道路伸縮縫圖




圖 6.32 各區域伸縮縫影像(左上)(右上)(左下)A 區伸縮縫影像(左下)D 區伸縮縫影像

(2) 使用模型

堤面伸縮縫與馬頭結構線之差異僅在剛興柔性材質的差別，因此，模型使用上同章節 6.1.4(2)，在模型上區分成兩種類別。

(3) 訓練細節

在影像當中的伸縮縫樣態如圖 6.33 所示，依照像素為單位透過 polygon 的方式進行標註，標註完成後影像資料集總共標記類別數量為 2720，在訓練過程中會將影像以 7:3 的方式切割影像資料集，故標記類別數量訓練及驗證集分別為 1904 與 816。在訓練集中每張影像所包含的類別數量如圖 6.34 所示，大部分影像集中於 2-7 個類別數量/圖片。




圖 6.33 伸縮縫標註樣態展示




圖 6.34 標記類別數量統計直方圖

(4) 辨識成果

同章節 6.1.4(4)。

(5) 投影定位方法




圖 6.35 無人機影像對應正射底圖

為了獲取拍攝無人機影像於正射底圖的真實地理對位，必須取得無人機拍攝影像與臺北港正射底圖的轉換關係，以獲得在實際物空間上伸縮縫的真實地理定位位置。因此，必須先切割出如圖 6.36 所示，A 區與 F 區的正射底圖，正射底圖 GSD 為 2.5cm/pixel，將各個區域分別切割也能夠節省在計算對位中的運算資源。




圖 6.36 正射底圖(左)A 區(右)F 區

接著，藉由 Homography 矩陣計算得到兩張影像之間姿態轉換的關係，計算過程如下：

假設圖片為 I_1 及 I_2 ，對應的特徵點為 P_1 及 P_2 ，而此特徵點落在三維空間中的平面 P 上，並假設此平面的方程式如式(6-1)：

$$n^T P + d = 0, \frac{-n^T P}{d} = 1 \quad (6-1)$$

把此式帶回至 pinhole 相機模型，如式(6-2)：

$$p_2 \cong K(RP + t), p_1 \cong KP \quad (6-2)$$

整理過後可以得到式(6-3)：

$$p_2 \cong K(R - \frac{tn^T}{d})K^{-1}p_1 \quad (6-3)$$

將中間的部分寫成 H 得到式(6-4)

$$p_2 \cong Hp_1 \quad (6-4)$$

式(6-4)為 Homography 矩陣與兩張圖片上對應的特徵點關係式，將式(6-4)展開後得到式(6-5)：

$$\begin{bmatrix} u_2 \\ v_2 \\ 1 \end{bmatrix} \cong \begin{bmatrix} h_1 & h_2 & h_3 \\ h_4 & h_5 & h_6 \\ h_7 & h_8 & h_9 \end{bmatrix} \begin{bmatrix} u_1 \\ v_1 \\ 1 \end{bmatrix} \quad (6-5)$$

令 $h_9 = 1$ ，得式(6-6)、(6-7)

$$u_2 = \frac{h_1 u_1 + h_2 v_1 + h_3}{h_7 u_1 + h_8 v_1 + 1} \quad (6-6)$$

$$v_2 = \frac{h_4 u_1 + h_5 v_1 + h_6}{h_7 u_1 + h_8 v_1 + 1} \quad (6-7)$$

經整理得式(6-8)、(6-9)

$$u_2 = h_1 u_1 + h_2 v_1 + h_3 - h_7 u_1 u_2 - h_8 v_1 v_2 \quad (6-8)$$

$$v_2 = h_4 u_1 + h_5 v_1 + h_6 - h_7 u_1 u_2 - h_8 v_1 v_2 \quad (6-9)$$

故每一組對應特徵點可以共線，如式(6-10)

$$\begin{bmatrix} u_1 & v_1 & 1 & 0 & 0 & 0 & -u_1 u_2 & -v_1 u_2 \\ 0 & 0 & 0 & u_1 & v_1 & 1 & -u_1 v_2 & -v_1 v_2 \end{bmatrix} \begin{bmatrix} h_1 \\ h_2 \\ h_3 \\ h_4 \\ h_5 \\ h_6 \\ h_7 \\ h_8 \end{bmatrix} = \begin{bmatrix} u_2 \\ v_2 \end{bmatrix} \quad (6-10)$$

最終計算結果如式(6-10)，又稱 Direct Linear Transform(DLT)，計算後可以再計算出旋轉矩陣 R 與平移向量 t 轉換，而特徵點的取得使用尺度不變特徵變換匹配算法 Scale Invariant Feature Transform(SIFT)計算。

SIFT (Scale-Invariant Feature Transform) 被視為一種影像特徵描述子，簡單來說就是從一張影像中找尋出重要或獨特的特徵點，並透過這些特徵點來表示整張影像。SIFT 技術的特點在於其具備標度和旋轉不變性，這意味著它能夠偵測同一物體在不同尺度和旋轉下的特徵，即使物體會因為在不同位置、不同距離或角度下看起來不同，但是 SIFT 技術仍能有效地將它們描繪出來。

為了解決一張影像中可能會有多個物體或場景，SIFT 算法會先找出關鍵點 (keypoints)，也就是在影像中具有顯著變化的特徵點，這些特徵點在整個影像中都是獨特的，通常是色彩、紋理、邊緣、角度等方面的變化都非常明顯，而且對於影像的旋轉和縮放都不會影響到這些特徵點的位置和大小。SIFT 技術會以這些特徵點為基礎，構建出一個高級的特徵向量，以此來描述物體的特徵。

正射底圖與無人機影像匹配區域的影像，會先從輸入的目標影像(無人機影像)的 exif 資訊中取得該影像的 GPS 座標，接著將 GPS

座標投影至正射底圖上找到對應的位置，以 GPS 座標為原點切割出 2000x2000 的範圍，得到對應目標影像的局部正射底圖區域，進行 SIFT 匹配，如圖 6.37 所示，匹配後特徵點將會計算 homography 矩陣，計算目標影像與切割的局部正射底圖的轉換關係，在匹配過程中可能會遇到匹配錯誤的情形，如圖 6.38 所示。

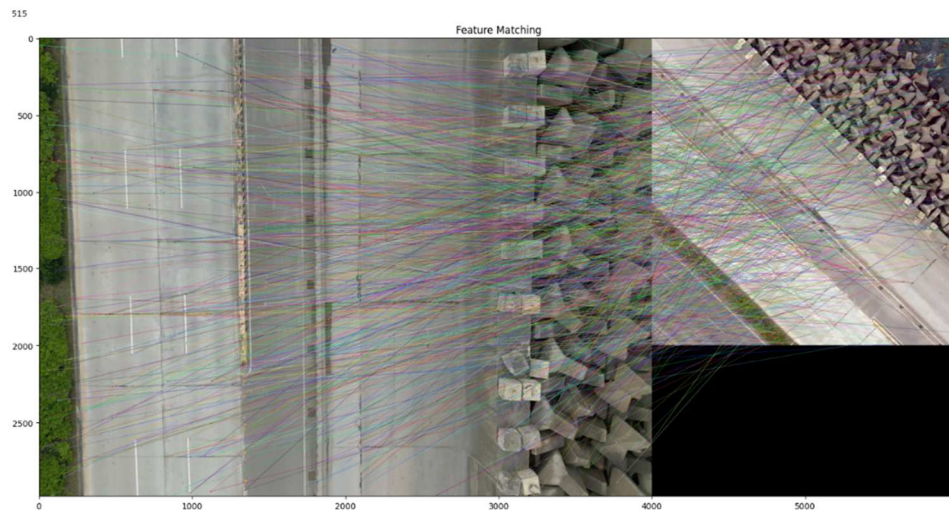


圖 6.37 SIFT 匹配無人機影像和正射影像特徵點圖(左)無人機拍攝影像(右)正射底圖對應位置之切片




圖 6.38 SIFT 匹配異常影像

當匹配過程中，會檢視在不同地區投影時的 homography 矩陣，透過各地區的矩陣特徵，可以自適應調整 SIFT 投影是否發生異常，

本研究中會透過調整 SIFT 中的 sigma 參數，藉由調整高斯輸入層，能夠使得圖像模糊或清晰化，使得影像特徵點能夠重新校正。

(6) 成果驗證

由圖 6.39 所示，目前已成功將模型預測的成果，將預測伸縮縫以 POI 為單位進行投影，能夠從預測影像中看出對應 POI 的伸縮縫位置，並檢視是否有發生錯位，在 A 區正確的解析度月份下能夠抓取 7 成以上的伸縮縫數量，在 F 區中，投影成功下也能夠抓到 7 成的數量，經過地理定位的方式，能夠將多條伸縮縫的影像進行切割，使得在錯位檢測的過程中，可以針對每條進行檢測，確認是否有發生錯位，相比與多條伸縮縫檢測，可以達到更優秀的精度與預測成果。




圖 6.39 預測成果展示圖(左)20240708 資料集(中)20240529 資料集
(右)20240829 資料集

預測成果主要會分類為 3 個等級，分別為紅色(red)、綠色(green)與橘色(orange)，紅色表示預測出來的交點過多或異常，需要人工檢視，綠色表示預測交點與預期相符無異常，橘色表示無檢測到交點，需要人工輔助判別是否有異常情形發生，在無人機影像有正確拍攝到完整伸縮縫的月份，如圖 6.40 所示，能夠成功針對各條 POI 確認伸縮縫樣態與是否有異常錯位，如在 A-1 區的伸縮縫預期交點皆為

一個，若是有錯位的情形發生時，則會出現多個交點的情況，如圖 6.41 所示，則會顯示為紅色，若有異常可由人工輔助判釋是否有異常情況發生。




圖 6.40 20240529 正確檢測影像(POI:26)




圖 6.41 伸縮縫交點預測異常影像，黑色圈圈為交點

經過錯位檢測過後，每張影像會保存至相對應該伸縮縫像素值的 POI 位置，因此每個 POI 會有存放 3 個資料夾，分別為 pred_imgs、

record 與 vis 資料夾，預測完的成果影像會存放在 pred_imgs 資料夾中，並將預測成果存成 json 檔，最終會評估所有的預測影像，若是發生異常影像超過 2 張時，則會輸出異常影像，若是皆為正常影像的話，則輸出正常影像，若無預測的話，則輸出無預測影像，並在檔案名稱前儲存預測成果，如 :GREEN_MAX_0615、RED_MAX_0616...，最終平台上呈現影像為 vis 資料夾內的影像，並將該對應顏色存於對應 POI 的 ICON 中。



圖 6.42 伸縮縫在平台上 POI 及樣態呈現

平台上的伸縮縫位置如圖 6.42 所示，影像呈現流程如圖 6.43 所示，在 A 區(道路)共 179 個 POI，每個 POI 會對應相對位置的伸縮縫，而在 F 區(港區)有 30 個 POI，共 30 條伸縮縫。

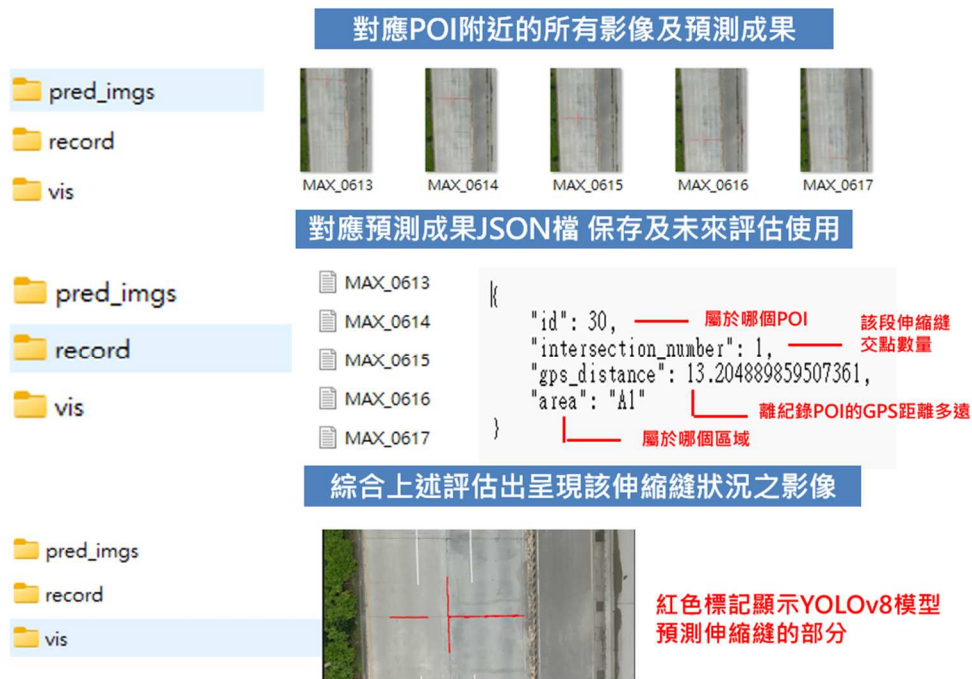


圖 6.43 平台上影像呈現流程

6.2 新增標的物

6.2.1 路面坑洞偵測模型建立

(1) 資料集

本年度新增之坑洞分類項目使用之資料集包含臺北港及臺中港之影像資料，除了舊有臺中港之資料外，新增之臺北港影像為 112 年 5 月、7 月，及 9 月之巡檢影像，目標區域為港區 A1 道路，如圖 6.44 所示，其中含有坑洞之影像為 16 張。原始影像為 7680*4320 的解析度，訓練過程將其裁切為 480*480 之訓練影像，其中 38 張訓練影像含有坑洞，其中 8 張設置為測試資料，而為了避免無坑洞影像過多導致影響模型訓練，僅保留了 45 張無坑洞之訓練影像，因此臺北港資料集之訓練資料及測試資料為 75:8，如圖 6.45 所示。而臺中港資料集之訓練資料及測試資料為 240:25，明顯多於臺北港，大小為 342*405，如圖 6.46 所示。




圖 6.44 臺北港正射影像，紅框處即為臺北港測試資料位置




圖 6.45 臺北港坑洞資料，上為影像下為標註




圖 6.46 臺中港坑洞資料，上為影像下為標註

(2) 使用模型

使用之模型架構同路面裂縫之偵測模型為 U-Net++ (Zhou et al., 2018)，模型架構如圖 6.47 所示，相較於傳統之 U-Net，U-Net++ 在殘差連結上新增了數個節點，以更好地處理淺層和深層之間的特徵傳遞，減少了特徵信息的流失。此結構也在去年度的研究證明了其能夠偵測在路面上的破壞，因此今年度沿用此模型架構。




圖 6.47 U-Net++架構

(3) 訓練細節

訓練細節基本上沿用去年之設定，編碼器使用 Efficientnet-B6(Tan and Le, 2019) 強化模型在特徵提取方面的能力，並使用遷移式學習將編碼器先預訓練在一個大型的 imagenet 資料集上以解決資料量不足的問題，損失方程式使用 Lovasz Loss(Berman et al., 2018) 加上 Cross Entropy，使訓練過程中模型的預測結果與真實標註的差距能夠更正確的被評估，使得訓練更有效率，使用資料強化後在搭載了四個 Intel Xeon E5-2620 CPUs 的 NVIDIA RTX Quadro 8000 GPU 上進行訓練，訓練細節如表 6-4。

表 6-4 坑洞模型訓練細節

訓練參數	值
預訓練編碼器	Efficientnet-B6 (imagenet)
損失方程式	Cross Entropy + Lovasz Loss
優化器	Adam
基礎學習率 (LRbase)	0.0001
學習率調整方程式	$LR = LRbase * (1 - \text{Epochcurrent} / \text{Epochmax})^{0.9}$
最大迭代數 (Epochmax)	50
批次大小	3

(4) 辨識成果

模型訓練將兩個資料集混合進行訓練，訓練集共含 315 張，臺中港資料與臺北港資料的比例為 240:75，而測試集共含 83 張，臺中港資料與臺北港資料的比例為 75:8，並使用了 intersection over union (IoU) 指標進行評估，如圖 6.48 所示，該指標是一種常用於評估圖像分割性能的指標。其嚴謹的以像素級的方式一個一個像素的衡量模型預測的分割區域與實際分割區域之間的重疊程度，值會在 0 到 1 之間，越大則代表重疊度越高，模型預測效能越好，常應用於物體檢測和語義分割等應用中。

學習曲線如圖 6.49 所示，表示模型在迭代過程中的表現變化，本計畫將模型在不同資料集的表現獨立展示，因此會有三條曲線，綠線代表模型在臺中港測試集的表現，橘線代表模型在臺北港測試集的表現，而藍線代表兩者混合的計算成果，由於訓練資料較多的緣故，模型在臺中港資料集的表現較佳且穩定，而臺北港的表現則起伏較大，有時甚至接近於零，代表其有因為資料量過少所導致的過度擬合(overfitting)問題，在未來能夠透過資料集的擴充來解決，而本計畫使用模型在臺北港測試集中表現最佳的迭代數來當做最終模型權重以解決此問題。

模型測試成果如表 6-5 所示，可見模型在 83 張中的測試資料集中 IoU 高達 82.1，其中在臺中港的 75 張影像中較優，可達 88.4，而資料量較少的臺北港資料則為 52.8，圖 6.50 為預測成果，圖中上方為預測成功實例，可見模型能抓取路面坑洞輪廓，而圖中下方可見模型有可能將路面補釘誤識為坑洞，進而影響模型表現。




圖 6.48 圖解 intersection over union(IoU)




圖 6.49 坑洞模型之學習曲線

表 6-5 坑洞模型測試成果

IoU(%)		
	背景	坑洞
臺北港	99	52.8
臺中港	99	88.4
混和	99	82.1





圖 6.50 坑洞模型預測成果

(5) 成果驗證

此節將驗證模型預測成果與實際狀況的差異，將使用港區 A1 道路為例，實際測試區域及該處航攝圖，如圖 6.51 所示，初始航攝圖大小為 7680*4320，裁切為 480*480 大小後依序讓模型預測並重建回原始大小，成果如圖 6.52 所示，綠色表示預測成功，黃色表示無坑洞誤識為有坑洞，紅色表示有坑洞但無法辨識，可見該區域除了一個較小的坑洞，其他皆能成功辨識，但模型也容易將水溝蓋等物體辨識成坑洞。



(a)



(b)

圖 6.51 坑洞測試(A1 道路)，(a)測試位置(紅框)，(b)測試影像




圖 6.52 坑洞模型預測成果驗證

6.2.2 堤面鋼筋裸露

(1) 模型介紹

由於鋼筋裸露的部分在航攝影像中過於不明顯，若是使用影像分割方式標註鋼筋裸露的部分會過於困難，於是使用與過去偵測裂縫和伸縮縫不同的標注方式，也就是物件偵測的方式。因此，模型結構也有所不同，在這部分使用的是 YOLO(Redmon, 2016)深度學習模型的最新一代 YOLOv9(wang et al., 2024)。

YOLOv9 引進了 PGI (Programming Gradient Information)，讓模型在不同深度的時候，都可以處理梯度訊息的傳播，使得模型可以獲得更可靠的資訊來更新權重，結構如圖 6.53。除此之外，還設計了一種新型輕量級網路結構 GELAN (Generalized Efficient Layer Aggregation Network) 改善模型的資訊整合以及計算速度，以提升模型的效能以及效率，結構如圖 6.54。

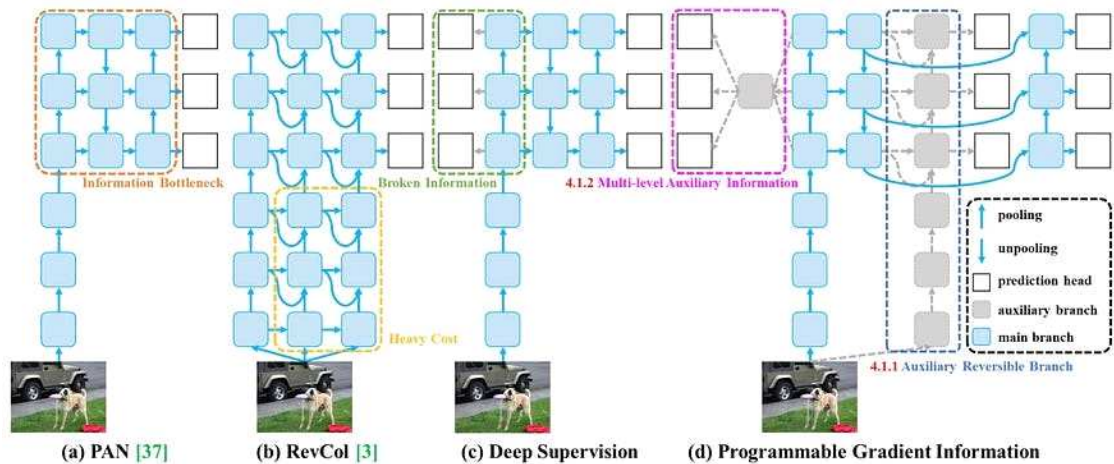


Figure 3. PGI and related network architectures and methods. (a) Path Aggregation Network (PAN) [37], (b) Reversible Columns (RevCol) [3], (c) conventional deep supervision, and (d) our proposed Programmable Gradient Information (PGI). PGI is mainly composed of three components: (1) main branch: architecture used for inference, (2) auxiliary reversible branch: generate reliable gradients to supply main branch for backward transmission, and (3) multi-level auxiliary information: control main branch learning plannable multi-level of semantic information.

圖 6.53 PGI 結構圖




圖 6.54 GELAN 結構圖

(2) 資料集

訓練用的資料集使用的是 113 年 4 月 29 日臺北港的航攝影像，共 126 張圖片。其中有 86 張圖片做為訓練集，20 張圖片做為驗證集，以及 20 張圖片做為測試集。並且因應模型，統一將圖片尺寸調整為 640*640，如圖 6.55 所示。



圖 6.55 臺北港堤面影像

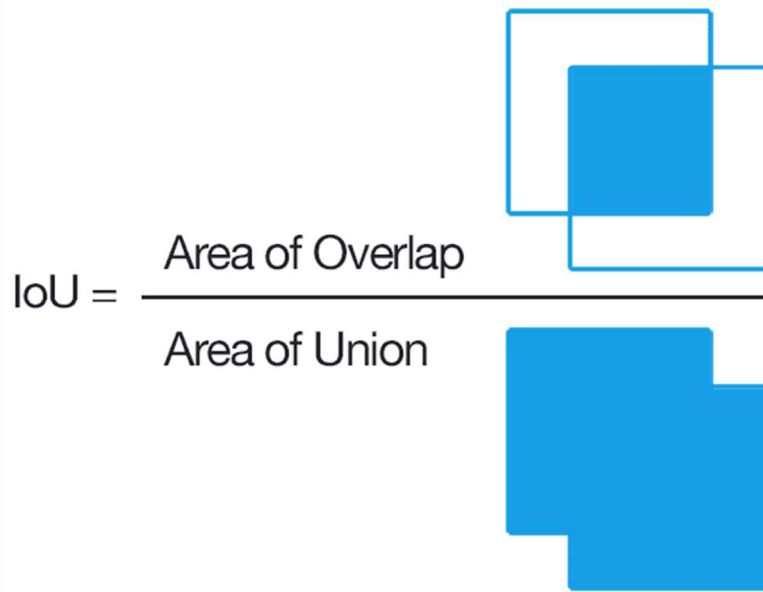
(3) 訓練細節

YOLOv9 有 4 種不同的模型類別，分別是 YOLOv9-S、YOLOv9-M、YOLOv9-C、YOLOv9-E。YOLOv9-S 的模型結構較為簡單，是因應計算能力較為不足的環境而製造的模型，不過也因此偵測的準確度比較低；YOLOv9-M 是在運算量能與準確度之間取得平衡。YOLOv9-C 是結構較為複雜的模型，但是偵測的準確度也較好；YOLOv9-E 則是結構最複雜、規模也最大的模型，相較於另外 3 種模型來說預測準確率最高，但也因此需要較大的計算能力。

因此本計畫選擇採用 YOLOv9-C 作為預訓練模型，期望能夠有比較高的預測準確率。而訓練參數的部分則是將最大迭代數是設定為 80 次、訓練集與驗證集的批次大小皆設定為 4。

(4) 訓練結果

Intersection over union (IoU) 可用於評估偵測結果的準確程度，當偵測的物體區域與原本標注的邊界框 (bounding box) 的重疊部分越多，IoU 值就越大，如圖 6.56 所示。而在物件偵測當中，當預測框的 IoU 大於門檻數值時，才會將此視為偵測成功。



$$\text{IoU} = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$

圖 6.56 intersection over union (IoU) 的公式

訓練的情形如圖 6.57 所示，圖片當中的 box_loss 用於衡量模型中預測框與真實邊界框之間的差異。cls_loss 是用於檢測對於不同分類物體進行分類的準確程度，當 cls_loss 較低時就代表模型對物體的分類較為準確。dfl_loss 則是將邊界框的位置與大小視為連續的機率分布來處理，而會將預測框與實際邊界框的偏移程度轉換成連續值，有助於讓模型更好定位物體。Average precision(AP)則是 recall 為橫軸、precision 為縱軸所畫出的曲線底下的面積，AP 數值高的話可視為模型偵測物件的能力較好，recall 與 precision 的曲線，如圖 6.58 所示。可以從圖 6.57 看到 3 種 loss 都是隨著迭代數的增加而減少，AP、precision、recall 則是隨著迭代數的增加而增加。

而從不同迭代數時訓練出的模型當中表現最好的參數來偵測在訓練時沒有看過的資料，使用此模型可以將大多的鋼筋裸露部分偵測出來，有一些鋼筋裸露的區域會被模型重複偵測，以及會有將堤面上的伸縮縫、消波塊造成的陰影等地方誤判成鋼筋裸露的區域，也有部分圖片的情況是會重複偵測同一個區塊的鋼筋裸露區域，於是變成偵測到兩塊，結果如圖 6.59 所示。

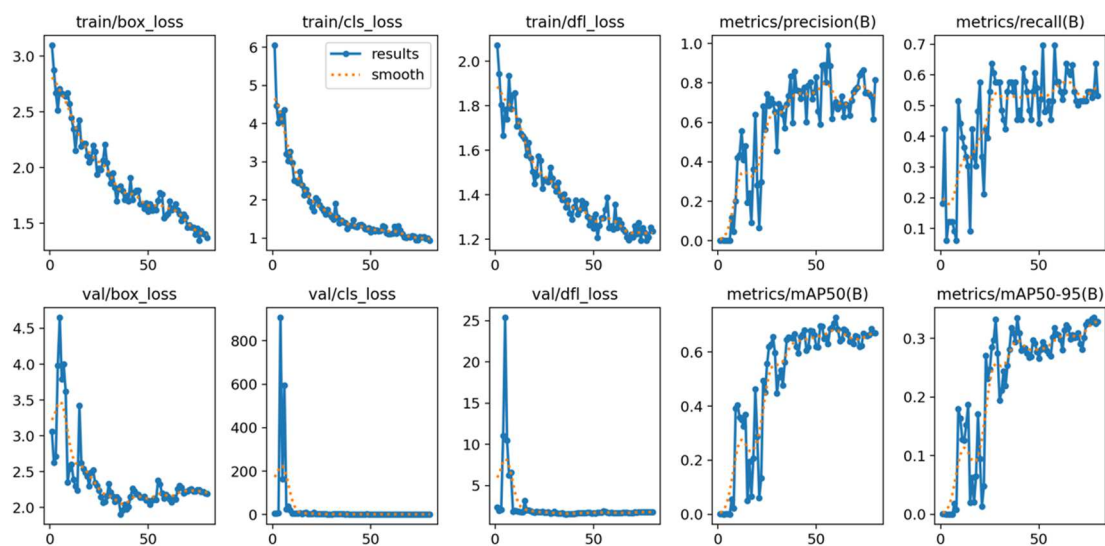


圖 6.57 鋼筋裸露偵測模型各項指標訓練圖




圖 6.58 Precision-Recall 曲線圖



圖 6.59 鋼筋裸露偵測結果

6.2.3 碼頭面裂縫

(1) 模型介紹

本模型沿用過去使用之 U-Net++(Zhou et al., 2018)。此模型相較於傳統的 U-Net 來說，在殘差連結的部分新增數個節點，使得不同層的特徵資料比較容易在傳遞的過程中被保留，因此更能捕捉到細微的特徵，使得訓練結果再更上一層樓，模型結構如圖 6.60 所示。




圖 6.60 U-Net++結構

(2) 資料集

訓練該模型的資料集使用了從 112 年 5 月 6 日至 112 年 9 月 8 日拍攝的臺中港與臺北港航攝影像以及現有的水泥牆裂縫照片混合進行訓練，分別使用 1293 張圖片做為訓練集，113 張圖片做為測試集，一共有 1406 張圖片。至於標注的種類則是總共有背景、裂縫與伸縮縫 3 種，並且將訓練用的資料統一裁切成 480*480 的方形圖片，如圖 6.61 所示。而需要檢測的目標則是 113 年 4 月 29 日在臺北港所拍攝的港口影像，如圖 6.62 所示。




圖 6.61 (a)為航攝的影像，(b)為標註的影像




圖 6.62 臺北港港口影像

(3) 訓練細節

本模型基本上沿用過去所使用的訓練資訊，預訓練編碼器使用 Efficientnet-B6(Tan and Le, 2019) 強化特徵提取方面的能力。損失方程式的部分則是除了常見的 Cross Entropy，利用計算偵測內容的機率分布與實際情形的機率分布的誤差範圍評估和量化兩者的落差程度，還再加上了 Lovasz Loss(Berman et al., 2018)，使模型更能正確地評估在訓練過程中的標注結果與標注實際上的圖片之間的差距。優化器則是使用在深度學習模型訓練中常見的 Adam，用來調整模型的學習率，並且沿用與過去相同的平台進行模型的訓練，訓練細節如表 6-6。

表 6-6 模型訓練細節

訓練參數	值
預訓練編碼器	Efficientnet-B6 (imagenet)
損失方程式	Cross Entropy + Lovasz Loss
優化器	Adam
基礎學習率 (LRbase)	0.0001
學習率調整方程式	$LR = LRbase * (1 - Epochcurrent/Epochmax)0.9$
最大迭代數 (Epochmax)	80
批次大小	3

(4) 辨識結果

同樣使用 IoU 評估，模型的訓練情形如圖 6.63 所示。訓練集的 IoU 值在隨著迭代數的增長而跟著提高；驗證集的部分不管是裂縫還是伸縮縫，都在大約迭代數來到 50 以後就差不多收斂了。

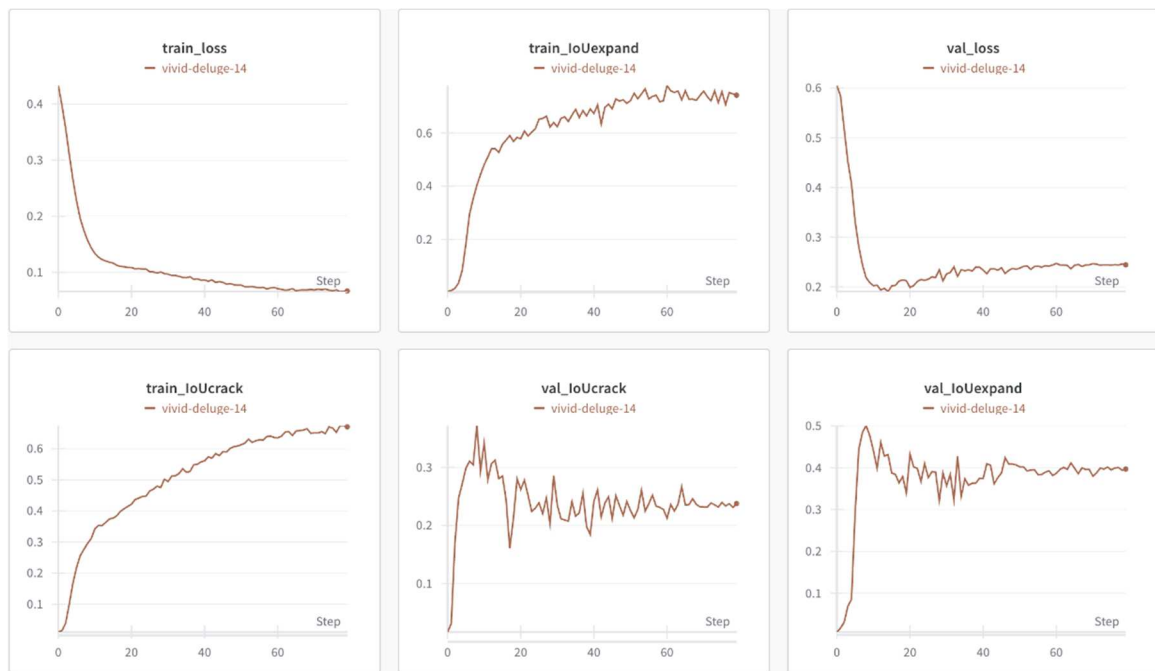


圖 6.63 裂縫偵測的訓練情形

使用此模型偵測的結果可以將大量的伸縮縫以及裂縫偵測出來，不過有一些伸縮縫與裂縫連接在一起的部分容易將伸縮縫判斷成裂縫，以及方形伸縮縫的部分容易被當成背景，因此沒有全部都偵測出來，如圖 6.64 所示。




圖 6.64 (a)為臺北港港口影像，(b)為偵測的影像

6.3 本章小結

(1) 岸邊設施小結

112 年度的經驗發現，無人機拍攝的影像尺寸對於模型偵測的影響是顯著的，為保持穩定的偵測結果，使用同一規格的無人機與拍攝手法是非常重要的一環。

同時在研究成果中證明，若能保持影像的一致性，透過將近千張的影像進行訓練，模型的預測結果就能夠達到九成以上，幾乎不遺漏目標。

在工程應用上，能透過自動化的控制來實現近乎相同的拍攝條件，規格化模型的輸入影像，在此條件底下，現今的深度學習模型已能針對特定規格的輸入影像，達到九成以上的偵測準確度。

未來會再針對物件的地理位置屬性進行研究，期盼能完成以物件為主的巡察結果。

(2) 變電箱小結

本計畫採用 YOLOv8 模型進行變電箱偵測，結合了本年度與去年的所蒐集的影像資料，展現出高準確性和模型的泛化能力。模型的平均精度均值 (mAP) 達到了 93%，證明了其在偵測變電箱方面的高效性，並在各種尺度上都表現良好。進一步的成果驗證中，模型在不同距離尺度下的偵測表現均維持高準確度，顯示了其在實際應用中的可靠性和效果，故 YOLOv8 模型能應用於港區之實際變電箱熱像巡檢之相關應用。

(3) 坑洞小結

此結新增了關於路面坑洞的檢測模型訓練過程，包含資料集的建置、模型選擇及訓練成果，因為資料量有限的關係，本研究將臺中港與臺北港的資料混合訓練並驗證，並使用遷移學習的方式來改善小樣本訓練的困難，而小樣本訓練的不穩定及過度擬合問題也透過模型在測試集上的表現挑選出一個最佳的結果來處理，最後模型在混合資料集的成果以 IoU 來計算可達 82.1%，其中在臺北港的資料可達 52.8%，最後也驗證了模型的預測成果預實際差異，可見模型可將坑洞檢測出，但也可能將水溝蓋或路面補釘等誤識為坑洞，影響其表現。

(4) 法線小結

目前已成功透過 YOLOv8 模型與霍夫直線技術預測胸牆走向並將其投影至對應的 POI 上，在錯位檢測的部分也能夠成功檢測是否有錯位發生，無偵測的影像目前多是因為無人機拍攝視角未能夠完整拍攝胸牆兩側導致無法偵測胸牆走向是否正常，在未來會調整影像使得拍攝角度能夠完整拍攝胸牆兩側，並加入更多期胸牆影像，使得模型能夠更精準預測胸牆法線，提高在不同情況下胸牆錯位的檢測能力。透過本章節技術，能夠達成半自動化胸牆法線預測及錯

位評估，在平台上可以清楚的去檢核各個位置的胸牆是否有異常發生，並將影像保存於平台上，在未來評估結構健康時，能夠有參考依據。

(5) 伸縮縫小結

本次成果在模型辨識伸縮縫上，可以達到預測準確率約 0.85 的水準，然而在影像地理定位上，因為仍舊在調整拍攝時的視角與影像解析度，故在某些月份上無法抓取超過 5 成以上的 POI，在未來會訂定完整的影像拍攝流程與規範，能夠使得在影像特徵點的抓取上能夠提高精度，並且更新正射底圖，也能夠增加在影像匹配上的精度，而在錯位檢測上，目前也是會受到模型檢測與地理定位的影響，若是無法完整抓取伸縮縫或是沒有正確對位到 POI 上都會影響後續再進行錯位檢測時的優化，本技術為了達到以單條伸縮縫為精度進行地理定位、匹配與預測，故比起單純的影像模型預測上會需要更優化的流程標準化與影像一致性，才能夠對長距離的道路伸縮縫異常進行檢測，若是修正為輸出伸縮縫預測成果再由人工進行判釋解讀，就能夠達成整條道路或是全域 POI 檢測，但是就無法達成全自動化檢測的技術，故在未來會需要在進行優化及討論。針對伸縮縫檢驗的部分，將會進一步研究如何取出在物空間中相同區域的裂縫進行比對，並加入相關的比較，考量使用何種相似性評估的方式能夠挑選出異常變化或錯位的伸縮縫線段，提供給後續人員進行評估監測。

(6) 碼頭面小結

此節主要是在測試集主要為混凝土版的情況下，選擇額外加入現有的混凝土牆裂縫資料集的訓練狀況。可以從結果看得出來在偵測裂縫的表現整體來說是能夠將裂縫與伸縮縫偵測出來的，但是卻有部分的伸縮縫被誤判成裂縫，以及旁邊的排水孔被誤認成伸縮縫的狀況。未來可以再蒐集現成有伸縮縫的混凝土板資料做為訓

練集。而若是能夠收集到更多現有的資料庫用於訓練的話，也能夠再調整批次大小，以達到最好的訓練成果。

(7) 鋼筋裸露小結

透過深度學習當中物件偵測的方式偵測堤面鋼筋裸露的情況，可以看得到此模型能夠將大部分鋼筋裸露區塊偵測出來，不過會有一些鋼筋裸露的區域會被模型重複偵測，以及會有將堤面上的伸縮縫、消波塊造成的陰影等地方誤判成鋼筋裸露的區域。未來可以將堤面照片裁切成 640*640 的大小，而不是直接將原圖直接縮小，用裁切的方式能夠確保處理後的圖片還是原本的畫質，也就是說能夠提升訓練集與驗證集的圖片品質，因此，這個行動能夠提升模型的訓練效果。

第七章、多來源感測資料整合

臺北港是臺灣最年輕的國際商港，也是首座藉由無線感測技術打造無人貨櫃碼頭的國際港口。為了提升營運效率、節省成本、強化安全、維護環境等目的，臺北港導入了多種感測器，遍布港區各角落，蒐集即時資訊，提供決策依據。

7.1 港區現有感測器種類與應用現狀

臺北港所使用的感測器種類繁多，依功能可大致分為以下幾類：

7.1.1 環境監測感測器

主要用於監測港區環境品質，包括空氣品質、水質、噪音等。空氣品質感測器可偵測懸浮微粒、硫氧化物、氮氧化物等污染物濃度；水質感測器可監測水溫、酸鹼值、溶解氧等參數；噪音感測器則可測量噪音音量。

7.1.2 貨櫃追蹤感測器

主要用於追蹤貨櫃動向，提升貨櫃作業效率。常見的貨櫃追蹤感測器包括 RFID 感測器、光學辨識系統（OCR）等。RFID 感測器可透過無線射頻技術識別貨櫃標籤，記錄貨櫃位置、進出港區時間等資訊；OCR 則可辨識貨櫃號碼，並與 RFID 感測器資料整合。

7.1.3 車輛感測器

主要用於監控車輛動態，確保交通安全。常見的車輛感測器包括車流感測器、車牌辨識系統（LPR）等。車流感測器可偵測車流量、車速等資訊；LPR 則可辨識車牌號碼，並追蹤車輛行蹤。

7.1.4 設備感測器

主要用於監控設備運作狀況，預防故障發生。常見的設備感測器包括振動感測器、溫度感測器、壓力感測器等。振動感測器可監測設備振動幅度，預警設備磨損；溫度感測器則可監控設備溫度，避免過熱；壓力感測器可監測設備壓力，防止管線破裂。

7.1.5 CCTV 感測器

主要用於監控港區活動，提供即時影像畫面。CCTV 感測器可監控港區各角落的活動，提供全天候、高清晰度的監控畫面，具體應用包括安全監控、人員管控、貨櫃管理、交通管制、設備維護等。

7.2 現有岸邊設施模型與 CCTV 的結合

臺北港目前已架設了數千支 CCTV 感測器，遍布港區各個角落，形成綿密的監控網。透過 CCTV 感測器，可防範偷竊、搶劫、破壞等犯罪行為，並協助釐清事故責，而為了提升 CCTV 感測器的應用效益，臺北港也導入了多項智慧化技術，例如：

- (1) 影像分析：可自動分析 CCTV 影像畫面，偵測異常行為或事件，並發出警示通知。透過影像分析技術，CCTV 感測器可自動偵測人員入侵、貨櫃移動、車輛違規等異常行為或事件，並發出警示通知，讓警衛人員或管制中心即時掌握狀況，迅速做出應對。
- (2) 臉部辨識：可辨識人員身分，並追蹤人員動向。臉部辨識技術可透過 CCTV 影像畫面，辨識人員身分，並追蹤人員在港區內的動向，協助人員管控及安全監控。
- (3) 車牌辨識：可辨識車牌號碼，並追蹤車輛行蹤。車牌辨識技術可透過 CCTV 影像畫面，辨識車輛車牌號碼，並追蹤車輛在港區內的行蹤，協助交通管制及貨櫃管理。

7.2.2 申請區域

港區本已建有多個場域的 CCTV 系統，而在部分的港邊設施中，來自地面視角的 CCTV 能補足 UAV 的不足，提供更好的視野或是當 UAV 的視野被船隻遮蔽時，以另一個面向的角度補足缺失的部分。

然 CCTV 影像與 UAV 影像之間的角度不同，物件在其中的呈現大不相同，UAV 的模型是無法直接應用到 CCTV 的影像上的，需額

外針對 CCTV 的影像進行訓練。訓練。不過 CCTV 本身的視角與拍攝的場域較為固定，影像內的變化不像 UAV 複雜，因此在訓練上並不如 UAV 一般需要大量的訓練資料，少部分的資料即可達到不錯的效果。

在臺北港所提供多個不同區域的 CCTV 視角中，針對有拍攝到岸邊設施的幾個場域進行測試，總計有 4 個場域，位置分布如圖 7.1，並蒐集 7 月至 8 月每周一早上 10:00~10:30，共 8 期片段。




圖 7.1 CCTV 場域的分布位置（綠點）

7.2.3 選擇模型

將 4 個場域的 CCTV 影像分別擷取 1 分鐘進行標註與訓練，總計 120 張影像並已 7:2:1 的比例分成訓練、驗證與測試資料集，而後以 YOLOv8n 模型作為預訓練模型，經過 50 次的 Epochs 訓練後得到驗證資料集表現 mAP@0.5 在 0.853 左右的模型，模型的表現與訓練過

程，如圖 7.2，最佳的模型以混淆矩陣表示其在驗證資料的結果，如圖 7.3。




圖 7.2 CCTV 的模型訓練過程




圖 7.3 CCTV 的模型在驗證資料集上的混淆矩陣

在訓練資料的表現則如圖 7.4 所示，除去距離過遠的物件外，在視野範圍內的岸邊設施大部分都可以準確地偵測到。




圖 7.4 不同 CCTV 視角的偵測結果

7.3 本章小結

臺北港的現有感測器應用已漸具規模，並在提升營運效率、強化安全管理等方面發揮了顯著成效。本計畫 112 年也進行了不同感測器(光學感測器、熱紅外感測器、氣體感測器等)的測試，期許能與港區感測器整合，而於今年盤點港區現有感測器後，考量整合 CCTV 與團隊現有的 AI 智慧化技術，可開發更多智慧應用，然直接套用岸邊設施模型結果卻因拍攝視角而不盡理想，只能重新訓練模型，而好在 CCTV 視角皆固定且影像變化少，僅使用幾期影像即可在車擋辨識上獲得極好的表現，後續可思考如何結合 CCTV 與 UAV 彼此拍攝優點進行互補辨識，提供更全面的監控，以打造更安全、更智慧的港口。

第八章、基於高細緻港區空間資料之環境分析

8.1 三維建物模型資料處理

在太陽能光電發電的影響上，為增加整體太陽光電潛力估算的準確性，通常引入模型細緻度 LOD2 以上的建物模型(圖 8.1)可將以往忽略的建物屋頂部分納入考量。本計畫使用臺灣港務公司所提供之 LOD2 建物模型進行，針對三維都市建物模型進行資料處理，萃取出建物的屋頂結構部份，以建物的屋頂結構之點坐標進行詳細建物高度的擬合計算，並運用擬合結果建構屋頂結構模型。



圖 8.1 CityGML 建物模型細緻度等級(LOD)示意圖

8.1.1 建物模型結構萃取

為建構出建物屋頂結構模型以利後續大範圍的太陽能板角度與朝向、接收太陽輻射量及陰影遮蔽等計算，藉由引入三維都市建物模型，經資料的屋頂結構提取與建物詳細高度解算後，推衍出僅含建物屋頂結構之模型，並以此做為後續計算的依據。

本計畫根據表 8-1 規範彙整，採用 LOD2 三維都市建物模型，為臺灣港務公司所提供之小塊區域(圖 8.2)，全區資料以 KML 檔案格式儲存。然 KML 檔案中實際三維模型檔案以 COLLADA 文件格式各自獨立儲存，因此，需針對 KML 檔案中連結之三維建物資料進行拆解與篩選的處理，提取出建物的屋頂結構部分。

表 8-1 CityGML 對於 LOD 之建議規定彙整表

	LOD1	LOD2	LOD3	LOD4
模型尺度描述	城市、地區	城市、市區	市區、建築模型、地標	室內建築模型、地標
精度分類等級	低	中	高	非常高
點位絕對精度 (位置/高程)	5m/5m	2m/2m	0.5m/0.5m	0.2m/0.2m
模型簡化	面積大於 6m*6m 且高差大於 3m 之區塊物件以簡 化圖徵呈現	面積大於 4m*4m 且高差大於 2m 之區塊物件以簡 化圖徵呈現	面積大於 2m*2m 且高差大於 1m 之區塊物件以真 實圖徵呈現	以結構性元物件、 門窗開口呈現物件
建物外部附加設施	無	有	具代表性外部圖 徵	實際物件
屋頂結構展現	平坦屋頂	差異化屋頂結構	實際物件	實際物件



圖 8.2 臺北港 LOD2 之模型

8.1.2 屋頂結構模型建構

模型屋頂面資料為網格（Mesh）形式構成，因此，會以多個節點組成單個或多個三角形表示。為獲取建物模型屋頂各處的高度值，需針對屋頂面組成之三角形的三維坐標進行屋頂的詳細高度擬合，並以擬合出之屋頂面三維坐標做為屋頂結構模型的依據(圖 8.3)。



圖 8.3 屋頂結構圖

8.1.3 建物邊緣線篩除

本計畫假設建物屋頂面可全部鋪設太陽能板，但考量到建物屋頂邊緣大多有矮牆等設計，實際上無法裝設太陽光電系統，因此需將建物邊緣線排除於可裝設區域外。為此，本計畫採用 Canny 演算法（Canny, 1986）進行建物邊緣線偵測，可有效辨識出影像中的邊緣像素，並將偵測出之建物邊緣線寬度設為 1 公尺，進行剔除，將剩餘區域做為可裝設太陽光電系統之區域(圖 8.4)。



圖 8.4 利用 canny 偵測邊緣

8.2 港區日輻射資料


於太陽輻射氣象資料部分，本計畫使用內政部建築研究所建置之建築能源模擬解析用 TMY3 標準氣象年，對屋頂面接收日射量進行推估，採用此資料來代表一區域之長期氣候變化，提高本計畫推估結果的可靠程度。建築能源模擬解析用 TMY3 標準氣象年採用 CSV 通用格式，使用長達 23 年的氣象資料篩選後組成，各氣象要素依據對建築熱負荷的影響程度給予不同權重，以逐月資料選出最符合長期氣候的月份，組合全年份 8760 筆資料的標準氣象年。

8.3 研究成果


根據所提供之 LOD2 模型所示，港區共有 67 個大小不一的建物，在剔除面積過小不適合架設太陽能板之屋頂範圍後，僅剩下為數不多之建物，因此在評估結果上，無論是可接收日設量或是換算成發電量，數量皆較少。

8.3.1 接收日射量成果


推估結果顯示(圖 8.5)，由於臺北港位於臺北市區，接收日射量以臺北市地區建築能源模擬解析所使用的 TMY3 標準氣象年中日射量資料計算。研究考量建築物高度及周邊環境陰影遮蔽等因素，得出各月份累積接收日射量，結果顯示因建物數不多，其太陽光電潛力較少。然而，由於缺乏完整數量的建築物模型資料，此估算結果僅能提供部分參考。




(a)1 月日射量




(b)2 月日射量




(c)3 月日射量




(d)4 月日射量




(e)5 月日射量



(f)6 月日射量



(g)7 月日射量



(h)8 月日射量




圖 8.5 臺北港各月接收日射量成果

8.3.2 系統發電量成果

最終系統發電量估算，除需考量各屋頂結構模型及其屋頂面積外，更須結合環境陰影遮蔽分析結果、接收日射量結果與假設的光電系統發電效率 15%。並將太陽能電池面積與區域建物屋頂面各處接收到的日射量及太陽光電模組效率結合，配合台灣電力公司與內政部的資料得知，每戶每日平均用電 10 度，臺北市每戶平均坪數 32.55 坪，得知每平方公尺每日耗電量約為 0.1，推算出區域太陽光電系統發電量及每個月每平方公尺架設太陽能板之收益，如表 8-2 所示。

表 8-2 臺北港全區推估發電量

月份	全年推估系統發電量(單位：度)
1 月	144491.7
2 月	222767.4
3 月	214039.7
4 月	233560.3
5 月	279530
6 月	289381
7 月	423173.6
8 月	365277.1
9 月	299335.5
10 月	261670.1
11 月	214463.1
12 月	157477.6
全年	3105167



圖 8.6 臺北港全年推估系統發電量

8.4 本章小結

本節首先探討光電潛力之計算方法，並假設港區現有建物屋頂鋪設太陽能板之發電量。經由發電量推估結果(圖 8.6)顯示，台北港

於夏季可產生較多電力。然而，由於該推估方法受限於模型數量及完整度，值得注意的是，其中一棟建物上已鋪設太陽能板，後續若能取得其真實發電量，則可進行此推估方法之精度驗證。

第九章、無人載具之通訊技術研析

9.1 空中無人載具

本節說明了無人機即時影像串流系統的架構(圖 9.1)，包含無人機、傳輸設備、處理軟體、伺服器 and 最終的使用者影像觀看平台。以下為各項通訊技術之詳細說明：

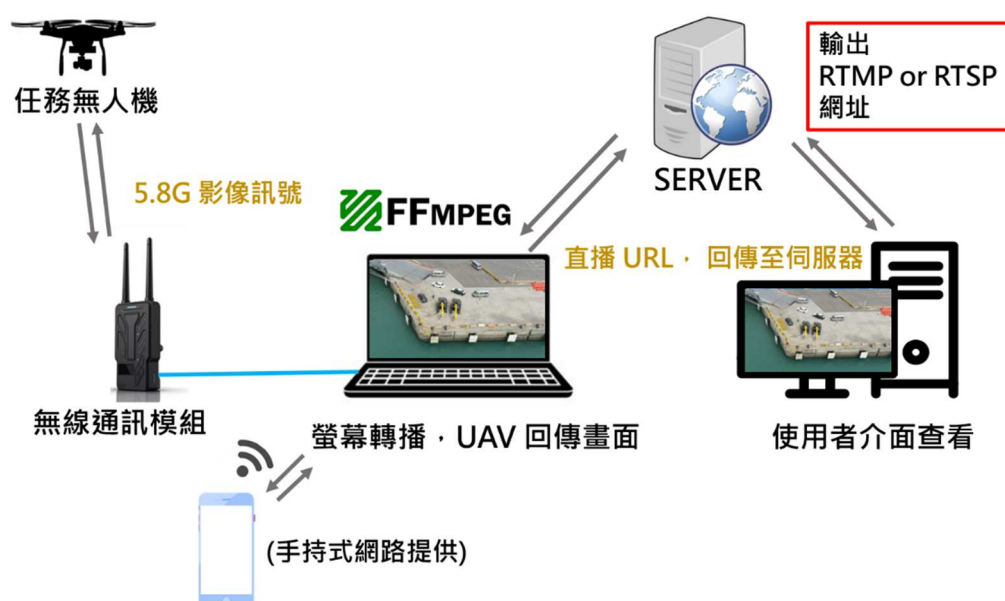


圖 9.1 無人機影像傳輸通訊技術架構

1、無人機和 5.8G 無線傳輸：

無人機裝備有攝影機，可即時捕捉影像。這些影像通過 5.8GHz 的無線頻率傳輸，這種頻率主要用於無線影像傳輸，因其高頻特性能提供快速數據傳輸，適合即時影像的需求。5.8G 信號強度和穩定性對於保持影像傳輸的連續性和清晰度至關重要。

2、接收設備和 FFmpeg 處理：

地面上的接收設備（可能是特定的無線接收器或具有相應接收功能的裝置）接收來自無人機的 5.8G 訊號。收到的影像數據被傳輸至連接的電腦，電腦上運行的 FFmpeg 軟體負責對這些影像進行處理。

FFmpeg 是一個強大的多媒體處理工具，能夠進行影像的解碼、編碼、轉換格式等多種處理。

3、網際網路和影像傳輸：

處理後的影像需要通過網際網路傳送到指定的伺服器。電腦可以通過多種方式連接到網際網路，包括使用行動網路（如 4G 或 5G 手持裝置提供的熱點）或是局部區域的 Wi-Fi（例如港區內部的 Wi-Fi 系統）。這種彈性的網絡連接選擇使得系統能夠在不同環境下都能維持網絡連接的穩定性和影像傳輸的流暢性。

4、伺服器處理和安全傳輸：

影像資料在送達伺服器後，會進一步被處理和轉發。為了保障資料的安全和保密性，伺服器會使用 SSL（安全套接字層）加密技術對影像資料進行加密處理。之後，加密後的影像可通過網際網路安全傳輸至最終的使用者端。

最終，使用者可以透過網頁或其他應用程式訪問經過 SSL 加密的 URL，從而在不同的裝置上觀看即時的或存儲的影像串流。這種方法不僅確保了高效的影像傳輸，還強化了整個系統的安全性和應用靈活性。

圖 9.2 說明了無人機透過網路 IP 將影像傳送到電腦的設定過程，其中包括無人機配置、網路設定以及串流與攝影機控制的相關步驟。圖中左上角顯示的無人機攝影機配置介面，是地面控制站（GCS, Ground Control Station）軟體的一部分，用於控制和監控無人機的飛行及其功能。網絡設定部分指定了無人機的 IP 地址為 192.168.168.67(暫定)，子網遮罩為 255.255.255.0，這使無人機能在局部網絡內與其他設備進行通訊傳輸。此外，圖中還展示了多個設定窗口，涉及如何將數據流透過特定的協議發送到電腦上。經由本案這些配置，無人機可以即時傳輸影像數據到電腦。



圖 9.2 無人機影像傳輸通訊技術協議設定

9.2 地面無人載具

UGV 通訊方式在本計畫中有多種選項，根據測試需求和應用場景進行比較：

本期計畫透過導入靜態 IP 技術，成功改善了 UGV 與操作電腦之間的通訊方式，達成遠端操控的目標。為解決過往因分享器距離限制所導致的通訊問題，嘗試於 UGV 與操作電腦之間導入靜態 IP。靜態 IP 的使用使使用者無須再與 UGV 保持在特定範圍內，進而大幅提升操作的靈活性和便利性。

透過靜態 IP，使用者可以連接不同的無線網路，並且使用安全外殼協定(SSH)與 UGV 遠端連線，實現遠端操控 UGV，使用者可以在任何地方通過安全外殼協定(SSH)操控 UGV，拓展了應用場景和操作範圍。圖 9.3 展示了過去與改進後的通訊方式。

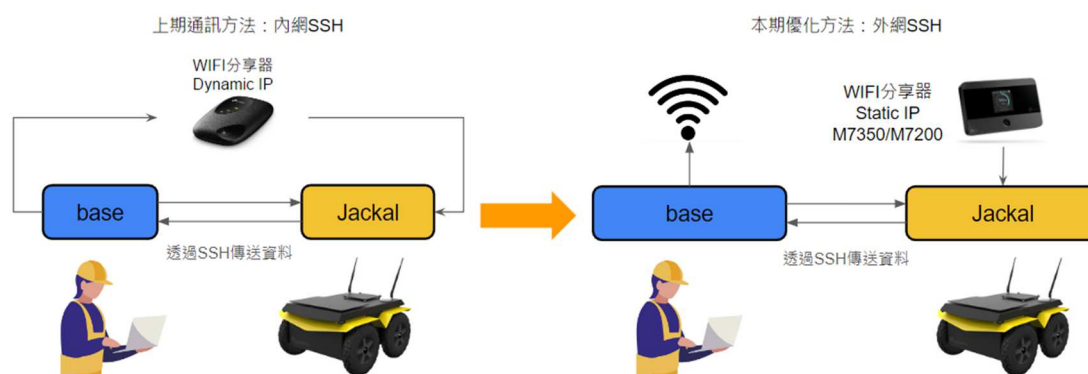


圖 9.3 112 年度通訊方法與本期引進靜態 ip 通訊方法比較

9.3 本章小結

本節說明了無人機即時影像串流系統的架構和實施過程。系統涉及無人機配備攝影機、地面接收設備、處理軟件 FFmpeg、網際網路連接設施及伺服器處理和安全傳輸。本計畫成功實現了 5.8G 無線頻率來傳輸無人機捕捉的即時影像，並透過 FFmpeg 軟件進行必要的處理。此外，系統支援多種網絡連接方式，包括行動網路(4G)和 Wi-Fi，以適應不同的運行環境。伺服器部分採用 SSL 加密保證數據傳輸的安全性，並使終端使用者能夠通過加密的 URL 在多種裝置上安全地觀看影像串流。現階段的工作不僅增強了系統的傳輸效率和靈活性，也顯著提升了資料的安全性。隨著系統的進一步完善和測試，在未來實際操作中實現更廣泛的應用。

港區實地測試結果發現，新的通訊方式不僅有效解決了過去的距離限制問題，還提升了 UGV 的應用靈活性，訊號的強度以及便利性經過測試後皆較過去之方法有顯著提升。

第十章、無人載具之影像即時串流建構

10.1 空中無人載具

本節主要說明影像串流的架構。影像串流介接功能示意圖如圖 10.1 所示，UAV 即時影像串流為現場採用一台筆電，須配合任意上網裝置。人員操作須開啟 FFmpeg 程式，以命令提示字元打開(圖 10.2)。並輸入特定指令 (表 10-1)，其中指令不同之處是依據現場電腦效能以及影像品質所進行設計。完成指令設定後，影像會發報至影像串流伺服器，並處理成 SSL 安全憑證加密網址，提高資料保密安全性。人員最後可在系統平台查看即時串流影像。

表 10-1 直播程式串流指令

指令功能	指令名稱
採用顯示卡解碼串流畫面	ffmpeg -f gdigrab -framerate 6 -i desktop -c:v h264_nvenc -qp 0 -f flv rtmp://61.216.153.153:3004/live/avix
降解為 720P 串流畫面	ffmpeg -f gdigrab -framerate 6 -i desktop -c:v h264_nvenc -qp 0 -vf scale=720:-1 -f flv rtmp://61.216.153.153:3004/live/avix
採用 CPU 解碼串流畫面	ffmpeg -f gdigrab -framerate 6 -i desktop -c:v libx264 -qp 0 -f flv rtmp://61.216.153.153:3004/live/avix
採用 CPU 解碼與降解為 720P 串流畫面	ffmpeg -f gdigrab -framerate 6 -i desktop -c:v libx264 -qp 0 -vf scale=720:-1 -f flv rtmp://61.216.153.153:3004/live/avix
無人機鏡頭直接輸出 (有限定機種)	ffmpeg -i rtsp://admin:admin@192.168.168.108:554/cam/realmonitor?channel=1 subtype=2 -c:v copy -c:a copy -f flv rtmp://61.216.153.153:3004/live/avix
串流直播網址	https://engdig.maa.com.tw:3005/hls/avix.m3u8

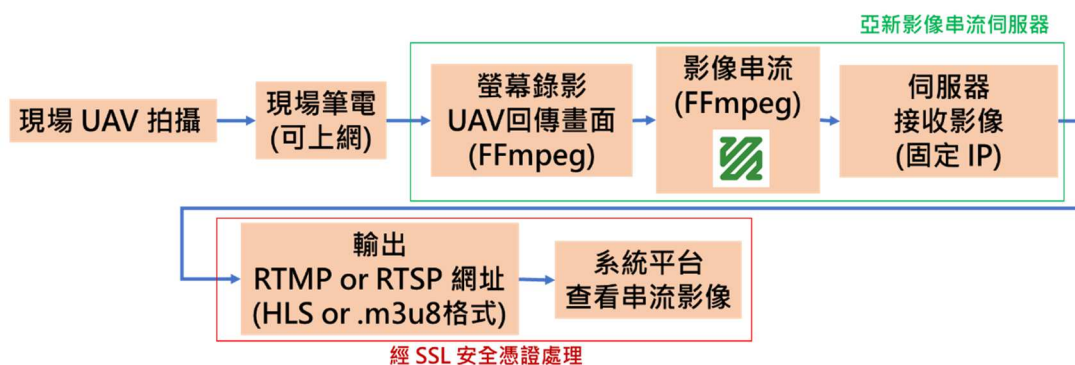


圖 10.1 影像串流介接功能示意圖

```
命令提示字元 - ffmpeg -fgdi x + v
nable-libtwolame --enable-libuavs3d --disable-libdrm --disable-vaapi --enable-libvidstab --enable-vulkan --enable-libsha
derc --enable-libplacebo --enable-libx264 --enable-libx265 --enable-libxavs2 --enable-libxvid --enable-libzimg --enable-
libzvbi --extra-cflags=-DLIBTWOLAME_STATIC --extra-cxxflags= --extra-ldflags=-pthread --extra-ldexeflags= --extra-libs=-
lgomp --extra-version=20230213
libavutil      58. 1.100 / 58. 1.100
libavcodec     60. 2.100 / 60. 2.100
libavformat    60. 2.100 / 60. 2.100
libavdevice    60. 0.100 / 60. 0.100
libavfilter     9. 1.100 / 9. 1.100
libswscale     7. 0.100 / 7. 0.100
libswresample  4. 9.100 / 4. 9.100
libpostproc   57. 0.100 / 57. 0.100
[gdigrab @ 0000015e4c579500] Capturing whole desktop as 3840x1080x32 at (0,0)
[gdigrab @ 0000015e4c579500] Stream #0: not enough frames to estimate rate; consider increasing probesize
Input #0, gdigrab, from 'desktop':
Duration: N/A, start: 1679384441.435650, bitrate: 796264 kb/s
Stream #0:0: Video: bmp, bgra, 3840x1080, 796264 kb/s, 6 fps, 1000k tbr, 1000k tbn
Stream mapping:
  Stream #0:0 -> #0:0 (bmp (native) -> h264 (h264_nvenc))
Press [q] to stop, [?] for help
Output #0, flv, to 'rtmp://61.216.153.153:3004/live/avix':
Metadata:
  encoder      : Lavf60.2.100
Stream #0:0: Video: h264 (Main) ([7][0][0][0] / 0x0007), bgra(pc, gbr/unknown/unknown, progressive), 720x203, q=2-31,
2000 kb/s, 6 fps, 1k tbn
Metadata:
  encoder      : Lavc60.2.100 h264_nvenc
Side data:
  cpb: bitrate max/min/avg: 0/0/2000000 buffer size: 4000000 vbv_delay: N/A
frame= 30 fps=4.2 q=-1.0 size= 219kB time=00:00:04.50 bitrate= 398.0kb/s speed=0.633x
```

圖 10.2 現場筆電串流指令介面

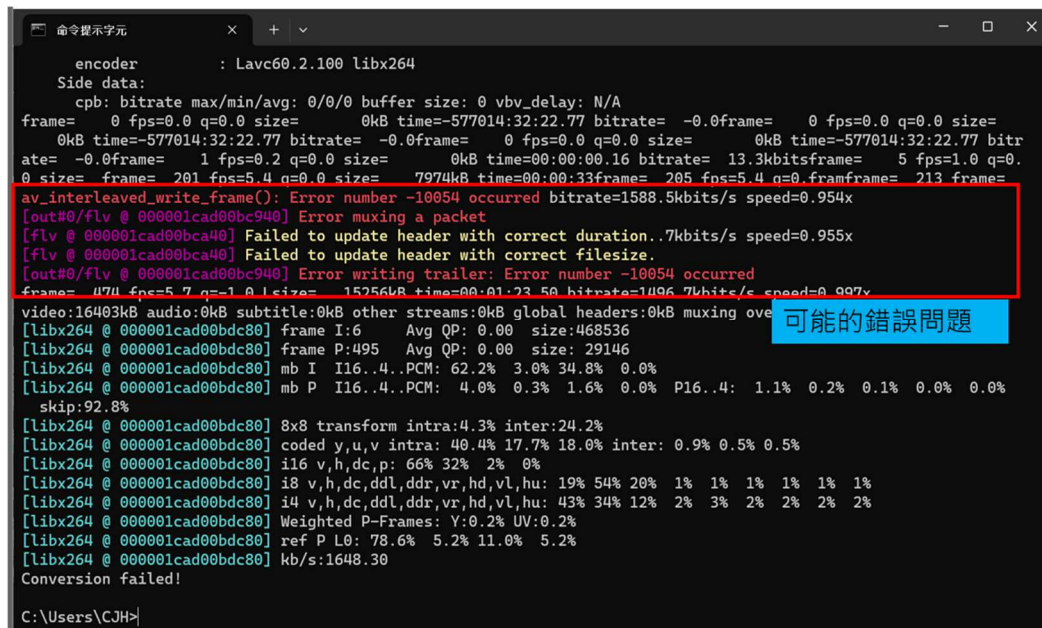
關於串流直播指令，本案提供了高品質直播指令的相關介紹如下：

- **ffmpeg**：這是 FFmpeg 命令列工具的名稱，用於處理音影片檔案。
- **-f gdigrab**：此選項指示 FFmpeg 使用 GDI（Windows 圖形裝置介面）進行螢幕擷取。
- **-framerate 6**：設定擷取螢幕的幀率為每秒 6 幀。
- **-i desktop**：指定擷取的對象為整個桌面。
- **-c: libx264**：選擇使用 libx264 編碼器進行影片編碼。
- **-qp 0**：設定影片的品質參數為 0，這代表最高品質。
- **-vf scale=720:-1**：使用影片濾鏡（scale）調整影片的寬度至 720 像素，高度按比例自動調整。
- **-f flv**：設定輸出的影片格式為 FLV。

● **rtmp://61.216.153.153:3004/live/avix**：指定 RTMP 伺服器的

的位址(範例)，用於串流影片。

UAV 回傳常見之影像串流格式 (RTMP、HLS)，影像串流轉發至影像串流服務中，由影像串流服務完成整合並由網頁存取，供使用者透過網頁查看即時影像串流。其中，由於影像即時性受限於傳輸頻寬及網路速度，會存在一定時間的延遲。另外可能出現的錯誤問題，如圖 10.3 顯示在編碼過程中出現了問題，特別是有關 bitrate 和影片文件的混合。需要進行額外的調試並調整編碼設置。相關的處理流程為更改編碼器指令：`ffmpeg -i input.mp4 -c:v libx265 -c:a copy output.mp4`。完成相關指令後，圖 10.4 為實測串流畫面，以無人機拍攝國立臺灣大學總圖書館，並進行即時串流成果。



```
encoder : Lavc60.2.100 libx264
Side data:
cpb: bitrate max/min/avg: 0/0/0 buffer size: 0 vbv_delay: N/A
frame= 0 fps=0.0 q=0.0 size= 0kB time=-577014:32:22.77 bitrate= -0.0frame= 0 fps=0.0 q=0.0 size= 0kB time=-577014:32:22.77 bitrate= -0.0frame= 1 fps=0.2 q=0.0 size= 0kB time=00:00:00.16 bitrate= 13.3kbitsframe= 5 fps=1.0 q=0.0 size= 201 fps=5.4 q=0.0 size= 7974kB time=00:00:33frame= 205 fps=5.4 q=0.0 frame= 213 frame= 474 fps=5.7 q=1.0 size= 15256kB time=00:01:23.50 bitrate=1406.7kbits/s speed=0.997x
av_interleaved_write_frame(): Error number -10054 occurred bitrate=1588.5kbits/s speed=0.954x
[out#0/flv @ 000001cad00bc940] Error muxing a packet
[flv @ 000001cad00bc940] Failed to update header with correct duration..7kbits/s speed=0.955x
[flv @ 000001cad00bc940] Failed to update header with correct filesize.
[out#0/flv @ 000001cad00bc940] Error writing trailer: Error number -10054 occurred
frame= 474 fps=5.7 q=1.0 size= 15256kB time=00:01:23.50 bitrate=1406.7kbits/s speed=0.997x
video:16403kB audio:0kB subtitle:0kB other streams:0kB global headers:0kB muxing over
[libx264 @ 000001cad00bdc80] frame I:6 Avg QP: 0.00 size:468536
[libx264 @ 000001cad00bdc80] frame P:495 Avg QP: 0.00 size: 29146
[libx264 @ 000001cad00bdc80] mb I I16..4..PCM: 62.2% 3.0% 34.8% 0.0%
[libx264 @ 000001cad00bdc80] mb P I16..4..PCM: 4.0% 0.3% 1.6% 0.0% P16..4: 1.1% 0.2% 0.1% 0.0% 0.0%
skip:92.8%
[libx264 @ 000001cad00bdc80] 8x8 transform intra:4.3% inter:24.2%
[libx264 @ 000001cad00bdc80] coded y,u,v intra: 40.4% 17.7% 18.0% inter: 0.9% 0.5% 0.5%
[libx264 @ 000001cad00bdc80] i16 v,h,dc,p: 66% 32% 2% 0%
[libx264 @ 000001cad00bdc80] i8 v,h,dc,ddl,ddr,vr,hd,vl,hu: 19% 54% 20% 1% 1% 1% 1% 1%
[libx264 @ 000001cad00bdc80] i4 v,h,dc,ddl,ddr,vr,hd,vl,hu: 43% 34% 12% 2% 3% 2% 2% 2%
[libx264 @ 000001cad00bdc80] Weighted P-Frames: Y:0.2% UV:0.2%
[libx264 @ 000001cad00bdc80] ref P L0: 78.6% 5.2% 11.0% 5.2%
[libx264 @ 000001cad00bdc80] kb/s:1648.30
Conversion failed!
C:\Users\CJH>
```

圖 10.3 可能出現的轉播錯誤問題

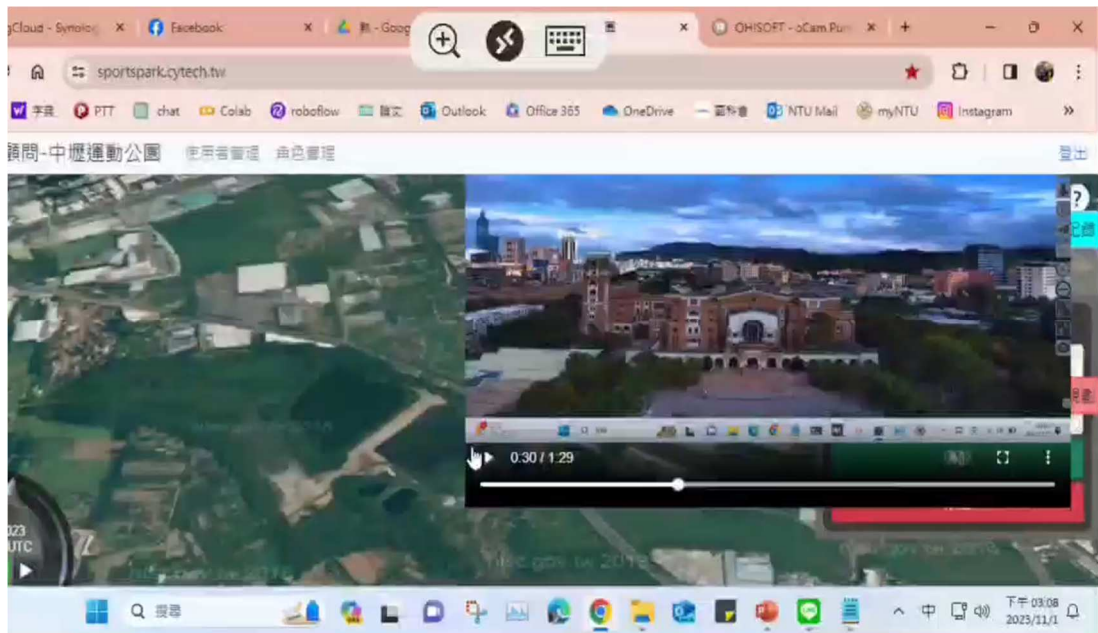


圖 10.4 臺大總圖書館無人機拍攝影像串流畫面

10.2 地面無人載具

本期計畫以實現即時數據串流為主要目標，透過使用者操作電腦與無人地面載具（UGV）之間的遠端操控進行數據傳輸。使用者操作電腦與 UGV 分別連接至不同之無線網路分享器，並透過 SSH 協議將感測器、GPS 數據、氣體偵測器資料、熱像儀數據及圖片即時傳輸至使用者電腦。為確保數據傳輸的穩定性和即時性，系統擬採用了多無線網路設置並整合 4G 網路。實地測試結果顯示，該系統於港區不同環境下皆能維持良好的傳輸速度。圖 10.5 為蒐集之資料以及傳輸之流程圖：

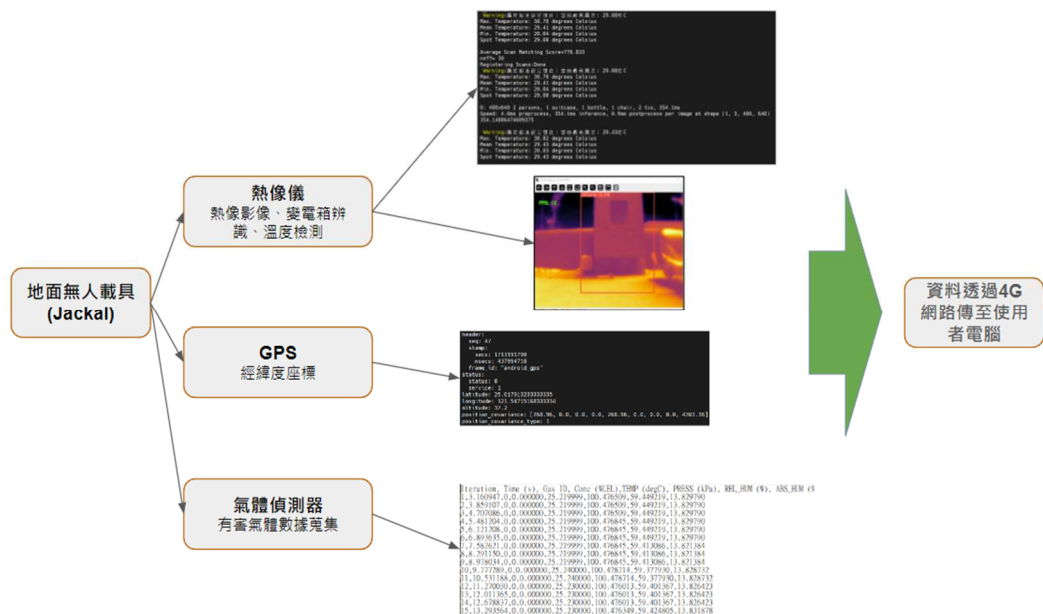


圖 10.5 蒐集之感測器資料和數據串流流程圖

10.3 本章小結

本計畫深入探討了使用 FFmpeg 進行即時影像串流的整體架構與實作方式，重點在於實現多樣化的串流方案，涵蓋不同編碼器和解析度設定，以滿足不同場景與需求。經過縝密的測試與優化，成功建置並實施了包含 GPU 與 CPU 解碼的多條指令路徑，以及直接從無人機鏡頭回傳影像的功能。這些指令確保了現場至遠端伺服器的高品質影像傳輸，並透過 SSL 安全憑證進一步保障傳輸過程的資料安全性。此外，也針對傳輸過程中可能發生的常見錯誤與問題進行了調試與調整，以確保影像串流的穩定性和連續性，進而提升系統可靠性與使用者體驗。

在地面無人載具方面，經由港區實地測試結果顯示，即時串流系統可穩定地將蒐集的感測器數據與影像回傳至使用者操作電腦。

第十一章、系統整合平台

11.1 平台架構與功能介紹

本平台以 Node.js 語言進行開發，搭配資料庫系統 Mysql，建構軟體開發環境，Node.js 語言是非同步和事件驅動的架構，這使 Node.js 能夠高效地處理大量併發請求，其次，Node.js 基於 JavaScript，這使得前端和後端開發可以使用相同的語言，促進了開發人員之間的協作，並降低了團隊的學習曲線。此外，Node.js 擁有強大的生態系統，通過 npm (Node Package Manager) 可以輕鬆地獲取和整合數以萬計的開源函式庫，進一步加速開發過程。

Node.js 的輕量性和高效性使其特別適合微服務架構，能夠快速構建和部署可擴展的應用。綜合來看，Node.js 提供了一個高效、靈活且易於學習的開發平台，非常適合本計畫使用；在網頁前端的部分使用開源技術 CesiumJS 進行開發，CesiumJS 為 Cesium 公司所釋出之開源 Javascript 函式庫，應用於 Web3D 地圖的呈現、互動操作等，CesiumJS 具備輕量化、快速的使用者體驗，此外，CesiumJS 除支援 3D 圖形化之呈現外，對於地理資訊之坐標系統與常見之空間資料格式亦有具備高支援度與整合性。本計畫系統功能架構圖如圖 11.1 所示，其中紅色底色的功能為本期建置之成果，成果說明如後所述。

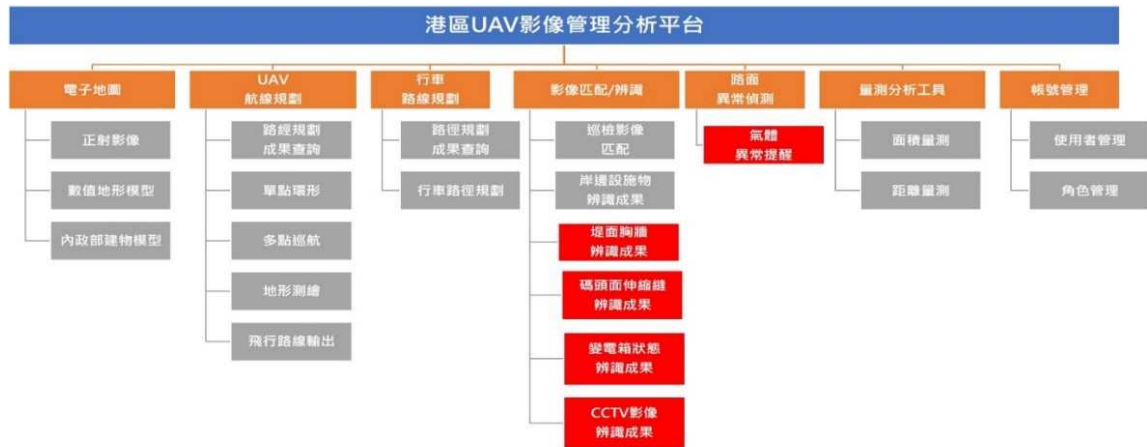


圖 11.1 系統功能架構圖

11.2 平台功能展示說明

11.2.1 基本圖層

系統提供多重圖資之存取展示，有利使用者進行相關資料之查看與評判，介接的圖資包含國土測繪中心正射影像(圖 11.2)、本計畫拍攝製作的正射影像(圖 11.3)及數值地形模型(圖 11.4)、內政部提供的建物 3D 模型(圖 11.5)等。



圖 11.2 國土測繪中心正射影像



圖 11.3 本計畫拍攝製作的正射影像




圖 11.4 本計畫拍攝製作的數值地形模型



圖 11.5 內政部提供的建物 3D 模型

11.2.2 量測功能

系統支援使用者於圖台上進行量測，透過於圖台上點選特定點位，系統自動取得該點位之坐標值，將相關資訊呈現給使用者。

點擊系統左側選單，開啟影像量測功能選單(圖 11.6)，系統具備距離量測及面積量測 2 種工具，點擊對應之按鈕啟動量測工具後，可於右側之影像上進行特定點位置之選取，系統可根據正射影像或數值地形模型中之相關資訊，計算劃定範圍內於真實物空間中之面積、距離，如圖 11.6 及圖 11.7 所示。




圖 11.6 距離量測功能

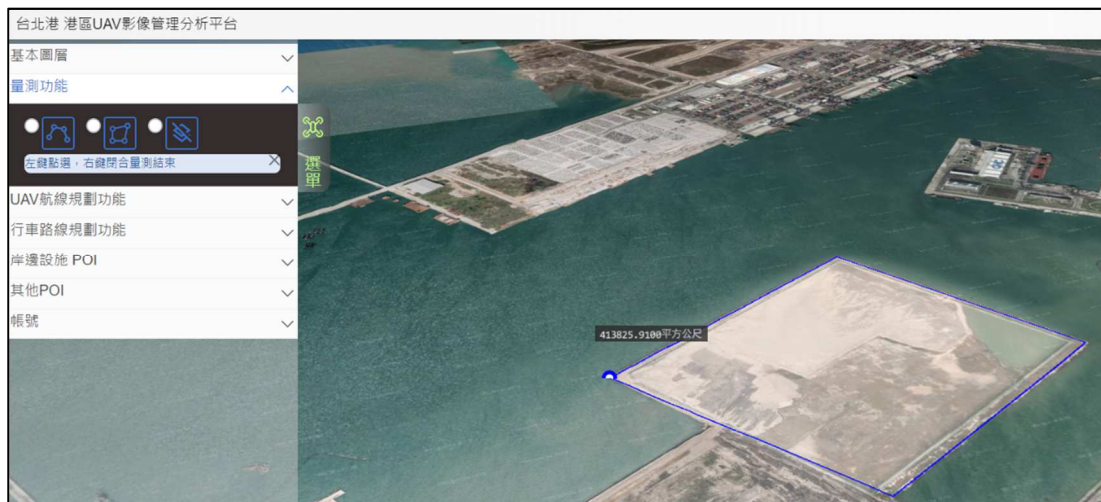


圖 11.7 面積量測功能

11.2.3 UAV 航線規劃

針對不同之資料蒐集目的，平台提供 3 種飛行模式，各模式規劃之成果，如圖 11.8 所示。

- 單點環行：選擇指定目標物後，系統自動根據與目標物之距離、周圍建物高度及資料蒐集精細程度等條件，以目標物為中心，生成圓形之飛行軌跡。
- 多點巡航：選擇指定目標物後，點擊指定飛行點位，系統根據相關資訊生成飛行軌跡。
- 地形測繪：圈繪指定飛行區域後，系統根據選取區域及預設之影像重疊率進行航線規劃。




圖 11.8 航線規劃成果

使用者開啟各飛行路徑規劃模式(圖 11.9)後，於右側電子地圖內點選輸入起訖點及目標區域，點擊左側規劃參數設定按鈕，輸入各項飛行參數後，點擊規劃參數設定對話框中，執行飛行路線規畫之按鈕(圖 11.10 紅框處)，系統自動規劃飛行路徑並跳出提示(圖 11.11)。




圖 11.9 飛行路徑規劃功能

航線規劃參數設定

環拍半徑: 20

起始點位(X): 287585.66870 起始點位(Y): 2782327.21092 路徑點位(X): 288503.06081 路徑點位(Y): 2782104.75040

飛行速率(m/s): 3 航高(m): 30 相對飛行方式: 0 緩衝區大小: 6

可飛行時間(min): 20 拍攝角度(度): 45 安全係數: 0.7

執行飛行路線規劃 取消

圖 11.10 飛行點位圈繪及規劃參數輸入

程式執行中!, 稍後請查詢專案編號: 39

確定

圖 11.11 規劃提示視窗

使用者透過系統頁面輸入相關規劃資訊後，系統自動進行航線規劃，規劃完成後，使用者可開啟規劃路線列表(圖 11.12)操作相關管理行為，包括：查看規劃狀態、查看規劃路線、查看細節參數、匯出路線檔案、刪除飛行規劃及重新執行規劃。

專案編號	建立時間	模式	狀態	規劃耗時(秒)	展示	詳細內容	匯出	刪除	REDO
39	2023/10/11 17:12:25	單點環拍	規劃完成	0.012					
38	2023/09/05 15:20:34	單點環拍	規劃完成	0.021					
37	2023/08/29 14:31:57	地形測繪	規劃完成	0.01					
36	2023/08/29 14:31:20	地形測繪	規劃完成	0.019					
35	2023/08/29	地形測繪	規劃完成	0.04					

1 2 3 4 >> 1 of 4

圖 11.12 規劃成果列表

11.2.4 UAV 斜拍調查影像查詢

uav 影像上傳完成後，系統擷取影像資訊檔內的坐標訊息，將該影像歸類於特定位置之 poi(Point of Interest, POI)內，並且在上傳完成後，提供 AI 物件辨識的功能，針對碰墊、反光板、車擋及繫船柱的存在狀態進行辨識，並將成果呈現於頁面上供使用者查看(圖 11.13 及圖 11.14)。




圖 11.13 巡檢影像查看頁面

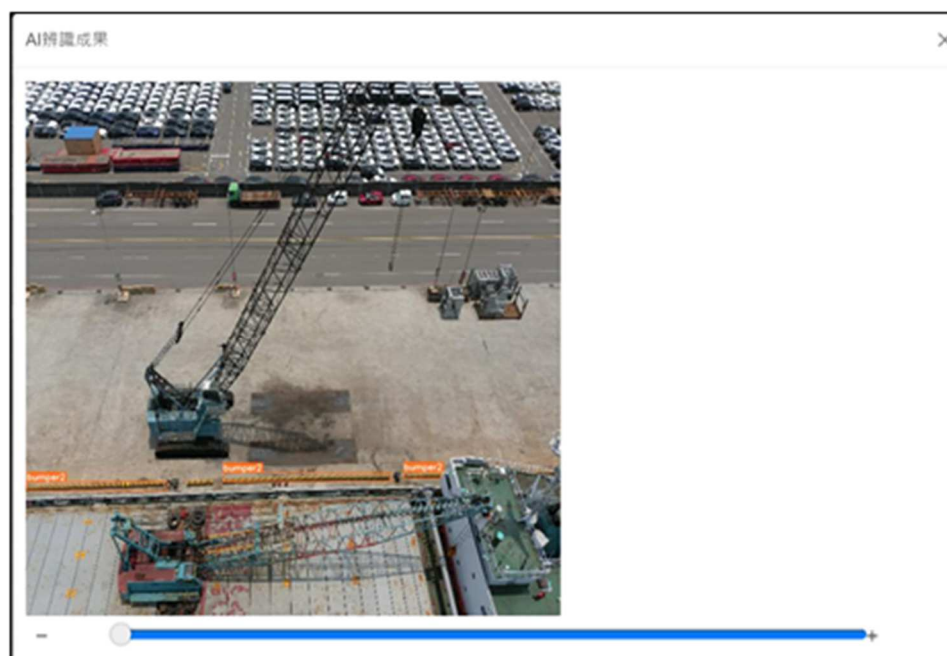


圖 11.14 AI 辨識成果查看

11.2.5 路面破損評分

本計畫將使用 AI 影像辨識所得之各類型異狀，根據路面分級制度，將各區塊路面進行評級，並使用不同顏色標註，以利使用者快速了解各路面區段之狀態，使用者點擊開啟對應圖層後，路段位置會有顏色區塊的圖層展示(圖 11.15)，並於左下方產生圖例，方便使用者進行比對查看。




圖 11.15 路面 PCI 成果

11.2.6 堤面胸牆辨識成果

本期工作於堤面位置建置有 34 個 POI 點，點位分布情形如圖 11.16 所示，系統目前建置有 2024 年 5 月至 9 月之資料，點擊 POI 點可查看該位置不同時期的辨識成果(圖 11.17 及圖 11.18)。




圖 11.16 堤面胸牆 POI 點位分布情形

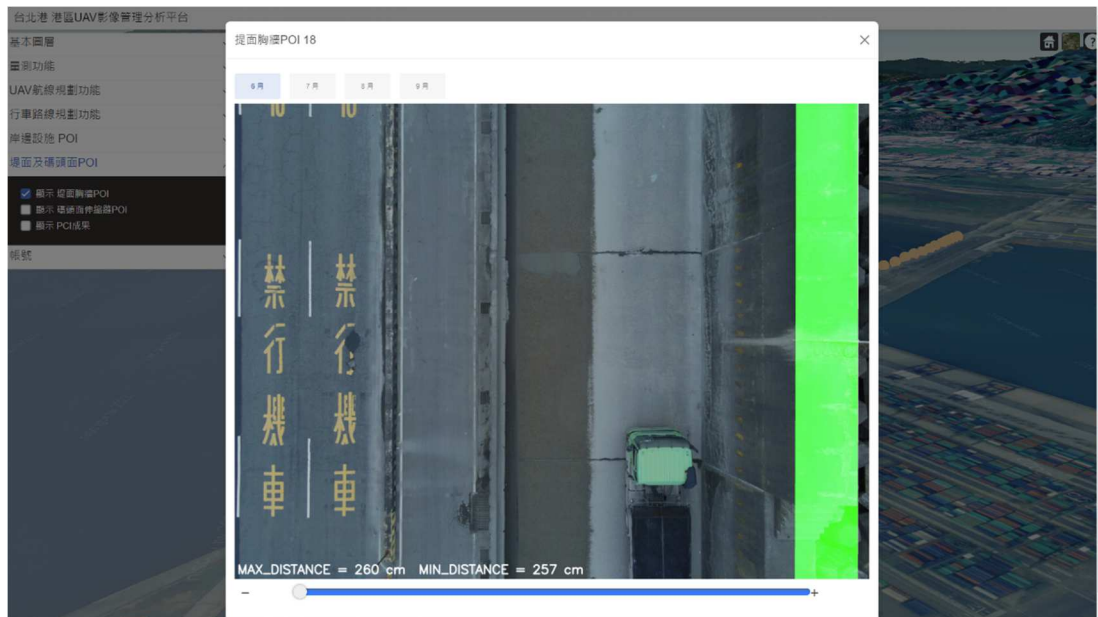


圖 11.17 堤面 18 號 POI 點 6 月份之辨識成果

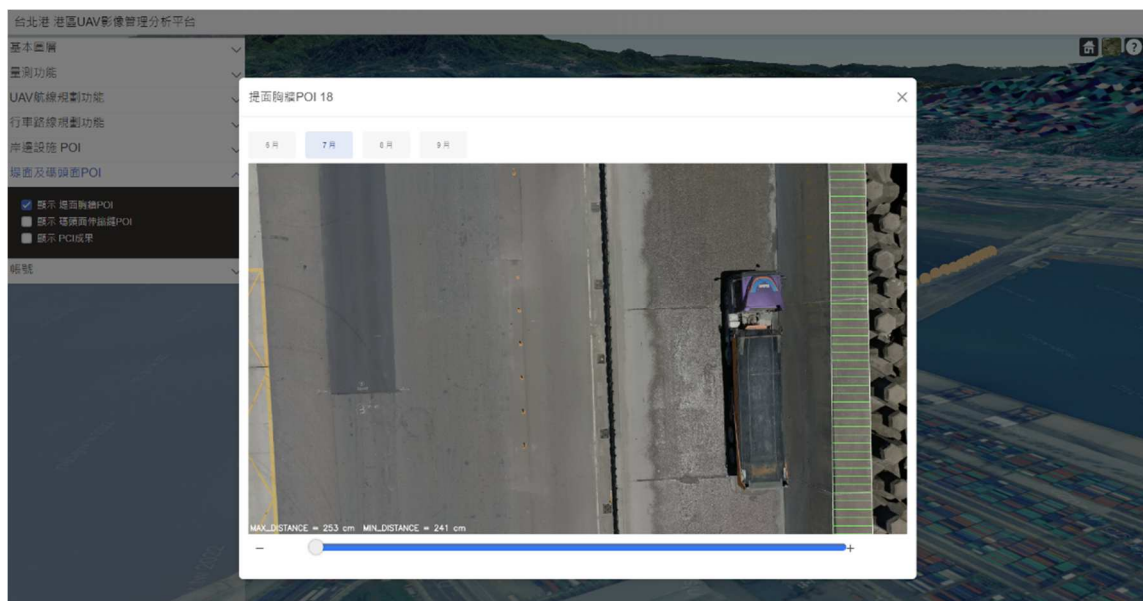


圖 11.18 堤面 18 號 POI 點 7 月份之辨識成果

11.2.7 碼頭面伸縮縫辨識成果

碼頭面伸縮縫辨識 POI 分為 A1 區(圖 11.19 上半部 POI)及 A2 區(圖 11.19 下半部 POI)，A1 區建置有 99 個 POI 點，A2 區建置有 81 個 POI 點，各 POI 點依辨識成果不同，以橘色、綠色及紅色進行標註，

點擊 POI 可查看該點位於不同時期之道路伸縮縫辨識成果(圖 11.20、圖 11.21)，若該 POI 點未存取到影像則顯示灰色。




圖 11.19 碼頭面 POI 點位分布情形

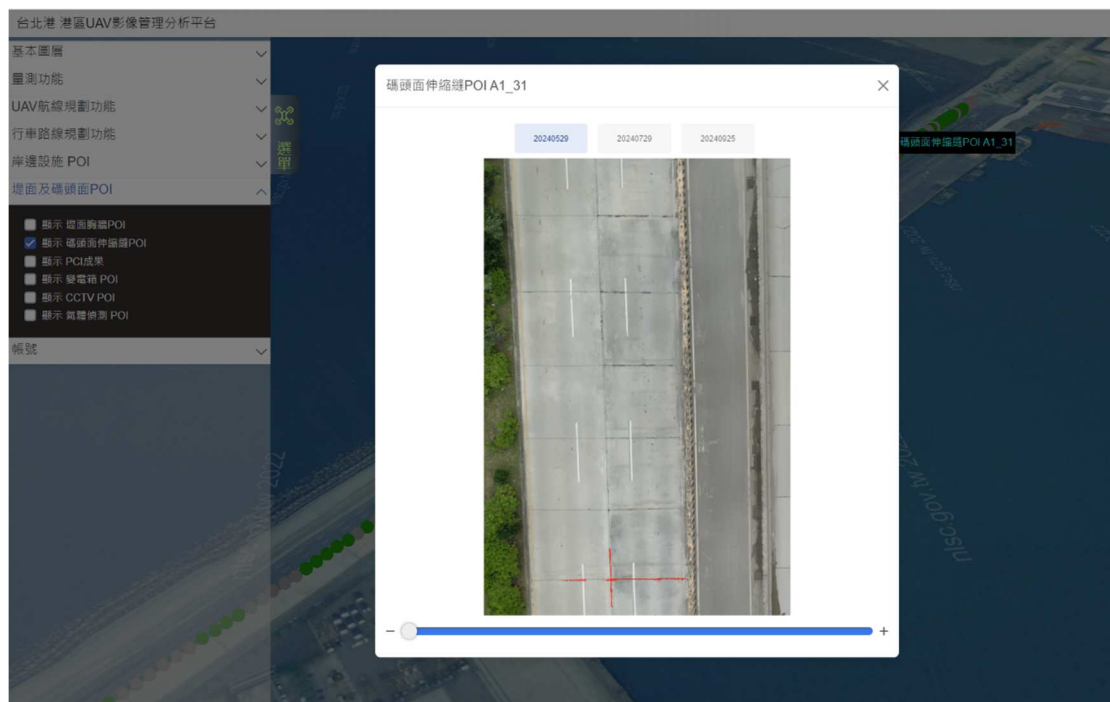


圖 11.20 碼頭面 A1 區 31 號 POI 點 5 月份之辨識成果

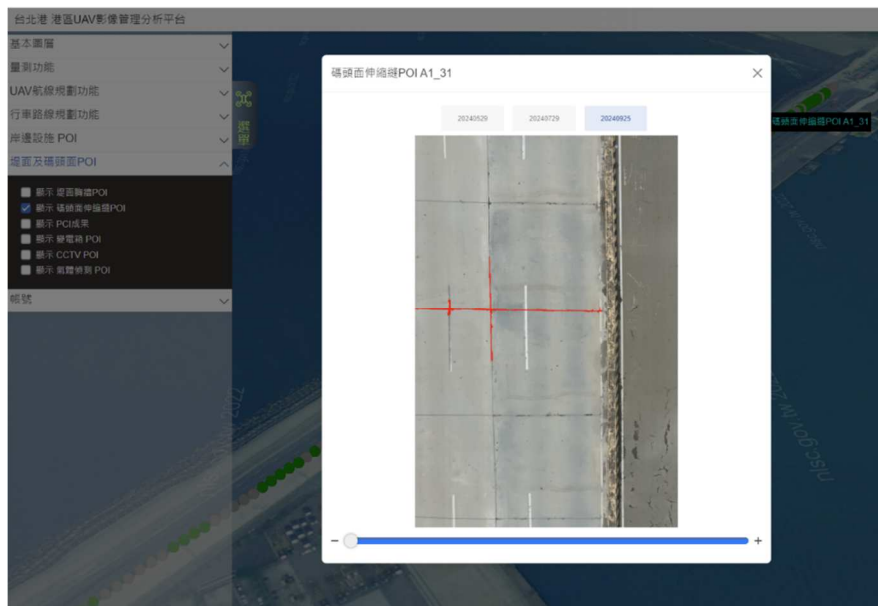


圖 11.21 碼頭面 A1 區 31 號 POI 點 9 月份之辨識成果

11.2.8 變電箱狀態辨識成果

依據變電箱所在位置，系統建置有對應的 POI 點位，可供使用者查看不同時期變電箱熱影像辨識之成果，平台上目前建立有 3 個變電箱 POI，各 POI 內建置有 113 年 5 月(圖 11.23)、6 月、9 月(圖 11.24)、10 月之成果，點擊 POI(圖 11.22)可切換查看不同時期之熱影像。



圖 11.22 變電箱 POI 點位分布情形

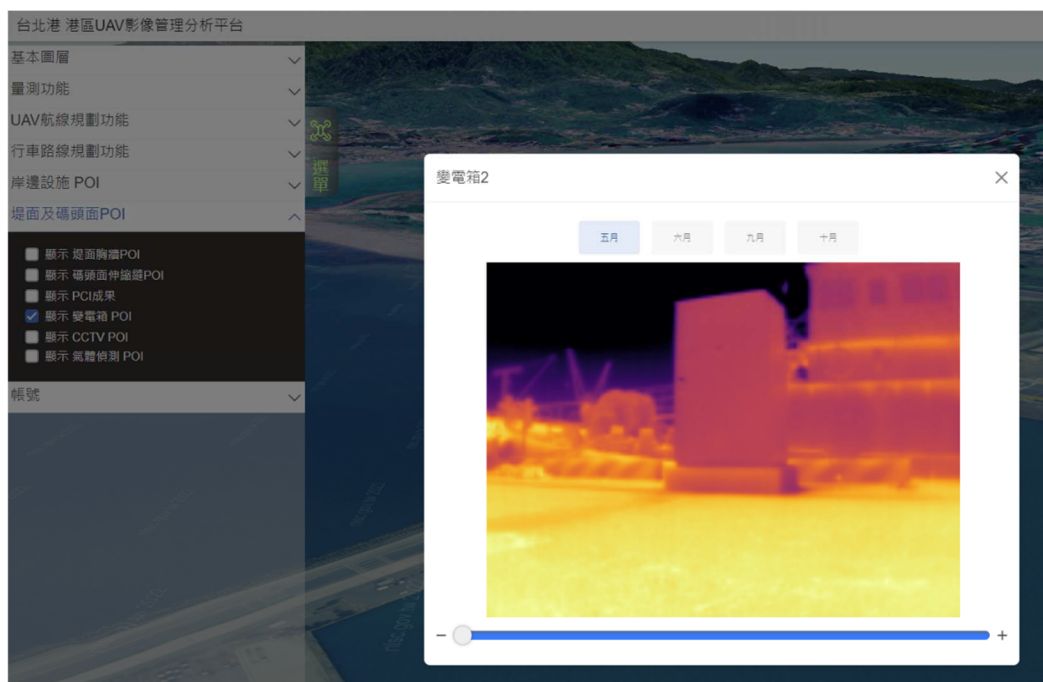


圖 11.23 變電箱 2 號 POI 5 月之熱影像

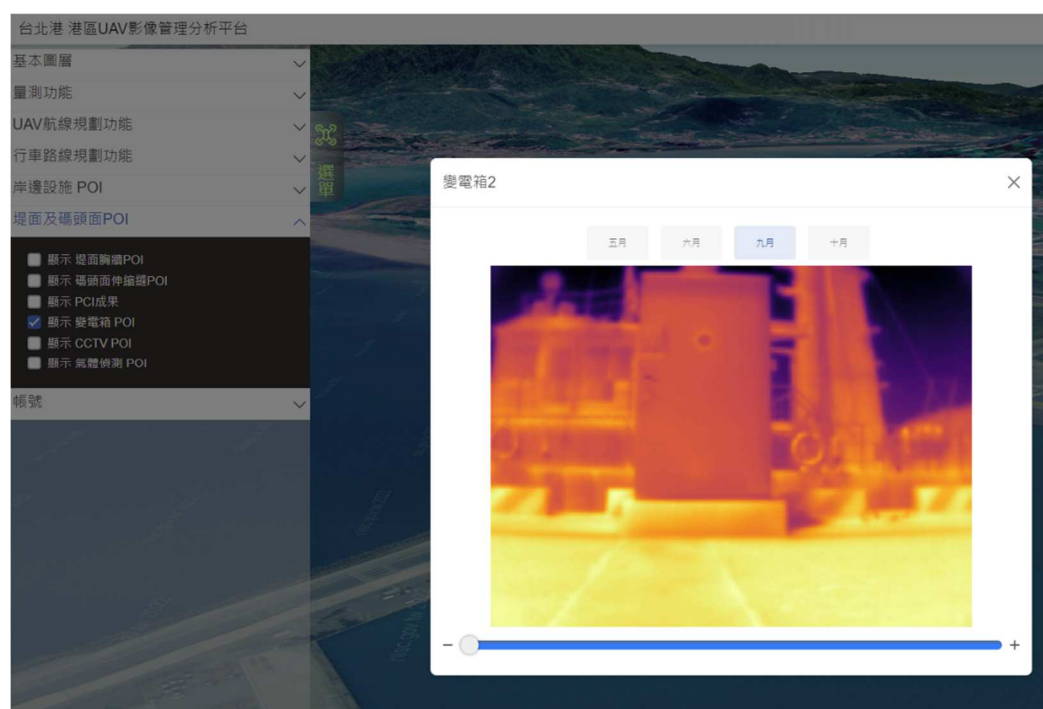


圖 11.24 變電箱 2 號 POI 9 月之熱影像

11.2.9 CCTV 設施物辨識成果

依據業主提供之 CCTV 位置，平台上建置有 4 個 CCTV POI 點位(圖 11.25)，其位置描述分別為東 4 碼頭增設、東 4 碼頭增設(2)、

東 5 碼頭往東 4 碼頭及東五碼頭作業區，點擊 POI 可查看該位置之辨識成果影片(圖 11.26)，在影片中可查看每一秒鐘，設施物辨識情形的變化，點擊影片窗格中的放大按鈕，可全螢幕檢視影片(圖 11.27)。




圖 11.25 CCTV POI 分布情形



圖 11.26 CCTV POI 東五碼頭作業區影片




圖 11.27 影片全螢幕檢視畫面

11.2.10 氣體偵測異常提示

地面無人車行進過程，於指定區域蒐集氣體相關數值及蒐集地點，事後於平台內建立有氣體偵測 POI 共 45 個(圖 11.28)，紀錄、展示各點位之氣體資訊，其內容包含可燃氣體濃度(%LEL)、氣壓(kPa)、相對濕度(%)及相對溼度(%) (圖 11.29、圖 11.30)。



圖 11.28 氣體偵測 POI 點位分布情形



圖 11.29 氣體偵測 1 號 POI 5 月之成果



圖 11.30 氣體偵測 1 號 POI 9 月之成果

11.3 本章小結

本計畫開發建立 3D 電子地圖圖台，做為資料展示介面，介接其他單位提供之 WMS/WMTS 標準化圖磚資料做為底圖外，並基於本

計畫過去執行飛行任務的成果影像，進行各項分析與辨識，將相關成果整合於圖台之上，提供使用者一快速掌握港區情況之實用工具，輔助使用者進行港區及周遭位置狀態之理解及判斷。除資料展示外，系統亦提供 uav 航線規劃功能及量測功能等工具，輔助使用者順利推進相關業務執之進行，並於 113 度新增地面車輛相關功能之開發及整合，提供更全面的業務支援。

第十二章、實地驗證與品質評估

12.1 無人機影像品質檢核

12.1.1 原始影像解析度檢核

為製作高解析度正射影像和三維點雲，原始拍攝的影像品質至關重要。本計畫隨機選取了原始製作整個測區正射影像所使用的影像，以確保原始影像的解析度是否足夠。由於原始影像本身沒有真實的尺度資訊，必須透過像素級別的觀察來評估其解析度。因此，選擇了路面標線作為參考物件，並查看白線和雙黃線的寬度，白線和雙黃線的單線寬度都是 10 公分。本計畫設定了目標解析度為 5 公分。根據這個目標，需要確保原始影像上的白線寬度大致等於 2 到 3 個像素的大小。觀察到，圖 12.1 中的標線都呈現出均勻的 2-3 像素寬度，而且肉眼可以清晰地識別其邊界。這表明原始拍攝的影像提供了足夠的解析度，且也沒有模糊或扭曲的現象發生，因此，品質足夠可以用來生成高解析度的正射影像。




圖 12.1 原始 UAV 航拍影像

12.1.2 正射影像幾何精度檢核

關於正射影像幾何精度檢核，在這個案例中，選擇了斑馬線和雙白線做為檢核對象。斑馬線之所以被選用，是因為它具有高度對比的地面特徵，這使得它特別容易識別。根據臺灣目前的交通部和內政部的規定（道路交通標誌標線號誌設置規則第 185 條），斑馬線應該設置在交岔路口上，其線型為枕木紋白色實線，線段長度應在 3 公尺至 8 公尺之間，寬度為 40 公分。因此，將檢查斑馬線的寬度是否符合這個規定。另外，第 2 個檢核對象是雙白線，依據道路交通標誌標線號誌設置規則第 158 條的規定，這種標線是一條雙白虛線，每段長度為 4 公尺，間距為 6 公尺，線寬為 10 公分，間隔為 10 公分。考慮整體雙白線的寬度，將檢查它是否符合整條線的寬度為 30 公分的寬度。使用均方根誤差公式來檢核，如式(12-1)，其中 X_i 為量測值、 x_i 為真值、 N 為檢核數量。檢核成果如表 12-1 所示，整體誤差約為 ± 0.056 m。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - x_i)^2}{N-1}} \quad (12-1)$$

表 12-1 斑馬線影像尺寸檢核表

數量	量測值(m)	誤差(m)
1	40.015	0.015
2	40.034	0.034
3	40.081	0.081
4	39.985	-0.015
5	39.895	-0.105
6	40.017	0.017
7	40.055	0.055
8	40.066	0.066
9	40.057	0.057
10	40.038	0.038
RMSE= ± 0.056 m		

12.1.3 數值地形模型高程精度檢核

為評估臺北港港區域的 DSM 高程數據品質，本計畫使用 112 個既有的控制點（E，N，H）如圖 12.2。這些控制點是 111 年的測繪成果，具有已知的 TWD97/Zone 121 地理坐標（Easting 和 Northing）以及高程（H）。本計畫的目標是檢查 DSM 中的高程數據是否與這

些控制點的已知數據一致，以評估其準確性。首先，從 DSM 中提取了 112 個控制點的高程數據，這些點在臺北港區域內均勻分佈。接下來，如式(1)使用均方根誤差（RMSE）公式來統計 DSM 高程數據的誤差。檢核精度如表 12-2 所示。




圖 12.2 檢核點坐標分布圖

表 12-2 DSM 誤差精度統計表


項目	內容
最大值	0.855m
最小值	-0.755m
RMSE	$\pm 0.339\text{m}$

12.2 UGV 導航路徑正確性檢核

本計畫於至臺北港執行工作項目時，進行 UGV 路徑規劃測試，測試 UGV 於戶外環境之自主導航和資料蒐集能力。測試地點為臺北港區內的 4 個目標點(圖 12.3)，並檢查其路徑軌跡記錄。檢查清單的目的是確保機器人是否抵達了預定的目標點，以及在過程中是否碰撞到了任何物體。



(a)



(b)

圖 12.3 (a) 地面機器人路徑正確性檢核實驗地點


(b) 地面機器人路徑記錄在 RVIZ 顯示

最後的測試結果令人滿意。UGV 在實驗中成功達到了所有預定的目標點，並在整個過程中未出現任何碰撞或障礙。並且對於避障

功能，本次測試結果發現地面無人載具對於障礙物可以在不碰撞的情況下，避開並且規劃出一條新的路徑抵達目標點，結果非常成功。

12.3 標的物件辨識及變遷偵測信賴度評估

根據實際偵測變電箱的成果，如圖 12.4 發現模型信心值在多個測試情境下都非常穩定。以下是對這些成果的進一步分析，在實際偵測過程中，模型產生的信心值分別為 0.91、0.96、0.64、0.90、0.56、和 0.75。這些信心值表示模型對於偵測到的變電箱的信心程度，越高的信心值代表模型對於偵測結果的信心越高。在這些成果中，所有的信心值都高於 0.5，這表明模型對於其偵測結果非常自信且可信度較高。值得注意的是，這個模型經過樣本增強後，在不同拍攝角度都能成功辨識變電箱。這顯示模型在面對不同視角和場景時都能保持穩定的性能，這對於實際應用非常關鍵。不論是在變電箱位於不同位置、角度或光線條件下，模型都能夠可靠地偵測變電箱，這增強了其實用性。






圖 12.4 不同拍攝角度變電箱偵測成果

12.4 道路破損評分

此結使用之模型同 5.3 使用之模型，詳見 5.3.2 之模型介紹，而成果如表 6-3 所示，而該模型在裂縫的預測結果，如圖 12.5 所示，之後便基於該預測結果進行路面破損評估，詳述於以下小結。




圖 12.5 路面裂縫模型預測結果

12.4.1 裂縫分級定義

本研究參考市區道路管理維護與技術規範手冊研究，將裂縫的嚴重程度分為 3 級：

(1) 輕級：

裂縫型態呈細小毛髮狀，且裂縫沒有破裂現象，裂縫可填補但不可有滲水情況，無填補之裂縫平均寬度須小於 0.3 公分以下，不會導致車輛有明顯跳動現象，如圖 12.6。




圖 12.6 輕級裂縫

(2) 中級:

裂縫有輕微破裂現象，且裂縫周圍或相交處有其他細小、不規則裂縫出現。有填補之裂縫會有滲水情況，無填補之裂縫平均寬度須介於 0.3 公分至 0.5 公分，導致車輛有較明顯跳動現象，如圖 12.7。




圖 12.7 中級裂縫

(3) 重級：

裂縫有嚴重破裂現象，且裂縫周圍或相交處有其他中級至重級嚴重程度之不規則裂縫出現。已填補之裂縫有滲水情況，無填補之

裂縫平均寬度會大於 0.5 公分，導致車輛有較劇烈跳動現象，如圖 12.8。




圖 12.8 重級裂縫

12.4.2 坑洞分級

坑洞分級標準於市區道路管理維護與技術規範手冊中評估了坑洞面積及深度資訊，因本研究之航攝影像不易取得深度資訊，因此僅以坑洞面積為標準進行分級，標準如表 12-3，A 為坑洞面積。

表 12-3 坑洞分級標準

\sqrt{A} 小於 15cm	\sqrt{A} 介於 15cm 至 30cm	\sqrt{A} 大於 30cm
輕級	中級	重級

12.4.3 評分方法原理

(1) 各級裂縫長度計算

本計畫參考骨架正交法(Sunet al., 2021)來評估裂縫的寬度，以圖 12.9 為例，流程如下：

1. 利用骨幹化(詳見 8.5.2.2)的方式求得裂縫中線。
2. 用 SVD(Klema and Laub, 1980)算出中線上某個點的法線（藍線 y 軸）。

3. 將裂縫輪廓線上最接近法線的兩個點連線並找出與法線的交點（紅點）。
4. 於另一邊重複步驟三，並將兩交點連起來，連線長度即為該點寬度。
5. 在每條裂縫上每 20 公分量一次長度，不到 20 公分者則不量，最後即可算出該裂縫的最大，最小及平均寬度。
6. 將所有得到的寬度用 13.4.1 的標準分級，並將各級裂縫的數量乘 0.2m 獲得總長。




圖 12.9 圖解骨架正交法

(2) 骨幹化(Skeletonize)

本計畫參考 Zhang and Suen(1984)論文提出的方式來進行骨架化，骨架化目的為找出裂縫走向，如此，才能找出法向量並算出寬度，流程如下(用預裂縫上的成果則如圖 12.11 所示)：

1. 將圖片轉換成二值圖，以圖 12.10 為例，符號@代表 1，而符號.代表 0。
2. 將圖中 1 的部分由最外層一層一層的轉換成 0，直到留下來的部分滿足以下條件：

- a、寬度只有一個像素寬，並為骨架的端點。
- b、該像素兩端都是骨架，為骨架的中點。




圖 12.10 圖解骨幹化




圖 12.11 骨架化成果

(3) 路面狀況評估

路面狀況評估流程如下：

1. 將原圖放入模型預測出所有裂縫及坑洞。
2. 計算折減值，如表 12-4 所示，將裂縫以章節 12.4.1 之流程計算各級裂縫之長度並除以路面面積以獲得各級裂縫密度。
3. 將坑洞預測結果以章節 12.4.2 之標準分級，將各級坑洞面積加總，計算密度填入表 12-4。
4. 對密度取 log 得 x ，如式 12-2。接著依公式換算折減值，公式分為兩類，坑洞(式 12-3~式 12-5)及裂縫(式 12-6~式 12-8)，每類各含三個公式，套用到輕(式 12-3、式 12-6)、中(式 12-4、式 12-7)，以及重(式 12-5、式 12-8)三個分級。
5. 折減值大於 2 者列入 CDV 計算，以表 12-4 為例，將 9.56(1H)、5.19(1M)，及 3.46(2M)依大小填入表 12-5 進行計算。
6. 將各折減值迭代計算 CDV，首先將折減值加總藉公式計算 CDV，公式為式 12-9~12-14，挑選標準為該次迭代中有多少折減值大於 2，以 No.1 為例，在第 1 次 3 個折減值皆大於 2，因此取式 9(N3)，算得 CDV 則將最小折減值替換成 2，進行下一輪迭代，直到所有值皆為 2，後於 CDV 中取最大值，表 12-5 為例最終 CDV 為 13.56，則 $PCI = 100 - 13.56 = 86.44$ 。

表 12-4 鋪面折減值計算

路面面積 = 148 m^2			
損壞種類及型式 1 裂縫 2. 坑洞 嚴重程度 輕級：L、中級：M、重級：H			
損壞類型及嚴重程度	總數	密度(D) (%)	折減值(d)
1L	4.6 m	3.10	1.73
1M	2.6 m	1.75	5.19
1H	1.8 m	1.21	9.56
2L	0.04 m^2	0.02	-5.89
2M	0.11 m^2	0.07	3.46

表 12-5 鋪面 CDV 計算

No.	折減值 (deduct Value)			Total	q	CDV
1	9.56	5.19	3.46	18.21	3	8.10
2	9.56	5.19	2	16.75	2	11.16
3	9.56	2	2	13.56	1	13.56

$$x = \log(D) \quad (12-2)$$

$$d = 21.2 + 27.15x + 6.41x^2 \quad (12-3)$$

$$d = 31.4 + 40.77x + 14.14x^2 \quad (12-4)$$

$$d = 52.3 + 43.87x + 10.22x^2 \quad (12-5)$$

$$d = -1.7 + 4.45x + 5.18x^2 \quad (12-6)$$

$$d = 2.1 + 11.51x + 4.93x^2 \quad (12-7)$$

$$d = 8.3 + 14.06x + 12.96x^2 \quad (12-8)$$

$$N2 \text{ CDV} = -3.6 + 0.91 \times \text{Total} - 0.0017 \times \text{Total}^2 \quad (12-9)$$

$$N3 \text{ CDV} = -6.4 + 0.82 \times \text{Total} - 0.0013 \times \text{Total}^2 \quad (12-10)$$

$$N4 \text{ CDV} = -13 + 0.86 \times \text{Total} - 0.0015 \times \text{Total}^2 \quad (12-11)$$

$$N5 \text{ CDV} = -12 + 0.76 \times \text{Total} - 0.0011 \times \text{Total}^2 \quad (12-12)$$

$$N6 \text{ CDV} = -14.7 + 0.75 \times \text{Total} - 0.0011 \times \text{Total}^2 \quad (12-13)$$

$$N7 \text{ CDV} = -18.5 + 0.86 \times \text{Total} - 0.0018 \times \text{Total}^2 \quad (12-14)$$

表 12-6 PCI 等級對照表

PCI 值	等級(Rating)
85~100	最佳(Excellent)
70~85	很好(Very good)
55~70	好(Good)
40~55	尚可(Fair)
25~40	差(Poor)
10~25	很差(Very poor)
0~10	不合格(Failed)

12.4.4 路面裂縫評估成果

本計畫沿用 112 年度的方法，將路面每 20 公尺分為一段進行 PCI 檢測，不同於 111 年度於臺中港人工分割、拼湊出一張張圖片後再一一檢測，這次使用的是較系統化的分割流程，能夠自動的將檢測的路面航攝圖投影回具有 TWD97 坐標資訊的正射圖上，使模型可以精確地知道每條裂縫在哪個路段，方便對每個路段進行路況評估，流程圖如圖 12.12 所示，上半部為計算正射影像及逐個航攝影像的角度及座標關係，下半部為裂縫預測及評估，兩者資訊結合即可算出該航攝影像的路面狀況及位置。以下小結將詳述裂縫定位方法級路況評估結果。

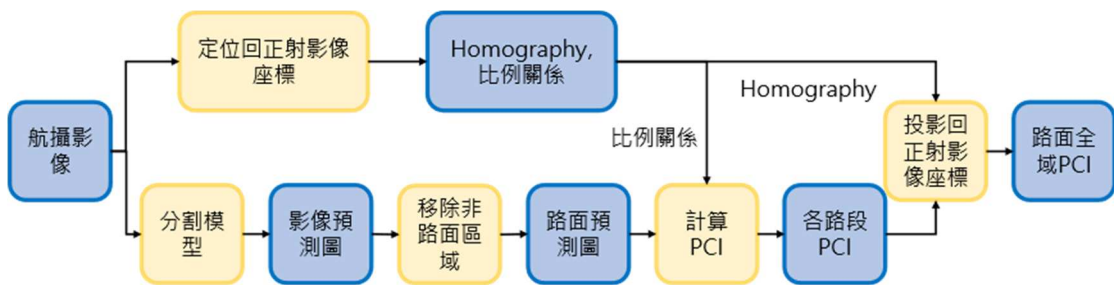


圖 12.12 裂縫預測及定位之流程圖

(1) 裂縫定位

本計畫透過利用航拍影像與正射影像之間的空間關聯來進行定位，如圖 12.13 所示。首先，根據航拍影像的 Exif 數據可以初步推測影像的大致位置，接著在此範圍內切割出相應的正射影像片段，並與航拍影像進行特徵點匹配，以計算兩者之間的 Homography。本研究採用的特徵點匹配方法是 SIFT，它是一種用於計算機視覺和影像處理的特徵檢測和描述算法。SIFT 的主要功能是在多種尺度和旋轉變化下識別影像中的關鍵點，並將其轉換為具有不變性的特徵向量，從而實現不同影像之間的匹配與識別。透過這種方式，可以確定航拍影像中的某一點在正射影像上的對應位置，進而推算出兩者之間的 Homography，如圖 12.14 所示。

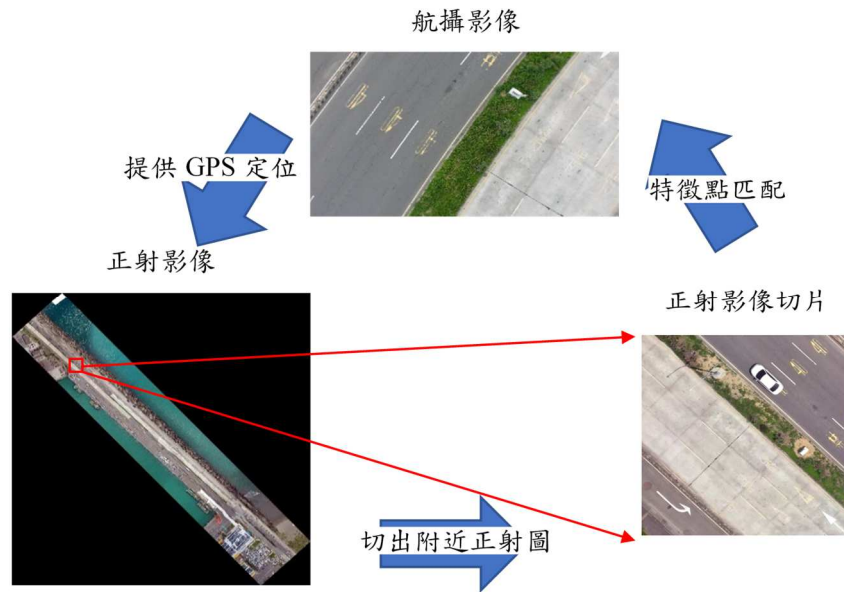


圖 12.13 航攝影像的資訊以及正射影像之間的關係



圖 12.14 SIFT 檢測的成果

(2) 路段劃分及編號

本計畫將目標檢測路段每 20 公尺分為一段，總共 82 段，每期固定分析相同位置，以利後續監測路面狀況，如圖 12.15 所示，每 20 公尺分為一段，總共 82 段，以此監控每段之路面狀況。模型能依據該期 UAV 影像所涵蓋到的範圍進行 PCI 估算，且因為能把每張航攝影像精準投放到正射影像上，因此，不會重複計算到影像重疊範圍，如圖 12.16 所示，可估算出各路段之路況。




圖 12.15 (a)正射影像原圖 (b)路面分段圖 (c)放大檢視





圖 12.16 分段評分結果

(3) 路面裂縫評估成果

模型預測結果如圖 12.17 所示，檢測目標分為 3 類:坑洞、伸縮縫及裂縫，破壞模式中僅包含坑洞及伸縮縫，因此只將裂縫及坑洞的預測結果納入 PCI 計算。






圖 12.17 道路裂縫，坑洞及伸縮縫預測成果

(4) 成果驗證

將 PCI 依表 12-6 分為 7 級，成果如圖 12.18 所示，可見路面大多為最佳狀態，少部分路段鋪面狀況較差，從 18(a)與 18(b)的比較中可見裂縫多在正射圖的上半部路段，而坑洞則多在下半部路段。而綜合成果，即兩者皆計算的成果，如圖 12.19 所示，可見上半柏油路段確實因多個裂縫導致 PCI 分數低落，而分數較高之路段則裂縫較少，另外可以注意到 PCI 分數較低處皆在柏油路段，可知水泥路面是較完整的，較少裂縫及坑洞，且雖然外觀相似，但模型不會將路面伸縮縫誤判為裂縫。




圖 12.18 PCI 檢測成果




圖 12.19 A1 道路路面狀況(PCI)分級

12.5 本章小結

本章說明並證實了如何將原始的像素級預測結果，利用骨幹化及寬度計算等影像處理方法，系統化地量化成路面狀況指標。這個方法還能夠將路面分割成小區域，以便定期檢查路面狀況。此外，它還能將裂縫位置轉換成世界坐標，以計算各路段的路面狀況，從而達到定期檢測的目標。最後的目視結果證明了該算法的準確性，且不易受其他雜訊干擾。

第十三章、教育訓練

13.1 活動議程

時間：民國 113 年 11 月 26 日（星期一）

地點：臺大醫院國際會議中心 4 樓(403) 台北市中正區徐州路 2 號)

時間	活動內容	講者
09:00 -10:00	人員報到	
10:00 - 10:10	開場與計畫背景說明	蔡立宏 主任 港灣技術研究中心 韓仁毓 教授 國立臺灣大學
10:10 - 10:50	計畫成果分享與討論	韓仁毓 教授國立臺灣大學
11:00-11:25	生成式 AI 於土木工程之應用	吳日騰 教授 國立臺灣大學
11:40-12:05	自動化營建工程生產	林之謙 教授 國立臺灣大學
12:05 - 12:30	後會討會&賦歸(便當)	

13.2 活動影像








圖 13.1 活動剪影

13.3 活動回饋


活動主講者的整體表現
21 則回應




課程的整體滿意程度
21 則回應




活動時間的安排
21 則回應




活動場地（地點）的安排
21 則回應



餐點安排
21 則回應




工作人員的服務品質
21 則回應




對您未來工作的幫助

21 則回應



其他建議

7 則回應



各項回饋平均皆達 4.9 分，充分展現與會者對活動規劃高度肯定，以及對無人機於港區深化應用的濃厚興趣。展望未來，我們將持續秉持研究精神，嘗試更多無人機影像的辨識應用，並在議程中加入更多目前工程上的新進展，推動相關領域的創新與實踐，期望能在 114 年的活動中帶來更多突破與亮點。

第十四章、結論與建議

為建立完善的港區 UAV 影像管理與分析平台，以降低港區未來在巡檢所需的人力成本，並提高港區構造物管理的效率及處理損壞的即時性。本計畫在第二年期，以第一年期所提出從港區高精度空間資料庫為基礎，藉由定期的影像蒐集，逐步匯入平台中累積樣本數，並結合物件辨識技術，發展出越發全面且自動化的影像管理平台。

14.1 研究成果

(1) 港區高細緻空間基礎資料建構

利用 FNN 神經網路技術建置港區風速環境資訊系統，在自動化分區的問題上，也不需人工介入劃分，這項技術的應用使得風速資料的預估更為精確，為相關領域的決策提供了可靠的依據。此外，本案進行了地面控制點測量和全港區影像資料蒐集，透過精確的地面控制點配合攝影測量原理進行影像建模，並在某些因航高受限導致建模不理想區域，採用傾斜攝影測量進行拍攝補足物件的側面資訊。

(2) 無人載具以及感測器硬體系統分析

分別整理了空中無人載具、地面無人載具及水下無人載具，並羅列各自可搭載之感測器，以及不同重量大小下可航行、移動或航行的最大距離及時間。

(3) 感測資料自動化辨識技術發展於臺中港

在岸邊設施方便，將過去在臺中港的自動化辨識流程優化，使用最近發布的 YOLOv8 模型取代過去偵測使用的 Mask R-CNN 實例分割模型與前一步驟所需的 FPN 語意分割模型，將兩步驟的模型簡化為一步驟，同時也能維持優秀的辨識效果；路面裂縫則分析了將模型更改為新架構及調整一些訓練參數後是否能對結果有提升，而實驗結果是肯定的，新模型在臺中港圖資的表現提升 3.8%，代表模型

增加了對於裂縫的辨識能力，且模型在訓練時新增了臺北港的資料，因此強化了模型的適應力。

(4) 感測資料自動化辨識技術發展於臺北港

在無人機影像偵測技術中，保持影像一致性對於模型的準確性至關重要，規格化影像輸入能使深度學習模型達到九成以上的偵測準確度。針對變電箱偵測，使用 YOLOv8 模型，結合多年度影像資料，達到 97.6% 的平均精度均值，顯示其在實際應用中的高效性。路面坑洞檢測透過遷移學習改善小樣本訓練問題，混合資料集的 IoU 達 82.1%，但仍存在誤識情況。法線檢測因訓練資料不足導致模型不完整，未來將擴大訓練資料以提高準確度。針對伸縮縫檢驗，計劃研究相似性評估方法，以挑選出異常變化，提升後續監測效果。

(5) 多來源感測資料整合

113 年度盤點臺北港現有感測器及其應用，並嘗試整合 CCTV 與 AI 智慧化技術，補足無人機在拍攝的視角缺漏，開發更多智慧應用，打造更安全、更智慧的港口。

(6) 基於高細緻港區空間資料之環境分析

先提出計算光電潛力之方法，作態潛能發電潛力可行性評估，利用港區所提供之 LOD2 模型資料套入計算，可發現整體發電量多集中於夏季，且因提供之建物棟數較少，並未獲得預期之量能，推估為 LOD2 模型尚未完善，且港區尚在開發中，因此，僅能以部分區域計算。

(7) 地面無人載具控制邏輯方法

本期研究通過改進 UGV 自主導航技術，顯著提升了其性能。研究成功更改了地圖建立方法，減少了計算資源並縮短了反應時間，同時保持了優秀的避障能力。通過微調路徑規劃算法，UGV 增強了無碰撞路徑生成的能力，兼顧全球和區域成本地圖。新高精度 GPS 接收器的整合進一步提升了 UGV 的定位精度，特別是在開闊的室外環境中，能精確執行航點導航任務。實地測試結果表明，改進後的

系統在多種環境下均能保持高精度定位和可靠導航。綜上所述，本計畫通過改進地圖建立方法和避障技術，顯著提升了 UGV 的自主導航能力，新 GPS 接收器的引入則確保了其在各種環境中的精準定位，為未來複雜任務環境中的 UGV 應用奠定了堅實基礎。

(8) 無人載具之通訊技術研析

本節詳細說明了無人機即時影像串流系統的架構和實施過程。該系統包括無人機配備攝影機、地面接收設備、FFmpeg 處理軟件、網際網路連接設施及伺服器處理和安全傳輸。本計畫成功實現了 5.8G 無線頻率傳輸無人機即時影像，並利用 FFmpeg 進行必要處理。系統支援多種網絡連接方式，如 4G 和 Wi-Fi，以適應不同運行環境。伺服器採用 SSL 加密確保數據傳輸安全，使終端用戶可通過加密 URL 在多種裝置上安全觀看影像串流。系統提升了傳輸效率和靈活性，顯著增強資料安全性。港區實地測試結果表明，新通訊方式有效解決距離限制問題，提升了 UGV 應用靈活性、訊號強度和便利性，較過去方法有顯著改進。

(9) 無人載具之影像即時串流建構

本計畫探討了使用 FFmpeg 進行即時影像串流的整體架構和具體執行方式，涵蓋多種串流方案，包括不同的編碼器和解析度設置，以適應多種需求。經詳細測試和優化，計畫成功設計並實施了 GPU 和 CPU 解碼的多條指令路徑，以及直接從無人機鏡頭回傳影像的功能，確保高品質影像從現場傳輸到遠程伺服器。透過 SSL 安全憑證保障傳輸資料安全，並針對常見錯誤進行調試，提升影像串流的穩定性和連續性。經港區實地測試，該系統能穩定回傳感測器數據及圖片至使用者操作的電腦，增強系統可靠性和用戶體驗。

(10) 系統整合平台

以臺中港平台功能為基礎，將維度由二維轉至三維，做為資料展示介面，並基於團隊過去執行飛行任務的成果影像，進行各項分

析與辨識，將相關成果整合於圖台之上，提供使用者一快速掌握港區情況之實用工具，提供更全面的業務支援。

14.2 後續建議

為進一步提升港區 UAV 影像管理與分析平台的效能及應用價值，建議從以下幾個方向進行：

首先，在資料與技術優化方面，應持續增加影像蒐集的頻率與範圍，特別是針對港區內不易拍攝的區域進行補充，也可同時蒐集不同天氣、光線與季節下的影像，提升模型適應性與普遍性。從長期來看，更建議定期更新模型以提升整體效率，並專門蒐集及標註一些稀有或異常的劣化樣態。此外，可探索影像資料與熱影像或 LIDAR 等感測數據的融合，以提高損壞辨識能力與準確度。

在平台功能擴展方面，建議應繼續完善 LOD2 模型，將更多建物與構造物納入三維視覺化平台，並結合即時數據更新（如天氣或潮汐），打造動態數位孿生系統，用於即時監測與決策輔助。後續也可以規劃自動化產製損壞報告，根據影像分析結果自動輸出圖文並茂的報告，進一步提升管理效率。

在應用與效益推廣方面，可將平台功能進行推廣，使應用範圍得以擴展至其他港區或交通基礎設施（如高速公路與橋梁），以驗證其適應性與可行性。同時，開發針對特殊應用的功能模組，如結構變形檢測與即時應急方案規劃。此外，也建議推動數據共享合作，構建全國性的高精度港區數據生態系統，並開放部分研究成果為 API，促進外部開發者利用。

而在持續驗證與改進方面，應定期進行現場測試，檢驗平台在實際應用中的穩定性與可靠性，同時蒐集使用者回饋以進行迭代優化。建議對平台應用的效益進行量化評估，包括對人力成本、損壞處理效率及環境影響的具體改善，為未來決策提供科學依據。

透過上述建議，港區 UAV 影像管理與分析平台將能進一步提升港區構造物的管理效率與損壞處理即時性，並在智慧港口建設中發揮核心作用，助力提升國際競爭力。

14.3 成果效益與後續應用情形

透過本計畫所建構之平台以及平台內所設計之功能，可使相關操作人員進行自動化的巡檢管理。透過不同飛行模式所執行得到的影像，可進行影像匹配，不僅可進行長期性的港區環境監測，更能透過匹配後的成果得知改變之處，並進行政策調整或立即性維護。隨著後續物件辨識功能於平台的加入，使用者可更直覺地將各項巡檢標的進行分類，提升對各項構造物的檢查效率，達到精簡人力同時不影響巡檢品質的效益。

參考文獻

1. Ballard, D. H. (1981). Generalizing the Hough transform to detect arbitrary shapes. *Pattern recognition*, 13(2), 111-122.
2. Biljecki, F., Ledoux, H., & Stoter, J. (2016). An improved LOD specification for 3D building models. *Computers, Environment and Urban Systems*, 59, 25-37.
3. Berman, M., Triki, A. R., & Blaschko, M. B. (2018). The lovász-softmax loss: A tractable surrogate for the optimization of the intersection-over-union measure in neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4413-4421).
4. Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*, (6), 679-698.
5. Colomina, I., and Molina, P., 2014. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of photogrammetry and remote sensing*, 92, 79-97.
6. Drury, C. G., Fox, J. G., 1975. The imperfect inspector. In C. G. Drury & J. G. Fox (Eds.) *Human Reliability in Quality Control*, pp. 11-16.
7. Hearn, D., and Baker, M. P., 1986. *Computer Graphics*, Prentice Hall International, pp. 205-302.
8. Hough, P. V. (1959). Machine analysis of bubble chamber pictures. In *International Conference on High Energy Accelerators and Instrumentation, CERN, 1959* (pp. 554-556).
9. J. Canny, "A Computational Approach to Edge Detection," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-8, no. 6, pp. 679-698, Nov. 1986, doi: 10.1109/TPAMI.1986.4767851.
10. Jau, U. L., Teh, C. S., and Ng, G. W., 2008. A comparison of RGB and HSI color segmentation in real-time video images: A preliminary study on road sign detection. In *2008 International Symposium on Information Technology*, 4, 1-6.

11. Li, H., Sun, F., Liu, L., and Wang, L., 2015. A novel traffic sign detection method via color segmentation and robust shape matching. *Neurocomputing*, 169, 77-88.
12. Liu, Z., An, J., and Jing, Y., 2011. A simple and robust feature point matching algorithm based on restricted spatial order constraints for aerial image registration. *IEEE Transactions on Geoscience and Remote Sensing*, 50(2), 514-527.
13. Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2117-2125).
14. Malik, Z., and Siddiqi, I., 2014. Detection and recognition of traffic signs from road scene images. In *2014 12th International Conference on Frontiers of Information Technology*, 330-335.
15. Maxim Berman, Amal Rannen Triki, & Matthew B. Blaschko. (2018). The Lovasz-Softmax loss: A tractable surrogate for the optimization of the intersection-over-union measure in neural networks.
16. Plastiras, G., Kyrkou, C., & Theocharides, T. (2018, September). Efficient convnet-based object detection for unmanned aerial vehicles by selective tile processing. In *Proceedings of the 12th international conference on distributed smart cameras* (pp. 1-6).
17. Redmon, J. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*.
18. Ronneberger O, Fischer P, Brox T (2015). "U-Net: Convolutional Networks for Biomedical Image Segmentation". arXiv:1505.04597
19. See, J.E., 2012. Visual Inspection: A Review of the Literature. Sandia National Laboratories.
20. See, J. E., Drury, C. G., Speed, A., Williams, A., Khalandi, N., 2017, September. The Role of Visual Inspection in the 21st Century. In *Proceedings of the Human Factors and Ergonomics Society Annual Meeting* (Vol. 61, No. 1, pp. 262-266). Sage CA: Los Angeles, CA: SAGE Publications.

21. Shan, Q., Wu, C., Curless, B., Furukawa, Y., Hernandez, C., and Seitz, S. M., 2014. Accurate geo-registration by ground-to-aerial image matching. In 2014 2nd International Conference on 3D Vision, 1, 525-532.
22. Shelhamer E, Long J, Darrell T (April 2017). "Fully Convolutional Networks for Semantic Segmentation". IEEE Transactions on Pattern Analysis and Machine Intelligence. 39 (4): 640–651. arXiv:1411.4038. doi:10.1109/TPAMI.2016.2572683. PMID 27244717. S2CID 1629541.
23. Soheilian, B., Paparoditis, N., and Vallet, B., 2013. Detection and 3D reconstruction of traffic signs from multiple view color images. ISPRS journal of photogrammetry and remote sensing, 77, 1-20.
24. Sun, P., Wu, Z., Zhang, Y., & Wu, J. (2021). A Novel Assessment Method of Cracks Width Quantitative Model Based on Computer Vision. In 2021 17th International Conference on Computational Intelligence and Security (CIS). 2021 17th International Conference on Computational Intelligence and Security (CIS). IEEE. <https://doi.org/10.1109/cis54983.2021.00072>
25. Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning (pp. 6105-6114). PMLR.
26. Tsai, C. H., and Lin, Y. C., 2017. An accelerated image matching technique for UAV orthoimage registration. ISPRS Journal of Photogrammetry and Remote Sensing, 128, 130-145.
27. Klema, V., & Laub, A. (1980). The singular value decomposition: Its computation and some applications. IEEE Transactions on automatic control, 25(2), 164-176.
28. Wang, C. Y., Yeh, I. H., & Liao, H. Y. M. (2024). Yolov9: Learning what you want to learn using programmable gradient information. arXiv preprint arXiv:2402.13616.
29. Zhang, T. Y., & Suen, C. Y. (1984). A fast parallel algorithm for thinning digital patterns. Communications of the ACM, 27(3), 236-239.

30. Zhao, K., Liu, L., Meng, Y., & Gu, Q. (2019). Feature deep continuous aggregation for 3D vehicle detection. *Applied Sciences*, 9(24), 5397.
31. Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J. (2018). Unet++: A nested u-net architecture for medical image segmentation. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4* (pp. 3-11). Springer International Publishing.
32. Zhuo, X., Koch, T., Kurz, F., Fraundorfer, F., and Reinartz, P., 2017. Automatic UAV image geo-registration by matching UAV images to georeferenced image data. *Remote Sensing*, 9(4), 376.

附錄一、工作會議紀要

113 年 3 月工作會議紀要

採購編號：MOTC-IOT-113-H2CB001a

會議名稱：「港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作研究案 113 年 3 月份工作會議

時間：113 年 3 月 14 日(星期四)上午 10 時至 12 時 30 分

地點：國立臺灣大學土木工程系土木館307會議室

主持人：李俊穎副研究員

出席者：如後附簽到表

主辦單位：本所運輸技術研究中心第二科

執行廠商：國立臺灣大學

紀錄：洪維屏

壹、討論議題

一、工作進度說明：

- (一) 計畫整體執行內容討論。
- (二) 完成無人載具即時通訊技術之流程規劃。
- (三) 完成本年度港區辨識項目之初步規劃。

二、針對目前研究方向與執行情形進行討論：

- (一) 無人載具即時通訊技術流程說明。
- (二) 地面無人移動載具性能說明。
- (三) 港區物件自動化辨識技術之標的物討論。

貳、主要結論

- 一、有關無人機於港區作業申請相關事宜：臺北港區 UAV 定義黃區區域請國立臺灣大學依程序向民航局提出申請，其餘可供飛行之區域由本所向基隆港務分公司提出申請，另作業人員港區通行證申請部分，請基隆港務分公司協助國立臺灣大學依規定辦理。
- 二、本年度港區辨識項目之測試區域，請國立臺灣大學依會議當天討論情形，進行評估規劃。
- 三、請國立臺灣大學依規劃之期程，進行後續工作。

會議簽到表

壹、會議名稱：「MOTC-IOT-113-H2CB001a 港區影像智慧辨識技術之研究
(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作
研究案 113 年 3 月份工作會議

貳、時間：113 年 3 月 14 日(星期四)上午 10 時

參、地點：國立臺灣大學土木工程系土木館 307 會議室

肆、主持人：李俊穎副研究員 李俊穎

伍、出(列)席人員：

出席單位	職稱	姓名
基隆港務分公司	資深技術員	林孝良
	技師	張郁菖
合作研究單位： 國立臺灣大學	計畫主持人	韓仁範
	協同主持人	吳日勝
	專任研究助理	林名海
		甘明萱
本所運輸技術研究中心	副研究員	洪維屏

113 年 4 月工作會議紀要

採購編號：MOTC-IOT-113-H2CB001a

會議名稱：「港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作研究案 113 年 4 月份工作會議

時間：113 年 4 月 22 日(星期一)上午 9 時 30 分至 11 時 30 分

地點：本所運輸技術研究中心3樓會議室

主持人：李俊穎副研究員

出席者：如後附簽到表

主辦單位：本所運輸技術研究中心第二科

執行廠商：國立臺灣大學

紀錄：洪維屏

壹、討論議題

一、工作進度說明：

- (一) 計畫整體執行內容討論。
- (二) 確認岸邊設施之地理座標計算方法。
- (三) 完成地面無人移動載具初步功能測試。

二、針對目前研究方向與執行情形進行討論：

- (一) 感測資料自動化辨識技術討論。
- (二) 地面無人移動載具測試結果說明。
- (三) 無人移動載具即時串流技術說明。

貳、主要結論

- 一、本年度新增辨識物件之辨識內容及方法，請國立臺灣大學依據臺北港-港灣構造物維護管理手冊，提及之設施劣化度判定標準研擬。
- 二、有關專利申請事宜，本所已請專利公司進行初步評估，後續流程作業，請國立臺灣大學配合辦理。
- 三、請國立臺灣大學依規劃之期程，進行後續工作。

會議簽到表

壹、會議名稱：「MOTC-IOT-113-H2CB001a 港區影像智慧辨識技術之研究
(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作
研究案 113 年 4 月份工作會議

貳、時間：113 年 4 月 22 日(星期一)上午 9 時 30 分

參、地點：本所運輸技術研究中心 3 樓會議室

肆、主持人：李俊穎副研究員 李俊穎

伍、出(列)席人員：

出席單位	職稱	姓名
基隆港務分公司		請假
合作研究單位： 國立臺灣大學	教授 (計畫主持人)	韓仁統
	研究助理	甘翎萱
	研究助理	林育鈺
本所運輸技術研究中心	副研究員	吳維偉

113 年 5 月工作會議紀要

採購編號：MOTC-IOT-113-H2CB001a

會議名稱：「港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作研究案 113 年 5 月份工作會議

時間：113 年 5 月 23 日(星期四)上午 10 時至 11 時 50 分

地點：國立臺灣大學土木工程系土木館318會議室

主持人：李俊穎科長

出席者：如後附簽到表

主辦單位：本所運輸技術研究中心第二科

執行廠商：國立臺灣大學

紀錄：洪維屏

壹、討論議題

一、工作進度說明：

- (一) 計畫整體執行內容討論。
- (二) 精進岸邊設施之地理座標計算方法。
- (三) 進行地面無人移動載具港區功能測試。

二、針對目前研究方向與執行情形進行討論：

- (一) 感測資料自動化辨識技術討論。
- (二) 地面無人移動載具測試結果說明。
- (三) 無人移動載具即時串流技術說明。

貳、主要結論

- 一、本年度新增之辨識物件-坑洞，請國立臺灣大學增加影像資料蒐集數量，且調整及精進相關辨識模組，以提高辨識率。
- 二、為進行臺北港區多來源感測資料整合，請基隆港務分公司協助提供臺北港區目前設置之 CCTV 座標位置及港區道路、碼頭附近部分歷史影像資料，以利發展與無人移動載具感測資料之整合技術。
- 三、請國立臺灣大學依規劃之期程，進行後續工作。

會議簽到表

壹、會議名稱：「MOTC-IOT-113-H2CB001a 港區影像智慧辨識技術之研究
(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作
研究案 113 年 5 月份工作會議

貳、時間：113 年 5 月 23 日(星期四)上午 10 時

參、地點：國立臺灣大學土木工程系土木館 318 會議室

肆、主持人：李俊穎科長 李俊穎

伍、出席(列)席人員：

出席單位	職稱	姓名
基隆港務分公司	事務員	羅雅文
合作研究單位： 國立臺灣大學	計畫主持人	韓仁龍
	協同主持人	吳日勝
	研究助理	甘翊萱 江冠均
本所運輸技術研究中心	副研究員	吳維倫

113 年 6 月工作會議紀要

採購編號：MOTC-IOT-113-H2CB001a

會議名稱：「港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作研究案 113 年 6 月份工作會議

時間：113 年 6 月 13 日(星期四)上午 9 時 30 分至 11 時 30 分

地點：本所運輸技術研究中心3樓會議室

主持人：李俊穎科長

出席者：如後附簽到表

主辦單位：本所運輸技術研究中心第二科

執行廠商：國立臺灣大學

紀錄：洪維屏

壹、討論議題

一、工作進度說明：

- (一) 計畫整體執行內容討論。
- (二) 精進岸邊設施影像辨識模組。
- (三) 進行地面無人移動載具港區功能測試。

二、針對目前研究方向與執行情形進行討論：

- (一) 感測資料自動化辨識技術討論。
- (二) 地面無人移動載具測試結果說明。

貳、主要結論

- 一、本年度新增辨識物件之辨識內容及方法，請國立臺灣大學再依據臺北港-港灣構造物維護管理手冊，提及之設施劣化度判定標準評估研擬。
- 二、為進行臺北港區多來源感測資料整合，請國立臺灣大學依相關規定向基隆港務分公司臺北港營運處，申請提供臺北港區部分區域設置之 CCTV 座標位置及歷史影像資料，以利發展與無人移動載具感測資料之整合技術。
- 三、請國立臺灣大學依規劃之期程，進行後續工作。

會議簽到表

壹、會議名稱：「MOTC-IOT-113-H2CB001a 港區影像智慧辨識技術之研究
(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作
研究案 113 年 6 月份工作會議

貳、時間：113 年 6 月 13 日(星期四)上午 9 時 30 分

參、地點：本所運輸技術研究中心 3 樓會議室

肆、主持人：李俊穎科長 李俊穎

伍、出(列)席人員：

出席單位	職稱	姓名
基隆港務分公司		請假
合作研究單位： 國立臺灣大學	計畫主持人 專任研究助理	韓仁龍 甘翎菱 林育龍
本所運輸技術研究中心	副研究員	洪維屏

113 年 7 月工作會議紀要

採購編號：MOTC-IOT-113-H2CB001a

會議名稱：「港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作研究案 113 年 7 月份工作會議

時間：113 年 7 月 29 日(星期一)下午 1 時 30 分至 3 時

地點：本所運輸技術研究中心5樓第二會議室(視訊會議)

主持人：李俊穎科長

出席者：如後附簽到表

主辦單位：本所運輸技術研究中心第二科

執行廠商：國立臺灣大學

紀錄：洪維屏

壹、討論議題

一、工作進度說明：

- (一) 計畫整體執行內容討論。
- (二) 優化感測資料自動化辨識技術。
- (三) 地面無人移動載具控制方法分析。

二、針對目前研究方向與執行情形進行討論：

- (一) 感測資料自動化辨識技術討論。
- (二) 地面無人移動載具控制方法說明。

貳、主要結論

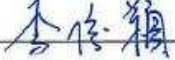
- 一、請國立臺灣大學持續調整及精進相關辨識模組，並增加影像資料蒐集數量，以提高辨識率。
- 二、請國立臺灣大學依相關規定向基隆港務分公司臺北港營運處，申請提供臺北港區部分區域設置之 CCTV 歷史影像資料，以進行臺北港區多來源感測資料之整合。
- 三、請國立臺灣大學依規劃之期程，進行後續工作。

會議簽到表

壹、會議名稱：「MOTC-IOT-113-H2CB001a 港區影像智慧辨識技術之研究
(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作
研究案 113 年 7 月份工作會議

貳、時間：113 年 7 月 29 日(星期一)下午 1 時 30 分

參、地點：本所運輸技術研究中心 5 樓第二會議室(視訊會議)

肆、主持人：李俊穎科長 

伍、出(列)席人員：

出席單位	職稱	姓名
基隆港務分公司		請假
合作研究單位： 國立臺灣大學	計畫主持人	韓仁毓(視訊)
	專任研究助理	甘翊萱(視訊)
本所運輸技術研究中心	副研究員	洪維屏

113 年 9 月工作會議紀要

採購編號：MOTC-IOT-113-H2CB001a

會議名稱：「港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作研究案 113 年 9 月份工作會議

時間：113 年 9 月 23 日(星期一)下午 2 時至 3 時 30 分

地點：本所運輸技術研究中心3樓會議室

主持人：李俊穎科長

出席者：如後附簽到表

主辦單位：本所運輸技術研究中心第二科

執行廠商：國立臺灣大學

紀錄：洪維屏

壹、討論議題

一、工作進度說明：

- (一) 計畫整體執行內容討論。
- (二) 感測資料自動化辨識技術精進。
- (三) 地面無人移動載具定位測試分析。

二、針對目前研究方向與執行情形進行討論：

- (一) 感測資料自動化辨識技術討論。
- (二) 地面無人移動載具定位測試說明。
- (三) 系統平台架構規劃討論。

貳、主要結論

- 一、請國立臺灣大學持續精進路面裂縫辨識模組，並增加影像資料蒐集數量，以降低誤判率。
- 二、請國立臺灣大學預先規劃，如何將臺北港區提供之 CCTV 歷史影像資料，與本計畫無人移動載具感測資料進行整合，且納入系統平台辨識模組內，以利使用者日後操作。
- 三、本年度教育訓練訂於 113 年 11 月 26 日辦理，請妥適規劃課程，以利教育訓練如期、如質舉行。
- 四、請國立臺灣大學依規劃之期程，進行後續工作。

會議簽到表

壹、會議名稱：「MOTC-IOT-113-H2CB001a 港區影像智慧辨識技術之研究
(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作
研究案 113 年 9 月份工作會議

貳、時間：113 年 9 月 23 日(星期一)下午 2 時

參、地點：本所運輸技術研究中心 3 樓會議室

肆、主持人：李俊穎科長 李俊穎

伍、出(列)席人員：

出席單位	職稱	姓名
基隆港務分公司		請假
合作研究單位： 國立臺灣大學	計畫主持人 專任研究助理	韓仁範 江冠均 甘明堃
本所運輸技術研究中心	副所長	洪維屏

113 年 10 月工作會議紀要

採購編號：MOTC-IOT-113-H2CB001a

會議名稱：「港區影像智慧辨識技術之研究(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作研究案 113 年 10 月份工作會議

時間：113 年 10 月 9 日(星期三)上午 10 時至 11 時 30 分

地點：國立臺灣大學土木工程系土木館217會議室

主持人：李俊穎科長

出席者：如後附簽到表

主辦單位：本所運輸技術研究中心第二科

執行廠商：國立臺灣大學

紀錄：洪維屏

壹、討論議題

一、工作進度說明：

- (一) 計畫整體執行內容討論。
- (二) 感測資料自動化辨識技術精進。
- (三) 空間資訊平台功能建構。

二、針對目前研究方向與執行情形進行討論：

- (一) 感測資料自動化辨識技術討論。
- (二) 多來源感測資料分析說明。
- (三) 系統平台架構規劃討論。

貳、主要結論

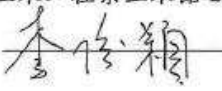
- 一、請國立臺灣大學針對 UAV 及 CCTV 影像辨識模組進行分析比較，並就成果精度進行比較。
- 二、請國立臺灣大學就後續將套疊至臺北港正射影像底圖之物件辨識模組進行盤點，以利平台功能建置。
- 三、請國立臺灣大學依規劃之期程，進行後續工作。

會議簽到表

壹、會議名稱：「MOTC-IOT-113-H2CB001a 港區影像智慧辨識技術之研究
(2/3)-空間資料環境分析及優化影像檢監測應用技術」合作
研究案 113 年 10 月份工作會議

貳、時間：113 年 10 月 9 日(星期三)上午 10 時

參、地點：國立臺灣大學土木工程系土木館 217 會議室

肆、主持人：李俊穎科長 

伍、出席(列)席人員：

出席單位	職稱	姓名
基隆港務分公司		請假
合作研究單位： 國立臺灣大學	計畫主持人 專任研究助理	韓仁毓 江冠均 甘羽萱
本所運輸技術研究中心	副研究員	洪維屏

附錄二、期中報告審查意見處理情形表

交通部運輸研究所合作研究計畫(具委託性質)

期中報告審查意見處理情形表

計畫名稱：港區影像智慧辨識技術之研究 (2/3)-空間資料環境分析及優化影像檢監測應用技術

合作研究單位：國立臺灣大學

參與審查人員及其所提之意見	合作研究單位處理情形	本所計畫承辦單位審查意見
一、江文山委員		
研究成果豐碩，內容詳實，值得肯定。	感謝委員肯定。	符合。
辨識模型訓練過程中提到因為相機更換，導致結果較差，是否會造成後續此模型應用的限制?有何因應想法?	透過加入變更後的尺寸的影像進行訓練來使模型適應不同尺寸的影像，影像尺寸可以視為一種物件的外觀，不同外觀在未見過的時候表現肯定是會較差的，但一旦有給予模型學習的機會，表現就能恢復。	符合。
研究成果與港區現有的各種監測資訊值得發展，目前的成果都是透過取得資訊之後，經由模型分析，判斷環境或是各項設施的差異，未來若可取得即時環境資訊是否可能對即時管理應用有些助益值得思考。	感謝委員建議，未來將納入考量。	依處理情形辦理。
針對所發展的系統，建議後續審查考慮現場展示的可能性。	感謝委員建議，未來將納入考量。	依處理情形辦理。
目前發展的技術對陸域相關設施檢測已有相當好的效果，請教應用這些技術在水域環境變異檢視的可能性?	感謝委員建議，目前的技術已經在陸域相關設施的檢測上取得了很好的成果。至於應用在水域環境變異檢視方面，團隊已有一些相關的水下影像辨識研究。然而，必須謹慎指出的	依處理情形辦理。

參與審查人員及其所提之意見	合作研究單位處理情形	本所計畫承辦單位審查意見
	是，由於水下環境的複雜性，尤其是光線折射和水中懸浮物的影響，現有的相機鏡頭在效果上還存在一定的局限性，因此成果並不如在陸域環境中那麼理想。未來若有更適合水下的感測技術出現，相信這方面的研究會有更大的進展。	
二、吳瑞堯委員		
港區標的物偵測及辨識應明列各種標的物之數量、偵測率及辨識正確率。第一期數據、目前精進情形及期末目標都應陳列。	感謝委員建議，未來會將這類資訊陳列於報告與簡報之中。	所提意見及執行內容調整，列入期末報告辦理。
資料集應呈現各種標的物之數量，而非影像數量，各種標的物訓練資料是否足夠應評估。驗證資料與測試資料有何不同？	感謝委員建議，未來會將這類資訊陳列於報告與簡報之中。 驗證資料與測試資料的不同在於驗證資料是訓練過程中對答案所使用的資料。測試資料則是不參與訓練過程的資料，是最後的檢核標準。	所提意見及執行內容調整，列入期末報告辦理。
P2-6 影像尺寸影響辨識結果不規避。	感謝委員建議，報告中提及尺寸導致影像辨識結果不佳是將研究過程中發現的問題歸納並提出，供單位未來進行作業時若遇到類似問題，能瞭解其源自何處，並非規避問題。且在後續研究結果裡也已克服此類問題。	符合。
地理位置可運用固定設施調校。	感謝委員建議，在研究中影像尺度的判定即是以相關概念進行。	符合。
變電箱是固定設施，偵測意義不大，溫度偵測可能重要，但，是甚麼意思？為	感謝委員建議，變電箱確實是固定設施，因此偵測目的僅在避免誤判，而溫度偵測的重要	符合。

參與審查人員及其所提之意見	合作研究單位處理情形	本所計畫承辦單位審查意見
什麼有溫度偵測的正確率。	性在於它能幫助我們及早發現設備過熱等潛在故障，從而避免更大的安全隱患。正確率的概念是指能夠多準確地識別出這些異常溫度，這對於預防故障和延長設備壽命非常關鍵。	
P2-20 胸牆預測是甚麼意思?是指錯位偵測嗎?目前成果為何?	胸牆預測是指利用 YOLOv8 模型預測胸牆頂部的邊緣線，錯位偵測是利用預測出來的邊緣線再經過霍夫直線等相關電腦視覺操作，利用圖像進行自動化錯位偵測，目前成果已成功訓練偵測模型，並對胸牆法線進行錯位檢測，待未來放置於平台上。	依處理情形辦理。
新增標的物為何須採不同技術，鋪面裂縫跟地面裂縫有何不同？ P2-32 loU 代表甚麼意思？	<ol style="list-style-type: none"> 1. 本研究主要採用兩種分割方式，語意分割 (semantic segmentation) 及實例分割 (instance segmentation)，語意分割是像素級的預測出目標的遮罩(mask)，實例分割則是除了遮罩外還可以檢測出目標的個數。在鋪面裂縫的檢測中因為裂縫單位為長度而非個數，因此使用語意分割足矣。 2. 鋪面裂縫與地面裂縫在外觀上有著很大的差異，鋪面裂縫為水泥路面的伸縮縫，走向成格狀，筆直且規律，檢測目標為計算裂縫走向，監測有無變形。地面裂縫則為柏油路面的破壞裂縫，成因可能為地震或車輛的輾壓，外觀錯綜複雜且不規則，檢測目標為評估道路狀況，是否 	符合。

參與審查人員及其所提之意見	合作研究單位處理情形	本所計畫承辦單位審查意見
	<p>需要修補。</p> <p>IoU 是一種常用於評估圖像分割性能的指標。其嚴謹的以像素級的方式一個一個像素的衡量模型預測的分割區域與實際分割區域之間的重疊程度，值會在 0 到 1 之間，越大則代表重疊度越高，模型預測效能越好，常應用於物體檢測和語義分割等應用中。</p>	
多來源資料整合應說明如何整合應用，並規劃系統整合架構。	感謝委員建議，未來會將這類資訊陳列於報告與簡報之中。	所提意見及執行內容調整，列入期末報告辦理。
P4-6 三維資料在無太陽光照資料下為何能估算發電量？發電量估算為何與耗電量/平方公尺有關？	<p>感謝委員建議，關於三維資料在無太陽光照下估算發電量的部分，可能有些誤會。實際上，本研究是使用典型氣象年（TMY）資料來進行發電量估算，而這些資料是以每小時為單位記錄的，因此並不存在無太陽光照的數據。為了更準確地計算發電量，我們搭配使用了 hillshade 模型來估算陰影遮蔽的影響，然後根據太陽能的轉換效率計算最終的發電量。</p> <p>至於發電量與每平方公尺耗電量的關聯，這部分是用來評估發電系統的效率，確保所產生的能量能夠滿足用電需求。</p>	符合。
地面無人載具之避障能避開動態障礙物嗎？	經過台北港實地測試，結果顯示是可以避開動態障礙物的，載具會隨著傳感器偵測到的障礙進行路徑的修正。	符合。
三、鄭志宏委員		

參與審查人員及其所提之意見	合作研究單位處理情形	本所計畫承辦單位審查意見
本案成果相當豐富，感謝台大團隊及運技中心努力。	感謝委員肯定。	符合。
P2-16，有關影像辨識，可否新增地上物異物之辨識。	感謝委員建議，只要影像解析度足夠，且有明確的標的物，可於未來考慮納入。	依處理情形辦理。
P2-20，有關位移偵測，可否知道位移精度為幾公分，是否可測垂直位移。	感謝委員建議，考量無人機影像之地面解析度於拍攝時為0.67cm，精度約落在1-2cm左右，若與前期影像有相異處，垂直與水平位移皆可測得。	符合。
P2-36，人工檢視部分，可否自動監測。	感謝委員建議，人工檢視的意思為檢視法線自動化檢測成果是否有異狀，否則目前電腦已經會自動判定每張影像是否有錯位發生。	符合。
P4-6，發電量推估是否過高，其太陽能又分陸上、海上及屋頂型，效率是否相同。	感謝委員建議，太陽能系統的效率會因應用場景而有所不同，如陸上、海上和屋頂型太陽能的效率並不相同。本研究主要聚焦於屋頂型太陽能發電系統的應用，因此推估的發電量是基於此場景進行的。此外，在期中報告撰寫時，由於尚未取得更精細的LOD2建物模型，僅能使用數值地表模型（DSM）進行初步計算。因此，這部分結果可能相對粗略，後續於期末報告將會呈現以LOD2計算之成果。	所提意見及執行內容調整，列入期末報告辦理。
地面無人載具可否辨識交通號誌。	目前辨識模型中只包含辨識變電箱的溫度，無法辨識交通號誌	符合。
P7-1，影像串流處理時間可達多快。	感謝委員提問。影像串流的處理速度會受到多種因素的影響	依處理情形辦理。

參與審查人員及其所提之意見	合作研究單位處理情形	本所計畫承辦單位審查意見
	響，包括影像解析度、處理的複雜度、硬體設備的效能以及演算法的優化程度。根據目前的技術水準，針對高清影像（如 1080p 或 4K）的即時處理速度，通常可以達到每秒幾十到上百幀。如果使用高效能硬體（如 GPU 加速）和進行適當的演算法優化，處理時間可以進一步縮短，滿足每秒 30 幀或更高的即時處理需求。未來會根據實際應用場景進行測試和調整，以達到最佳效能。	
四、運技中心蔡立宏主任		
胸牆法線變位偵測是否可分析出水平及高程變動。	因考量蒐集影像為無人機影像，也就是二維平面影像，故無充足的資料能夠取得高程變動，水平的話可以透過無人機地面解析度去推算位移距離約為多少。	依處理情形辦理。
除胸牆法線，是否能辨識堤面或碼頭法線之高程變化。	堤面或碼頭的相關法線特徵因與胸牆有異，故需要重新訓練 AI 模型去抓取相關法線，若建立偵測堤面或碼頭法線之模型，則能夠用相近的演算法去檢測法線錯位之可能性。如 1. 所述，二維影像無法計算出高程。	符合。
岸上設施偵測因不同目標區，須重新訓練以提升辨識率，其他胸牆、伸縮縫、坑洞，此技術移至其他示範區，須再進行優化訓練嗎？	不同地區的地理環境、拍攝條件導致最後影像上的目標或許多少有不同，移至其他示範區後進行優化能確保有較好的結果。但隨著資料量的累積，各種樣態的目標都納入資料庫後，模型未來能逐漸朝向不需進行優化。	符合。

參與審查人員及其所提之意見	合作研究單位處理情形	本所計畫承辦單位審查意見
五、運技中心李俊穎科長		
建議將本案 UAV 及 UGV 拍攝過程或路徑等適當整理呈現或收錄至附件。	感謝委員建議，未來會將這類資訊陳列於報告與簡報之中。	依處理情形辦理。
有關不同設施 UAV 飛行及拍攝高程、角度等建議再彙整說明。	感謝委員建議，未來會將這類資訊陳列於報告與簡報之中。	依處理情形辦理。
坑洞偵測後其坑洞面積大小辨識方式建議補述說明。	感謝委員的意見，首先我們會使用 python 中的一個函式 skimage.measure.label 來將辨識成果轉換為坑洞個數及相應像素個數，相連像素視為同個坑洞，之後再以解析度將像素個數換算成坑洞面積。	符合。
後續 CCTV 整合、港區 LOD2 分析等請依計畫期程儘速辦理。	感謝委員建議，依計畫期程儘速辦理。	依處理情形辦理。
建議將本案 UAV 及 UGV 拍攝過程或路徑等適當整理呈現或收錄至附件。	感謝委員建議，未來會將這類資訊陳列於報告與簡報之中。	所提意見及執行內容調整，列入期末報告辦理。

附錄三、期末報告審查意見處理情形表

交通部運輸研究所合作研究計畫(具委託性質)

期末報告審查意見處理情形表

計畫名稱：港區影像智慧辨識技術之研究 (2/3)-空間資料環境分析及優化影像檢監測應用技術

合作研究單位：國立臺灣大學

參與審查人員及其 所提之意見	合作研究單位 處理情形	本所計畫承辦單位 審查意見
一、江文山委員		
本計畫從載具硬體分析，感測器評估到各項的應用測試與整合平台的建置等技術發展詳實可行，團隊的努力值得肯定。	感謝委員肯定。	符合。
結論中對各項技術評估多附說明，對於後續建議部分，請再多加著墨，以利主辦單位參考。	感謝委員建議，已於報告對所列出評估設定進行補充說明。	所提意見及執行內容調整，列入修正定稿辦理。
技術發展過程中，各項測試與訓練的模型除原理說明，若有相關參數設定，請加註說明。	感謝委員建議，已於報告對所列出評估設定進行補充說明。	所提意見及執行內容調整，列入修正定稿辦理。
各項偵測與標的物分析結果，是否列表納入資料庫供港口營運單位後續參考？	感謝委員建議，只要上傳到系統上，都會以 POI 呈現並儲存。	符合。
港區風速評估中使用的測站風速資料是否轉換到相同高度的風速，請補充說明。	感謝委員建議，此部分為去年度成果，去年度進行分析時，皆有換算到無人機飛行高度。	符合。
計畫所發展的軟硬體，未來若臺灣港務股份有限公司要應用如何處理，請預做規劃。	感謝委員建議，因本研究工項繁多，實際規劃還是要回歸港公司需求。	符合。
二、王聖鐸委員		
本案工作項目繁多，執行團隊均如期如質完成，且成果優秀，應給予高度肯定。	感謝委員肯定。	符合。
1.2 節文獻回顧有多篇引用文獻並未列入文末參考文獻，請補充。	感謝委員建議，已於報告進行補充。	所提意見及執行內容調整，列入修正定稿辦理。
P1-9 甘特圖建議分列預定進度及實際進度檢核點，最好能補	感謝委員建議，已於報告進行補充。	所提意見及執行內容調整，列入修正定稿

參與審查人員及其 所提之意見	合作研究單位 處理情形	本所計畫承辦單位 審查意見
充第 1 期及第 3 期工作進度甘特圖，以利了解全盤計畫。		辦理。
P3-14 港區內是否 LV3、LV4、LV5 風向會不同?以致適飛天數較多的月份不同?	表 3-4 內容，因為 type1 機型較小，level5 以上無法飛會變 0。	符合。
第 4 章中有多張圖名及圖說跳到下頁。	感謝委員建議，已於報告修正。	所提意見及執行內容調整，列入修正定稿辦理。
第 5 章的辨識成果影像不易看出辨識成果(圖 5.2、5.3、5.10、5.11)。	感謝委員建議，因辨識影像為長條狀，在呈現上較為困難，後續可於平台進行查詢。	依處理情形辦理。
P6-14 變電箱側面因遮蔽而不易辨識，是否有可能從 UAV 辨識成果回饋協助 UGV 辨識?	UAV 並無拍攝變電箱，故無訓練變電箱之模型，不過 UAV 與 UGV 在拍攝上航高及解析度上都不同，無法直接套用。	符合。
對於 CCTV 影像應不只是偵測，而應著重在監控，是否可計算出變化量?	感謝委員建議，監控為研究團隊不斷強調的最終使用目的，然港公司資料取得不易，現階段僅能先嘗試使用。	依處理情形辦理。
P12-2 此處檢核均為抽樣而非母體全檢，應使用 RMSD，分母應為 n-1。	感謝委員建議，已於報告進行修正。	所提意見及執行內容調整，列入修正定稿辦理。
P13-1 研究成果(2)、(3)建議重寫，讓成果更能簡要呈現。	感謝委員建議，已於報告進行修正。	所提意見及執行內容調整，列入修正定稿辦理。
建議避免使用大陸用語，例如：軟件=>軟體、占比=>比例。	感謝委員建議，已於報告進行修正。	所提意見及執行內容調整，列入修正定稿辦理。
三、王驥魁委員		
建議未來規劃多次實證巡檢，並呈現全自動化之效益。	感謝委員建議，本研究為研究案，主要還是以具有研究效益之工項為主，全自動化以目前經費來說較無實質效益，此外，全自動目前不見	符合。

參與審查人員及其 所提之意見	合作研究單位 處理情形	本所計畫承辦單位 審查意見
	得為趨勢，將某幾項自動化較合理，由機器輔助人力，資料蒐集/資料分析的自動化分析。	
UGV 車速較慢，未來是否可安全使用於港區自動化巡檢？	感謝委員建議，本研究對於 UGV 的定位在夜間巡檢，在夜間較無人車的環境上進行。至於用 UGV 巡查之標的物，則須與港公司共同討論。	依處理情形辦理。
發電量評估是否能考量牆面、立面的貢獻？	感謝委員建議，牆面發電成本高，且考慮建築物用途，建物建造時的通風條件及採光皆可能會影響太陽能架設的地區。	符合。
四、鄭志宏委員		
多旋翼及定翼機特性不同，建議分析優缺點及各自實用作業 (P 3-16)。	感謝委員建議，此部分為去年度成果，根據期中審查對於期末報告之建議，僅摘錄去年度研究重點，因此並非所有成果都呈現，重點還是放在今年度成果上。	符合。
P2-19 水下 ROV 安全係數採 0.35 是否太保守？	感謝委員建議，係數從靜態水與動態水的差距，未來可納入公司規範作為參考。	依處理情形辦理。
P3-2 臺北港圖示是舊的。	感謝委員建議，此部分為去年度拍攝成果，並非今年度工項，因此不會進行底圖更新。	符合。
圖 3.4、3.5 建議附上單位。	感謝委員建議，已於報告補充。	所提意見及執行內容調整，列入修正定稿辦理。
巡查中的無人機可否避開 300 餘米高的風機等構造物。	在航線規劃功能中能夠設定各項參數，其中也包含航高設定。	符合。
道路的隆起或沉陷可否測出？以及看不見的隱患，如潛變、側移可否發現。	使用 UAV 光學鏡頭比較高程方向較不易，通常會使用光達，但由於光達價格較高昂，後續若港務單位有意進行，建議可用測量工具做較	依處理情形辦理。

參與審查人員及其 所提之意見	合作研究單位 處理情形	本所計畫承辦單位 審查意見
	精準。	
圖 6.11 位置誤差可否再減少？	誤差主要來自 UAV 在拍攝時的定位精度，屬於無人機本身定位誤差，因此目前已為最佳精度。	符合。
除 RC 道路外，AC 道路可否檢測？或連鎖磚、壓花地坪。	若有拍攝道路之無人機影像，則可納入檢測系統。	依處理情形辦理。
可否辨識比對出非原設定的缺失，如避雷針掉落，或跟前次影像比對。	只要拍攝角度及位置皆相同，即可以比對出差異，但因為對額外標的進行模型訓練，僅能以肉眼檢視。	依處理情形辦理。
資安是否有注意到可行性(軍方)。	在系統端可預先設定禁航區，或對影像作自動遮蔽，並可於帳號設定部分，針對不同使用者進行不同比例的遮蔽。	符合。
成果豐富具可行性	感謝委員肯定。	符合。
建議可討論成本，以利未來運用	感謝委員建議，未來可對成本進行評估。	依處理情形辦理。
五、運輸技術研究中心蔡立宏主任		
岸邊設施辨識率可達 9 成以上，而無法辨識或遺漏部分可再進行評估？	AI 無法完全取代人力，但可以減少人力使用，目前在辨識上設有機制，讓檢測人員可以於平台上進行再次確認，針對辨識成果進行修改。	依處理情形辦理。
碼頭堤面之伸縮縫及裂縫，目前可辨識之解析度？	目前可辨識之解析度為 0.67cm/pixel。	符合。
六、運輸技術研究中心李俊穎科長		
摘要及結論中有提及，利用傾斜攝影測量技術補足高空影像不足部分，在報告主文內卻未被提及，建議加以補充說明。	感謝委員建議，此部分為去年度成果，重點仍以今年度成果為主。	符合。
摘要中建議放入今年度優化及新增辨識項目成果。	感謝委員建議，已於報告進行補充。	所提意見及執行內容調整，列入修正定稿辦理。

參與審查人員及其 所提之意見	合作研究單位 處理情形	本所計畫承辦單位 審查意見
第四章，第 1 次提及名詞請再補述全名，如 ROS1 Melodic、RVIZ、表 4-1 內 NMEA 等。	感謝委員建議，已於報告進行補充。	所提意見及執行內容調整，列入修正定稿辦理。
第六章，有關堤面鋼筋裸露辨識，建議亦放入到 6.3 小節內。	感謝委員建議，已於報告進行補充。	所提意見及執行內容調整，列入修正定稿辦理。
第 7.3.2 節進行標註及訓練項目，請加以補述辨識項目為何？	感謝委員建議，已於報告進行補充。	所提意見及執行內容調整，列入修正定稿辦理。
第八章，因 LOD2 缺少難以呈現其成效，後續計畫可評估是否直接利用本案 DTM 資料進行分析。	嘗試使用 DTM 資料進行分析，但會有嚴重高估之情形。	符合。
第九章及第十章，所提及 UAV 及 UGV 通訊技術似不相同，主要考量原因為何？	感謝委員建議，4G 對於 UGV 是較為穩定的傳輸方式。	符合。
第 11.2.10 節有關平台內呈現 POI 時間，紀錄上請可查詢到拍攝時間至分鐘尺度，如圖 11.29 及圖 11.30 地面無人車氣體偵測似乎只能看到 5 月及 9 月。	時間尺度依照所提供之數據呈現，氣體偵測在當時設定上並未以分鐘為單位，後續可針對不同需求進行設定。	依處理情形辦理。
P12-12 文內有提及 1.3.3.1、1.3.3.2 似誤植，請再修改，另表 12-4 第 2 欄裂縫前應該要補 1，密度 D 對應 2M 欄位值似乎為 0.07，請再確認表內相關數值，以及表 12-5 內 q 值定義為何？此外，報告內所述「…該次大於 2 只有 3 個，因此取式 9(N3)…」文意不易理解，請再修改。	感謝委員建議，已於報告修正。	所提意見及執行內容調整，列入修正定稿辦理。
P 12-17 文內表 4 是否為表 12-6，請再確認。	感謝委員建議，已於報告修正。	所提意見及執行內容調整，列入修正定稿辦理。

附錄四、期末審查簡報資料



交通部運輸研究所運輸技術研究中心


港區影像智慧辨識技術 之研究(2/3)--- 空間資料環境分析及優 化影像檢監測應用技術

期末審查11/13

計畫主持人 韓仁毓 教授



國立臺灣大學
National Taiwan University



簡報大綱

- 歷年成果與今年度現況分享
- 計畫目的及效益
- 今年度成果說明
 - 優化感測資料自動化辨識技術
 - 多來源感測資料整合
 - 基於高細緻港區空間資料之環境分析
 - 地面無人載具控制邏輯方法
 - 無人載具之通訊技術研析
 - 無人載具之影像即時串流建構
 - 平台現況
- 結論及後續工作

前期成果彙整

臺中港(110~111年)

- ✓ 光達、可見光、熱紅外等感測器用於巡檢任務之可行性評估
- ✓ 影像資料蒐集，並建立高精度正射底圖(10公分解析度)及數值地形模型
- ✓ 無人機影像之智慧化分析，自動辨識標的物並進行多時期比對
- ✓ UAV載具分析及飛控邏輯技術，可依據不同任務類型進行路線規劃
- ✓ 系統平台建構

臺北港(112~113年)	延續臺中港技術與成果
---------------	------------

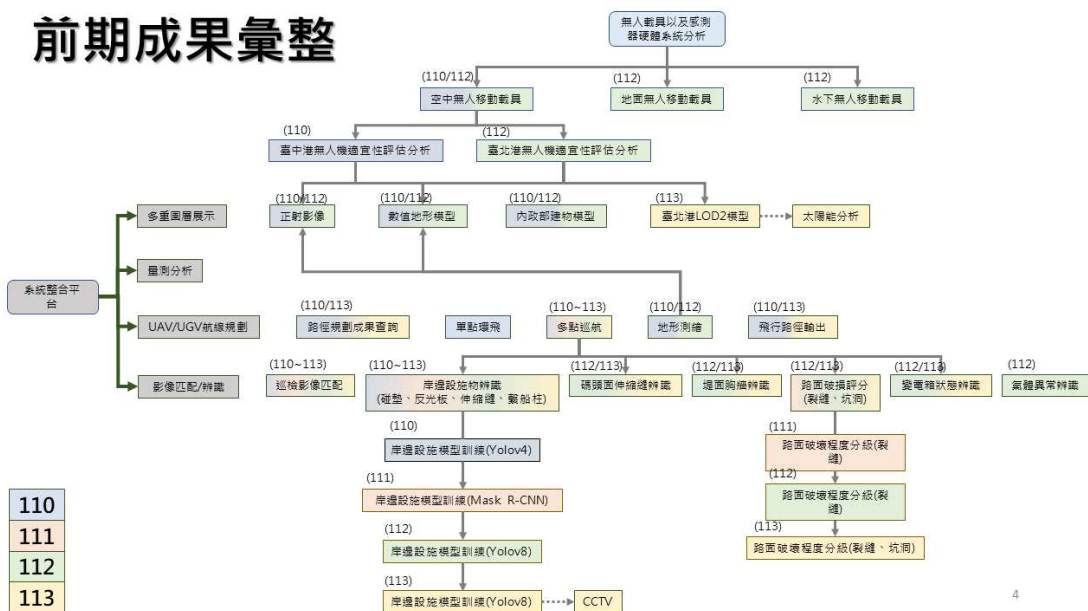
舊有技術深化:

- ✓ 影像資料蒐集，並建立高精度正射底圖(3公分解析度)及數值地形模型
- ✓ 延續臺中港成果精進無人機影像之自動智慧化分析(新增標的物&深化臺中港已有標的物模型)
- ✓ 系統平台建構

新興技術研發：

- ✓ 基於高細緻港區空間資料進行太陽能光電潛力分析
- ✓ 地面無人載具(UGV)種類分析及可搭載之氣體、熱紅外、可見光等感測器用於巡檢任務之可行性評估
- ✓ UGV遙控邏輯技術，可依據不同環境進行路線避障規劃
- ✓ 開發UAV及UGV串流技術，並研擬各自所應用之通訊技術

前期成果彙整



113年度計畫目的及效益

(一)計畫目的

持續發展一套結合機器學習技術與無人機影像的港區空間資訊整合應用方案，能有效利用定期且自動化獲取港區之大量空拍影像，藉以促進港區精準的智慧化空間資訊管理應用。

(二)預期效益

1. 可應用於港區的定期巡檢任務，並可針對特定任務與目標進行自動化的追蹤與判斷，降低人力負擔並提升任務執行品質。
2. 透過空間資訊的整合，可有效發揮各式資訊之特色，建構港區更為完整的空間資訊智慧管理基礎。



優化感測資料自動化 辨識技術



本年度精進及新增項目

已有標的物模型			
標的物類別	標的物	辨識模型內容	預計精進
岸邊設施	碰墊	物件偵測與辨識	地理位置定位
	反光板		
	車擋		
	繫船柱		
路面	裂縫	物件辨識與溫度偵測	持續偵測並更新
	人手孔蓋		地理位置定位
	變電箱		地理位置定位與即時告警
碼頭面	伸縮縫	結構線偵測與歪斜計算	法線位移
堤面	胸牆		
新增標的物件模型(本年度3項)			
標的物類別	標的物	辨識模型內容	
路面	坑洞	物件偵測與辨識	
堤面	鋪面裂縫		
碼頭面	鋪面裂縫		

7

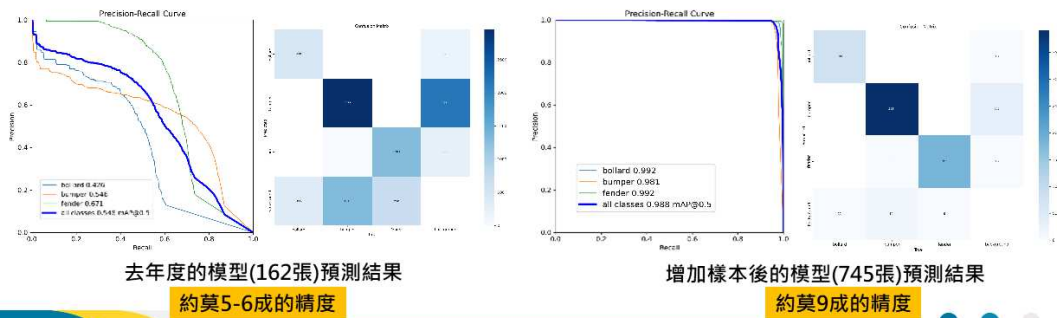
精進項目---岸邊設施持續偵測並更新



8

精進項目---岸邊設施驗證表現

- 針對10月一整期(三條岸線)的偵測結果量化，新的模型整體可達到九成以上的辨識準確度，相較於去年度的模型有大幅度的提升。



若需更換相機則加入新相機影像訓練後模型即可適應



9

精進項目---岸邊設施偵測成果比較

在不同張照片常有物件框時有時無的情況



去年度的模型預測結果

近乎穩定的偵測出全部的物件

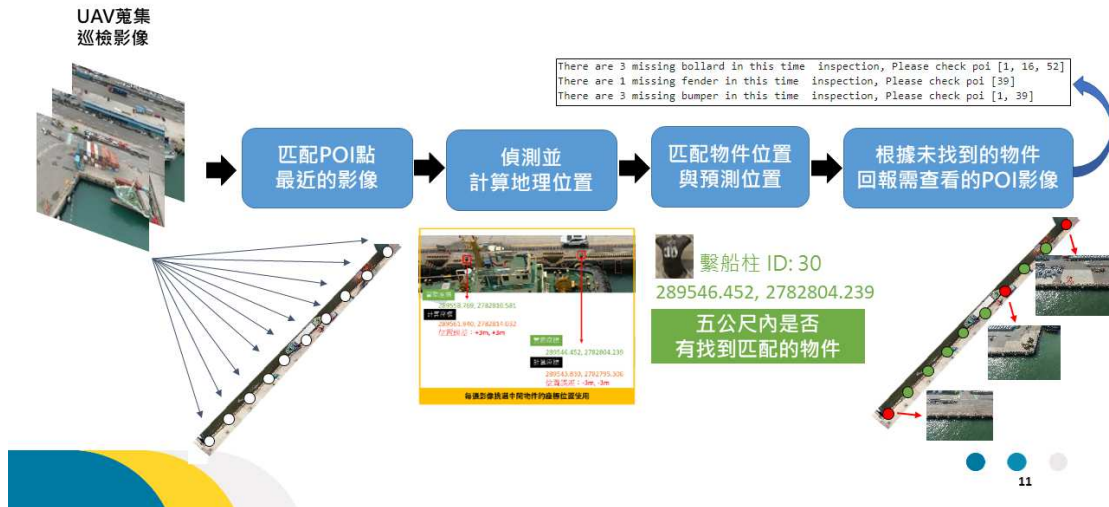


增加樣本數後的模型預測結果



10

精進項目---岸邊設施自動化巡檢流程



人工檢核岸邊設施流程



精進項目---變電箱模型持續偵測並更新

去年僅拍攝單一變電箱且缺乏不同視角樣本，故雖可成功偵測卻有overfitting的問題，且僅能偵測變電箱正面


增加變電箱樣本



拍攝日期: 2024/4
影像解析度: 640*480




拍攝日期: 2024/5
影像解析度: 640*480



拍攝日期: 2024/6
影像解析度: 640*480

模型訓練


數量：881張
Epoch：200
預訓練模型：yolov8n
訓練:驗證:測試=7:2:1




後續可透過UGV路徑規劃移動辨識變電箱並持續收集樣本

13

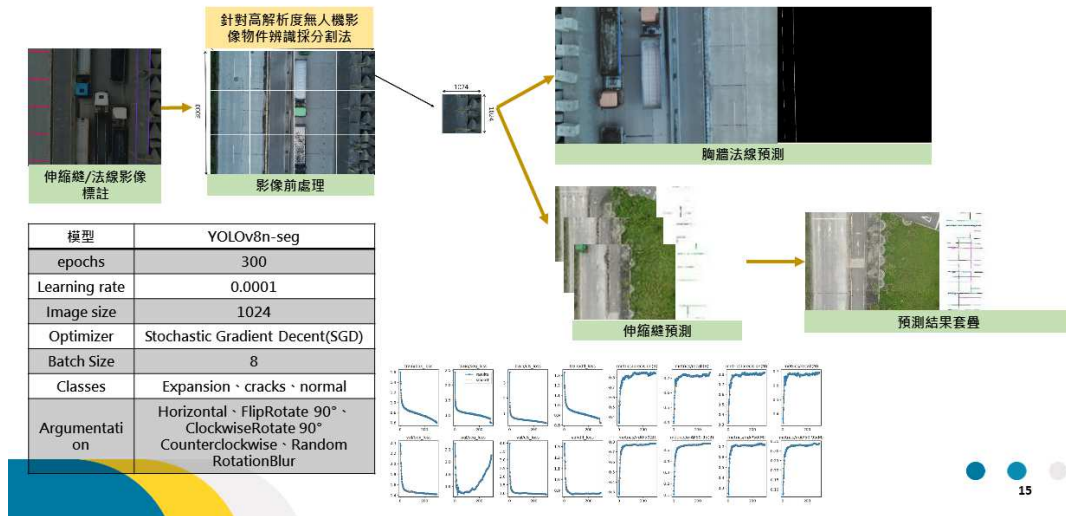
變電箱辨識成果



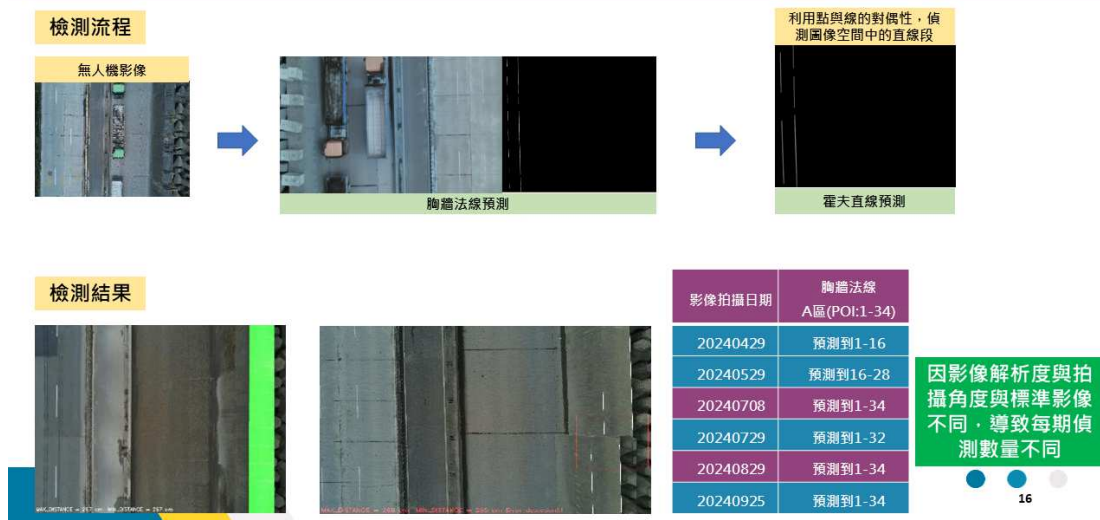
可成功辨識90%正面、側面、中距離、遠距離，
但側面近距離因樣本數較少，僅有30%成功率



精進項目---胸牆法線/岸邊伸縮縫預測模型




精進項目---胸牆法線檢測




新增項目---伸縮縫檢測流程

檢測流程



檢測結果



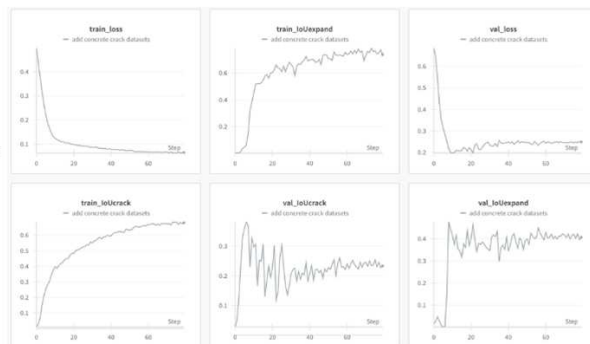
影像拍攝日期	伸縮縫 A區(1-179)	伸縮縫 F區(1-30)
20240429	預測35條	預測20條
20240529	預測163條	預測26條
20240708	預測21條	預測5條
20240729	預測157條	預測17條
20240829	預測17條	預測9條
20240925	預測101條	預測20條

因影像解析度與拍攝角度與標準影像不同，導致每期偵測數量不同

17

新增項目---鋪面裂縫


- 使用模型：
 - Arch: U-Net++
 - Encoder: Efficientnet-B6
- 資料集：
 - 圖片大小: 480*480
 - 訓練集資料量: 711(台北港237、台中港474)+300(現成的混凝土資料集)
 - 驗證集資料量: 180(台北港)





原有台北港+台中港裂縫樣本多為AC材質，而台北港堤面鋪面則為PC材質，故需額外增加公開資料集新增PC樣本

訓練成果比較



原圖



僅用港區資料集偵測結果





港區資料集+公開資料集偵測結果



後續將持續收集樣本，
並結合伸縮縫模型，透
過將成功辨識出的伸縮
縫濾除得出裂縫

新增項目---鋼筋外露

- 使用模型：YOLOV9
- 使用模型類別：YOLOV9-c
- 迭代數 (epoch)：80
- 批次大小：4
- 資料集：
 - 圖片大小：640*640
 - 訓練集鋼筋裸露處數量：144
 - 驗證集鋼筋裸露處數量：33
 - 測試集鋼筋裸露處數量：25



訓練成果比較

Ground truth



預測結果



消波塊陰影誤判



伸縮縫誤判

目前破壞性樣本數仍不足，堤面伸縮縫及消波塊後方的陰影處容易被誤判成鋼筋裸露，後續將持續收集樣本，減少誤判情形


21

新增項目---坑洞物件偵測與辨識模型建構

- 訓練資料集:2023/5~8台北港(A-1)+2022台中港影像資料
- 影像裁切: 480*480
- 測試張數:8張
- 台北港訓練資料及測試資料為75:8；台中港資料集之訓練資料及測試資料為240:25

將兩種資料混合做訓練及評估

台中港



台北港




A1道路



22

新增項目---坑洞模型訓練成果

模型及訓練方式同去年度，成果如以下所示，台北港坑洞之IoU score可達52.8，因資料量較少表現較台中港差。




台北港容易有overfitting(無法收斂)情形

測試資料集	IoU score (%)	
	背景	坑洞
台北港	99	52.8
台中港	99	88.4
混合	99	82.1

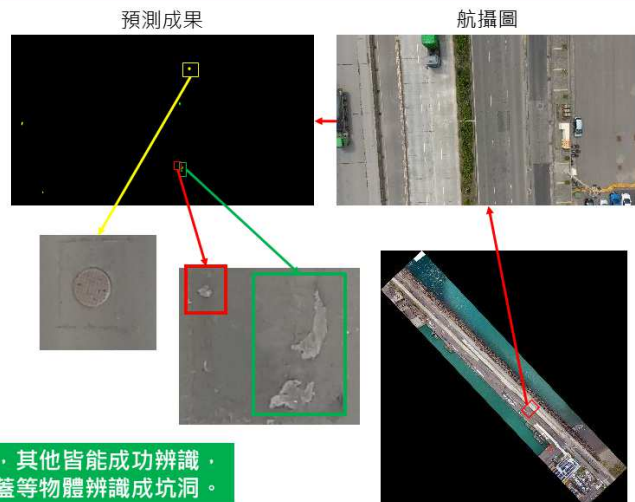
預測成功實例

路面補丁誤判



PCI坑洞預測結果(A-1道路)

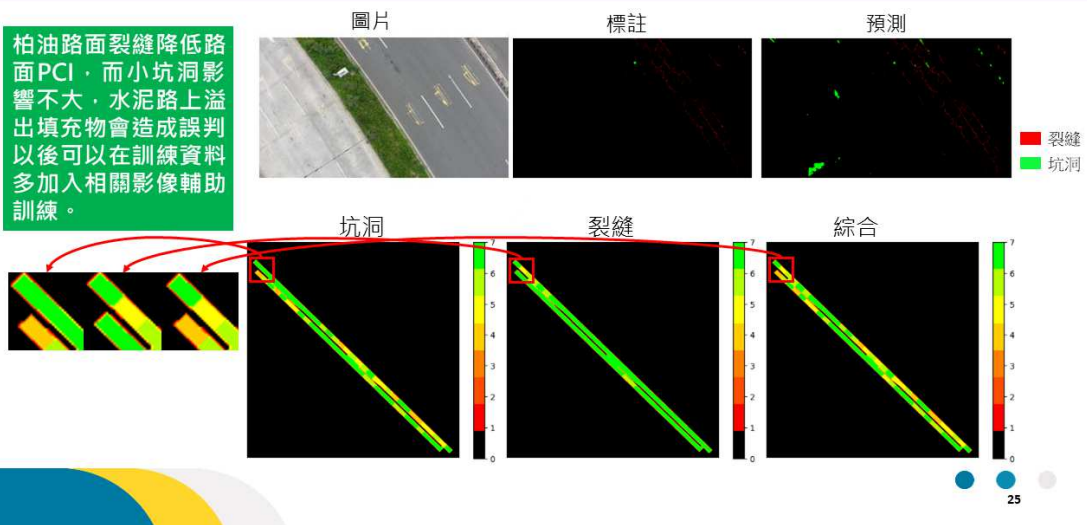
綠色:預測成功
黃色:無坑洞誤識為有坑洞
紅色:有坑洞但無法辨識



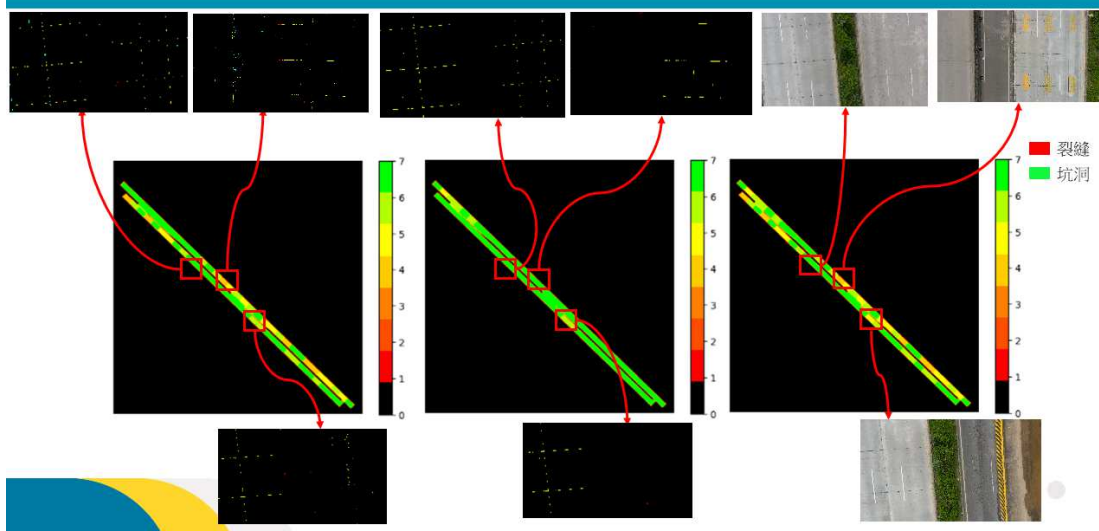
除了一個較小的坑洞，其他皆能成功辨識，但模型也容易將水溝蓋等物體辨識成坑洞。

道路PCI---裂縫及坑洞量化指標

柏油路面裂縫降低路面PCI，而小坑洞影響不大，水泥路上溢出填充物會造成誤判以後可以在訓練資料多加入相關影像輔助訓練。



道路PCI---成果檢視



多來源感測器整合

資料來源

- 訓練資料：7月~8月每周一
早上10:00~10:30
- 資料來源:台北港公司
- 4台監視器





直接套用UAV視角之現有模型，但模型未見過的視角不能兼容



CCTV視角的岸邊設施偵測結果

- 訓練模型：YOLOv8n
- 影像大小：640 x 640
- 訓練資料：不同視角各30張影像
- Epochs：50
- 偵測類別：車檔、繫船柱
- 模型表現：0.853(mAP50)



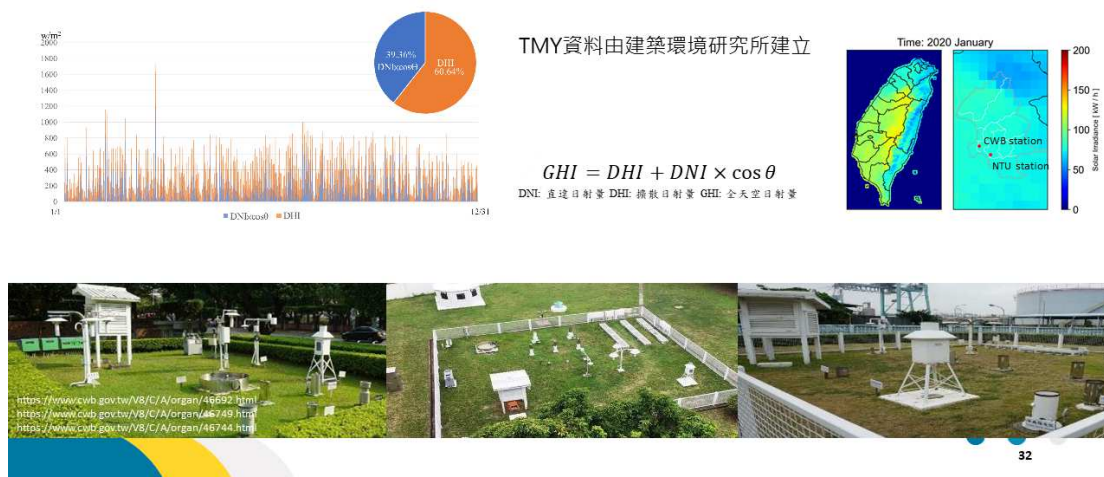
基於高細緻港區空間資料之環境分析

三維環境模型建立




31

太陽光電潛能評估技術-TMY日射資料



32

太陽光電潛能評估技術-每月發電量



月份	每平方公尺每月發電量(度)
1月	258.3669
2月	398.3324
3月	382.7263
4月	417.6313
5月	499.8301
6月	517.4448
7月	756.6806
8月	653.1553
9月	535.2445
10月	467.8947
11月	383.4834
12月	281.5871

以港公司所提供之LOD2模型計算，對照台電數據，非夏月期間全
台每戶平均月用電339度，夏月期間則為428度，與結果趨勢相符。

地面無人載具控制 邏輯方法

地面無人載具(Jackal)硬體設備介紹



Jackal 硬體設備	
Lidar	Velodyne VLP-16
深度相機	Realsense D456
GPS	ublox zed-f9p
氣體偵測器	flir lepton thermal camera
熱像儀	Nevada Nano Gas Detector

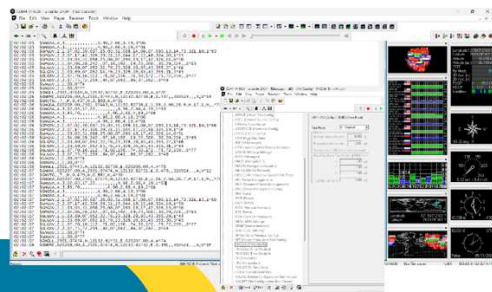
35

GPS定位方法

高精度GPS裝設



SparkFun GPS-RTK (u-blox ZED-F9P)



手機內建GPS




將手機內建GPS接受器收到的訊息由WIFI傳給UGV(需要連接同一個WIFI)

36


地圖建立方法

特性	Gmapping(新方法)	Rtab map(上年度方法)
地圖類型	2D	2D&3D
計算資源需求	較少	較高
Sensor 類型	Lidar	Lidar & Depth camera
戶外適用性	大範圍開放空間可能無法有效建圖	戶外環境下表現佳，適合大範圍和變化較大的空間
優點	計算資源需求較低、建立速度較快	資源有限的設備上無法即時建圖
缺點	對環境變化敏感度較低	適合大範圍和變化較大的空間



避障測試---路徑規劃演算法

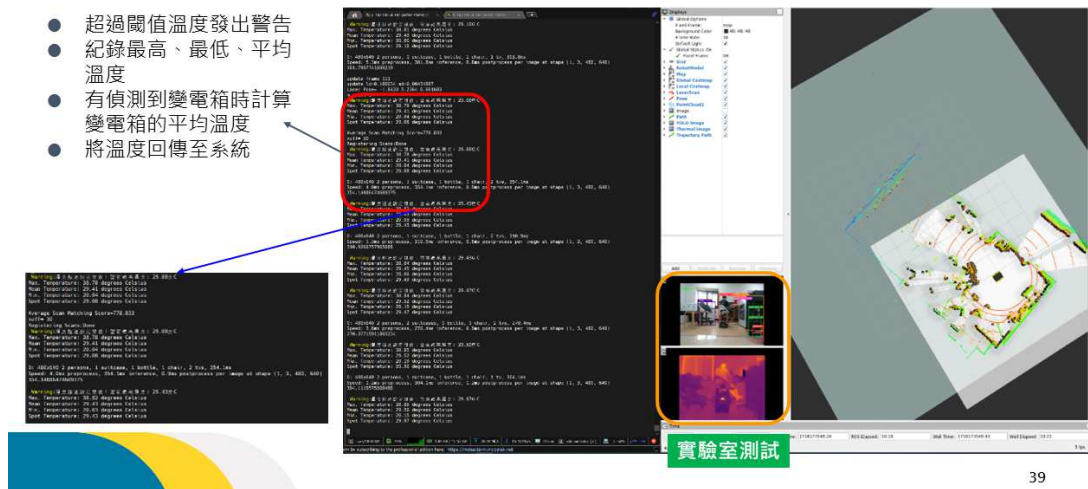
路徑規劃使用Dynamic Window Approach演算法 (DWA Planner)



1. 考慮周圍的障礙物和UGV的運動學參數，產生一條安全的路徑。
2. 考慮了每個格子的值（由本地成本地圖提供）和機器人允許的線性和角速度，以計算最小成本的路徑。

熱像儀溫度自動偵測與回傳

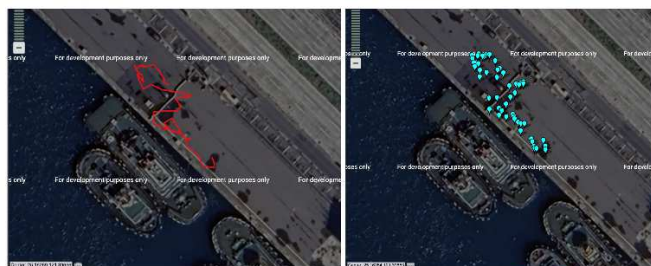

- 超過閾值溫度發出警告
- 紀錄最高、最低、平均溫度
- 有偵測到變電箱時計算變電箱的平均溫度
- 將溫度回傳至系統



39

航點導航測試

測試目的:整合UGV避障移動至變電箱並進行溫度偵測



UGV記錄之GPS座標路徑放至於地圖上

UGV記錄之避障情形

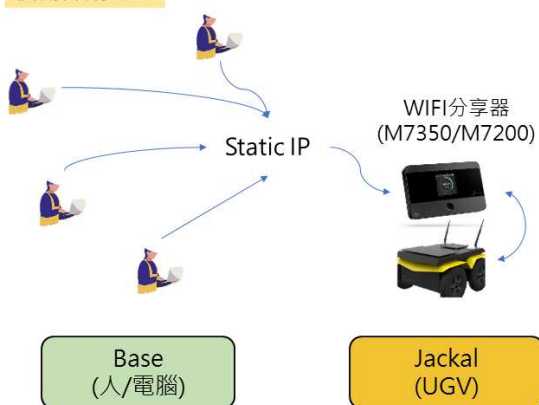
通訊方法與及時串流

無人機影像串流架構



UGV通訊方法---靜態IP

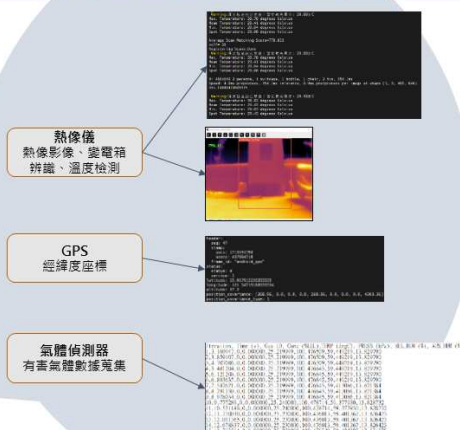
使用外網SSH



透過SSH傳送資料

操作人員不用至現場也可以控制無人車

UGV與系統對接流程圖



43

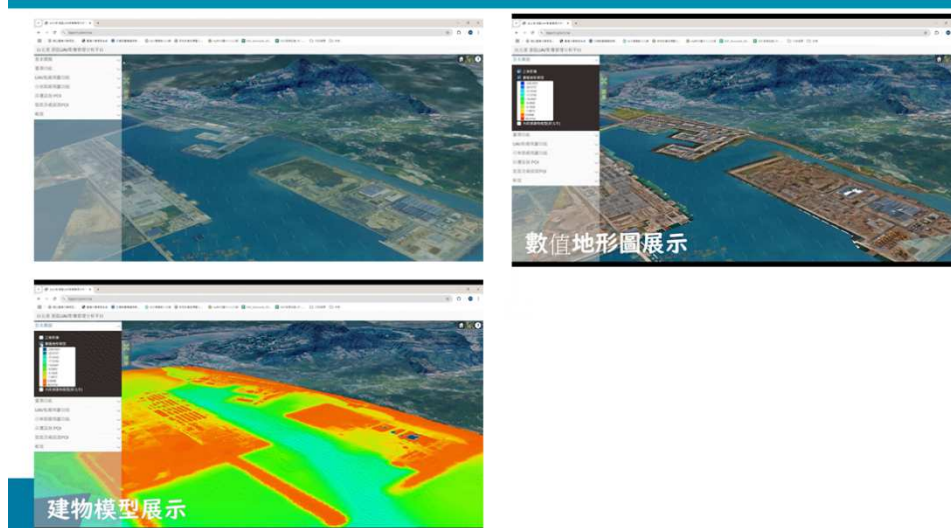
平台現況

平台架構(113年度)



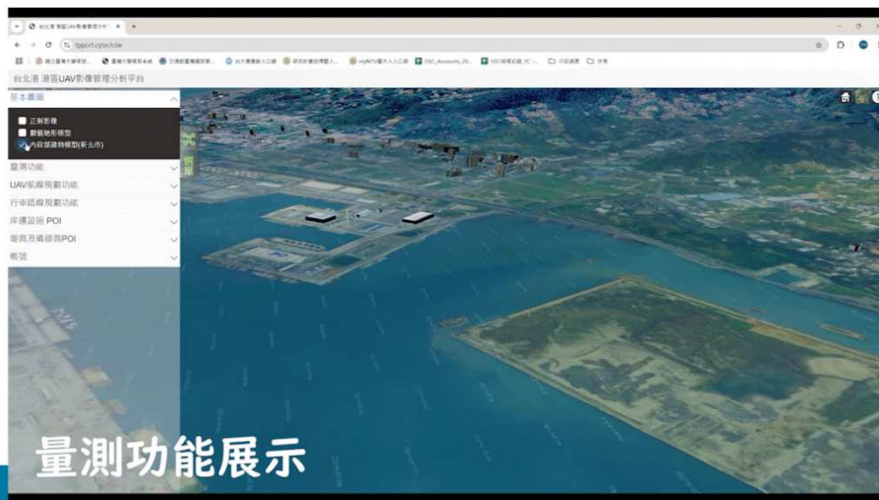
45

圖層




46

量測功能



UAV飛行路徑規劃



UGV行車路徑規劃



POI(岸邊設施)



POI(堤面胸牆)



51

POI(碼頭伸縮縫)

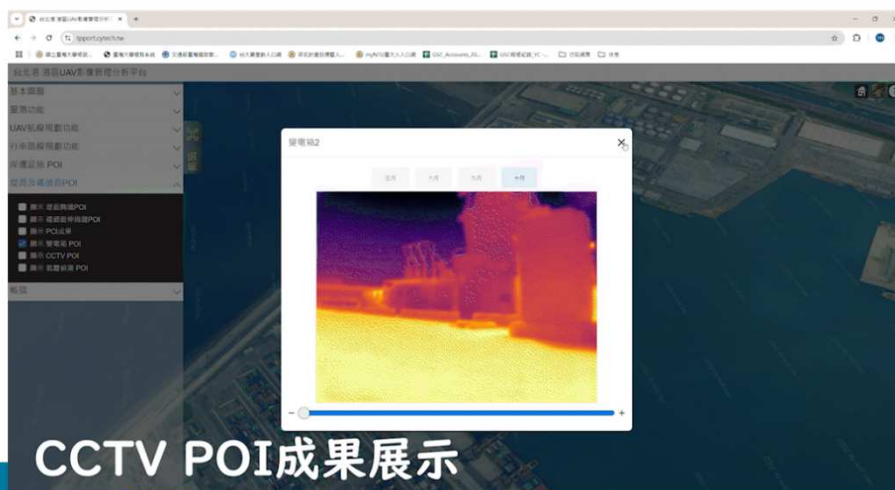


52

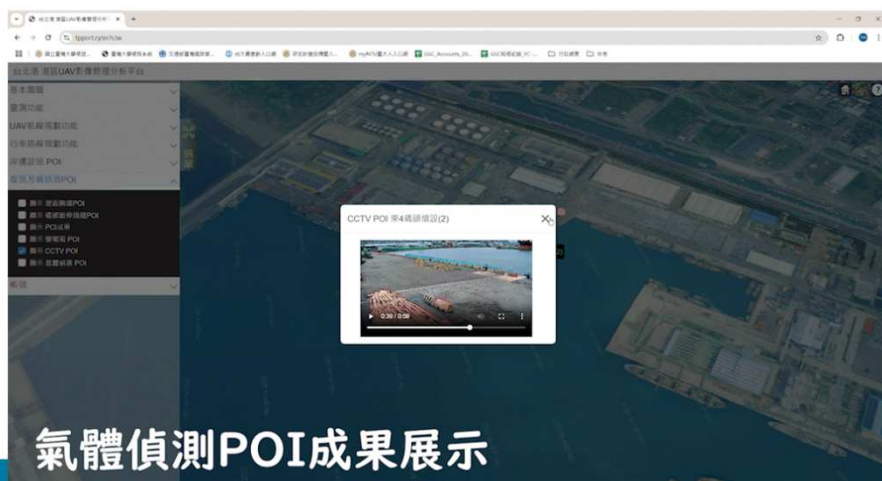
POI(變電箱)



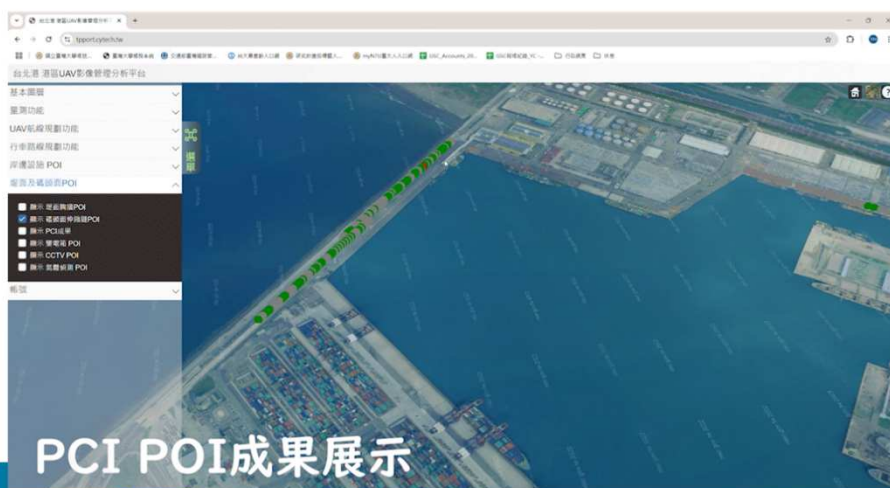
POI(CCTV)



POI(氣體偵測)



路面破損評分(PCI)



帳號管理



結論及後續工作

本年度完成項目

1. 優化感測資料自動化辨識技術：

透過YOLOv8模型和多年度影像資料，岸邊設施原92%精度提升至98%；變電箱偵測達到97.6%準確度；路面坑洞檢測混合資料集的IoU達82.1%；法線檢測計劃擴大訓練資料以提升準確度；今年度新增三項標的物：鋪面裂縫、鋼筋裸露及坑洞則因破壞性樣本不足而尚無法得到較好的成效。

2. 多來源感測資料整合：

嘗試將CCTV與團隊現有AI技術結合，然因角度不同而無法成功辨識，但在CCTV固定的視角下，重新訓練的模型即可達到相當好的成果。

3. 基於高細緻港區空間資料之環境分析：

提出光電潛力計算方法，利用港區LOD2模型資料計算後，可精確估算出太陽能光電潛力。

4. 地面無人載具控制邏輯方法：

改進UGV自主導航技術和地圖建立方法，整合高精度GPS接收器，顯著提升定位精度和自主避障能力。

5. 無人載具之通訊技術研析及影像即時串流建構：

可利用無線頻率傳輸UGV即時影像，利用SSL加密確保影像傳輸安全，提升資料安全性和傳輸效率。

6. 整合平台：

以臺中港平台功能為基礎，將維度由二維轉至三維，並整合開發成果於圖台之上。

感謝聆聽
敬請指教



國立臺灣大學
National Taiwan University