



內政部
111年度三維國土形變及空間智能分析技術
發展工作案

期末報告書（修正版）

案號：111CCL030C

主辦單位：內政部

執行單位：國立中央大學 太空及遙測研究中心

國立陽明交通大學 防災與水環境研究中心

計畫期程：自 111 年 3 月 4 日至 111 年 11 月 25 日

摘要

為發展與推廣智慧國土及智慧測繪科技以及相關應用，內政部 109 年度辦理「智能測繪科研發展計畫」，透過發展人工智慧與大量數據分析技術，利用衛星與航遙測影像進行國土地表形變分析、整理國際遙測影像訓練資料集、辦理相關科教活動等，進一步提升國土利用與形變分析技術。隨著人工智慧技術逐漸受到重視，如何將這些技術擴充及應用於國土利用與形變分析技術上，已成為刻不容緩的重要課題。

本計畫目的為發展人工智慧於測繪科技之相關應用，並透過人工智慧技術進行航遙測影像分析、辨識等應用。在技術發展與應用方面，本計畫工作成果包含：(1)透過雷達衛星影像地表形變智慧分析、機器學習等相關技術，發展衛星影像地表形變分析技術、(2)建立航遙測影像地表形變智慧分析、影像智慧辨識訓練資料集等相關技術，發展航遙測影像辨識技術與應用、(3)衛星與航遙測影像智慧分析與辨識，進行製圖防災整合應用案例試辦、(4)發展智慧物聯網之防災整合應用技術。在推動與評估方面，本計畫工作成果包含：(1)高程基準潮位站數據分析、(2)科教活動之推廣、(3)協助與配合內政部推動國際測繪合作事務、(4)發展智能實驗室。

本期報告詳述上列工作內容之實施方法以及階段性成果。透過本計畫的執行，達到整合與強化人工智慧應用之發展、落實科技紮根、厚植國家科研人才，以及提昇相關產業與國家整體的競爭力。

Abstract

In order to develop and promote related technologies and applications for smart land use and deformation monitoring and analyses, the Ministry of Interior (MOI) has initiated the “Technology Development for Smart Surveying and Mapping” project in 2020. The initiative aims to develop and integrate satellite and airborne remote sensing analysis with artificial intelligence (AI) and Big Data Analysis related technologies for land use and deformation monitoring and applications. In addition, the project will also promote the use of these new technologies and increase the public awareness of their applications.

In terms of technology development, the primary contents of this project include: (1) satellite-based optical and SAR data analysis for land change and deformation analysis and machine learning for this type of analysis; (2) airborne image analysis for land use and deformation monitoring and object detection applications; (3) smart analysis of satellite and airborne images for mapping and hazard mitigation applications; and (4) integrated IoT technologies for hazard mitigation applications.

On the other hand, this project also undertakes necessary tasks to promote the related technologies and their applications. These tasks include: (1) analysis of tidal station data; (2) promotion and popular science education of related topics; (3) international promotion and collaboration on surveying and mapping; and (4) establishment of smart mapping laboratories.

This report describes the materials, algorithms, and methodologies used and developed in this project as well as the progress and preliminary results of the tasks listed above. The outcomes of this project not only will integrate AI and remote sensing for smart surveying and mapping but also build and increase

the capacity for technology development and applications.

目 錄

目 錄.....	i
圖目錄.....	iv
表目錄.....	x
第一章 前言.....	1
1.1 計畫背景.....	1
1.2 計畫目的.....	1
1.2.1 技術建立.....	3
1.2.2 應用服務試辦.....	3
1.2.3 數據分析.....	4
1.2.4 科教活動、參與國際事務與成果推廣.....	4
1.3 分年度規劃與目標.....	5
第二章 背景分析.....	12
第三章 工作項目.....	14
3.1 工作項目.....	14
3.2 工作進度與自我發展評估.....	18
3.3 繳交成果及繳驗時程.....	24
第四章 實施方法與成果.....	26
4.1 應用人工智慧發展衛星影像地表形變分析技術與應用.....	26
4.1.1 利用雷達衛星影像發展長期地表形變自動化智慧分析技術.....	26
4.1.2 精進機器學習於高解析光學影像地表形變分析技術.....	43
4.1.3 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取.....	53
4.1.4 擴充衛星影像智慧加值應用與後續推動可行性評估.....	67
4.2 應用人工智慧發展航遙測影像辨識技術與應用.....	70
4.2.1 建立航遙測影像地表三維形變智慧分析技術.....	70
4.2.2 建立航遙測影像智慧辨識訓練資料集，須對不同類型之資料集進行整理並分析其適用	

性，探討結合影像與高程模型於地表分類之效益	81
4.2.3 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效	95
4.2.4 精進航遙測影像結合測量實工作之智慧整合應用	109
4.3 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦	120
4.3.1 利用雷達衛星影像地表形變分析，建立臺灣各地初步形變分析圖資，至少包含全臺灣 C-波段多時期雷達影像，及選定之災害潛勢區域 L-波段與 X-波段雷達影像；前述潛勢區域之選定須至少 2 處，並與內政部討論定案，任 1 處之辦理面積須達 200 平方公里以上，且運用包含（或優於）3 公尺解析度之影像在內進行分析	120
4.3.2 以兩年內高解析（2 公尺或更優）光學衛星影像進行數值地表模型（DSM）變異分析，發展利用衛星影像進行 DSM 變異以協助光達修測規劃之方法與作業程序，辦理區域選定須內政部討論且總面積須達 3,600 平方公里以上	130
4.3.3 航遙測影像分析與辨識之結果，精進與坡地防災應用平臺進行整合，其整合方案須與內政部討論後辦理	148
4.3.4 前述試辦本團隊需自行取得相關資料，並協調應用平臺之整合	182
4.3.5 以臺灣地區航遙測影像進行地物辨識與分類，辦理區域範圍至少為五分之一圖幅 10 幅（含）以上，辦理區域需與內政部討論選定且得洽內政部協助提供必要之既有測繪圖資	182
4.4 評估智慧物聯網之防災整合應用技術	203
4.4.1 模擬基於感測器與模型資料，發展智慧建築等適地性應用；前述模擬須運用三維圖資在內之整合技術	204
4.4.2 模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術	209
4.4.3 以實際場域進行適地性服務應用，其辦理方式與場域選擇需與內政部討論定案；前述工作本團隊需自行取得相關資料或建置物聯網相關所需裝置	217
4.5 數據分析與科教活動	225
4.5.1 持續分析基隆潮位站數據，包含調和分析、平均海水面、最低天文潮面等之計算，並比較共站不同潮位計觀測值之差異	225
4.5.2 配合內政部及國立海洋科技博物館，規劃水深與高程測量相關成果發表之科學教育教材，並舉辦 1 場次（至少 6 小時）之科教活動；受邀參加活動對象需經內政部同意	240

4.5.3 蒐集本案相關之航遙測技術與應用文件，製作科學教育數位課程教材 1 式，並舉辦 1 場次（至少 6 小時）之科教活動；受邀參加活動對象需經內政部同意	242
4.6 成果發表及技術交流	244
4.7 成果效益評估與計畫進度管考	245
4.8 工作會議	246
第五章 結論	247
參考文獻	257
其他相關資料及附件	263

圖目錄

圖 1.2-1、工作項目關聯圖	2
圖 4.1-1、合成孔徑雷達差分干涉示意圖	27
圖 4.1-2、PS 點強度篩選概念示意圖	28
圖 4.1-3、永久散射體像素相位穩定度分析示意圖	29
圖 4.1-4、U-NET 模型示意圖	30
圖 4.1-5、方法流程圖	31
圖 4.1-6、由 AI 模型得到的 PS 點圖	32
圖 4.1-7、STAMPS 選點後 PSINSAR 成果	33
圖 4.1-8、AI 選點後 PSINSAR 成果	33
圖 4.1-9、STAMPS 選點後 PSINSAR (僅使用與 AI 輸入相同的差分干涉影像)	34
圖 4.1-10、驗證資料	35
圖 4.1-11、都市區	36
圖 4.1-12、城鎮區	37
圖 4.1-13、鄉村區	37
圖 4.1-14、港灣	38
圖 4.1-15、橋梁	38
圖 4.1-16、河道區	39
圖 4.1-17、GNSS 驗證站點	40
圖 4.1-18、GNSS (藍點) 與 INSAR (紅圈) 時間序列	42
圖 4.1-19、CONVLSTM U-NET 模型示意圖	44
圖 4.1-20、訓練模型資料-8 種特徵影像	45
圖 4.1-21、模型訓練流程圖	46
圖 4.1-22、訓練影像區域	47
圖 4.1-23、測試影像與預測成果-案例 1	48
圖 4.1-24、測試影像與預測成果-案例 2	50
圖 4.1-25、訓練影像區域	51

圖 4.1-26、訓練資料（左：光學影像、中：訓練標籤、右：雷達影像）	52
圖 4.1-27、測試成果（左：光學影像、中：預測影像、右：雷達影像）	52
圖 4.1-28、三維點雲成果	56
圖 4.1-29、數值地表模型重建成果	56
圖 4.1-30、融合正射影像	57
圖 4.1-31、房屋偵測 AI 訓練資料集	58
圖 4.1-32、機器學習模式架構示意圖	59
圖 4.1-33、訓練過程之準確率及損失率	59
圖 4.1-34、機器學習模型分類房屋區成果	60
圖 4.1-35、PLEIADES 影像房屋偵測成果精度評估區域	61
圖 4.1-36、PLEIADES 房屋區域輪廓正規化與約化處理	63
圖 4.1-37、道路物件國際公開 AI 訓練資料集（部分）	64
圖 4.1-38、道路物件訓練影像與分類標示	65
圖 4.1-39、機器學習演算法道路區萃取成果	66
圖 4.1-40、道路區萃取成果檢核驗證資料	66
圖 4.1-41、SAR 淹水判釋加值應用範例	69
圖 4.1-42、石門水庫區域 NDVI 成果	70
圖 4.2-1、位移資訊位置示意圖(THIELICKE & STAMHUIS, 2014)	72
圖 4.2-2、花蓮縣瑞穗鄉林區數值地表模型	73
圖 4.2-3、地表平面位移場（黑色框為崩塌範圍）	75
圖 4.2-4、前後期 DSM 相減後高度變化	76
圖 4.2-5、地表高程位移場	77
圖 4.2-6、房屋前後期同位點平面位置	78
圖 4.2-7、房屋前後期同位點高程位置	78
圖 4.2-8、PIV 萃取三維地表位移向量	78
圖 4.2-9、各年度計畫建置之地表位移場	80
圖 4.2-10、不同應用目的之智慧辨識技術	83
圖 4.2-11、比較使用不同方式的土地覆蓋分類成果	86

圖 4.2-12、房屋輪廓萃取成果比較(SUN ET AL., 2021)	87
圖 4.2-13、臺灣市區與華盛頓建物影像比較	90
圖 4.2-14、比較不同方式產生的數值地表模型	94
圖 4.2-15、AIOI 資料集內航空正射影像(BRADBURY ET AL., 2016).....	95
圖 4.2-16、前期房屋辨識成果有無受到高差移位的差別	96
圖 4.2-17、精化數值地表模型設計架構 (WANG ET AL., 2021)	96
圖 4.2-18、建築範圍標籤稍微偏移應不影響預測成果	98
圖 4.2-19、TRANSUNET 模型架構圖(CHEN ET AL., 2021)	99
圖 4.2-20、TRANSUNET 模型偵測有高差移位屋頂面的能力	99
圖 4.2-21、TRANSUNET 模型偵測 AIOI 資料集房屋成果.....	100
圖 4.2-22、TRANSUNET 模型架構修改	101
圖 4.2-23、訓練與驗證與獨立檢核區域地真標籤展示	101
圖 4.2-24、RGB 直接訓練獨立檢核評估成果.....	102
圖 4.2-25、RGB+DSM 直接訓練獨立檢核評估成果.....	102
圖 4.2-26、只使用 RGB 影像與使用 RGB+DSM 影像成果展示.....	104
圖 4.2-27、訓練資料中有部分工地被標示為建築物	104
圖 4.2-28、AIOI 訓練後獨立檢核評估成果.....	105
圖 4.2-29、AIOI 預訓練模型對臺灣獨立檢核區辨識成果.....	105
圖 4.2-30、遷移式學習獨立檢核評估成果	106
圖 4.2-31、遷移式學習獨立檢核辨識成果	107
圖 4.2-32、臺北市一千分之一數值地形圖編碼及圖式 (臺北市政府都市發展局, 2004)	111
圖 4.2-33、電信人手孔圖例製作符號.....	112
圖 4.2-34、人孔智慧判釋試辦資料 (紅框：獨立驗證區)	113
圖 4.2-35、比較不同空間解析度之無人機正射影像.....	114
圖 4.2-36、影像切割後人孔資料將獲得增益.....	115
圖 4.2-37、人孔偵測之成功率與正確率	116
圖 4.2-38、人孔智慧辨識成果	119
圖 4.3-1、全臺灣五年(2017-2021)多時期形變監測試辦成果	122

圖 4.3-2、全臺五年(2017-2021) PSINSAR 三維平均速度成果圖	124
圖 4.3-3、臺北港 PSINSAR 年平均速度成果	126
圖 4.3-4、臺北港 A 點海堤 PSINSAR 時間序列	127
圖 4.3-5、臺北港 B 點海堤 PSINSAR 時間序列	127
圖 4.3-6、臺北港 C 點海堤 PSINSAR 時間序列	128
圖 4.3-7、L 波段 ALOS-2 高雄地震觀測成果	130
圖 4.3-8、高雄地震 DINSAR 變形量剖面	130
圖 4.3-9、地表形變分析試辦區	132
圖 4.3-10、SPOT-6/7 立體對	133
圖 4.3-11、利用 SPOT-6/7 立體對產製之數值地表模型	134
圖 4.3-12、地表形變分析使用之數值地表模型	134
圖 4.3-13、數值地表模型地表變異	135
圖 4.3-14、累計地表形變區域面積統計	136
圖 4.3-15、累積增減高度統計	137
圖 4.3-16、試辦區域明顯地表變異之圖幅	138
圖 4.3-17、圖 95192011 地表變異及前後時期 SPOT 影像	140
圖 4.3-18、圖 95192024 及 95192034 地表變異及前後時期 SPOT 影像	141
圖 4.3-19、圖 95192022 地表變異及前後時期 SPOT 影像	142
圖 4.3-20、圖 95192052 地表變異及前後時期 SPOT 影像	143
圖 4.3-21、衛星影像數值地表模型變異分析及更新建議作業程序流程圖	144
圖 4.3-22、邊坡變異點判釋示意圖	152
圖 4.3-23、時間序列粗差濾除	153
圖 4.3-24、時間序列前處理	153
圖 4.3-25、DEM 資料分布位置圖	154
圖 4.3-26、集水區重疊法(XIE ET AL., 2004)	155
圖 4.3-27、斜坡單元繪製流程圖	156
圖 4.3-28、各分割成果 IoU 大於 50%之崩塌參考資料比例	159
圖 4.3-29、SU1K、SNICxSU1K、MRSxSU1K IoU>50%之分割成果	160

圖 4.3-30、基於機器學習之崩塌地偵測程序圖	163
圖 4.3-31、SU1K、MRS_w99 及 MRSxSU1K_w99 之分割示意圖	165
圖 4.3-32、獨立檢核區之圖幅編號與 DEM (藍色為崩塌參考資料)	168
圖 4.3-33、獨立檢核區之崩塌參考資料與 SVM 預測崩塌地圖	170
圖 4.3-34、基於深度學習之崩塌地偵測程序圖	173
圖 4.3-35、單變量時序資料與 DEM 特徵融合策略	174
圖 4.3-36、雙變量時序資料與 DEM 特徵融合策略	174
圖 4.3-37、深度學習模型訓練 LOSS CURVE 圖	176
圖 4.3-38、獨立檢核區#10 之崩塌參考資料與深度學習預測崩塌地圖	180
圖 4.3-39、獨立檢核區#10 之機器學習與深度學習預測崩塌地圖	181
圖 4.3-40、臺灣地區航遙測影像房屋辨識試辦區	185
圖 4.3-41、農航所原始航照影像攝影展點	185
圖 4.3-42、房屋變遷偵測研究資料	188
圖 4.3-43、地面及非地面點雲	188
圖 4.3-44、DTM 及 DSM 改正正射影像套疊臺灣通用電子地圖房屋區域	189
圖 4.3-45、AI 預測房屋區域	191
圖 4.3-46、智慧辨識房屋變遷區域流程	191
圖 4.3-47、混淆矩陣	192
圖 4.3-48、臺灣通用電子地圖 (圖幅號 96224072) 與 AI 偵測房屋區域 (黑色：非房屋； 白色：房屋區域)	195
圖 4.3-49、人工數化及 AI 判釋房屋變遷物件示意圖	197
圖 4.3-50、臺灣通用電子地圖與 AI 判釋房屋變遷物件	199
圖 4.3-51、22 圖幅變遷面積直方圖分布 (含 16M ² 的變遷)	200
圖 4.3-52、22 圖幅變遷面積直方圖分布 (不含 16M ² 的變遷)	200
圖 4.3-53、房屋變遷比例較高圖幅	201
圖 4.3-54、房屋變遷區域局部放大	203
圖 4.4-1、善化區靜態資料	205
圖 4.4-2、水體交換示意圖(JANG ET AL., 2019)	207
圖 4.4-3、以 UNITY 建立淹水導航應用	208

圖 4.4-4、跨 CCTV 攝影機移動物件追蹤處理程序	210
圖 4.4-5、RE ³ 追蹤器身份變換問題範例	211
圖 4.4-6、追蹤器成果比較	213
圖 4.4-7、特徵匹配相似度驗證	215
圖 4.4-8、110 年度及本年度方法之移動物件追蹤成果比較	216
圖 4.4-9、桃園捷運 A18 站應用試辦系統架構圖	218
圖 4.4-10、人體骨架辨識行為之網路架構	220
圖 4.4-11、POSEC3D 架構	220
圖 4.4-12、行為辨識驗證成果	222
圖 4.4-13、ST-GCN++ 行為辨識驗證成果	223
圖 4.4-14、桃捷 A18 站行為辨識應用介面	225
圖 4.5-1、基隆潮位站現況	227
圖 4.5-2、K997、K996 及 TG997 示意圖	228
圖 4.5-3、臺灣水準原點高程基準網示意圖	228
圖 4.5-4、基隆潮位站壓力式及音波式水位計 2021/9/12 至 11/30 潮位數據	231
圖 4.5-5、基隆潮位站雷達式水位計 2022/6/1 至 10/31 潮位數據	232
圖 4.5-6、基隆潮位站音波式水位計歷年潮位變化	232
圖 4.5-7、基隆潮位站壓力式水位計歷年潮位變化	233
圖 4.5-8、基隆潮位站雷達式水位計歷年潮位變化	234
圖 4.5-9、基隆潮位站音波式水位計觀測數據與調和分析重組潮位時序圖	235
圖 4.5-10、基隆潮位站壓力式水位計觀測數據與調和分析重組潮位時序圖	236
圖 4.5-11、基隆潮位站雷達式水位計觀測數據與調和分析重組潮位時序圖	237
圖 4.5-12、研習營活動紀實	242
圖 4.5-13、科教活動上課照片	244

表目錄

表 1.3-1、規劃之發展目標	5
表 3.2-1、工作進度表	18
表 3.2-2、工作項目之自我評估表	22
表 3.3-1、各期程成果繳交項目	25
表 4.1-1、精度評估指標代表意義	34
表 4.1-2、精度評估使用之公式	35
表 4.1-3、各類區域之精度評估	39
表 4.1-4、影像資訊	43
表 4.1-5、預測成果精度評估-案例 1	50
表 4.1-6、預測成果精度評估-案例 2	51
表 4.1-7、訓練影像資訊	53
表 4.1-8、測試例影像資訊	55
表 4.1-9、PLEIADES 影像房屋偵測成果精度評估	62
表 4.1-10、PLEIADES 影像房屋正規化與約化成果精度評估	63
表 4.1-11、道路驗證資料表	67
表 4.1-12、道路萃取成果精度評估	67
表 4.2-1、頻率域匹配參數設定	74
表 4.2-2、比較人工量測與 PIV 萃取三維地表位移量	79
表 4.2-3、使用不同模型與資料的地物分類精度(JAHAN ET AL., 2018)	85
表 4.2-4、使用不同資料的地物分類精度(AL-NAJJAR ET AL., 2019)	86
表 4.2-5、國際標竿資料集基本資料	88
表 4.2-6、AIOI 訓練及 AIOI 預測精度	100
表 4.2-7、使用 RGB 與使用 RGB+DSM 最佳訓練成果獨立檢核評估指標	103
表 4.2-8、AIOI 訓練第 4 EPOCH、第 14 EPOCH 評估指標	105
表 4.2-9、遷移式學習獨立檢核評估指標	106
表 4.2-10、獨立檢核辨識漏授與誤授展示	108

表 4.2-11、人孔測量相關作業規範.....	110
表 4.2-12、辨識類別分類.....	114
表 4.2-13、原始與增益後之人孔資料.....	115
表 4.2-14、各訓練資料模型與影像資料庫的對應.....	116
表 4.2-15、各模型對各空間解析度之人孔偵測成果.....	116
表 4.2-16、各模型對各空間解析度之人孔偵測—平面誤差成果分析.....	117
表 4.2-17、智慧辨識與現地測量之人孔形心的距離差異量.....	117
表 4.2-18、智慧辨識與現地測量之平面誤差成果分析.....	118
表 4.2-19、智慧辨識與現地測量之高程誤差成果分析.....	119
表 4.3-1、TERRASAR-X 拍攝模式列表.....	125
表 4.3-2、ALOS-2 拍攝模式列表.....	128
表 4.3-3、影像集資訊.....	152
表 4.3-4、TSFRESH 時序特徵類別.....	164
表 4.3-5、SVM 模型測試集分類精度.....	166
表 4.3-6、SVM-F+P+D 模型獨立驗證精度評估.....	168
表 4.3-7、深度學習模型測試集分類精度.....	175
表 4.3-8、深度學習模型獨立驗證精度評估（全區）.....	177
表 4.3-9、深度學習模型獨立驗證精度評估（高海拔區#7-15）.....	179
表 4.3-10、機器學習與深度學習模型獨立驗證精度比較（高海拔區#7-15）.....	181
表 4.3-11、機器學習與深度學習模型預測耗時(#10-11).....	182
表 4.3-12、農航所原始航照影像說明.....	186
表 4.3-13、房屋區域偵測方法.....	193
表 4.3-14、房屋偵測精度分析：單圖幅.....	194
表 4.3-15、房屋偵測精度分析：22 幅圖幅.....	196
表 4.3-16、房屋變遷偵測方式.....	197
表 4.3-17、房屋變遷偵測精度評估.....	198
表 4.3-18、房屋變遷偵測成果之面積統計.....	199
表 4.3-19、各圖幅 AI 房屋變遷率統計表.....	201

表 4.4-1、追蹤器相關資訊.....	213
表 4.4-2、110 年度及本年度方法之移動物件追蹤成果比較.....	217
表 4.4-3、POSEC3D 及 ST-GCN++ 成果比較.....	223
表 4.5-1、基隆潮位站設備、型號及數量.....	227
表 4.5-2、基隆潮位站 2018 至 2020 年水位計參考點高程.....	229
表 4.5-3、基隆潮位站各水位計主要分潮比較.....	235
表 4.5-4、基隆潮位站水位計平均海水面高（單位：M）.....	238
表 4.5-5、基隆潮位站水位計最低天文潮水位（單位：M）.....	238
表 4.5-6、基隆潮位站逐年水位計平均海水面高（單位：M）.....	239
表 4.5-7、科教活動預定議程.....	241
表 4.5-8、科教活動議程.....	243
表 4.8-1、工作會議舉辦時間表.....	246

第一章 前言

1.1 計畫背景

內政部自100年起藉由「應用先進航遙測技術發展空間資訊計畫」引進國外先進行航遙測技術進行測試研究，105年接續推動「空間測繪應用研究發展計畫」進一步扶植自主科研技術，加速基礎圖資之測製效率，作為災害防救、國土規劃及民生經濟等重大事務應用。為進一步提升國土利用與形變分析技術，內政部109年度賡續辦理「智能測繪科研發展計畫」，透過發展人工智慧與大量數據分析技術，利用衛星與航遙測影像進行國土地表形變分析、整理國際遙測影像訓練資料集、研發自動化地物辨識技術、評估物聯網防災整合應用、潮位數據檢討分析、辦理相關科教活動、協助內政部推動國際測繪合作事務、成立智能實驗室厚植國家科研人才。

1.2 計畫目的

本計畫目的為發展人工智慧之相關應用，包含：(1)透過雷達衛星影像地表形變智慧分析、機器學習等相關技術，發展衛星影像地表形變分析技術、(2)建立航遙測影像地表形變智慧分析、影像智慧辨識訓練資料集等相關技術，發展航遙測影像辨識技術與應用、(3)衛星與航遙測影像智慧分析與辨識，進行製圖防災整合應用案例試辦、(4)發展智慧物聯網之防災整合

應用技術、(5)高程基準潮位站數據分析與科教活動之推廣。透過本計畫的執行，不僅可以整合與強化人工智慧應用之發展，落實科技紮根。此外，對於人工智慧應用的推廣和人才培育等也有正面貢獻，更能提昇相關產業與國家整體的競爭力。由於本計畫執行之工作項目較多，且並不是每一個工作項目皆有進行試辦作業，因此透過圖 1.2-1說明工作項目之屬性與關聯性，例如中大團隊負責之4.1.1節工項為技術之建立，並於4.3.1節中進行試辦，陽明交通大學團隊負責之4.2.1節工項為技術之建立，並於4.3.3節中進行試辦。

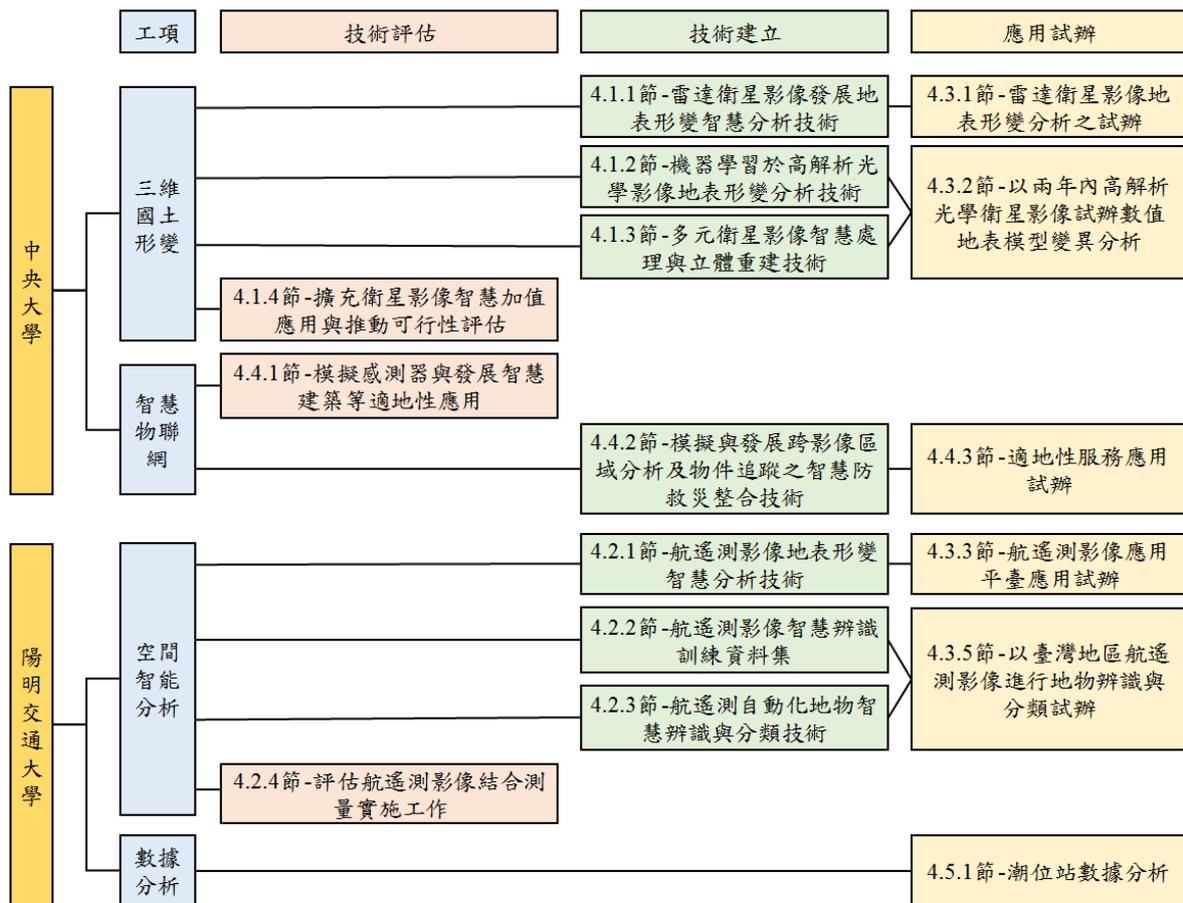


圖 1.2-1、工作項目關聯圖

1.2.1 技術建立

本計畫以「三維國土形變」及「空間智能分析」為主軸發展以下各項技術：

- (1) 雷達衛星影像發展地表形變智慧分析技術。
- (2) 機器學習於高解析光學影像地表形變分析技術。
- (3) 多元衛星影像智慧處理與立體重建技術。
- (4) 航遙測影像地表形變智慧分析技術。
- (5) 航遙測影像智慧辨識訓練資料集。
- (6) 航遙測自動化地物智慧辨識與分類技術。

1.2.2 應用服務試辦

本計畫以「智慧防災」為應用服務試辦主題，將前項工作發展之技術整合於防災應用領域，此外，亦針對「智慧物聯網」進行適地性服務應用試辦：

- (1) 雷達衛星影像地表形變分析之試辦，至少包含全臺灣 C-波段多時期雷達影像，及選定之災害潛勢區域 L-波段與 X-波段雷達影像。
- (2) 以兩年內高解析（2 公尺或更優）光學衛星影像進行數值地表模型 (DSM) 變異分析，發展利用衛星影像進行 DSM 變異以協助光達修測規劃之方法與作業程序。

- (3) 以實際場域進行適地性服務應用試辦，評估智慧物聯網之防災整合應用技術之成效。
- (4) 航遙測影像應用平臺應用試辦，以坡地防災應用為試辦主題，將航遙測影像分析與辨識之結果，整合 Google Earth Engine 雲端應用平臺之時序即時分析影像。
- (5) 以臺灣地區航遙測影像進行地物辨識與分類試辦。

1.2.3 數據分析

潮位站數據分析是檢視高程基準之必要工作，本計畫針對分析基隆潮位站數據，包含調和分析、平均海水面、最低天文潮面等之計算，並比較共站不同潮位計觀測值之差異。

1.2.4 科教活動、參與國際事務與成果推廣

為落實科普教育及計畫成果推廣，本計畫規劃配合內政部及國立海洋科技博物館，規劃水深與高程測量相關成果發表之科學教育教材；並規劃航遙測技術與應用相關成果發表之科教活動，以及製作科學教育數位課程教材 1 式。除此之外，本計畫以研發三維國土形變與空間智能分析之相關智慧製圖技術為主題發展「GeoAI Lab」實驗室，強化智慧製圖與空間資訊領域產業之聯結。

1.3 分年度規劃與目標

本計畫全程為三年期，本年度為第三年計畫，為使工作項目達到有效之研究與技術開發，因此增列現階段規劃之發展目標，且每年根據規劃目標之進度、國際相關之發展等進行內部評估，檢視、修改規劃之發展目標，以維持後續精進研究之技術。規劃之發展目標如表 1.3-1 所示。

表 1.3-1、規劃之發展目標

工作項目	分年工作		
應用人工智慧發展衛星影像地表形變分析技術與應用	1. 利用雷達衛星影像發展長期地表形變智慧分析技術		
	109	影像處理參數的建立與測試	
	110	處理參數成果精度驗證	
	111	利用機器學習進行參數最佳化	
	各期程工作項目之關聯	本項工作規劃於三年完成地表智慧形變分析之功能，主要聚焦於智慧的影像處理參數抉擇使得形變分析成果最佳化，109 年度以建立自動化的影像處理系統為主要工作，110 年度規劃完成參數資料建立與成果精度分析。今(111)年度啟動智慧參數學習的工作，快速的機器學習進行永久散射體自動辨別，結合人工智慧技術，找出最佳的雷達永久散射體來進行處理分析，縮短影像處理的時程，並減少失敗重試的機會。	
	2. 建立機器學習於高解析光學影像地表形變分析技術		
	109	應用高解析光學影像以機器學習偵測地表崩坍	
	110	應用多時期影像及地表模型以機器學習偵測地表形變	
	111	以機器學習進行地物類別分類及形變分析	
	各期程工作項目之關聯	本項工作規劃於三年完成機器學習進行地表形變分析之功能，109 年度以機器學習偵測高解析光學影像之地表崩坍為主要工作，110 年度精進機器學習相關技術，提供產製之訓練模型資料。今(111)年度增加訓練模型之影像種類，並以機器學習進行地表類別分類及形變分析的工作。	
	3. 發展多元衛星影像智慧處理與立體重建技術		
	109	衛星立體像對重建數值地表模型	
	110	多重疊衛星影像重建數值地表模型	
	111	以機器學習提升數值地表模型智慧處理	

工作項目	分年工作	
各期程工作項目之關聯		本項工作 109 年度目標為建立影像之物像空間關係與進行影像密匹配產生深度影像，進而產製點雲資料。110 年度以更多重疊之衛星影像，進行重建數值地表模型，利用多視角影像相互補償遮蔽區域，並提高匹配及定位品質。今(111)年度則預計針對所產製之數值地表模型，進行特徵目標物之萃取，例如建物或道路等目標物。
	4. 擴充衛星影像智慧增值應用與後續推動可行性評估	
	109	建立衛星影像成果圖資
	110	智慧增值應用彙整
	111	智慧增值應用推動可行性評估
各期程工作項目之關聯		本項工作 109 年度目標為進行圖資之蒐集與建立工作。110 年度以智慧增值應用案例彙整為主。今(111)年度則根據前兩年整合及評估成果，進行智慧增值應用可行性評估。
應用人工智慧發展航遙測影像辨識技術與應用	1. 建立航遙測影像地表形變智慧分析技術	
	109	建立多時期 光學影像地表形變智慧分析技術
	110	建立多時期 地形模型地表形變智慧分析技術
	111	整合多時期 光學影像及地形模型之三維地表形變智慧分析技術
	各期程工作項目之關聯	本項工作發展使用不同遙測資料獲取地表位移之技術。109 年度建立多時正射影像為基礎之二維地表位移偵測技術，並驗證發展技術之可行性。在航測產製正射影像的過程中，同時產出數值地形模型，提供高程方向上的改變，110 年度發展以數值地形模型進行地表位移偵測，比對使用正射影像之光譜及數值高程之高度進行匹配之效益。今(111)年度則是整合前兩期的技術，分別從正射影像及數值地形模型獲取平面及高程位移，探討取得三維地表位移之可行性。
	2. 建立航遙測影像智慧辨識訓練資料集，須對不同類型之資料集進行整理並分析其適用性	
	109	國際遙測影像標竿資料集整理與分析：以影像分類為主
	110	國際遙測影像標竿資料集整理與分析：以影像分割為主
	111	國際遙測影像標竿資料集整理與分析：以影像及高程資料融合之影像分割為主
	各期程工作項目之關聯	本項工作蒐集及分析不同類型的訓練資料集。109 年度標竿資料蒐集以影像單一類別(Single Label)分類為主，即每一張影像對應單一種類別(例如分類影像是否是房屋類別)，這類的標竿資料是普及化最高的測試標竿資料集。在遙測影像的分類應用中，需要知道地物在影像中的區域，即每一張影像中地物的輪廓(如偵測影像中房屋區域)，110 年度針對影像語意分割之標竿資料進行分析。今(111)年度則是針對融合航遙測影像及高程模型於房屋偵測之國際標竿資料集收集及分析。

工作項目	分年工作		
	3. 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效		
	109	發展深度學習於遙測 地物 智慧辨識技術	
	110	發展深度學習於遙測 房屋 智慧辨識技術	
	111	發展深度學習於遙測影像及高程模型之房屋智慧辨識技術	
	各期程工作項目之關聯	本項工作發展使用深度學習技術自動化判釋不同地物、房屋區域偵測及道路區域偵測。109 年度配合所蒐集之影像分類訓練資料集，針對多光譜遙測影像進行地物之判釋，判釋影像場景的地物類別，例如分類影像是否是房屋類別。110 年度則是配合所蒐集之影像語意分割資料集，針對遙測影像進行房屋區域偵測，以萃取影像中的房屋區域。今(111)年度則是配合所蒐集之語意分割資料集，進一步整合遙測影像及高程模型資料，進行房屋區域偵測，以資料融合提升房屋區域偵測成果。	
	4. 評估航遙測影像結合測量實工作之智慧整合應用		
	109	評估使用無人機輔助 地籍測量製圖 作業	
	110	評估使用無人機輔助 人孔調查測量 作業	
	111	評估使用無人機輔助 人孔調查測量 作業	
	各期程工作項目之關聯	本項工作評估無人機測繪技術於不同測量實工作之智慧整合應用。109 年度評估導入無人機測繪技術於「地籍測量」製圖實施作業，探討無人機影像輔助辦理非都區地籍圖更新、土地複丈等業務之案例。110 年度則是評估導入無人機測繪技術於「人孔調查」測量實施作業，探討無人機影像應用於公共設施管線資料庫系統之人孔測量智慧整合。今(111)年度則是精進無人機測繪技術於「人孔調查」測量實施作業，導入無人機密匹配三維點雲提供人孔高程資訊，並模擬分析不同空間解析度無人機影像之偵測效益。	
衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦	1. 雷達衛星影像地表形變分析之試辦，至少包含全臺灣 C-波段多時期雷達影像，及選定之災害潛勢區域 L-波段與 X-波段雷達影像；前述潛勢區域之試辦須選定至少 2 處，並與內政部討論定案，任 1 處之試辦面積須達 200 平方公里以上，且運用包含(或優於) 3 公尺解析度之影像在內進行分析		
109	影像處理流程、參數設定與對應成果的產製		
110	引入更多試辦案例，完成參數資料建立與成果精度分析		
111	引入前期成果為人工智慧參數學習基礎，啟動智慧參數學習工作		

工作項目	分年工作	
各期程工作項目之關聯		本項工作 109 年度利用雷達衛星影像發展長期地表形變智慧分析技術，完成影像處理流程、初始參數設定與對應成果的產製。110 年度為引入更多試辦案例，逐步建立影像處理之參數數據庫與經驗。今(111)年度引入前期成果作為人工智慧參數學習之基礎，同時建立臺灣各地的初步形變分析圖資。
	2. 以兩年內高解析(2 公尺或更優)光學衛星影像進行數值地表模型(DSM)變異分析，試辦區總面積須與達 3600 平方公里以上，且須內政部討論選定	
109		分析光學衛星影像，進行數值地表模型的高程差異分析
110		不同種類多時期地表形變分析
111		不同種類多時期地表形變分析
各期程工作項目之關聯		本項工作 109 年度分析光學衛星影像，進行數值地表模型的高程差異分析。透過 109 年度發展之技術，110 年度規劃以更多種類型之多時期地表形變分析。今(111)年度，規劃更多種類型(或精進)之多時期地表形變分析
	3. 航遙測影像分析與辨識之結果，須與相關應用平臺進行整合試辦，其試辦方案須與內政部討論後辦理	
109		坡地防災應用平臺試辦
110		精進坡地防災應用平臺試辦
111		精進坡地防災應用平臺試辦
各期程工作項目之關聯		本項工作使用 Google Earth Engine (GEE)應用平臺進行坡地防災應用。GEE 遙測大數據平臺是遙測應用的重要發展趨勢，其優勢是可進行遙測大數據時序分析與應用。109 年度使用 GEE 應用平臺整合航遙測影像分析與辨識之結果，發展以時序光學衛星影像為基礎之坡地防災植生復育。為提升判釋效率，110 年度持續精度使用 GEE 應用平臺發展坡地防災應用，進一步發展機器學習演算法進行時序分析，以判釋坡地變異點。今(111)年度則是融合光學衛星影像及數值高程模型之地形因子，發展機器學習演算法進行物件式時序分析，進行坡地防災應用平臺試辦。
	4. 以臺灣地區航遙測影像進行地物辨識與分類試辦，試辦區範圍至少為五千分之一圖幅 10 幅(含)以上，試辦區需與內政部討論選定且得洽內政部協助提供必要之既有測繪圖資	
109		地物辨識試辦
110		地物變遷試辦
111		精進地物辨識與變遷試辦

工作項目	分年工作	
各期程工作項目之關聯		本項工作 109 年度選定試辦區，並進行不同年度航空正射影像之地物辨識作業。110 年度為選定試辦區，進行房屋變遷試辦，今(111)年度整合光學影像及數值地表模型精進房屋變遷偵測試辦。
評估智慧物聯網之防災整合應用技術	1. 模擬基於感測器與模型資料，發展智慧建築等適地性應用；前述模擬須運用三維圖資在內之整合技術	
	109	針對數項智慧應用進行模擬測試
	110	以模擬之資料探討潛在整合應用案例
	111	針對數項智慧應用進行模擬測試
	各期程工作項目之關聯	本項工作於 109 年度測試並證明透過模擬可避免花費大量時間與金錢成本實際布設物聯網硬體設施。110 年度以模擬之資料探討潛在整合應用案例，例如連結火警通報系統、物聯網抽風機與灑水機之火災逃生系統等。今(111)年度依據 109 年及 110 年之模擬研究成果，進行更適用於實際場域之模擬應用。
	2. 模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術	
	109	研究跨 CCTV 攝影機影像移動物件追蹤技術
	110	納入時間與空間資訊進行 CCTV 追蹤技術優化
	111	精進跨影像區域之追蹤技術
	各期程工作項目之關聯	本項工作於 109 年度發展跨 CCTV 攝影機影像移動物件追蹤技術作為物聯網位置資訊之重要來源。110 年度於模擬場域散布不同位置之 CCTV 攝影機，安排多個移動物件於此模擬環境隨機移動。今(111)年度根據模擬之成果，精進跨 CCTV 攝影機移動物件追蹤技術。
	3. 以實際場域進行適地性服務應用試辦，其試辦方式與場域選擇需與內政部討論定案；前述試辦本團隊需自行取得相關資料或建置物聯網相關所需裝置	
	109	於實際場域建置物聯網基礎建設測試智慧應用
	110	於實際場域建置物聯網基礎建設測試智慧應用
111	於實際場域建置物聯網基礎建設測試智慧應用	
各期程工作項目之關聯	本項工作於 109 年度測試跨 CCTV 攝影機影像移動物件追蹤之技術，並於中央大學太遙中心進行試辦應用。110 年度選擇桃園捷運 A18 站進行智慧廁所為主題進行物聯網的建置與應用。今(111)年度除與前兩年度相同尋找合作單位於實際場域部署相關之物聯網基礎建設及智慧應用，亦將延續城市模型與物聯網整合技術之領域應用。	
數據分析與科教活動	1. 辦理高程基準潮位站數據分析工作，其至少須包含基隆與東沙潮位站數據	
	109	基隆新設潮位站、東沙潮位站之潮位數據分析
	110	基隆新設潮位站、東沙潮位站之潮位數據分析

工作項目	分年工作		
各期程工作項目之關聯	111	基隆新設潮位站之潮位數據比較分析	
	各期程工作項目之關聯	本項工作 109 年度工作為分析基隆新設潮位站、東沙潮位站之潮位數據。110 年度擬持續分析基隆新設及東沙潮位站。今(111)年度工作分析基隆潮位站數據，包含調和分析、平均海水面、最低天文潮面等之計算，並比較共站不同潮位計觀測值之差異。	
	2. 配合內政部及國立海洋科技博物館，規劃水深與高程測量相關成果發表之科學教育教材，並舉辦 1 場次(至少 6 小時)之科教活動；受邀參加活動對象需經內政部同意		
	109	於海洋科技博物館辦理研習營	
	110	規劃水深與高程測量相關成果發表之科學教育教材，並舉辦科教活動	
	111	規劃水深與高程測量相關成果發表之科學教育教材，並舉辦科教活動	
	各期程工作項目之關聯	本項工作 109 年度於海洋科技博物館辦理「海洋與生活：空間資訊篇」，教材以基隆潮位站及鄰近之臺灣水準原點為主題，內容包含水準原點、潮汐、高程測量，對象為高中職學生為主。110 年度規劃水深與高程測量相關成果發表之科學教育教材，並舉辦 1 場次之科教活動。今(111)年度持續辦理辦理水深與高程測量相關成果發表之科學教育活動。	
	3. 蒐集本案相關之航遙測技術與應用文件，製作科學教育數位課程教材 1 式，並舉辦 1 場次(至少 6 小時)之科教活動；受邀參加活動對象需經內政部同意		
	109	規劃航遙測技術與應用相關成果之科較活動	
	110	規劃航遙測技術與應用相關成果之科較活動，並製作科學教育數位課程教材	
	111	規劃航遙測技術與應用相關成果之科較活動，並製作科學教育數位課程教材	
	各期程工作項目之關聯	本項工作 109 年度與國立中央大學太空及遙測研究中心-資源衛星接收站合辦，規劃航遙測技術與應用相關成果，並以衛星遙測科技應用案例進行說明，對象為高中、國中與國小教師為主。110 年度蒐集本計畫相關之航遙測技術與應用文件，製作科學教育數位課程教材 1 式，並舉辦 1 場次科教活動，今(111)年度蒐集本計畫相關之航遙測技術與應用文件，製作科學教育數位課程教材 1 式，並舉辦 1 場(6 小時)次科教活動。	
	成果發表及效益評估	109	進行期刊與論文投稿、成立人工智能實驗室，配合內政部之年度計畫成果發表活動，進行三小時之成果發表
110		進行期刊與論文投稿、發展人工智能實驗室	
111		進行期刊與論文投稿、發展人工智能實驗室	

工作項目	分年工作	
各期程工作項目之關聯		<p>本項工作 109 年度共投稿 5 篇期刊、論文，成立 GeoAI@NCU 及 GeoAI@NCTU 實驗室，研發三維國土形變與空間智能分析之相關智慧製圖技術，推動智慧製圖與空間資訊領域產業之聯結。並配合內政部參加 2020 年 11 月 17 日舉辦之智能測繪應用相關之年度計畫成果發表活動，本團隊進行三小時之成果發表，共四項主題。110 年度進行期刊與論文投稿 4 篇，參加 1 場次實體或線上之國內外測繪相關研討會，發展人工智能實驗室，強化產學合作。今(111)年度規劃進行期刊與論文投稿 4 篇，發展人工智能實驗室，強化產學合作。</p>

第二章 背景分析

「數位國家、智慧島嶼」為國家的發展願景，其中「前瞻基礎建設之數位建設」及「臺灣 AI 行動計畫」為推動發展的重要政策，不論是數位化或智慧化，空間資訊在數位國家基礎建設均扮演關鍵且必要的角色，因此內政部極積推動「邁向 3D 智慧國土-國家底圖空間資料基礎建設計畫」及「智能測繪科研」等發展計畫，以發展智慧國土及智慧測繪科技。

智慧國土(ide@Taiwan 2020 政策白皮書)與三維國土形變發展的背景分析：臺灣地處歐亞大陸及菲律賓海兩板塊聚合交界處，地質條件複雜。不論在平地或山區，受天然災害或人為因素的影響，地表形變的動態分析是重要議題，因此智慧國土管理與三維國土形變分析密不可分。傳統地面測量可提供高精度的地表形變監測成果，因有限的測站及經費，不易達成多時期及面狀地表形變監測的需求。航遙測影像具有高機動性及大範圍取樣的特性，為滿足大範圍三維國土形變分析的需求，有必要發展合成孔徑雷達干涉或影像匹配等國土形變分析技術。

智慧測繪與空間智能發展的背景分析：人工智慧被稱為第四次工業革命的核心，人工智慧為各個領域帶來許多新的發展契機。2019 年 Nature 期刊報導使用深度學習(Deep Learning)可自動化從航遙測影像萃取豐富的語意空間資訊(Reichstein et al., 2019)，對地球觀測、測量與繪圖、或空間智能

的發展都有顯著正面的助益，因此國內外各單位均積極投入這項發展，也造就了關鍵領域的發展，如 GeoAI 及 AI4EO 等。圖資的繪製為維持所需精度與正確性，需投入大量繪點人力。從製圖的角度出發，導入人工智慧可渴望提升效能，測繪領域亦必須掌握此發展脈動及契機進行測繪產業技術升級。

綜合以上，本計畫以「三維國土形變」及「空間智能分析」為主軸，進行技術評估、技術發展及應用試辦。

第三章 工作項目

3.1 工作項目

本團隊由國立中央大學太空及遙測研究中心、國立陽明交通大學防災與水環境研究中心系所組成。111 年度計畫期程自簽約日次日起至 111 年 11 月 25 日止，各項工作項目之說明如下。

一、應用人工智慧發展衛星影像地表形變分析技術與應用

- (一) 利用雷達衛星影像發展長期地表形變自動化智慧分析技術。
- (二) 精進機器學習於高解析光學影像地表形變分析技術。
- (三) 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取。
- (四) 擴充衛星影像智慧加值應用與後續推動可行性評估。

二、應用人工智慧發展航遙測影像辨識技術與應用

- (一) 建立航遙測影像地表三維形變智慧分析技術。
- (二) 建立航遙測影像智慧辨識訓練資料集，須對不同類型之資料集進行整理並分析其適用性，探討結合影像與高程模型於地表分類之

效益。

(三) 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效。

(四) 精進航遙測影像結合測量實施工作之智慧整合應用。

三、衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦

(一) 利用雷達衛星影像地表形變分析，建立臺灣各地初步形變分析圖資，至少包含全臺灣 C-波段多時期雷達影像，及選定之災害潛勢區域 L-波段與 X-波段雷達影像；前述潛勢區域之選定須至少 2 處，並與內政部討論定案，任 1 處之辦理面積須達 200 平方公里以上，且運用包含（或優於） 3 公尺解析度之影像在內進行分析。

(二) 以兩年內高解析（2 公尺或更優）光學衛星影像進行數值地表模型(DSM)變異分析，發展利用衛星影像進行 DSM 變異以協助光達修測規劃之方法與作業程序，辦理區域選定須內政部討論且總面積須達 3,600 平方公里以上。

(三) 航遙測影像分析與辨識之結果，精進與坡地防災應用平臺進行整合，其整合方案須與內政部討論後辦理。

(四) 前述工作本團隊需自行取得相關資料，並協調應用平臺之整合。

- (五) 以臺灣地區航遙測影像進行地物辨識與分類，辦理區域範圍至少為五千分之一圖幅 10 幅（含）以上，辦理區域需與內政部討論選定且得洽內政部協助提供必要之既有測繪圖資。

四、評估智慧物聯網之防災整合應用技術

- (一) 模擬基於感測器與模型資料，發展智慧建築等適地性應用；前述模擬須運用三維圖資在內之整合技術。
- (二) 模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術。
- (三) 以實際場域進行適地性服務應用，其辦理方式與場域選擇需與內政部討論定案；前述工作本團隊需自行取得相關資料或建置物聯網相關所需裝置。

五、數據分析與科教活動

- (一) 持續分析基隆潮位站數據，包含調和分析、平均海水面、最低天文潮面等之計算，並比較共站不同潮位計觀測值之差異。
- (二) 配合內政部及國立海洋科技博物館，規劃水深與高程測量相關成果發表之科學教育教材，並舉辦 1 場次（至少 6 小時）之科教活動；受邀參加活動對象需經內政部同意。

- (三) 蒐集本案相關之航遙測技術與應用文件，製作科學教育數位課程教材 1 式，並舉辦 1 場次（至少 6 小時）之科教活動；受邀參加活動對象需經內政部同意。

六、成果發表及技術交流

- (一) 提送國內外期刊或研討會論文文稿至少 4 篇，且其中 1 篇需提送國際期刊（SCI/EI 等級）並應配合內政部需求。
- (二) 以航遙測及空間數據為主題發展人工智能實驗室，強化產學合作。
- (三) 配合內政部辦理 111 年度行政院災害防救科技創新服務方案，並協助研發災後智慧監測、變異分析及物聯網防災應用相關作業與成果展示。

七、成果效益評估與計畫進度管考

依據科技計畫績效管考平臺(<http://gstp.stpi.narl.org.tw>)提供格式，配合內政部辦理本案計畫「科技發展計畫績效評估作業」自評作業需求，參考內政部提供之相關績效作業範本，填寫本案相關成果效益報告書、績效指標、佐證資料、政府科技發展計畫績效評估；另配合將本案各期資訊登載政府研究資訊系統(GRB, <https://www.grb.gov.tw/>)，且將登

載結果繳附於各期工作成果，並適時接受諮詢。

八、工作會議

本團隊定期召開工作會議，並適時接受諮詢。每次工作會議需提供會議紀錄。其中 2 次需邀請專家學者（名單需先與內政部討論）參與交換意見，並作為後續應用方向或執行參考，所需費用由本團隊負擔。

3.2 工作進度與自我發展評估

本團隊各項工作進度如表 3.2-1，藍色線段為預計進度，黃色區塊為實際進度，期中與期末進度分別代表該工作項目於期中與期末時限內之完成度，透過此工作進度表檢測各項工作進度。表 3.2-2 為自我評估現階段工作項目之發展狀況。

表 3.2-1、工作進度表

項次	工作項目	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	期中進度	期末進度
1	工作計畫書與各期報告												
	工作計畫書	■											
	期中報告		■	■	■							100	
	期末報告					■	■	■	■	■	■		100
2	應用人工智慧發展衛星影像地表形變分析技術與應用												
	利用雷達衛星影像發展長期地表形變自動化智慧分析技術		■	■	■	■	■	■	■	■		35	100

項次	工作項目	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	期中進度	期末進度
	精進機器學習於高解析光學影像地表形變分析技術											45	100
	發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取											40	100
	擴充衛星影像智慧增值應用與後續推動可行性評估											15	100
3	應用人工智慧發展航遙測影像辨識技術與應用												
	建立航遙測影像地表三維形變智慧分析技術											45	100
	建立航遙測影像智慧辨識訓練資料集，須對不同類型之資料集進行整理並分析其適用性，探討結合影像與高程模型於地表分類之效益											40	100
	建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效											45	100
	精進航遙測影像結合測量實施工作之智慧整合應用											40	100
4	衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦												
	雷達衛星影像地表形變分析之試辦，至少包含全臺灣 C-波段多時期雷達影像，及選定之災害潛勢區域 L-波段與 X-波段雷達影像											40	100

項次	工作項目	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	期中進度	期末進度
	以兩年內高解析(2公尺或更優)光學衛星影像進行數值地表模型(DSM)變異分析，發展利用衛星影像進行 DSM 變異以協助光達修測規劃之方法與作業程序，辦理區域總面積須達 3,600 平方公里以上											30	100
	航遙測影像分析與辨識之結果，須與相關應用平臺進行整合試辦，其試辦方案須與內政部討論後辦理											40	100
	前述試辦本團隊需自行取得相關資料，並協調應用平臺之整合											50	100
	以臺灣地區航遙測影像進行地物辨識與分類試辦，試辦區範圍至少為五千分之一圖幅 10 幅(含)以上											45	100
5	評估智慧物聯網之防災整合應用技術												
	模擬基於感測器與模型資料，發展智慧建築等適地性應用；前述模擬須運用三維圖資在內之整合技術											40	100
	模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防災整合技術											40	100

項次	工作項目	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	期中進度	期末進度
	以實際場域進行適地性服務應用，其辦理方式與場域選擇需與內政部討論定案；前述工作本團隊需自行取得相關資料或建置物聯網相關所需裝置											30	100
6	數據分析與科教活動												
	持續分析基隆潮位站數據，包含調和分析、平均海水面、最低天文潮面等之計算，並比較共站不同潮位計觀測值之差異											40	100
	配合內政部及國立海洋科技博物館，規劃水深與高程測量相關成果發表之科學教育教材，並舉辦 1 場次(至少 6 小時)之科教活動											35	100
	蒐集本案相關之航遙測技術與應用文件，製作科學教育數位課程教材 1 式，並舉辦 1 場次(至少 6 小時)之科教活動											20	100
7	成果發表及技術交流												
	提送國內外期刊或研討會論文文稿至少 4 篇，且其中 1 篇需提送國際期刊 (SCI/EI 等級) 並應配合內政部需求											25	100
	以航遙測及空間數據為主題發展人工智能實驗室，強化產學合作											20	100

項次	工作項目	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	期中進度	期末進度
	配合內政部辦理 111 年度行政院災害防救科技創新服務方案，並協助研發災後智慧監測、變異分析及物聯網防災應用相關作業與成果展示											50	100
8	成果效益評估與計畫進度管考											50	100
9	工作會議											50	100

表 3.2-2、工作項目之自我評估表

工項	發展評估
應用人工智慧發展衛星影像地表形變分析技術與應用	
利用雷達衛星影像發展長期地表形變自動化智慧分析技術	(2)發展中，本計畫已驗證機器學習選取 PS 點的效能，惟受限於機器學習所需之資料量與記憶體容量之限制，目前僅能投入最多 12 張影像進行評估(目前的訓練模型與 PS 預測成果已經相當不錯)，未來若有效能更佳之硬體，可納入為精進之方案。
精進機器學習於高解析光學影像地表形變分析技術	(2)發展中，單純以光學影像進行機器學習部分，已可提供訓練模型，光學加雷達的訓練模型仍有改善空間，後續可以針對高解析雷達影像進行深入。
發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取	(2)發展中，經特殊形狀之房屋正規化約化處理與道路向量化處理精進後，有機會導入建模之應用。
擴充衛星影像智慧增值應用與後續推動可行性評估	(3)先期研究，需引入相關平臺進行各項增值應用開發後方可能使用。
應用人工智慧發展航遙測影像辨識技術與應用	
建立航遙測影像地表三維形變智慧分析技術	(1)已成熟，本項工作發展無人機正射影像、數值地表模型及資料融合策略之三維質點影像量測(3D PIV)技術，經試辦分析確認可有效地建立三維位移場，技術成熟度佳，可導入坡地監測工作使用。

工項	發展評估
建立航遙測影像智慧辨識訓練資料集，須對不同類型之資料集進行整理並分析其適用性，探討結合影像與高程模型於地表分類之效益	(1)已成熟，本項工作蒐集及分析國際公開訓練資料集，可導入未來建置在地化智慧辨識訓練資料集及後續 GeoAI 技術發展參考使用。
建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效	(2)發展中，本項工作融合正射影像及 DSM 建立房屋智慧辨識技術，並驗證資料融合能更有效辨識房屋區域。針對房屋模型重建應用，DSM 改正之正射化影像之房屋邊界會有局部變形，需要進一步發展房屋邊界正規化技術，經精進後，有機會導入製圖應用。
精進航遙測影像結合測量實工作之智慧整合應用	(2)發展中，本項工作使用無人機影像發展人孔智慧辨識偵測技術，試辦成果顯示可達 85%之成功率及正確率，為提升人孔智慧辨識的泛用性，應增加不同場域的資料，精進智慧辨識模型供後續應用未來可導入重劃區人孔測量作業。
衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦	
雷達衛星影像地表形變分析之試辦，至少包含全臺灣 C-波段多時期雷達影像，及選定之災害潛勢區域 L-波段與 X-波段雷達影像	(1)已成熟，傳統 PS 技術現階段已成熟，可導入多時期形變監測。
以兩年內高解析(2 公尺或更優)光學衛星影像進行數值地表模型(DSM)變異分析，發展利用衛星影像進行 DSM 變異以協助光達修測規劃之方法與作業程序	(1)已成熟，本項工作利用光學立體像對產製 DSM 並與光達 DSM 進行比對分析，可得建議更新 DSM 之區域。可導入在光達修測工作規畫時參考，將所建議區域列為優先目標區，以評估實際工作區。
航遙測影像分析與辨識之結果，須與相關應用平臺進行整合試辦，	(2)發展中，本項工作建立物件式之時序多光譜衛星影像與 DEM 崩塌偵測技術，並比較機器學習與深度學習崩塌地偵測效益，已完成技術驗證。受限於 Landsat 公開衛星影像之空間解析度為 30 公尺，後續將使用更高空間解析度的衛星影像，精進崩塌偵測技術，有機會導入坡地防災應用。

工項	發展評估
以臺灣地區航遙測影像進行地物辨識與分類試辦	(2)發展中，本項工作融合正射影像及 DSM 進行房屋智慧辨識及變遷偵測技術，試辦成果顯示：房屋偵測精度約為 85%、房屋變遷精度約為 75%，小面積的房屋變遷偵測率較差，經精進後，有機會導入製圖應用。
評估智慧物聯網之防災整合應用技術	
模擬基於感測器與模型資料，發展智慧建築等適地性應用	(2)發展中，本項工作為透過感測器與模型資料進行模擬智慧建築之應用，將各項資料與應用藉由 Unity 系統進行模擬，本年度主題為整合城市資訊、物聯網及都市淹水模式建立導航防救災之模擬應用。後續可以風場模型分析三維建物間之風場，進而探討如空氣污染散佈等應用。
模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術	(2)發展中，本項工作改進前期(109、110年)跨 CCTV 攝影機移動物件追蹤技術，包含替換為更強健之追蹤器，以及加入物件分類至身份辨識程序，精進物件分類等技術，成果表現良好。未來可針對身份辨識的自我檢核與運算效能優化進行改進。
以實際場域進行適地性服務應用	(2)發展中，本項工作建立的行為辨識方法較適合應用在監視影片之離線分析，未來可精進使用骨架姿態特徵直接判斷異常與否進行通報，配合離線行為分類等。
數據分析與科教活動	
持續分析基隆潮位站數據，包含調和分析、平均海水面、最低天文潮面等之計算，並比較共站不同潮位計觀測值之差異	(1)已成熟，本項工作分析基隆潮位站數據，潮位數據分析技術成熟度佳，可導入高程基準工作。

3.3 繳交成果及繳驗時程

本計畫之執行分為三個期程完成下列項工作項目，包含工作計畫書、期中報告及期末報告，各期程成果繳交項目如表 3.3-1 所示。本團隊依照契

約書及服務建議徵求書相關規定確實執行，並於工作項目完成後將應繳交之各項成果送交內政部，經審核認可後為合格，若有資料不詳、不全、錯誤或系統功能不符合需求者，則退還本團隊補正，本團隊應於內政部指定期限內完成資料之修正。各期程之說明如下：

- 一、 工作計畫書：本團隊於簽約日起 1 個月內，就以下各項工作採目標管理法(OKR)規劃繳交「工作計畫書」，並依工作計畫書核定方式（或更優方式）辦理相關工作。
- 二、 期中報告及期末報告：期中報告初稿於 111 年 7 月 8 日前繳交，期末報告初稿於 111 年 11 月 25 日前繳交，俟內政部指定期限內，依審查意見修正後於分別繳交期中報告及期末報告定稿。

表 3.3-1、各期程成果繳交項目

期別	成果繳交項目及份數	成果繳交期限
第 1 期	1. 工作計畫書書面資料 2 份及電子檔 1 份。	簽約日起 1 個月內。
第 2 期	1. 期中報告書 9 份。 2. 國內外期刊或研討會論文文稿 1 篇。	111 年 7 月 8 日前繳交。
第 3 期	1. 期末報告書 9 份。 2. 國內外期刊或研討會論文文稿 3 篇。	111 年 11 月 25 日前繳交。 期末報告書經召開專家學者會議後，倘需修正，廠商需於內政部指定期限內繳交修正後期末報告書 3 份及其電子檔 1 份。

第四章 實施方法與成果

4.1 應用人工智慧發展衛星影像地表形變分析技術與應用

4.1.1 利用雷達衛星影像發展長期地表形變自動化智慧分析技術

長時間的地表形變如地層下陷、斷層滑動、坡地潛移等常會造成災害的發生，該類變遷光學衛星難以觀測，因此常以合成孔徑雷達差分干涉技術 (Differential Interferometric Synthetic Aperture Radar, DInSAR) 來實現，本方法係以衛載雷達系統，對地面發射雷達波後接收其回波，從而得到地表回波之強度與相位資訊。人造衛星於以太陽同步軌道運行，可以對單一地點進行週期性的拍攝，而得到此地區連續時間的雷達影像，將兩幅不同時間拍攝的影像進行差分干涉，可以得到在兩幅影像拍攝期間因目標距離變化產生的波相位差，經過計算後便得到地表形變的量值 (圖 4.1-1) (Massonnet and Feigl, 1998)。

利用軌道衛星持續拍攝的特性，用長時間獲取之雷達遙測影像進行 DInSAR 分析，獲取不同時期的地表形變量，便能重建觀測區域的地表形變歷史，本技術已成功應用於火山、斷層等地表形變的監測(Tai et al., 2018; Tsai et al., 2019)。

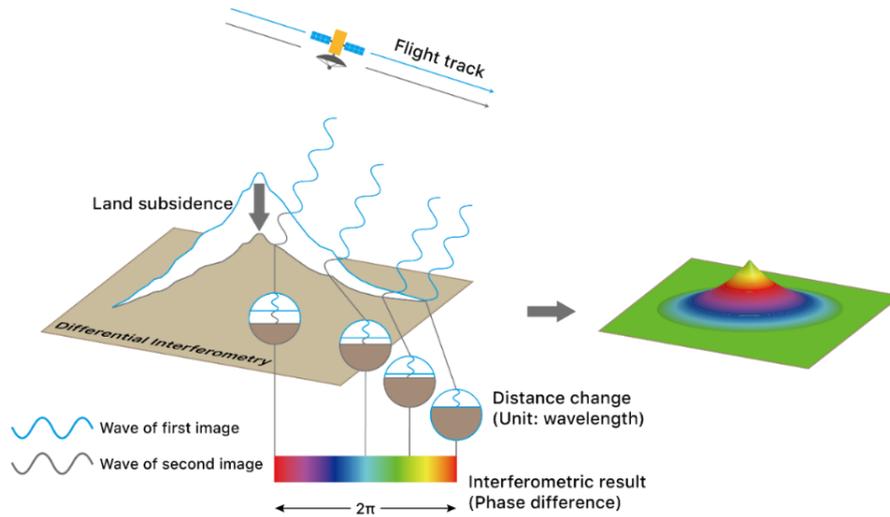


圖 4.1-1、合成孔徑雷達差分干涉示意圖

傳統 DInSAR 技術已發展數十年，其在測地學的應用已經相當純熟，但由於該技術的物理特性，使其使用上仍有諸多限制，雷達波去相關現象 (decorrelation) 會使得幾乎無法產生可以利用於計算地表形變得干涉圖。有鑒於這些技術的限制，Ferretti 等人率先提出永久散射體差分干涉技術 (Permanent Scatterers Interferometry Synthetic Aperture Rader, PSInSARTM) 的概念 (Ferretti, 2000)，利用挑選雷達影像中回波強度較強的像素為永久散射體 (Permanent Scatterers, PS)，由於這些像素擁有高的訊噪比 (SNR)，使得像素中的雜訊較容易被分析與消除，從而萃取出精確且能真正代表該地區地表形變的資訊 (戴于恒, 2016)。

利用雷達回波的訊號強度作為 PS 點選取依據的方法，在高訊噪比 (SNR>10) 之環境可以正確選出相位穩定的 PS 點，進而解算出優良的結果；然而在訊噪比低的環境，訊號強度與相位穩定度不再呈現正相關，單純考慮訊號強度所篩選出來的 PS 點未必具有永久散射體的性質，因此 Hooper

等人改良上述方法發展出另一種永久散射體雷達差分干涉技術 (Persistent Scatterers InSAR, PSInSAR)，此方法基於雷達反射波強度分析，選出可能具備永久散射體性質的像素後，在對其進行相位穩定性分析，篩選相位表現相對穩定的 PS 點，經篩選過之永久散射體像素其相位資訊能真正反映該地區之地表形變(Hooper, 2004)。

永久散射體之篩選主要由 Hooper 所開發的 StaMPS (Stanford Method for Persistent Scatterers)軟體完成，執行步驟分為兩個階段，第一階段設定雷達回波訊號的強度門檻，篩選出具備永久散射體潛力的像素 (圖 4.1-2)，稱作 PS 候選點 (Permanent Scatterers Candidates, PSC)，第二階段則針對 PS 候選點進行相位穩定性分析 (圖 4.1-3)，篩選相位表現相對穩定的 PSC 作為後續干涉運算與誤差估計的計算對象，以上過程需經過多次迭代計算與篩選，同時也必須考慮多時期的影像資料，影像數量越多、範圍越大則執行處理的時間也越久。

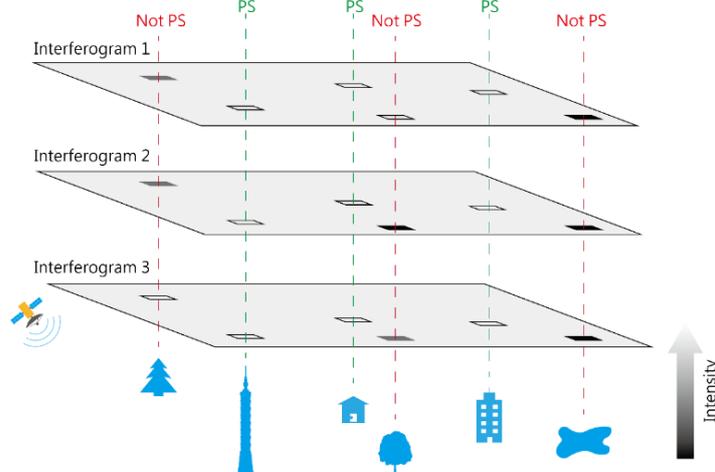


圖 4.1-2、PS 點強度篩選概念示意圖

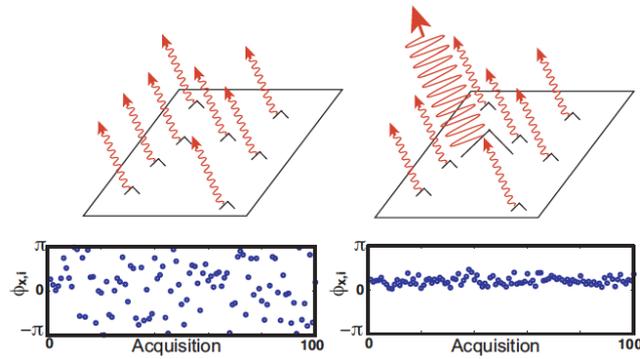


圖 4.1-3、永久散射體像素相位穩定度分析示意圖

為能提高影像分析與成果產製之效率，本項工作使用目前在影像分割任務上精度及效能表現較佳的全卷積神經網路 U-Net 架構來進行永久散射體之辨識工作，該模型已廣泛被應用到醫學、衛星等方面的影像辨識，藉此模型辨識後的成果影像，可大幅減少 PSInSAR 分析與尋找永久散射體所耗費的時間。

本項工作採用神經網路模型 U-Net (Ronneberger et al., 2015)，因為其模型結構形似 U 型而得名 (圖 4.1-4)。U-Net 是基於 FCN (Long et al., 2015) 神經網路模型所改進的，其為可達到像素級別的分類 (Pixel-Wise Classification)，主要分為兩部分，第一部分為特徵萃取，透過不同數量的卷積層 (Convolutional Layer) 與最大池化層 (Max-Pooling Layer)，將不同尺寸的特徵提取出來，並且透過最大池化層縮小特徵圖維度。在最後一個階段，會開始進行反卷積，透過反卷積層 (Deconvolutional Layer) 將特徵圖漸漸放大。第二部分，在第一次反卷積後，會得到比前一張特徵圖大 2 倍的特徵圖，接下來利用疊加 (Concatenate) 將此特徵圖與先前第一部分特徵萃取時相

同尺寸的特徵圖相結合，增加描述影像本身的特徵，並且利用新的特徵圖繼續分析。之後以相同的方法和不同數量的反卷積層，將反卷積後的特徵圖一一與先前同尺寸的特徵圖做疊加。最後會得到與輸入影像相同大小的特徵圖，完成 U-Net 的主要兩部分的訓練。

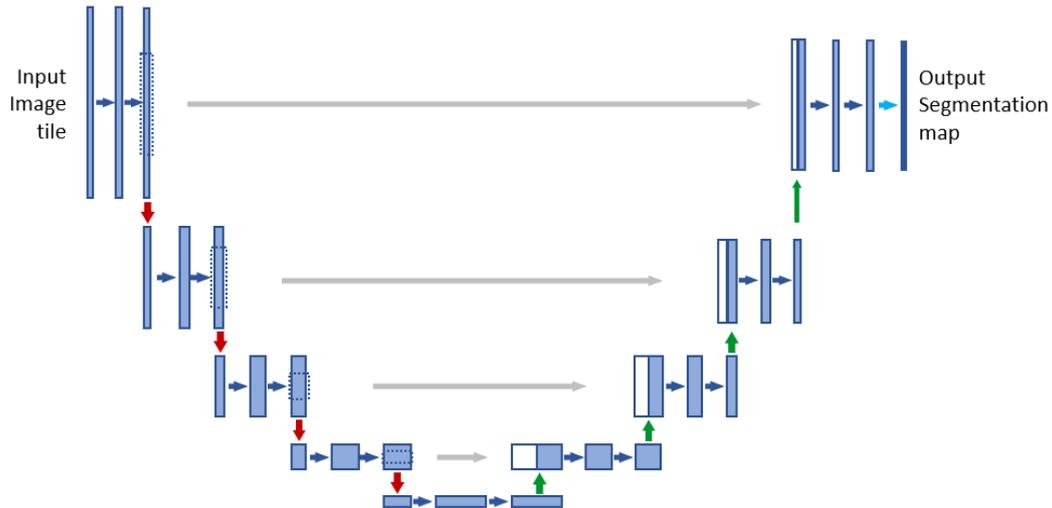


圖 4.1-4、U-Net 模型示意圖

在 U-Net 訓練各個階段中會加入 Batch Normalization 層與 Dropout 層，模型訓練時因為每一層的參數都會受到前面所有層的參數影響，如果每一層的數據分布不一致，將導致神經網路模型需要不斷學習新的分布，該變化會隨著層數越深而越大，模型訓練更為困難，因此加入 Batch Normalization 層，於每一層的輸入時進行常態化(Normalization)，使所有數據分布較為一致，有助於減緩梯度消失及加速模型收斂，避免因特徵之間對結果的影響差異，造成預測不準確。而 Dropout 層則是防止模型過擬合(Overfitting)，神經網路模型學習時，會讓各神經元的權重符合需要的特性，

不同的神經元組合後，可以分辨數據中的某項特徵，而每個神經元會依賴其他神經元的特徵，如果其相互之間過度依賴，就會造成過擬合現象。因此，假設每次學習時，隨機消除一部分神經元，使其斷開連接，其餘神經元就需要補上消失神經元的功能，整個網路模型將變成許多獨立網路，當模型對某個神經元的權重變化較不敏感時，即可增加神經網路模型之泛化能力，並且避免發生過擬合現象。透過 Batch Normalization 層與 Dropout 層的作用，可使神經網路模型訓練時更有效率，預測結果更為精確。

本項工作主要使用 Sentinel-1 雷達衛星影像，以多張雷達影像製成多時序雷達干涉圖，並以深度學習方式，在多時序雷達相位干涉圖中，辨別出可能是 PS 點的特徵位置。第一步為產生雷達差分干涉成果，匯入 StaMPS 產出傳統的 PSInSAR 成果，同時匯出 PS 點的位置與雷達相位干涉圖做為訓練資料，輸入 U-Net 進行深度學習訓練，最後會獲得 PS 點篩選模型，詳細方法見圖 4.1-5。

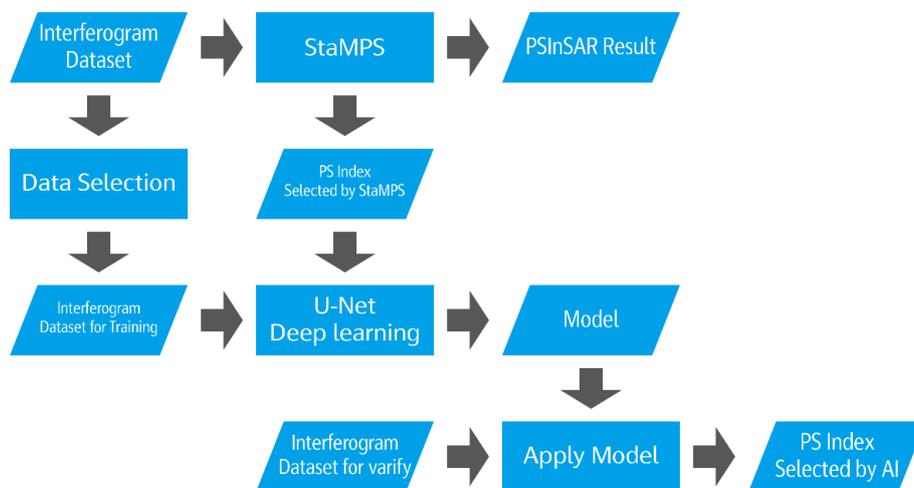


圖 4.1-5、方法流程圖

訓練資料集選取三年期的 Sentinel-1 雷達衛星影像，且平均每月一張以增加不同季節造成地表特徵的多元性，進行三年期的 PSInSAR 分析，其成果作為標籤，另外於 35 張差分干涉影像中平均選取 12 張干涉圖以做為代表訓練資料進行機器學習，獲得 PS 點篩選模型之後，再另從其他區域與時間段的差分干涉影像進行成果測試。成果可見圖 4.1-6，結果顯示由機器學習進行的 PS 點篩選成果與 StaMPS 篩選成果十分相似，可以推測機器學習方法應有掌握永久散射體之影像特徵，藉此篩選出擁有類似特徵的像素。

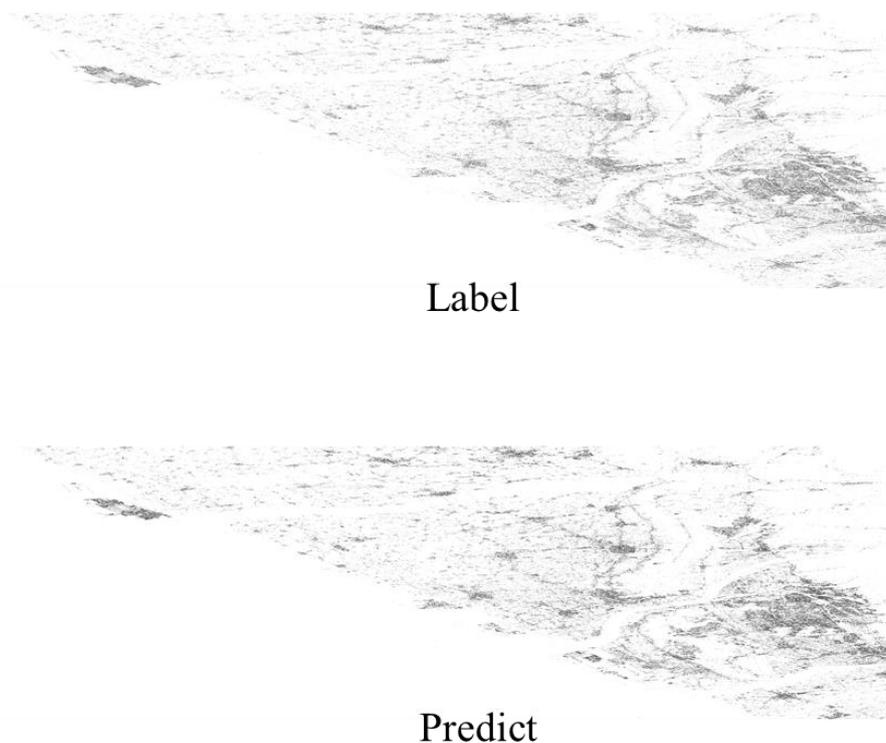


圖 4.1-6、由 AI 模型得到的 PS 點圖

對篩選出的永久散射體像素進行形變解算並評估精度，將 35 張差分干涉影像進行測試，圖 4.1-7 為使用 StaMPS 方法選點後所產生的之 PSInSAR 成果，圖 4.1-8 為從 35 張差分干涉影像內，依時間平均選取 12 張差分干涉

影像進行 AI 預測所產生的 PSInSAR 成果。從圖 4.1-7 與圖 4.1-8 可看出，兩者的點位分布非常相似，因此 AI 在 PS 點的選取上是合理的。

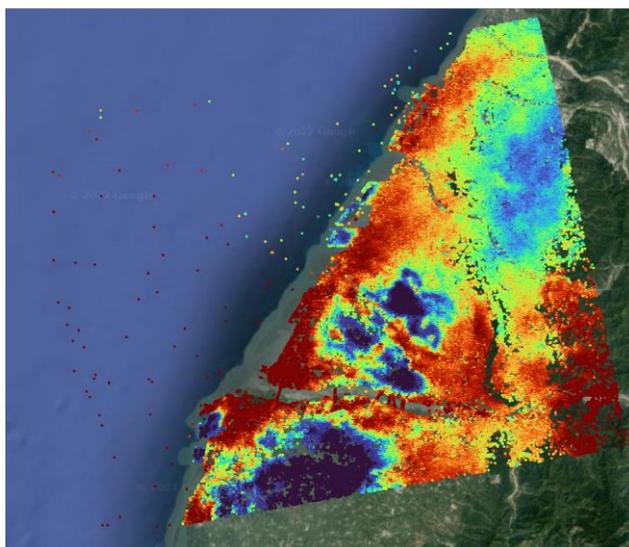


圖 4.1-7、StaMPS 選點後 PSInSAR 成果

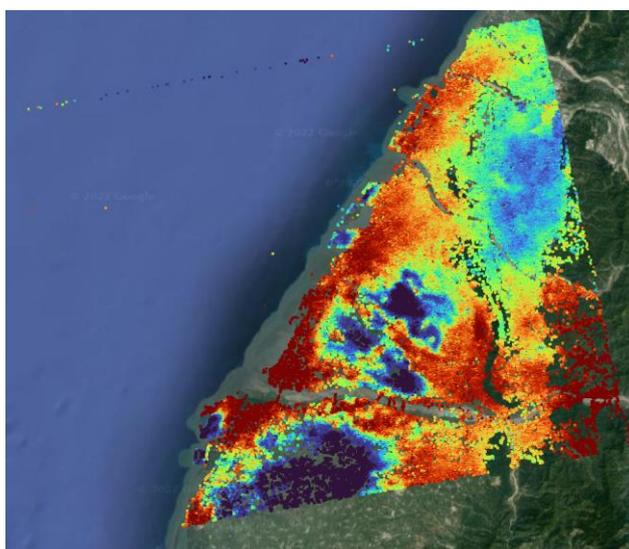


圖 4.1-8、AI 選點後 PSInSAR 成果

若將 AI 預測時所輸入的 12 張差分干涉影像改為使用 StaMPS 選點方法，成果如圖 4.1-9，PS 點數量與使用 35 張差分干涉影像相比，會大幅增加 PS 點數量。雖然 PS 點數量增加，但從圖 4.1-9 可看出此 PS 點的選取並不可

靠，甚至於海上還有大量 PS 點，而在使用相同資料的情況下，使用 AI 判定的 PS 點（圖 4.1-8）與圖 4.1-9 相比較，AI 所產生的 PS 點更加合理。

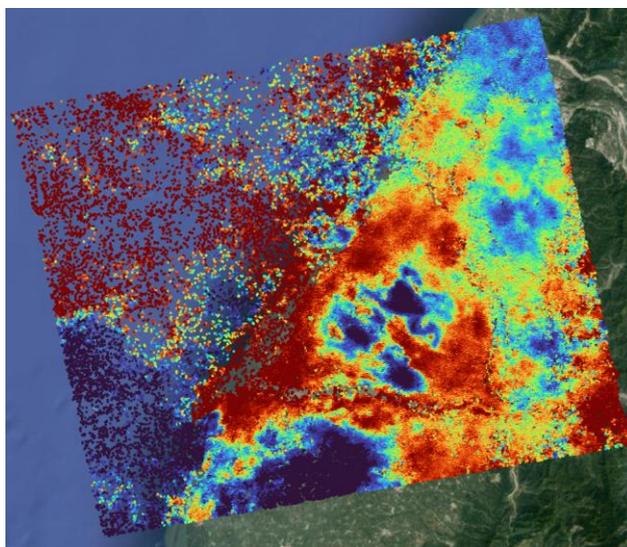


圖 4.1-9、StaMPS 選點後 PSInSAR(僅使用與 AI 輸入相同的差分干涉影像)

由於本計畫多個工作項目皆透過機器學習進行訓練，並提供精度評估之結果。因此，統整精度評估使用之相關內容與公式，以便後續內文參照，表 4.1-1 為精度評估指標代表意義，表 4.1-2 為精度評估指標對應之公式。

表 4.1-1、精度評估指標代表意義

英文	代表意義
Accuracy	準確率
Precision	精確率
Recall	召回率
F1-Score	F1 分數，精確率和召回率的加權平均
IoU (Intersection-over-Union)	兩個物件的重疊(overlap)/交集比例
TP (True Positive)	真陽性，如偵測為房屋，實際上為房屋
TN (True Negative)	真陰性，如偵測為非房屋，實際上為非房屋
FP (False Positive)	偽陽性，如偵測為房屋，實際上為非房屋
FN (False Negative)	偽陰性，如偵測為非房屋，實際上為房屋
Omission	漏授率

英文	代表意義
Commission	誤授率
CE (Commission Error)	漏授率誤差
OE (Omission Error)	誤授率誤差

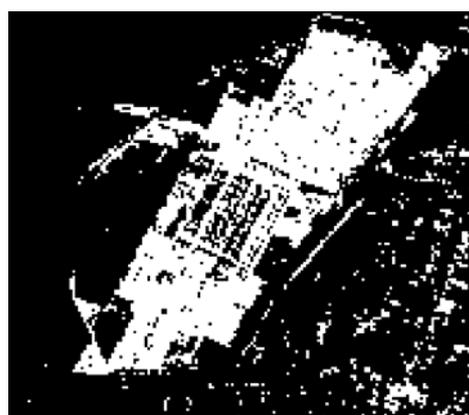
表 4.1-2、精度評估使用之公式

編號	精度評估名詞	參照公式
1.	Accuracy	$(TP+TN) / (TP+FP+FN+TN)$
2.	Precision	$TP / (TP+FP)$
3.	Recall	$TP / (TP+FN)$
4.	Omission	1-Recall
5.	Commission	1-Precision
6.	F1-Score	$2 / (1/Precision + 1/Recall)$
7.	IoU	$TP / (TP+FP+FN)$

基於原始 PSInSAR 成果作為參考地真資料對 AI 成果進行驗證，對於各類區域進行檢驗，檢測其 IoU 與 F1-Score 等，檢測前會先將 PS 的向量點資料轉化成解析度 50m 的網格資料，若該網格內存在 PS 點則判斷為真，若無則為假，如圖 4.1-10 所示。



(a) PS 向量點資料



(b) PS 網格資料

圖 4.1-10、驗證資料

對於各類區域，如都市、城鎮、鄉村、港灣與橋梁等區域個別進行檢驗，成果如圖 4.1-11 至圖 4.1-15 所示，其中藍色點代表原始 PSInSAR 方法的成果，其作為地真資料，而紫色點則代表 AI 分析後的成果，將兩種方法產生的 PS 網格化，檢測其 IoU 與 F1-Score 等數值。藉由成果可看出由 AI 所產生的 PS 點可大略覆蓋於原始 PS-InSAR 所產生的 PS 點上，精度上可有不錯的表現，其精度評估如表 4.1-3。

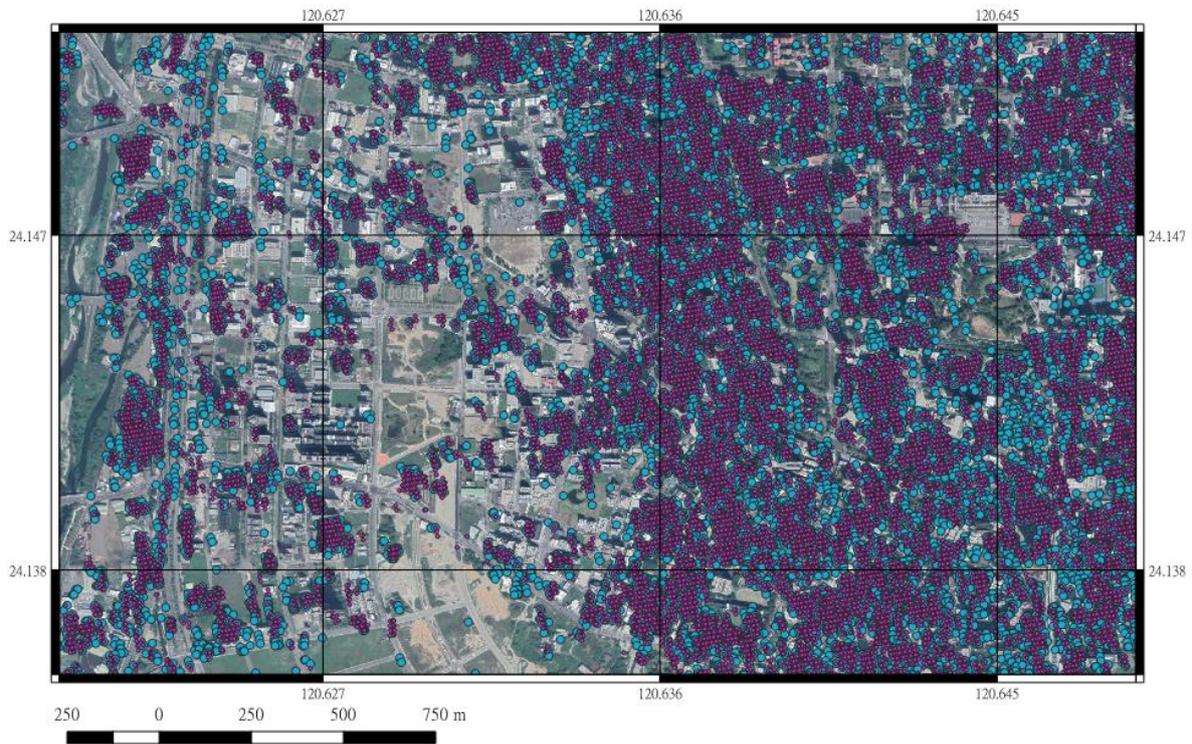


圖 4.1-11、都市區

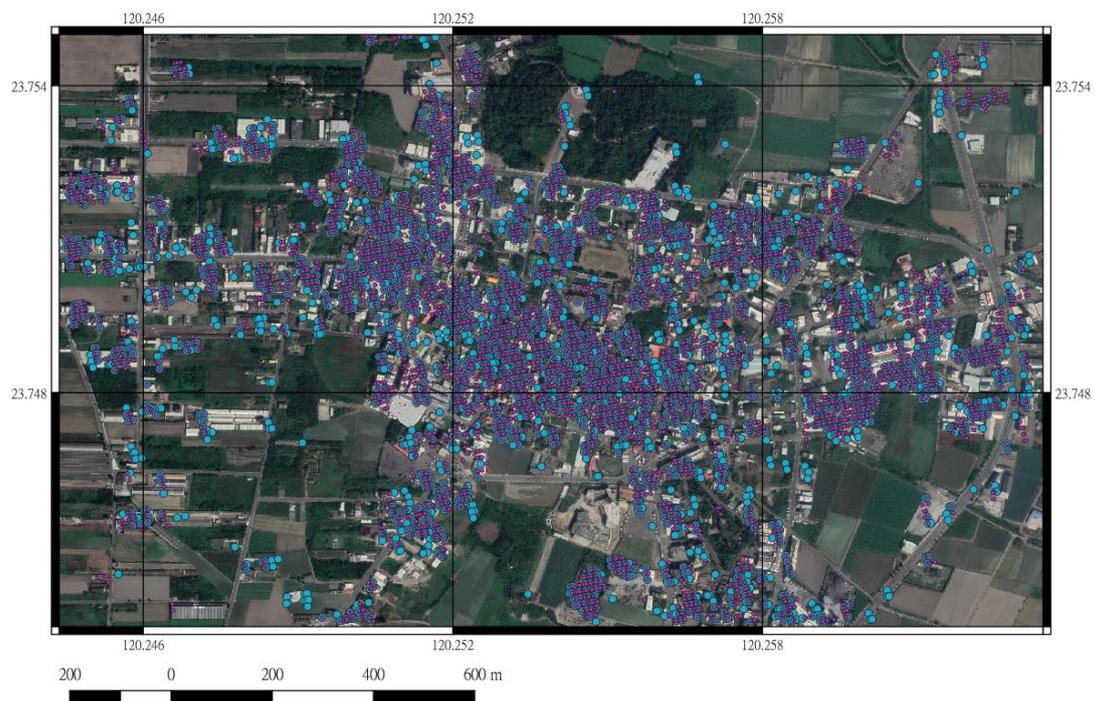


圖 4.1-12、城鎮區

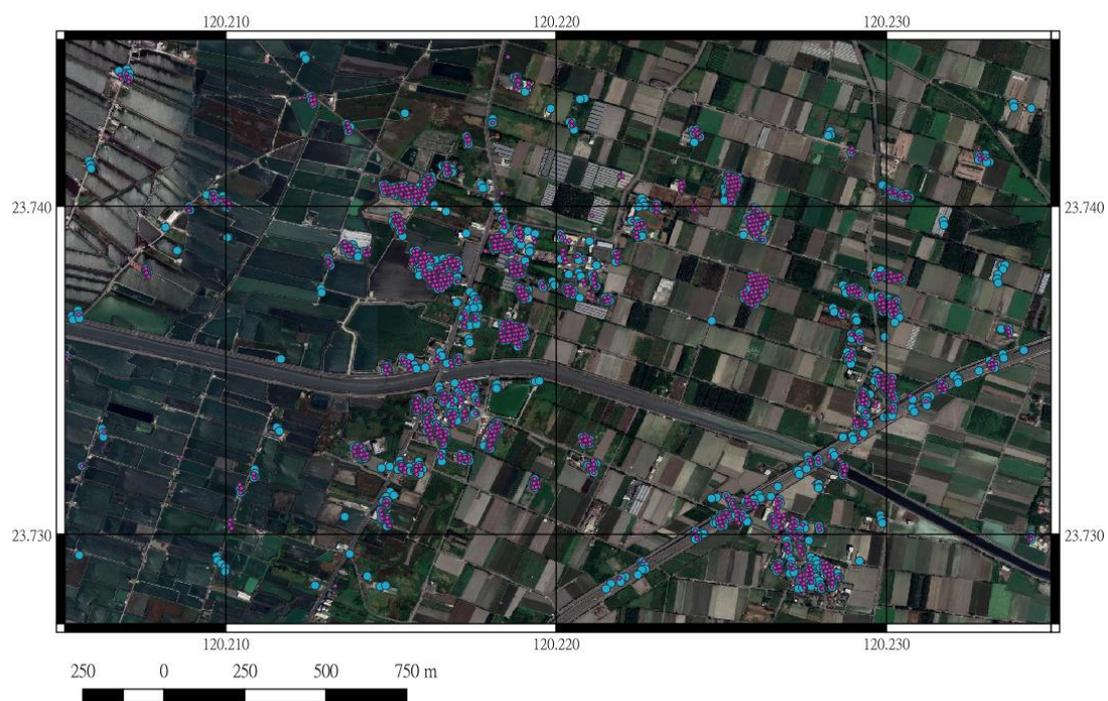


圖 4.1-13、鄉村區

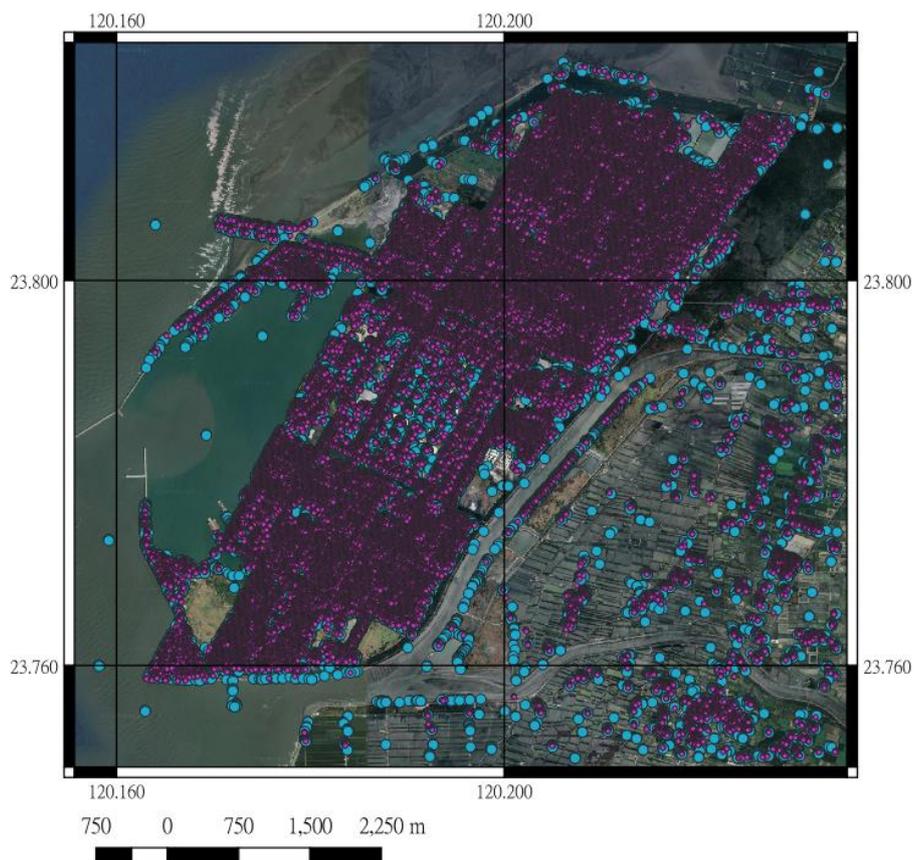


圖 4.1-14、港灣

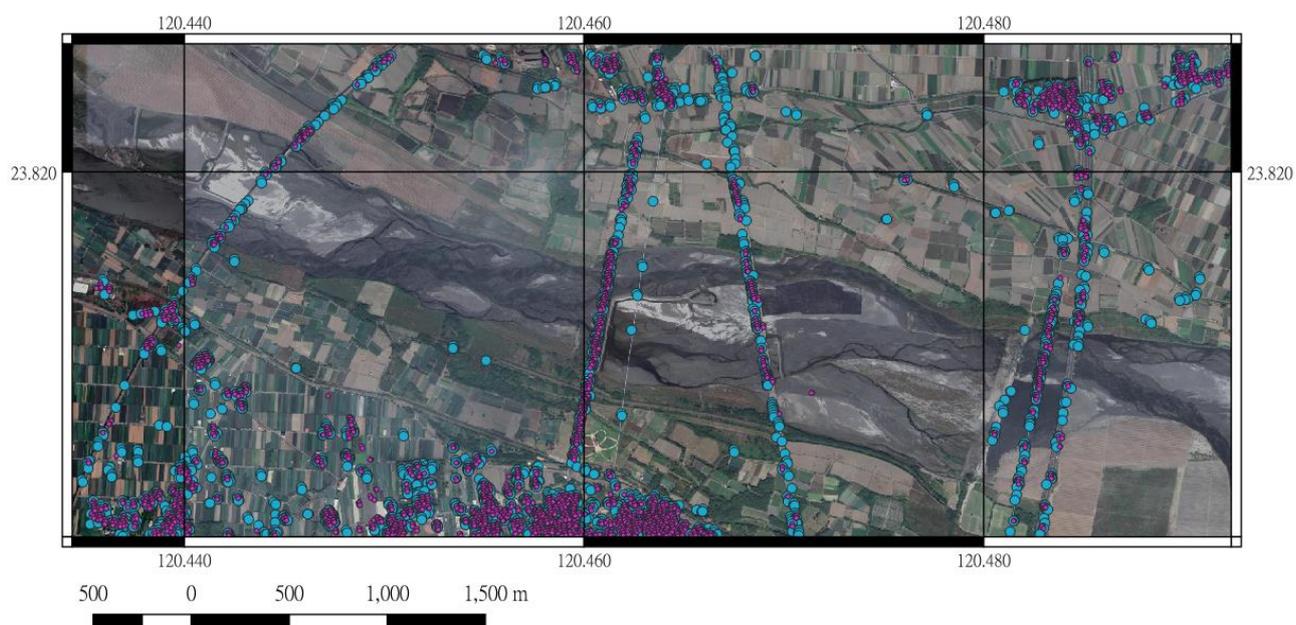


圖 4.1-15、橋梁

表 4.1-3、各類區域之精度評估

區域	Precision	F1-Score	IoU
都市區	0.93	0.92	0.85
城鎮區	0.94	0.91	0.83
鄉村區	0.89	0.78	0.64
港灣	0.94	0.9	0.82
橋梁	0.88	0.74	0.58

部分特殊區域 AI 無法檢測出 PS 點，如河道區域（圖 4.1-16）。大量由原始 PSInSAR 所產生的 PS 點覆蓋於河道上，而 AI 卻幾乎無法在此找出 PS 點。造成此情況的原因可能是因河道的季節性變化造成地形變化較不穩定。

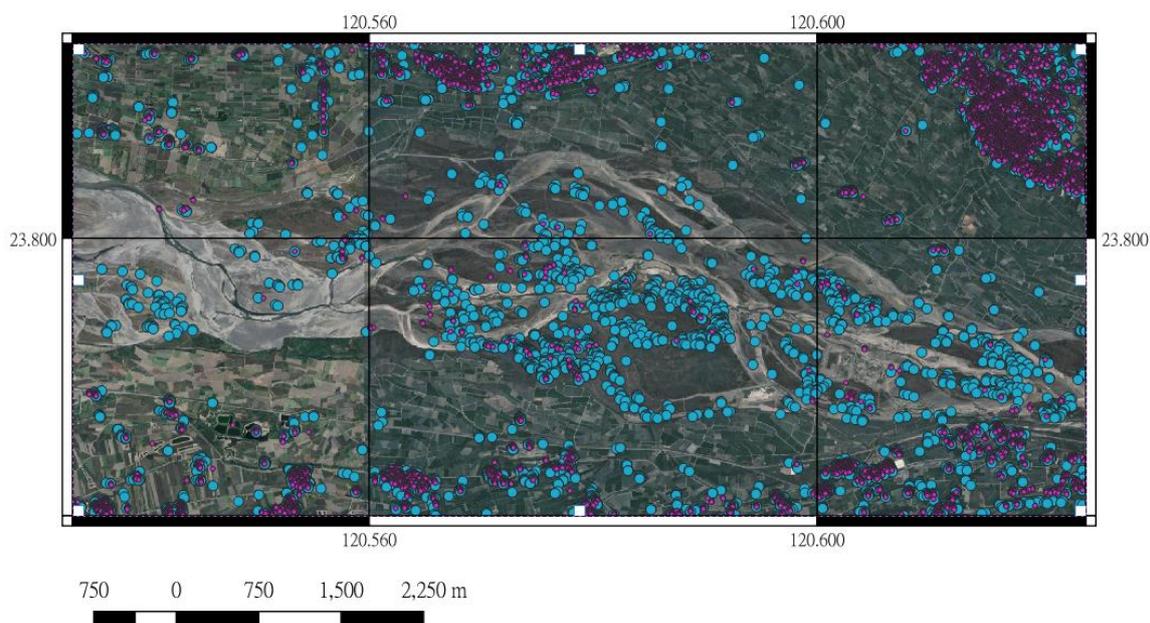


圖 4.1-16、河道區

使用 GNSS 資料檢測兩種方法所產生的差異，將蒐集此區域的 GNSS 資料，比對不同位置 GNSS 之間的相對變形，位置如圖 4.1-17 所示，計算

GNSS 站點 FUNY 與其他 GNSS 站點之間的相對變形。比較 StaMPS 選點方法與 AI 選點的地形相對變量的時間序列，如圖 4.1-18，左排為使用 StaMPS 方法，右排為使用本項工作之 AI 研究方法，兩者的 InSAR 相對變量變化幾乎一致，在同位置的 GNSS 與 InSAR 間的 RMSD 也相差約 1mm 以內，由 AI 所產生的 PS 點經解算後，與 StaMPS 產生的成果並無甚大差距。

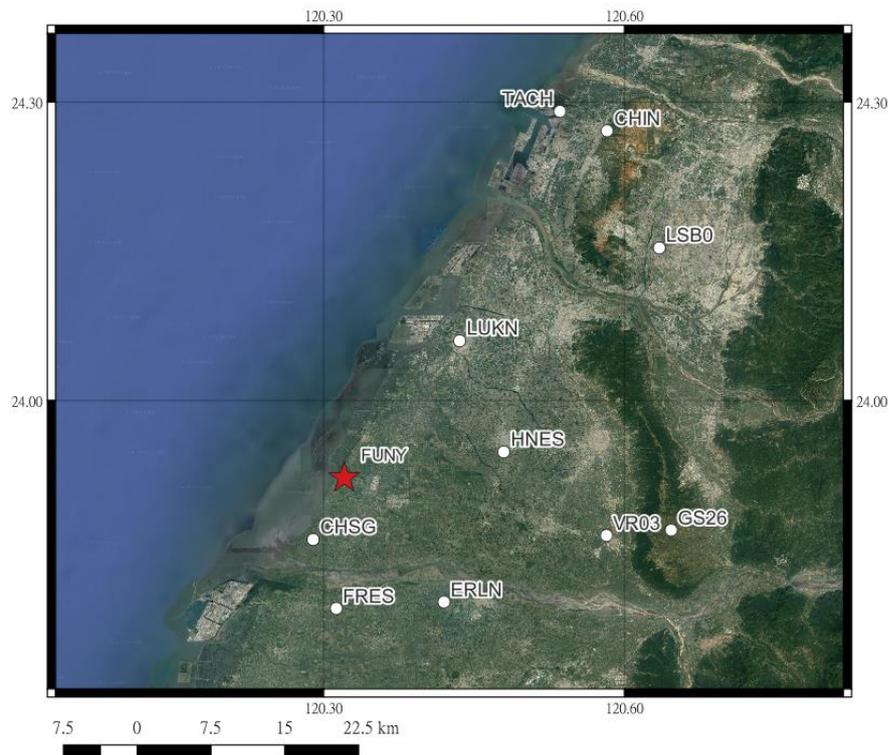
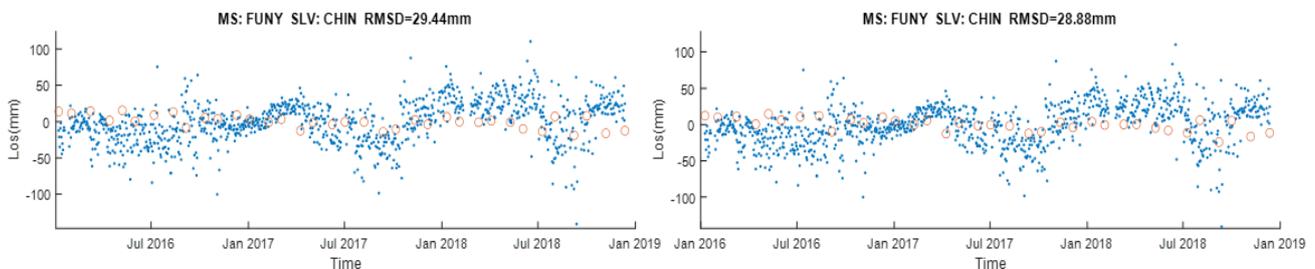
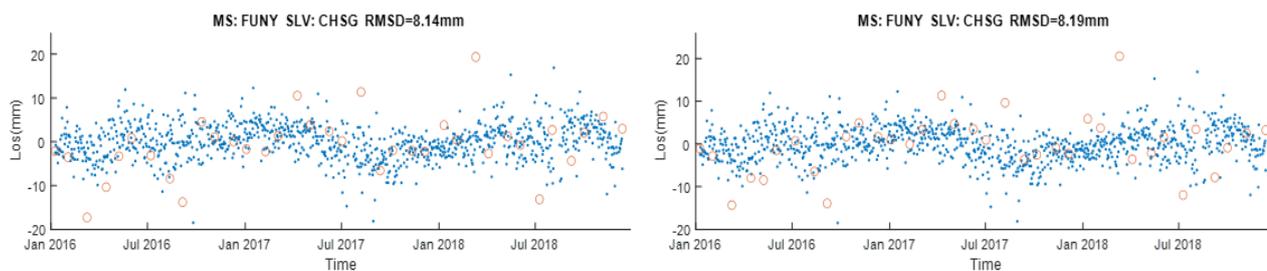


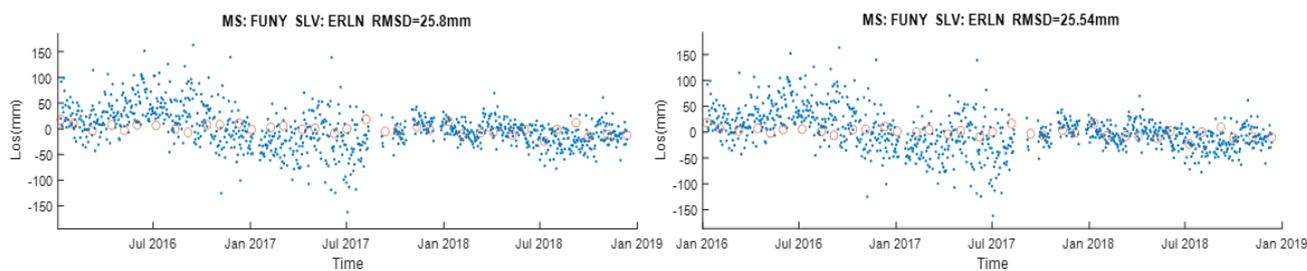
圖 4.1-17、GNSS 驗證站點



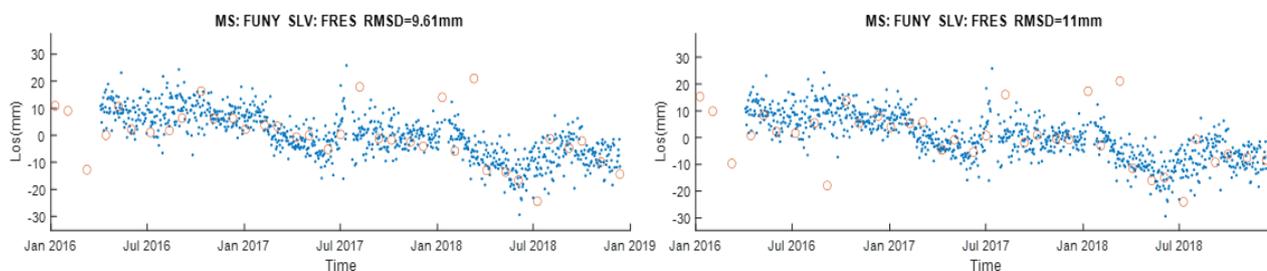
(a) 驗證站點-CHIN



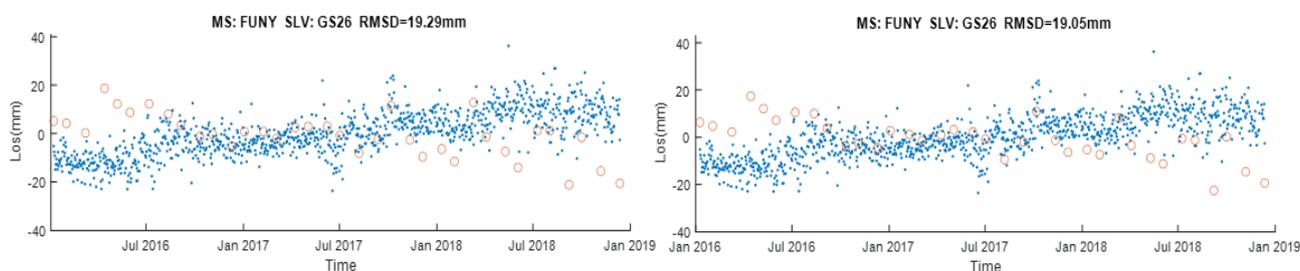
(b) 驗證站點-CHSG



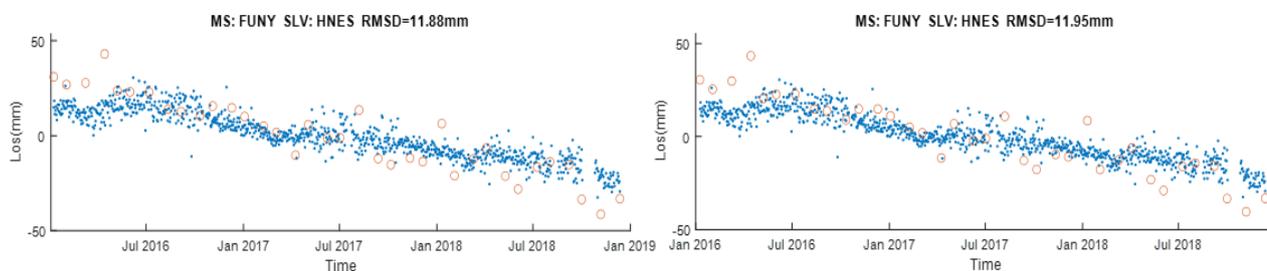
(c) 驗證站點-ERLN



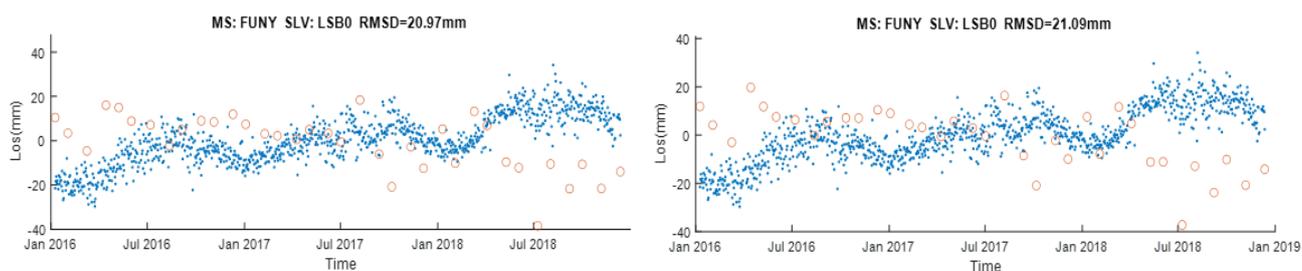
(d) 驗證站點-FRES



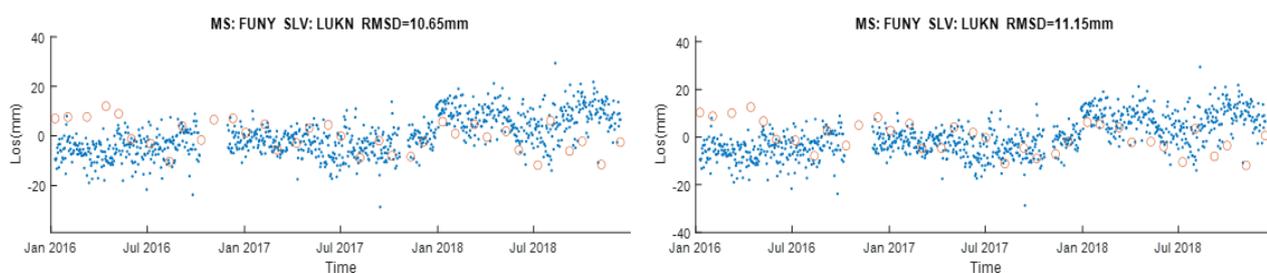
(e) 驗證站點-GS26



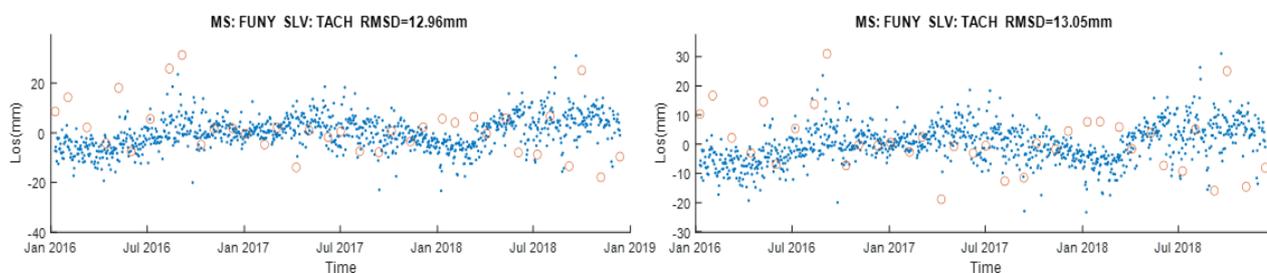
(f) 驗證站點-HNES



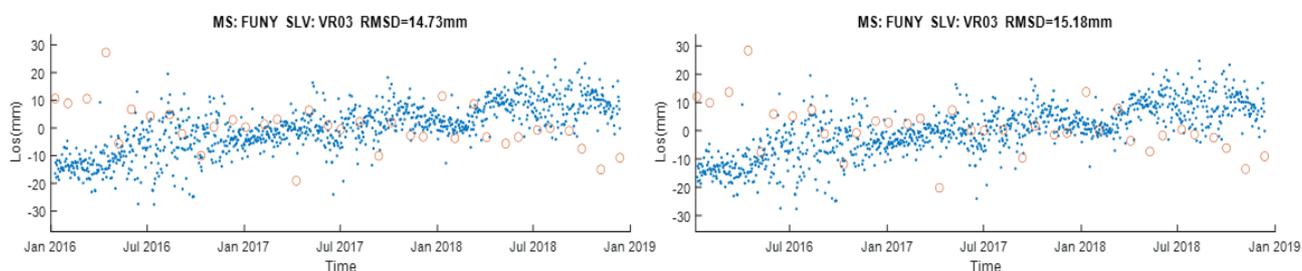
(g) 驗證站點-LSB0



(h) 驗證站點-KUKN



(i) 驗證站點-TACH



(j) 驗證站點-VR03

(左：StaMPS，右：AI)

圖 4.1-18、GNSS (藍點) 與 InSAR (紅圈) 時間序列

透過 AI 替換 StaMPS 的 PS 點選取方式，可省略最耗費時間之步驟，原本需 472.26 分鐘才能計算完成的區域，現依此方法僅需 116.39 分鐘即可

完成，大幅降低所需求的時間，並提高作業效率。

4.1.2 精進機器學習於高解析光學影像地表形變分析技術

現今光學衛星具靈活取像能力及高機動性，可於短時間內獲取同軌衛星立體像對，雖然所產製之數值地表模型精度及解析度，均不及航照或空載光達所產製之數值地表模型，但光學衛星可同時取得多光譜之光學衛星影像，並藉由多光譜影像資訊輔助判斷地表形變情況，且可在較低成本需求下取得多時期之數值地表模型，用以分析地表形變情況。

機器學習主要為利用大量資料，透過不同的訓練方式進行學習，最後透過學習好之模型提供形變分析成果。本項工作以三種影像來源進行模型訓練與形變預測，分別為(1)光學影像、(2)光學加雷達影像、(3) TerraSAR-X 影像，影像資訊如表 4.1-4。在機器學習部分，加入具備空間(CNN)與時間(LSTM)架構關連性的 ConvLSTM U-Net 演算（模型示意圖如圖 4.1-19），以及隨機森林(random forest)進行模型訓練。

表 4.1-4、影像資訊

影像來源	影像時間	影像解析度
光學影像	前、後期影像，2003 年至 2013 年	2.5 m
光學加雷達	前、後期影像，2003 年至 2011 年 7 月	光學影像 2.5 m，雷達影像 15m
TerraSAR-X	單時期影像，2013 年	約 1.5m

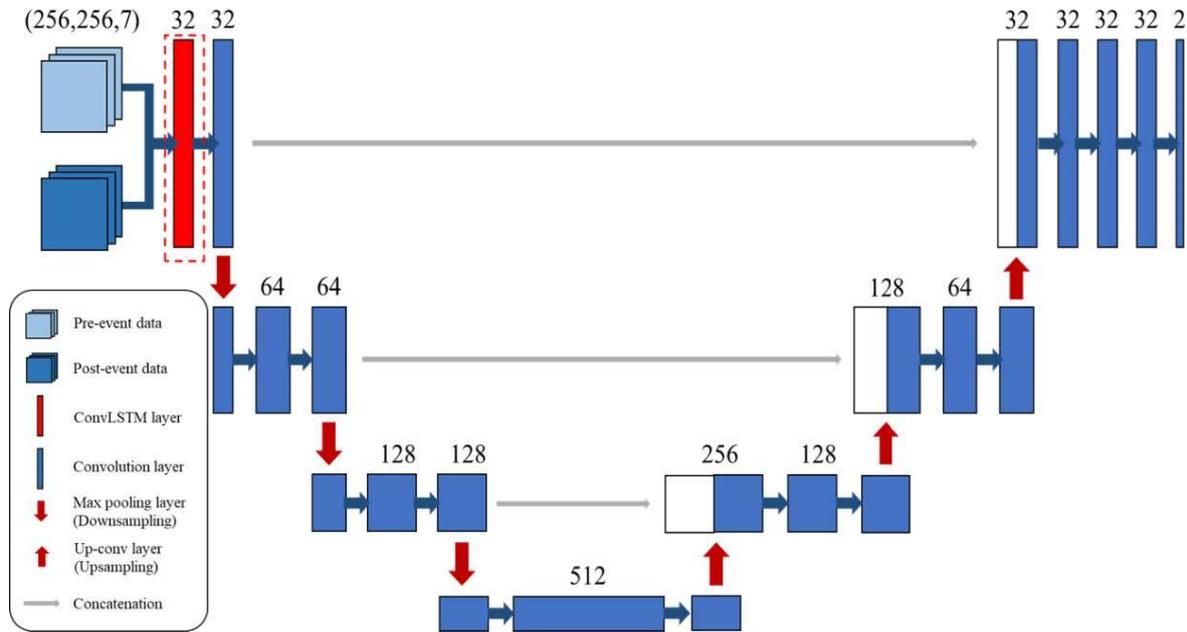


圖 4.1-19、ConvLSTM U-Net 模型示意圖

在光學影像與雷達影像部分，光學影像在訓練影像資訊為 SPOT-5 之全色態解析度為 2.5m、多光譜為 10m，在測試影像資訊為 SPOT-6 全色態解析度為 1.5m、多光譜為 6m，而雷達影像為 ERS2 與 Sentinel-1，在經投影後的解析度約為 15m。訓練模型包含光學影像的多光譜、全色態影像、經灰度共生矩陣所產生之紋理特徵影像與常態化差異植生指標(NDVI)等作為訓練影像，共 7 種特徵影像；在光學加雷達影像影像部分，使用上述之 7 種光學影像特徵外，另加入雷達影像 sigma0 波段作為訓練影像，每張影像皆包含 8 種特徵影像（如圖 4.1-20 所示）。圖 4.1-20(a)至圖 4.1-20(g)為分析光學影像之特徵影像、圖 4.1-20(h)為分析雷達影像之特徵影像。

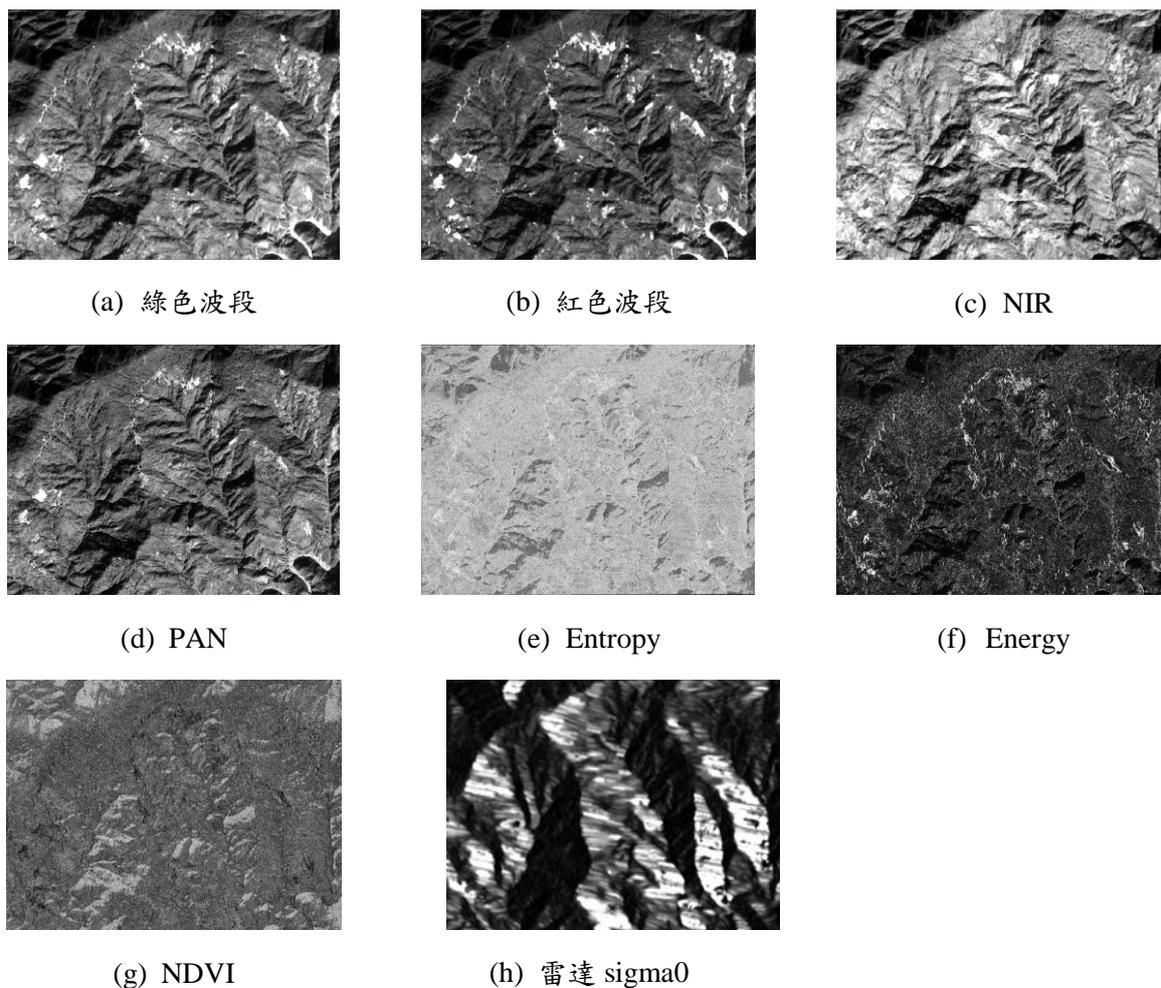


圖 4.1-20、訓練模型資料-8 種特徵影像

崩塌主要發生於坡度 $30^{\circ}\sim 60^{\circ}$ 之陡坡，考量地表形變與坡度與坡向有關，本項工作於地表形變分析作業時，加入數值地表模型資訊，使用不同時期之多光譜正射影像與坡度圖等資料作為訓練資料來源。透過 ConvLSTM U-Net 產製訓練模型，經由隨機森林進行分析，得到真正訓練好之模型與模型權重資料，模型訓練工作流程圖如圖 4.1-21 所示。

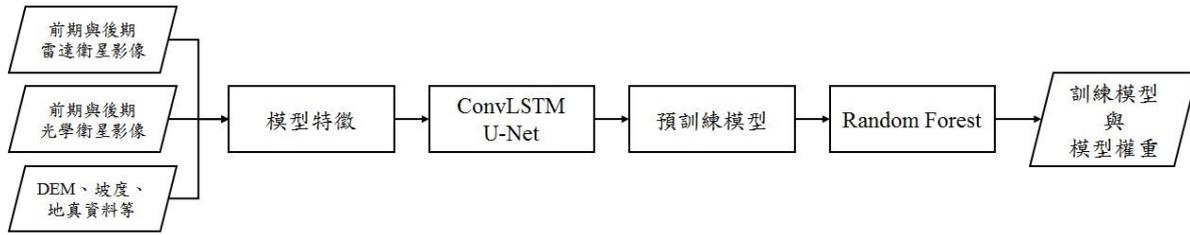


圖 4.1-21、模型訓練流程圖

本項工作在光學、光學加雷達部分，使用之影像資料可分為訓練資料與測試資料，所使用之標籤使用前後期光學影像進行比對，以人工方式圈選。影像區域皆為石門水庫集水區與荖濃河流域，區域位置如圖 4.1-22 所示。(1)影像訓練資料，影像格式為高解析光學影像(SPOT-5)與雷達衛星影像(ERS2)。光學影像資料時間為 2003 年至 2013 年之間，雷達衛星影像資料時間為 2003 年至 2011 年 7 月之間（2011 年 7 月停止服務）。因此產製 2 組訓練模型資料，一組為純光學影像訓練模型，一組為光學與雷達影像訓練模型，在純光學影像所訓練之模型使用的資料組數會較多。(2)影像測試資料，影像格式為高解析光學影像(SPOT-6)與雷達衛星影像(Sentinel-1)，光學與雷達影像時間為 2015 年至 2018 年。圖 4.1-23 為使用光學影像及光學與雷達影像 2 種訓練模型，針對影像測試資料進行預測之成果案例。圖 4.1-23(a)與圖 4.1-23(b)為使用之前後期光學影像（全色態），圖 4.1-23(c)與圖 4.1-23(d)為使用之前後期雷達影像(sigma0)，圖 4.1-23(e)為地真資料，圖 4.1-23(f)為使用光學影像訓練模型之預測成果，圖 4.1-23(g)為使用光學與雷達影像訓練模型之預測成果，圖 4.1-24 為另一組預測成果案例。

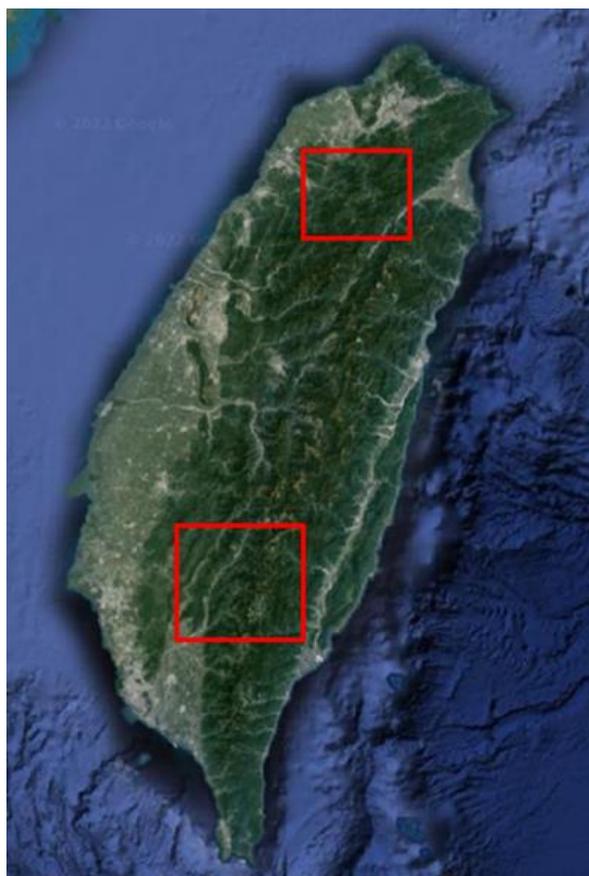
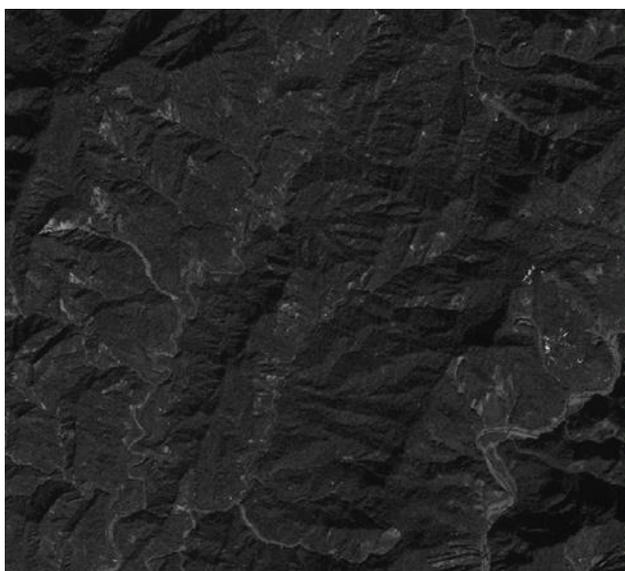
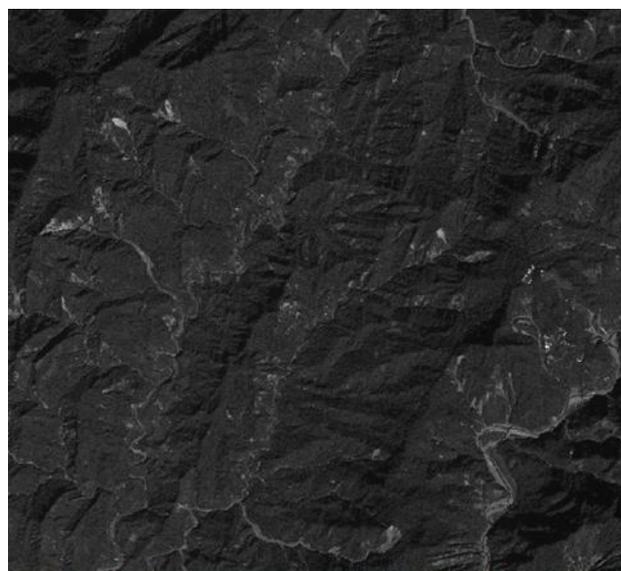


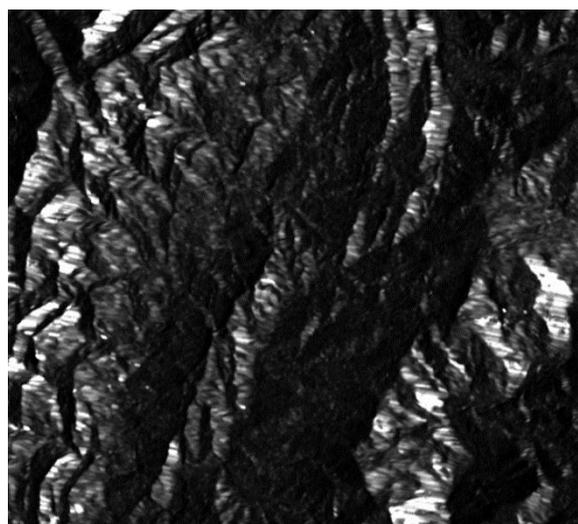
圖 4.1-22、訓練影像區域



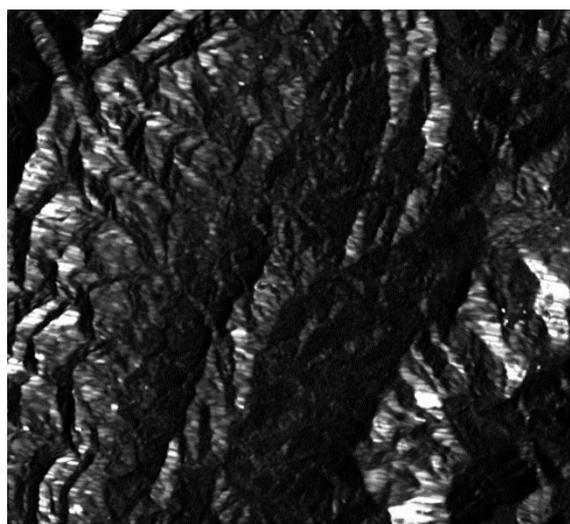
(a) 前期光學影像 (全色態)



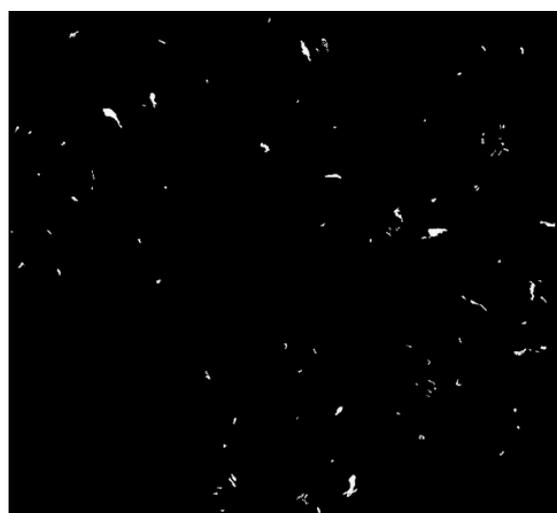
(b) 後期光學影像 (全色態)



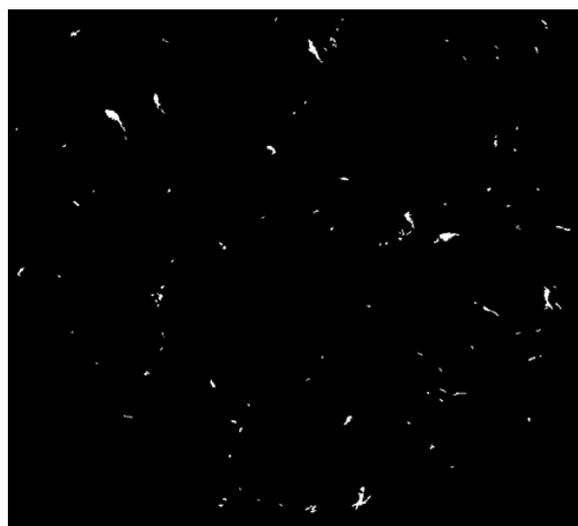
(c) 前期雷達影像(sigma0)



(d) 後期雷達影像(sigma0)



(e) 地真資料



(f) 預測成果 (僅光學)



(g) 預測成果 (光學與雷達)

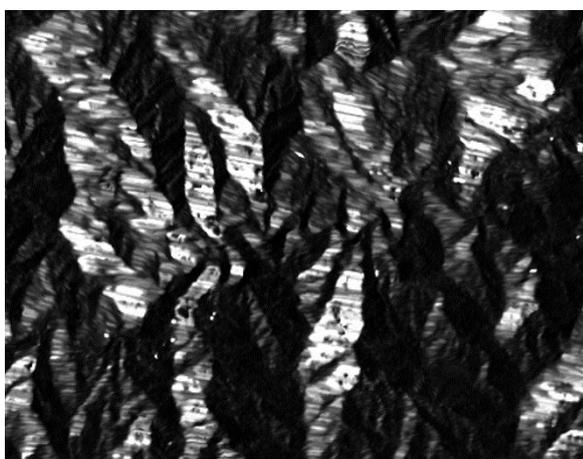
圖 4.1-23、測試影像與預測成果-案例 1



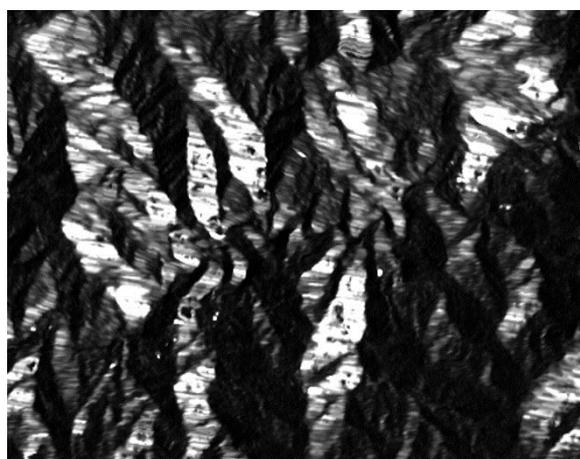
(a) 前期光學影像 (全色態)



(b) 後期光學影像 (全色態)



(c) 前期雷達影像(sigma0)



(d) 後期雷達影像(sigma0)



(e) 地真資料



(f) 預測成果 (僅光學)



(g) 預測成果 (光學與雷達)

圖 4.1-24、測試影像與預測成果-案例 2

在圖 4.1-23 (e)至圖 4.1-23 (g)與圖 4.1-24(e)至圖 4.1-24(g)中，兩組訓練模型大致上可找出較大之崩塌區域，證明此方法在變遷分析上是可行的。表 4.1-5 與表 4.1-6 為使用兩組訓練模型於此區域預測成果之精度評估（對應圖 4.1-23 與圖 4.1-24 之案例 1 與案例 2），在僅使用光學影像進行訓練之預測成果是優於光學加雷達影像預測成果雷達影像。加入雷達影像進行訓練無法取得較好之原因是雷達影像在空間上之解析度過低，與光學影像在解析度上相差過大，加上雷達影像於山區會有前坡縮短、疊置等問題，經投影後會產生幾何扭曲，在影像辨識辨識較不易。

表 4.1-5、預測成果精度評估-案例 1

訓練模型-影像來源	Precision	F1-Score	IoU
光學	0.69	0.66	0.49
光學與雷達	0.64	0.55	0.38

表 4.1-6、預測成果精度評估-案例 2

訓練模型-影像來源	Precision	F1-Score	IoU
光學	0.71	0.67	0.5
光學與雷達	0.87	0.53	0.36

在 TerraSAR-X 影像部分，使用單時期影像、解析度約 1.5m 高解析合成孔徑雷達影像，使用其 HH 與 HV 偏極作為紋理進行訓練與崩塌區域預測，影像區域如圖 4.1-25 所示，藍色區域為訓練影像區域，紅色區域為測試區域。在建置訓練資料時，由於雷達影像投影後會產生幾何扭曲，較難透過人工辨識、圈選出崩塌區域，故先從光學影像上圈出訓練影像標籤，再於雷達影像上相同位置處裁出影像（如圖 4.1-26 所示）進行訓練。圖 4.1-27 為預測成果，將預測的影像與光學影像進行比對，可看出雖然有部分崩塌區域可以辨識出來，但成果中仍有許多誤判區域，造成雷達影像紋理無法有效辨識。

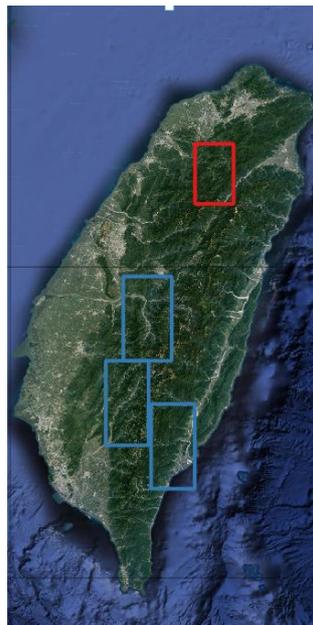


圖 4.1-25、訓練影像區域

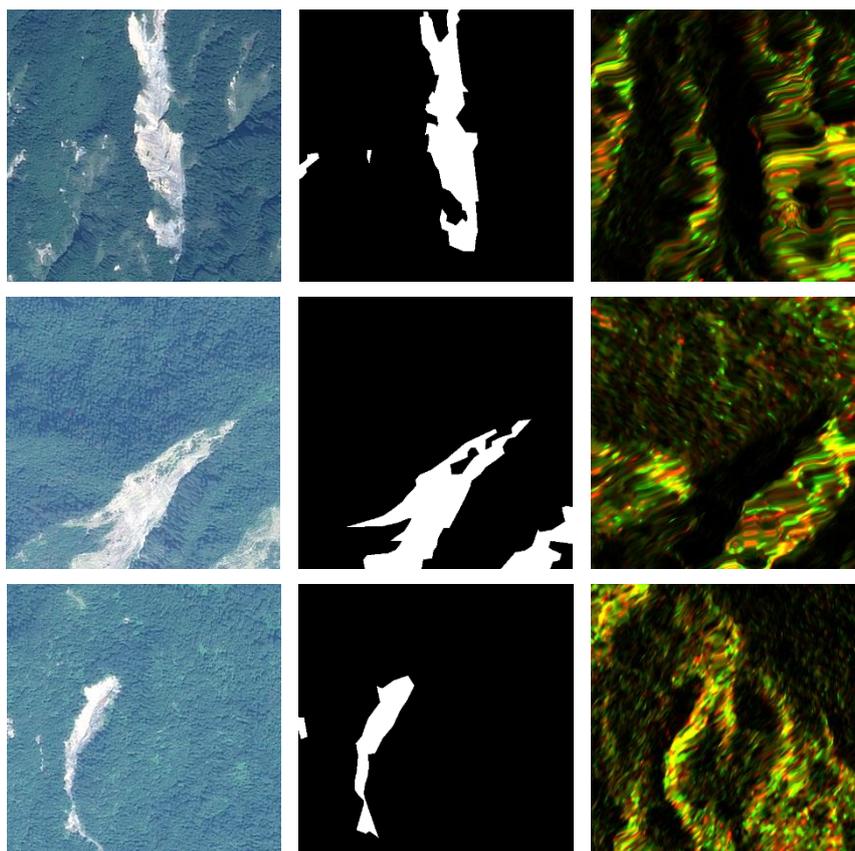


圖 4.1-26、訓練資料（左：光學影像、中：訓練標籤、右：雷達影像）

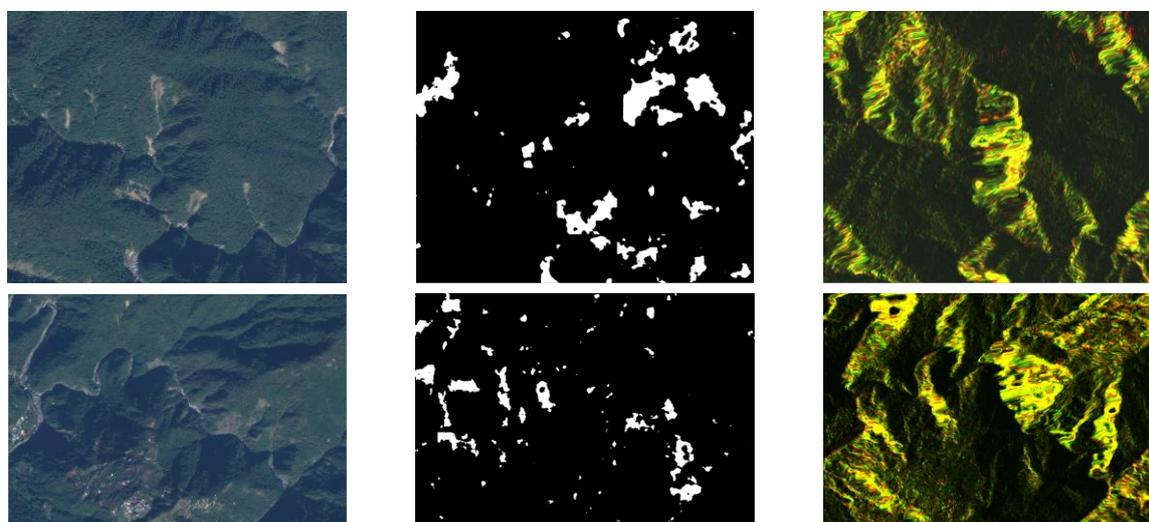


圖 4.1-27、測試成果（左：光學影像、中：預測影像、右：雷達影像）

在本項工作中，使用之 TerraSAR-X 影像具有高解析度的特性，但 TerraSAR-X 影像價格高昂，無法如光學影像可以針對特定事件區域，並蒐

集到該事件之前、後期影像，因此在僅使用單時期的紋理影像進行訓練情況下，較難有效、正確的預測崩塌區域，但是，在天候不佳的情況下，雷達影像卻有優於光學影像之品質。因此，若是在影像資訊充足，且不考慮影像成本情況下，使用多時期之雷達影像(如 TerraSAR-X)進行模型訓練，並進行地表形變區域預測，仍有值得研究之空間。表 4.1-7 為統計使用三種來源影像進行模型訓練，所產製之訓練影像資訊。

表 4.1-7、訓練影像資訊

影像來源	訓練模型資訊 (影像像素為 256x256)
光學影像	共 5100 組訓練影像，每組訓練影像資料有 7 種特徵影像資訊
光學加雷達	共 3600 組訓練影像，每組訓練影像資料有 8 種特徵影像資訊
TerraSAR-X	共 500 組訓練影像，每組訓練影像資料有 2 種特徵影像資訊

4.1.3 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取

隨著衛星影像空間解析力的大幅提升，以及三維立體測繪與電腦視覺技術的演進，以高解析衛星影像透過立體測繪以產製三維點雲得以逐步實現。這些三維點雲資料可進一步加工成為數值地表與地形模型，甚至針對建物等特定目標產製三維物件模型。除了地形模型外，房屋模型以及道路模型為三維空間資訊系統中重要的元素，實務上已有相當多的應用，例如：國防、都市計劃、防救災應用、汽車導航、房地產、觀光、網路遊戲、古蹟等。如同其他圖資，三維物件之建置可能是全區域的新測或是針對變遷區域之修測。無論是新測或是修測，偵測該物件區域都是一關鍵步驟。以影像偵測房屋或道路區域，傳統上常用的資訊可概略分為光譜及形狀資訊。

本項工作使用衛星立體像對立體重建技術，即自動匹配產製之三維點雲資訊，配合光譜所提供的特徵，開發機器學習(Machine Learning)演算法等人工智慧(Artificial Intelligence, AI)技術進行影像分析，以萃取衛星影像上房屋與道路物件的輪廓，並將所產製之三維點雲依物件分群，以利未來之三維模型建置、變遷偵測與更新等工作。

延續前期(109、110)計畫成果，測試區域位於新竹。前期計畫成果分別使用 109 年度所測試超高解析度 Pleiades 衛星之三重疊立體像對與 110 年度所使用之 16 張異軌 SPOT-6/7 衛星影像資料進行比較與分析。工作項目包括三維點雲建置、地形重建、機器學習模型（房屋與道路）建立、影像目標區（房屋與道路）分類、與目標輪廓處理。其中，三維點雲建置與地形重建成果為前期（109、110 年）計畫成果。本次期末報告完成房屋區域與道路區域機器學習模型建立與分類，並針對偵測成果進行精度評估。因台灣房屋輪廓大多數屬規律及方正之多邊形，房屋區域偵測成果額外利用形態學與輪廓正規化等處理萃取房屋之輪廓線，並去除過小或不屬於房屋的多餘區域，以利未來三維模塑、變遷更新等作業。處理流程先依據房屋頂點位置去除過短的邊緣，再判斷相鄰邊緣之夾角，門檻內之夾角調整成 90 度或是 180 度使房屋邊緣正規；約化步驟則判斷房屋多邊形許凸出或凹陷區域且其面積小於門檻值，將其填滿或去除，以簡化房屋多邊形的複雜度。而根據前期（109、110 年）所產製之三維點雲經驗，本項工作可建置滿足

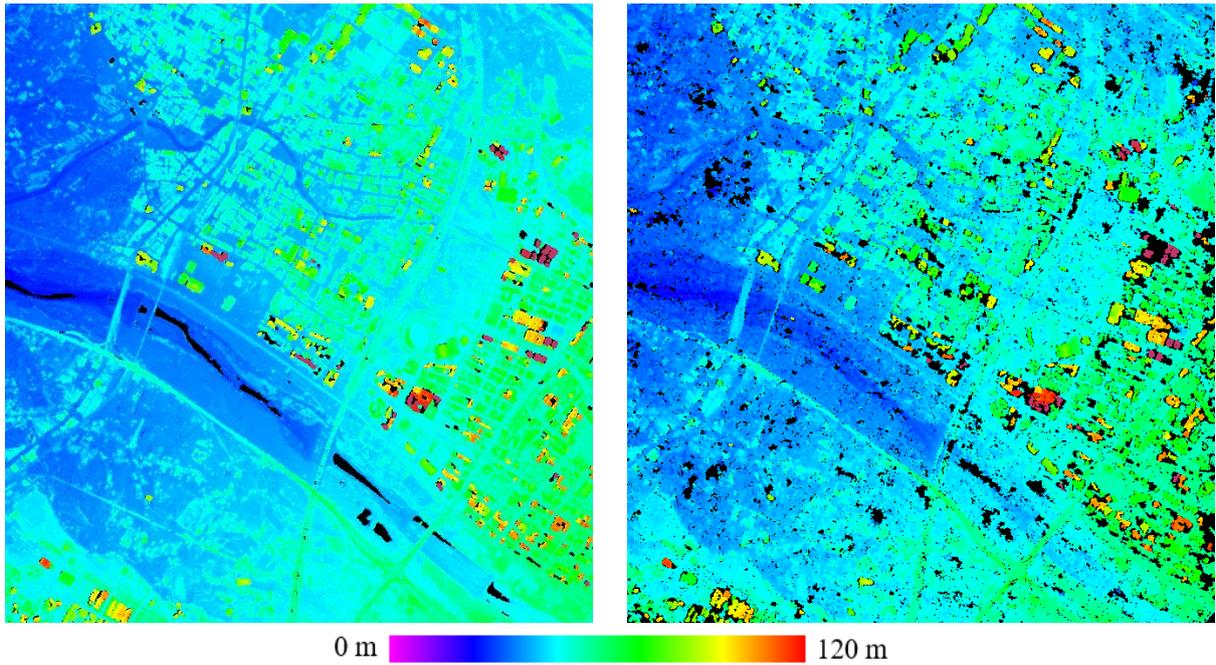
OGC CityGML LOD-1 規範的三維模型。以下說明本項工作成果。

(1) 資料及研究區域

測試區位於新竹，測試資料有兩組，分別為 3 張 Pleiades 同軌立體衛星影像與 16 張 SPOT-6/7 多重疊影像。兩組測試例影像資訊如表 4.1-8 所示。影像匹配使用全色態影像，其三維點雲與數值地表模型重建成果(地面解析度分別為 1.5m 與 5.0m)如圖 4.1-28 與圖 4.1-29 所示。三維點雲成果圖中黑色區域，如河道中央，表示無匹配成功點。從數值地表模型重建成果圖可明顯看出雖然 Pleiades 只使用三張影像，影像張數遠低於測試例二（16 張 SPOT-6/7 影像），但因為其超高解析度，所建置出之地表模型細緻度優於使用 SPOT-6/7 影像之成果。後續機器學習演算法則挑選匹配影像中之一張影像進行融合與正射改正後進行目標區分類，兩測試例之融合正射影像如圖 4.1-30 所示。

表 4.1-8、測試例影像資訊

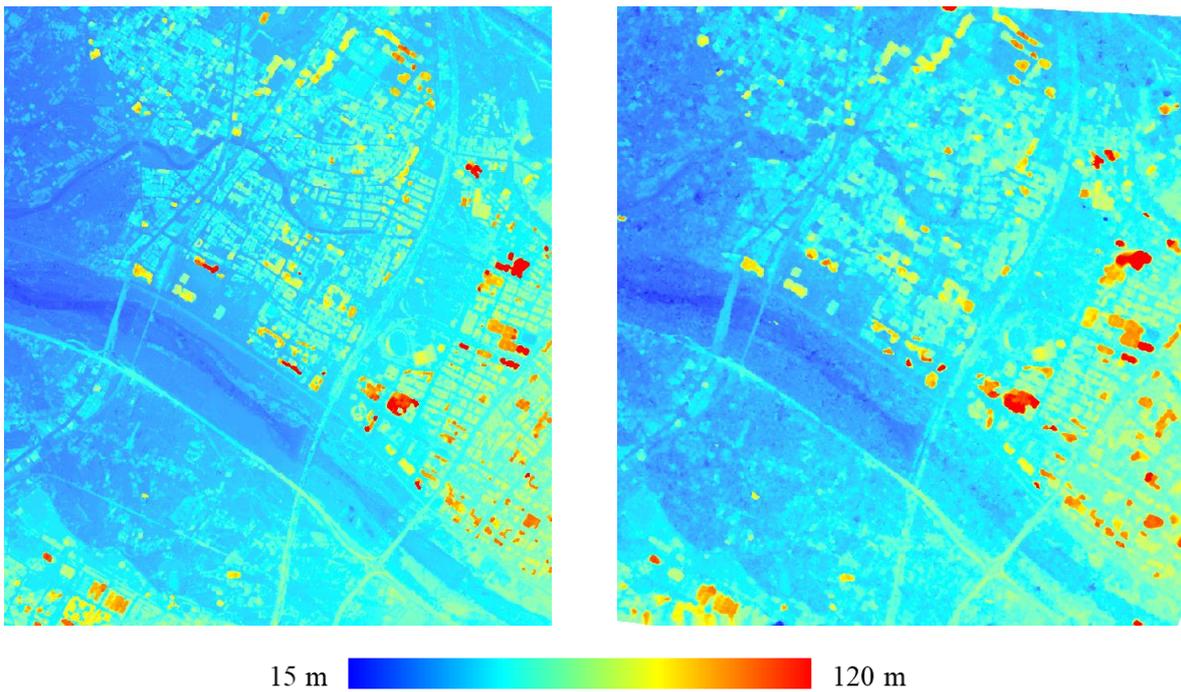
測試例	衛星	影像張數	影像日期	解析度（近地點） 全色態/多光譜
一	Pleiades	3	2019/08/17	0.7m / 2.8m
二	SPOT-6/7	16	2019/03/12~2020/01/09	1.5m / 6m



(a) 測試例一：Pleiades

(b) 測試例二：SPOT-6/7

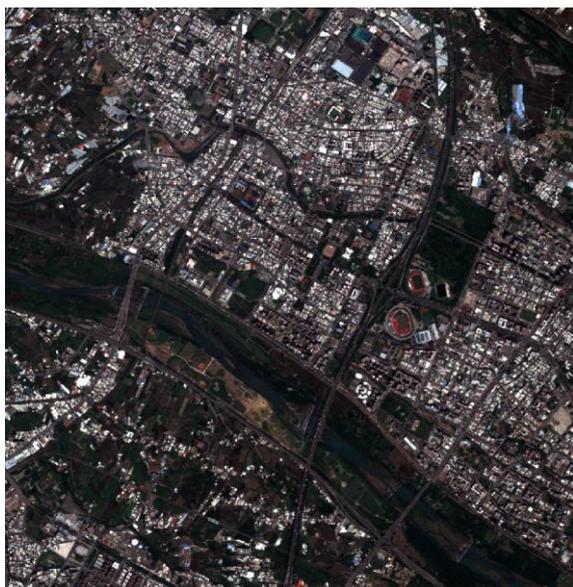
圖 4.1-28、三維點雲成果



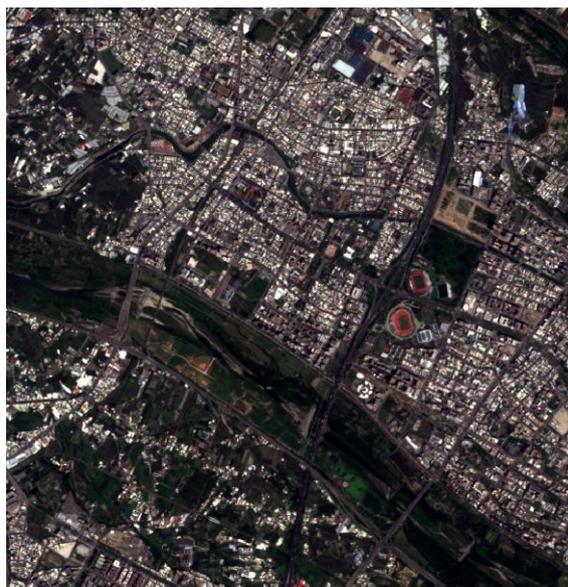
(a) 測試例一：Pleiades

(b) 測試例二：SPOT-6/7

圖 4.1-29、數值地表模型重建成果



(a) 測試例一：Pleiades 2019/08/17



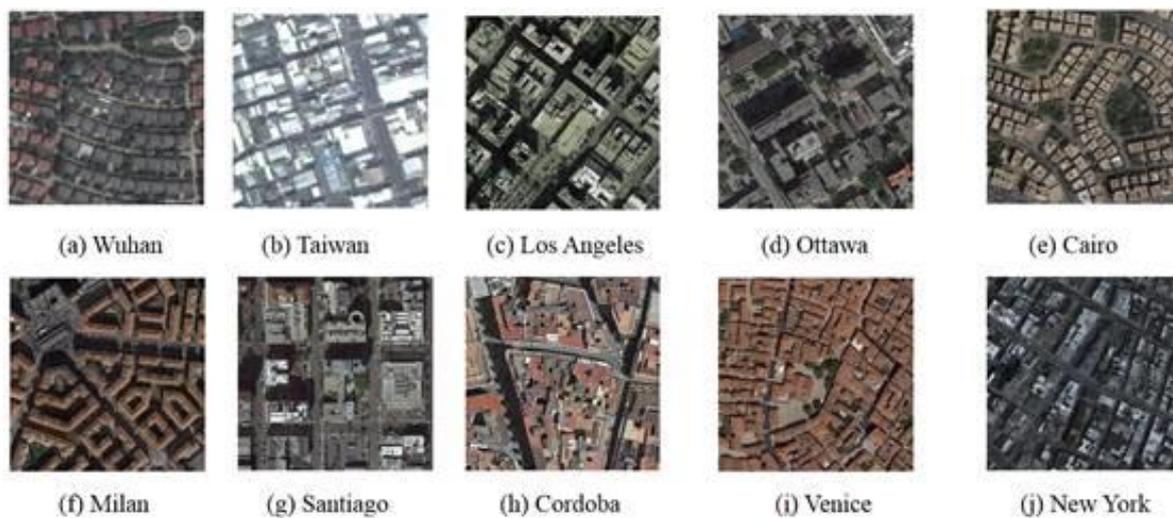
(b) 測試例二：SPOT-6 2020/03/26

圖 4.1-30、融合正射影像

(2) 房屋區機器學習演算法建立與分類成果

本項工作使用之機器學習演算法為利用國際上針對建物所提供的標竿資料集建置神經網路模型 U-Net。國際訓練集資料大多針對歐、美地區的建物，但也有少數包含亞洲（甚至臺灣地區）的城市。經篩選本項工作使用之超高解析衛星影像的資料集 WHU Building (Satellite dataset I) 這組資料集，其訓練資料集影像解析度從 0.3 公尺至 2.5 公尺，可同時滿足本項工作兩組不同影像解析度（0.7 公尺與 1.5 公尺）之測試。此外，亦加入少數臺灣地區 Pleiades 多光譜影像並以人工圈選房屋區作為標示，利用遷移式學習訓練增加泛用性。圖 4.1-31 為部分訓練資料。訓練模型時為輸入影像大小為 256x256 像元，本項工作利用兩萬筆訓練資料建置 U-Net 模型，其模型架構如圖 4.1-32 所示。其訓練過程之準確率(Accuracy)及損失率(Loss)如圖

4.1-33 所示。由圖 4.1-33 可看出訓練完成後之模型已收斂。



(a) WHU Building 訓練集



(b) 臺灣房屋影像

圖 4.1-31、房屋偵測 AI 訓練資料集

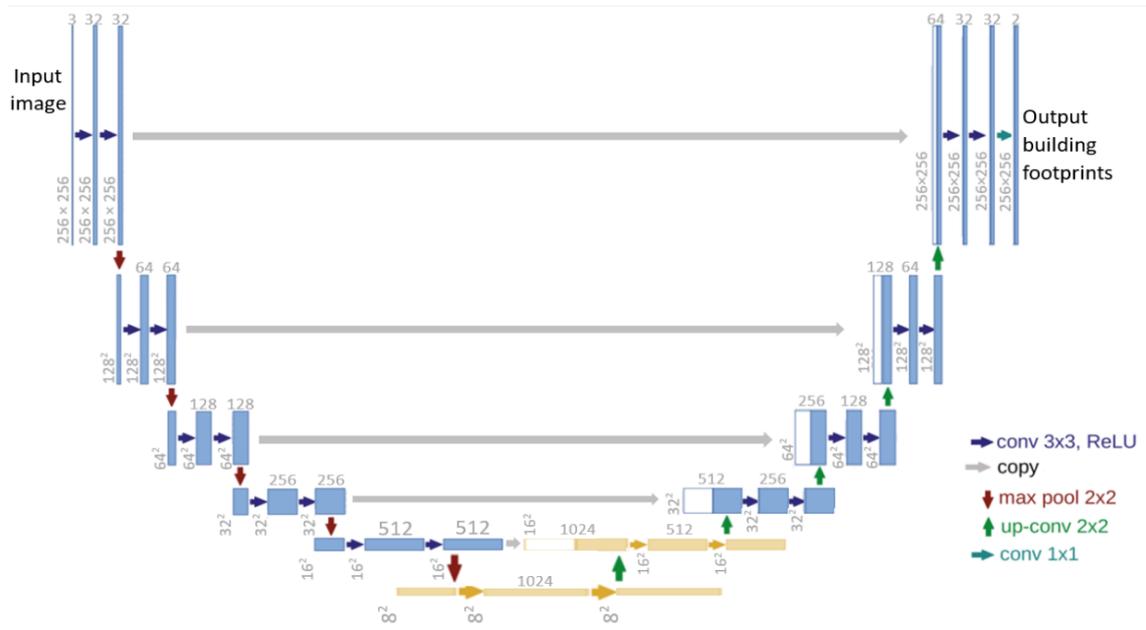


圖 4.1-32、機器學習模式架構示意圖

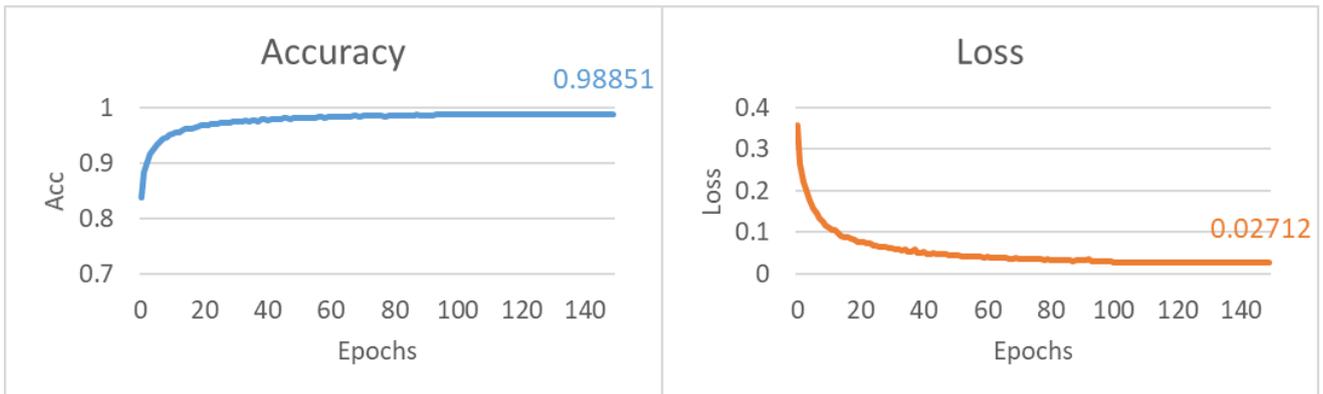


圖 4.1-33、訓練過程之準確率及損失率

透過機器學習模式分類出之房屋區成果如圖 4.1-34 所示，圖中黃色區塊顯示分類出之房屋區域。從成果可明顯看出，Pleiades 衛星影像因空間解析度較高，測試例一分類房屋區域成果較為細緻。測試例二利用 SPOT-6 影像所分類出之房屋區相較起來，其分出之房屋區域比較傾向以街廓來分區

之房屋區域，狹小之防火巷與較鄰近之棟距的房屋容易被分成一整塊房屋區。若要以偵測之房屋區來重建房屋模型，本項工作提出之方法利用 Pleiades 衛星影像所萃取之房屋區域較為適當，故以下僅針對 Pleiades 衛星影像萃取之成果進行精度評估與房屋輪廓正規化與約化處理。



(a) 測試例一：Pleiades

(b) 測試例二：SPOT-6

圖 4.1-34、機器學習模型分類房屋區成果

為評估偵測房屋區成果，本項工作挑選檢核區域，以人工辨識 Pleiades 影像圈選房屋區與非房屋區，並與分類成果逐像元比對。檢核區與人工圈選房屋區如圖 4.1-35 所示，評估統計成果如表 4.1-9。由套疊成果圖可發現遺漏的房屋是具比較深色或是接近道路顏色之屋頂，統計像元數，整體精度為 82.80%；成果誤授率較低，約有 5.5% 的誤授；漏授率則較高，超過 27%。但若是以房屋棟數統計來統計，這三區評估區域中僅遺漏 2 棟房屋，如圖 4.1-35(b) 中綠色箭頭所指處。成果顯示本項工作提出之方法應用於房

屋區偵測之可行性。



(a) 檢核區域與人工圈選房屋區

(b) 套疊分類成果(黃色)

圖 4.1-35、Pleiades 影像房屋偵測成果精度評估區域

表 4.1-9、Pleiades 影像房屋偵測成果精度評估

檢核像元數	整體精度	誤授率	漏授率
441165	82.80%	5.49%	27.12%

圖 4.1-36 為房屋輪廓正規化與約化處理成果，局部放大圖顯示透過正規化與約化處理後，房屋輪廓線大多變得較規則且較合理的形式，但若偵測不完整或是有房屋相連等狀況，仍會影響最終房屋區塊之合理性。正規化與約化後之成果同樣利用圖 4.1-35 所示之檢核區域進行精度評估，其成果如表 4.1-10 所示。如上所述雖然透過正規化與約化處理後房屋輪廓變的較規律且方正，但偵測不完整或是有房屋相連等狀況會造成房屋區塊誤差的提升，故整體精度(79.50%)略為下降，誤授率與漏授率相較於偵測結果也略為上升。



(a) 正規化與約化成果



(b) 房屋區域分類成果(局部)



(c) 正規化與約化成果(局部)

圖 4.1-36、Pleiades 房屋區域輪廓正規化與約化處理

表 4.1-10、Pleiades 影像房屋正規化與約化成果精度評估

檢核像元數	整體精度	誤授率	漏授率
441165	79.50%	6.80%	32.11%

(3) 道路區機器學習演算法建立與分類成果

考量道路物件之國際訓練集資料影像色調及道路樣態與臺灣道路差異顯著，如圖 4.1-37 所示，本項工作使用臺灣地區影像配合道路向量圖資來建置神經網路模型 U-Net。本項工作一樣會測試 Pleiades 與 SPOT-6 兩組不同解析度之影像，兩組訓練影像與對應之道路圖資如圖 4.1-38 所示，Pleiades 影像位於臺中，SPOT-6 影像則位於桃園與新竹，兩組資料各自訓練神經網路模型。與房屋區偵測相同，訓練模型時影像大小為 256x256 像元，道路區的部分，本項工作利用兩千筆訓練資料建置 U-Net 模型，其模型架構同圖 4.1-32。

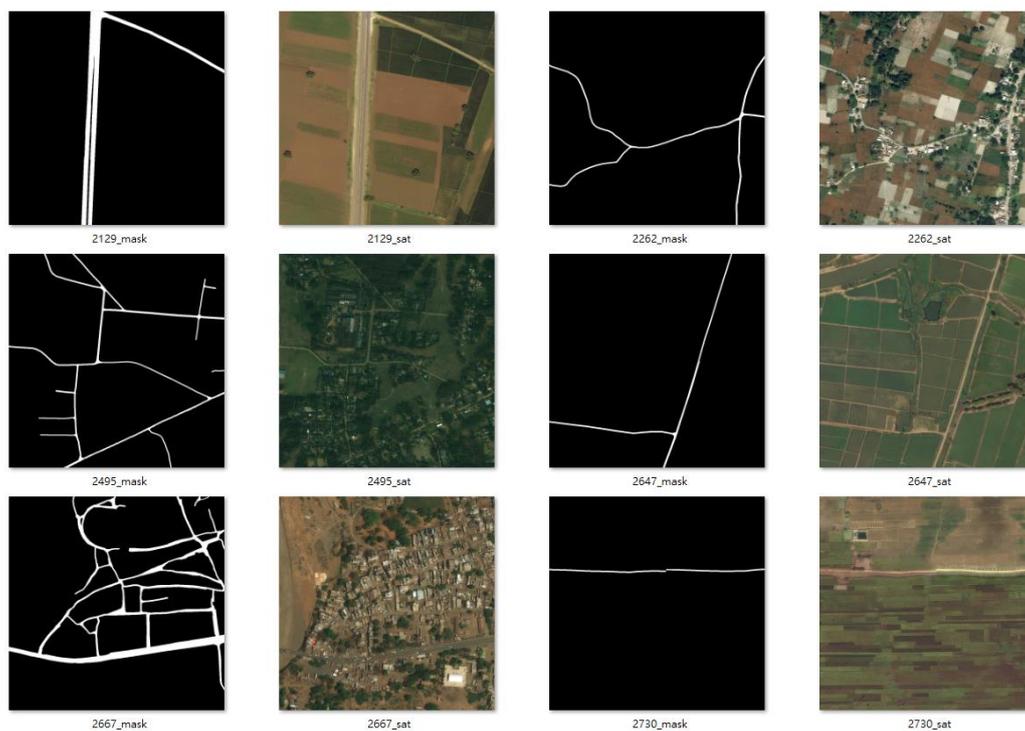


圖 4.1-37、道路物件國際公開 AI 訓練資料集 (部分)



(a) Pleiades 影像與其對應之道路向量標示圖



(b) SPOT-6 影像與其對應之道路向量標示圖

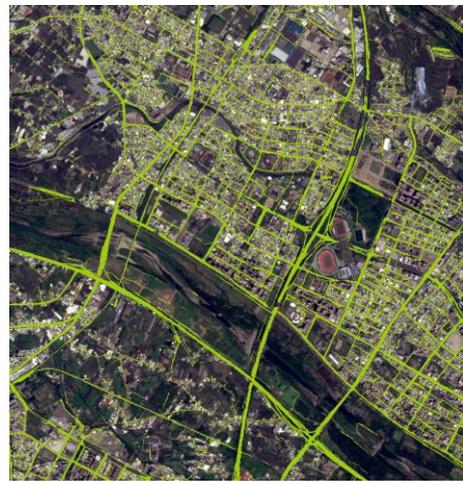
圖 4.1-38、道路物件訓練影像與分類標示

由訓練神經網路模型偵測之成果如圖 4.1-39 所示。比較兩組不同解析度測試例之成果，可發現道路偵測的部分，兩組成果視覺上的差異相較於房屋偵測成果較不顯著，兩組成果在主要幹道與重要道路均可成功偵測。推測因為相較於房屋的複雜與多元，道路在影像中之光譜、紋理與尺寸等特性較為單純，且 SPOT-6/7 影像之解析度已可清楚呈現絕大多數的道路，故兩測試例在道路偵測的成果差異並無房屋偵測成果的差異這麼顯著。本項工作挑選測區中 1 號國道、68 快速道路與 434 條之路、街、巷進行精度評估，其位置如圖 4.1-40 所示。其中，434 條之路、街、巷依路寬分別統計，相關資料如表 4.1-11 所示。將驗證區之道路向量圖資套疊分類成果，以人工判釋成果成功偵測道路數量與誤判道路的數量，即統計單位為線段 (polyline)。表 4.1-12 為道路萃取成果精度評估表。從表 4.1-12 可得，影像解析度較高之測試例一在各項統計之精度都略高於測試例二，其誤判數量

為 31 條道路，亦略低於測試例二的 38 條誤判數量。此外，由圖 4.1-39 可明顯見到，以超高解析影像偵測到的道路完整性高於利用高解析影像偵測到道路，此一現象在所偵測到的國道等較寬道路上更明顯。兩組測試例對於路寬 6 至 10 公尺之道路，其偵測之成功率均超過 91%，對於路寬大於 11 公尺以及國道與快速道路亦皆能成功偵測。對於路寬較小之道路，遺漏的比例則較高。



(a) 測試例一：Pleiades



(b) 測試例二：SPOT-6

圖 4.1-39、機器學習演算法道路區萃取成果



圖 4.1-40、道路區萃取成果檢核驗證資料

表 4.1-11、道路驗證資料表

類型	路、街、巷						國道與快速道路
	≤3	4	5	6~10	11~19	≥20	
路寬(公尺)	≤3	4	5	6~10	11~19	≥20	
數量	69	57	19	176	109	4	2

表 4.1-12、道路萃取成果精度評估

	類型	路、街、巷						國道與快速道路
		路寬(公尺)	≤3	4	5	6~10	11~19	
地真資料	數量	69	57	19	176	109	4	2
測試例一	偵測數量	37	32	12	164	109	4	2
	成功率	53.62%	56.14%	63.16%	93.18%	100%	100%	100%
	誤判數量	31						
測試例二	偵測數量	29	36	10	161	109	4	2
	成功率	42.03%	63.16%	52.63%	91.48%	100%	100%	100%
	誤判數量	38						

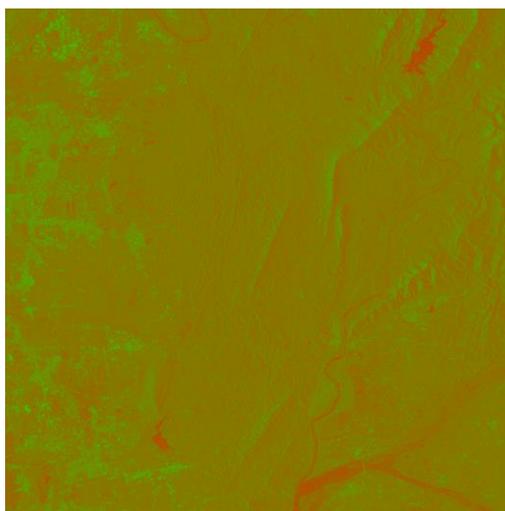
4.1.4 擴充衛星影像智慧加值應用與後續推動可行性評估

由於近年雷達衛星技術的改善，加上雙星/多星系衛星的運作模式盛行，使得影像的獲取頻率趨於穩定，時間域的解析度也因而提高。大量且穩定的資料有利於我們長時間進行觀測，成為穩定有效且可靠的大地測量工具，以長期地表形變監測之成果為例，可結合如雨量、地形坡度、潛勢區圖資等其他相關資訊來做進一步分析，對於未來國土規劃、災害預警、設施整

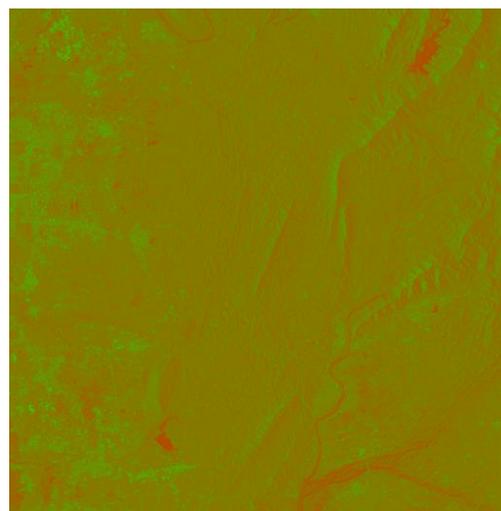
治等議題上有相當著墨空間。

整合平臺建議可以採用 Open Data Cube 系統，Data Cube 在國際間已開始推動，建置即可分析資料並同時可提供服務之衛星影像資料倉儲模型。國內目前有中央大學太遙中心以及國家太空中心在 Data Cube 領域進行相關的研究應用與開發。太遙中心建置之 Data Cube 系統配合接收站 SPOT 直接接收任務，支援 SPOT 影像匯入作業，現有 SPOT 影像資料將處理為大氣層頂反射率產品，並匯入系統中作為即可分析資料提供使用者可直接進行分析的影像，進行線上即時如 NDVI 或淹水判釋等加值應用之影像運算。

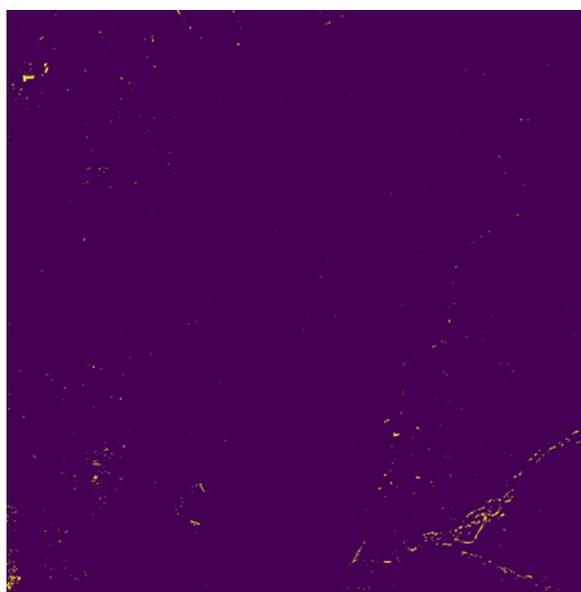
本項工作為採用前期（109、110 年）與本年度計畫產製之圖資成果進行整合平臺的測試，並彙整遙測各項常見加值應用案例，圖 4.1-41 為淹水判釋應用之影像運算案例，將高雄地區前後兩期雷達影像匯入 Data Cube，利用兩影像之間觀測直變化判斷被水覆蓋的區域，圖 4.1-41(c)圖中的黃色區域即為淹水區，利用已完成的圖資建立類似之加值應用，可作為後續應用推廣參考指標。



(a) Sentinel-1 前期影像



(b) Sentinel-1 後期影像



(c) Sentinel-1 淹水區域判釋成果

圖 4.1-41、SAR 淹水判釋加值應用範例

此外，光學影像也可以進行加值應用，以 NDVI 計算為例，Data Cube 系統會自動搜尋已匯入系統中之影像，利用雲遮罩挑選可用的影像來來進行計算，最後生成可下載的 NDVI 計算成果，圖 4.1-42 為以石門水庫區域進行 NDVI 功能之示範，圖中綠色代表植生相對茂密、土黃色代表植生相

對稀疏，而藍色部分為水體。

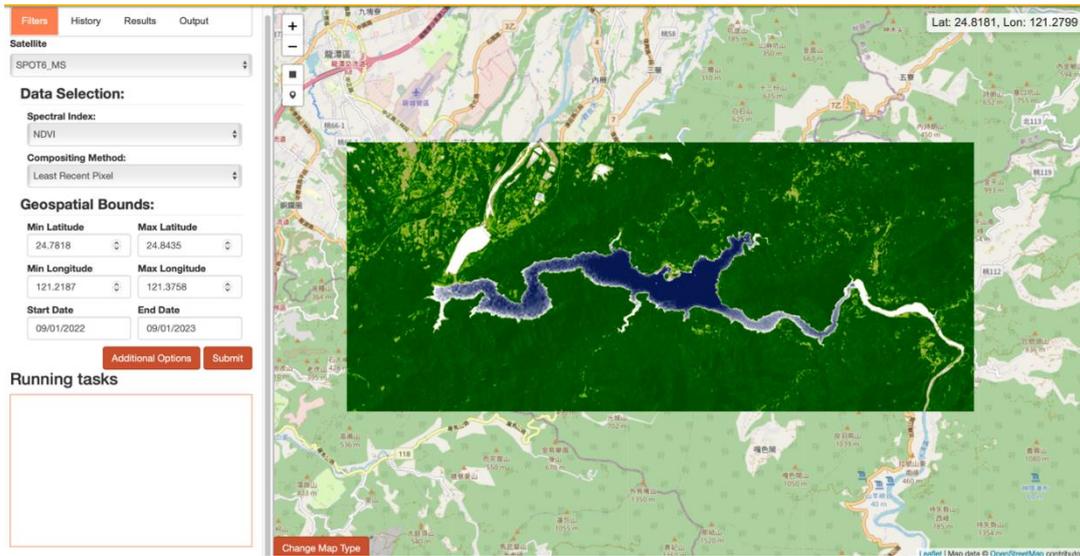


圖 4.1-42、石門水庫區域 NDVI 成果

本項工作僅進行可行性評估，考量到 Data Cube 具有相當彈性的功能擴充性，只要設置妥當便能匯入各式各樣的衛星資料，並且自訂客製化的演算法來進行資料加值處理，對於衛星影像智慧加值應用而言肯定具有相當的價值，建議後續之應用處理能基於類似之平臺來進行發展。

4.2 應用人工智慧發展航遙測影像辨識技術與應用

4.2.1 建立航遙測影像地表三維形變智慧分析技術

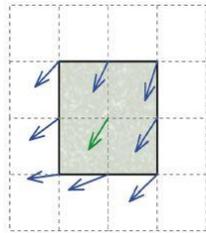
本項工作建立使用不同遙測資料獲取地表位移之技術，前期(109、110)計畫發展使用被動式光學影像進行質點影像量測(Particle Image Velocimetry, PIV)於獲取密集的地表像元(pixel)位移場(Displacement Field)，並證實利用前後期航拍正射影像或數值地表模型(Digital Surface Model, DSM)偵測山坡

地表二維形變之可行性。本年度工作目標為發展應用 PIV 技術於整合多時期航拍正射影像與數值地形模型偵測地表三維形變，及驗證技術之可行性。主要工作項目包括：(1)應用 PIV 技術對前後期航照正射影像獲取地表二維位移場；(2)利用前後期 DSM 獲取地表高程位移場；(3)以實際案例分析人工量測及自動化萃取成果；(4)比較各年度計畫建置之地表位移場。本項工作具體成果為建立多時期航遙測影像地表三維形變智慧分析技術，自動化萃取三維地表位移場並驗證技術可行性。

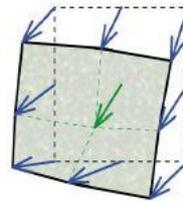
未來成果應用可輔助坡地地表位移偵測，利用多時期航拍影像與 DSM，有助於快速執行大面積山林地區監測與管理工作。定期觀測山坡地變化趨勢能夠及時對潛在的危害做出必要防護措施與擬定應對方針，例如：加裝監測儀器或設置警告牌提醒鄰近民眾勿隨意進入崩塌潛勢範圍；評估未來可能影響的範圍，分析水源是否會受影響及提早規劃居民撤離事宜等，預防並降低山坡地因地層滑動造成的災害與損失。

質點影像量測法的核心技術為前後期影像間之精密匹配。基於匹配精度及匹配點密集度之考量，本項工作採用頻率域匹配(Phase Correlation Matching) (Stone et al., 2001)，以快速傅立葉轉換(Fast Fourier Transform)視窗變形(window deformation)方法在頻率域中計算相關矩陣(Thielicke & Stamhuis, 2014)。頻率域匹配的概念是在等間距的子分析區域(Interrogation Area) (又稱視窗) 中心匹配產生位移量。匹配的流程：首先設定視窗之間

的重疊率(Overlap)為 50% (假如匹配視窗大小為 128x128 pixels, 相鄰視窗跨距為 64 pixels)。經過第一次頻率域匹配後(稱為 Pass 1), 每個視窗中心點會得到對應的位移量(圖 4.2-1(a)), 這些位移量利用雙線性內差法(Bilinear Interpolation)可計算視窗內每個像元概略的位移量, 並使視窗變形(圖 4.2-1(b)) (Thielicke & Stamhuis, 2014)。接著, 為了得到最佳解, 第二次頻率域匹配(稱為 Pass 2)以 Pass 1 的匹配成果為起始值, 縮小視窗大小(如: 64 x 64 pixels)並依相鄰視窗重疊率改變視窗跨距(如: 32 pixels), 鎖定局部區域將原始視窗與變形的視窗進行匹配, 得到 Pass 2 視窗中心點精化後的位移量。以此類推, 計算視窗之間的相關性, 累積每次縮小子分析區域範圍及間距的剩餘位移資訊, 由大視窗(粗)到小視窗(細), 最後獲得高精度、密集且等間距分布的位移場。



(a) 原始子分析區域



(b) 變形的子分析區域

圖 4.2-1、位移資訊位置示意圖(Thielicke & Stamhuis, 2014)

本項工作實驗區域位於花蓮縣瑞穗鄉林區, 研究材料包含由無人飛行載具於 2019/5/30 與 2020/3/24 拍攝且經正射化處理之航拍正射影像, 及經影像密匹配產生之 DSM。兩種資料的空間解析度均為 0.2 公尺, 圖 4.2-2 展示實驗區域的航拍正射影像與 DSM, 圖中黑色虛線框選的範圍為主要崩

塌區域(area of interest, AOI)。

為確保應用 PIV 技術自動化偵測地表位移成果為地表滑動造成，而非影像前處理的系統偏差，本項工作利用多重疊航拍影像進行空中三角測量平差，以人工量測明確的道路標記位置作為控制點。由於道路位於滑坡區域外，因此道路標記的位移量遠小於山區地表形變。前後期航拍影像均採用相同的控制點，經多視角航拍影像密匹配作業程序產生 DSM，再以 DSM 進行影像正射化，使多時期地表自動化匹配成果可以反映真實地表位移。

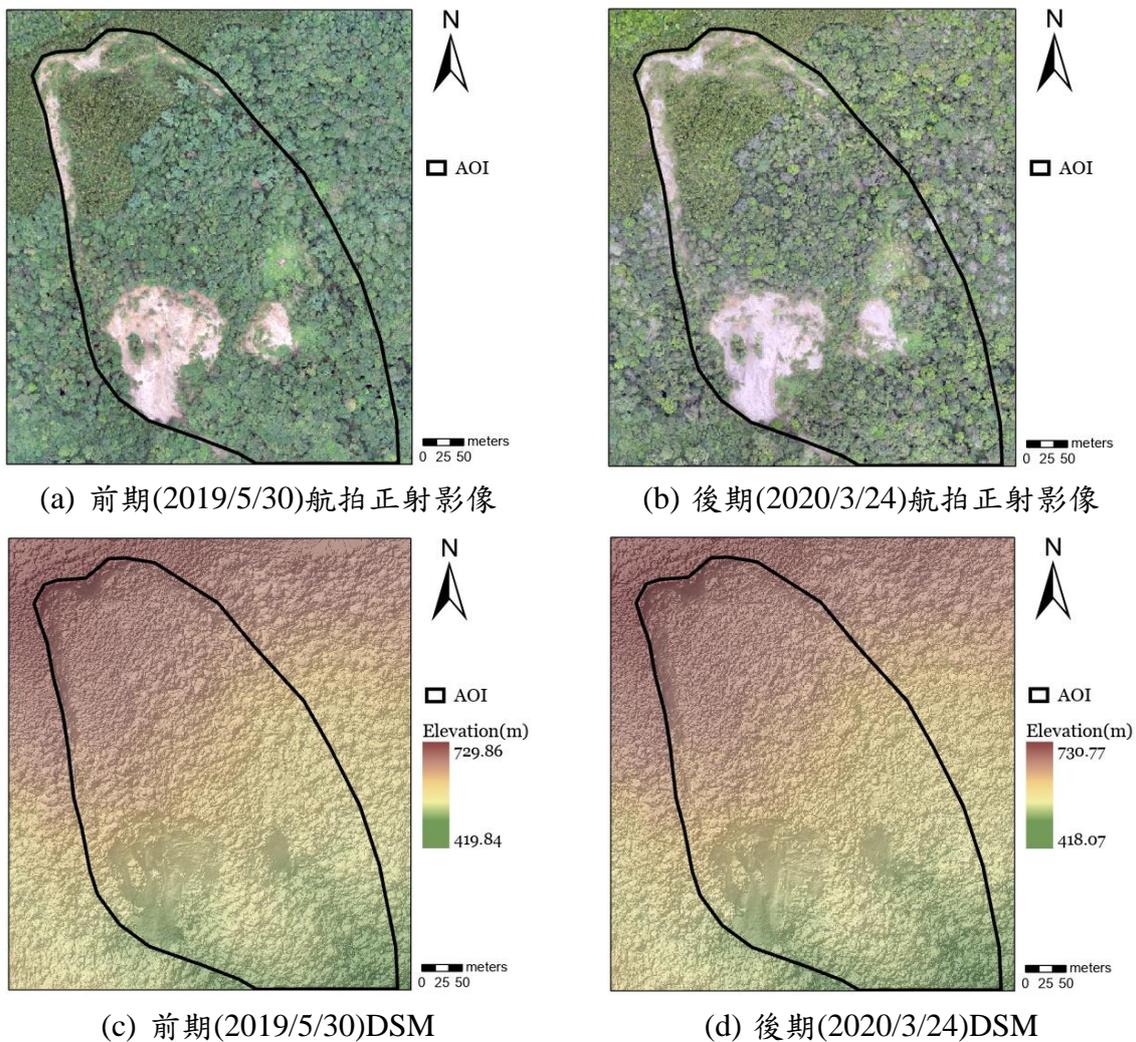


圖 4.2-2、花蓮縣瑞穗鄉林區數值地表模型

研究方法為應用 PIV 技術於整合多時期航拍正射影像與 DSM 偵測地表三維形變。使用前後期航拍正射影像色彩提供之光譜資訊 (Spectral Information) 計算地表平面位移量，及使用 DSM 高度提供之形狀資訊 (Shape Information) 計算地表高程變化量。方法主要可分成兩個部分，第一部分為應用 PIV 技術對前後期航照正射影像進行精密匹配以獲取地表二維位移場。地表滑動會造成多時期正射影像間的像元位移，故將前後期航拍正射影像依固定間距設定規則網格點後，再利用頻率域匹配進行影像密集匹配，得到網格點對應的同名點，即可計算每個網格點在東西方向及南北方向之前後期位移變化量(式 4.2-1, 4.2-2)，最後得到整體地表平面位移場(圖 4.2-3)。頻率域匹配參數設定如表 4.2-1 所示。

$$\Delta X_{(i,j)} = X_{t+1}(i,j) - X_t(i,j) \quad \text{式 4.2-1}$$

$$\Delta Y_{(i,j)} = Y_{t+1}(i,j) - Y_t(i,j) \quad \text{式 4.2-2}$$

其中， $(X_t(i,j), Y_t(i,j))$ 為網格點位(X, Y)前期坐標； $(X_{t+1}(i,j), Y_{t+1}(i,j))$ 為網格點位(X, Y)後期坐標； $(\Delta X_{(i,j)}, \Delta Y_{(i,j)})$ 為點位(X, Y)的二維位移量。

表 4.2-1、頻率域匹配參數設定

	Interrogation area (pixel) 子分析區域 (視窗) 大小	Step (pixel) 相鄰視窗跨距	Overlap (%) 相鄰視窗重疊率
Pass 1	512 x 512	256	50
Pass 2	256 x 256	128	
Pass 3	128 x 128	64	
Pass 4	64 x 64	32	

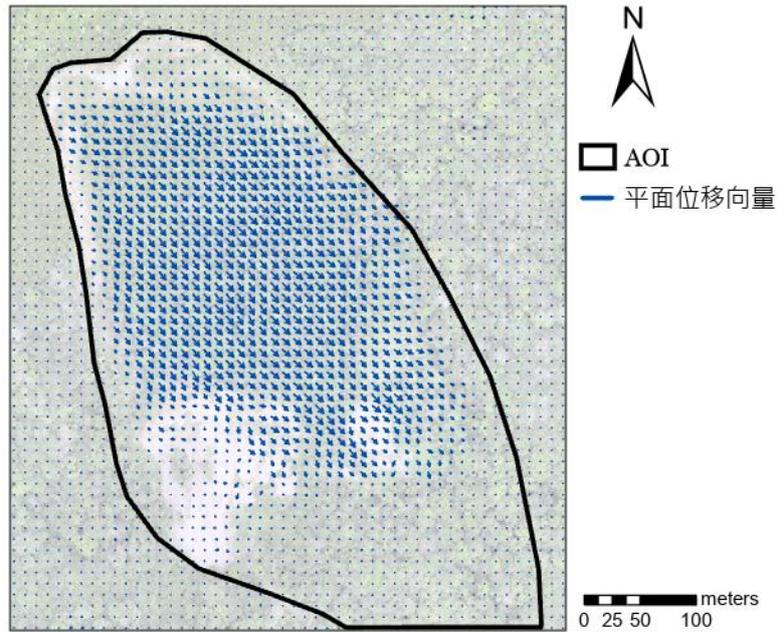


圖 4.2-3、地表平面位移場（黑色框為崩塌範圍）

第二部分為利用前後期 DSM 獲取地表高程位移場。考慮到坡地滑動後，地物在地表的位置會改變。若直接將兩期 DSM 相減，得到的變化並非地表的高程形變量，而是地理位置的高度變化，無法呈現地表實際的高程位移量（圖 4.2-4）。而 PIV 技術將前後期資料經頻率域匹配後，可得到前期網格點對應的後期網格同名點。因此，為能自動化獲取與地表真實形變狀況接近之高程位移量，本項工作將前後期 DSM 也依固定間距設定規則網格點，並在前期 DSM 中以網格點 $(X_t(i, j), Y_t(i, j))$ 為中心，框一個 128 x 128 pixels 的分析區域後，萃取區域範圍內所有像元的高程值並計算平均高程。同理，在後期 DSM 中以前期網格點對應的同名點 $(X_{t+1}(i, j), Y_{t+1}(i, j))$ 為中心，框選一個 128 x 128 pixels 大小的區域後，計算區域範圍內像元的後期平均高程值。接著，將後期平均高程值減去前期平均高程值（式 4.2-3），得到網

格點(X, Y)前後期高程位移量 ΔZ 。以此類推，計算每個網格點的高程改變（圖 4.2-5(a)），並利用克利金法(Kriging)內插網格高程變化，得到整體地表高程位移場（圖 4.2-5(b)）。

$$\Delta Z_{(i,j)} = Z_{t+1}(i,j) - Z_t(i,j) \quad \text{式 4.2-3}$$

其中， $Z_t(i,j)$ 為網格點(X, Y)前期平均高程； $Z_{t+1}(i,j)$ 為網格點(X, Y)後期平均高程； $\Delta Z_{(i,j)}$ 為網格點(X, Y)的高程變化量。

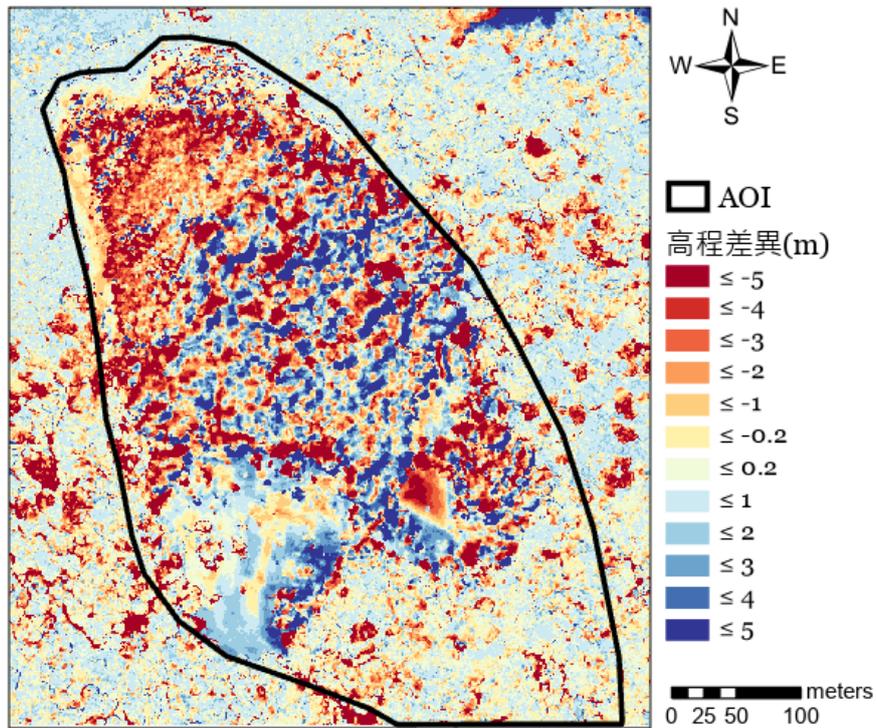


圖 4.2-4、前後期 DSM 相減後高度變化

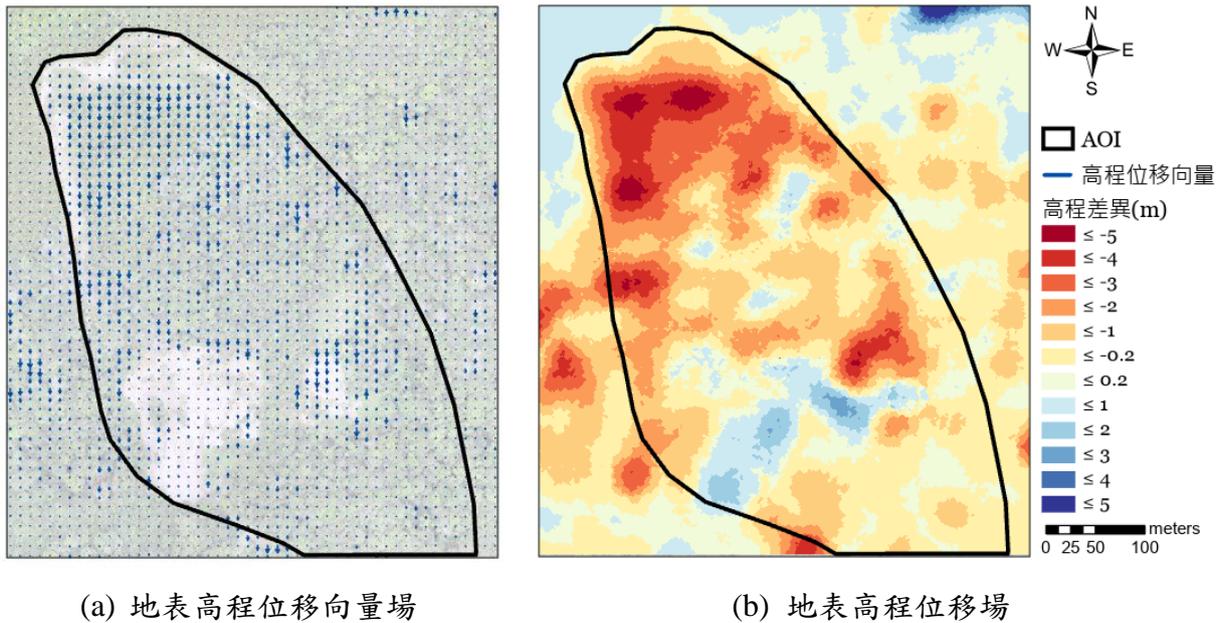


圖 4.2-5、地表高程位移場

為驗證整合航遙測影像與數值地表模型萃取三維地表位移向量場之可行性，本項工作比較人工量測成果及自動化萃取成果，以人工量測多時期航拍正射影像中房屋前後期同位點的坐標（圖 4.2-6），計算房屋在前後期影像上移動的距離與方向，以評估自動化萃取的地表平面位移量。另外，也人工量測由航拍影像密匹配產生之三維點雲(Point cloud)中房屋前後期同位點的高程（圖 4.2-7），計算房屋前後期的高度變化量，以評估自動化萃取的地表高程位移量。表 4.2-2 為比較人工量測及自動化萃取之成果（圖 4.2-8），兩組數據之間的位移方向與三維形變量相關性高，特徵良好點位之平面及高程位移差異量均小於 0.2 公尺(1 pixel); 位移方向差異小於 2 度，由此可證實應用 PIV 於地表三維形變智慧分析技術之成果具參考價值。



(a) 人工量測前期同位點 (黃點)
(底圖:前期正射影像)



(b) 人工量測後期同位點 (黃點)
(底圖:後期正射影像)

圖 4.2-6、房屋前後期同位點平面位置

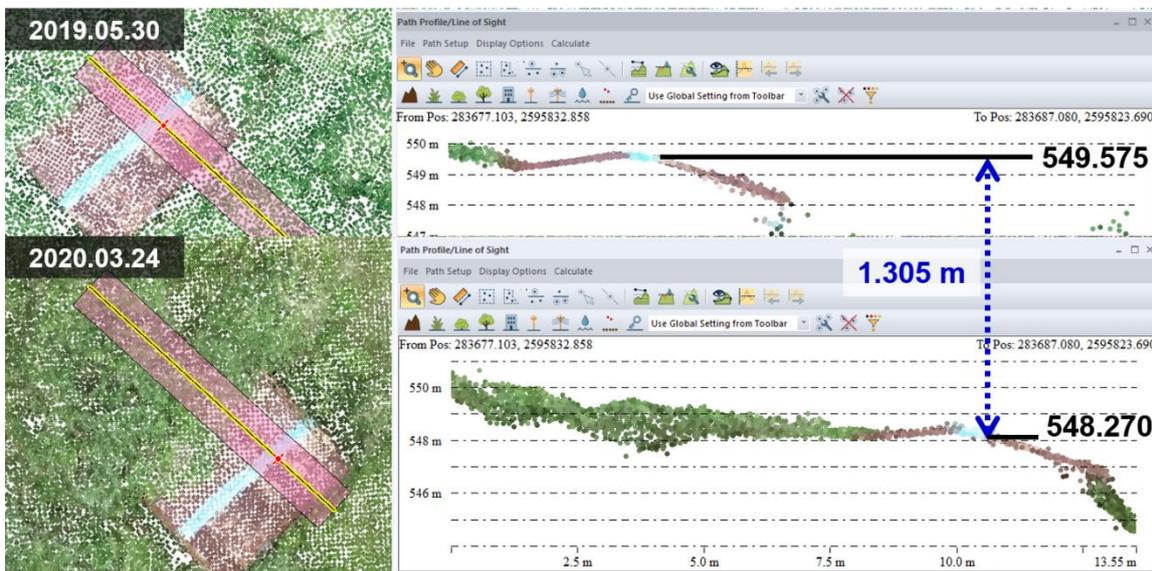


圖 4.2-7、房屋前後期同位點高程位置



(a) PIV 萃取三維向量(底圖:前期影像)



(b) PIV 萃取三維向量 (底圖:後期影像)

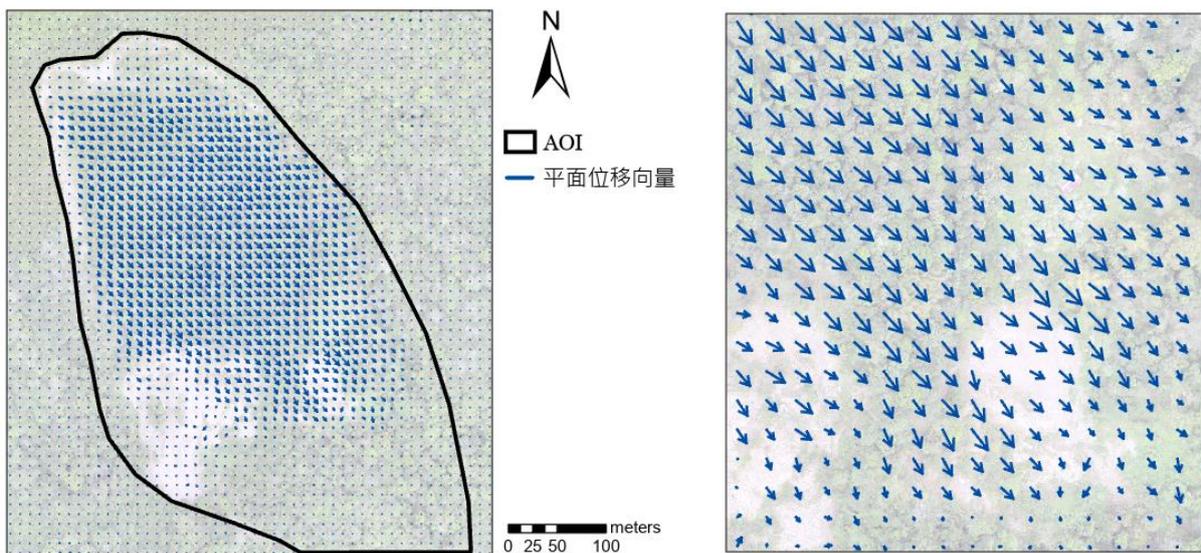
(紅色箭頭:高程位移向量; 藍色箭頭:平面位移向量)

圖 4.2-8、PIV 萃取三維地表位移向量

表 4.2-2、比較人工量測與 PIV 萃取三維地表位移量

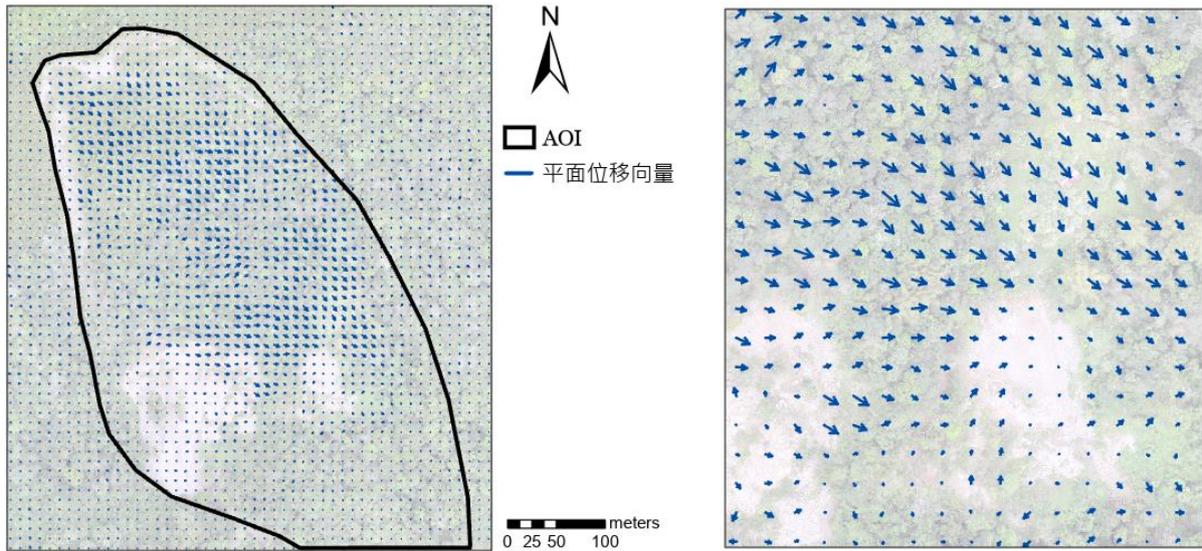
	人工量測	PIV 向量	差異
平面位移量 (m)	6.338	6.169	-0.169
高程位移量(m)	-1.305	-1.131	-0.174
位移方向	132°29' 19"	133°40' 08"	1°10' 49"

比較各年度建置之地表位移場（圖 4.2-9），第一年度(109)計畫使用前後期航拍正射影像之光譜資訊產生實驗區域的地表二維位移場(Image-PIV)；第二年度(110)使用前後期 DSM 之高度資訊產生實驗區域的地表二維位移場(DSM-PIV)；本年度則是使用前後期航拍正射影像與 DSM 產生地表三維位移場(Image+DSM-PIV)。



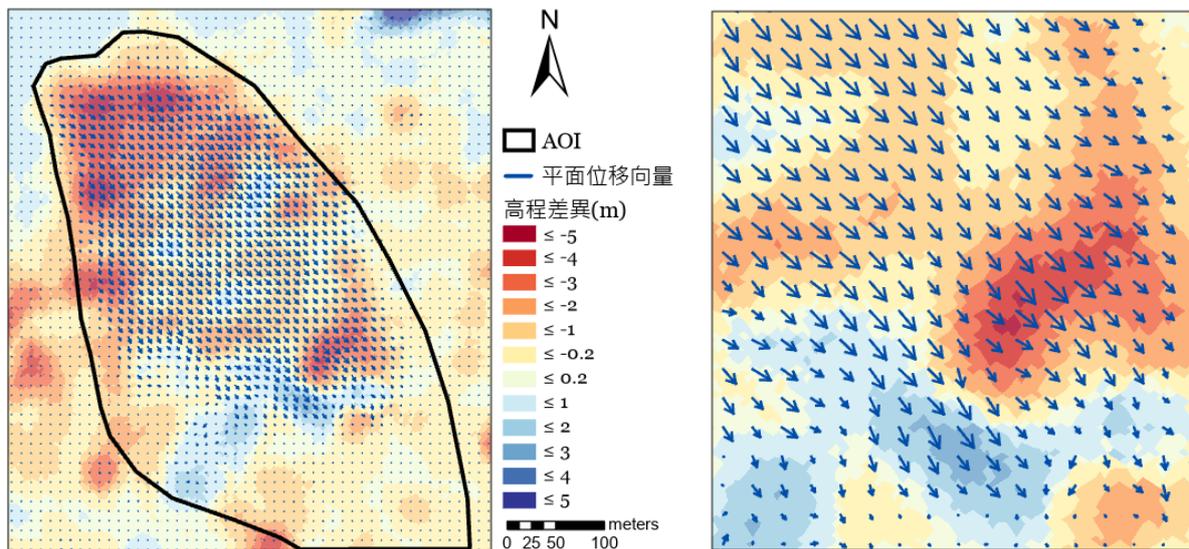
(a) 第一年度計畫: Image-PIV 二維位移場

(b) Image-PIV 二維位移場局部放大



(c) 第二年度計畫: DSM-PIV 二維位移場

(d) DSM-PIV 二維位移場局部放大



(e) 第三年度計畫: Image+DSM-PIV 三維位移場
(箭頭方向指平面位移, 底圖顏色為高程方向位移)

(f) 三維位移場局部放大(箭頭方向指平面位移, 底圖顏色為高程方向位移)

圖 4.2-9、各年度計畫建置之地表位移場

各年度計畫之成果以實際案例分析，三種方式產生的地表二維形變整體趨勢一致，而 Image+DSM-PIV 除了偵測地表二維形變量外，亦可萃取地表在高程方向上的變化資訊。此外，觀察局部實驗區域後發現 Image-PIV 與 Image+DSM-PIV 偵測到的位移方向與距離較接近實際坡地滑動狀況，而

DSM-PIV 獲取的局部地表位移場成效較差。不過，DSM 含有地表高度資訊，故 DSM-PIV 能提供高程方向整體的抬升或沉降量，但 DSM-PIV 的局部抬升或沉降量效果較差。綜整上述，Image-PIV 的優點是可獲得精度相對高的地表二維變化，缺點是無法偵測地表高度變化；DSM-PIV 的優點是除了可獲得地表二維變化外，亦可進一步偵測高程變化，缺點是萃取的地表二維位移場精度較低。Image+DSM-PIV 則透過結合 Image-PIV 與 DSM-PIV 的優點，利用航拍正射影像萃取地表平面位移量，及利用 DSM 萃取高程位移量，以得到精度良好且具有平面與高程形變資訊的地表三維位移場。

本項工作完成自動化偵測地表三維形變技術開發，利用多時期航拍正射影像與數值地形模型偵測山坡地滑動趨勢，產生地表三維位移場，並透過實際案例確認技術可行性。

4.2.2 建立航遙測影像智慧辨識訓練資料集，須對不同類型之資料集進行整理並分析其適用性，探討結合影像與高程模型於地表分類之效益

導入電腦視覺(Computer Vision)技術於遙感探測領域可提升自動化效能，以人工智慧技術自動化偵測航遙測影像中建物輪廓是提升都市變遷偵測及三維城市模型建置效率的重要工作。然而自動化辨識技術的發展，需仰賴大量且多元的訓練資料集產生智慧辨識的分類參數，故發展人工智慧於航遙測影像辨識技術中，首先面臨到的挑戰即為訓練資料集，以應用於開發及測試智慧辨識技術能力，並對辨識成果進行定性及定量之評估

(Goldberg et al., 2017)。

目前國際上已有許多由航遙測影像建置，應用於地物分類與辨識之開放標竿資料集(Benchmark Dataset)。雖然僅利用航遙測影像便能萃取特徵並辨識地物，但考量到不同感測器所蒐集的資料具有不同特性，若結合多源（如：主動及被動感測器）或具有不同特徵的多模式(multimodal)（如：影像及點雲）資料，可加強特徵(Feature)提取能力，並增進地物辨識精度(Gómez-Chova et al., 2015；Gibril et al., 2017)。近期也有不少彙整異質資料且用於辨識航遙測影像地物的國際開放標竿資料集，例如：DroneDeploy 標竿資料集整合了航空正射影像與數值地表模型(Digital Surface Model, DSM)。在發展智慧辨識技術的階段若直接使用此類具有代表性且多模式的資料集，能夠快速比較與測試多種演算法外，亦可縮小演算法開發與實際應用之間的差距(Jahan et al., 2018; Long et al., 2021)，有助於促進研究發展。

航遙測影像智慧辨識依不同應用目的主要可以分為影像分類(Image Classification)、物件偵測(Object Detection)、語意分割(Semantic Segmentation)及實體分割(Instance Segmentation)等。本項工作第一年度(109)針對影像分類（圖 4.2-10(a)）之訓練資料集進行分析；第二年度(110)計畫為能夠細部萃取影像中屬於建物的像元，針對語意分割（圖 4.2-10(b)）訓練資料集進行分析；第三年度(111)計畫則為了提升萃取影像中建物像元的精度，從資訊融合(Data Fusion)的角度出發，進一步針對結合二維與三維資訊之語意分

割訓練資料集進行分析。



(a) 影像分類:分類此影像為房屋

(b) 語意分割:萃取屬於房屋的像元

圖 4.2-10、不同應用目的之智慧辨識技術

本年度工作目標為蒐集與分析整合航遙測影像及高程模型於房屋偵測之國際標竿訓練資料集，探討各資料集應用於臺灣之適用性，並使用標竿資料集建立航遙測影像智慧辨識訓練資料集。這些國際標竿資料集均為開放資料，可經由網路免費申請下載使用，本項工作重要貢獻為系統性收集航遙測國際標竿資料集，橫向比較各國際標竿資料集的適用性，以利國內相關機關及學界選定適用的國際標竿資料集，有利後續發展航遙測自動化房屋智慧辨識與分類技術。本項工作內容分成三個部分，第一部分探討結合航遙測影像與高程模型於地表分類之效益，並蒐集用於辨識影像中房屋像元且由航遙測影像與地表高程模型所建立之國際標竿訓練資料集。第二部分為橫向比較與分析各個標竿資料集的內容與特性。第三部分為探討各國際標竿資料集應用於臺灣之適用性。本項工作具體成果為提供結合航遙測影像及高程模型之國際標竿資料集於建立航遙測自動化地物智慧辨識與

分類技術使用。未來成果應用可於建立房屋智慧辨識深度學習模型時提供訓練資料，經由訓練模型參數值，萃取航遙測影像的深度特徵(deep feature)，應用於自動化辨識航遙測影像中的房屋。

以航遙測資料進行土地覆蓋分類時，採用不同來源或類型的感測器能夠獲取不一樣的分類特徵，例如多光譜航遙測影像可獲得地物的光譜資訊、而 DSM 可獲得地物的高程資訊、光達(Light Detection and Ranging, LiDAR)資料則可萃取地物的幾何形狀。多光譜影像的優點為能提供地物光譜及邊界資訊，缺點為缺乏地物高程資訊；DSM 的優點為能提供高程資訊，缺點為缺乏光譜資訊；光達資料的優點為能提供良好的地物幾何形狀，缺點是光達點雲為離散點，線形特徵較不明顯。DSM 與光達資料皆含有地物高度資訊，有助於區分建築物、道路或樹木等不同高度的地物(Audebert et al., 2016; Jahan et al., 2018)，因此將 DSM 或光達資料用於地物辨識，可以改善影像語意分割的分類結果(Marcos et al., 2018)。

為結合不同類型資料的優勢，克服單一感測器硬體的限制，並增進土地覆蓋分類精度，Jahan et al., (2018)融合高光譜(Hyperspectral, HS)影像與光達資料產生的 DSM 對 15 種不同地物進行分類，並分別利用隨機森林(Random Forest)與支持向量機(Support Vector Machine)分類器比較整合兩種資料(HS+DSM)或單使用影像(HS)分類的精度。成果顯示，不論使用哪種分類器，以 HS+DSM 分類地物的成果優於 HS，整體精度相差 2.4 至 4.4%，

且加入 DSM 後，住宅與商業建物類別的整體精度可提升 1.5 至 26.5%（表 4.2-3）。

表 4.2-3、使用不同模型與資料的地物分類精度(Jahan et al., 2018)

Unit:%	Random Forest		Support Vector Machine	
	HS	HS + DSM	HS	HS + DSM
健康的草	83.57	83.57	83.10	84.14
不健康的草	98.40	98.31	98.21	98.31
人工草皮	98.02	98.22	99.41	99.41
樹木	97.44	97.44	98.20	98.77
土壤	96.40	96.88	94.98	94.98
水	97.20	97.20	88.81	90.91
住宅建物	83.02	84.51	88.53	88.43
商業建物	40.74	50.52	42.64	69.14
道路	69.12	70.63	56.00	72.62
高速公路	57.43	58.30	62.64	67.76
鐵路	76.09	79.22	79.22	87.67
停車場 1	49.28	58.89	54.47	46.40
停車場 2	60.35	63.51	42.81	44.21
網球場	99.19	99.60	98.79	98.38
跑道	97.67	97.89	95.98	97.25
整體精度（15 個類別）	77.46	79.86	77.49	81.93

除了傳統的機器學習方法，深度學習方法亦應用於資料融合的智慧識別，Al-Najjar et al., (2019)利用卷積神經網路(Convolutional Neural Network, CNN)模型探討僅使用從多光譜影像萃取之單一特徵，及融合多光譜影像與 DSM 之異質特徵對於土地覆蓋分類的效益。藉由比較訓練與檢核模型的精度來評估不同分類方式的性能，發現輸入資料選擇整合影像與 DSM 的分類精度高於單選用影像，兩者的整體精度相差 2 至 3%；平均精度相差 2 至 5%

(表 4.2-4)。此外，在地物外觀相似且沒有高度資訊的情況下，深度學習模型容易誤將裸露地辨識為建築物，或將草地辨識為樹木(圖 4.2-11)。

表 4.2-4、使用不同資料的地物分類精度(Al-Najjar et al., 2019)

模型		整體精度	平均精度	Kappa
訓練	CNN (影像+DSM)	0.92	0.91	0.91
	CNN (影像)	0.89	0.86	0.88
檢核	CNN (影像+DSM)	0.90	0.89	0.89
	CNN (影像)	0.88	0.87	0.88

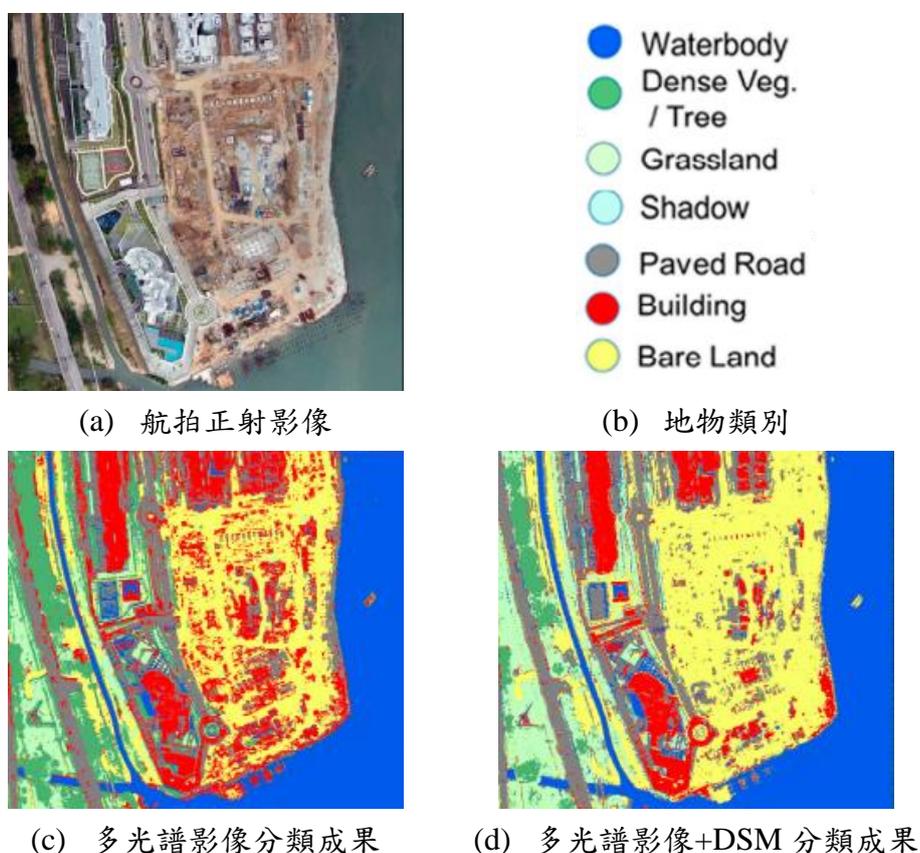


圖 4.2-11、比較使用不同方式的土地覆蓋分類成果

Sun et al., (2021)比較使用多光譜航拍影像(RGB)、正規化數值地表模型(Normalized Digital Surface Model, nDSM)、融合影像 1 (RGB + nDSM)及融合影像 2 (RGB + NIR + nDSM)，各資料集萃取建築物輪廓的準確度。成果

顯示在深度學習模型中加入 DSM 後，萃取的建物位置更精確，形狀相似性有顯著改善，邊界也更接近實際房屋輪廓（圖 4.2-12），故融合航遙測影像與 DSM 應用於自動化辨識房屋具有正面效益。整合上述，比起利用單一來源的航遙測影像辨識地物，結合不同類型或來源的資料可有效地增加判釋精度。除此之外，由於 DSM 提供地物高度資訊，有益於區分不同高度的物體。因此，利用航遙測影像進行地物分類時加入 DSM 資料，對於提升地物種類辨識及輪廓萃取能力相當有幫助。

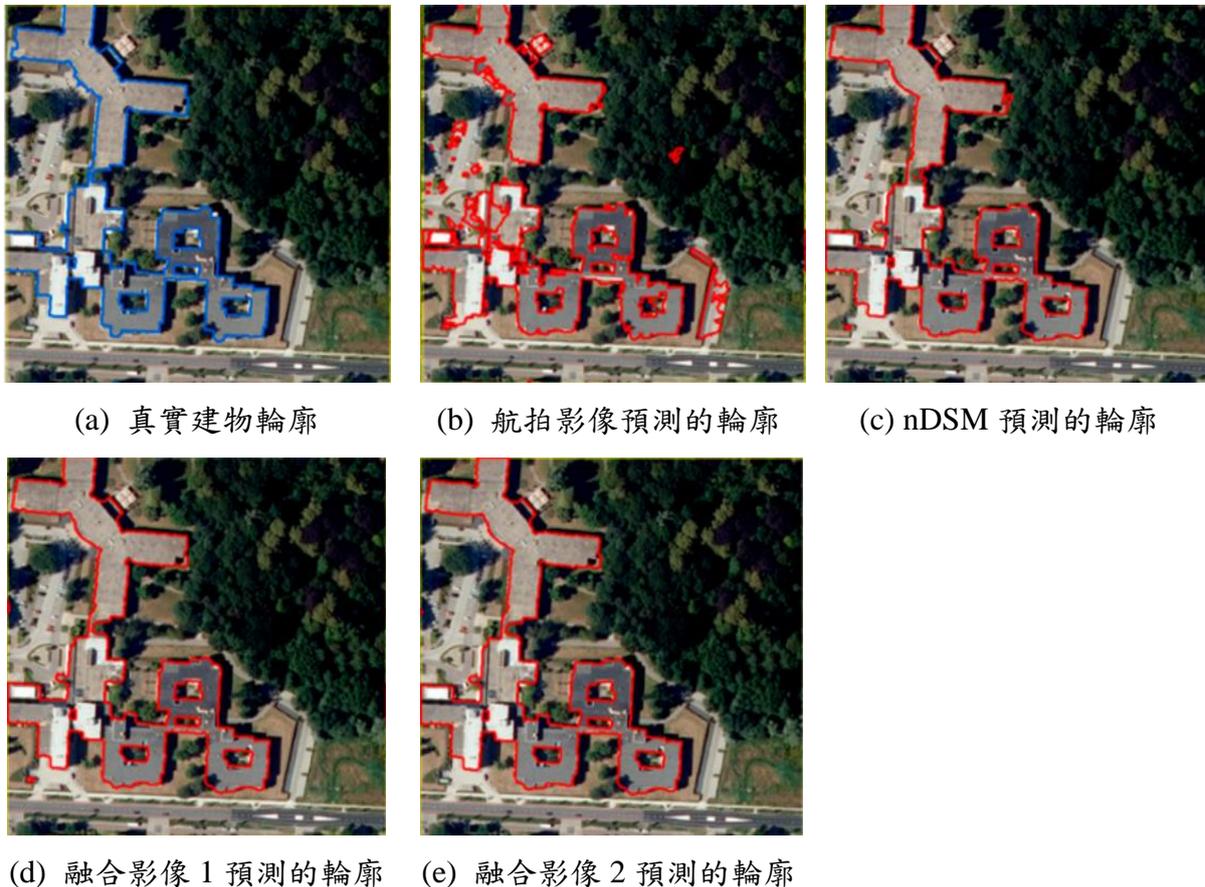


圖 4.2-12、房屋輪廓萃取成果比較(Sun et al., 2021)

為建立性能良好的深度學習模型，在模型訓練階段需提供大量、多元

且高品質的訓練資料。另外，由於各個國家與城市受歷史人文、地理環境及天候條件等影響，不同地區建築物的外觀和型態也不一樣。因此，並非所有國際標竿資料集皆適合用於辨識臺灣的房屋。考量到上述問題，為了選出較適用之訓練資料集，本項工作蒐集五個國際公開標竿資料集，比較與分析各標竿資料集的內容與特性（表 4.2-5），以可能影響自動化房屋辨識成果的要素為主要分析項目，例如：資料來源、空間解析度、場景類別、建物分布型態與數量等。

表 4.2-5、國際標竿資料集基本資料

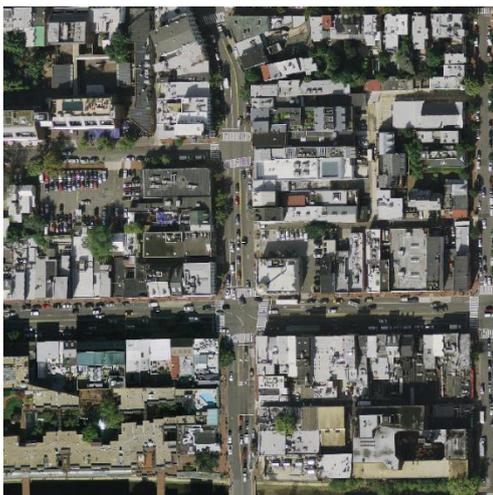
國際標竿資料集	資料集區域	資料類型	解析度 (m/pixel)	建物 數量 (棟)	影像 場景
DroneDeploy: Aerial Segmentation Benchmark	-	航空正射影像	0.1	2,000	都市、住宅區及工業區
		DSM			
		地真資料			
Aerial Imagery Object Identification Dataset(AIOI)	Arlington, Atlanta, Austin, Washington, New Haven, New York, Norfolk, San Francisco, Seekonk (USA)	航空正射影像	0.15 - 0.3	44,000	市區、住宅區及住商混合區
		DSM (光達點雲產製)			
		地真資料			
2018 IEEE GRSS Data Fusion Dataset	Houston, University of Houston (USA)	航空正射影像	0.05	270	大學校園、市區
		高光譜影像	1		
		DSM (光達點雲產製)	0.5		
		強度網格資料	0.5		
		地真資料	0.5		

國際標竿資料集	資料集區域	資料類型	解析度 (m/pixel)	建物 數量 (棟)	影像 場景
ISPRS: Urban Modelling and Semantic Labelling Benchmark <ul style="list-style-type: none"> Urban Classification and 3D Building Reconstruction 2D Semantic Labeling 3D Semantic Labeling 	Vaihingen (Germany)	航空影像	0.08	111	市區、住宅區及住商混合區
		航空正射影像	0.09		
		空載光達點雲	4 points/m ²		
		DSM(光達點雲/影像產製)	0.25/ 0.09		
		地真資料	-		
	Toronto (Canada)	航空影像	0.15	96	
		空載光達點雲	6 points/m ²		
		DSM (光達點雲產製)	0.25		
		地真資料	-		
	Potsdam (Germany)	航空正射影像	0.05	1053	
DSM (影像產製)					
地真資料		-			
Urban 3D Challenge Benchmark	Jacksonville, Tampa, Richmond (USA)	航空正射影像	0.5	103,143	
		DSM (影像產製)			
		DTM (影像產製)			
		地真資料			

五個標竿資料集的簡述與分析如下：(1) DroneDeploy：航空影像分割標竿(Aerial Segmentation Benchmark) (Dronedeploy, 2019)資料集提供 55 張由藍光、綠光與紅光波段組成的多光譜航空正射影像、數值地表模型及地真(Ground truth)類別資料。影像與 DSM 的空間解析度為 0.1 公尺，地真資料包含建築物、雜物、植物、水、地面、汽車、背景，共 7 種類別。其中，建築物類別僅佔整個資料集的 5.6% (Parmar et al., 2020)，約有 2000 棟建物。

資料集內影像拍攝自不同城市，場景涵蓋都市、郊區及工業區。

(2) 航空影像物體辨識(Aerial Imagery Object Identification, AIOI) (Bradbury et al., 2016)資料集由杜克大學能源倡議組織(Duke University Energy Initiative)建置，提供：(a) 25 張由藍光、綠光與紅光波段組成的多光譜航空正射影像，其中 20 張含有近紅外光波段；(b) 由空載光達點雲產生的數值地表模型；(c) 來自開放街圖(OpenStreetMap, OSM)的地真資料。影像與 DSM 的空間解析度介於 0.15 至 0.3 公尺，地真資料包括建築物及道路類別。影像拍攝於美國 9 座城市，包括阿林頓(Arlington)、亞特蘭大(Atlanta)、奧斯丁(Austin)、華盛頓(Washington)、新哈芬(New Haven)、紐約市(New York City)、諾福克(Norfolk)、舊金山(San Francisco)、錫康克(Seekonk)，場景涵蓋都市與郊區，共約有 44,000 棟建築。建物型態及屋頂複雜度不一，其中拍攝於華盛頓的建物（圖 4.2-13）與臺灣市區建物較相似。



(a) 華盛頓建物影像



(b) 臺灣市區建物影像

圖 4.2-13、臺灣市區與華盛頓建物影像比較

(3) 2018 IEEE GRSS 資料融合(Data Fusion)資料集(Le Saux et al., 2018) 來自 2018 年 IEEE GRSS 資料融合競賽，提供訓練及檢核資料。其中，訓練資料包括：(a) 4 張 5 公分空間解析度，由藍光、綠光與紅光波段組成的多光譜航空正射影像；(b) 1 公尺空間解析度的高光譜(Hyperspectral, HS)影像；(c) 空載光達點雲；(d) 由空載光達點雲產製 0.5 公尺空間解析度的強度(Intensity)網格資料及數值表面模型；(e) 0.5 公尺空間解析度的地真類別資料，包含人造草、常青樹、裸露地表、住宅建築、非住宅建築、道路等，共 20 種類別(Xu et al., 2019)。影像拍攝於美國休士頓(Houston)，場景涵蓋休士頓大學校園及其周邊市區，共有約 270 棟建築。

(4) ISPRS 都市建模與語意標籤(Urban Modelling and Semantic Labelling Benchmark)資料集，依據不同計畫與競賽主題分成三組，分別為都市分類與三維建築重建測試計畫(Test Project on Urban Classification and 3D Building Reconstruction) (Rottensteiner et al., 2012；Rottensteiner et al., 2013)、二維語意標籤(2D Semantic Labeling)競賽(Rottensteiner et al., 2014) 及三維語意標籤(3D Semantic Labeling)競賽(Blomley & Weinmann, 2017)。

這三組資料拍攝於德國 Vaihingen 與 Potsdam，及加拿大多倫多(Toronto)。Vaihingen 航遙測資料包含：(a) 20 張 8 公分空間解析度，由綠光、紅光與近紅外光波段組成的多光譜航空原始影像；(b) 由原始影像正射化後鑲嵌，空間解析度為 9 公分之航空正射影像；(c) 每平方公尺平均有 4 個點的空載

光達點雲；(d) 由點雲產製 25 公分空間解析度的 DSM，及由航空影像產製 9 公分空間解析度的 DSM；(e) 地真類別資料。影像場景涵蓋建物密集且屋頂結構複雜的市中心，及建物旁種植樹木的高層連棟和低層獨棟住宅區，共有約 111 棟建築。Toronto 航遙測資料包含：(a) 13 張 15 公分空間解析度，由藍光、綠光與紅光波段組成的多光譜航空正射影像；(b) 每平方公尺平均有 6 個點的空載光達點雲；(c) 由點雲產製 25 公分空間解析度的 DSM；(d) 地真類別資料。影像場景涵蓋由高樓大廈組成的都會區，及混合低層與高層建築的住商混合區，共有約 96 棟建築。Potsdam 航遙測資料包含：(a) 38 張 5 公分空間解析度的多光譜航空正射影像，影像波段組合有三種，分別為藍光、綠光與紅光波段；綠光、紅光與近紅外光波段；藍光、綠光、紅光與近紅外光波段。(b) 由航空影像產製 5 公分空間解析度的 DSM；(c) 地真類別資料。影像場景涵蓋由大型連棟建物組成且聚落結構密集的市區，共有約 1053 棟建築。

三組資料的地真類別資料依據不同計畫或競賽主題而有所差異，都市分類與 3D 建築重建測試計畫將地物類別分成自然表面與矮植被、建物、樹木，共 3 類。2D 語意標籤競賽將地物類別分成不透水表面、建物、矮植被、樹木、汽車、背景，共 6 類。3D 語意標籤競賽則將地物類別分成不透水表面、屋頂、建物立面、矮植被、樹木、柵欄／樹籬、灌木、電力線、汽車，共 9 類。

(5) 都市三維挑戰標竿 (Urban 3D Challenge Benchmark) 資料集 (Goldberg et al., 2017; Goldberg et al., 2018) 來自一項由美國特種作戰指揮部 (United States Special Operations Command, USSOCOM) 贊助的公開錦標挑戰賽，該挑戰賽旨在使用 2D RGB 正射校正影像及利用商業衛星影像產製的 3D DSM 共同辨識建築物輪廓。此資料集提供訓練與檢核資料。其中，訓練資料包括：(a) 174 張 50 公分空間解析度，由藍光、綠光與紅光波段組成的多光譜衛星正射影像；(b) 由航空影像產製 50 公分空間解析度的 DSM 與 DTM；(c) 50 公分空間解析度的地真類別資料，包含建物、非建物類別。影像拍攝於美國 3 座城市，包括傑克孫維(Jacksonville)、坦帕(Tampa)及里奇蒙(Richmond)，共有約 103,143 棟建築。場景涵蓋都市、住宅區及住商混合區，都市大多是大型、間隔很近的建築物；住宅區大多是小型、間隔很近的建築，通常建物旁會種植樹木與其他植被；住商混合區則由中型建物和小型住宅建物組成。

上述五個資料集的高程模型由航空影像或光達資料產生，通常由光達資料產生的高程模型會比被動式光學影像透過多視圖三維重建技術產生的資料有更高的解析度，其提取與辨識三維物體特徵的能力也較佳(Goldberg et al., 2017)。例如：ISPRS 都市建模與語意標籤資料集中，使用航空影像產生的 14 公分空間解析度 DSM 中的建物邊角為弧形，特徵較不明顯；而點雲產生的 25 公分空間解析度 DSM 中建物的邊角較容易被區分，特徵也較

明顯（圖 4.2-14）。

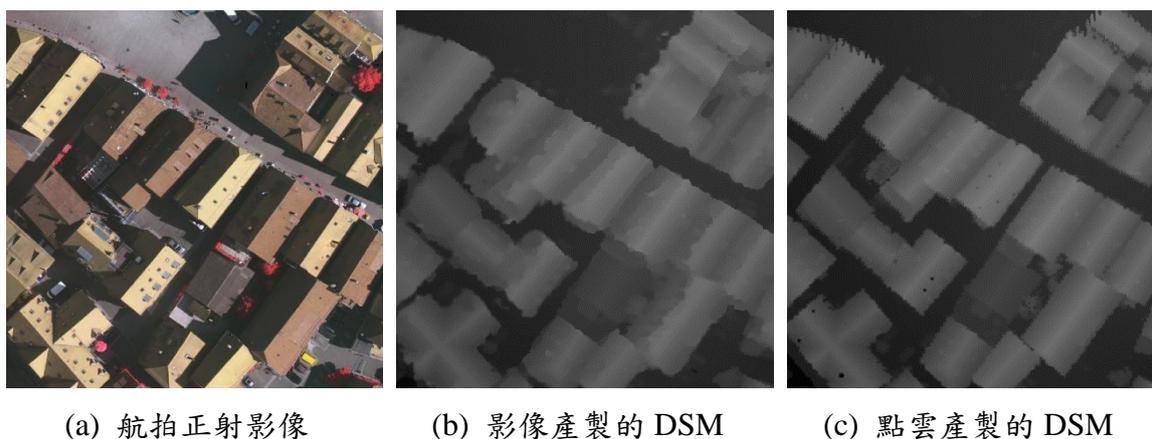


圖 4.2-14、比較不同方式產生的數值地表模型

以資料品質的角度探討，航空影像物體辨識(Aerial Imagery Object Identification, AIOI)、2018 IEEE GRSS 資料融合及 ISPRS 都市建模與語意標籤資料集皆提供品質相對較好的高空間解析度航空影像與 DSM。不過，比較資料集內建物型態與數量，AIOI 資料集較適合用於辨識臺灣房屋。因為此資料集影像拍攝自多座城市，場景涵蓋建物密度高的都市與建物密度低的郊區（圖 4.2-15），建物類型多元且數量僅次於都市三維挑戰標竿(Urban 3D Challenge Benchmark)資料集，再加上資料集內拍攝於華盛頓的建物影像與臺灣市區建築物的型態與外觀相似，有利於訓練用於辨識臺灣房屋的深度學習模型。因此，本項工作選擇 AIOI 資料集作為後續建立航遙測自動化地物智慧辨識與分類深度學習模型之訓練資料。

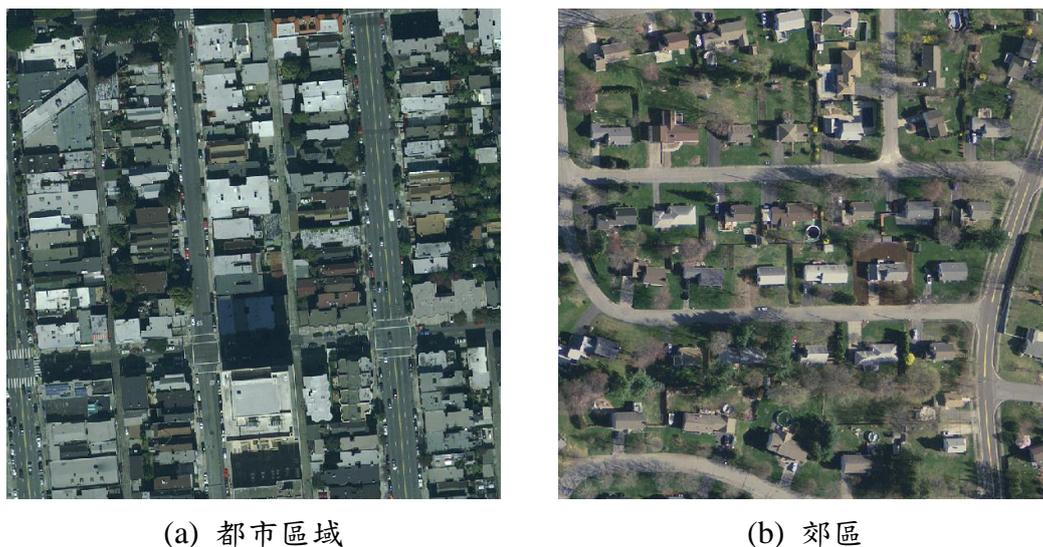
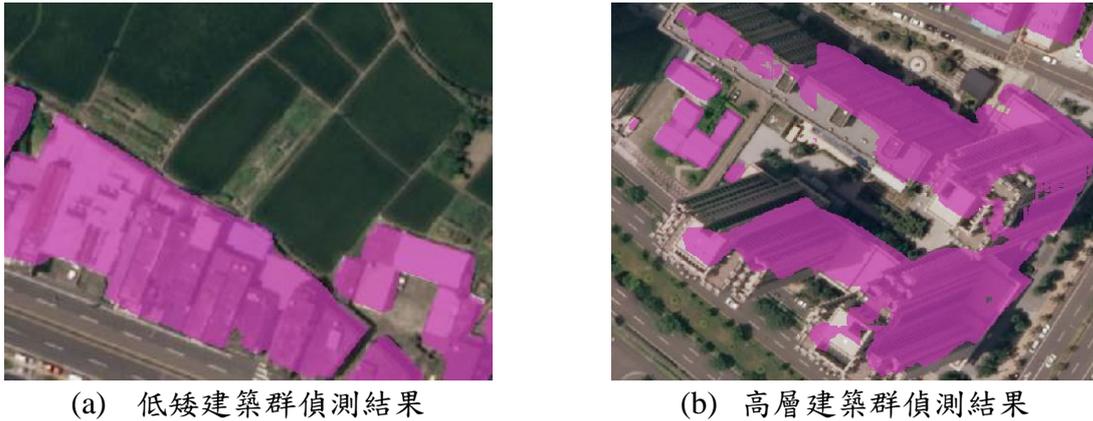


圖 4.2-15、AIOI 資料集內航空正射影像(Bradbury et al., 2016)

4.2.3 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效

本項工作之目的為利用深度學習神經網路萃取影像中房屋區域以建立自動化房屋智慧辨識技術，並評估偵測精度與成效。前期（110年）研究成果顯示，遙測影像中因地形起伏所產生的高差移位(Relief Displacement)會影響地物辨識品質與精度，以圖 4.2-16為例，低矮的建物與地表高度差異小，故高差移位小，房屋區域偵測效果較佳，可完整描繪屋頂以及整體建築（圖 4.2-16(a)）。然而，在高樓大廈林立的區域，建物與地表高度差異大，故高差移位大，造成房屋範圍偵測結果相對較差，無法正確且完整辨識房屋屋頂位置（圖 4.2-16(b)）。



(a) 低矮建築群偵測結果

(b) 高層建築群偵測結果

圖 4.2-16、前期房屋辨識成果有無受到高差移位的差別

Ortner et al., (2007)從高程模型萃取建築輪廓的實驗成果顯示，使用數值地表模型(Digital Surface Model, DSM)萃取地表高度急遽變化點(Height Jump)可偵測房屋範圍。經由點位連結形成房屋邊緣線，再以房屋邊緣線進行正規化處理後可獲得房屋輪廓線，故使用DSM將有利提升房屋智慧辨識。在融合航測影像與DSM的策略中，影像提供明銳的邊界資訊修正DSM邊緣，而DSM的地物高程可精化產生高程較為平整的房屋範圍（圖 4.2-17），因此，整合影像與DSM可提升房屋偵測成果(Wang et al., 2021)。

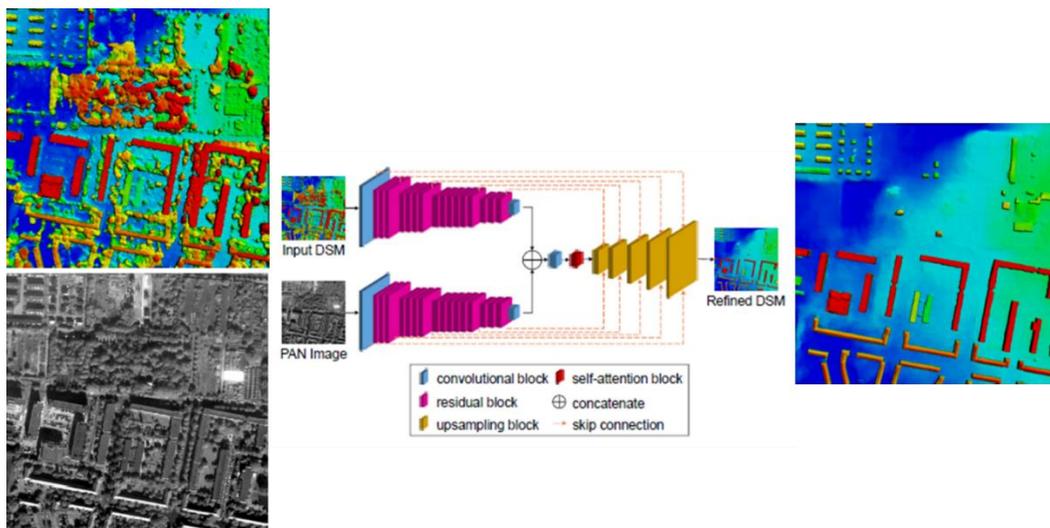


圖 4.2-17、精化數值地表模型設計架構 (Wang et al., 2021)

為了降低房屋高差移位之影響，本年度工作重點為結合影像及 DSM 建立房屋智慧辨識技術，提升房屋智慧辨識成果。本年度工作目標為使用多視角航測影像產製之正射影像與 DSM 進行房屋範圍識別與正規化。本項工作可分成三個部分，第一部分為經由文獻探討選擇適合的深度學習模型，建立資料融合房屋智慧辨識深度學習架構。第二部分為獲取航遙測影像、數值地表模型及房屋區域標籤之國際標竿訓練資料集進行初步訓練及精度分析，並進行房屋邊界正規化。本項工作使用由 Duke 大學建置之 Aerial Imagery Object Identification (AIOI)標竿資料集執行房屋辨識工作。AIOI 資料集的房屋型態多元且影像包含不同建築物密度的區域，故選用此資料集進行測試。第三部分為引入臺灣地區資料集執行遷移式學習，以臺灣資料集進行建築物辨識精度分析。本項工作具體成果為建立房屋智慧辨識模型架構與流程，並且利用國際公開資料集(AIOI)產成初始預訓練模型，以利遷移式學習提升辨識精度。

前期（110年）模型遇到的問題分別為：(1) 正射影像中多數高樓層建物有明顯的高差移位；(2) 正射影像中高樓層建物的屋頂範圍與臺灣通用電子地圖的房屋範圍不符。這兩項皆為資料面的問題，因應方法是使用 DSM 搭配多幅原始航空影像產製「DSM改正正射航照影像」，將所有建築物屋頂校正回到正射投影位置，以降低高差移位的影響。此外，根據前期經驗與成果分析得知選擇人工智慧學習模型架構的條件包含：

1. 前期討論傳統機器學習與深度學習方法優勢差異，由於深度學習在萃取建築物輪廓能力較佳，透過多次迭代尋求最佳特徵萃取的方式較傳統機器學習佳，故以深度學習架構為優先。
2. 深度學習架構需具備訓練資料之容錯能力，當訓練資料有些許錯誤需要自行尋求通用性高的特徵並且修正。例如：受到少量高差移位影響使建築物範圍標籤與影像部分範圍無對應，模型進行特徵分析時要專注於多數明顯的屋頂與周邊地面特徵而生成正確的辨識範圍。如圖 4.2-18，從紅框區域可看出建築範圍標籤與影像中建物相比，標籤整體範圍稍微向左上方偏移，不過在經過訓練後模型應能辨識大多數的房屋邊緣特徵，因此預測成果有修正標籤範圍偏移的問題。

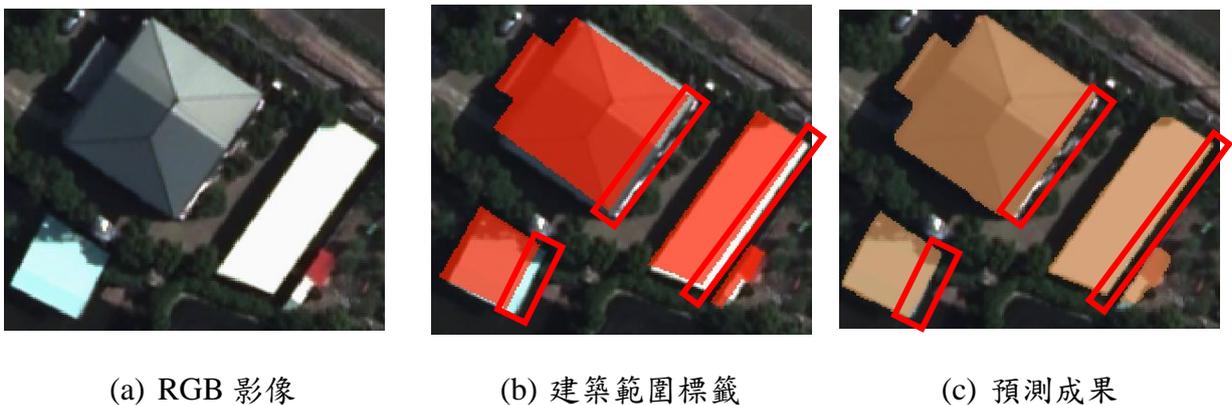


圖 4.2-18、建築範圍標籤稍微偏移應不影響預測成果

基於前述兩項需求而選定TransUNet (Chen et al., 2021)架構，以傳統U-Net進行修改，保留卷積網路以提供有效特徵萃取。萃取的高維度特徵採

用有自我專注能力的Transformer架構進行分析，最後再使用卷積網路將特徵還原為影像，模型架構如圖 4.2-19所示。

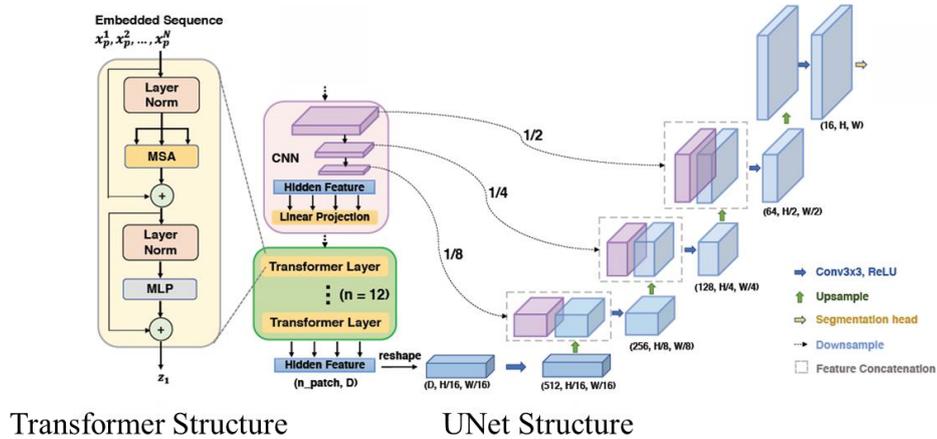
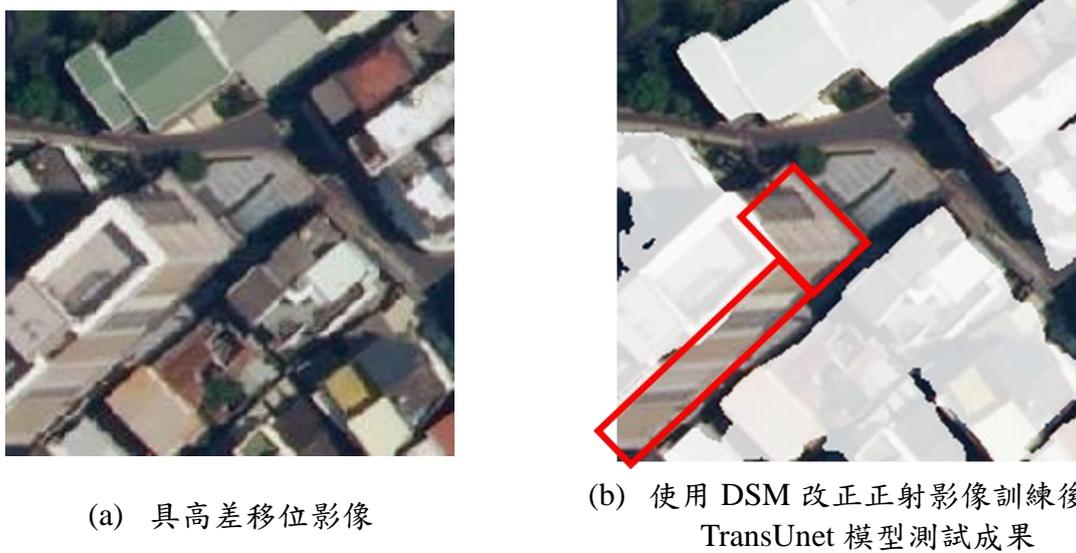


圖 4.2-19、TransUnet 模型架構圖(Chen et al., 2021)

為測試TransUNet模型，使用少量臺灣DSM改正正射影像進行TransUNet初步測試，利用有高差移位影像進行辨識成果（圖 4.2-20），此TransUNet模型可成功偵測屋頂區域，而不會誤判建築物外牆，有利本項工作房屋偵測之目的。



(a) 具高差移位影像

(b) 使用 DSM 改正正射影像訓練後
TransUnet 模型測試成果

圖 4.2-20、TransUnet 模型偵測有高差移位屋頂面的能力

決定TransUNet網路模型架構後，針對AIOI國際訓練資料集進行訓練及預測。表 4.2-6為房屋偵測精度成果，使用相同AIOI訓練資料集進行分析，其F1-Score精度表現可以達到97%。抽樣展示的成果如圖 4.2-21所示，預測TransUnet網路模型具良好的判釋能力。

表 4.2-6、AIOI 訓練及 AIOI 預測精度

Accuracy	Precision	Recall	F1-Score
99.09%	95.35%	99.71%	97.48%

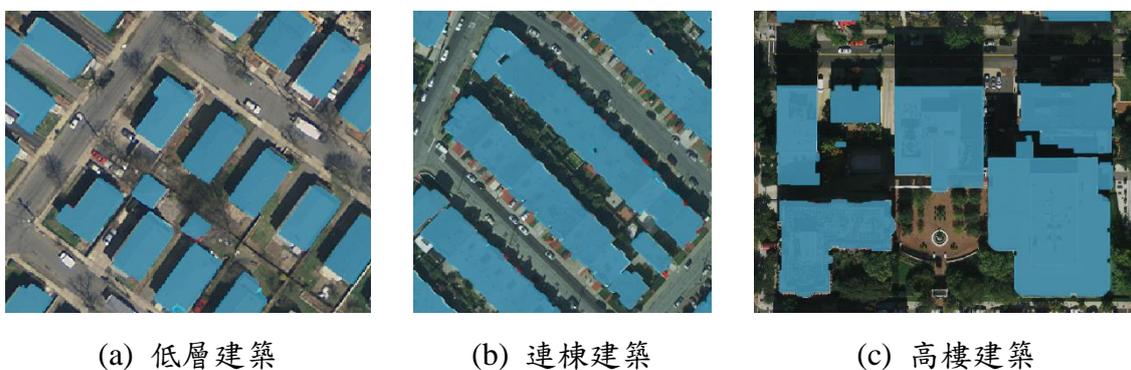


圖 4.2-21、TransUnet 模型偵測 AIOI 資料集房屋成果

本項工作進一步使用臺灣 DSM 改正正射影像與 DSM 資料測試 TransUNet 訓練深度學習模型。由於原始架構只有正射航照影像（RGB 影像）輸入層，故須修改網路架構整合 RGB 影像及 DSM（圖 4.2-22）。修改後的 TransUNet 網路架構中，各別萃取影像及 DSM 特徵並且共用權重，再經由 Concatenate 處理整合影像及 DSM 的 Transformer 之特徵。

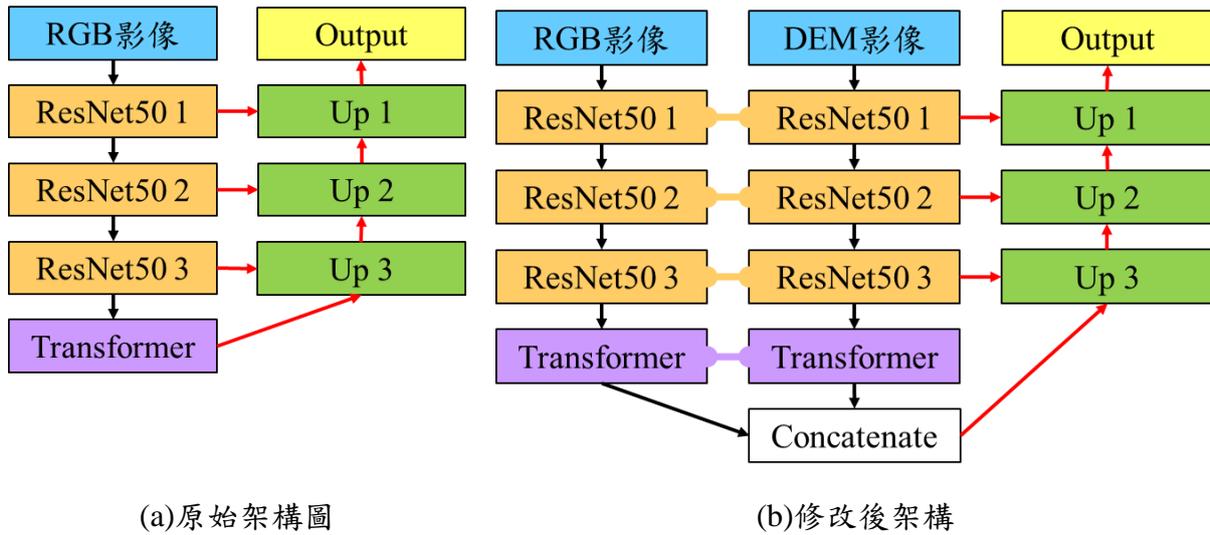


圖 4.2-22、TransUnet 模型架構修改

在測試TransUNet階段將只使用RGB影像訓練以及使用RGB+DSM，訓練，資料使用23幅臺灣通用電子地圖圖幅範圍，其中22幅進行訓練(80%)與驗證(20%)、1幅進行獨立檢核，影像裁切為224x224 pixel並且水平與垂直重疊率皆為50% (122 pixels)，訓練與驗證與獨立檢核區域如圖 4.2-23。

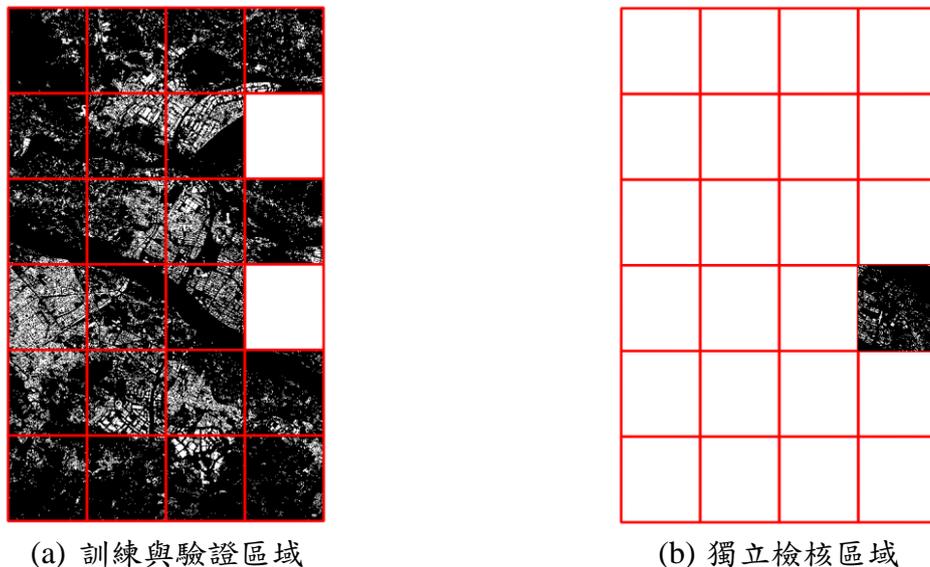


圖 4.2-23、訓練與驗證與獨立檢核區域地真標籤展示

RGB影像直接進行完整150 epochs訓練以現有設備需要120小時，對每

次存檔進行獨立檢核評估找出最佳成果為第93 epoch，評估成果如圖 4.2-24 所示。RGB+DSM直接進行完整150 epochs訓練以現有設備需要260小時，對每次存檔進行獨立檢核評估找出最佳成果為第121 epoch，評估成果如圖 4.2-25所示。

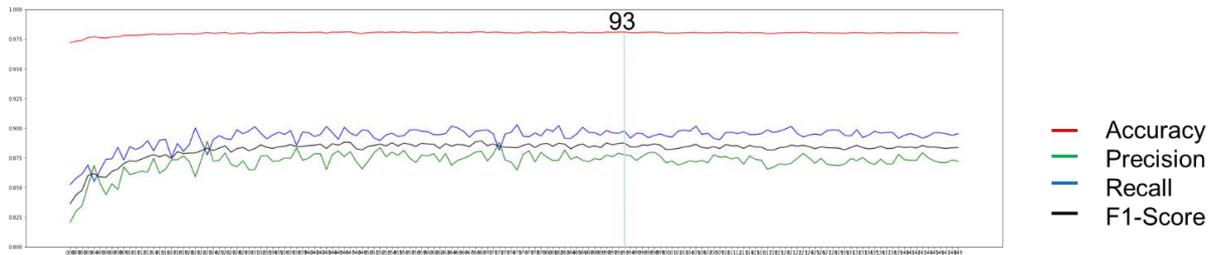


圖 4.2-24、RGB 直接訓練獨立檢核評估成果

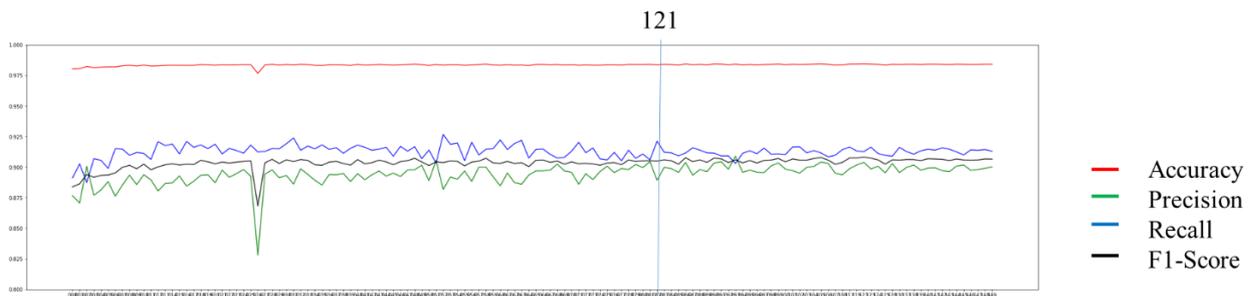


圖 4.2-25、RGB+DSM 直接訓練獨立檢核評估成果

訓練後偵測精度分析如表 4.2-7所示，RGB+DSM的各項精度指標都比只使用RGB影像的成果佳。偵測成果如圖 4.2-26所示，圖 4.2-26 (a)、(b) 比較紅色框內低矮建築的偵測成效，可明顯看出受惠於DSM擁有高度資訊，整合RGB影像與DSM能夠將建物與地面分離；圖 4.2-26 (c)、(d)紅色橢圓框為建築物之間的結構受到陰影遮蔽，透過DSM提供高度資訊讓此區域也能正確辨識。較常出現的誤判情況出現在施工中的工地如圖 4.2-27，經過檢

視是此資料集的特性有部分影像顯示還在施工中的建築已經在通用電子地圖上被標示為建築物。

綜合上述，評估視覺展示以及精度分析成果，使用RGB+DSM影像都優於只使用RGB影像，因此後續會選用RGB+DSM資料整合方式進行遷移式學習。

表 4.2-7、使用 RGB 與使用 RGB+DSM 最佳訓練成果獨立檢核評估指標

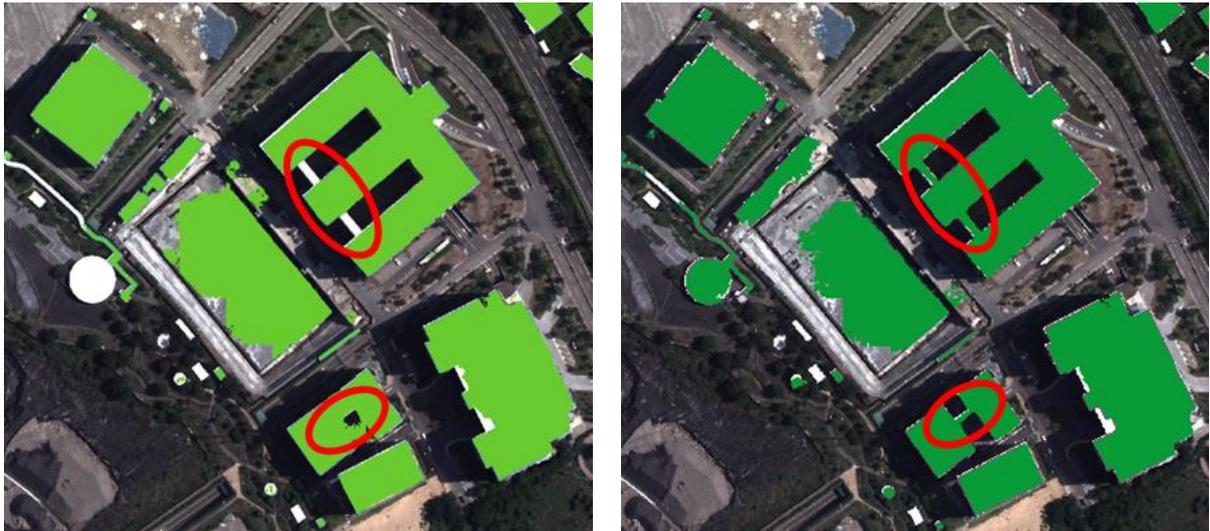
	Accuracy	Precision	Recall	F1-Score
RGB @ 93 epoch	98.15%	88.55%	89.66%	89.10%
RGB+DSM @ 121 epoch	98.44%	90.38%	91.26%	90.82%



(a) 純 RGB 影像



(b) RGB+DSM 影像



(c) 純 RGB 影像

(d) RGB+DSM 影像

圖 4.2-26、只使用 RGB 影像與使用 RGB+DSM 影像成果展示



圖 4.2-27、訓練資料中有部分工地被標示為建築物

遷移式學習以先前AIOI資料集訓練完成之模型作為良好初始值，對臺灣資料獨立檢核區進行多個模型存檔評估如圖 4.2-28所示，最終選擇使用評估指標F1-Score最佳第4 epoch與Precision最佳第14 epoch為預訓練模型，評估指標如表 4.2-8。圖 4.2-29為AIOI預訓練模型對臺灣獨立檢核區辨識成果，可見第4 epoch辨識結果比較粗糙，不過大致上正確涵蓋建築物，第14

epoch能夠辨識細部建築構造。

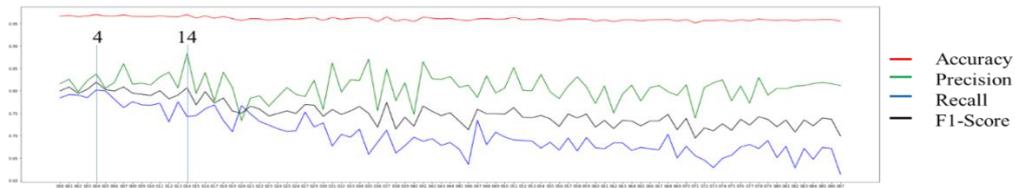


圖 4.2-28、AIOI 訓練後獨立檢核評估成果

表 4.2-8、AIOI 訓練第 4 epoch、第 14epoch 評估指標

	Accuracy	Precision	Recall	F1-Score
RGB+DSM @ 4 epoch	97.01%	83.76%	80.20%	81.94%
RGB+DSM @ 14 epoch	96.99%	88.29%	74.28%	80.68%



(a) 4 epoch 辨識成果



(b) 14 epoch 辨識成果

圖 4.2-29、AIOI 預訓練模型對臺灣獨立檢核區辨識成果

為使用相同條件比較直接訓練及遷移式學習，遷移式學習仍使用22幅進行訓練(80%)與驗證(20%)，另1幅進行獨立檢核。使用臺灣資料集進行訓練完整150 epochs並保持與直接訓練相同偽隨機數種子讓訓練過程可重現，由於訓練兩個模型以現有設備至少需要20天以上，因此使用國家高速網路與計算中心TWCC臺灣AI雲進行運算，租用4個GPU平行訓練共7天。訓練

完成後進行獨立驗證評估（評估成果如圖 4.2-30所示），兩個AIOI預訓練模型進行遷移式學習出現最佳成果消耗的時間接近，第4 epoch進行遷移式學習第94 epoch有最佳F1-Score評估指標、第14 epoch進行遷移式學習第83 epoch有最佳F1-Score評估指標，評估指標如表 4.2-9。相較於直接訓練最佳位於第121 epoch可減少約15%疊代次數，換算成現有設備可減少1.3天運算時間。現有設備為i7-9700K、32 GB RAM、RTX Titan 24 GB，AIOI訓練1 epoch 2.4小時，臺灣資料訓練1 epoch 1.7小時。

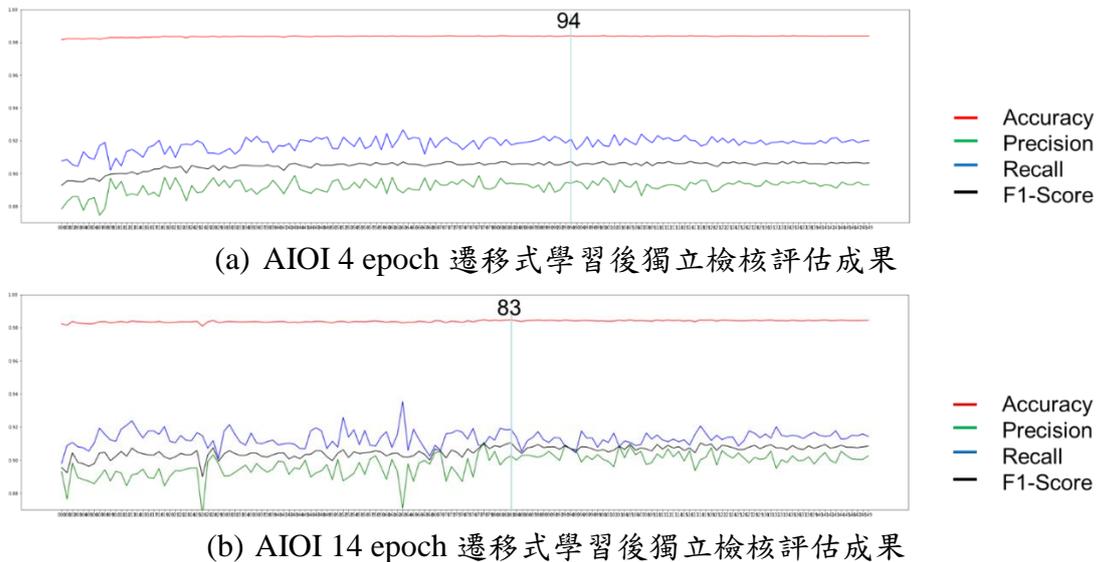


圖 4.2-30、遷移式學習獨立檢核評估成果

表 4.2-9、遷移式學習獨立檢核評估指標

	Accuracy	Precision	Recall	F1-Score
RGB+DSM @ 4 + 94 epoch	98.41%	89.39%	92.09%	90.72%
RGB+DSM @ 14+ 83 epoch	98.47%	90.25%	91.85%	91.04%

評估指標F1-Score最佳為AIOI第14 epoch進行遷移式學習第83 epoch，

此結果也優於直接訓練的F1-Score 90.82%，本項工作進行遷移式學習可以達成訓練時間縮短以及更佳預測成果（圖 4.2-31）。辨識漏授多是被植物遮蔽、工地或是遮雨棚，而誤授多是建築邊緣或是標籤上的建築物定義不清，在表 4.2-10展示數個案例。



(a) 地真標籤



(b) 4 + 94 epoch 辨識成果



(c) 14 + 83 epoch 辨識成果

圖 4.2-31、遷移式學習獨立檢核辨識成果

表 4.2-10、獨立檢核辨識漏授與誤授展示

	正射影像	地真標籤	最佳辨識成果
建築物被樹叢遮蔽 (漏授)			
影像顯示是工地但標示為建築物 (漏授)			
遮雨棚沒有辨識成功 (漏授)			
建築物邊緣 (誤授)			
標籤上的建築物定義不清 (誤授)			

4.2.4 精進航遙測影像結合測量實工作之智慧整合應用

因應數位科技發展，各項測繪業務逐漸隨著科技發展改變了作業的方法與程序，提高圖資品質與更新頻率並減少人力資源是測量技術發展的重要方向之一。無人飛行載具系統(Unmanned Aircraft Systems, UAS)、移動測繪系統(Mobile Mapper System, MMS)等行動測量系統皆為新興之測量技術，其中，無人飛行載具(Unmanned Aerial Vehicle, UAV)機動性強，已廣泛應用於測量等應用領域。利用 UAV 搭配攝影測量技術可快速獲取地面拼接影像，結合無人機影像及智慧辨識則可快速提供測量製圖所需的資訊。

「三維管線」是國土資訊系統重要的發展工作之一，而人孔是三維管線資料庫中必要的圖資，在內政部「公共設施管線資料標準（第 2 版）」（內政部營建署，2020）、「一千分之一數值航測地形圖測製作業規定」（內政部國土測繪中心，2011）、「高精地圖圖資內容及格式標準」（臺灣資通產業標準協會，2020）中人孔為必要圖資。前期（110 年）工作為評估導入無人機測繪技術於「人孔調查」測量實施作業，本年度工作目標為精進測量作業中無人機測繪技術及智慧製圖技術於「人孔調查」之整合應用。延續前期研究方法，應用深度學習模型進行人孔物件偵測，並探討不同解析度無人機影像於人孔偵測之效益。本項工作內容主要針對以下兩個部分進行精進，第一部分為使用不同空間解析度(2、5、10cm)之無人機正射

影像偵測人孔位置，並評估不同解析度之影像對偵測能力的影響；第二部分為使用無人機拍攝的多角度影像，利用密匹配方法產出地面高程值，結合智慧辨識之成果再經由平面擬合得到人孔所在的高度。本項工作具體成果為建立無人機影像自動化人孔辨識技術，整合密匹配高程資訊獲取人孔高程，並分析不同影像空間解析度之人孔精度評估。

本項工作整理三項人孔調查測量作業相關之規範，分析人孔圖徵類別及其量測精度規範，以探討使用無人機攝影測量於人孔智慧判釋的可行性，

表 4.2-11 整理人孔測量相關作業規範，說明如下：

表 4.2-11、人孔測量相關作業規範

	內政部 一千分之一數值航測地形圖 測製作業規定 內政部 100 年 2 月 9 日台內地字第 1000025069 號函修訂	內政部營建署 公共設施管線資料標準 NGISTD-ANC-028-2020.01.13 (內政部營建署，2020)	臺灣資通產業標準協會 高精地圖圖資內容及格式標準 TAICS TS-0024 v1.0
人孔相關物件	道路上(含人行道)之電力人孔、電信人孔、自來水人孔、雨污水下水道人孔、電線桿(電力、電信)、路燈等均需測繪，手孔及管線免予施測。	人孔類別包含: 1.電信管線的人孔(Manhole) 2.電力管線的人孔 3.自來水管線的人孔 4.污水及雨水下水道管線的人孔	人孔類別包含: 1.孔蓋: holeCover 2.水溝蓋: drainCover
精度要求	一千分之一數值航測地形圖成果檢查作業規定(內政部, 2011), 地形地物之幾何精度檢查: 抽查點位重複量測之平面位置與原平面位置之均方根誤差(RMSE)不大於 25 公分或地物點間之相對距離與原距離之均方根誤差不大於 40 公分。	人孔幾何精度要求: 1.孔蓋中心坐標測量, 其施測成果之坐標誤差應小於正負二十公分。 2.孔蓋蓋頂高程測量, 其高程為間接高程, 其施測成果之誤差應小於正負二十公分。	人孔幾何精度要求: 1.平面坐標誤差應小 20 公分。 2.三維坐標誤差應小 30 公分。

(1) 內政部「一千分之一數值航測地形圖測製作業規定」(內政部,2011), 規定道路上(含人行道)之電力人孔、電信人孔、自來水人孔、雨污水下水道人孔、電線桿(電力、電信)、路燈等均需測繪,手孔及管線則免予施測,圖 4.2-32 展示臺北市一千分之一數值地形圖不同的人孔類別編碼及圖示。依內政部「一千分之一數值航測地形圖成果檢查作業規定」探討人孔測量所需的量測精度,地形地物之幾何精度檢查中,抽查點位重複量測之平面位置與原平面位置之均方根誤差不大於 25 公分,或地物點間之相對距離與原距離之均方根誤差不大於 40 公分。

地形資料名稱	人孔		地形資料名稱	電信人孔	
基本地形圖資料庫地形編碼	96920		基本地形圖資料庫地形編碼	96925	
圖式	⊙		圖式	Ⓣ	
圖例碼	2207		圖例碼	2502	
顏色	0		顏色	0	
圖層	22		圖層	25	
地形資料名稱	電信人孔		地形資料名稱	電力人孔	
基本地形圖資料庫地形編碼	96924		基本地形圖資料庫地形編碼	96926	
圖式	Ⓣ		圖式	Ⓣ	
圖例碼	2501		圖例碼	2503	
顏色	0		顏色	0	
圖層	25		圖層	25	
地形資料名稱	污水排水溝蓋		地形資料名稱	地下排水溝蓋	
基本地形圖資料庫地形編碼	96921		基本地形圖資料庫地形編碼	96922	
圖式	Ⓣ		圖式	○	
圖例碼	2303		圖例碼	2304	
顏色	0		顏色	0	
圖層	23		圖層	23	

圖 4.2-32、臺北市一千分之一數值地形圖編碼及圖式(臺北市政府都市發展局,2004)

(2) 內政部「公共設施管線資料標準(第2版)」(內政部營建署,2020)之適用範疇為國內具有二維或三維數值坐標描述之設施與管線資料,包括歸屬於公共管線之電信管線、電力管線、自來水管線、下水道、瓦斯管線、

水管線、輸油管線、綜合管線等八大類管線，以及非屬公共設施管線之工業用管線。在管線標準圖例製作符號中，圓形人手孔直徑 3mm，圓形中為管線代號，下地之人手孔則於距孔蓋頂端 0.5mm 加一橫線代表；方形人手孔直徑 3mm，方形中為管線代號，下地之人手孔則於距孔蓋頂端 0.5mm 加一橫線代表(圖 4.2-33)。管線代號可分為電信(T)、電力(E)、自來水(W)、污水下水道(SS)、雨水下水道(SD)、瓦斯(G)、輸油(O)、綜合(C)以及工業用(P)。孔蓋中心坐標施測成果之坐標誤差應小於正負二十公分；孔蓋蓋頂高程測量，其高程為間接高程，施測成果之誤差應小於正負二十公分。



圖 4.2-33、電信人手孔圖例製作符號

(3) 在「高精地圖圖資內容及格式標準」(臺灣資通產業標準協會,2020)中，人孔的類別包含孔蓋(holeCover)及水溝蓋(drainCover)兩大類，其精度要求為孔蓋中心平面坐標誤差應小於正負二十公分，孔蓋中心三維坐標誤差應小於正負三十公分。

綜合以上三項人孔測量相關製圖規範，現行無人機攝影測量製圖作業可獲取空間解析度小於 10cm 的影像且空中三角測量作業可達到 10cm 以內的均方根誤差(國土測繪中心,2020)，因此有機會結合無人機攝影測量

與人工智慧技術於人孔測量實工作之智慧整合應用。

為評估導入無人機測繪技術於人孔智慧判釋作業，本項工作蒐集 36 幅（每幅 155m x 155m）無人機正射影像。影像拍攝地點為臺中市西屯區水湳經貿園區，面積共約 84 公頃，影像原始空間解析度為 2cm，空三定位精度小於 10cm，精度上滿足人孔調查測量作業之規範要求。36 幅影像中，其中 35 幅作為 Mask-RCNN 深度學習模型之訓練及驗證資料，另 1 幅則用於獨立驗證分析（圖 4.2-34）。

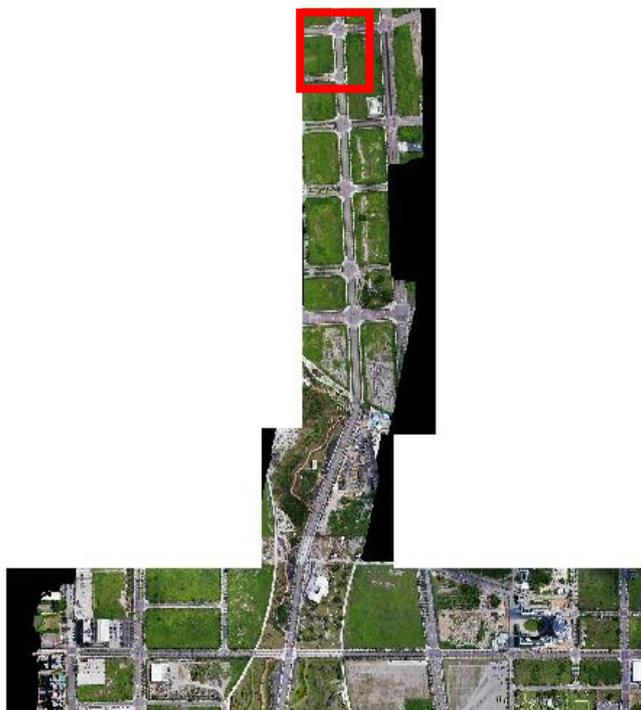


圖 4.2-34、人孔智慧判釋試辦資料（紅框：獨立驗證區）

將 2cm 影像空間解析度利用 QGIS 的 Batch Processing 批次處理，重新取樣(Resampling)採用三次內插(Cubic)，分別產製 5、10cm 的空間解析度，如圖 4.2-35。

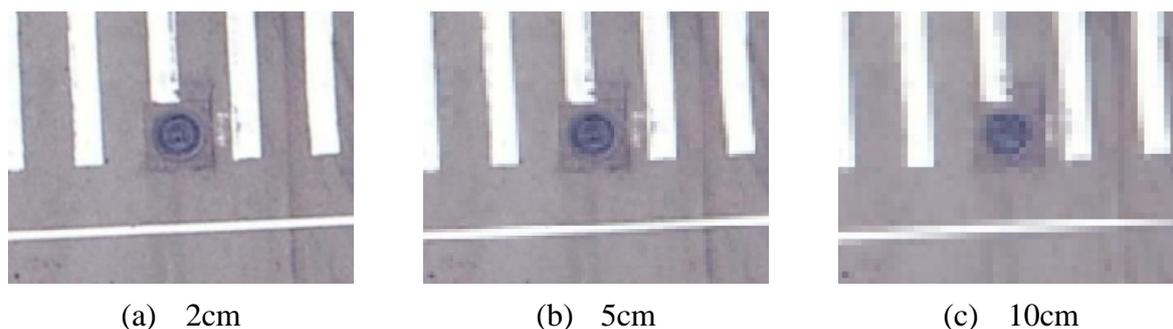


圖 4.2-35、比較不同空間解析度之無人機正射影像

受限於無人機影像的空間解析度，難以為影像上辨別不同人孔之紋理，故本項工作僅區分孔蓋(holeCover)與水溝蓋(drainCover)，孔蓋部分又細分成道路區間之孔蓋(holeCover)及非道路區間之孔蓋(holeCover2)(表 4.2-12)。透過人工數化無人機正射影像中人孔之位置，獲得原始人孔資料共 4,539 筆。為增加訓練資料，在訓練學習模型前將每幅影像切割成 512 x 512 pixels 大小的區塊(Patch)影像，並使區塊影像之間重疊 50% (圖 4.2-36)，以 50% 重疊率進行資料增益(Data Augmentation)後，完成人孔訓練資料建置。人孔資料增益成果如表 4.2-13 所示，36 幅影像對應不同空間解析度影像分別產生 15,817、17,731 及 17,468 筆人孔資料。

表 4.2-12、辨識類別分類

類別(classes)	drainCover	holeCover	holeCover2
特徵樣本			



圖 4.2-36、影像切割後人孔資料將獲得增益

表 4.2-13、原始與增益後之人孔資料

	原始人孔資料 (36 幅)	增益後人孔資料 (36 幅)		
		2cm	5cm	10cm
drainCover	2264	8069	9028	8867
holeCover	706	2401	2707	2714
holeCover2	1569	5347	5996	5887
總數	4539	15817	17731	17468

本次工作以 Mask-RCNN (He et al., 2017) 深度學習模型進行人孔物件偵測，藉由資料擴增技術增加訓練資料，並利用遷移式學習進行深度學習模型的訓練，最後完成影像語意分割的任務。為探討多尺度人孔偵測之效益比較，除了將不同空間解析度各自獨立為一個模型並預測，也將 2、5、10cm 的空間解析度整合為一個模型，因無人機攝影測量時，同一任務之影像空間解析度會受到不同航高影響，故設計具有多重影像空間解析度的整合模型，並預測不同空間解析度，如表 4.2-14 所示。表 4.2-15 與圖 4.2-37 為在獨立驗證中，不同影像空間解析度的深度學習模型預測成果精度評估，在 2cm 空間解析度的預測成果中，所有人孔類別之成功率與正確率皆大於 89%，但隨著空間解析度下降，成功偵測的比例也逐漸降低。

表 4.2-14、各訓練資料模型與影像資料庫的對應

影像資料庫	AI 模型
2cm	模型 1
5cm	模型 2
10cm	模型 3
2cm+5cm+10cm	模型 4

表 4.2-15、各模型對各空間解析度之人孔偵測成果

AI 模型	空間解析度	人孔是否被成功偵測			自動萃取人孔是否正確		
		成功	失敗	成功率	成功	錯誤	正確率
模型 1	2cm	195/218	23/218	89.45%	195/204	9/204	95.59%
模型 2	5cm	186/218	32/218	85.32%	186/199	13/199	93.47%
模型 3	10cm	137/218	81/218	62.84%	137/155	18/155	88.39%
模型 4	2cm	195/218	20/218	90.83%	198/214	16/214	92.52%
模型 4	5cm	183/218	35/218	83.94%	183/192	9/192	95.31%
模型 4	10cm	98/218	120/218	44.95%	98/103	5/103	95.15%

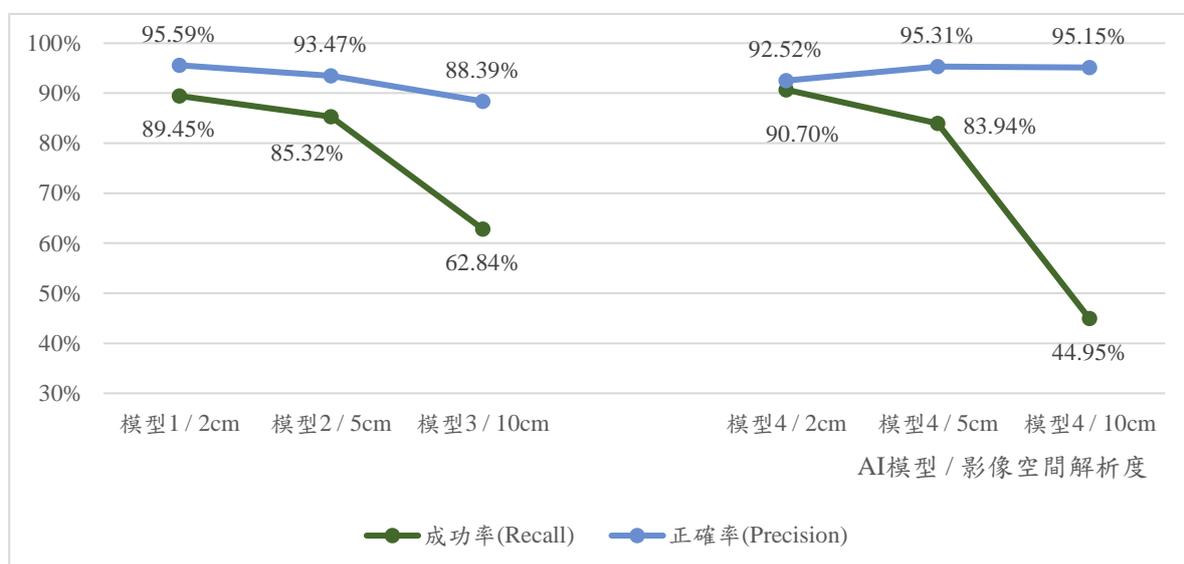


圖 4.2-37、人孔偵測之成功率與正確率

表 4.2-16 為將表 4.2-15 各模型中成功偵測的人孔蓋總數進行平面誤差分析，在空間解析度為 2cm 時，平面誤差小於 10cm 的比例可達 99%；

空間解析度為 5cm 時，平面誤差小於 10cm 的比例可達 95%；空間解析度為 10cm 時，平面誤差小於 10cm 的比例可達 85%。

表 4.2-16、各模型對各空間解析度之人孔偵測—平面誤差成果分析

AI 模型	空間解析度	<5cm (個)	<5cm (%)	<10cm (個)	<10cm (%)	>10cm (個)	>10cm (%)	總數 (個)
模型 1	2cm	187	95.90%	192	98.46%	3	1.54%	195
模型 2	5cm	143	76.88%	180	96.77%	6	3.23%	186
模型 3	10cm	58	42.34%	117	85.40%	20	14.60%	137
模型 4	2cm	191	96.46%	197	99.49%	1	0.51%	198
模型 4	5cm	147	80.33%	174	95.08%	9	4.92%	183
模型 4	10cm	37	37.76%	86	87.76%	12	12.24%	98

無人機正射影像使用 TWD97 橫麥卡托二度分帶(TM2)投影系統，經由智慧辨識可偵測人孔並獲取人孔在物空間的坐標位置。透過 e-GNSS 現地測量及智慧辨識人孔的形心坐標，計算形心坐標間之差值以評估辨識精度。

表 4.2-17 以現地測量之人孔形心作為參考依據，統計利用深度學習模型自動萃取及現地測量的人孔形心間之距離差異量。由統計成果可知，在空間解析度 2cm 中的自動化偵測與現地測量成果的均方根誤差，平面誤差小於 5 公分，並隨著空間解析度越差，誤差量會越大；而高程誤差在不同空間解析度下約為 15cm。

表 4.2-17、智慧辨識與現地測量之人孔形心的距離差異量

AI 模型	空間解析度	MeanError			RMSE		
		dE (cm)	dN (cm)	dh (cm)	dE (cm)	dN (cm)	dh (cm)
模型 1	2cm	0.27	-3.65	-14.37	3.95	4.41	15.03
模型 2	5cm	-0.24	-4.86	-14.39	5.00	5.96	15.05
模型 3	10cm	1.06	-4.90	-14.00	7.63	6.98	14.74

AI 模型	空間 解析度	MeanError			RMSE		
		dE (cm)	dN (cm)	dh (cm)	dE (cm)	dN (cm)	dh (cm)
模型 4	2cm	-0.70	-3.46	-14.39	4.05	4.21	15.05
模型 4	5cm	-2.11	-4.18	-14.35	5.16	5.40	15.03
模型 4	10cm	-4.10	-5.04	-14.20	6.72	6.80	14.80

表 4.2-18 為智慧辨識有成功偵測現地測量之人孔蓋總數，進行平面誤差分析。現行精度規範為平面誤差應小於 10cm，本次成果在空間解析度為 2cm 時，平面誤差小於 10cm 的比例可達 95%；空間解析度為 5cm 時，平面誤差小於 10cm 的比例可達 84%；空間解析度為 10cm 時，平面誤差小於 10cm 的比例可達 60%。

表 4.2-18、智慧辨識與現地測量之平面誤差成果分析

AI 模型	空間 解析度	<5cm (個)	<5cm (%)	<10cm (個)	<10cm (%)	>10cm (個)	>10cm (%)	總數 (個)
模型 1	2cm	45	45.92%	94	95.92%	4	4.08%	98
模型 2	5cm	26	26.26%	84	84.85%	15	15.15%	99
模型 3	10cm	23	29.11%	48	60.76%	31	39.24%	79
模型 4	2cm	48	48.98%	93	94.90%	5	5.10%	98
模型 4	5cm	35	36.84%	82	86.32%	13	13.68%	95
模型 4	10cm	17	28.81%	40	67.80%	19	32.20%	59

備註：現地測量中，共測得 100 個人孔蓋中心。

利用無人機多視角影像，以影像密匹配產生地面點，取得該區域的地面高程，並與現地測量成果進行高程誤差分析，如表 4.2-19 所示。現行精度規範為高程差應小於 20cm，人孔智慧辨識在高程誤差小於 20cm 的比例可達 91%。

表 4.2-19、智慧辨識與現地測量之高程誤差成果分析

AI 模型	空間解析度	<10cm (個)	<10cm (%)	<20cm (個)	<20cm (%)	>20cm (個)	>20cm (%)	總數 (個)
模型 1	2cm	15	15.31%	90	91.84%	8	8.16%	98
模型 2	5cm	15	15.15%	91	91.92%	8	8.08%	99
模型 3	10cm	15	18.99%	72	91.14%	7	8.86%	79
模型 4	2cm	15	15.31%	90	91.84%	8	8.16%	98
模型 4	5cm	14	14.74%	87	91.58%	8	8.42%	95
模型 4	10cm	10	16.95%	54	91.53%	5	8.47%	59

備註：現地測量中，共測得 100 個人孔蓋中心。

綜整實驗成果與分析，無人機影像與人工智慧技術之智慧整合可輔助「人孔調查」測量施測作業，其預測成果亦可從網格式資料模式轉換成向量式資料模式（圖 4.2-38），供給後續測量製圖運用。

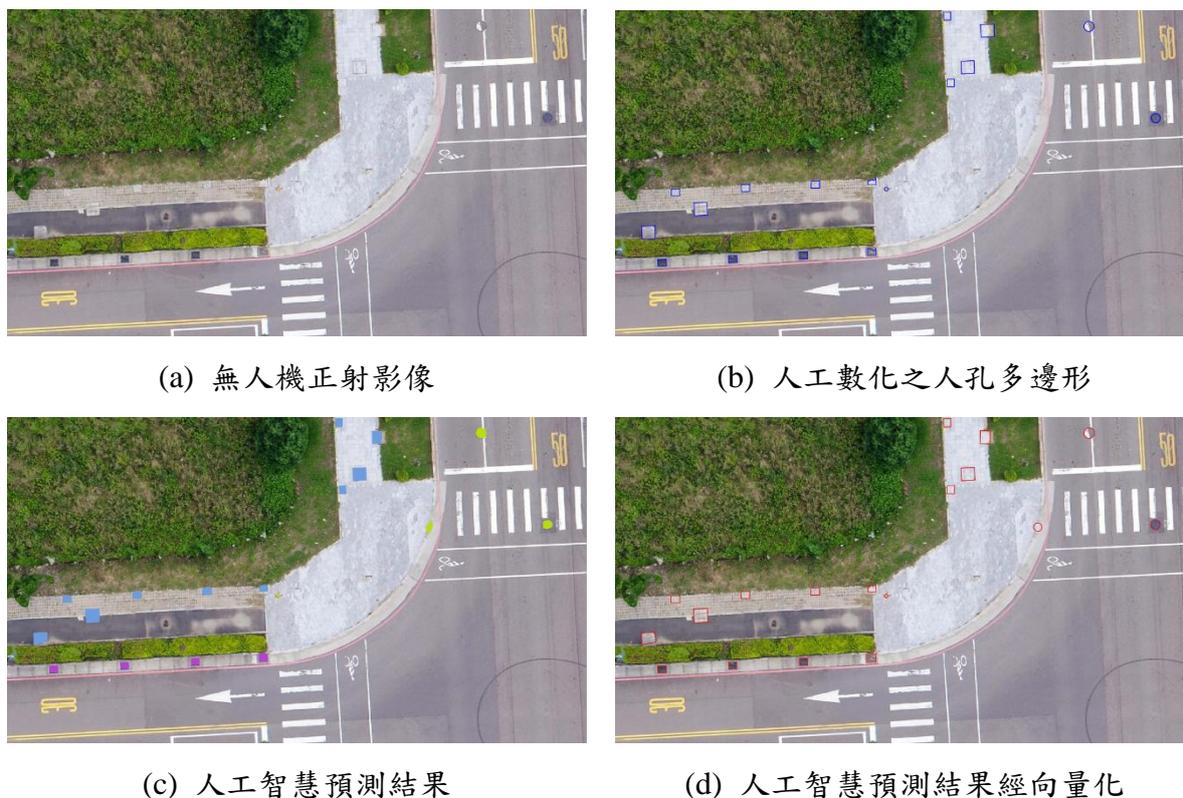


圖 4.2-38、人孔智慧辨識成果

試辦成果顯示，影響偵測成果的主要因素為兩點：第一點為遮蔽問題，受到樹木、車輛等部分或完全遮蔽，使得電腦無法清楚進行偵測；第二點為影像空間解析度，影像的細緻度將影響整體辨識成果。在無人機影像空間解析度為 2cm 時，獨立檢核區的成功率及正確率均達到 90%，人孔中心坐標與現地測量成果比較，平面均方根誤差小於 10cm 達到 95%，高程均方根誤差小於 20cm 達到 90%。隨著空間解析度的下降，其偵測成果的成功率與正確率均會有所下降，因此建議人孔尺度的智慧辨識採用優於 5cm 空間解析度之影像。

4.3 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦

4.3.1 利用雷達衛星影像地表形變分析，建立臺灣各地初步形變分析圖資，至少包含全臺灣 C-波段多時期雷達影像，及選定之災害潛勢區域 L-波段與 X-波段雷達影像；前述潛勢區域之選定須至少 2 處，並與內政部討論定案，任 1 處之辦理面積須達 200 平方公里以上，且運用包含（或優於）3 公尺解析度之影像在內進行分析

本項工作前期（109、110 年）以影像分析與處理為主，本年度逐步建立影像處理之參數數據庫與經驗，以供後續人工智慧參數學習之基礎，同時亦逐步建立臺灣各地的初步形變分析圖資。本次期末報告完成五年期間之全臺灣 PSInSAR 相對形變速率觀測（C 波段）、臺北港區填海造陸（X 波

段)與高雄美濃地震(L波段)地表形變分析之試辦成果。各波段研究成果如下：

(1) C 波段多時期雷達影像地表形變試辦—全臺灣多時期形變監測

雷達衛星影像應用分為兩個部分進行，第一部分為全臺灣多時期形變監測試辦，規劃利用歐洲太空總署(European Space Agency, ESA)發射之 C 波段雷達衛星 Sentinel-1 所拍攝之影像來進行分析。Sentinel-1 衛星為歐洲太空總署哥白尼計畫(Copernicus Programme)的衛星任務之一，該計畫預計發射多顆地球觀測衛星，組成全球環境監測網路，提供全球環境保護、海洋觀測、歐洲政策、民間防禦、維和行動等用途。Sentinel-1 為該計畫之首顆資源衛星，由 A/B 兩顆衛星構成星系，提供最高 6 天的再訪周期，優異的 C 波段雷達感測器能提供最高五米的空間解析度與寬達 400 公里的幅寬，相當適合用作大範圍的地表監測用途。Sentinel-1A 於 2014 年 4 月發射成功，2014 年 10 月開始提供涵蓋臺灣地區之影像，Sentinel-1B 亦於 2016 年 4 月發射成功，由於 1B 觀測目標區規劃與 1A 不同，因此於臺灣地區僅拍攝北部之影像，故涵蓋全臺灣的形變監測僅能以 Sentinel-1A 影像進行。本年度工作規劃拓展全臺灣形變監測之觀測時間，由前期計畫之 2016 至 2020 年延伸為 2017 至 2021 共五年之形變觀測成果。

本節之全臺灣多時期形變監測試辦採用雷達差分干涉技術來產生多時序的地表形變成果，技術細節與影像處理流程參照 4.1.1 節說明，蒐集自 2017

年至 2021 年全臺灣共 128 張之 Sentinel-1 影像，完成五年期間之全臺灣 PSInSAR 相對形變速率觀測成果，見圖 4.3-1，圖中每個 PS 點皆為具有 128 期觀測值之獨立資料，配合軟體處理即能分析出五年期間形變之時間序列。成果可見自 2017 年至 2021 年五年期間全臺灣地表形變狀況，其中以雲林地區之地層下陷、2018 年花蓮地震產生的地形變狀況最為顯著，雲林地區之地層下陷速率測得每年下陷約 5 公分，需注意地震事件屬於瞬間發生的事件型地表形變，花蓮地震事件發生當下產生約 15 公分的地表形變，但由於觀測期間為五年，因而最後以呈現為約每年 30mm 之形變速度，於形變解釋時需要特別小心。

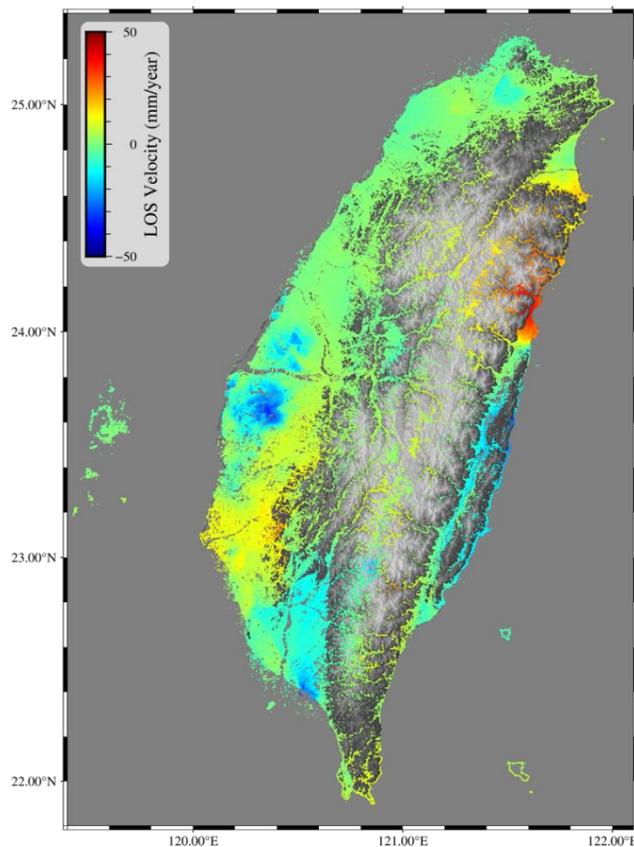
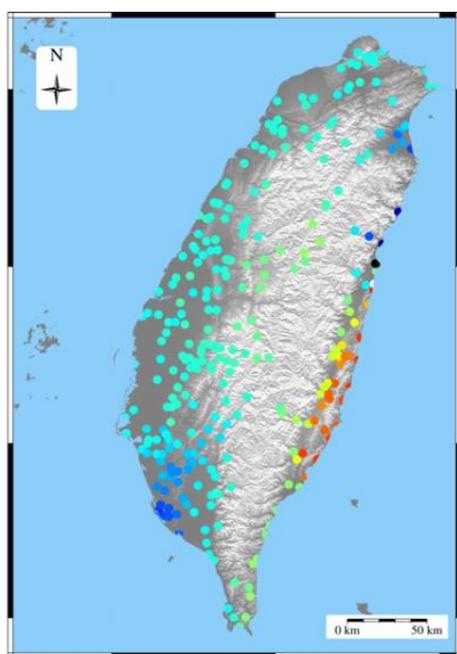
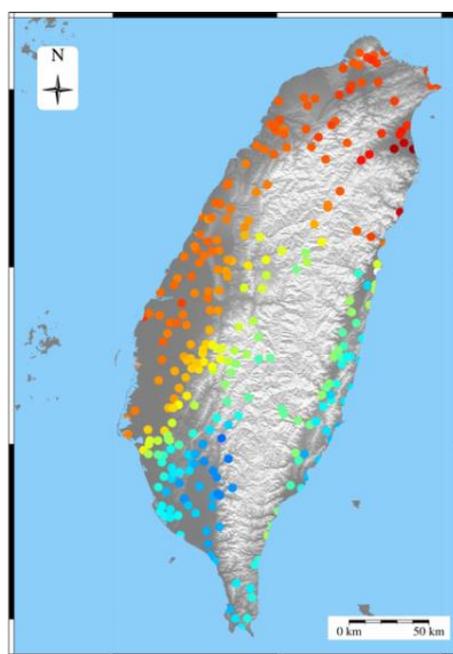


圖 4.3-1、全臺灣五年(2017-2021)多時期形變監測試辦成果

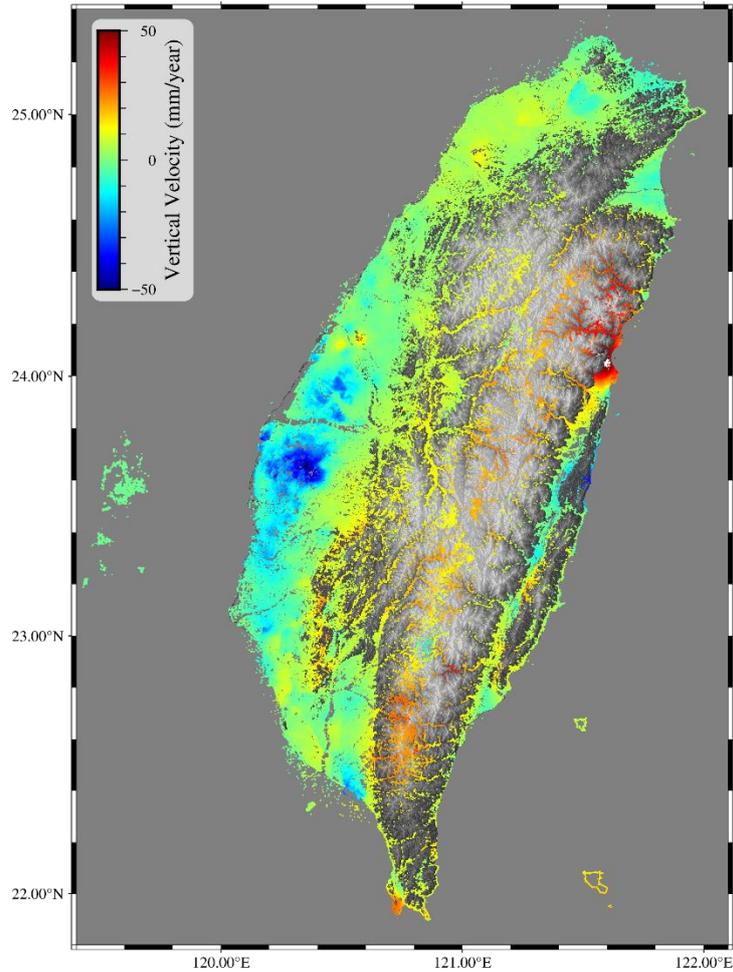
永久散射體雷達差分干涉法測得 PS 多時序形變乃是雷達衛星視角方向 (LOS) 變形量，可以看做是東西、南北及垂直這三維空間上的變形，以一維方向的衛星視角方向呈現的綜合觀測量，因此在利用雷達影像評估垂直向變形時，會受到水平方向變形的貢獻而產生誤判。本年度延續採用結合 GNSS 觀測之垂直形變量分析，雷達衛星受觀測幾何影響，沿衛星飛行方向的地表變化（南北向之位移）較不敏感，對垂直向的變化較為敏銳；相反的，GNSS 則對水平向的運動較為敏銳，對垂直向的位移較為不敏感。取 GNSS 觀測資料的優點，衛星視角方向中水平方向位移量的貢獻可利用 GNSS 所觀測之水平向位移去除，剩餘部分為垂直向的貢獻(簡留玄, 2020)，三維形變分析成果見圖 4.3-2。



(a) GNSS 東西向累積形變量



(b) GNSS 南北向累積形變量



(c) PSInSAR 垂直向累積形變量

圖 4.3-2、全臺五年(2017-2021) PSInSAR 三維平均速度成果圖

經過垂直變形解算後，結果與原始衛星視角方向之變形速度存在一定差異，較顯著的差異為彰化雲林地層下陷區，在衛星視角方向之下陷速度有低估之情況，經過修正後低估的狀況已經改善，另外如中央山脈南段於 LOS 方向呈現略為下沉的趨勢，主要由於水平方向遠離衛星的趨勢主導了衛星視角方向的測量結果，去除水平方向變形後可見實際上中央山脈呈現緩慢抬升的狀態。由此可見在大範圍的形變研判上，經 GNSS 解算後的垂

直變形相較於衛星視角方向變形更加的可靠。

(2) X 波段多時期雷達影像地表形變試辦—臺北港區填海造陸

X 波段之雷達衛星採用德國太空總署(DLR)發射之超高解析度 X 波段雷達衛星 TerraSAR-X 所拍攝之影像，目前 TerraSAR-X 系列衛星共有 3 顆衛星，TerraSAR-X 於 2007 年發射，二號衛星 TanDEM-X 於 2010 年發射，而第三顆衛星 PAZ 也於 2018 年升空，三顆衛星皆由法國空中巴士公司 (Airbus) 負責營運，提供最高 11 天的再訪周期，TerraSAR-X 衛星能夠採用特殊的 Staring Spotlight 模式進行拍攝，於該拍攝模式下解析度高達 25 公分，但該模式拍攝範圍僅 4x4 公里，適合特定目標之觀測，而大範圍的地表形變監測通常採用 StripMap 拍攝模式，該模式之地面解析度為 3 公尺，雖低於 Staring Spotlight 但具有 50 公里的幅寬，TerraSAR-X 詳細拍攝規格見表 4.3-1。

表 4.3-1、TerraSAR-X 拍攝模式列表

拍攝模式	像幅大小 (寬 x 長)	解析度
Staring Spotlight	4 x 3.7 km ²	0.25 公尺
High Resolution Spotlight	10 x 5 km ²	1 公尺
Spotlight	10 x 10 km ²	2 公尺
StripMap	30 x 50 km ²	3 公尺
ScanSAR	100 x 150 km ²	18.5 公尺
Wide ScanSAR	270 x 200 km ²	40 公尺

本項工作試辦區選定為臺北港，臺北港位於淡水河口，該區域海象相對平靜，加上陸上交通便利，鄰近桃園機場，使其成為兼具海空聯運功能

的國際型物流加值港。臺北港為人工港，完全使用填海造陸方式興建，為配合政府推行循環經濟政策，以及解決公共工程土方去化問題，臺北港填海造地案規劃收容工程餘土、水庫清淤土方及再生粒料等來源作為填築資材，本處使用之再生粒料由於其具有含水後可能膨脹的特性，為了解填築過程中是否會對於海堤結構造成影響，故進行針對臺北港物流倉儲區之海堤進行長期性的形變監測。

X 波段多時期雷達影像地表形變試辦成果見圖 4.3-3，底圖為 Pleiades 高解析度光學影像，暖色系代表於衛星視角方向地表呈現抬升，冷色系為下沉。主要觀測目標為北側海堤，取樣 A、B、C 三點，結果 A 點呈現每年 -6.1mm 之變形速度，B 點呈現每年 -9.0mm 之變形速度，C 點呈現每年 7.4mm 之變形速度，表示該處海堤於觀測間變形趨勢並不一致，有微量的差異變形狀況，其中 C 點更是呈現略微抬升的狀態。

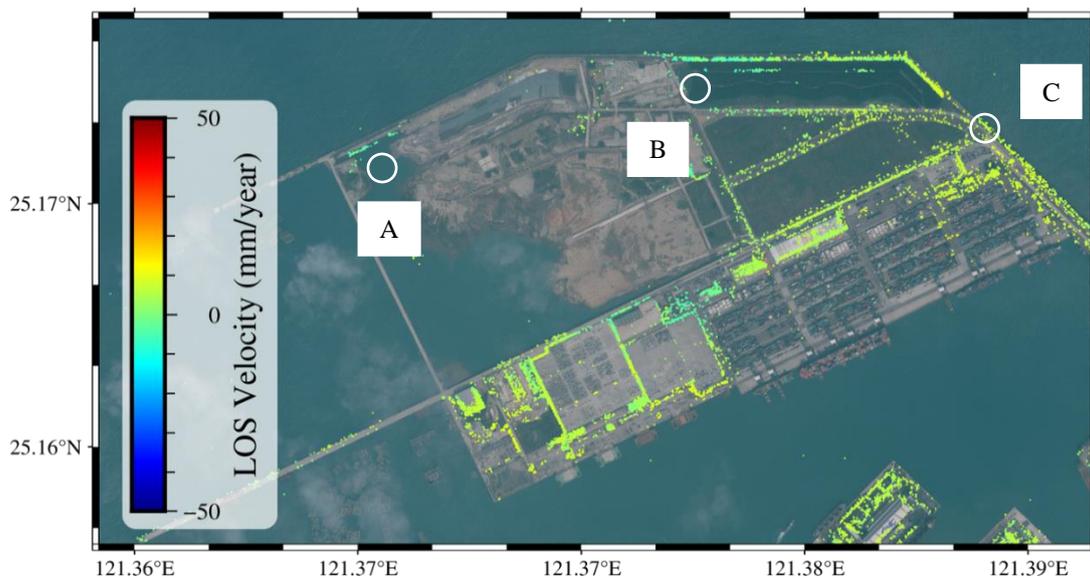


圖 4.3-3、臺北港 PSInSAR 年平均速度成果

A、B、C 三點 PS 時間序列分析成果見圖 4.3-4、圖 4.3-5 與圖 4.3-6，由成果可見三處皆呈現下沉的變形狀態，其中 B 點下沉狀態最為嚴重，變形的時間主要集中於 2021 年上半年，後續的累積變形量則較不顯著。另外 C 點可能因為第三期累積變形量之誤差進而導致變形速度的計算與實際有出入，實際變形趨勢為略有下沉，但累積變形量極小。

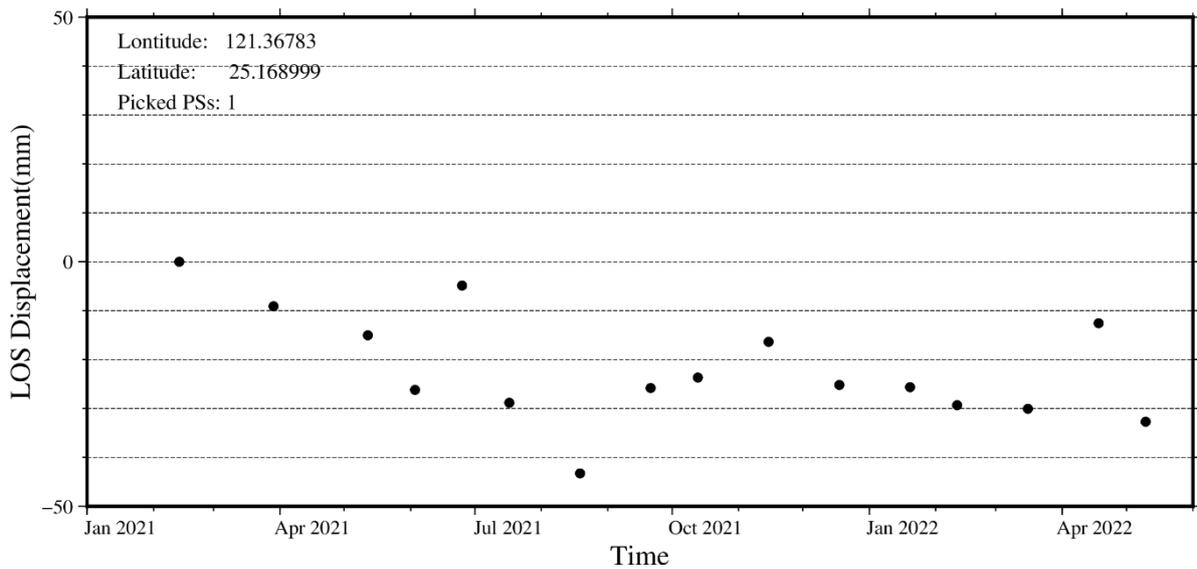


圖 4.3-4、臺北港 A 點海堤 PSInSAR 時間序列

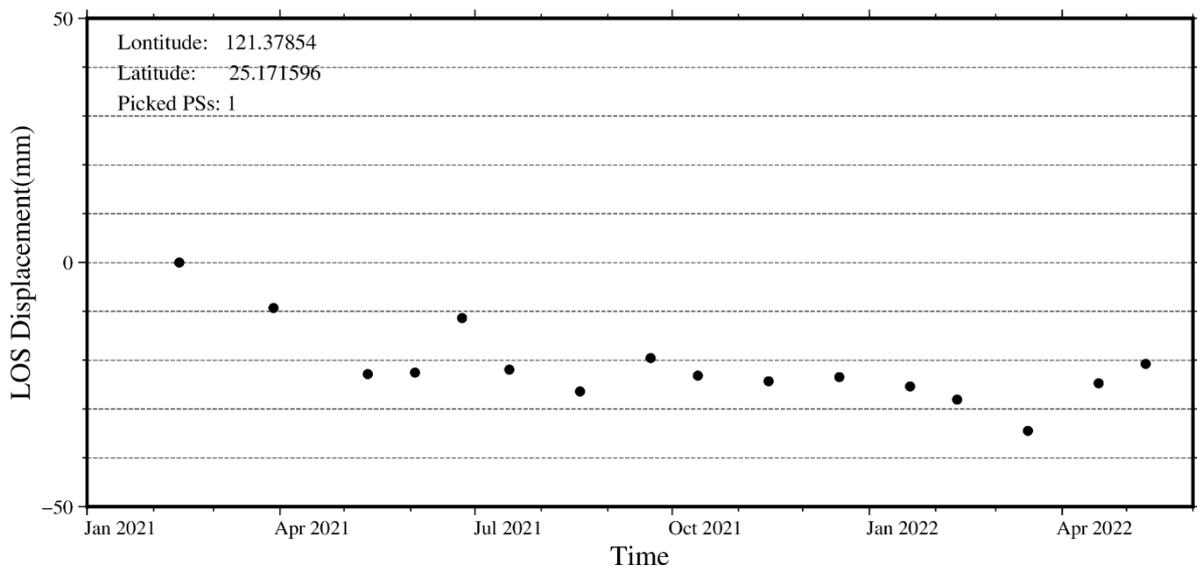


圖 4.3-5、臺北港 B 點海堤 PSInSAR 時間序列

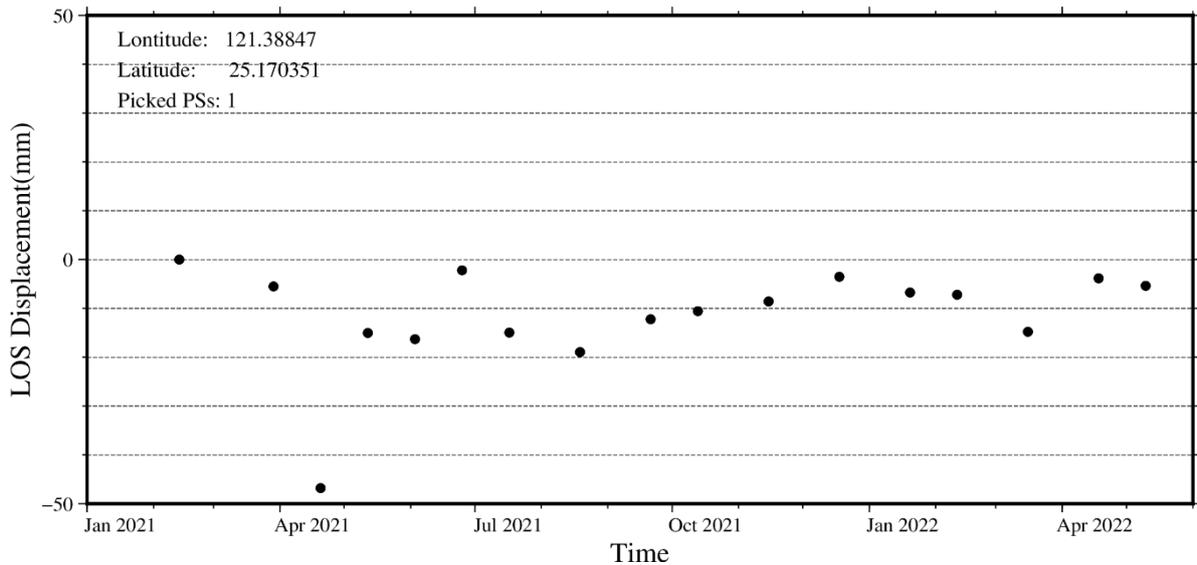


圖 4.3-6、臺北港 C 點海堤 PSInSAR 時間序列

(3) L 波段雷達影像地表形變試辦－高雄美濃地震

L 波段之雷達影像採用日本太空總署發射之雷達遙測資源衛星 ALOS-2 拍攝之影像，ALOS-2 衛星全名為進階地表觀測衛星(Advanced Land Observing Satellite)，為日本地球觀測衛星計畫中，負責針對陸地區域進行觀測的衛星，其主要工作為製圖、環境監測、災害監測及自然資源調查等。第一代 ALOS 衛星於 2007 年升空運行，2011 年除役，而目前運行中的 ALOS-2 為該計畫之第二代遙測資源衛星，於 2014 年升空，配備的 L 波段雷達感測器 PALSAR-2 改良自 ALOS 搭載之 PALSAR，具備最高 1 公尺的地面解析度，並且可以使用更多元的拍攝模式進行觀測，詳細之拍攝模式參數見表 4.3-2，衛星在訪週期為 14 天。

表 4.3-2、ALOS-2 拍攝模式列表

拍攝模式	像幅大小 (寬 x 長)	解析度
Spotlight	25 x 25 km ²	1 公尺
Ultra-Fine StripMap	55 x 70 km ²	3 公尺
High-Sensitive StripMap	55 x 70 km ²	4.3 公尺
Fine StripMap	70 x 70 km ²	5.3 公尺
ScanSAR	350.5 x 355 km ²	77.7 公尺
ScanSAR Wide	489.5 x 355 km ²	112 公尺

本項工作選定試辦區域為臺南高雄地區，利用 2015 年 11 月 26 日與 2016 年 2 月 18 日兩張雷達影像組成之影像對觀測 2016 年 2 月 6 日之高雄地震事件造成的地表形變，成果見圖 4.3-7，暖色系代表於衛星視角方向地表呈現抬升，冷色系為下沉，由成果可見高雄地震之地表最大形變發生於臺南地區，後續針對圖 4.3-8 左圖之白線進行剖面分析，可知形變中心之最大變形量達 150mm，成果可以解釋為何臺南為該次地震之重災區，其中臺南維冠金龍大樓倒塌更是直接造成百餘人喪生。

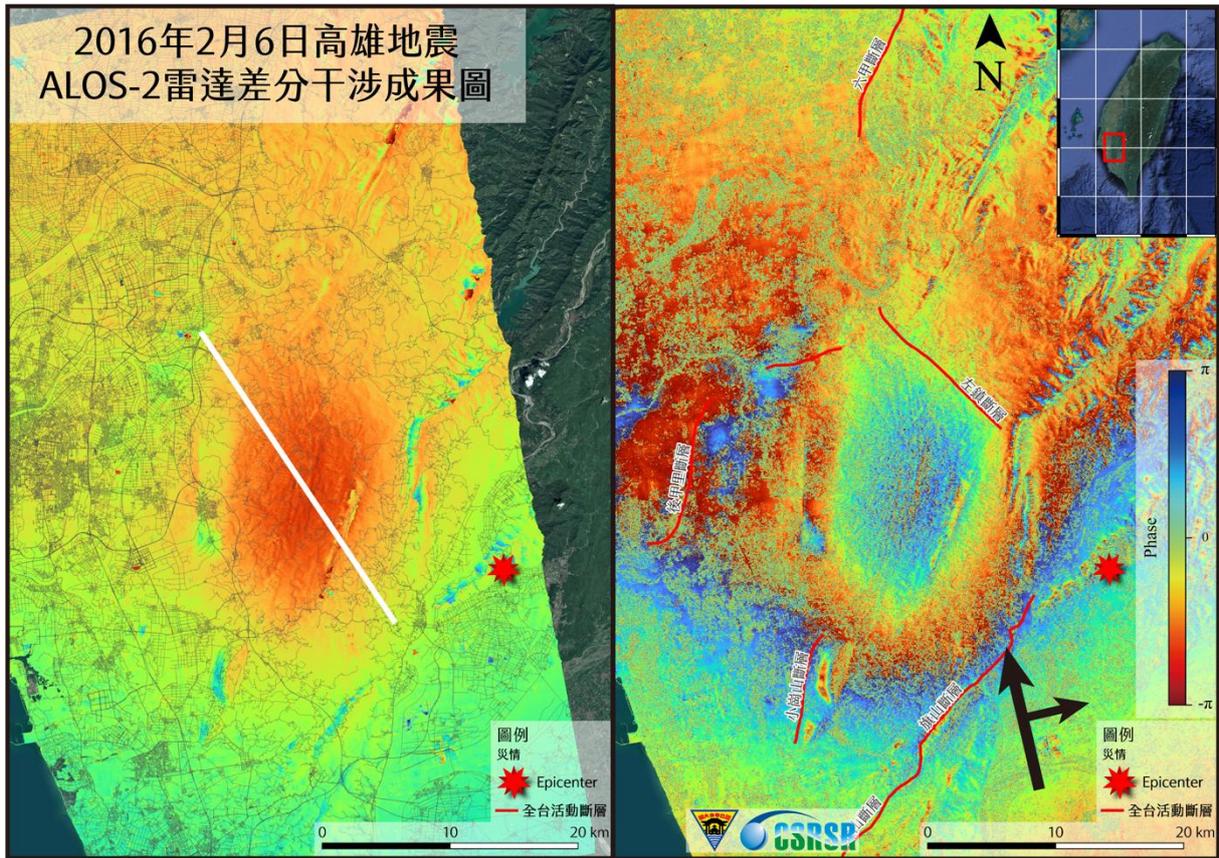


圖 4.3-7、L 波段 ALOS-2 高雄地震觀測成果

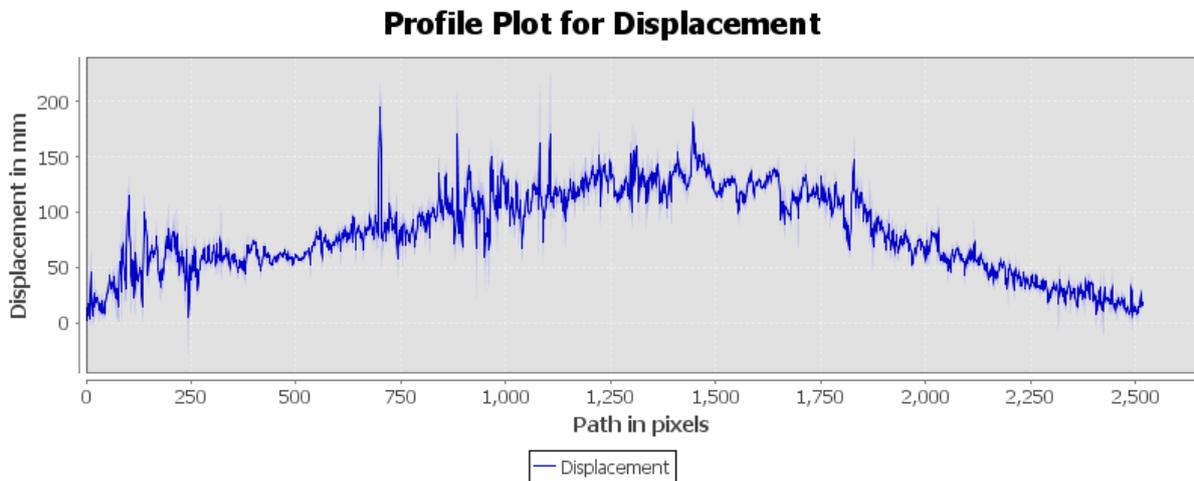


圖 4.3-8、高雄地震 DInSAR 變形量剖面

4.3.2 以兩年內高解析（2 公尺或更優）光學衛星影像進行數值地表模型

（DSM）變異分析，發展利用衛星影像進行 DSM 變異以協助光達修

**測規劃之方法與作業程序，辦理區域選定須內政部討論且總面積須達
3,600 平方公里以上**

本項工作延續前期（110 年）之試辦成果，使用 SPOT-6/7 光學衛星影像立體像對產製數值地表模型，與光達產製之 5 公尺數值地表模型進行變異分析。本項工作目的在於利用衛星立體像對，大範圍快速篩選地表形變區域，提供優先進行光達修測之目標區。另本項工作偵測之地表變形除大面積崩塌外，也包含大規模森林砍伐、人為之挖方填方及原有崩塌區域再次崩塌等情形，可與行政院農業委員會水土保持局進行之崩塌區域監測分析結果相互整合，提供更完整之地表形變資訊協助光達修測規劃。

本年度擴大試辦區域(如圖 4.3-9 所示)，圖中紅色區域為去年試辦區，黃色區域為本年度試辦區，本年度試辦區由去年之南部試辦區北側向北延伸至中部試辦區，試辦區域大小約 50x100 公里。試辦區域新拍 SPOT-6/7 立體像對，試辦區面積約為 5,000 平方公里。此外，參考本項工作之試辦經驗，訂定利用衛星影像協助光達修測規劃之方法與作業程序，並將現有程序作業化，以利後續大範圍執行。

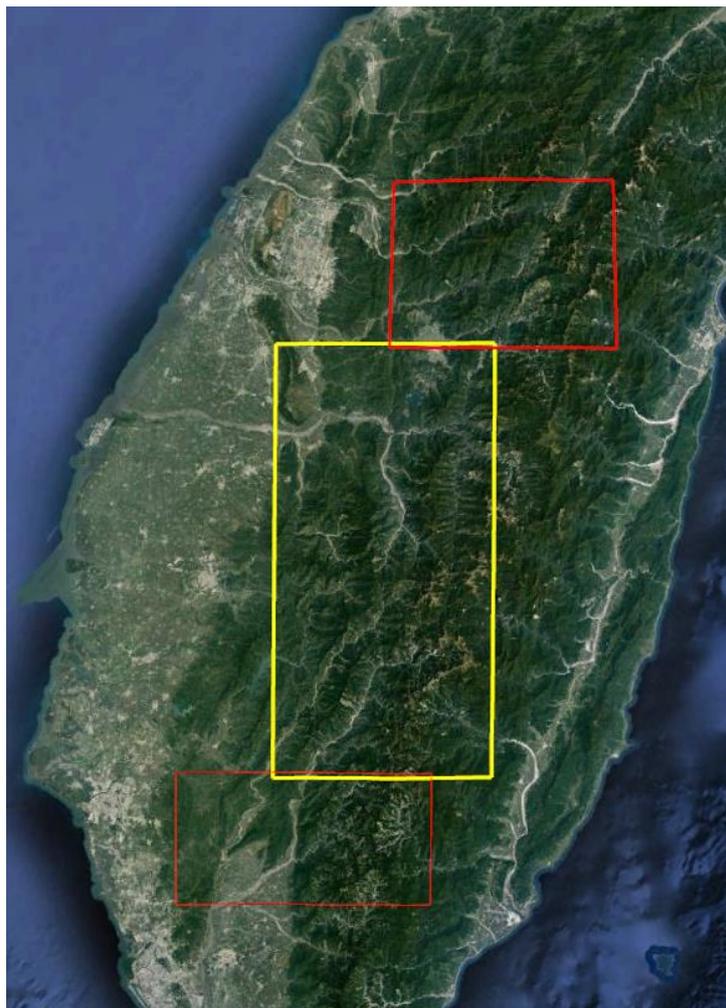


圖 4.3-9、地表形變分析試辦區

本項工作針對試辦區進行 SPOT-6/7 立體像對排程拍攝，共取得 3 組立體像對，可覆蓋完整試辦區，影像拍攝日期分別為 2022/6/22、2022/7/12 及 2022/7/24 之 SPOT-6/7，影像如圖 4.3-10 所示。利用前述之立體像對產製目標區域數值地表模型，產製成果如圖 4.3-11 所示。合併三組數值地表模型，並刪除受雲遮蔽影響無法產製正確數值地表模型之區域，成果如圖 4.3-12 所示，後續使用合併後之數值地表模型進行地表形變分析。

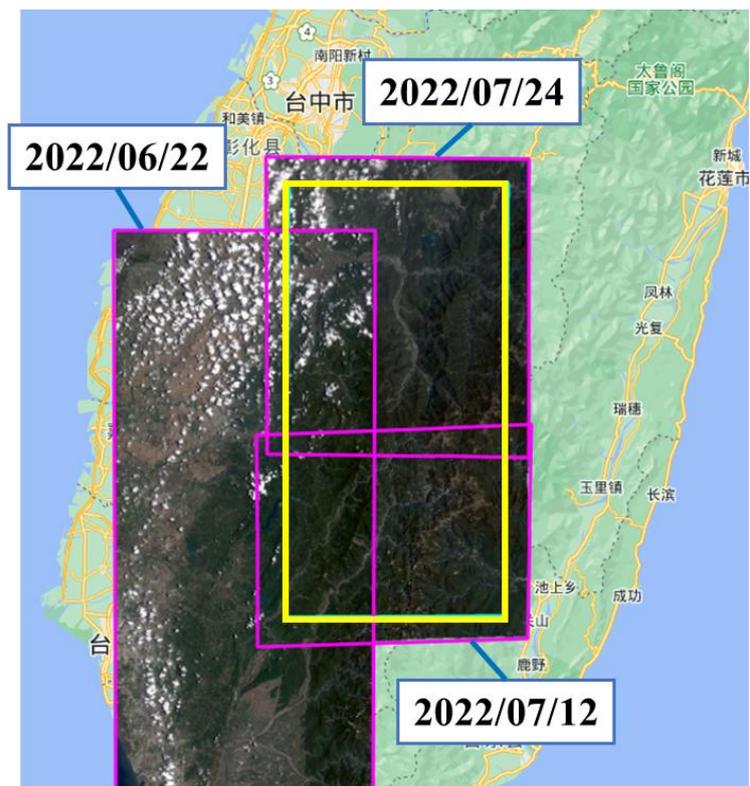
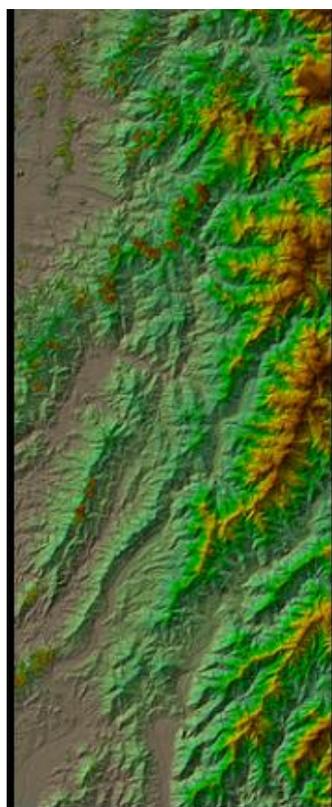
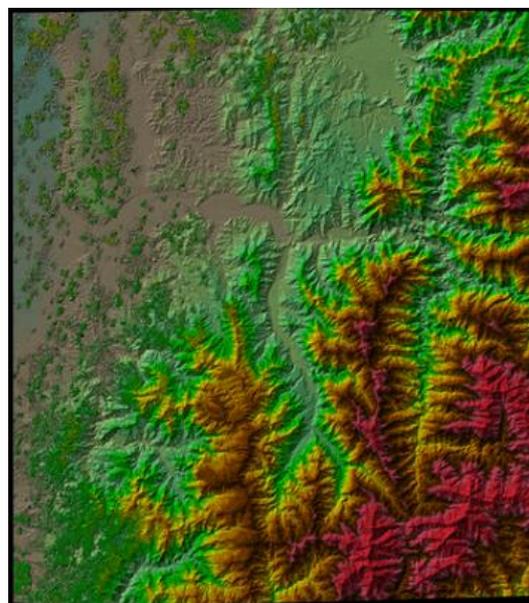


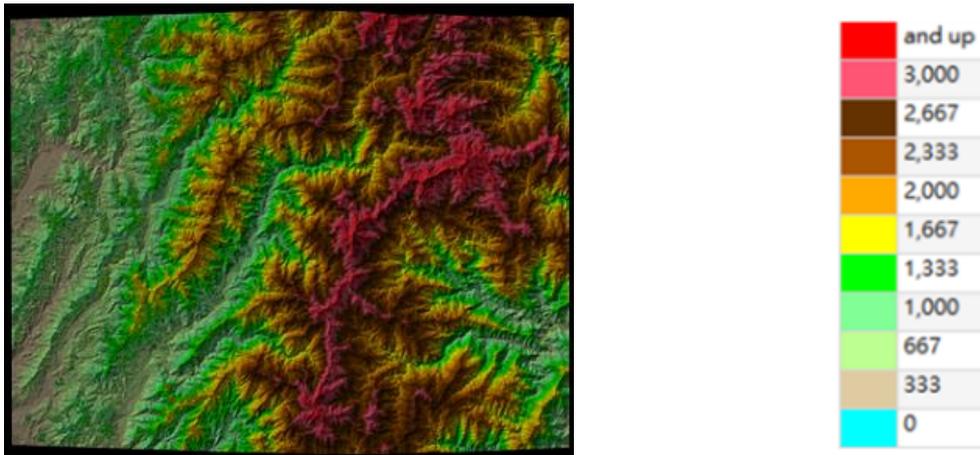
圖 4.3-10、SPOT-6/7 立體對



(a) 2022/6/22



(b) 2022/7/24



(c) 2022/7/12

圖 4.3-11、利用 SPOT-6/7 立體對產製之數值地表模型

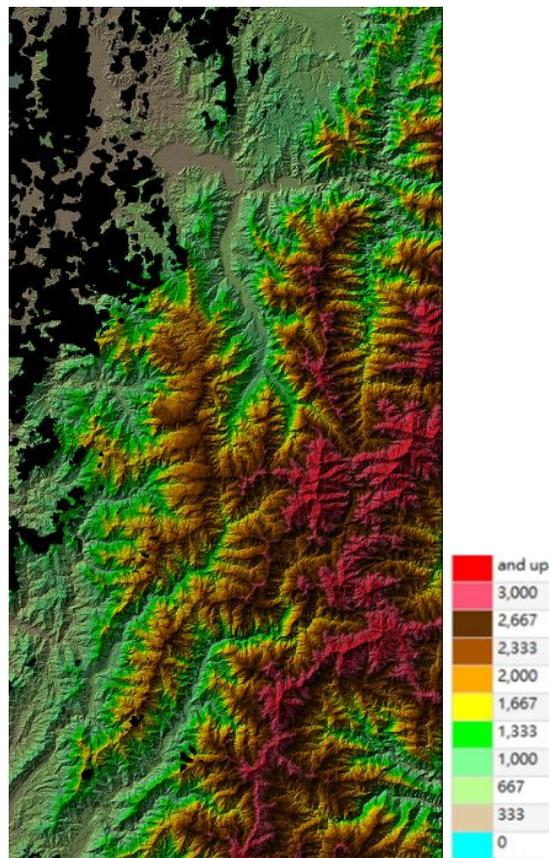


圖 4.3-12、地表形變分析使用之數值地表模型

將立體像對產製之數值地表模型減去空載光達所產製數值地表模型，可得地表高程變化量，高程變化量絕對值大於 10 公尺則視為地表變異區域。

高程差門檻設定係參考國家災害防救科技中心完成之「大規模崩塌災害防治行動綱領」，大規模崩塌係指崩塌面積超過 10 公頃或土方量達 10 萬立方公尺或崩塌深度在 10 公尺以上的崩塌地。以高程變化門檻值找出地表變異區域後，再使用形態學之開啟運算濾除零碎之區塊。地表變異成果如圖 4.3-13(a)所示，圖中黃色至紅色部分為正值，代表立體像對產製之數值地表模型高程較高，綠色至藍色部分代表立體像對產製之數值地表模型高程較低，區域 1 及區域 2 局部放大如圖 4.3-13(b)及圖 4.3-13(c)。

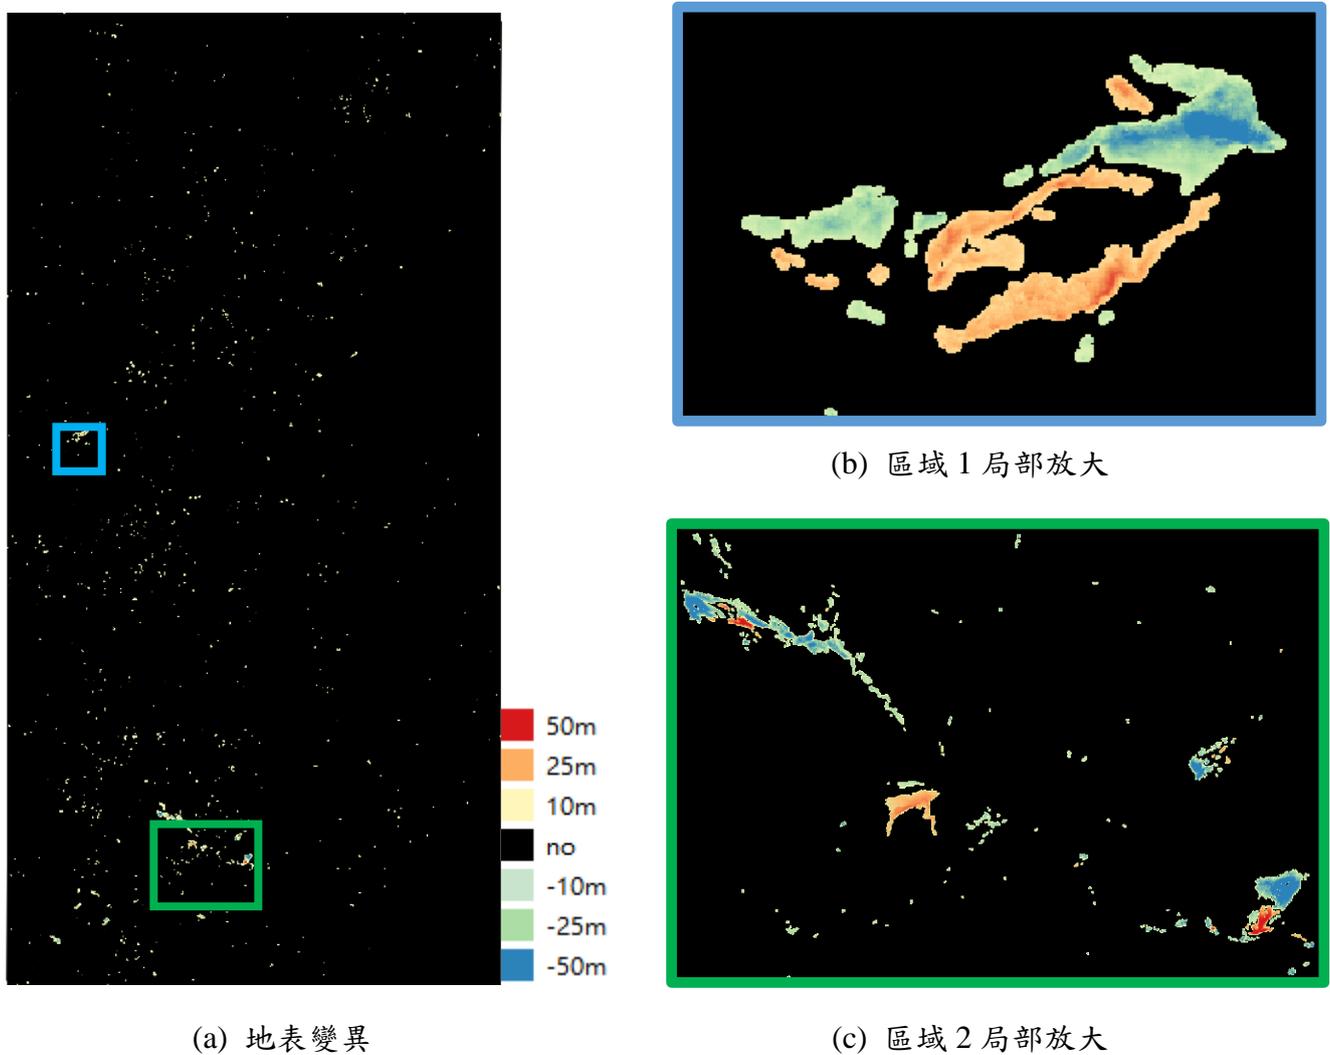


圖 4.3-13、數值地表模型地表變異

為了解地表高程變異程度以使用於未來空載光達測製工作之規劃，以 1/5000 圖幅為單元進行評估，評估之指標包括累計地表形變區域面積及累積增減高度。累計地表形變區域面積代表單一 1/5000 圖幅中有多少面積之區域有地表形變情形如圖 4.3-14，而累積增減高度則分別統計單一 1/5000 圖幅中高程增加及高程減少的累積高度如圖 4.3-15。高程增加及減少為分別統計，可避免累積增減高度相消造成之誤判情形。

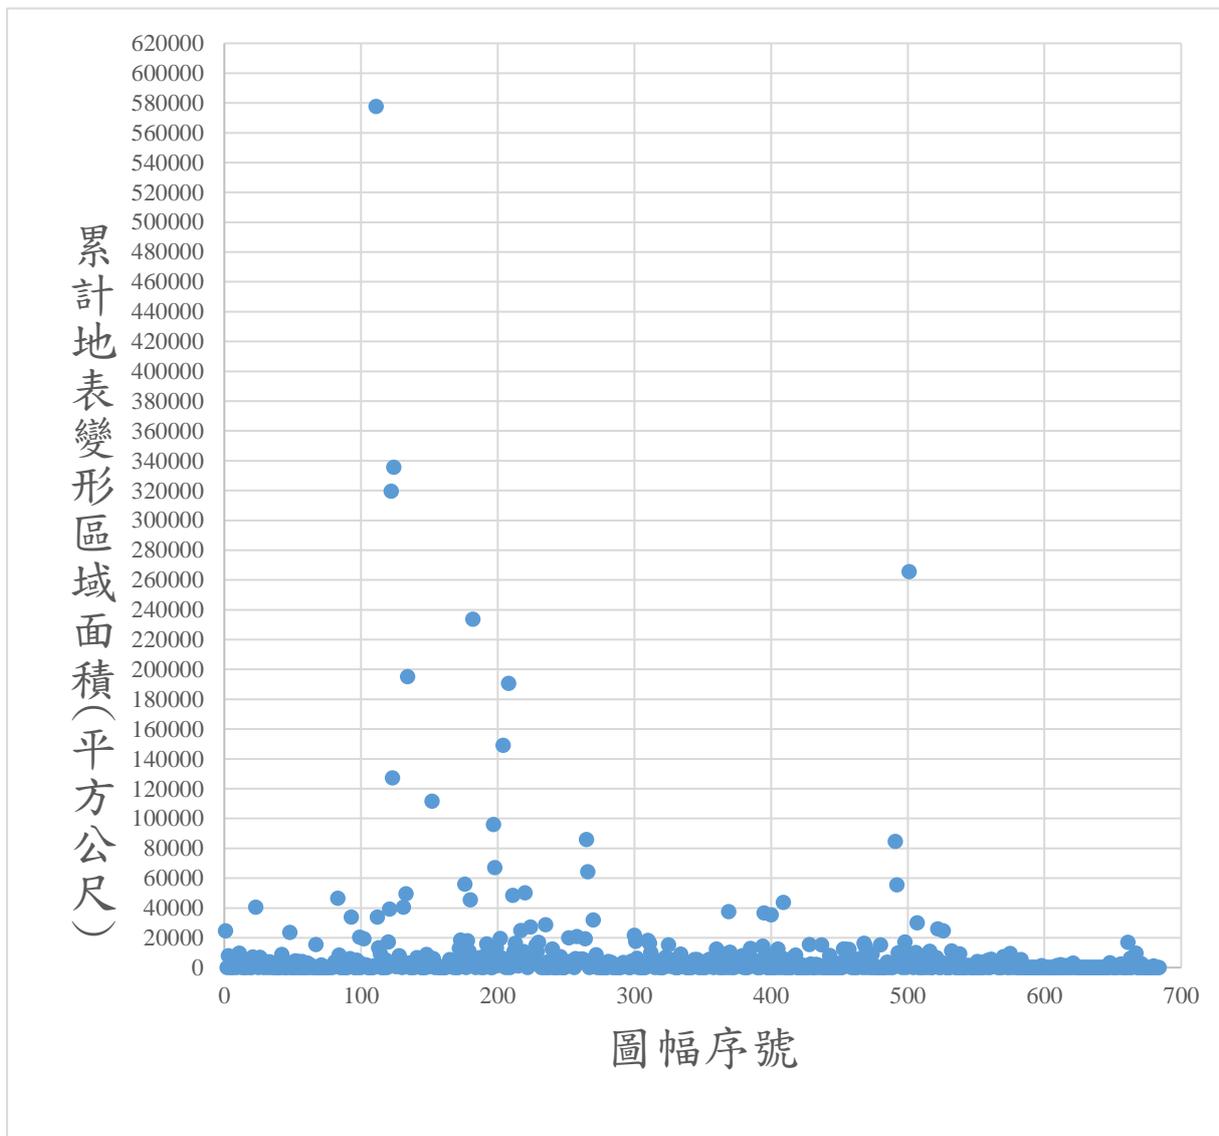


圖 4.3-14、累計地表形變區域面積統計

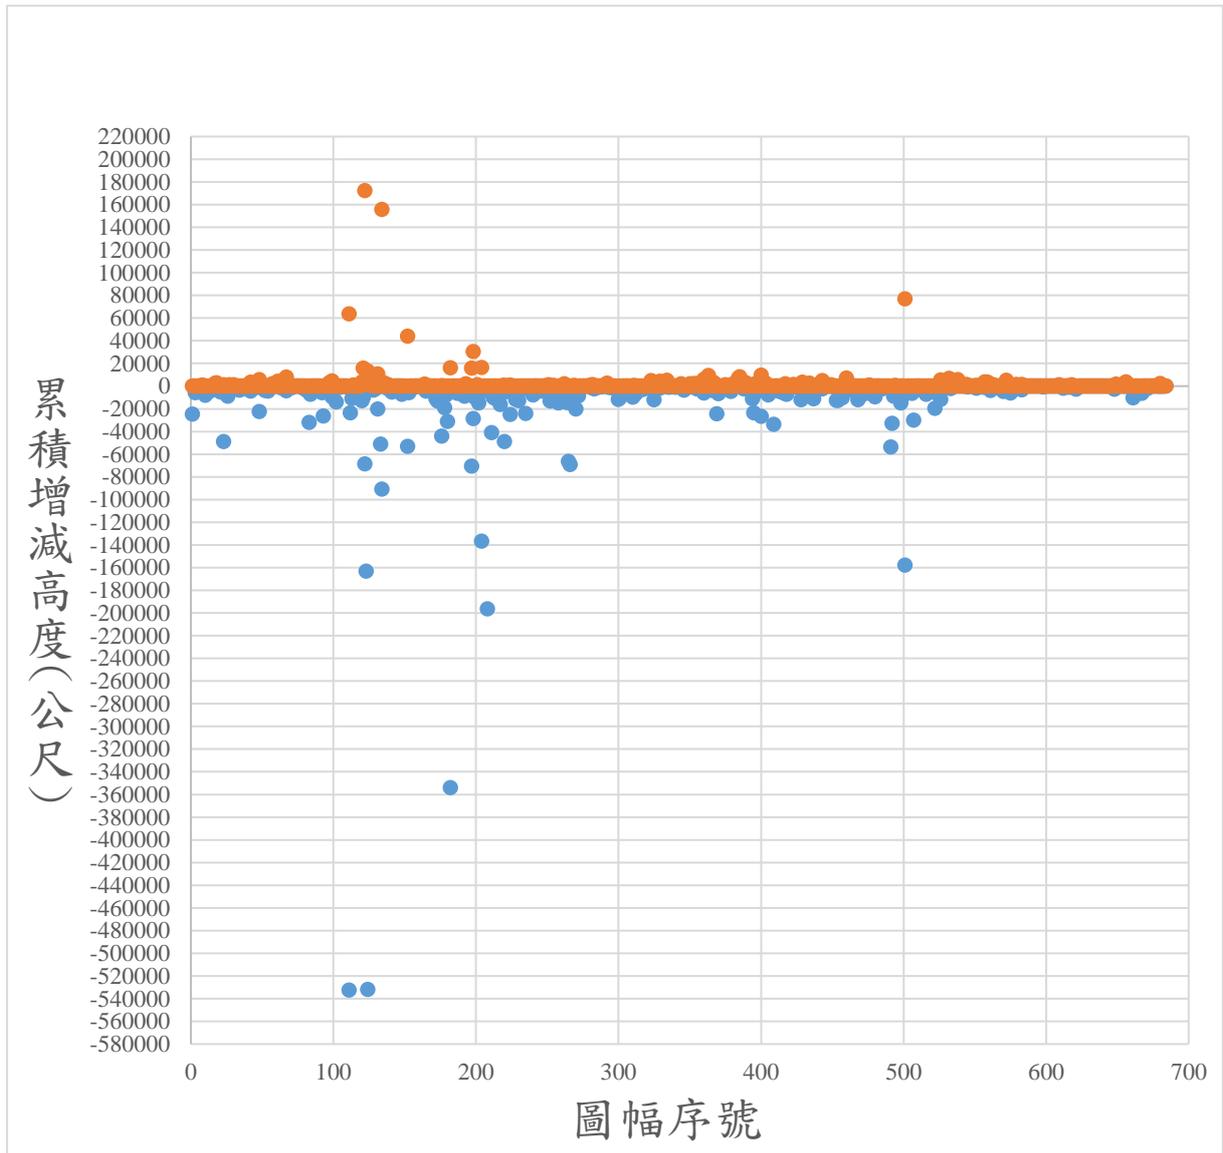


圖 4.3-15、累積增減高度統計

為取得有明顯地表形變之圖幅，分別對累計地表形變區域面積及累積增減高度設定門檻值，當單一 1/5000 圖幅範圍中超過門檻值時，該圖幅即為建議更新之圖幅。以本項工作試辦區為例，分別以累計地表形變區域面積大於 20000 平方公尺以及累積增減高度大於 20000 公尺為門檻值，可得建議更新之圖幅為如圖 4.3-16 中紅框部分。試辦區圖幅範圍為 684 幅，經

分區評估有 43 幅之地表形變大於門檻值，建議更新圖幅佔試辦區圖幅比例分別約為 6.3%。上述門檻值設定主要參考試辦區之測試成果，觀察經地表變異分析可得之崩塌規模，設定累計地表形變區域面積及累積增減高度門檻值。

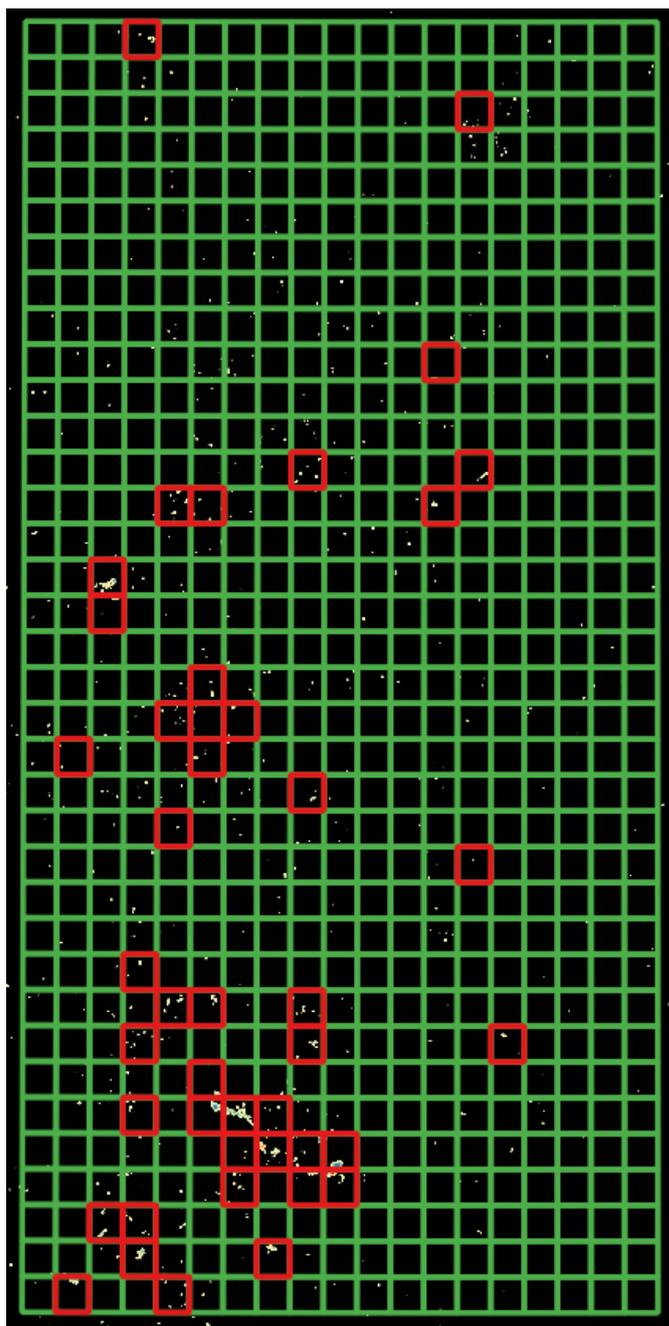
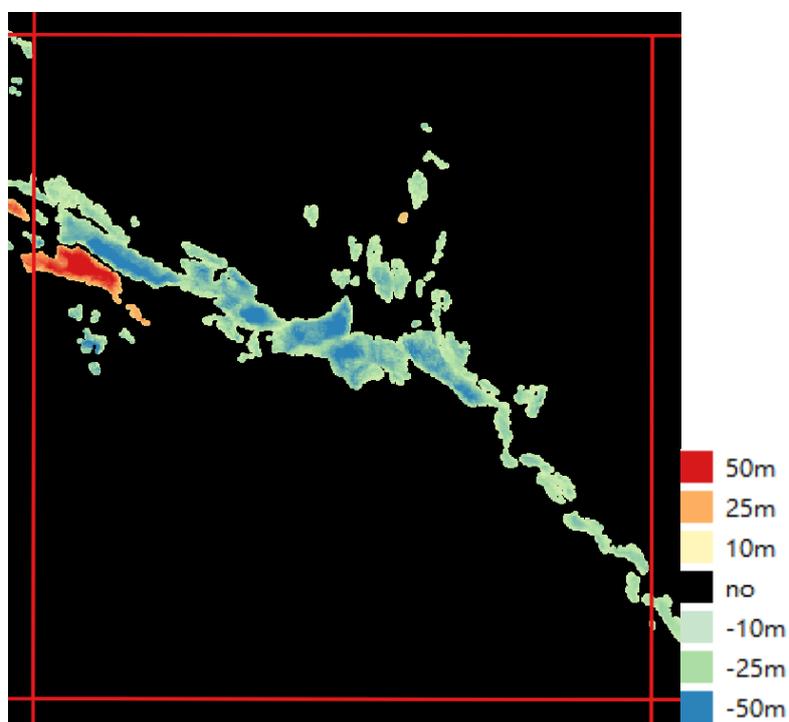


圖 4.3-16、試辦區域明顯地表變異之圖幅

由前述明顯地表變異之圖幅中，挑選 5 幅進行觀察，並比對前後期之 SPOT 影像，以了解造成地表變異的原因。

1. 圖 95192011 地表變異及前後時期 SPOT 影像如圖 4.3-17 所示，圖 4.3-17 (a) 中可觀察到有明顯地表高程降低及升高情形，高程變化最多可達約 50 公尺，且地表形變範圍橫跨整個圖幅。由 SPOT 影像中可以觀察到在原有的崩坍區域再次發生土石崩落及堆積情形，應為造成地表變異之原因。
2. 圖 95192024 及 95192034 地表變異及前後時期 SPOT 影像如圖 4.3-18 所示，此地表變異案例位於圖 95192024 及圖 95192034 交界處，圖 4.3-18(b) 中可觀察到有明顯地表高程降低及升高情形，由 SPOT 影像中可以觀察到北側區域土石崩落並於下方堆積。
3. 圖 95192022 地表變異及前後時期 SPOT 影像如圖 4.3-19 所示，圖 4.3-19(b) 中可觀察到大面積地表高程升高情形，由 SPOT 影像中可觀察到該區域為河道且旁邊有一支流，而其上游即為案例 2 之區域，此案例可能是上游土石崩落後堆積至下游河道，於影像中亦可看到河道改道情形。
4. 圖 95192052 地表變異及前後時期 SPOT 影像如圖 4.3-20 所示，圖 4.3-20(b) 中可觀察到有地表高程降低情形，全區高程變化量

相近，由 SPOT 影像中可以觀察到前期為整片森林後期則為草地，植生砍伐應為造成高程改變之原因。



(a) 圖 95192011 地表變異



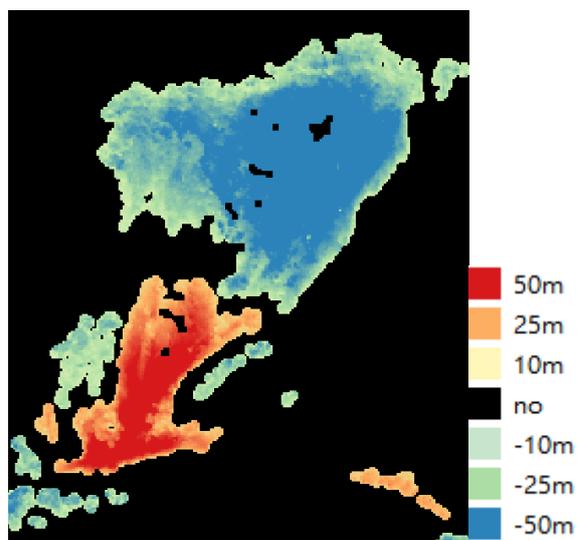
(b) 2016 年 SPOT 影像

(c) 2022 年 SPOT 影像

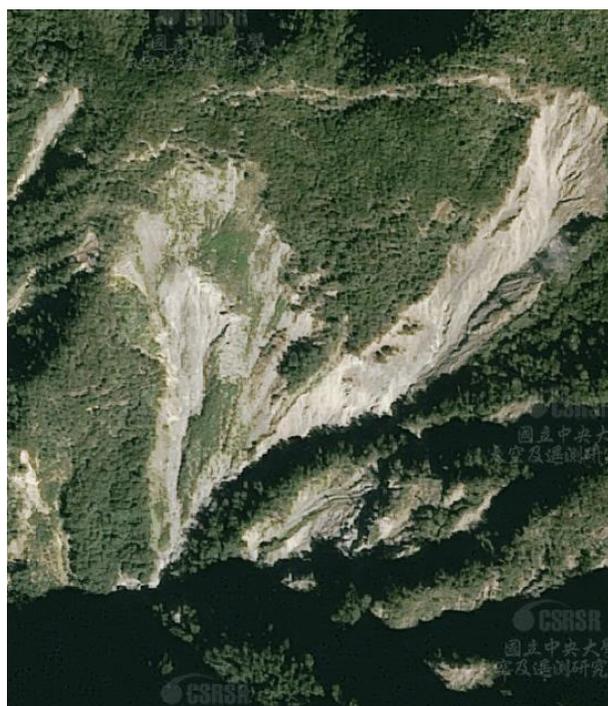
圖 4.3-17、圖 95192011 地表變異及前後時期 SPOT 影像



(a) 圖 95192024 及 95192034 圖框



(b) 局部放大地表變異

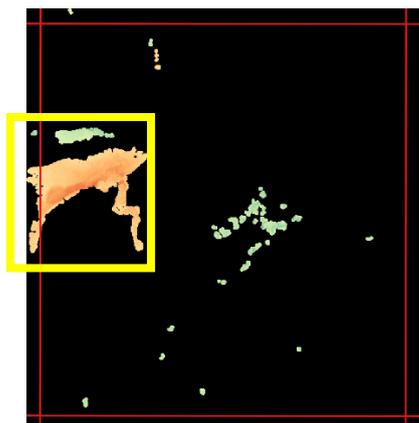


(c) 2016 年 SPOT 影像

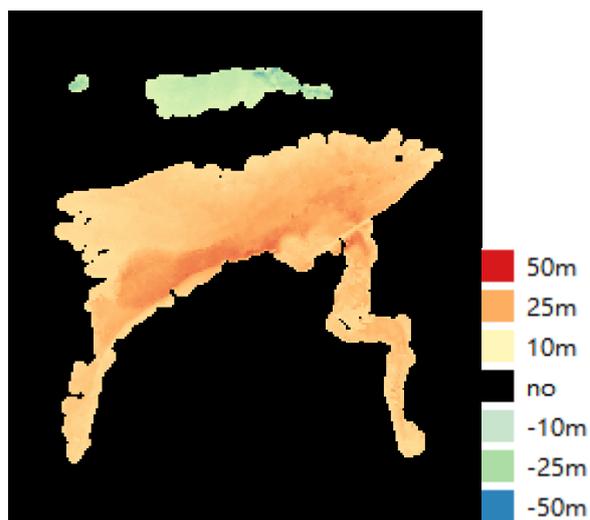


(d) 2022 年 SPOT 影像

圖 4.3-18、圖 95192024 及 95192034 地表變異及前後時期 SPOT 影像



(a) 圖 95192022 圖框



(b) 局部放大地表變異

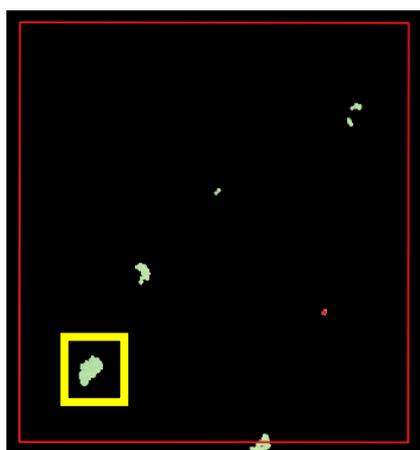


(c) 2016 年 SPOT 影像

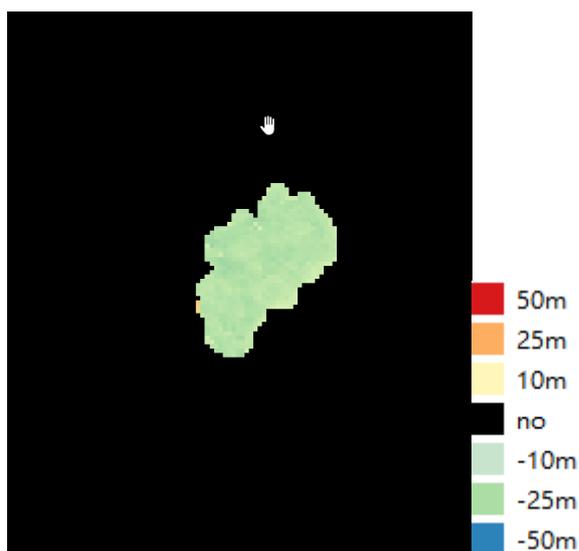


(d) 2022 年 SPOT 影像

圖 4.3-19、圖 95192022 地表變異及前後時期 SPOT 影像



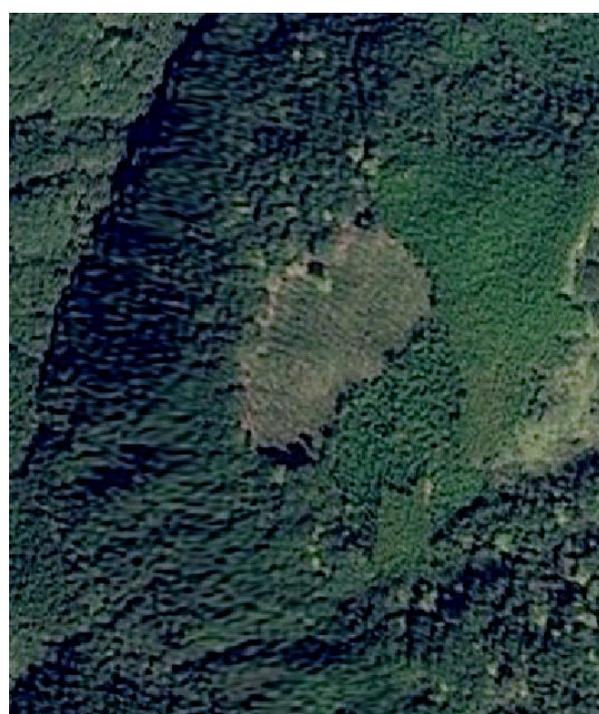
(a) 圖 95192052 圖框



(b) 局部放大地表變異



(c) 2016 年 SPOT 影像



(d) 2022 年 SPOT 影像

圖 4.3-20、圖 95192052 地表變異及前後時期 SPOT 影像

參考 110 年及本年度試辦經驗，擬定衛星影像 DSM 變異分析及更新建議作業程序。作業流程可分為 8 個步驟，流程圖如圖 4.3-21 所示，以下說明各步驟處理程序以及所需輸入資料。

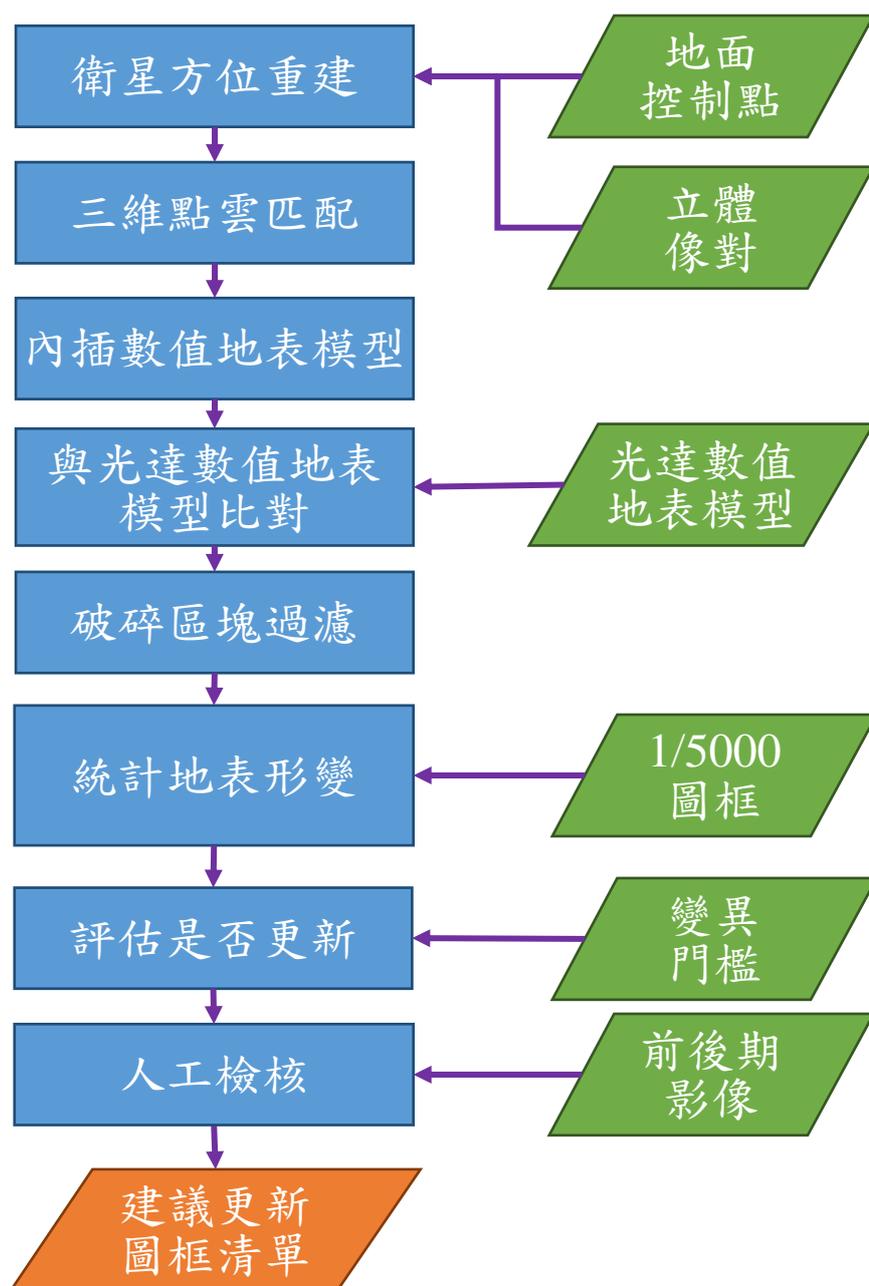


圖 4.3-21、衛星影像數值地表模型變異分析及更新建議作業程序流程圖

1. 衛星方位重建

此程序使用團隊自主開發程式處理。衛星方位重建之輸入資料為立體像對及地面控制點，由於衛星方位本身帶有誤差，因此利用控制點進行平差修正以重建衛星方位。衛星影像方位模式可採有理函數模式，利用兩個

多項式的比值來建立物空間與像空間的連結關係，由於衛星成像幾何的特性，且衛星的定位系統及姿態系統有很高的相對精度，可使用有理函數模式配合地面控制點，以線性的仿射轉換(Affine Transformation)進行修正處理。

2. 三維點雲匹配

此程序使用團隊自主開發程式處理。利用重建後之方位進行三維點雲匹配，影像匹配使用影像密匹配技術，並配合影像金字塔策略，將原始影像降低解析度，從低解析度影像開始處理至高解析度影像。由粗至細的匹配流程，可增加匹配成果的可靠度。完成匹配後配合影像區域平差成果進行空間前方交會，計算影像共軛點對應之三維物空間坐標。

3. 內插數值地表模型

此程序使用 Geospatial Data Abstraction Library (GDAL)處理。目前使用之 SPOT-6/7 立體像對，其全色態影像解析度為 1.5 公尺，數值地表模型內插時建議設定輸出資料解析度為 5 公尺。同時並記錄匹配成果不佳之區域，以供後續分析使用。

4. 數值地表模型比對

此程序使用 ERDAS IMAGEINE 處理。數值地表模型比對輸入資料為使用立體像對產製之數值地表模型與相同區域光達產製之數值地表模型，將所產製之數值地表模型減去光達產製之數值地表模型，計算兩者間之高

程差值，高程差絕對值大於 10 公尺則是為地表變異區域，並記錄其位置及高程差值。另外，剔除匹配成果不佳區域位置，例如有雲區域、水體及陰影。

高程差門檻設定係參考國家災害防救科技中心完成之「大規模崩塌災害防治行動綱領」，大規模崩塌係指崩塌面積超過 10 公頃或土方量達 10 萬立方公尺或崩塌深度在 10 公尺以上的崩塌地。

5. 破碎區塊過濾

此程序使用 ERDAS IMAGEINE 處理。由於所得之地表變異區域中有需多破碎區塊，使用形態學之開啟運算以及面積門檻濾除零碎之區塊。

6. 統計地表形

此程序使用團隊自主開發程式處理。以 1/5000 圖幅為單元進行建議更新地形評估，統計目標區域中每一 1/5000 圖幅範圍中，累計地表形變區域面積及累積增減高度。

7. 評估是否更新

此程序使用團隊自主開發程式處理。利用前一步驟統計之各圖幅範圍中累計地表形變區域面積及累積增減高度，進行評估是否應更新。建議變異門檻為累計地表形變區域面積大於 20000 平方公尺或累積增減高度大於 20000 公尺，當單一 1/5000 圖幅範圍中，累計地表形變區域面積或累積增減高度超過門檻值時，該圖幅即為建議更新之圖幅。變異門檻之設定主要

參考試辦區之測試成果，觀察經地表變異分析可得之崩塌規模，設定累計地表形變區域面積及累積增減高度門檻值。

8. 人工檢核

以人工方式檢核建議更新之圖幅是否有誤判或無須更新情形，利用相近時期之衛星影像檢核地表變異成果，比對影像中地物變化狀況是否與地表變異成果相符，或是其地表形變無更新之必要，例如砂石場之堆置變化。

依上述處理程序已完成 3 個試辦區之地表形變分析及建議更新作業，試辦區圖幅範圍分別為 253 幅、374 幅及 684 幅，依目前建議之變異門檻，經分區評估各試辦區分別有 15 幅、12 幅及 43 幅之地表形變大於門檻值，建議更新圖幅佔該試辦區圖幅比例分別約為 5.9%、3.2%及 6.3%。

近年來光學衛星影像之解析度提升與取像能力增加，可使用光學衛星影像立體像對產製數值地表模型。光學衛星拍攝立體像對主要分為同軌與異軌兩種方式，其中同軌立體像對之兩張影像拍攝時間差距小，取像時太陽角度及大氣等條件近似，在產製數值地表模型之過程中可減少錯誤，獲得較佳的數值地表模型，因此建議使用光學衛星同軌立體像對。

目前現役常見之光學衛星中，可拍攝同軌立體像對的衛星包括 Formosat-5、SPOT-6/7、Pleiades-1A/1B、Pleiades Neo 3/4、WorldView-1、WorldView-2、WorldView-3、GeoEye-1 及 Kompsat-3A 等。其中超高解析度（解析度優於 1m）衛星影像價格昂貴且影像幅寬小，較不適用於本作業

程序。而高解析度衛星影像中，SPOT-6/7 衛星影像之影像幅寬大於 Formosat-5 與 Kompsat-2 衛星影像，且有兩顆衛星在軌運轉，可提供較高之立體像對拍攝能量，有利於大範圍取像。因此，建議選擇 SPOT-6/7 衛星同軌立體像進行數值地表模型變異分析及更新建議作業程序。

4.3.3 航遙測影像分析與辨識之結果，精進與坡地防災應用平臺進行整合，其整合方案須與內政部討論後辦理

邊坡破壞會對人員、財產及環境造成嚴重威脅，其成因複雜，導致無法準確預估各式規模邊坡破壞之時間與位置。雖然不能預先得知新生崩塌地或邊坡變異地之時間與位置，但曾經歷大規模山崩的區域由於地質條件弱化且植被不易復育，有較高機率會重複地發生崩塌（陳棋炫等，2017）。進行監測以確切了解崩塌位置與規模有助於坡地管理，因此坡地變異點偵測為重要的研究工作。傳統建立崩塌事件地圖之方式為透過實地調查或使用航照影像之人為視覺判釋(Guzzetti et al., 2012)。前者受限於觀測者所在之地面視角，易受視線遮蔽影響且往往只能獲取部分信息；後者需要有經驗之專家學者透過完整的人員培訓並制定統一的判斷標準來實現。

近年遙測技術的成熟使原需大量人力與時間成本之傳統方式有了替代方案。Handwerger (2020)等人使用合成孔徑雷達影像之振幅變化進行即時性崩塌熱點圖繪製以對崩塌災害快速反應。Herrera (2019)透過崩塌事件前後

之 Sentinel-2 光學影像萃取崩塌特徵，再利用基於物件之影像分析 (Object-based Image Analysis, OBIA) 及機器學習演算法開發一種崩塌自動偵測方法。使用雙時相 (Bitemporal) 影像進行崩塌偵測需要有良好的前後期影像，若區域發生崩塌但在選定的時間區間內植被已復生，則可能無法成功檢測到該崩塌事件。為進行大範圍坡地監測，本項工作以坡地防災為應用試辦主題，利用航遙測多時期影像分析與辨識技術進行坡地變異點偵測，配合 Google Earth Engine (GEE) 雲端應用平臺進行坡地監測。坡地防災為國立陽明交通大學防災與水環境研究中心的核心研究主題之一，因此本項應用亦整合國立陽明交大防災中心之研究專長，以介接及試辦本項工作發展之技術的應用性。

本項工作前期 (110 年) 完成像元式 (Pixel-based) 時序多光譜衛星影像 NDVI 植生指標及機器學習演算法進行時間序列分類，驗證時序 NDVI 為崩塌判釋的有效特徵，可應用於判釋崩塌變異區。本年度工作目標為發展物件式 (Object-based) 時序多光譜衛星影像崩塌地判釋技術，以 GEE 平臺發展坡地防災之應用，精進並引入深度學習技術，同時整合地表高程資訊提供優化之崩塌目錄圖。本年度具體成果為透過影像分割技術建立以物件為時間序列索引之單元，以時序 NDVI 建立機器學習與深度學習崩塌地判釋模型，並引入 DEM 數值高程模型以優化判釋成果。未來可應用於更高空間解析度之多光譜衛星影像集，提供更細緻之歷史崩塌目錄圖，輔助坡地大面

積監測及管理應用，降低透過人為數化崩塌地之時間成本，獲取山坡地變遷資訊，以利圖資更新作業參考。

本項工作於 GEE 雲端開放平臺進行應用試辦，GEE 提供衛星影像圖資存取與應用整合介面，方便巨量資料的處理與統計分析，可應用於大範圍遙測影像處理的快速分析與初步評估。利用 GEE 平臺的長時期開放衛星影像，可有效率的發展多時序多光譜衛星影像坡地崩塌判釋技術。

本年度工作內容主要包含四個部分，第一部分為資料匯整與前處理，研究中整合雲端應用平臺的長時期開放多光譜衛星影像(Landsat-8)、林務局邊坡變異向量資料以及內政部提供之 5 公尺網格數值地形模型，以資料集(Data Set)的方式匯整在平臺中，爾後透過建立雲遮罩並計算 NDVI 值以獲取時間序列影像，接著經過粗差別除、高斯平滑化及重新採樣(Resampling)等時序前處理程序獲取精化後之時序資料；第二部分為物件分割程序，透過物件分割技術產生特徵相似的區域物件(Object)，再以物件為單元進行判釋，以改善像元式判釋之椒鹽效應並降低混合像元造成之影響；第三部分為基於機器學習(Machine Learning)之崩塌地偵測，此演算法分別對時間序列與 DEM 高程資訊進行特徵萃取，並透過主成分轉換對高維高相依之特徵向量進行處理，後以支持向量機演算法建置崩塌地判釋之分類模型；第四部分為引入時間序列分類之深度學習(Deep Learning)網路，設計時序特徵與 DEM 特徵之融合策略並比較不同網路間之差異，最後與機器學習演算法進

行橫向比較，各部分細節以下分述：

4.3.3.1 資料匯整與前處理

本項工作使用的資料包含：(1) 多時期多光譜 Landsat-8 (LS-8)衛星影像資料、(2) 高解析數值地形模型資料、(3) 衛星判釋全島崩塌地圖。資料蒐集與前處理說明如下：

(1) 多時期多光譜 Landsat-8 (LS-8)衛星影像資料：本項工作使用 GEE 雲端應用平臺獲取多時期多光譜 Landsat-8 (LS-8)衛星影像資料，研究中使用經過幾何與大氣輻射校正之地表反射率(Surface Reflectance)產品，利用 CFMask (Foga et al., 2017)演算法產生之 Pixel Quality 波段進行雲遮罩，再進一步計算植生指標(NDVI)，研究中使用的影像產品和波段如表 4.3-3 所示。邊坡變異的發生多集中在山區與地形變化快速之區域，通常伴隨地貌的驟變，最常見的現象即為由植被覆蓋轉變為裸露地(Deijns et al., 2020)，故以 NDVI 作為時間序列之計算單元，可有效辨別變異與非變異點，如圖 4.3-22。資料前處理包含粗差剔除（如圖 4.3-23 上紅色圓圈框選所示）、高斯平滑及時序重新取樣，研究中以 4 年為單位，將經過粗差濾除與高斯平滑後之各時間序列進行重新取樣至每週一筆（209 筆 / 4 年），時間序列前處理程序如圖 4.3-24。

表 4.3-3、影像集資訊

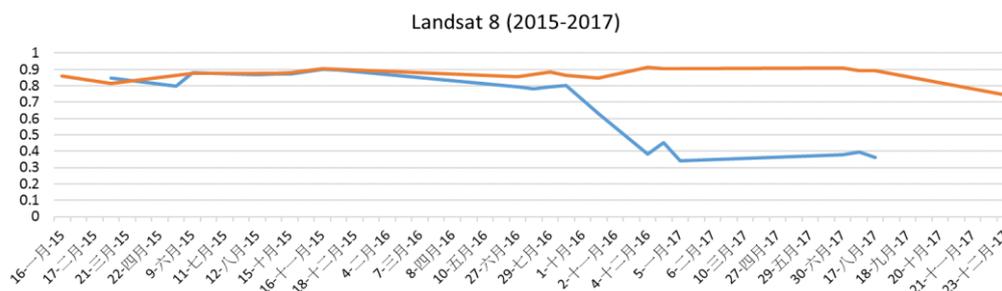
影像時間		供應者	GEE 代碼
2013/04/11-present		USGS	LANDSAT/LC08/C01/T1_SR
Band	Resolution (m)	Wavelength	Description
B2	30	0.45 - 0.51 μm	Blue
B3	30	0.53 - 0.59 μm	Green
B4	30	0.64 - 0.67 μm	Red
B5	30	0.85 - 0.88 μm	NIR
BQA	30		Landsat Collection 1 QA Bitmask



(a) 2015 年 Landsat-8 影像
(藍點：無變異點；紅點：變異點)



(b) 2017 年 Landsat-8 影像
(藍點：無變異點；紅點：變異點)



(c) 有變異及無變異點時序植生指標

圖 4.3-22、邊坡變異點判釋示意圖

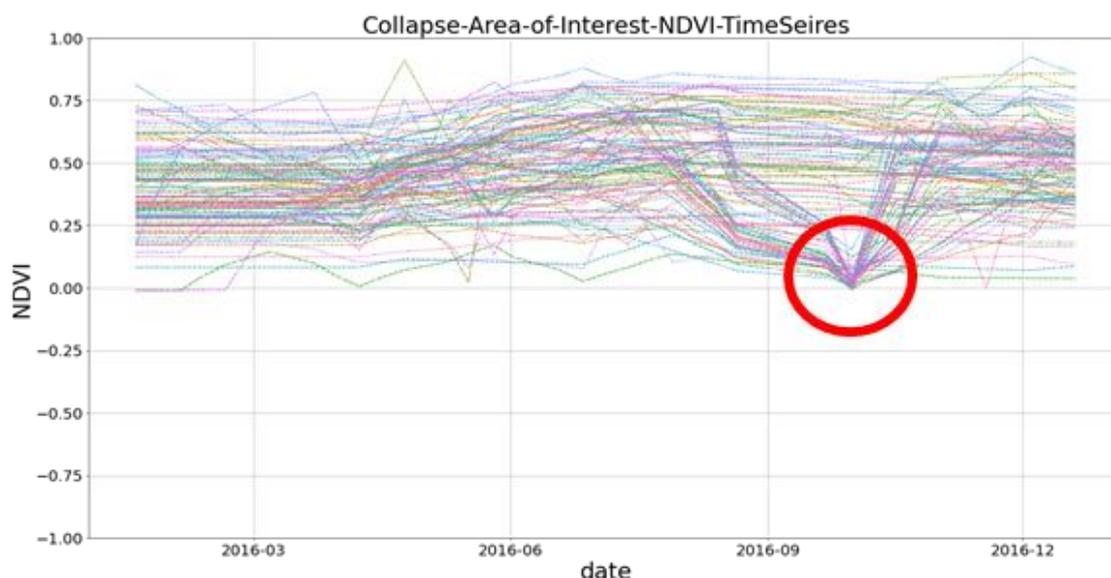


圖 4.3-23、時間序列粗差濾除

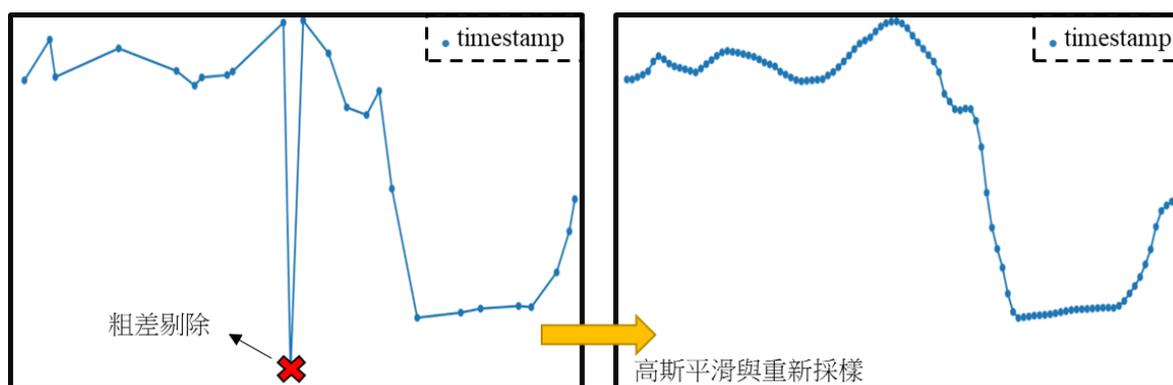


圖 4.3-24、時間序列前處理

(2) 高解析數值地形模型資料：本年度整合時序光譜及地形特徵偵測崩塌，研究中使用內政部提供之 5 公尺網格數值地形模型，DEM 資料分別為以中部山區為主之 A01 (11205 x 9432 pixels)與南部區域之 A02 (11811 x 6119 pixels)，此兩區域為該年度之研究區域，並以 A01 為模型訓練及測試區；A02 作為獨立驗證區，分布位置如圖 4.3-25 所示。

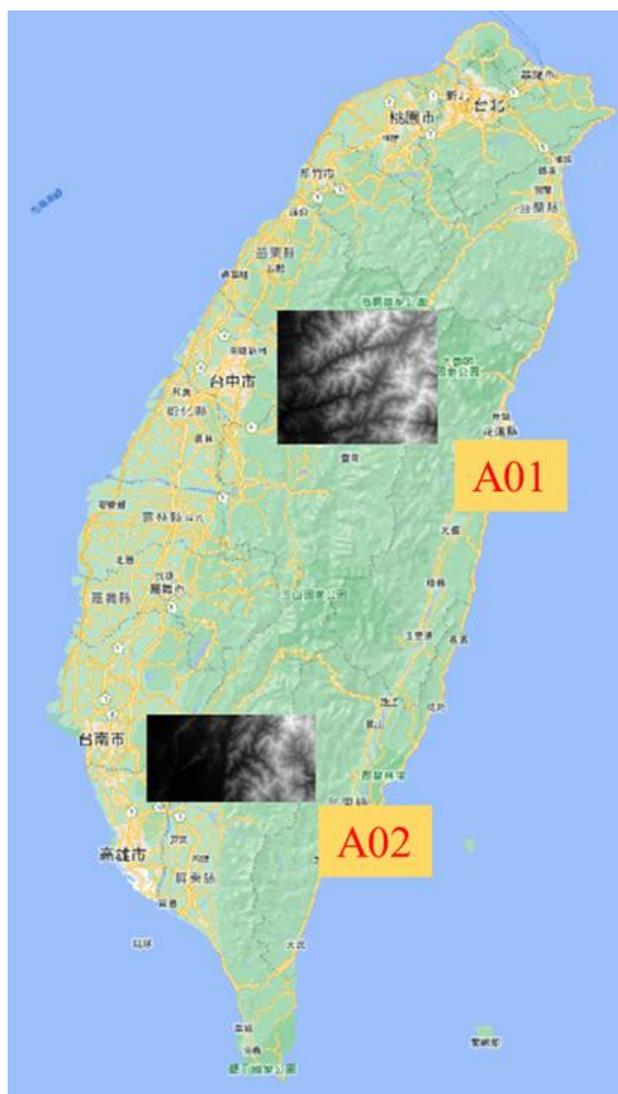


圖 4.3-25、DEM 資料分布位置圖

(3) 衛星判釋全島崩塌地圖：本年度亦使用林務局年度衛星判釋全島崩塌地圖作為崩塌參考資料以進行監督式學習，於研究區域內蒐集並建立 2015 至 2018 年衛星判釋全島崩塌向量聯集(Union)，以獲取四年間之歷史崩塌參考資料(.shp)並匯入 GEE。

4.3.3.2 物件分割

本年度研究以物件式(Object-based)分類精進前期（110 年）之像元式

(Pixel-based)分類，物件分割是將特徵相似的區域物件(Object)劃分為同一物件，並以各物件為崩塌判釋之單元，以改善像元式判釋之椒鹽效應並降低混合像元造成之影響，研究分析以下三種不同理論基礎之物件單元：(1) 基於 DEM 分割之斜坡單元、(2) 基於 Simple Non-Iterative Clustering (SNIC) 演算法之超像素(Superpixels)聚類、以及(3) 多尺度分割之演算法 Multiresolution Segmentation。

(1) 斜坡單元(Slope Unit, SU)

本項工作斜坡單元參考集水區重疊法(Xie et al., 2004)於商用軟體 ArcGIS pro 中進行繪製，斜坡單元為基於 DEM 之地表水文分析分割方式，其先將 DEM 進行地形填補後透過水文分析建置正集水區，後透過反轉 DEM 並施以相同程序建置反集水區，爾後將正反集水區合併分割並進行向量編修以完成斜坡單元之劃分，原理論示意圖如圖 4.3-26，研究設定不同累積流量門檻值(1K~5K)以劃分不同等級之集水區，門檻值越低將保留越多河網細節，主要繪製流程如圖 4.3-27 所示。

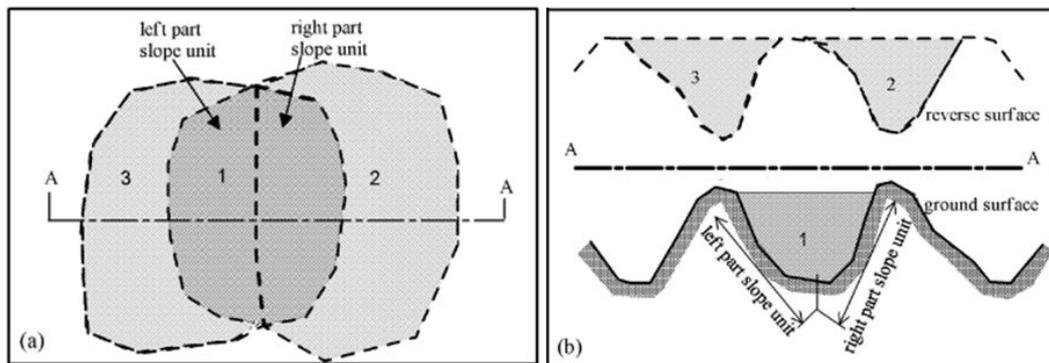


圖 4.3-26、集水區重疊法(Xie et al., 2004)

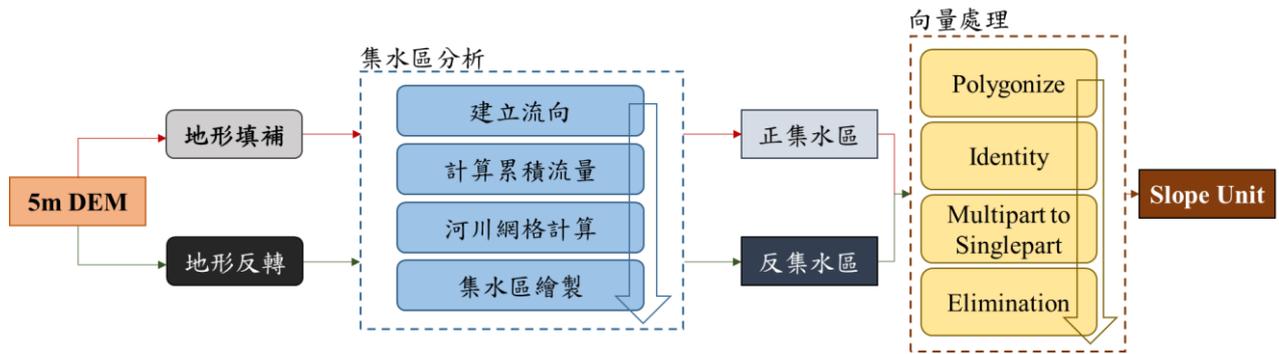


圖 4.3-27、斜坡單元繪製流程圖

(2) 簡單非迭代聚類(Simple Non-Iterative Clustering, SNIC)

簡單非迭代聚類演算法(Achanta & Susstrunk, 2017)為簡單線性迭代聚類法(Simple Linear Iterative Clustering, SLIC)的改良，其演算法不對所有像素計算彼此間的相似度，僅計算各種子點(seeds)與鄰接像素(4或8)之色彩空間與像素位置空間距離，並透過強制連接之預設取代SLIC演算法中耗時的連接後處理，SNIC演算法可在單次迭代中完成超像素(Superpixels)之聚類，且所需要的內存消耗與運算成本都低於SLIC演算法。SNIC超像素聚類分割於GEE平臺實現，演算法為基於影像之分割技術，影像輸入為2015~2018之4年間多光譜影像集中裸土指數(Bare Soil Index, BSI)前30%之像素平均值影像，影像包含R、G、B、NIR、BSI、NDVI共6個波段，輸出即為超像素分割。研究設定不同規則種子點分布間格(5、10、20、30m)，並另以斜坡單元各物件之最大內接圓中心為不規則分布種子點進行SNIC超像素分割。BSI指標計算公式如式4.3-1。

$$BSI = \frac{(Red + SWIR) - (NIR + Blue)}{(Red + SWIR) + (NIR + Blue)} \quad \text{式 4.3-1}$$

(3) 多尺度分割(Multiresolution Segmentation, MRS)

多尺度分割亦為基於影像之分割演算法(Benz et al., 2004)，其分割演算法為一種自下而上之聚類策略(Bottom-up Approach)，從 Single-pixel-sized 之物件開始向鄰接的物件探索（或合併），當鄰接的候選物件與其該物件互為最相似時將其合併，迭代計算至沒有任何物件可以合併為止。相似度之評斷準則受顏色同質性(Color homogeneity)與形狀同質性(Shape homogeneity)影響，兩者占比合為 1，若形狀同質性佔 0.9，顏色同質性則為 0.1，其分割成果將以形狀特性之影響為主；相反地，若形狀同質性佔 0.1，顏色同質性則為 0.9，則影像分割成果將以影像波段間之光譜差異為主要分割依據。MRS 演算法於商用軟體 eCognition 下進行，研究使用之形狀同質性與顏色同質性參數分別為 0.5 與 0.5，其中輸入影像與前項 SNIC 演算法一致，為 6 個波段之多時期平均影像。在 MRS 參數設定中，除了上述影響相似度評斷之參數外，可對各個波段賦予不同之權重。此外，演算法可將主題圖層(Thematic Layer)視為額外之分割依據，此研究以累積流量門檻值為 1K 之斜坡單元(SU1K)作為主題圖層，使其影像分割不僅考量光譜資訊，還包含斜坡單元中之高程資訊。

三種分割方式依其參數設置而有不同分割成果，為了進行分割成果之優劣差異分析，先將崩塌參考資料柵格化(Rasterize)並對齊 SNIC 與 MRS 之參考影像，爾後將各分割成果計算 IoU 指標以量化精度，IoU 大於 50% 判定能正確判釋；IoU 小於 50% 代表可能之漏授錯誤。圖 4.3-28 彙整所有分割成果在崩塌參考資料 IoU 大於 50% 之佔比，由於使用之光學影像空間解析度為 30m，在基於影像之分割演算法僅能判釋大面積之崩塌，故另設崩塌面積 1 公頃之門檻值量化各分割成果之重疊率。精度分析成果顯示，SU 分割成果中以 SU1K 為最佳，在所有面積之判釋率為 44.5%，在大於一公頃之崩塌地則可接近 70%；SNIC 整體分割成果不佳，其中最佳之 SNICxSU1K 在所有崩塌地中判釋率不到 40%，在大面積崩塌區域也僅有 64%。MRS 整體精度顯著優於 SU 與 SNIC 分割成果，且賦予 BSI 與 NDVI 較大權重之組合皆能有較所有波段等權(MRS_w11)高之判釋率，在大面積崩塌地有高達 80% 以上之判釋率。此外，SNIC 及 MRS 加入 SU 資訊進行分割亦都有提升精度，其中以 MRSxSU1K 的分割精度為最佳，在所有面積崩塌地可達約 78%，大面積崩塌更超過 95%。圖 4.3-29 分別展示三種分割演算法 IoU 大於 50% 之物件，其中可以很明確發現 MRSxSU1K 之分割物件最貼合崩塌參考資料（綠色向量資料），且存在較低之漏授錯誤。

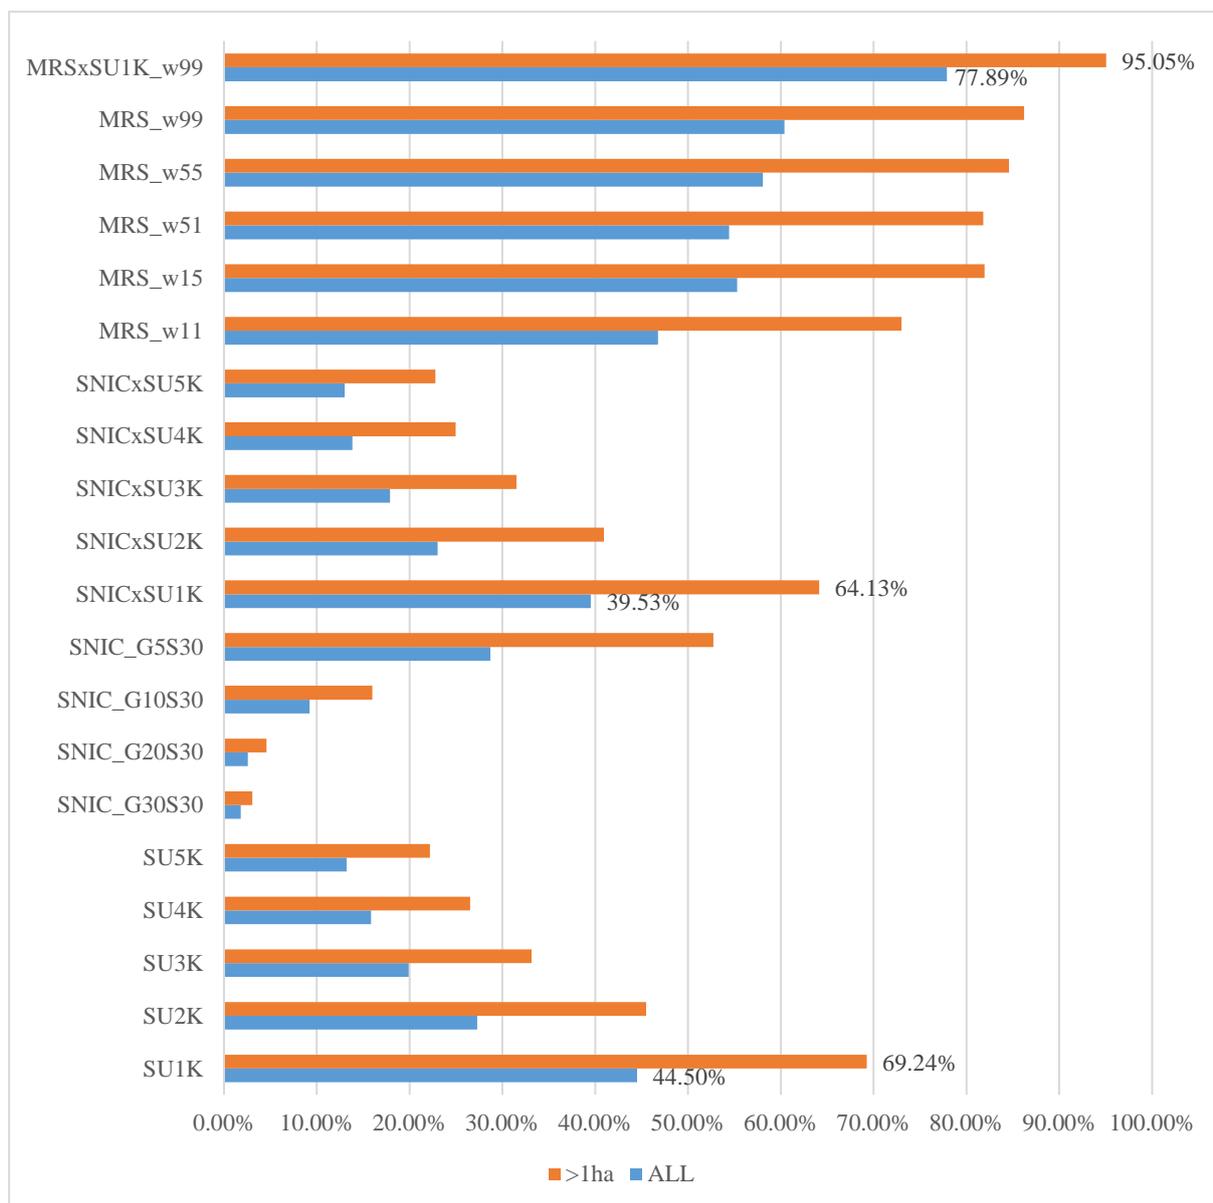


圖 4.3-28、各分割成果 IoU 大於 50%之崩塌參考資料比例

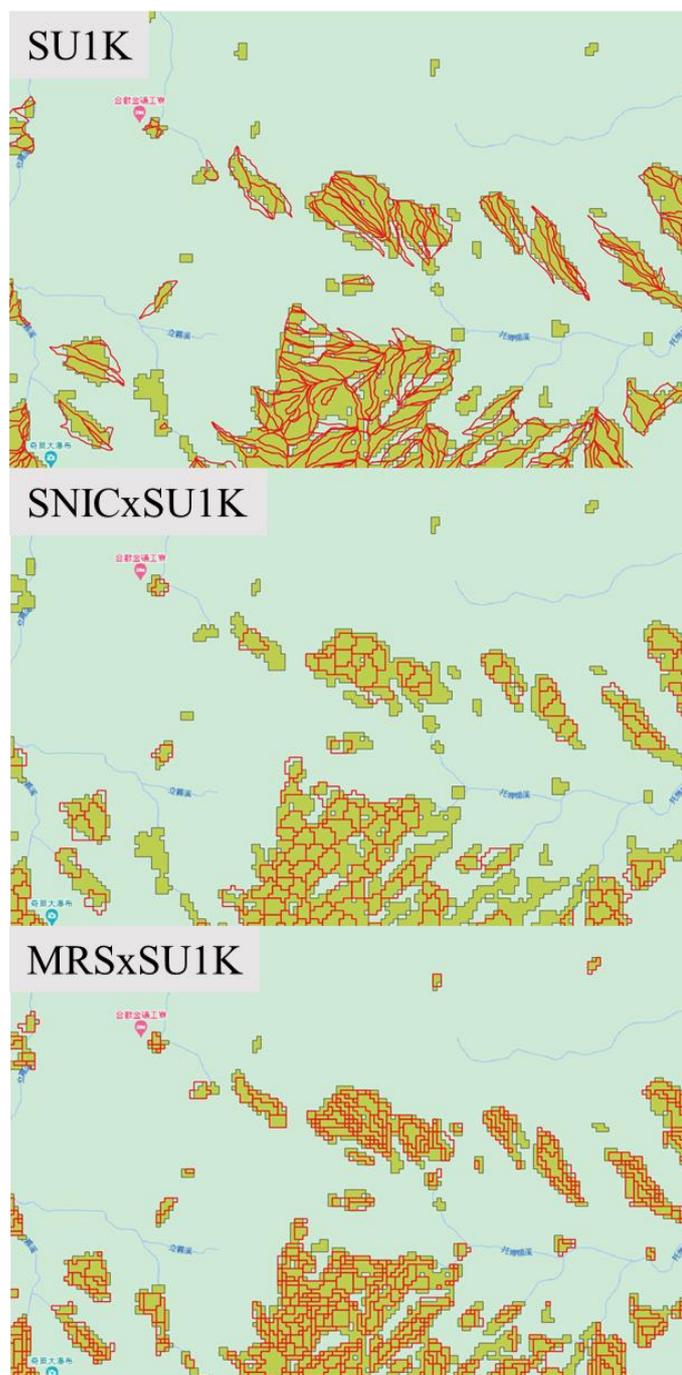


圖 4.3-29、SU1K、SNICxSU1K、MRSxSU1K IoU>50%之分割成果

4.3.3.3 基於機器學習之崩塌地偵測

本項工作建立基於時序及 DEM 特徵之崩塌地偵測程序，並使用機器學習演算法支持向量機(Support Vector Machine, SVM)進行監督式分類，整體

程序如圖 4.3-30 所示，崩塌地偵測程序僅需要輸入欲調查之時間區間之起訖以及調查範圍即可，起訖時間格式為西元年-月-日，如 2015-01-01；調查範圍則可以輸入四角經緯度坐標或是提供帶有絕對地理坐標之向量資料。

偵測程序包含多個子程序：(1) 資料蒐集與匯整，同 4.3.3.1 節，於給定之時間區間與研究範圍於 GEE 平臺中蒐集 LS8 多光譜多時期之影像資料集，並透過位置資訊切取(Clip)內政部 5 公尺 DEM，以獲得研究區域範圍之 DEM 高程資料；(2) 影像前處理，同 4.3.3.1 節，透過雲遮罩與波段運算建立 NDVI 影像資料集，此外，另計算裸土指標(BSI)並將每個像元在多時期影像中該值前 30%之像元進行平均，作為物件分割程序之輸入影像；(3) DEM 特徵萃取，對研究區域內之數值高程模型進行 DEM 衍生特徵之計算，計算程序於 ArcGIS pro 完成，特徵包含坡度(Slope)、坡向(Aspect)、山體陰影(Hillshade)、區域太陽輻射(Area Solar Radiation, ASR)、粗糙度(Roughness)、河流強度指數(Stream Power Index ,SPI)、地形位置指數(Topographic Position Index,TPI)、以及地形濕度指數(Topographic Wetness Index, TWI)，共八個由 DEM 衍生之高程特徵；(4) 物件分割，同 4.3.3.2 節，透過 BSI Top30% 平均影像以及 DEM 高程資訊依不同演算法進行物件分割(Segmentation)，並以分割單元(Segments)為後續資料處理之最小統計單元；(5) 擷取時間序列資料，將所有研究範圍內之分割單元個別擷取該時間區間內之 NDVI 時間序列並進行時間序列預處理（同 4.3.3.1 節），意即每一個分割單元將有一筆編修過之

NDVI 時間序列；(6) 區域統計(Zonal Statistics)，以分割物件為統計單元，將研究範圍內之所有分割物件統計各 DEM 衍生特徵之平均值，換言之，一個分割物件將有 8 個不同 DEM 特徵之區域平均值；(7) 時間序列特徵萃取，此程序透過開源之 python packages—tsfresh(v0.19.0) (Christ et al., 2018)於 Colab 環境實現，對每一個分割物件之 NDVI 時間序列進行特徵萃取，該演算法萃取 77 個類別 (表 4.3-4)，共 789 個時序特徵。此外，為驗證 tsfresh 多特徵之優劣，設計一組僅計算五個簡易統計特徵(Min, Max, Mean, STD, Cumulative NDVIs)之對照組予以比較；(8) 主成分分析(PCA)，此程序目的為透過正交轉換將觀測值中可能相關之多變量進行線性轉換，以降低數據集維度的同時保留數據集中對變異數貢獻最大之特徵。崩塌偵測程序分別對時間序列特徵與 DEM 特徵進行 PCA 轉換，前者時序特徵為 789 維之高維特徵，後者 DEM 特徵為 DEM 一次或是多次衍生物，進行 PCA 轉換之主要目的為降低維度並降低線性相依性；(9) 支持向量機(SVM)，此為機器學習監督式分類程序，以林務局崩塌地參考資料為地真標籤，將 A01 區域內之分割單元以 70/30%分割訓練與測試資料，後將經過主成分轉換之時間序列特徵與 DEM 特徵進行堆疊，以堆疊之融合特徵進行 SVM 分類器之模型訓練與預測。

SVM 分類器之 kernel 函數選擇徑向基函數核(RBF)，除了比較時序特徵數量(5 vs 789)對機器學習分類的影響外，另探討不同物件分割方式對崩

塌地判釋之優劣，研究選取 SU1K、MRS_w99 及 MRSxSU1K_w99 三種不同分割單元進行機器學習模型訓練與預測，分割示意圖如圖 4.3-31。

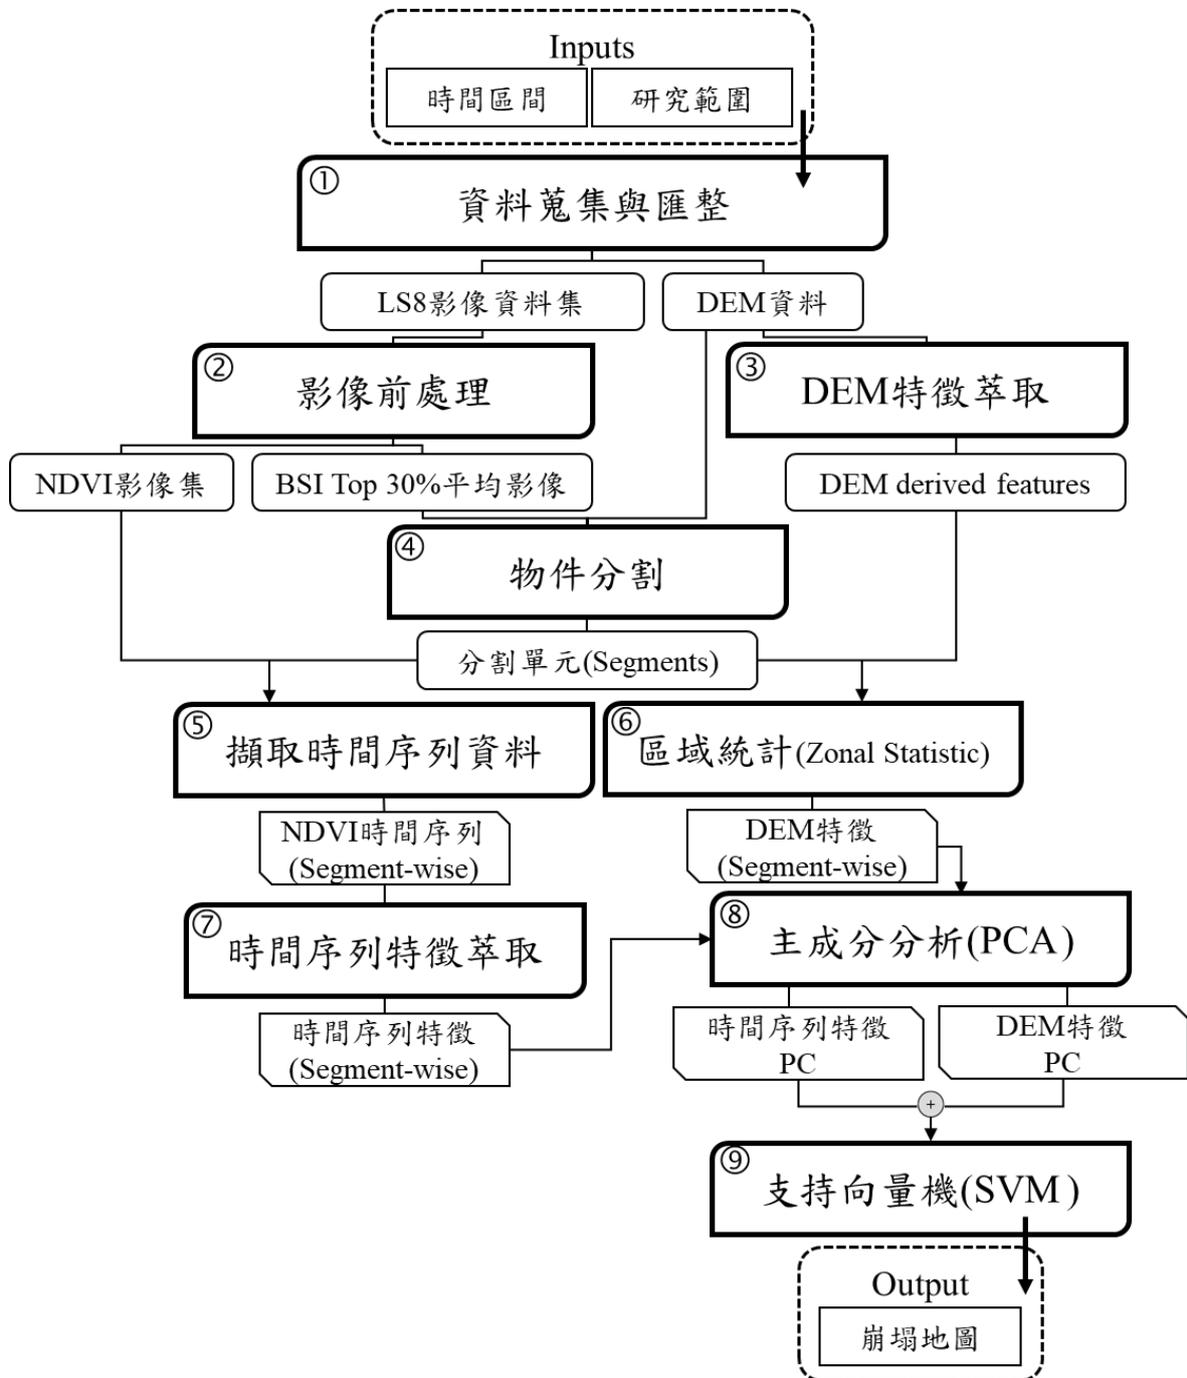


圖 4.3-30、基於機器學習之崩塌地偵測程序圖

表 4.3-4、tsfresh 時序特徵類別

ar_coef	ar_coef	fit_aggre	has_dupli	lempel_zi	max_lang	Median	percentag	root_mea	sum_of_r	variation
cient	cid_ce	gated	cate_max	v_comple	evin_fixe	ond_deri	e_of_reoc	n_square	eoocurrin	coefficie
approxim	change_q	energy_ra	has_dupli	last_locat	matrix_pr	mean_sec	percentag	ratio_val	sum_of_r	variance
ate_entro	quantiles	tio_by_ch	cate	ion_of_m	ofile	ond_deri	e_of_reoc	ue_num	eoocurrin	larger_th
py		unks		imum		vative_ce	curring_d	er_to_tim	g_data_p	an_stand
agg_linea	c3	cwt_coef	friedrich	last_locat	longest_s	mean_n	partial_au	ratio_bey	standard	variance
r_trend		icients	coefficien	ion_of_m	trike_bel	absolute	tocorrelat	ond_r_sig	deviation	
			ts	aximum	ow_mean	max	ion	ma		
agg_auto	binned_e	count_bel	fourier_e	large_sta	longest_s	mean_ch	number	range_co	spkt_wel	value_co
correlatio	ntropy	ow_mean	ntropy	ndard_de	trike_abo	ange	peaks	unt	ch_densit	unt
n				viation	ve_mean				y	
absolute	benford	count_bel	first_loca	kurtosis	linear_tre	mean_abs	number_c	query_si	skewness	time_reve
sum_of_c	correlatio	ow	tion_of		nd_timew	change	wt_peaks	milarity	rsal_asy	mmetry_s
hanges	n		minimum		ise			count		
absolute	autocorre	count_ab	first_loca	index_ma	linear_tre	mean	number_c	quantile	set_prope	symmetry
maximu	lation	ove_mea	tion_of	ss_quant	nd		rossing		rty	looking
m		n	maximu	le			m			
abs_ener	augmente	count_ab	fit_coef	has_dupli	length	maximu	minimum	permutati	sample_e	sum_valu
gy	d_dickey	ove	cient	cate_min		m		on_entro	ntropy	es
	_fuller							py		

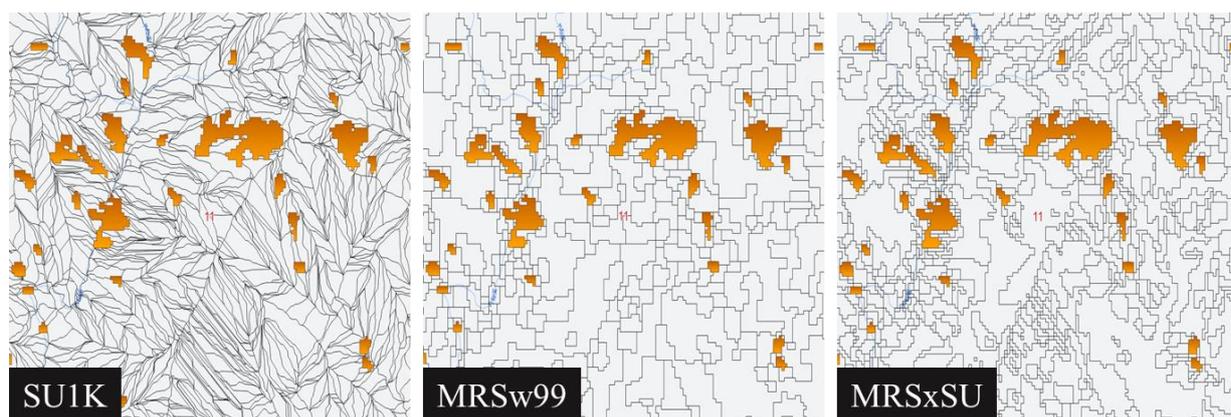


圖 4.3-31、SU1K、MRS_w99 及 MRSxSU1K_w99 之分割示意圖

使用與林務局崩塌參考資料 IoU 大於 50% 之分割物件於 A01 區域進行模型訓練，其測試資料預測結果如表 4.3-5 所示，S 代表僅用 5 個時序特徵之組合、F 代表使用 tsfresh 萃取之 789 個時序特徵、+P 代表對時間序列特徵進行 PCA 轉換並保留累積解釋變異量大於 90% 之主成分、+D 則代表加入 DEM 特徵之 PC1~6。以 SU1K 為例，其總樣本分別為崩塌地之正樣本 5439 個分割物件及非崩塌地之負樣本 5398 個分割物件，分別對各物件進行時間序列特徵萃取與 DEM 特徵區域統計，再將正負樣本隨機分割(Split)70% 為訓練、30% 為測試，並計算測試資料預測成果之各項分類精度指標 (Accuracy, Precision, Recall, F1-score, Kappa, AUC, Omission, Commission)。

無論是以何種分割單元進行模型訓練與預測，tsfresh 演算法皆被證實可萃取大量有分辨力之時序特徵(F>S)。另外，將 tsfresh 萃取之時序特徵進行主成分轉換後分類精度在測試資料上有顯著提升(F+P>F)。除此之外，加入 DEM 特徵之 PC1~6 在三種分割物件之預測成果皆顯示能降低漏授及誤

授誤差率以提升整體精度($F+P+D>F+P$)。在良好訓練測試資料集中各模型皆能有效分辨崩塌與非崩塌之物件，Accuracy 皆大於 0.94（表上紅框）。

表 4.3-5、SVM 模型測試集分類精度

min_ts=16	SU1K				
Samples (LS/nLS)	5439/5398=10837				
type	S	S+D	F	F+P	F+P+D
Dim.	5	11	789	138	144
Accuracy	0.8725	0.8941	0.9247	0.9576	0.9662
Precision	0.8733	0.8944	0.9252	0.9578	0.9663
Recall	0.8724	0.8942	0.9245	0.9574	0.9661
F1-Score	0.8724	0.8941	0.9246	0.9575	0.9662
Kappa	0.7450	0.7882	0.8493	0.9151	0.9323
AUC	0.8724	0.8942	0.9245	0.9574	0.9661
Omission	0.1041	0.0919	0.0596	0.0322	0.0286
Commission	0.1437	0.1176	0.0868	0.0507	0.0379
min_ts=16	MRS_w99				
Samples (LS/nLS)	6423/6400=12823				
type	S	S+D	F	F+P	F+P+D
Dim.	5	11	789	134	140
Accuracy	0.7820	0.8995	0.9069	0.9485	0.9683
Precision	0.7881	0.8996	0.9073	0.9486	0.9683
Recall	0.7809	0.8995	0.9068	0.9485	0.9683
F1-Score	0.7804	0.8995	0.9069	0.9485	0.9683
Kappa	0.5630	0.7990	0.8138	0.8970	0.9366
AUC	0.7809	0.8995	0.9068	0.9485	0.9683
Omission	0.1441	0.1085	0.0793	0.0474	0.0319
Commission	0.2499	0.0935	0.1024	0.0542	0.0309

min_ts=16	MRSxSU1K_w99				
Samples (LS/nLS)	15110/15000=30110				
type	S	S+D	F	F+P	F+P+D
Dim.	5	11	789	133	139
Accuracy	0.7818	0.8748	0.8875	0.9290	0.9456
Precision	0.7873	0.8752	0.8876	0.9290	0.9456
Recall	0.7822	0.8746	0.8874	0.9291	0.9457
F1-Score	0.7809	0.8747	0.8875	0.9290	0.9456
Kappa	0.5640	0.7494	0.7749	0.8580	0.8913
AUC	0.7822	0.8746	0.8874	0.9291	0.9457
Omission	0.1493	0.1417	0.1059	0.0716	0.0596
Commission	0.2544	0.1153	0.1140	0.0681	0.0478

將獨立驗證區 A02 劃分為 15 個五千分之一圖幅框之大小(圖 4.3-32)，並考量訓練區 A01 為高海拔之區域，故將 A02 高海拔區域(#7-15)進行獨立分析，精度評估以計算模型預測與地真崩塌參考資料間之 IoU 值、誤授誤差率及漏授誤差率。各分割模型獨立驗證之精度如表 4.3-6，時間序列特徵搭配 DEM 特徵能有效辨識崩塌地，無論是哪一種分割物件單元在高海拔大面積區域(>1ha)之漏授誤差皆小於前年度(0.26)。三種分割物件模型中，以 MRSxSU 分割方式之 SVM-F+P+D 模型漏授率誤差為最低，在所有面積崩塌中達 0.162，大面積崩塌則為 0.061。然而，各模型獨立驗證結果皆顯示 IoU 值不高（皆小於 0.6），意即分類成果含有誤授誤差，而主要因素為影像分割之細緻度受限於影像解析度(30m)。基於機器學習之崩塌地偵測之輸出為崩塌地圖，可視化成果以漏授誤差率最低之 MRSxSU 分割物件訓練之

SVM-F+P+D 模型為例(圖 4.3-33),紅色向量資料為林務局崩塌參考資料,藍色向量資料則為機器學習演算法 SVM-F+P+D 判釋之成果。成果顯示,整體預測與林務局崩塌參考資料之分布接近,絕大多數之崩塌地皆能正確判釋,僅因受限影像空間解析度導致細緻度略遜於崩塌參考資料。

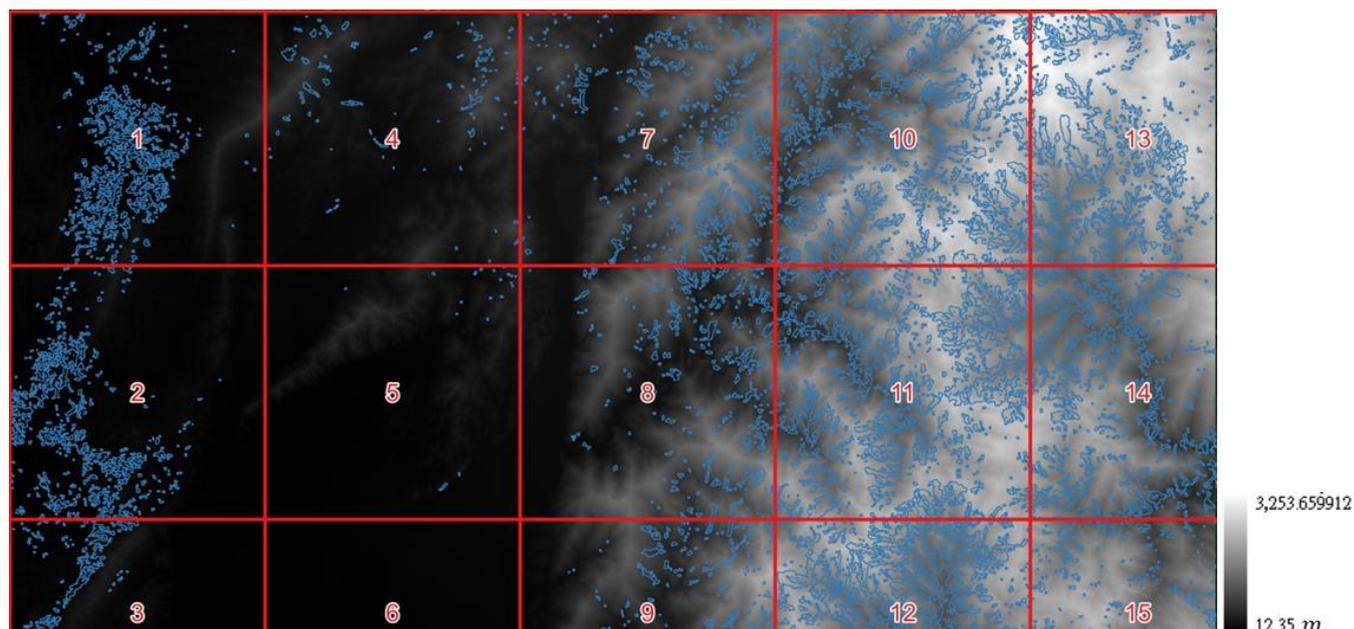


圖 4.3-32、獨立檢核區之圖幅編號與 DEM (藍色為崩塌參考資料)

表 4.3-6、SVM-F+P+D 模型獨立驗證精度評估

Unit: ha	Segments	SU1K	
	#	Total	#7-15
ALL	Intersection	11163.814	11056.099
	Union	32702.942	28261.695
	IoU	0.341	0.391
	Commission	0.368	0.331
	Omission	0.440	0.291
> 1ha	Intersection	10930.952	10826.254
	Union	31909.717	27725.404
	IoU	0.343	0.390

	Commission	0.360	0.320
	Omission	0.325	0.167
Unit: ha	Segments	MRSw99	
	#	Total	#7-15
ALL	Intersection	10195.166	10067.440
	Union	21785.473	18839.158
	IoU	0.468	0.534
	Commission	0.128	0.119
	Omission	0.503	0.376
> 1ha	Intersection	10020.713	9897.037
	Union	20933.840	18243.426
	IoU	0.479	0.542
	Commission	0.145	0.145
	Omission	0.343	0.194
Unit: ha	Segments	MRSxSU	
	#	Total	#7-15
ALL	Intersection	11874.243	11597.279
	Union	25187.932	22098.677
	IoU	0.471	0.525
	Commission	0.358	0.352
	Omission	0.320	0.162
> 1ha	Intersection	11543.880	11273.307
	Union	24492.209	21656.514
	IoU	0.471	0.521
	Commission	0.248	0.243
	Omission	0.214	0.061

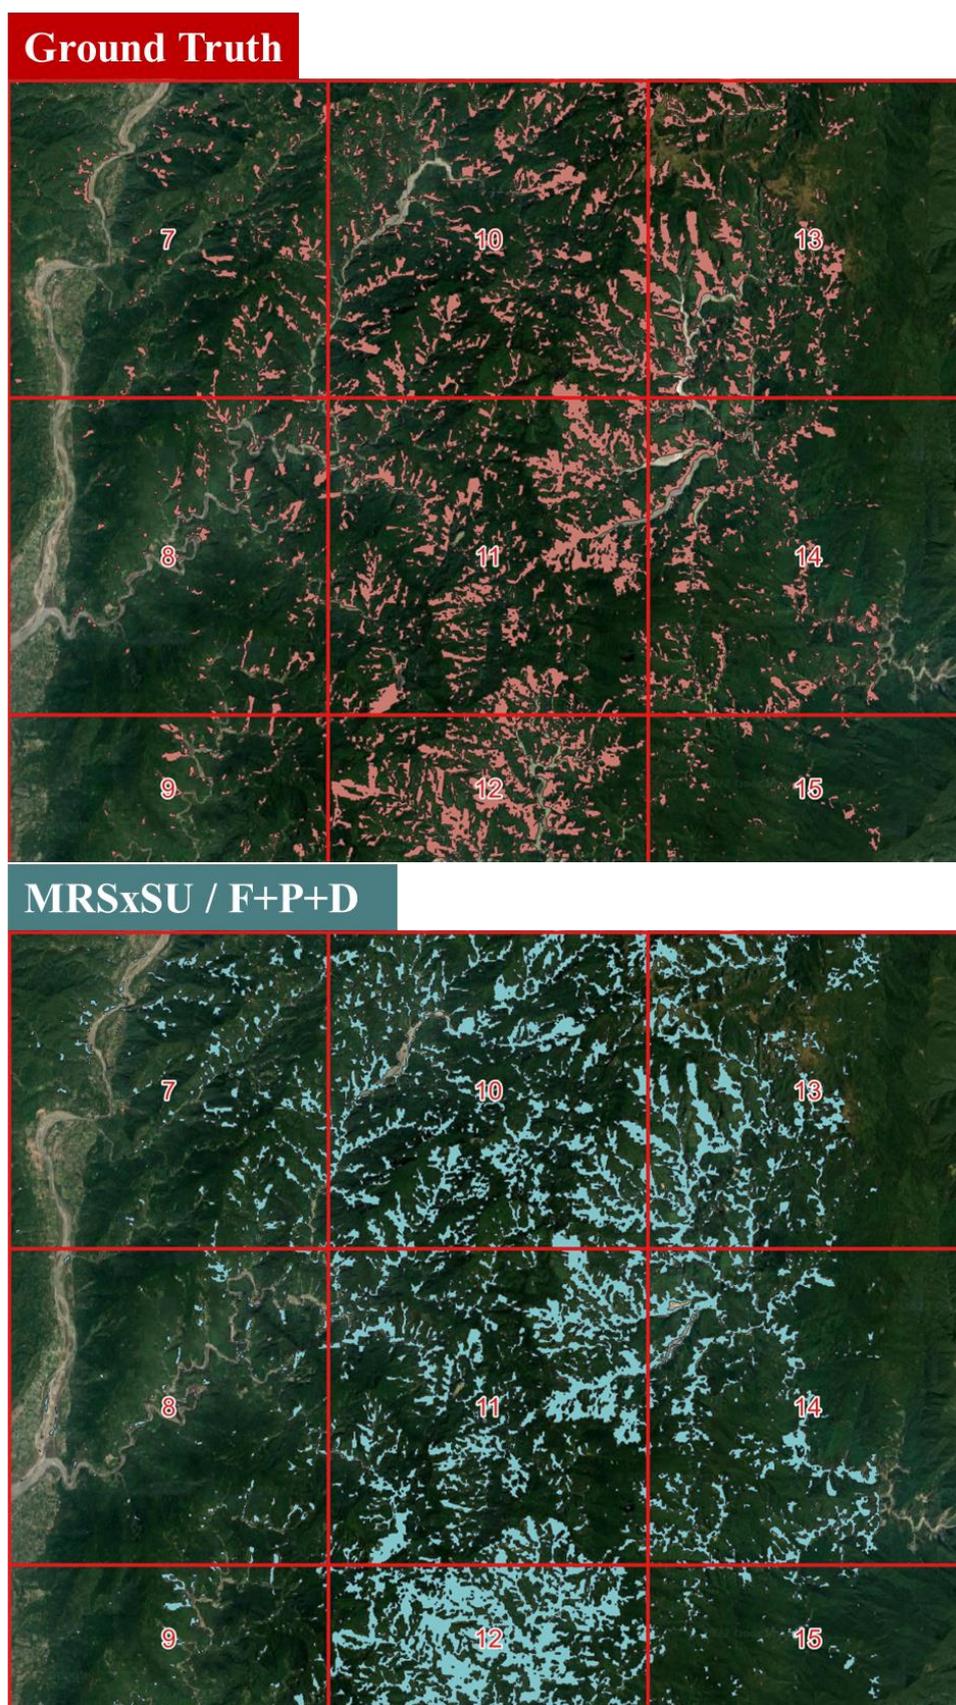


圖 4.3-33、獨立檢核區之崩塌參考資料與 SVM 預測崩塌地圖

4.3.3.4 基於深度學習之崩塌地偵測

本項工作另建立基於深度學習演算法之崩塌地偵測程序，透過整合時間序列資料與 DEM 高程資料對 MRSxSU 之分割物件進行監督式分類，整體程序如圖 4.3-34 所示，深度學習崩塌地偵測程序與 4.3.3.3 節之機器學習崩塌地偵測程序之相似，輸入為欲調查之時間區間之起訖及待調查之範圍，子程序(1)至子程序(6)與機器學習崩塌偵測程序雷同，該階段性程序之中間產物為以分割物件為單元之 NDVI 時間序列以及以分割物件為統計單元之 DEM 特徵平均值，而子程序(7)主成分分析僅對 DEM 特徵進行 PCA 轉換，以降低各衍生特徵間之線性相依性。

研究保留僅經過預處理程序之 NDVI 時間序列資料，並設計其與 DEM 區域特徵平均值 PC1~PC6 之融合策略，策略如下：(一)單變量融合策略，將 DEM 特徵主成分視為時間序列之末 6 筆資料，以單變量時間序列之資料型式作為深度學習訓練之資料集，如圖 4.3-35；(二)雙變量融合策略，將 DEM 特徵主成分拉張至時間序列長度，以堆疊之型式建立雙變量之時間序列資料，以此作為模型訓練預測之樣本，如圖 4.3-36。

子程序(8)主要進行深度學習模型訓練及預測，研究比較兩種 state-of-the-art 的時間序列分類深度學習模型，並與設計之兩種資料融合策略一併討論與分析。第一種深度學習模型為 LSTM-FCN (Karim et al., 2017)，長短期記憶(Long Short-Term Memory, LSTM)為遞迴神經網路(Recurrent

Neural Network, RNN)之改良，已在多個領域被證實其透過輸入門(Input gate)、遺忘門(Forget gate)、輸出門(Output gate)去學習序列中的時間依賴關係，進而分辨時間序列；全卷積網路(Fully Convolutional Networks, FCN)，為透過卷積層取代傳統 CNN 中之全連接層以進行特徵萃取與分類，亦為成熟之網路架構，最常應用於圖像之語意分割。LSTM-FCN 則是將序列資料同時輸入 LSTM 與 FCN 網路，並將各自的輸出（特徵圖）合併再連接上 Softmax 層以進行時間序列之分類。其 LSTM 網路透過維度置換(Dimension Shuffle)提高較少變量(變量數小於時序長度)之時間序列之模型訓練速度，並且引入注意力機制(Attention Mechanism)對輸入之特徵賦予不同之權重以萃取出更具分辨力之資訊，進而加速模型收斂也可提升分類精度；FCN 網路由三個堆疊的時間卷積(Temporal Convolution)塊組成，使用批量標準化(Batch Normalization)並以 ReLU 為激活函數，第三層時間卷積後則連接全局平均池化層。模型訓練以 Cross Entropy 為損失函數，並使用 Adam optimizer 進行優化，學習率(Learning rate)為 0.0001，批量大小(Batch size)為 256。

第二種深度學習模型為 TCN (Bai et al., 2018)，全名為時間卷積網路(Temporal Convolution Network)，其網路設計主要為克服 LSTM 網路在長序列資料上之資訊遺漏，透過 1-D 的全卷積層(FCN)與因果卷積(Causal Convolution)層搭配空洞卷積(Dilated Convolution)實現。由於因果卷積僅專

注於當下時間及其前一刻時間之資訊，若需考量整個時間序列時間斷內所有資訊，網路深度將會非常地深。因此，TCN 網路引入空洞卷積來增加感受野(Receptive Field)以減少過多參數之運算，並且加入殘差塊(Residual block)來避免較深網路可能會引起之梯度消失(Gradient vanishing)問題。模型訓練以 Cross Entropy 為損失函數，並使用 SGD optimizer 進行優化，學習率(Learning rate)為 0.001，批量大小(Batch size)為 256。

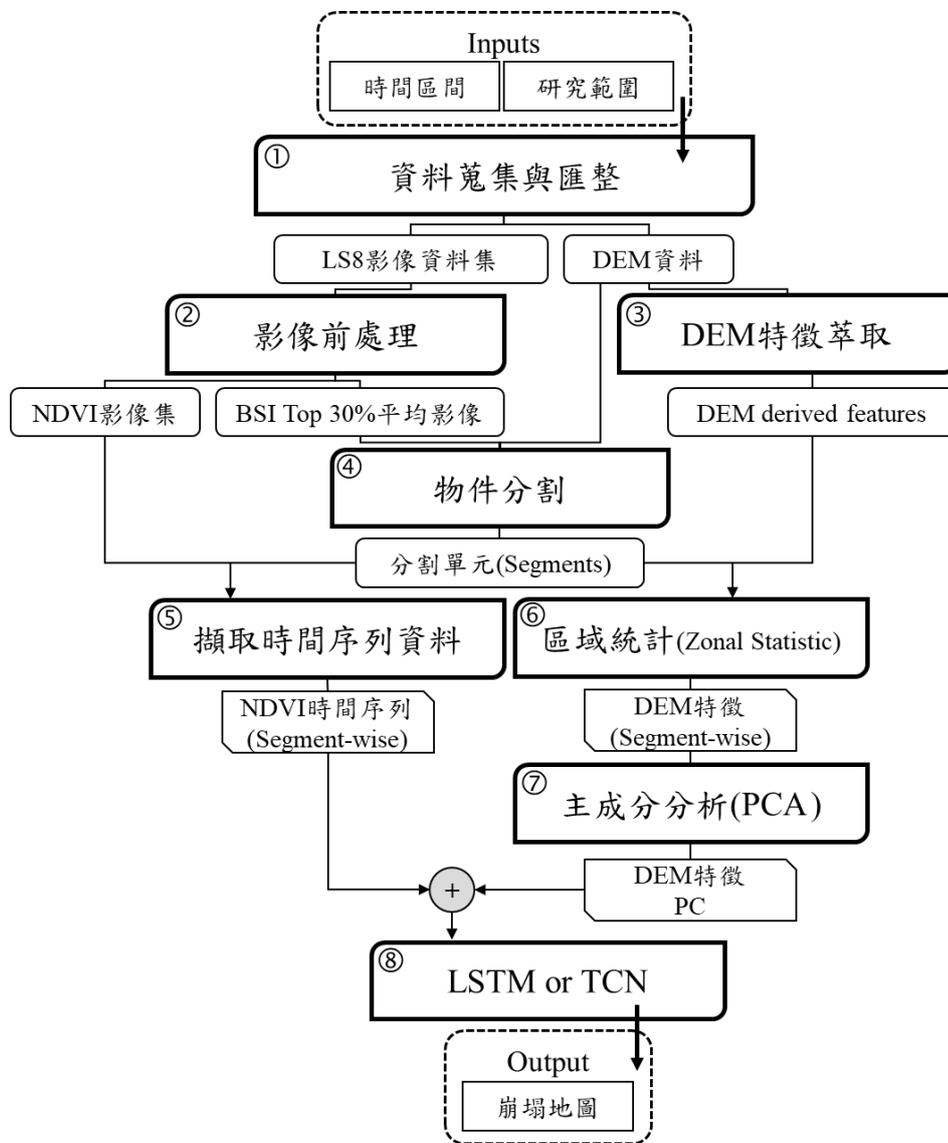


圖 4.3-34、基於深度學習之崩塌地偵測程序圖



圖 4.3-35、單變量時序資料與 DEM 特徵融合策略

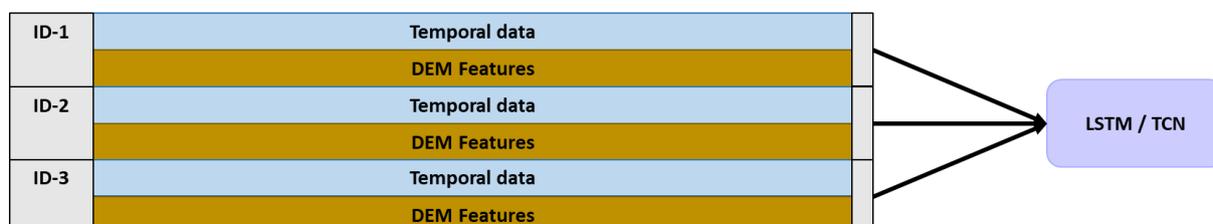


圖 4.3-36、雙變量時序資料與 DEM 特徵融合策略

使用林務局崩塌參考資料 IoU 大於 50% 之 MRSxSU1K_w99 分割物件於 A01 區域進行模型訓練，其測試資料預測結果如表 4.3-7 所示，T 代表僅使用 NDVI 時間序列、+D 代表將時間序列與 DEM 特徵主成分進行資料融合、/Uni. 及 /Bi. 則分別代表單變量(Univariate)融合策略與雙變量(Bivariate)融合策略。由於 NDVI 時間序列經過預處理程序已重新採樣至每週一筆，故僅使用 NDVI 時間序列為輸入之資料維度為 209，透過單變量融合策略之 T+D/Uni. 維度為 209+6，雙變量融合策略之 T+D/Bi. 則為 209x2。無論是何種深度學習模型或是哪一個 DEM 特徵融合策略，各模型在良好測試資料中皆能有 90% 以上之準確率，其餘精度指標也皆顯示良好的分類成果。然而，深度學習模型可能存在對訓練資料過擬合(Overfitting)之現象，故另需觀察 loss curve 收斂狀況。

各模型收斂行為之 Loss curve 如圖 4.3-37 所示，LSTM 模型中以

LSTM_FCN T+D/Bi.模型訓練較為穩定；LSTM_FCN T+D/Uni.網路雖然有收斂，但在訓練末期發生振盪。即便 TCN 網路設計已盡力避免過擬合現象之發生，但在模型訓練後期仍發生過擬，故另設定 Early stopping 容忍條件以提早中斷訓練並保留 loss 最低之模型。由於各模型訓練並未發散，且在訓練測試資料集皆能有良好之判釋成果，並未能透過 loss curve 評斷融合策略與深度學習網路之優劣。將獨立驗證區 A02 分為全區(Total)以及高海拔區域(#7-15)分別進行精度評估分析，精度評估以計算模型預測與地真崩塌參考資料間之 IoU 值、誤授誤差率及漏授誤差率。

表 4.3-7、深度學習模型測試集分類精度

min_ts=16	MRSxSU1K_w99					
Samples (LS/nLS)	15110/15000=30110					
model	LSTM_FCN			TCN		
	T	T+D/Uni.	T+D/Bi.	T	T+D/Uni.	T+D/Bi.
Dim.	209	209+6	209x2	209	209+6	209x2
Accuracy	0.9290	0.9146	0.9259	0.9332	0.9694	0.9078
Precision	0.9290	0.9147	0.9259	0.9332	0.9694	0.9079
Recall	0.9290	0.9149	0.9261	0.9332	0.9696	0.9080
F1-Score	0.9290	0.9146	0.9259	0.9332	0.9694	0.9078
Kappa	0.8580	0.8293	0.8519	0.8664	0.9389	0.8156
AUC	0.9290	0.9149	0.9261	0.9332	0.9696	0.9080
Omission	0.0676	0.0968	0.0805	0.0655	0.0363	0.1044
Commission	0.0715	0.0728	0.0660	0.0657	0.0240	0.0790

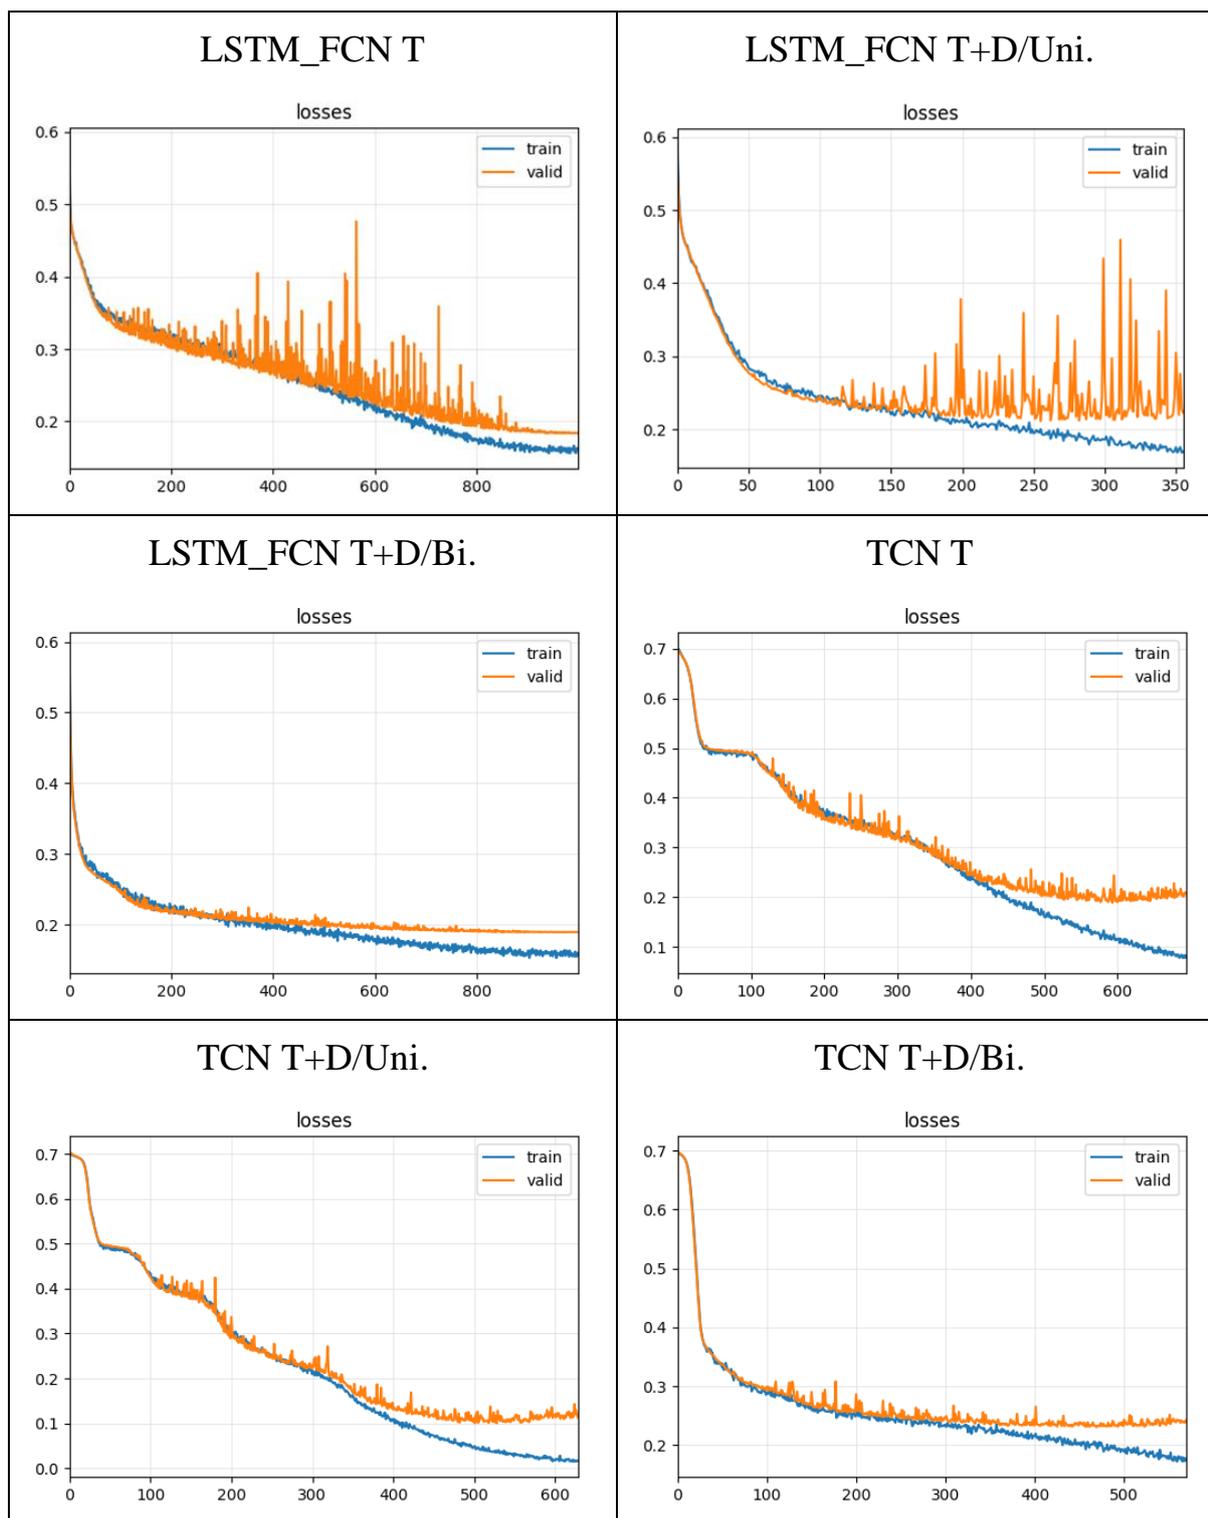


圖 4.3-37、深度學習模型訓練 Loss curve 圖

獨立驗證區 A02 全區之各模型與融合策略之精度評估量化成果如表

4.3-8。LSTM 網路模型預測成果顯示，時間序列搭配 DEM 特徵能提升崩塌地辨識成果，在所有面積預測成果中以 T+D/Uni.為最佳（IoU 最高；漏授次低；誤授最低），T+D/Bi.模型為次佳（IoU 次高；漏授最低；誤授次低），未使用 DEM 高程資訊之模型成果並不能良好分辨崩塌與非崩塌之分割單元（IoU 僅 0.313，誤授率高達 0.523）；在崩塌面積大於 1 公頃之預測成果以 T+D/Uni.為最佳（IoU 達 0.531；漏授率 0.182；誤授率僅 0.117）。TCN 網路模型預測成果顯示，僅有雙變量 DEM 融合策略(T+D/Bi.)可有效提升崩塌地辨識精度，並與 LSTM 網路精度相當（IoU 達 0.5 以上；漏授誤差率接近）；在崩塌面積大於 1 公頃之預測成果亦以 T+D/Bi.模型為最佳，誤授率更勝 LSTM T+D/Uni.模型，僅 0.165。

表 4.3-8、深度學習模型獨立驗證精度評估（全區）

Unit: ha	Model	LSTM_FC		
		T/Uni.	T+D/Uni.	T+D/Bi.
ALL	Intersection	10074.545	11156.416	11376.813
	Union	32152.648	21359.683	23030.038
	IoU	0.313	0.522	0.494
	Commision	0.523	0.222	0.357
	Omission	0.394	0.339	0.331
> 1ha	Intersection	9817.276	10918.772	11084.348
	Union	31383.831	20571.241	22296.418
	IoU	0.313	0.531	0.497
	Commision	0.490	0.117	0.197
	Omission	0.279	0.182	0.217
Unit: ha	Model	TCN		
		T/Uni.	T+D/Uni.	T+D/Bi.

ALL	Intersection	10215.840	12989.231	11078.281
	Union	37198.233	61267.410	21956.401
	IoU	0.275	0.212	0.505
	Commision	0.593	0.691	0.317
	Omission	0.302	0.160	0.320
> 1ha	Intersection	9876.388	12482.258	10840.727
	Union	36511.599	60748.296	21167.870
	IoU	0.271	0.205	0.512
	Commision	0.588	0.656	0.159
	Omission	0.193	0.090	0.165

獨立驗證區 A02 高海拔區域(#7-15)之各模型與融合策略之精度評估量化成果如表 4.3-9。LSTM 網路模型預測成果顯示，時間序列特徵搭配 DEM 特徵能提升崩塌地辨識成果，在所有面積與大面積崩塌判釋成果中，T+D/Uni.與 T+D/Bi.精度相當，並未有哪一種融合策略顯著優於另一者，漏授率分別 0.074 及 0.058，而未使用 DEM 高程資訊之模型成果明顯為最差。TCN 網路模型預測成果顯示，僅有雙變量 DEM 融合策略(T+D/Bi.)可有效提升崩塌地辨識精度，並與 LSTM 網路精度相當（IoU 達 0.5 以上；漏授誤差率接近）；在崩塌面積大於 1 公頃之預測成果亦以 T+D/Bi.模型為最佳，誤授率僅 0.073。

LSTM 與 TCN 深度學習模型皆能有效從時序與 DEM 特徵中判釋崩塌地，可視化成果放大於圖幅#10 之區域（圖 4.3-38），由深度學習模型預測之崩塌地圖與林務局崩塌參考資料之分布相當一致，多數崩塌地皆能被正確判釋，河道區域也能被正確分類為非崩塌地，各模型間預測成果接近。

表 4.3-9、深度學習模型獨立驗證精度評估（高海拔區#7-15）

Unit: ha	Model	LSTM_FC		
	#7-15	T/Uni.	T+D/Uni.	T+D/Bi.
ALL	Intersection	9996.325	10507.528	11158.984
	Union	26279.186	18332.536	19859.502
	IoU	0.380	0.573	0.562
	Commision	0.396	0.228	0.341
	Omission	0.234	0.227	0.171
> 1ha	Intersection	9740.316	10283.026	10874.710
	Union	25769.060	17790.904	19377.642
	IoU	0.378	0.578	0.561
	Commision	0.352	0.120	0.170
	Omission	0.112	0.074	0.058
Unit: ha	Model	TCN		
	#7-15	T/Uni.	T+D/Uni.	T+D/Bi.
ALL	Intersection	9762.635	11970.039	10392.579
	Union	26576.564	46736.321	18763.002
	IoU	0.367	0.256	0.554
	Commision	0.403	0.540	0.299
	Omission	0.228	0.092	0.222
> 1ha	Intersection	9463.058	11527.965	10171.497
	Union	26110.006	46412.261	18217.949
	IoU	0.362	0.248	0.558
	Commision	0.343	0.452	0.149
	Omission	0.128	0.036	0.073

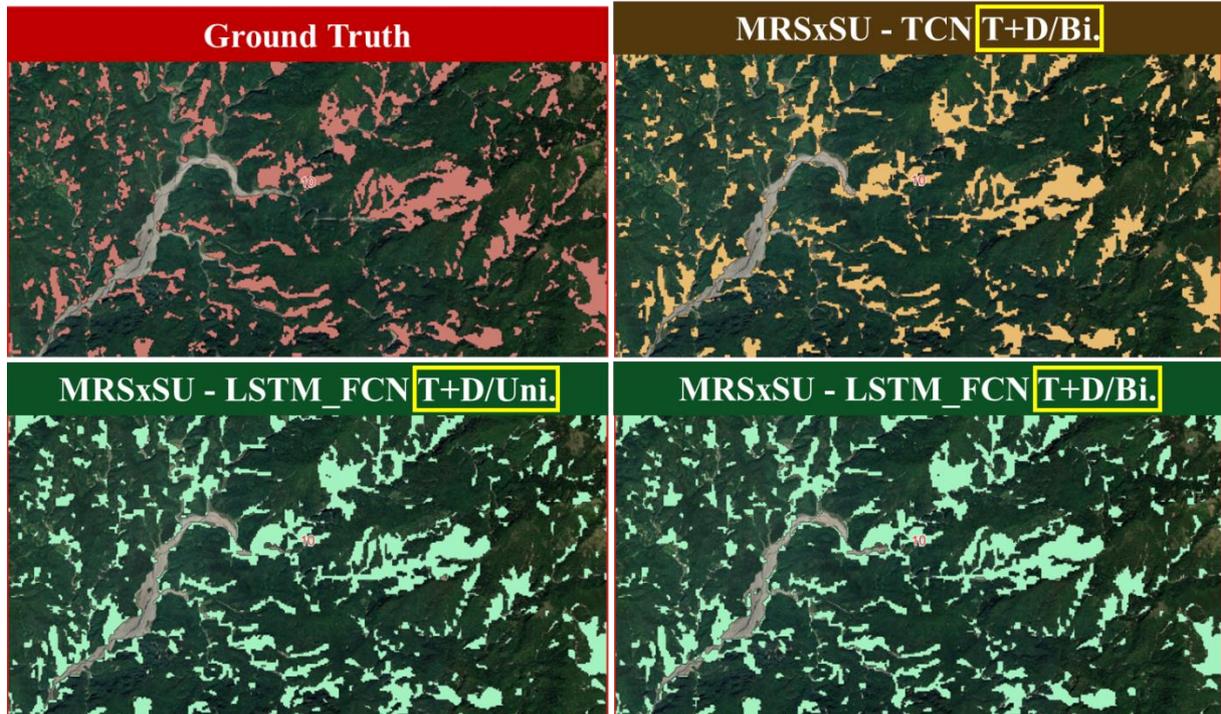


圖 4.3-38、獨立檢核區#10 之崩塌參考資料與深度學習預測崩塌地圖

與 4.3.3.3 節之機器學習崩塌偵測演算法於高海拔區域進行模型橫向之優劣分析比較，其精度分析彙整於表 4.3-10。在所有面積預測成果(ALL)中，SVM-F+P+D 模型漏授誤差最低(0.162)，但其誤授誤差較深度學習模型(DL)大，IoU 值也較低；在面積大於 1 公頃之預測成果(>1ha)中，以 LSTM-T+D/Bi.模型漏授率最低(0.058)，且誤授率與 IoU 表現皆優於機器學習模型(ML)。無論是 ML 或是 DL 模型在大面積崩塌地之判釋成果相當，漏授誤差差距小於 0.3 個百分比(0.061 vs 0.058)。然而，DL-based 模型能獲得較 ML-based 模型低之誤授率與較高之 IoU 值，在可視化成果圖 4.3-39 中黃色圈選處可以發現 DL-based 模型能減少錯誤分類並且在整體預測耗時上顯著優於 ML-based 演算法，耗時比約為 1:11，表 4.3-11 統計獨立驗證

區#10 及#11 之運算時間。

表 4.3-10、機器學習與深度學習模型獨立驗證精度比較（高海拔區#7-15）

Unit: ha	#7-15	Method	ML	DL		
			SVM-F+P+D	LSTM-T+D/Uni.	LSTM-T+D/Bi.	TCN-T+D/Bi.
ALL		IoU	0.525	0.573	0.562	0.554
		CE	0.352	0.228	0.341	0.299
		OE	0.162	0.227	0.171	0.222
> 1ha		IoU	0.521	0.578	0.561	0.558
		CE	0.243	0.120	0.170	0.149
		OE	0.061	0.074	0.058	0.073

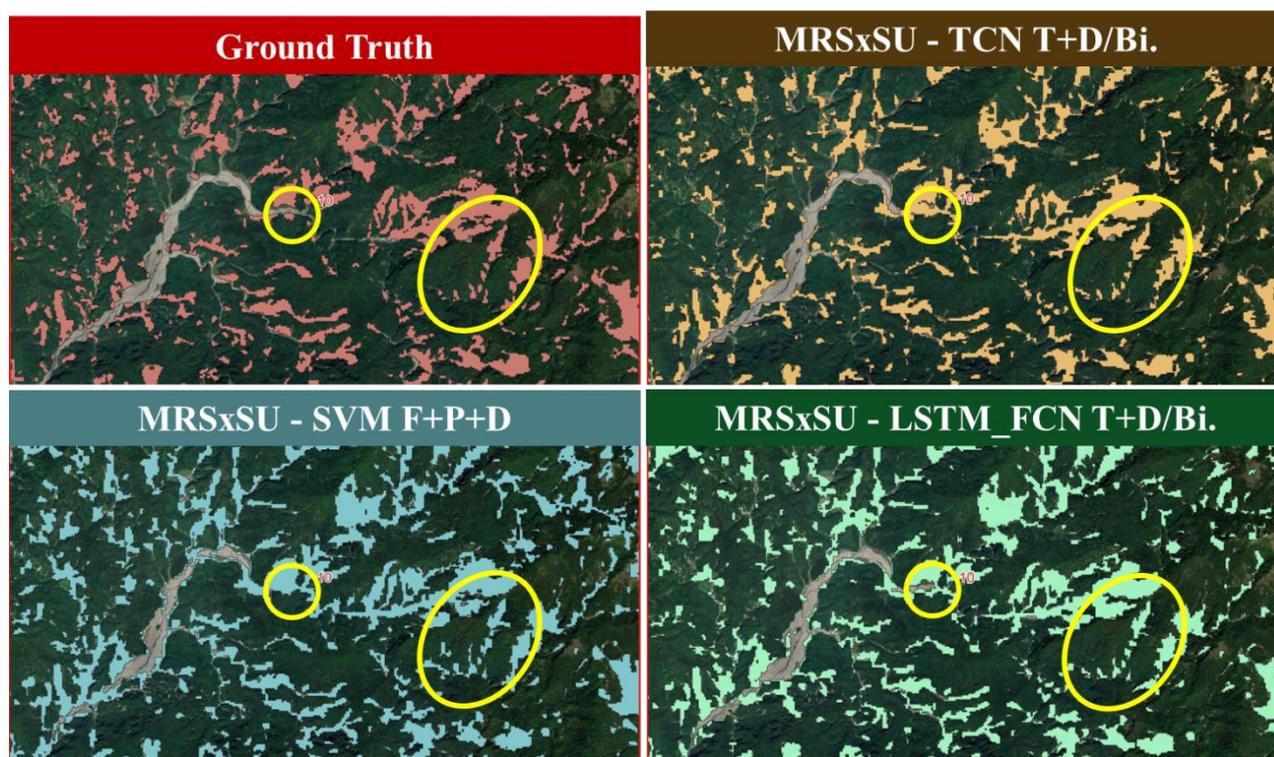


圖 4.3-39、獨立檢核區#10 之機器學習與深度學習預測崩塌地圖

表 4.3-11、機器學習與深度學習模型預測耗時(#10-11)

#10	18946 segments	ML	DL
	Pre-processing	04:01	04:00
	Feature Extraction	43:34	00:02
	Prediction	00:20	
	Total	47:55	04:02
#11	19135 segments	ML	DL
	Pre-processing	04:13	04:11
	Feature Extraction	44:19	00:02
	Prediction	00:19	
	Total	48:51	04:13

4.3.4 前述試辦本團隊需自行取得相關資料，並協調應用平臺之整合

前述應用試辦所需之雷達影像、光學影像及應用平臺之取得均由本團隊進行資料獲取。時序光學衛星影像、變異區域向量資料及識別成果均以資料集(Dataset)的方式，整合在 GEE 應用平臺中，具有資料存取及處理之便利性。

4.3.5 以臺灣地區航遙測影像進行地物辨識與分類，辦理區域範圍至少為五

千分之一圖幅 10 幅（含）以上，辦理區域需與內政部討論選定且得洽內政部協助提供必要之既有測繪圖資

房屋區域是大比例尺數值地形圖或臺灣通用電子地圖不可缺少的圖資，

因應地物的變遷，為確保圖資的時效性，圖資更新為必要的工作。由於局部圖資更新會比全部重測更有效率，故本項工作以房屋變遷偵測為應用主題進行試辦作業，並在作業中導入人工智慧(Artificial Intelligence, AI)技術提升偵測品質。

本項工作前期(110年)使用臺灣地區前後期臺灣通用電子地圖建物圖層及對應的正射影像進行房屋區域變遷之試辦作業，成果顯示由於航遙測影像中房屋存在高差移位，使影像中房屋範圍與臺灣通用電子地圖中建物輪廓有差別，因此降低AI偵測房屋之精度，且不同年度之航遙測影像因高差移位量不同，前後期房屋範圍也不一致，導致AI在偵測變遷時誤將高差移位量變化視為物件改變，進而影響房屋變遷偵測成果。為克服航遙測影像中房屋高差移位之影響，精進房屋變遷偵測成果，本年度工作目標為使用臺灣地區前後期航遙測影像及數值地表模型(Digital Surface Model, DSM)進行房屋區域變遷偵測(Teo and Shih, 2013)之試辦作業，並採用臺灣通用電子地圖進行成果分析。研究使用的DSM經由影像密匹配而得後，再利用此DSM產製正射影像，儘可能消除房屋高差移位。本項工作具體成果為分析利用智慧辨識技術進行臺灣地區房屋區域變遷偵測之品質，以探討圖資更新作業導入人工智慧之效益。未來成果可應用於檢視房屋變遷與否並判斷變遷比例，以評估圖資更新的優先順序，針對局部區域替換圖資，提升資料更新效率。

工作內容分為三個部分，第一部分為資料蒐集與前處理，取得臺灣通用電子地圖及其對應數位航空影像後，將航空影像經方位重建、影像密匹配及影像正射化等程序，產製前後期 DSM 及正射化航遙測影像；第二部分為訓練類神經網路進行房屋變遷偵測；第三部分為檢驗與分析變遷偵測試辦之精度。本次期末報告具體成果為完成試辦區域房屋偵測及變遷分析，並建立以人工智慧進行房屋變遷偵測之程序。

試辦區位於新竹縣市區域，且涵蓋地表有明顯變遷之竹北高鐵站周邊，地表主要包含建物、道路、水體、植物等地物。研究資料包括：(1) 內政部國土測繪中心提供之 106 與 108 年臺灣通用電子地圖的建物圖層。地圖之圖幅分號及圖號沿用五千分之一基本地形圖之分幅及圖號編碼（國土測繪中心，2020），包含圖幅號 96224071、96224072、95221089、95221090、95221099、95221100、96224081、96224082、96224091、96224092、95221079、95221080、95221069、95221070、96224061、96224062、95221059、95221060、96224051、95221049、95221050、96224041、96224042，共 23 幅(圖 4.3-40)，以每個圖幅 2.53km x 2.77km 進行計算，試辦面積達 161km²。(2) 農林航空測量所提供之 106 與 108 年原始數位航空影像。106 年航照影像由 DMC 相機拍攝，攝影時航高約為 3000 公尺，橫縱向重疊率分別為 40% 及 60%，攝影站展點如圖 4.3-41(a)所示，共有 167 幅；108 年航照影像由 UltraCam 相機拍攝，攝影時航高約為 4000 公尺，橫縱向重疊率分別為 40% 及 80%，攝

影站展點如圖 4.3-41(b)所示，共有 216 幅（表 4.3-12）。

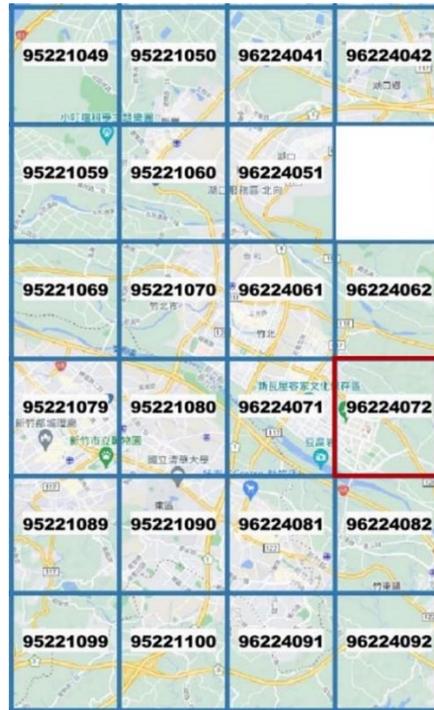
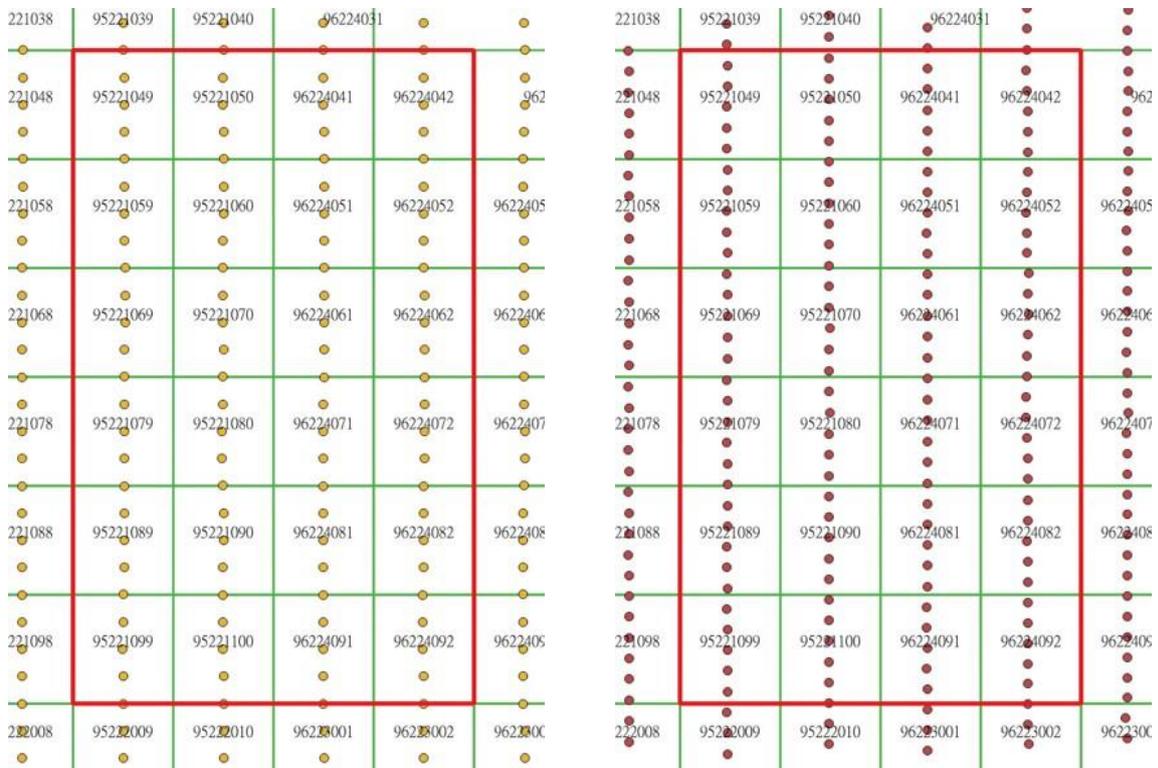


圖 4.3-40、臺灣地區航遙測影像房屋辨識試辦區



(a) 106 年航照攝影站展點

(b) 108 年航照攝影站展點

圖 4.3-41、農航所原始航照影像攝影展點

表 4.3-12、農航所原始航照影像說明

資料年度	數量(幅)	航高(公尺)	相機	橫向重疊率(%)	縱向重疊率(%)
106	167	3000	DMC	40	60
108	216	4000	UltraCam	40	80

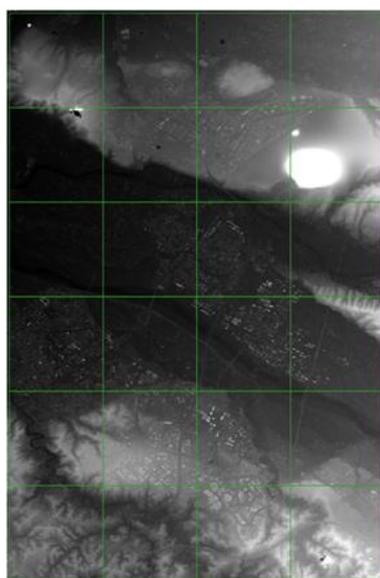
資料前處理首先利用 Agisoft Metashape 軟體搭配農航所提供之方位參數執行影像方位重建作業，重建原始航空影像方位後，再將多張重疊的航空影像進行密匹配(dense matching)建立密點雲(Dense point cloud)後產製 DSM，接著利用 DSM 產生正射航照影像。最後，裁切 DSM 與 DSM 改正正射航照影像，使圖資範圍對應臺灣通用電子地圖的房屋區域(圖 4.3-42)。密匹配點雲進一步分離為地形(地面點 ground point)及地表物體(非地面點 non-ground point)(圖 4.3-43)，利用地面點可產生數值地表模型(Digital Terrain Model, DTM)。

針對局部區域放大處理後的資料(圖 4.3-44)，比較本項工作前期(110年)與本年度的研究資料。去年度採用的臺灣通用電子地圖正射影像為使用 DTM 產製之正射影像，從圖 4.3-44(a)可明顯看出此區域應由兩張正射影像拼接而成，影像中高樓層房屋存在高差移位，且移位方向不同，故 DTM 改正正射影像與臺灣通用電子地圖中房屋區域之間有落差，特別是高層建物區域(圖 4.3-44(d))。相比之下，本年度利用 DSM 產製之正射影像中大部分房屋的高差移位已被校正，DSM 改正正射影像與臺灣通用電子地圖

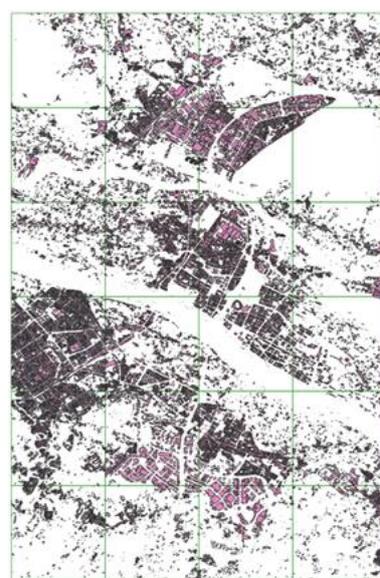
中房屋區域間之一致性改善顯著（圖 4.3-44(e)）。不過，由於農航所提供之數位航空影像的主要用途為產生臺灣通用電子地圖正射影像，而非為了建置三維建物模型，故拍攝影像時重疊率不高。因此，DSM 在建物間距太小或密集區域的高程品質較差，使 DSM 改正正射影像中房屋邊界會稍微被扭曲，如圖 4.3-44(b)與圖 4.3-44(c)黃色圈選處所示。綜合上述，利用 DSM 產製正射航照影像能夠校正地物高差移位，使影像房屋範圍與智慧化偵測房屋時做為地真(Ground truth)資料的臺灣通用電子地圖房屋區域相符。另外，DSM 含有高度資訊，可用於區分不同高度的地物，有助於辨識及萃取房屋輪廓，故在人工智慧深度學習模型中加入 DSM 能夠提升地物種類及範圍辨識的準確度，增進自動化偵測房屋區域的能力(Sun et al., 2021)。因此，使用 DSM 與 DSM 改正正射影像進行房屋偵測的效果會優於僅使用臺灣通用電子地圖正射影像。



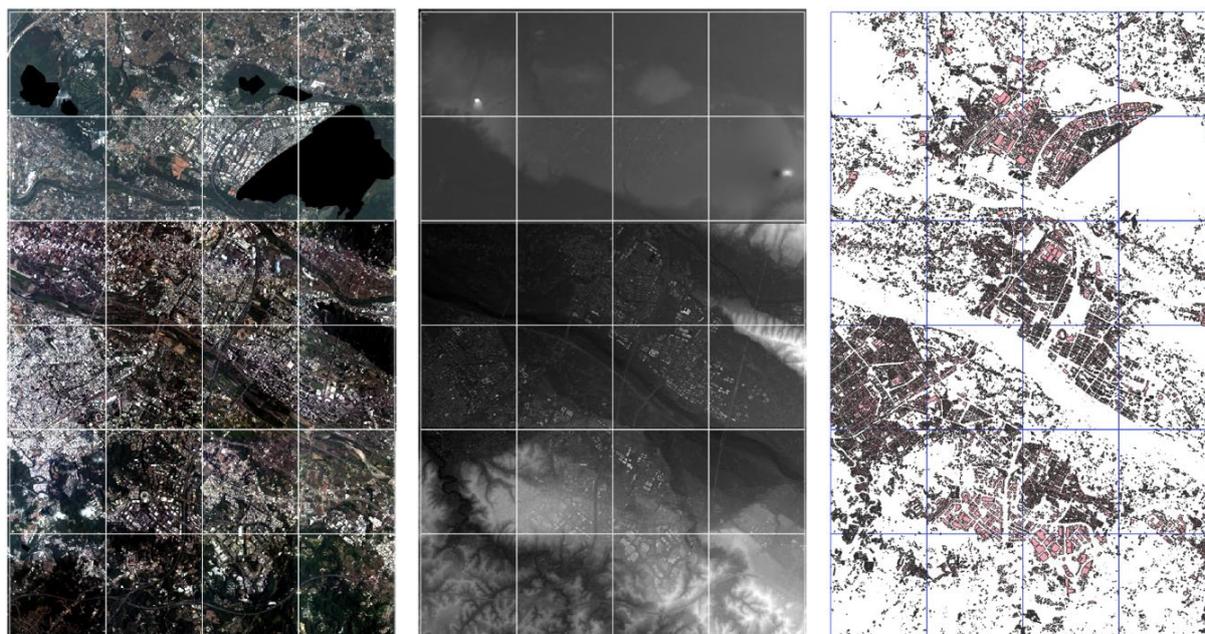
(a) 106 年 DSM 改正之正射影像



(b) 106 年影像密匹配之 DSM



(c) 106 年臺灣通用電子地圖房屋區域

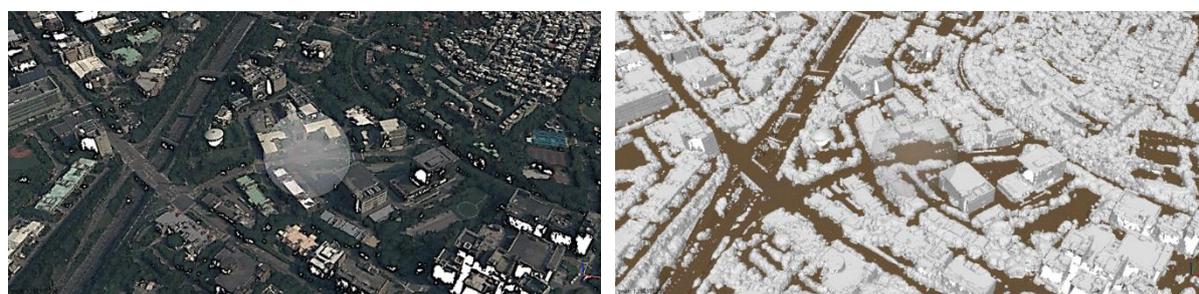


(d) 108 年 DSM 改正之正射影像

(e) 108 年影像密匹配之 DSM

(f) 108 年臺灣通用電子地圖房屋區域

圖 4.3-42、房屋變遷偵測研究資料



(a) 密點雲

(b) 地面及非地面點雲 (黑色:地面點; 白色:非地面點)

圖 4.3-43、地面及非地面點雲



(a) DTM 改正之正射影像

(b) DSM 改正之正射影像

(c) DSM



(d) DTM 改正之正射影像套
疊臺灣通用電子地圖房
屋區域

(e) DSM 改正之正射影像套
疊臺灣通用電子地圖房
屋區域

(f) DSM 套疊臺灣通用電子
地圖房屋區域

圖 4.3-44、DTM 及 DSM 改正正射影像套疊臺灣通用電子地圖房屋區域

本項工作採用卷積神經網路(Convolutional Neural Network, CNN)進行影像語意分割(Semantic Segmentation)，演算法為 TransUNet，分別偵測前後期航遙測影像之房屋區域，以圖幅 96224081 為例，呈現房屋偵測成果（圖 4.3-45），智慧判釋的房屋區域與人工數化的房屋區域有極高的相似性。經由比對前後期偵測成果，建立智慧辨識房屋變遷區域，流程如圖 4.3-46 所示。

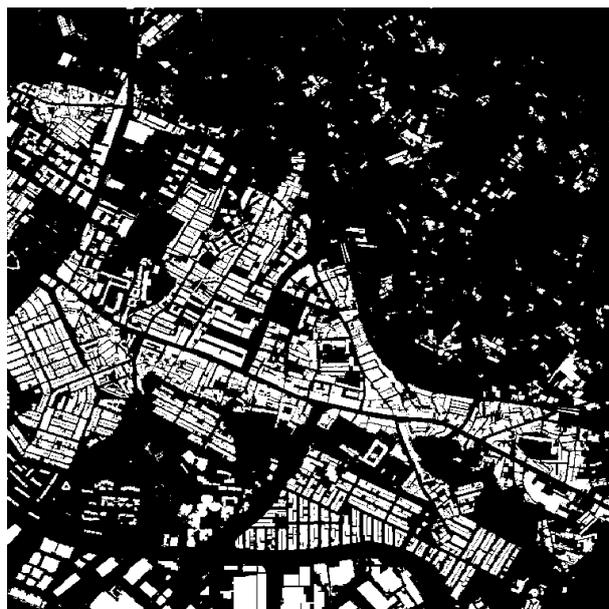


(a) 106 年正射影像

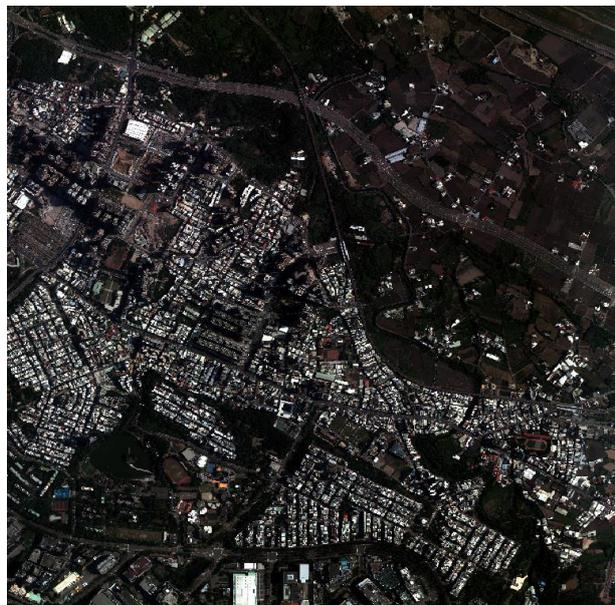
(b) 106 年 DSM



(c) AI 預測 106 房屋區域



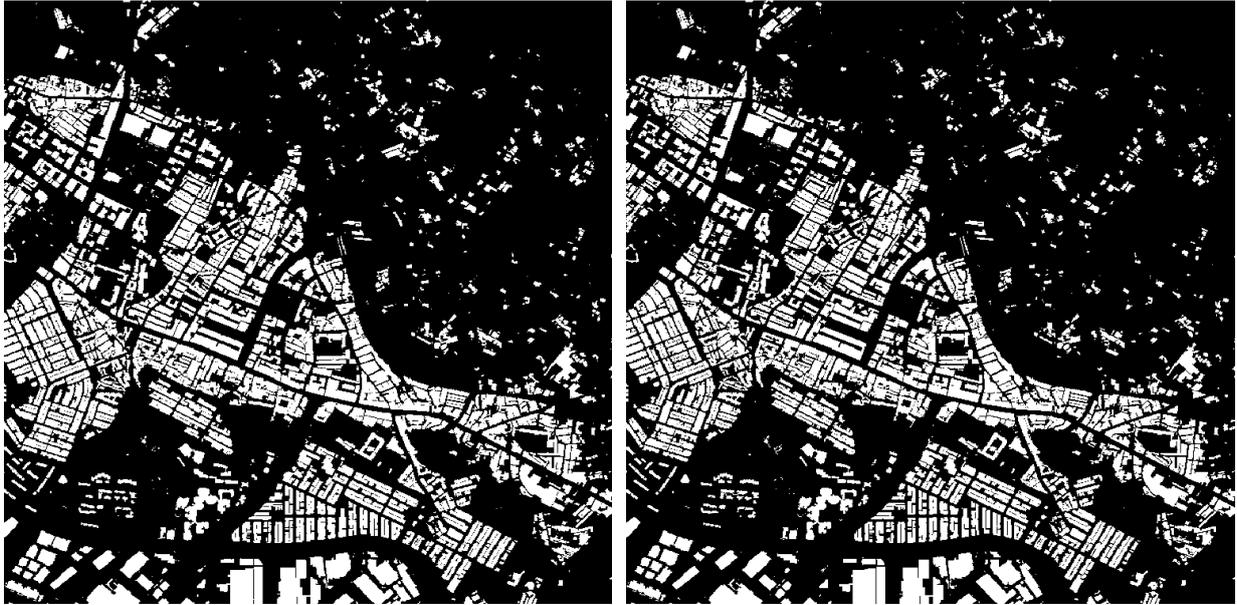
(d) 106 臺灣通用電子地圖



(e) 108 年正射影像



(f) 108 年 DSM



(g) AI 預測 108 房屋區域

(h) 108 臺灣通用電子地圖

圖 4.3-45、AI 預測房屋區域

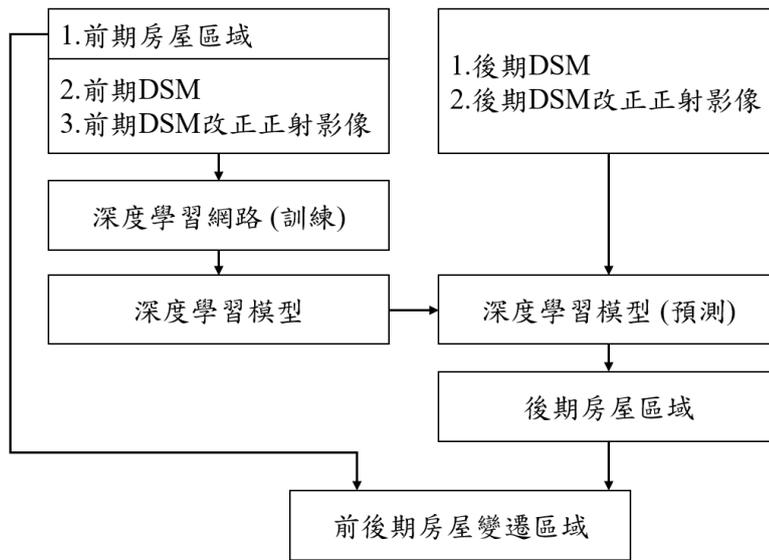


圖 4.3-46、智慧辨識房屋變遷區域流程

以人工智慧技術辨識房屋區域時所需的資料包含：(1) 來自臺灣通用電子地圖建物圖層的類別標籤、(2) 由多張數位航空影像產製之 DSM、(3) 使用 DSM 產製之 DSM 改正正射影像。在訓練神經網路模型階段，108 年 23 幅圖幅中，其中 22 幅圖幅範圍內的資料為訓練資料，影像裁切大小為

224x224 pixel, 水平與垂直重疊率皆為 112 pixels 一共有 154683 張訓練影像與 38671 張驗證影像；在檢驗神經網路模型階段，剩下的 1 幅圖幅（圖幅號：96224072）範圍內的資料為檢核資料，用於評估訓練模型偵測房屋的精度。此外，將 106 年 23 幅圖幅範圍內的資料做為預測資料，以分析前後期房屋變遷偵測之精度。房屋區域偵測精度評估以人工數化的臺灣通用電子地圖建物圖層為基準，比較 AI 自動偵測成果，並建立混淆矩陣(confusion matrix)（圖 4.3-47）

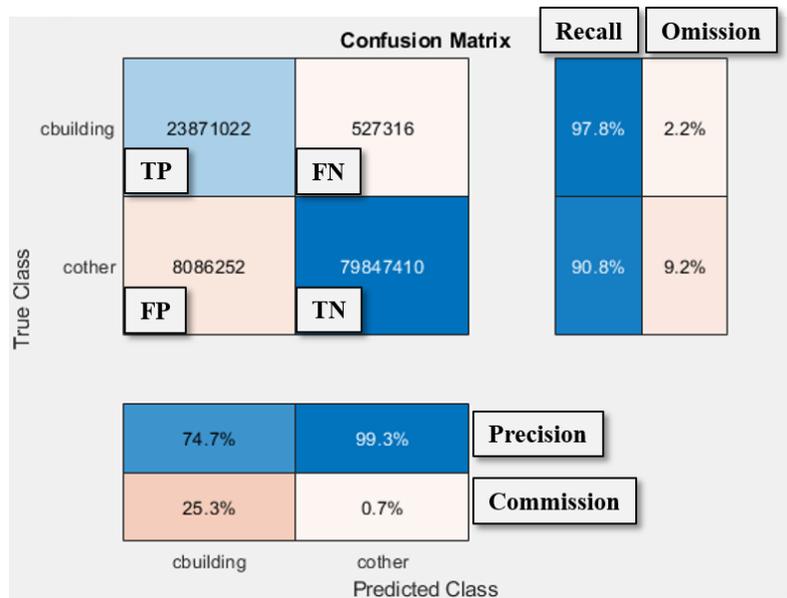


圖 4.3-47、混淆矩陣

本團隊使用不同年度及圖幅範圍之預測資料，將房屋區域偵測成果分為「單圖幅」及「22 幅圖幅」範圍進行分析，「單圖幅」偵測成果由「跨圖幅預測」及「跨年度預測」兩種方法產生；「22 幅圖幅」偵測成果則由「同年度預測」及「跨年度預測」兩種方法產生（表 4.3-13）。

表 4.3-13、房屋區域偵測方法

		訓練資料	預測資料	預測成果
單 圖 幅	跨年度獨立 預測	108 年 22 幅(不 含 96224072)： 臺灣通用電子 地圖房屋區 域、航照正射 影像與 DSM	106 年圖幅號 96224072 航照正射影像與 DSM	AI 預測 106 年圖幅號 96224072 房屋區域
	跨圖幅獨立 預測		108 年圖幅號 96224072 航照正射影像與 DSM	AI 預測 108 年圖幅號 96224072 房屋區域
22 幅 圖 幅	跨年度預測		106 年 22 幅 正射影像 航照正射影像與 DSM	AI 預測 106 年 22 幅 房屋區域
	同年度預測		108 年 22 幅 正射影像 航照正射影像與 DSM	AI 預測 108 年 22 幅 房屋區域

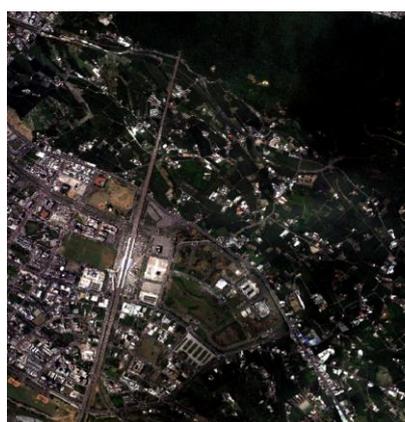
偵測「單圖幅」房屋區域時，「跨圖幅獨立預測」方法為使用 108 年 22 幅航照正射影像與臺灣通用電子地圖(不含圖幅號 96224072)進行訓練，以 108 年圖幅號 96224072 之正射影像及 DSM 進行獨立檢驗，預測同年度圖幅號 96224072 範圍內之房屋區域。「跨年度獨立預測」方法為使用 108 年 22 幅航照正射影像與臺灣通用電子地圖(不含 96224072)進行訓練，以 106 年圖幅號 96224072 正射影像進行獨立檢驗，預測跨年度 106 年圖幅號 96224072 範圍內之房屋區域，此預測方式之目的為分析獨立驗證區跨年度預測房屋的成效。

單圖幅偵測成果中(表 4.3-14、圖 4.3-48)，使用「跨圖幅獨立預測」的 F1-Score 達 90.99%，而「跨年獨立度預測」的 F1-Score 達 85.85%，這

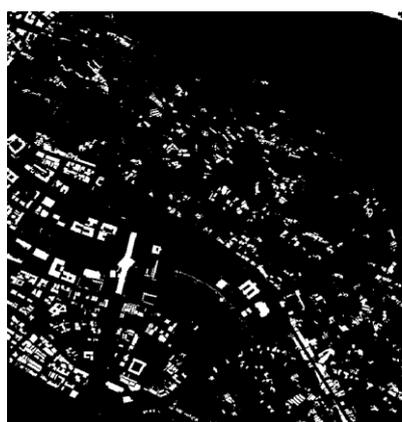
兩種獨立預測的漏授率及誤授率均小於 16%，顯示智慧判釋良好的預測能力。訓練過程中並沒有使用圖幅 96224072，但預測時對圖幅 96224072 進行驗證分析，觀察單圖幅「跨圖幅獨立預測」及「跨年度獨立預測」之成果可知，使用 108 年圖資進行訓練，跨年預測 106 年房屋區域，預測成果會「跨圖幅獨立預測」的 F1-Score 差 5%，建議房屋偵測之實務作業應選用與欲預測區域相同範圍之訓練資料。

表 4.3-14、房屋偵測精度分析：單圖幅

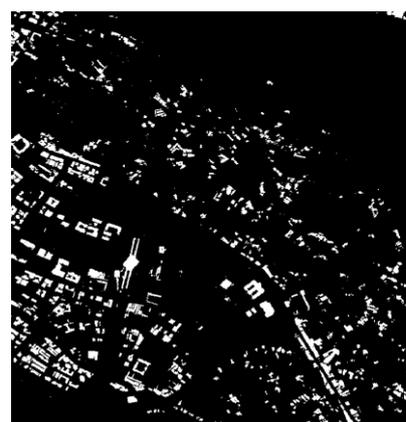
	跨圖幅獨立預測	跨年度獨立預測
TP/ FP/ FN/ TN (pixel)	8592729/ 980965/ 720976/101779530	7373009/1025374/ 1404461/102260276
Precision	89.75%	87.79%
Recall	92.26%	84.00%
F1- Score	90.99%	85.85%
IoU	83.47%	75.21%



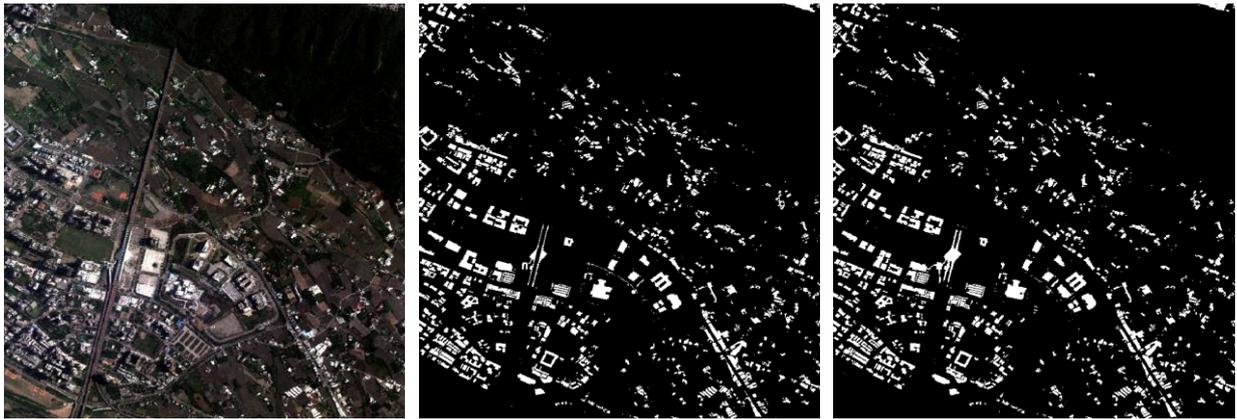
(a) 106 年正射影像



(b) 106 年臺灣通用電子地圖房屋區域



(c) AI 偵測 106 年房屋區域



(d) 108 年正射影像

(e) 108 年臺灣通用電子地圖

(f) AI 偵測 108 年房屋區域

房屋區域

圖 4.3-48、臺灣通用電子地圖（圖幅號 96224072）與 AI 偵測房屋區域（黑色：非房屋；白色：房屋區域）

偵測「22 幅圖幅」房屋區域時，「同年度預測」及「跨年度預測」方法皆使用 108 年 22 幅臺灣通用電子地圖（不含圖幅號 96224072）訓練深度學習模型。「同年度預測」是以 108 年 22 幅正射影像及 DSM 預測 108 年 22 幅圖範圍內之房屋區域，而「跨年度預測」則是以 106 年 22 幅正射影像及 DSM 預測 22 幅圖範圍內之房屋區域。

「跨年度預測」逐像元評估 106 年 22 幅房屋偵測成果，Precision 達 88.61%，Recall 達 92.07%，F1-Score 達 90.31%（表 4.3-15），與單圖幅偵測中「跨年度預測」相比，前者預測精度較佳。雖然兩者使用同樣的訓練資料，但後者所預測的圖幅範圍與訓練資料的圖幅範圍無重疊。「同年度預測」108 年 22 幅房屋偵測成果，Precision 為 93.86%，Recall 為 97.48%，F1-Score 為 95.63%，同為使用 108 年資料訓練又使用相同資料進行精度評

估，故精度指標均超過 90%。

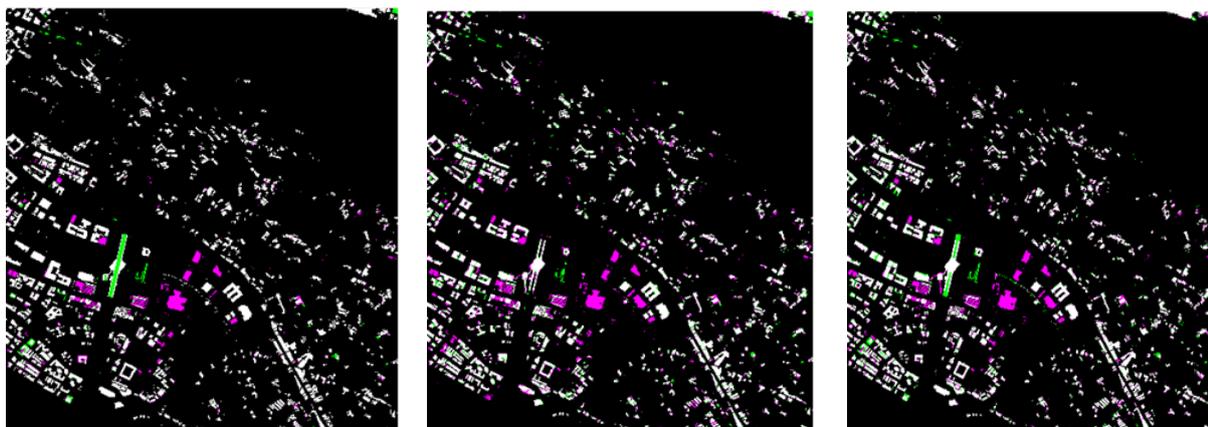
表 4.3-15、房屋偵測精度分析：22 幅圖幅

	跨年度預測	同年度預測
TP/ FP/ FN/ TN (pixel)	351120647/45137698/ 30232835/1925937529	384878859/25178074/ 9964079/2044403385
Precision	88.61%	93.86%
Recall	92.07%	97.48%
F1- Score	90.31%	95.63%
IoU	82.33%	91.63%

前項工作完成房屋偵測分析，接著進行房屋變遷精度分析。本項工作以臺灣通用電子地圖前後期變遷為基準，比較 108 年臺灣通用電子地圖與 AI 自動偵測 106 年房屋區域間之變遷區域(圖 4.3-49)，並建立混淆矩陣。用於變遷偵測精度分析的混淆矩陣中，TP 代表人工數化變遷物件，AI 有偵測到改變；TN 代表人工數化無變遷之物件，AI 無偵測到改變，此類物件無變遷，故不納入後續精度分析；FN 代表人工數化變遷物件，AI 無偵測到改變；FP 代表人工數化無變遷物件，AI 有偵測到改變。

「單圖幅房屋變遷」分析是使用 108 年 22 幅臺灣通用電子地圖（不含 96224072）做為訓練資料，預測 106 年幅號 96224072 房屋區域，再比較 108 年電子地圖及 AI 偵測 106 年房屋區域間之改變。「22 圖幅房屋變遷」分析則以 108 年 22 幅臺灣通用電子地圖（不含 96224072）做為訓練資料，預測 22 幅圖幅範圍內 106 年房屋區域，再比較 108 年電子地圖及 AI 偵測 106 年房屋區域間之變化，以評估 22 幅圖幅房屋前後期變遷偵測之精度，「單

圖幅房屋變遷」及「22 圖幅房屋變遷」比較整理如表 4.3-16。



(白色:無變遷, 洋紅:後期新增, 綠色:後期移除)

(a) 前後期 Taiwan eMap 之房屋變遷 (b) 前後期 AI 預測之變遷 (c) 前期 Taiwan emap、後期 AI 預測之變遷

圖 4.3-49、人工數化及 AI 判釋房屋變遷物件示意圖

表 4.3-16、房屋變遷偵測方式

	訓練資料	預測資料	預測成果 (108 年臺灣通用電子地圖/ 106 年 AI 預測)
單圖幅房屋變遷	108 年 22 幅(不含 96224072): 臺灣通用電子地圖房屋區域、航照正射影像與 DSM	106 年圖幅號 96224072 航照正射影像與 DSM	圖幅 96224072 房屋前後期變遷
22 幅圖幅房屋變遷		106 年 22 幅 航照正射影像與 DSM	22 幅圖幅 房屋前後期變遷

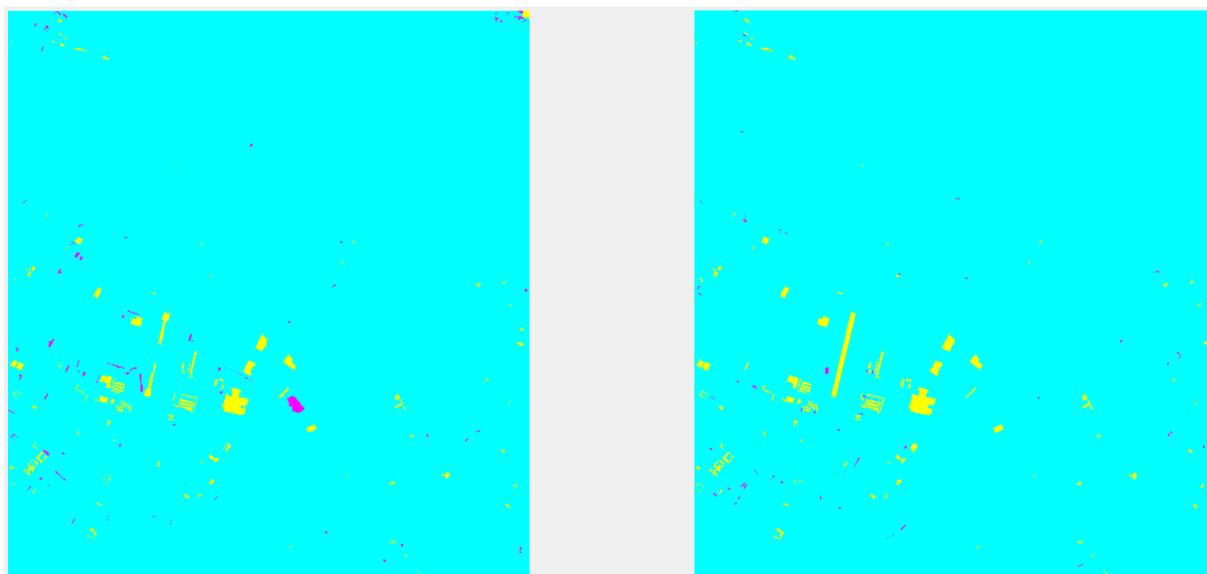
房屋變遷精度分析僅針對變遷區域，並未納入無變遷區域，以避免高估精度。首先像元為單位進行 22 幅之變遷精度分析，房屋變遷的 Precision 可達 74.99%，Recall 則為 74.66%，整體 F1-Score 達 74.82%，即 AI 房屋變遷精度約可達成 75% 的精度。

接著以變遷物件為單元分析單圖幅及 22 幅圖幅之房屋變遷偵測精度。

在單圖幅分析，以 AI 偵測偵測圖幅號 96224072 範圍內房屋變遷的 Precision 為 62.78%，Recall 為 70.19%（表 4.3-17、圖 4.3-50），整體 F1-Score 達 66.28%。在 22 幅圖幅分析，AI 偵測 22 幅圖幅房屋變遷的 Precision 及 Recall 分別為 51.11% 及 69.13%，整體 F1-Score 約 58.77%，統計誤授及漏授物件的面積可以發現（表 4.3-18、圖 4.3-51），有很高的比例是面積小於 20m² 的變遷，變遷判釋準確率與物件面積相關，誤授及漏授物件面積之中位數分別為 11.687 m² 及 11.937 m²，可見錯誤偵測多數發生在物件面積相對較小的房屋，由此可知，大面積物件被正確判釋的比例較高，面積較小的區域容易被遺漏。若排除 16m² 的變遷(即 4m x 4m 的物件)(表 4.3-18、圖 4.3-52)，則 Precision 及 Recall 分別為 68.13% 及 84.62%，整體 F1-Score 約 75.49%，整體 F1-Score 可提升約 17%，即在 AI 房屋變遷分析中，若變遷區域大於 16m² 的變遷，其整體精度可達 75.49%。

表 4.3-17、房屋變遷偵測精度評估

	單圖幅 96224072	22 幅圖幅	22 幅圖幅	22 幅圖幅
	(含 16m ² 的變遷) (object 為單元)	(含 16m ² 的變遷) (object 為單元)	(不含 16m ² 的變遷) (object 為單元)	(含 16m ² 的變遷) (pixel 為單元)
TP/ FP/ FN/	113/67/48	9379/8970/4188	6280/2837/1141	15461451/5155573 /5249014
Precision	62.78%	51.11%	68.13%	74.99%
Recall	70.19%	69.13%	84.62%	74.66%
F1- Score	66.28%	58.77%	75.49%	74.82%
IoU	49.56%	41.62%	60.63%	59.78%

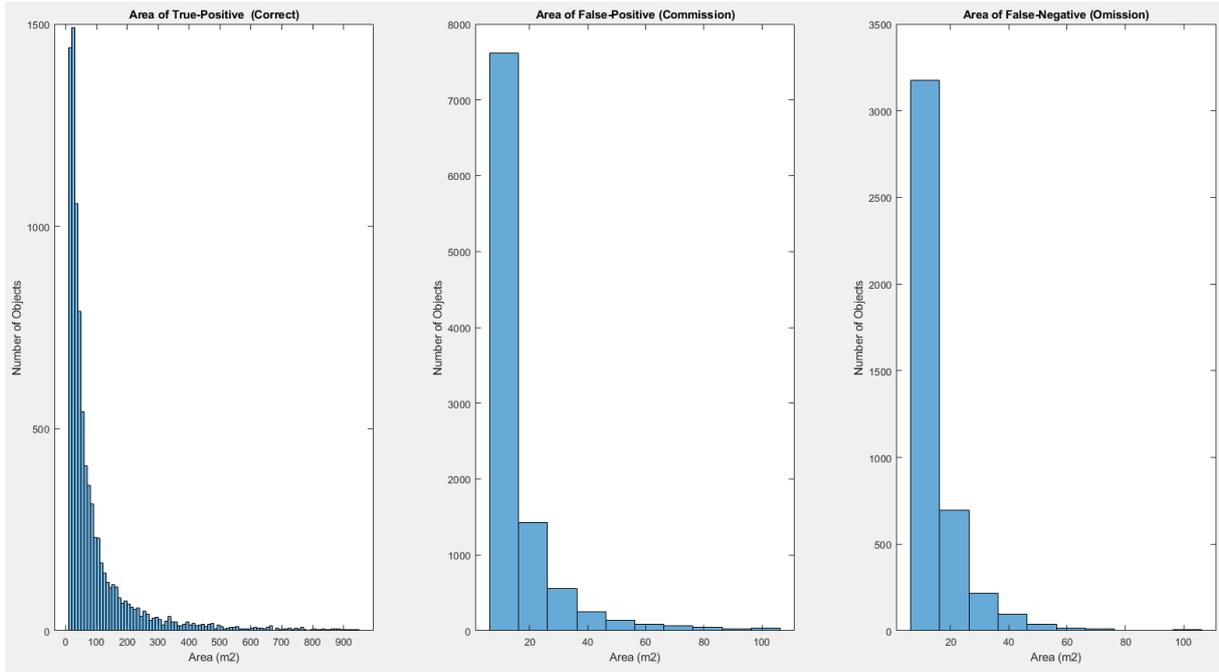


(a) 96224072 以 AI 偵測成果為基礎 (黃色：正確物件；洋紅色：誤授物件)
 (b) 96224072 以人工數化成果為基礎 (黃色：正確物件；洋紅色：漏授物件)

圖 4.3-50、臺灣通用電子地圖與 AI 判釋房屋變遷物件

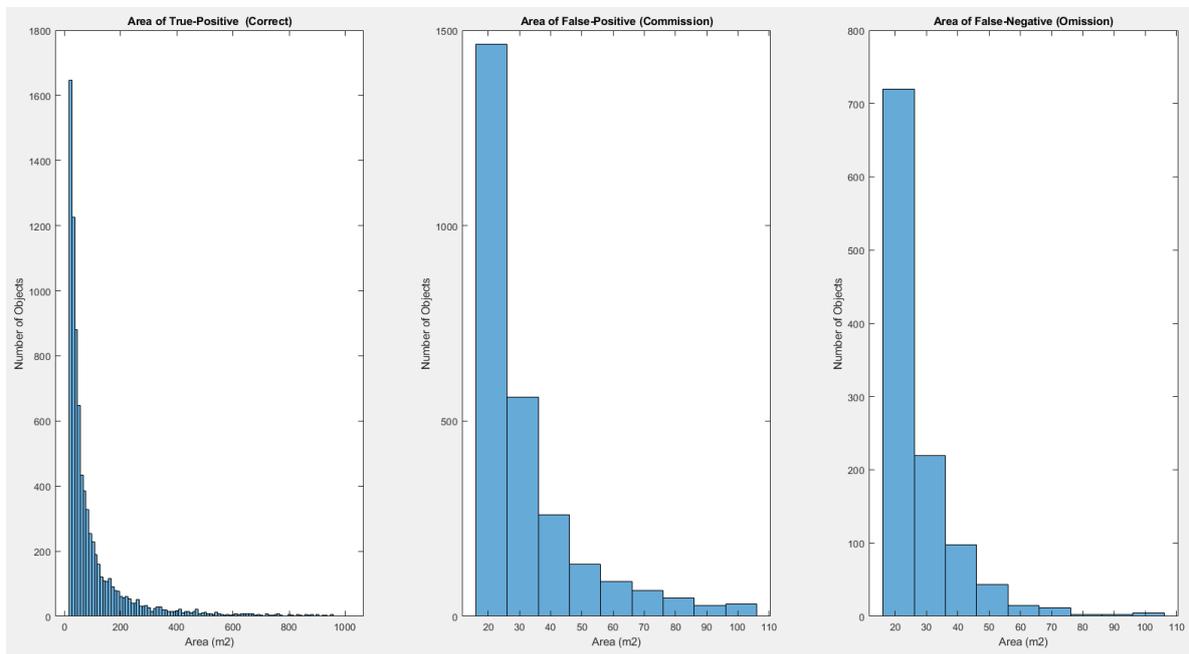
表 4.3-18、房屋變遷偵測成果之面積統計

	22 圖幅 (含小於 16m ² 的變遷)			22 圖幅 (不含小於 16m ² 的變遷)		
	正確 變遷偵測	誤授 變遷偵測	漏授 變遷偵測	正確 變遷偵測	誤授 變遷偵測	漏授 變遷偵測
物件數量	9379	8970	4188	6280	2937	1141
物件平均面積(m ²)	104.790	34.084	17.560	145.651	83.930	36.774
物件面積中值(m ²)	26.500	11.6875	11.937	51.750	26.125	22.500



(a) 正確物件之變遷面積 (b) 誤授物件之變遷面積 (c) 遺漏物件之變遷面積

圖 4.3-51、22 圖幅變遷面積直方圖分布 (含 16m² 的變遷)



(a) 正確物件之變遷面積 (b) 誤授物件之變遷面積 (c) 遺漏物件之變遷面積

圖 4.3-52、22 圖幅變遷面積直方圖分布 (不含 16m² 的變遷)

完成房屋變遷偵測後，可進一步利用 106 年 AI 房屋變遷面積及 108 年 Taiwan eMap 房屋面積計算房屋變遷率，各圖幅房屋變遷率整理如表 4.3-19，其中圖號 96224072 為竹北高鐵特區，因高鐵周邊有許多建案，其房屋變遷率達 14%；此外，圖號 96224071 為竹北市區，竹北市北區亦有許多新增建築物，其房屋變遷率接近 10%；圖號 95221069 在新竹市北區，其房屋變遷率約 7.4%。這三幅圖的房屋變遷成果如圖 4.3-53，局部放大如圖 4.3-54。實驗分析成果顯示，AI 房屋變遷可應用於探討各圖幅不同的變遷比例。

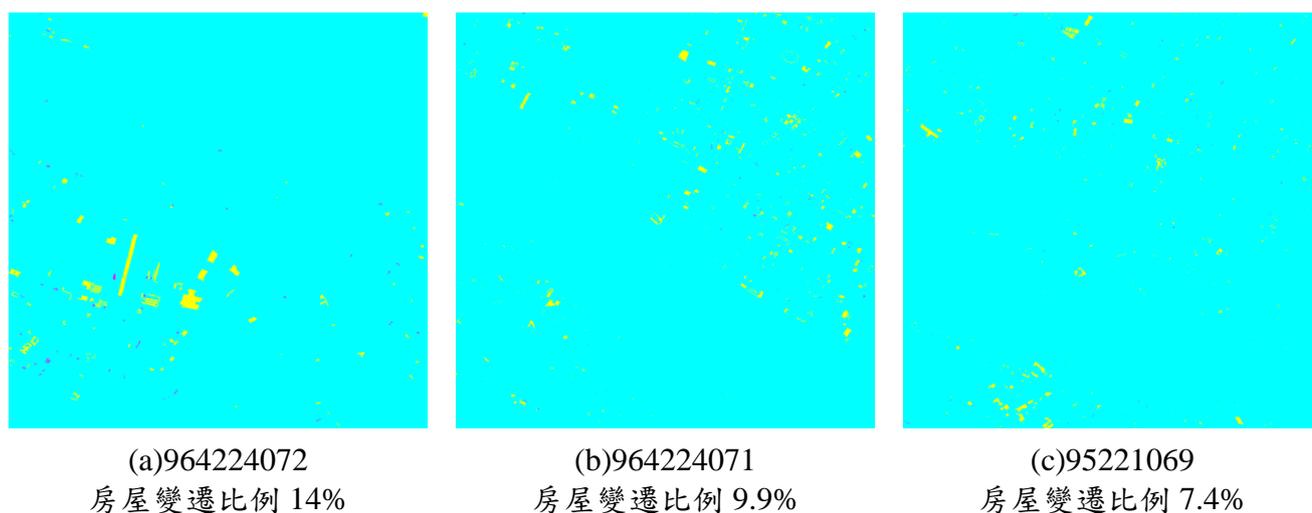


圖 4.3-53、房屋變遷比例較高圖幅

表 4.3-19、各圖幅 AI 房屋變遷率統計表

圖號	AI 偵測房屋變遷區域(Pixel)	圖幅內房屋區域總像元(Pixel)	房屋變遷率(%)
	A	B	C=A/B
95221049	329569	4034530	8.2%
95221050	1029633	17847027	5.8%
95221059	528834	9530747	5.5%
95221060	1111449	24162660	4.6%

圖號	AI 偵測房屋變遷區域(Pixel)	圖幅內房屋區域總像元(Pixel)	房屋變遷率(%)
95221069	780381	10509430	7.4%
95221070	1657509	26251327	6.3%
95221079	1828884	54899277	3.3%
95221080	797260	20149781	4.0%
95221089	782081	25170596	3.1%
95221090	955185	25609222	3.7%
95221099	422455	6687170	6.3%
95221100	340209	6532184	5.2%
96224041	750404	12175046	6.2%
96224042	813897	13738726	5.9%
96224051	1332778	28454222	4.7%
96224061	2290819	30627339	7.5%
96224062	516457	9356106	5.5%
96224071	1773457	17831372	9.9%
96224072	1176159	8397433	14.0%
96224081	982448	27021006	3.6%
96224082	388934	8599684	4.5%
96224091	793902	14287653	5.6%
96224092	410479	6737942	6.1%



(a) 圖幅 95221069



(b) 圖幅 964224071



(c) 圖幅 964224072

(左：AI 變遷偵測、中：106 年正射影像、右：108 年正射影像)

圖 4.3-54、房屋變遷區域局部放大

4.4 評估智慧物聯網之防災整合應用技術

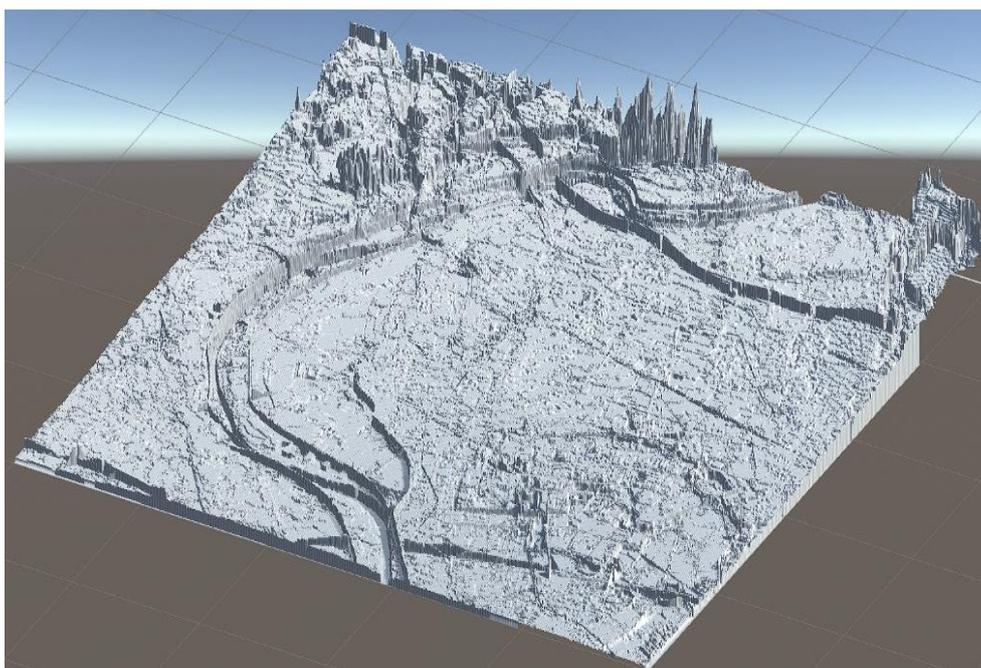
智慧城市應用由三項技術整合發展，包含數位城市模型、物聯網及領域應用模型。數位城市模型提供二維地圖、三維模型及路網結構等資訊輔助空間分析。物聯網提供動態感測資訊及遠端裝置控制之能力，幫助了解環境現象之變化，並支援控制任務之啟動。領域應用模型則根據不同領域應用發展物理或統計模型，可分析物聯網即時資訊做出即時決策判斷。本項工作為探討物聯網與數位城市模型之整合應用潛力，進行以下三項工作，分別為(1)模擬基於感測器與模型資料，發展智慧建築等適地性應用、(2)基

於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術與(3)以實際場域進行適地性服務應用試辦。以下於各小節說明細節。

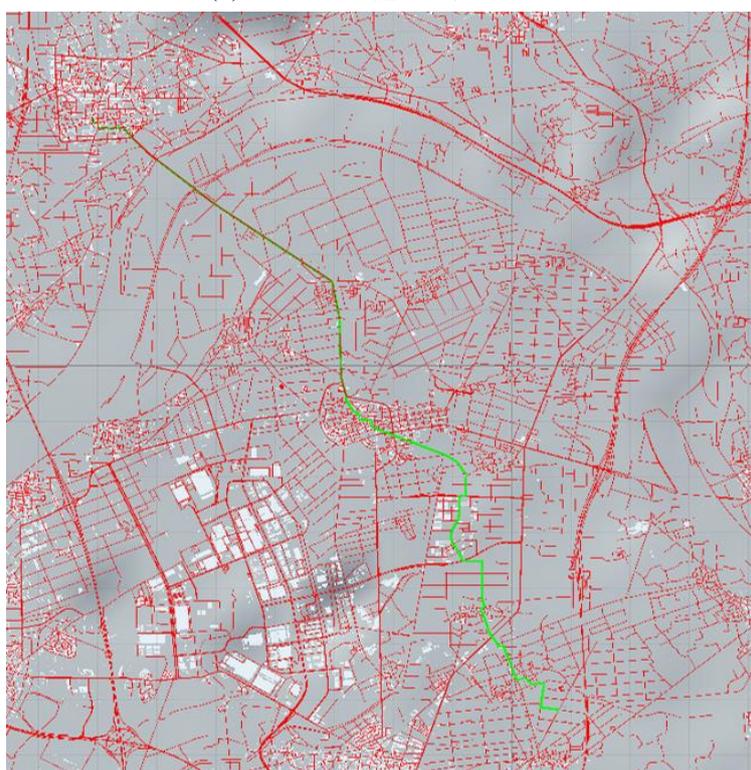
4.4.1 模擬基於感測器與模型資料，發展智慧建築等適地性應用；前述模擬須運用三維圖資在內之整合技術

本項工作前期（109、110 年）研究注重發展數位城市模型與物聯網之整合。為達成具互操作性之整合，城市模型與物聯網須先以開放式標準描述，再進行資料間之連結查詢以支援各式智慧城市應用。基於前期研究成果，本年度以更貼切現實世界運作之領域模式配合所提之城市模型與物聯網整合技術，提升應用之實務價值，並展示城市模型與物聯網資源整合應用之潛力。針對都市淹水之防救災導航進行模擬應用開發，其中包含三項主要步驟：(1)資料蒐集、(2)高精度淹水模擬與(3)防救災導航應用。

首先，為合理並精確地模擬都市淹水，需蒐集靜態與動態資訊。靜態資訊之獲取包含向內政部申請臺南善化區、曾文溪及鹽水河流域之三維模型、水利 DEM 與國土利用現況調查成果，以及從 OpenStreetMap 萃取路網結構(未來亦可使用國土測繪中心之 e-MAP 路網)，如圖 4.4-1 所示。而動態資訊則透過政府開放資料（如民生公共物聯網資料服務）獲取雨量、河川水位、淹水監測站、地下水位監測站、移動抽水監測站等感測資料。



(a) 地形模型及高架道路



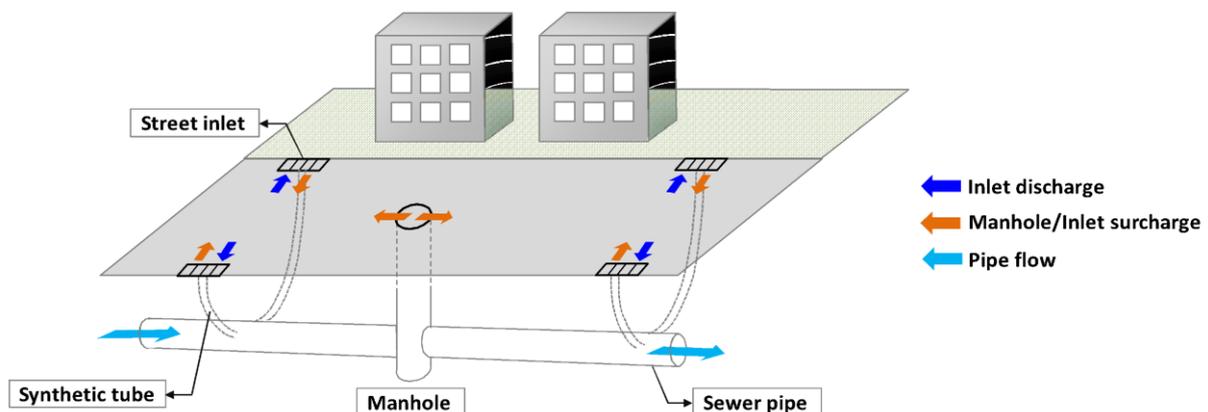
(b) 路網結構

圖 4.4-1、善化區靜態資料

關於高精度淹水模擬，本項工作與國立成功大學張駿暉教授合作，透過其所研發之本土淹水模式 COS-Flow (Coupled Overland-gully-Sewer Flow

model)進行高精度淹水模擬(Jang et al., 2018; Jang et al., 2019)。此淹水模式包含二維漫地流及一維的明渠管流模組，相互以節點的方式進行水體交換，可將治理工程、區域排水、滯洪池等水利設施納入模式。在邊界條件的部分，每個網格高程由 DEM 資料給定，上游銜接降雨歷線資料，以側入流方式直接降在每個網格上，下游銜接河口的潮位，流入最鄰近的二維網格進行水動力演算。

COS-Flow 模式與傳統以人孔作為水體交換方法不同，將每個二維淹水網格與地表、側溝(gully)及下水道(sewer)進行水體交換，進而同時模擬地表排水不及、側溝溢流及人孔冒管等三種都會區主要的淹水成因。文獻先前應用 COS-Flow 模式於臺北都市區，成果顯示若模式未考慮側溝及連接管(lateral tube)，地表水將直接進入下水道造成淹水區域低估，與真實情形不符，水體交換示意圖如圖 4.4-2 所示。此外，水利 DEM 提供溢堤線、閘門、海堤等邊界條件，可節省模式建模時人工判斷的耗時。



(a) 未考慮側溝

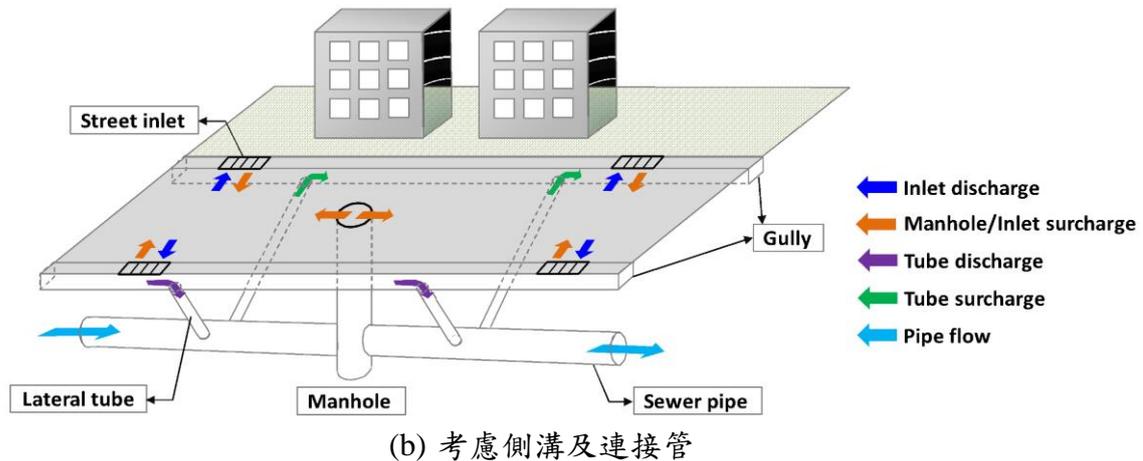
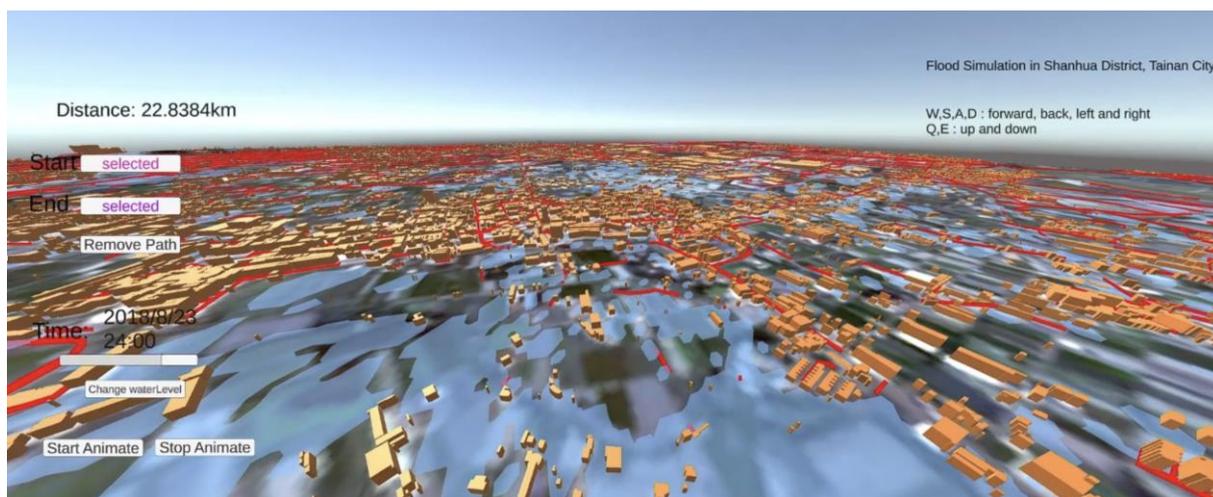
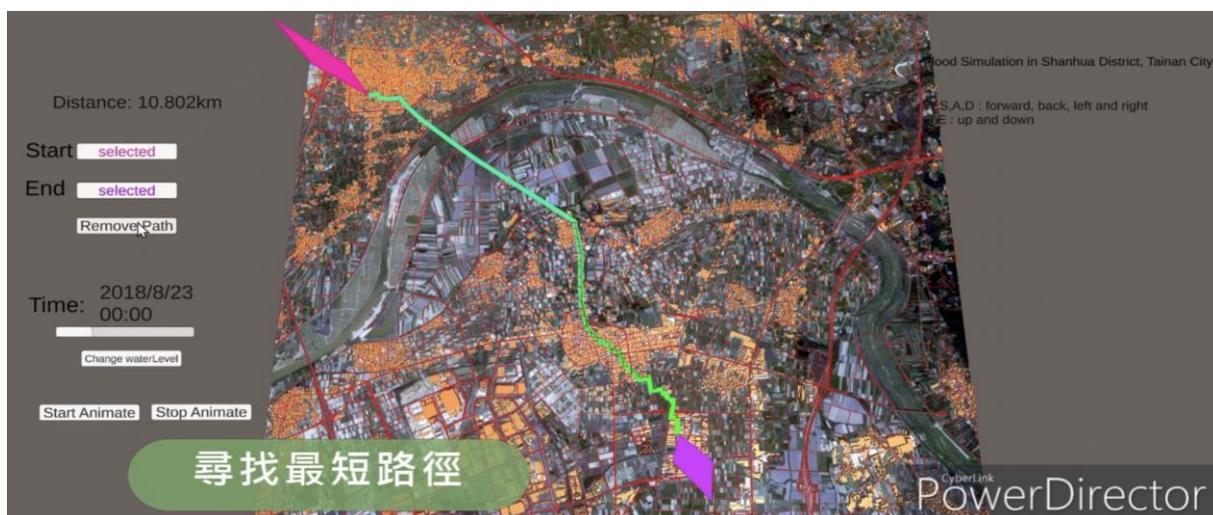


圖 4.4-2、水體交換示意圖(Jang et al., 2019)

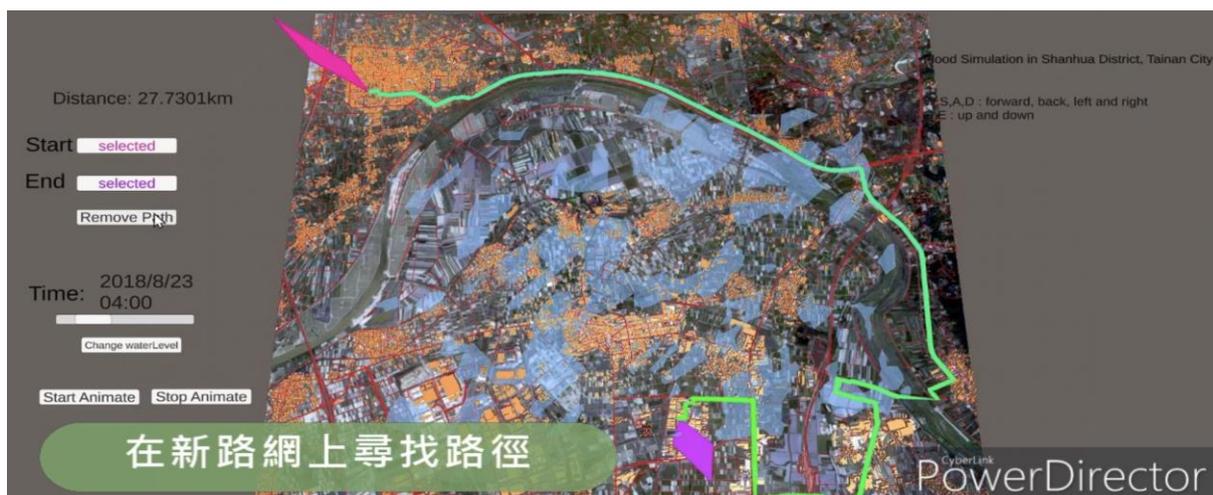
最終，本項工作以 Unity 遊戲引擎建立善化區之模擬環境，透過所蒐集的資料配合 COS-Flow 模型進行都市淹水模擬，並建立都市淹水導航防救災應用，此應用比對淹水區域與路網節點，提供避開淹水區域之即時導航指引。圖 4.4-3(a)於 Unity 呈現三維建物、路網、及淹水區域，預期在圖資解析度良好時，可提供使用者直覺且沉浸式的淹水區域展示，進行災害情資判讀等其他應用。本項工作以發生在 2018 年之 823 水災為例，使用該時之雨量等感測資料紀錄推估不同時間之淹水區域，並匯入所建立的 Unity 應用以支援淹水導航之判讀。如圖 4.4-3(b)所示，於該日 0 時淹水情形尚未嚴重，故在 Unity 內設定之導航起訖點（圖中之紅色標號）以路網結構中的最短距離路徑連結（圖中之綠色線段）。而圖 4.4-3(c)之該日 4 時淹水區域則大幅增加並影響交通，經由動態移除無法通行之淹水路段，亦考量高架道路不會受到淹水影響，相同的起迄點在改變後的路網結構則有不同的路徑規劃。



(a) 建物、路網、淹水區域呈現



(b) 無淹水區域之導航成果



(c) 有淹水區域之導航成果

圖 4.4-3、以 Unity 建立淹水導航應用

整體而言，本項工作整合城市資訊、物聯網及都市淹水模式建立導航防救災之模擬應用，顯示此些資源與技術之整合對發展智慧城市應用之潛力與重要性。

4.4.2 模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術

本項工作為發展跨 CCTV 攝影機之移動物件追蹤技術，109 年度計畫案提出此技術雛形，並於 110 年度計畫案進一步納入時間與空間資訊進行追蹤技術優化。110 年度計畫案透過移動物件之出現位置與先前消失於具路網連結關係之類別位置，根據該移動物件之平均移動速度，透過所設計之時空移動機率函式計算其歸屬機率。此外，在挑選需要比對之類別時，除使用物件與類別最後位置的路網連結性進行挑選，進一步判斷移動物件影像及候選類別影像之拍攝面向，並尋找相同拍攝面向之類別影像進行比對，經此可大幅減少須比對之影像數量及提升比對判斷的正確率。在前期(109、110 年)所使用的 Unity 模擬辦公室場域及移動物件，實驗成果得知在納入更多時間與空間資訊可有效提升物件身份辨識分群之一致性達 12%，追蹤誤差可達 30.7% 的精度提升，尤其在移動物件外觀相似時成效更加顯著。

110 年度亦細部了解各種誤差的原因，誤差來源歸類包含(1)最低點位置偏差、(2)遮蔽、(3)追蹤器誤差、(4)時空間機率函式誤差與(5)外觀特徵匹配誤差。此些類別中，影響顯著者為追蹤器誤差與外觀特徵匹配誤差，而

時空間機率函式雖可有效提升精度，然而在時間間隔過長實造成候選類別數量增加，亦仰賴外觀特徵匹配緩解此項誤差。

圖 4.4-4 為本年度所提方法之流程，其主要框架與 110 年度所提流程相似，主要差別在於移動物件追蹤(Object Tracking)之類神經網路追蹤器演算法改進，以及新加入的移動物件分類(Object Classification)步驟。以下逐步介紹此流程之細節。

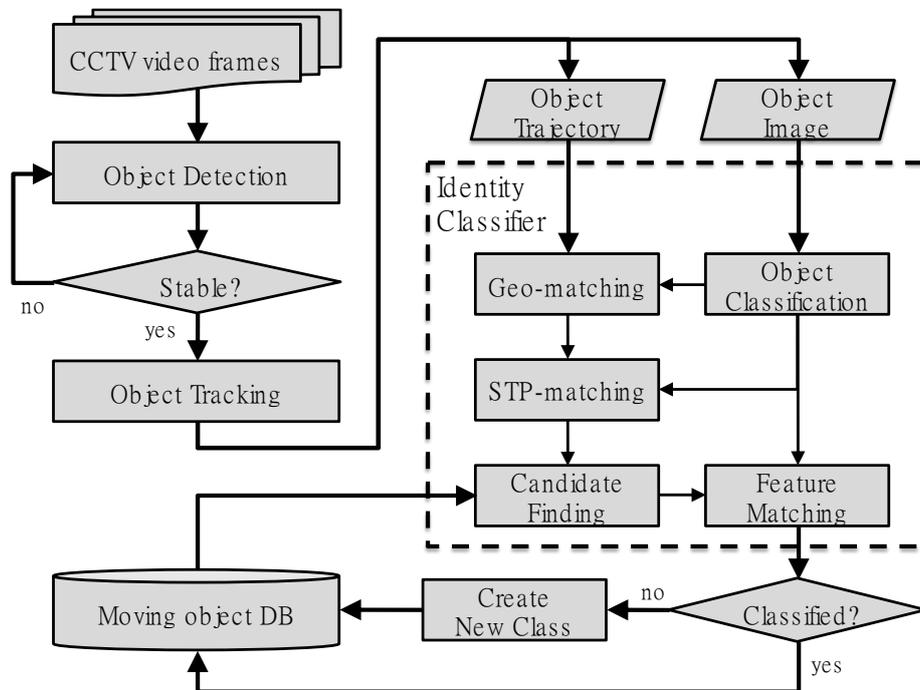


圖 4.4-4、跨 CCTV 攝影機移動物件追蹤處理程序

(1)移動物件偵測(Object Detection): 傳統的背景分離方法包含影像絕對相減方法及背景建模法。前者使用前後兩幀的像素絕對相減，差值微小的區域為背景，其餘則為前景。由於其對於光照變化及雜訊十分敏感，在環境變動較大的場域誤判率偏高。因此，本項工作選擇採用背景建模法中的

高斯混合模型(Mixture of Gaussians, MOG)(Zivkovic, 2004),以多個高斯常態分布模擬背景像素的行為,且由於其統計了不同幀的背景資訊,能夠處理一定程度的光照變化及陰影。接著將萃取各幀物件的邊界框,並進行 IoU (intersection-over-union)匹配。若同一物件持續存在,則認定其為穩定物件並初始化追蹤器進行追蹤。

(2)移動物件追蹤(Object Tracking):本年度將先前所使用的 RE³ 類神經網路追蹤器(Gordon et al., 2018)改為 DeepSORT 追蹤器(Wojke et al., 2017)進行移動物件之追蹤。由於 RE³ 使用長短期記憶模型(Long Short Term Memory networks, LSTM)以在物件外觀一定程度改變時仍可持續追蹤。然而,此特性雖在單一物件形變時極為有效,追蹤器則在不同物件交錯時可能錯誤地學習交錯之形變,進而造成身份變換(identity switch)的嚴重問題。如圖 4.4-5 所示,圖 4.4-5(a)中原先女生與男生物件分別為 B30 與 B31 物件,而當物件交錯後,RE³ 追蹤器誤將 B30 指派給男生物件,而重新給定女生物件之追蹤為 B33,如圖 4.4-5(b)。



(a) 女生與男生物件編號



(b) 物件指派與重新追蹤物件

圖 4.4-5、RE³ 追蹤器身份變換問題範例

反之，DeepSORT 追蹤器使用卡曼濾波(Kalman Filter)及匈牙利演算法(Hungarian Algorithm)進行物件之跨幀追蹤，同時以事先訓練的卷積類神經網路模型萃取物件外觀特徵納入考量。過往實驗成果顯示，相比於 SORT 演算法(Bewley et al., 2016)，DeepSORT 可減少 45%的身份變換問題，並仍維持良好之執行效能(40 Hz)。因此，本項工作以 DeepSORT 追蹤器改進所面臨的身份變換問題，以提供更良好的追蹤器強健性(robustness)。

在建立 DeepSORT 演算法後以相同資料集進行測試，成果如圖 4.4-6 及表 4.4-1 所示。從誤差向量圖可看出，DeepSORT 可有效改善身份變換問題。而量化指標顯示，DeepSORT 大幅降低所追蹤到的移動物件數量，代表具有更加的強健性以持續追蹤，亦間接降低群組數量並提升分群一致性（意即群組內物件歸屬於相同類別之比率）。

(a) RE³



(b) DeepSORT

圖 4.4-6、追蹤器成果比較

表 4.4-1、追蹤器相關資訊

追蹤器	物件數量	群組數量	加權分群一致性
RE ³	626	69	84.8%
DeepSORT	385	50	89.7%

(3)物件身份辨識(Identity Classifier)：此步驟包含以下程序。

(3.1)物件分類(Object Classification)：本年度加入物件分類以針對性地根據不同類別進行身份辨識以及類神經網路模型之預訓練。後續之地理對位、時空機率匹配、比對影像挑選及特徵匹配等步驟，將區分為不同高階類別之群組，如人、動物、車輛，並僅與該類別群組之物件進行身份辨識，經此可減少身份比對數量，亦可達更佳的身份辨識成效。本項工作加入以 ResNet50 為基底的分類器，並以 Market-1501(Zheng et al., 2015)及本項目內的模擬資料混合訓練，測試結果達 99%以上之人及非人區分正確率。分類

成人類的物件，會再以(3.5)專門訓練區分不同人類的特徵萃取網路比對相似程度進行再識別。

(3.2)地理對位(Geo-matching)：若兩攝影機之拍攝範圍有重疊，則可能分別追蹤到相同物件。將透過計算該物件在兩攝影機取得之軌跡相似度，進行物件之連結。為達成此判斷，兩攝影機需對應至相同坐標系統，本項工作在各個攝影機影像中選取地面之控制點進行八參數轉換之參數求解。

(3.3) 時空機率匹配 (Spatial-Temporal Probability matching, STP-matching)：本項工作利用移動物件與欲分類之類別進行該移動物件移動行為之時空機率估算，進而判斷其為該類別之機率。透過移動物件之出現位置與先前消失於具路網連結關係之類別位置，根據該移動物件之平均移動速度，透過所設計之時空移動機率函式計算其歸屬機率。

(3.4)比對影像挑選(Candidate Finding)：在挑選需要比對之類別時，最耗時的作法為與所有已知類別進行比對，然而此作法須比對大量類別，造成效能問題。因此，除可使用物件與類別最後位置的路網連結性進行挑選，本項工作欲進一步判斷移動物件影像及候選類別影像之拍攝面向，並尋找相同拍攝面向之類別影像進行比對。

(3.5)特徵匹配(Feature matching)：外觀特徵之相似度使用預訓練的類神經網路進行特徵萃取，將二維的影像資料降維成一維特徵向量。使用 ResNet (He et al., 2016)類神經網路進行特徵萃取。然而，此模型需針對不同目標物

件類別進行預先訓練，並根據物件分類之類別以對應的類神經網路模型萃取出具代表性的特徵，再進行 cosine 相似度評估。本項工作使用 ResNet50 模型，並以 Market1501 資料集進行訓練，以 100 個不同行人的影像集測試結果如圖 4.4-7 所示，相同人的不同影像以模型萃取特徵向量後計算 cosine 相似度平均約為 0.77，而不同人的影像相似度平均值約落在 0.66，可見模型確實有能力分辨來自不同人的影像。

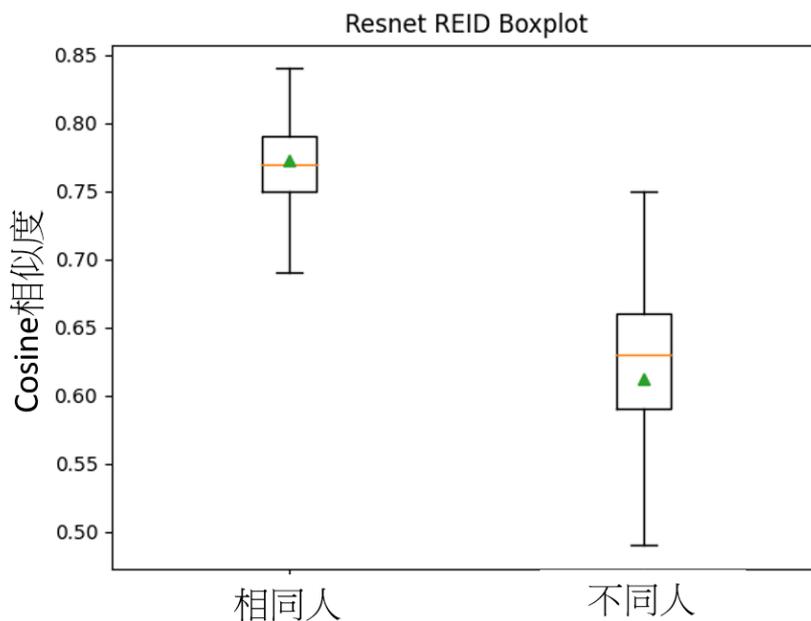
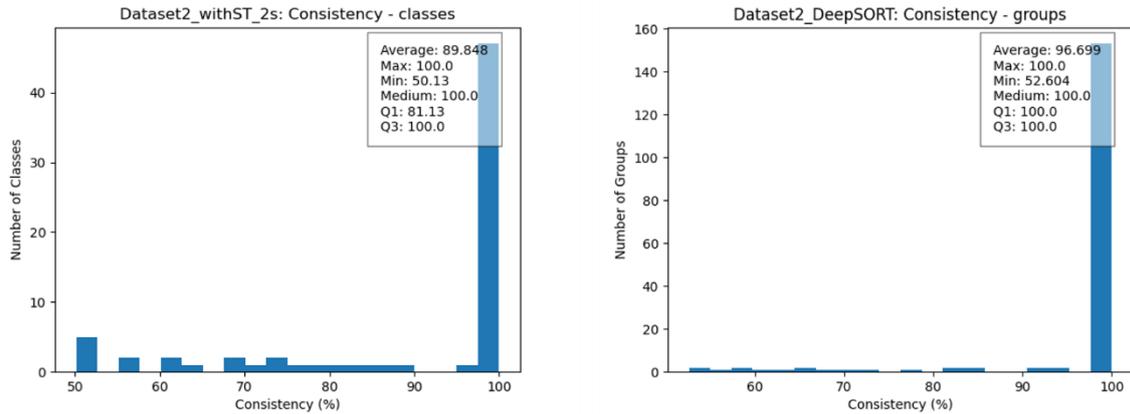


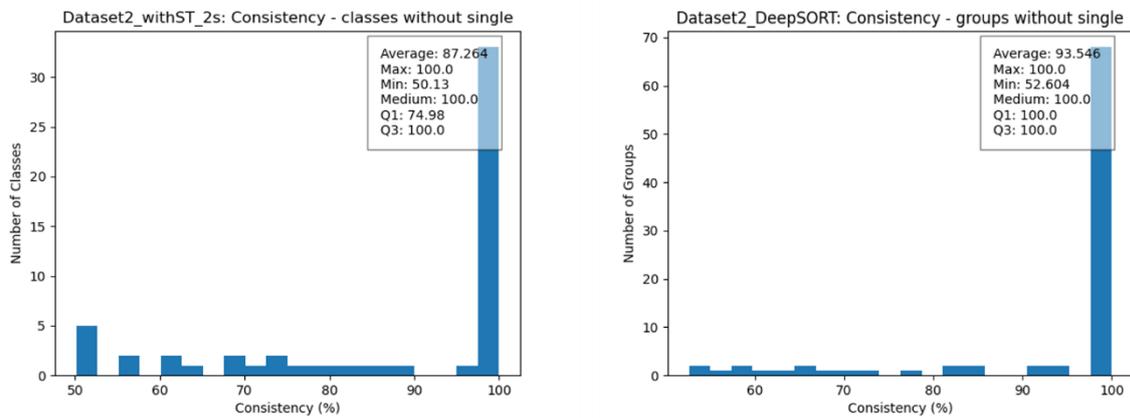
圖 4.4-7、特徵匹配相似度驗證

比較本年度與 110 年度方法，綜合了追蹤器的更換、分類篩選機制以及區隔不同人的特徵萃取器，成果比較展示如圖 4.4-8 及表 4.4-2。首先，一致性有 7% 左右的提升（圖 4.4-8(a)），排除僅有單一物件的群組後也仍有 6% 的提升（圖 4.4-8 (b)），而群組加權追蹤誤差則從 2.7m 誤差降低至

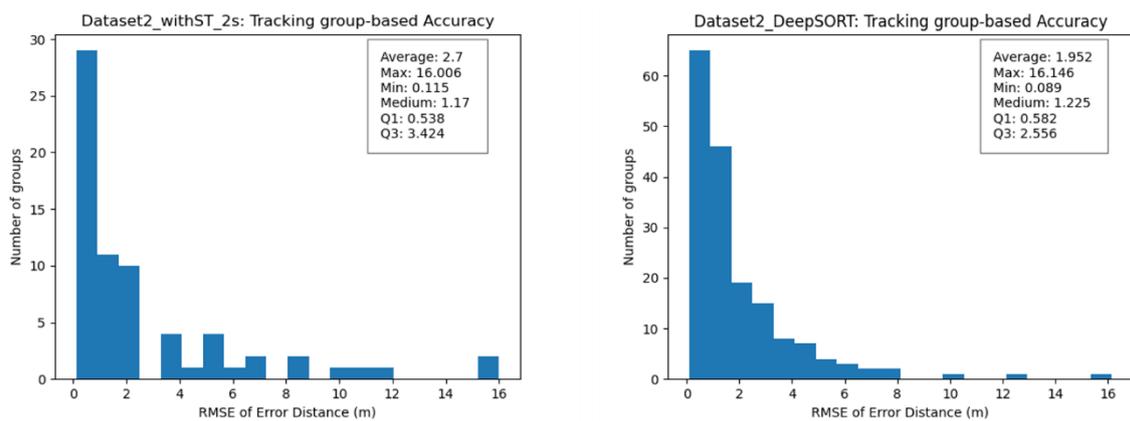
1.952m，具有 27.7%的精度提升（圖 4.4-8 (c)）。



(a) 身份辨識一致性比較（左：110 年度方法、右：本年度方法）



(b) 移除單一物件之群組後之身份辨識一致性比較（左：110 年度方法、右：本年度方法）



(c) 群組加權追蹤誤差比較（左：110 年度方法、右：本年度方法）

圖 4.4-8、110 年度及本年度方法之移動物件追蹤成果比較

表 4.4-2、110 年度及本年度方法之移動物件追蹤成果比較

	平均一致性	平均一致性 (去除單一物件群組)	群組加權追蹤誤差
RE ³ +無分類機制	89.9%	87.3%	2.7m
DeepSORT+分類機制+辨別 不同人之特徵萃取	96.7%	93.6%	1.952m

整體而言，本項工作改進前期（109、110 年）發展之跨 CCTV 攝影機移動物件追蹤技術，包含替換為更強健之追蹤器，以及加入物件分類至身份辨識程序，顯著提升此技術成果之精度。

4.4.3 以實際場域進行適地性服務應用，其辦理方式與場域選擇需與內政部

討論定案；前述工作本團隊需自行取得相關資料或建置物聯網相關所需裝置

本項工作以實際場域進行物聯網整合方案應用試辦。經與桃園捷運公司（以下簡稱桃捷）聯繫，討論其合作意願及項目，決定於桃園高鐵捷運站 A18 站以物件追蹤及人類行為辨識建立捷運車站智慧防救災通報系統。此合作試辦預計除了對緊急突發狀況反應及平時站內業務可有所幫助，評估其成效且擴充應用。

捷運車站為交通樞紐，來往人潮眾多，亦常是意外發生之處。舉例而言，臺北捷運 2016 年至 2020 年每年都有 300 件以上之意外受傷事故，其原因主要包含行走時未踩穩、站立時重心不穩、未留意環境、身體虛弱或疾病等，此外亦偶有攻擊及恐嚇等事件。為了提供更安全的運輸環境以及

即時的救護支援，發展高效率的異常事件監測技術是必要的。本項工作與桃捷合作，發展移動物件追蹤及人類行為辨識技術之應用試辦。此應用介接桃捷的監視網路，透過即時運算追蹤移動物件軌跡以及辨識人類行為，當異常行為發生時則通報給現場管理人員。本工作項目以行為分類為主軸，先行定義特定行為屬於異常，在同一行人連續發生異常行為時視為異常事件。透過此應用試辦，希望能以實際場域蒐集資料研發相關技術，並對旅客之人身安全提供更積極且快速的防護。

整體系統架構如圖 4.4-9 所示，主要分為辨識程序以及應用介面，前者接收監視影像串流進行行人追蹤及行為辨識，後者則基於前者之運算成果渲染至前端操作介面。辨識程序與應用介面架設於同一臺電腦主機，經討論過後決定放置於站務室內，提供給現場人員操作使用。

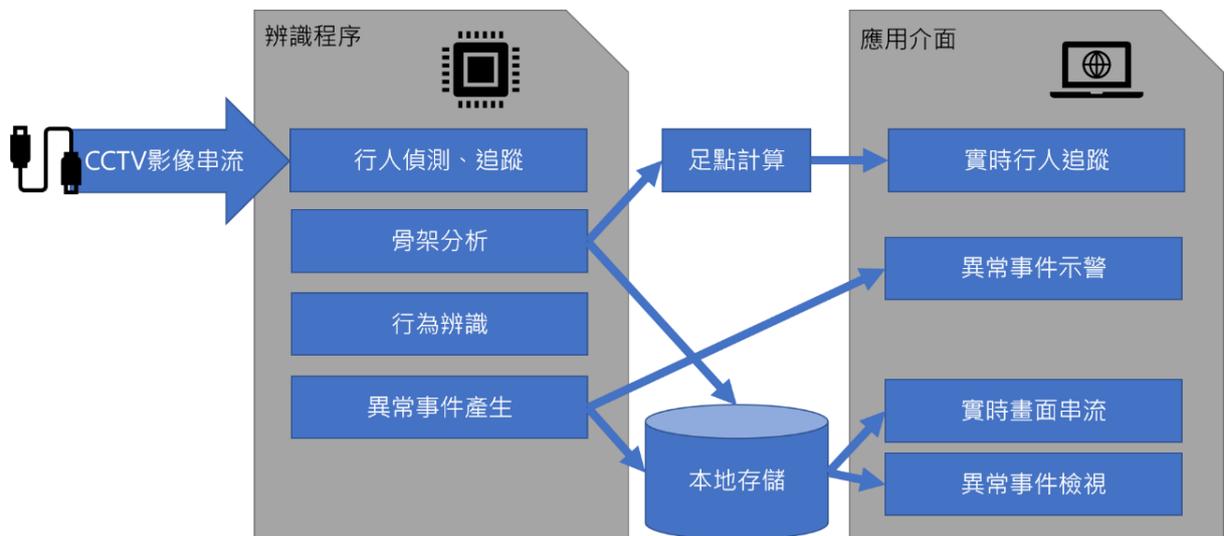


圖 4.4-9、桃園捷運 A18 站應用試辦系統架構圖

此應用中辨識程序所需之移動物件追蹤技術使用前述小節所發展之技

術，以達跨 CCTV 攝影機之移動物件身份辨識及追蹤。人類行為辨識(Human Activity Recognition, HAR)技術被應用在許多領域，包含監視系統判斷危險行為、自動導航系統判讀行人行為、影視產業之行為捕捉等(Sun et al., 2022)。從資料層面討論，用以辨識行為的視覺化資料包含 RGB 照片及影片、人體骨架(skeleton)、深度影像、紅外線影像等，而非視覺化的資料亦包含雷達、加速度計、WiFi 信號等。以本應用而言，透過攝影機所拍攝之 RGB 影像進行行為辨識較為合適。基於過往研究的經驗，直接從 RGB 影像辨識人類行為雖然具有更豐富的資訊，也可透過大量網路上的影片進行訓練，但其特徵萃取程序複雜且對於視角改變及背景內容敏感，所以透過人體骨架辨識人類行為的方法近年受到較多關注。

基於人體骨架辨識行為之演算法可基於 RNN (Recurrent Neural Network)、CNN (Convolutional Neural Network)、GNN (Graph Neural Network) 及 GCN (Graph Convolutional Network)等類神經網路模型。RNN 可透過骨架的時序變化進行辨識，CNN 則先將時序骨架資訊轉換為特定的二維表示再進行辨識，而 GNN 及 GCN 則以時序骨架關節的網絡連結關係進行行為辨識，如圖 4.4-10 所示。基於現有方法之比較，GNN 及 GCN 方法具有較佳的精度表現。

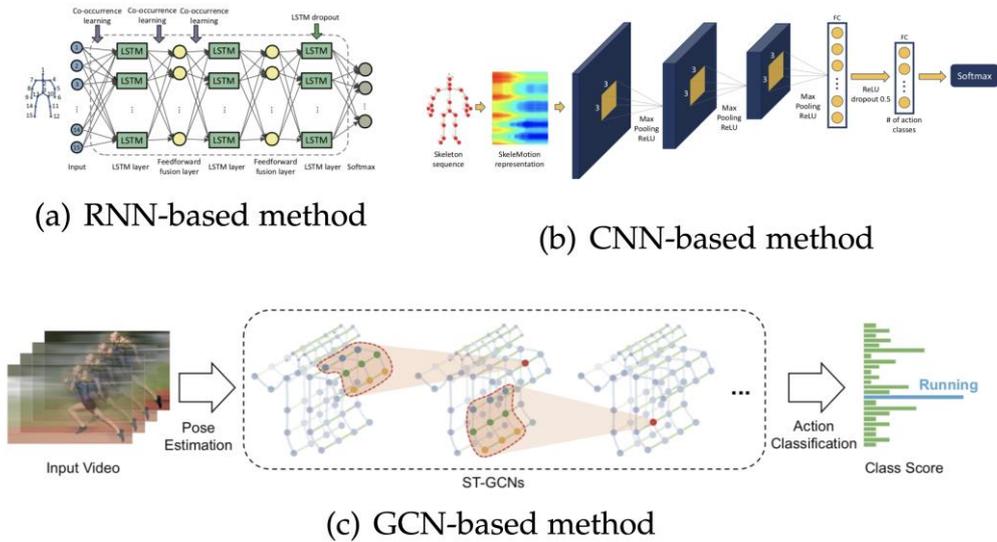


圖 4.4-10、人體骨架辨識行為之網路架構

本項工作使用 MMLab 提供的 ResNet101 搭配 COCO2017 資料集進行骨架分析。而如圖 4.4-11 所示，PoseC3D (Duan et al., 2022)方法將骨架坐標轉換成熱點圖並同時在時序維度上進行堆疊，相比一般骨架資訊僅能使用 GCN 做行為辨識，熱點圖的特性使其能夠使用 3DCNN 方法 C3D (Tran et al., 2015)，類似於 CNN 但使用多維的 Kernel，增加穩定性之餘，更能夠與一般 RGB 特徵萃取方法結合。

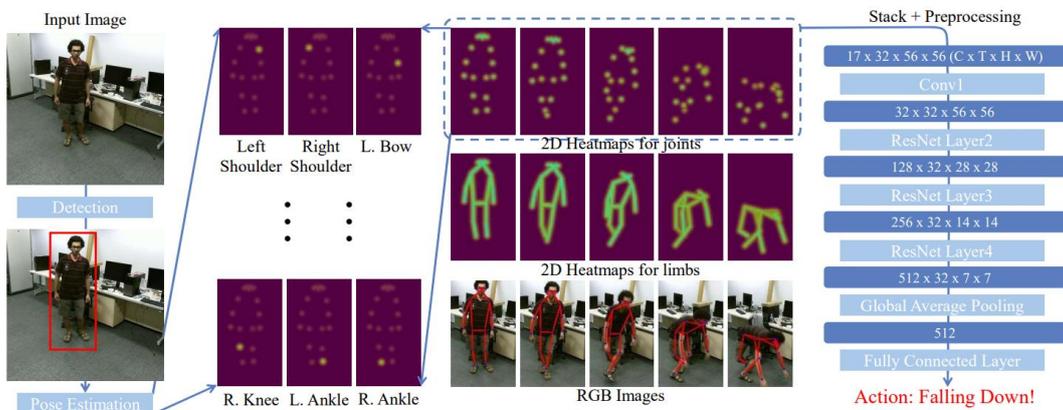
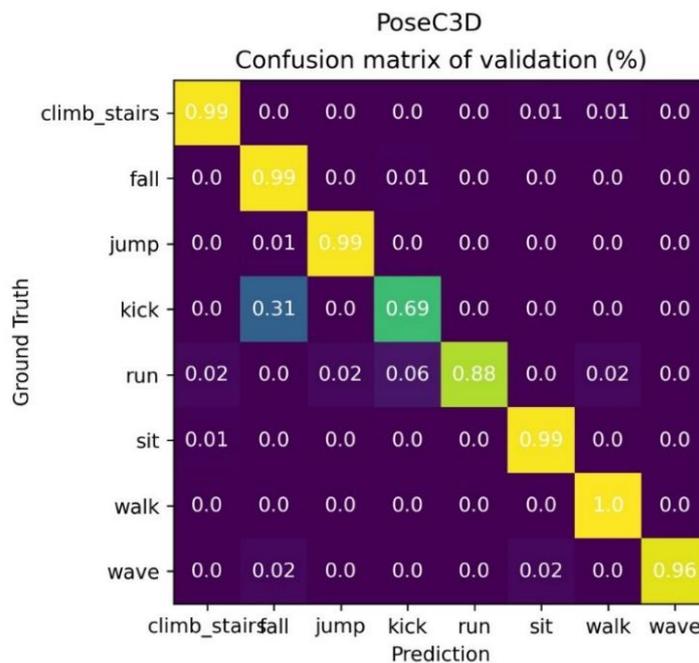
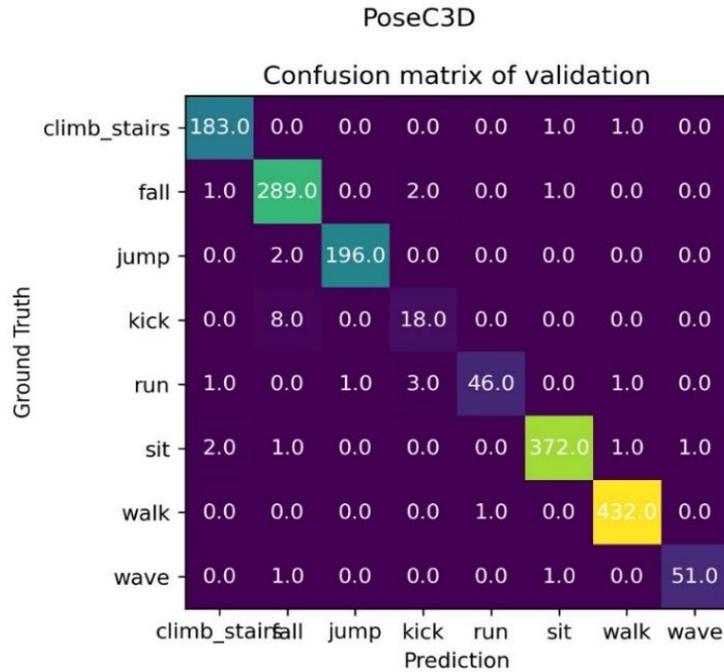


圖 4.4-11、PoseC3D 架構

本項工作最終使用的模型以超過 8000 支影片的混合資料集進行訓練，所偵測的行為包含「行走」、「跑」、「坐」、「踢」、「揮手」、「跳」、「跌倒」，其中本項工作設定後五項為異常行為。測試成果的混淆矩陣如圖 4.4-12 所示，大多數行為的正確率高達 99%，唯獨「踢」容易誤判為跌倒，推測原因為該動作的訓練資料不足，測試資料亦僅有 26 支影片。此外，由桃捷提供的測試影片辨識結果(<https://bit.ly/3gswXGu>)，可以觀察到大多數的行為辨識皆正確，而由團隊成員演示的異常行為也大多皆有偵測到，如前述辨識結果中攝影機 B 之測試影片 1:00 處團隊成員坐下，或在測試影片 E 中 1:52 處團隊成員演示跌倒，皆有偵測出正確的行為標籤，顯示此模型表現良好。



(a) 混淆矩陣 (百分比)



(b) 混淆矩陣 (數量)

圖 4.4-12、行為辨識驗證成果

在現場實際運作時須以異步方式處理串流影像，即辨識運算進行時需捨棄當下的影像幀，以避免畫面延遲。然而，在運算能力不夠快的情況會因堆疊的時序骨架不連續，而導致辨識結果不準確，如 <https://bit.ly/3V9bbX6> 成果影片所示。為了改善此問題，本團隊嘗試將 PoseC3D 更換為較輕量的 ST-GCN++ (Duan et al., 2022)，混淆矩陣如圖 4.4-13 所示，與 PoseC3D 比較結果如表 4.4-3，ST-GCN++ 的處理速度快了近 10 倍，而正確率僅有 1.25% 的下降。即便更換為較輕量的算法且已使用 NVIDIA GeForce RTX 3090 高階顯卡，在僅有一個骨架的情況仍然無法達到 10fps 以上，若畫面存在多個骨架，畫面卡頓導致幀率不穩的問題仍然嚴重影響即時處理的準確率。故未來在硬體算力無法大幅提升時，從監視影像進行即時行為辨識之策略或

需要調整。

表 4.4-3、PoseC3D 及 ST-GCN++ 成果比較

	PoseC3D	ST-GCN++
處理速度	1.27s / skeleton = 0.78fps	0.13s / skeleton = 7.69fps
準確率	93.625%	92.375%

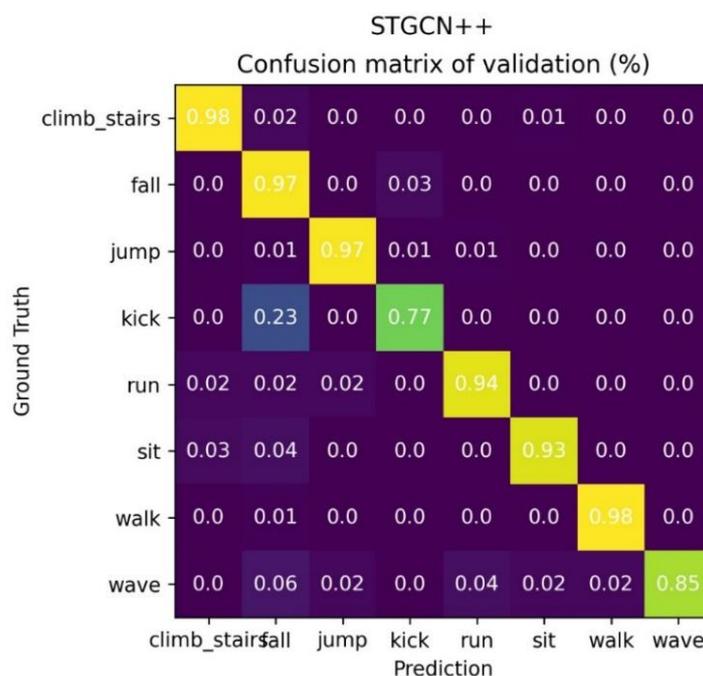
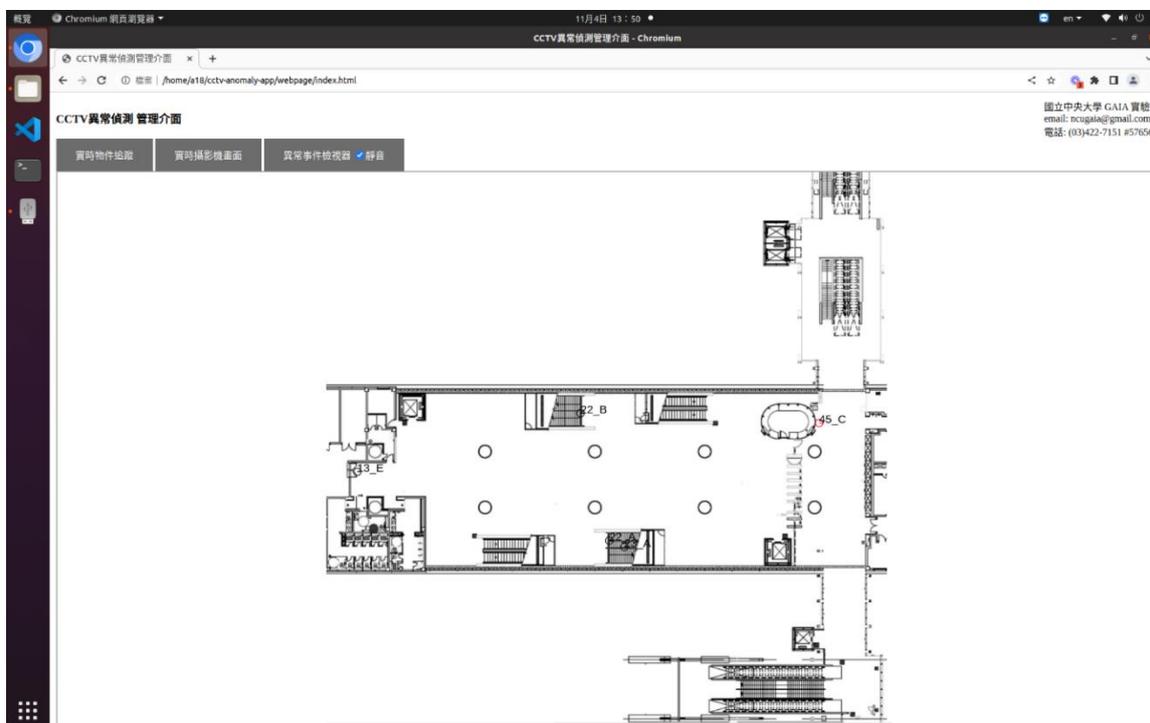


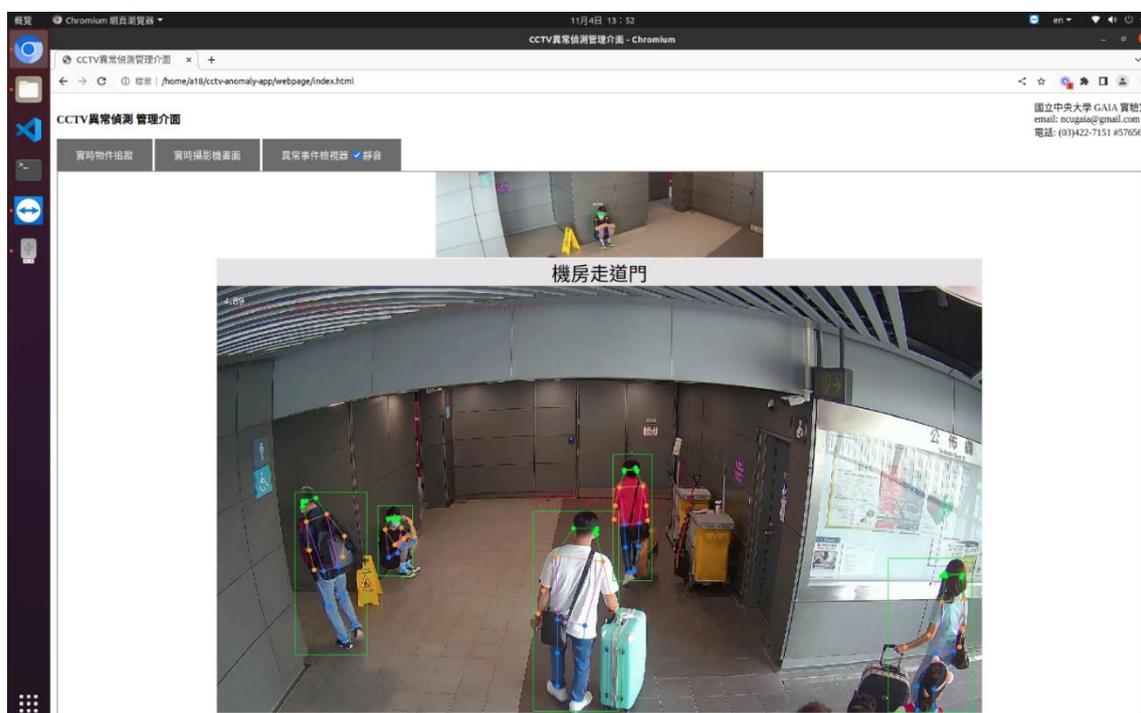
圖 4.4-13、ST-GCN++ 行為辨識驗證成果

應用介面方面，本項工作建立了異常事件警示、實時行人追蹤（圖 4.4-14(a)）、實時加註影像串流（圖 4.4-14(b)）、異常事件檢視（圖 4.4-14(c)）等功能。異常事件發生時以警示音提醒站務人員。而異常事件以 JSON 格式保存於本地檔案系統，可在前端介面上重現特定時間之物件軌跡，以及重播事件當下的影像紀錄，並附有進階搜尋功能可以查找特定異常事件，輔助管理人員進行事件追蹤判讀。為避免侵犯隱私權之疑慮，資料伺服器僅

儲存異常事件期間的影像，移動物件皆以編號表示，且系統僅在本地網路運行，無對外連網。



(a)實時行人追蹤



(b)實時加註影像串流



(c) 異常事件檢視

圖 4.4-14、桃捷 A18 站行為辨識應用介面

總結來說，本年度建立的行為辨識方法較適合應用在監視影片之離線分析，若要運用在現場串流進行即時運算，在程序的優化以及精簡神經網路模型兩個方面仍可以繼續著墨。目前使用的方法為先將行為分類，再以分類標籤界定異常與否，此方法必須先行判釋各個骨架之行為類別而造成運算負擔。因此未來或可考慮改為使用骨架姿態特徵直接判斷異常與否進行通報，後續再離線將其行為分類，如此不僅可以減少即時運算的運算量，所謂異常的行為亦不再侷限於事先界定的幾種類別。

4.5 數據分析與科教活動

4.5.1 持續分析基隆潮位站數據，包含調和分析、平均海水面、最低天文潮

面等之計算，並比較共站不同潮位計觀測值之差異

基隆潮位站設置於基隆市長潭里海洋科技博物館園區範圍內，距離臺灣水準原點現址甚近，本項工作透過收集及分析基隆潮位站潮位數據，數據分析包含調和分析、平均海水面、最低天文潮面等，並就三個潮位計之結果比較共站之差異。本項工作具體成果基隆潮位站音波式、壓力式及雷達式水位計至 2022 年 10 月 31 日 23:54 潮位數據蒐集及分析，本項工作兼具數據分析及科普教育之目的。

基隆潮位站於 2014 年 9 月 23 日完工，潮位站設置於國立海洋科技博物館主題館區（面北寧路 369 巷道）之舊臺電進水口，潮位站以不銹鋼管為靜水井，包含潮位觀測設備、氣象觀測設備（包括氣溫計、氣壓計、海上型風向風速計等）、觀測資料記錄、傳輸及展示設備（包括資料記錄器、太陽能板、充電控制器、GPS 定時器、資訊軟硬體等）。潮位站現況、設備及規格如圖 4.5-1 及表 4.5-1。本站除設置三種依據不同操作原理之水位計外，並設有不銹鋼水尺，以方便直接目視觀測。



圖 4.5-1、基隆潮位站現況

表 4.5-1、基隆潮位站設備、型號及數量

設備名稱	廠牌	型號	量測精度
音波式水位計	Aquatrak	3000XDCR and 4110 Controller	$\pm 0.025\%$ (FS)
連續式壓力式水位計	GE Druck	PTX 1830	$\pm 0.1\%$ (FS)
雷達式水位計	BM Tecnologie Industriali S.R.L.	Radar Level Meter CW Series 26GHz	5mm
水溫計	SETRON	PT-100	$\pm 0.1^{\circ}\text{C}$ at 0°C
氣溫計	SKYE	SKH2023/1/A	$\pm 0.05^{\circ}\text{C}$ at 0°C
氣壓計	VAISALA	BAROCAP	$\pm 0.35\text{hPa}$
風向風速計	YOUNG	YOUNG 05106	風速量測精度 $\pm 0.3\text{m/s}$ 風向量測精度 $\pm 3^{\circ}$
GPRS 通訊設備	廣新	MA8-2(CWB2)	
RS-232 串列設備聯網伺服器	MOXA	NPort 5210	
資料蒐集記錄器	VAISALA	QML201C	
太陽能板	聚恆	TYNP62409135	
充電控制器	Morningstar	SHS-10	
市電充電器	MEAN WELL	DR-60-12	
電池	YUASA	NP65-12	

潮位站鄰近新臺灣水準原點 K997，2014 年設置潮位站後即設置潮位站水準點 TG997（圖 4.5-2）作為參考基準點，並納入國土測繪中心高程基準網（圖 4.5-3），辦理長期且定期檢測工作。



影像來源:google earth

圖 4.5-2、K997、K996 及 TG997 示意圖



摘自國土測繪中心，2019

圖 4.5-3、臺灣水準原點高程基準網示意圖

基隆潮位站自 2019 年起由氣象局維護，2019 年水準測量由前期研究案執行，2020 年起氣象局廠商於維護時進行水準測量，潮位高程以潮位站水準點(TG997)為零點。2020 年 2 月 11 日前之潮位數據，各水位計量測之水深由參考點高程化算至水位，之後則以潮位站水準點(TG997)為零點，由前一年潮位站水準點(TG997)高程化算，水位計參考點高程如表 4.5-2，因壓力式水位計易受淤泥影響，自 2021 年 10 月 14 日起氣象局於維護時將壓力式水位計感測頭提高 0.185 公尺。

表 4.5-2、基隆潮位站 2018 至 2020 年水位計參考點高程

註:2020/02/11 後潮位高程以水準點(TG997)為零點

測點	2018/12/04 之 高程(m)	2019/8/1 之 高程(m)	2020/02/11 之 高程	2021 年之 高程	2022 年之 高程
水準點 TG997	4.6678 (2017/9/5)	4.6678 (2017/9/5)	4.6662 (2019/10)	4.6628 (2020/10)	4.6634
音波式水位計	1.0956	1.0979	-	-	-
壓力式水位計	-5.6264	-5.6298	-	-	0.185
雷達式水位計	0.2702	0.2712	-	-	-

潮位資料以 Matlab 程式語言建構之 UTide 程式進行調和分析(Harmonic Analysis) (Codiga, 2011)，UTide 程式為美國羅德島大學(University of Rhode Island, URI)所開發的潮位分析程式，基於 Foreman (1977)與 Foreman (1978)之 FORTRAN 程式碼為基礎發展而來，其分析振幅與相位角之演算法乃根據 T_Tide (Pawlowicz et al., 2002)、r_T_Tide (Leffler and Jay, 2009)與 versatile (Foreman et al., 2009)為基礎，UTide 主要有兩種分析方法，分別為普通最小

平方法(Ordinary Least Squares method, OLS)與迭代再加權最小平方法(Iteratively Reweighted Least Squares method, IRLS)配合不同加權函數計算。根據 Codiga 建議之方法，本項工作使用迭代再加權最小平方法以及 UTide 調和分析中預設之柯西加權函數(Cauchy weight function)來進行潮位調和分析。迭代再加權最小平方(Iteratively Reweighted Least Squares, IRLS)可將異常值的影響最小化，其最小化值指在觀測值與模型值之間的加權殘差之量測值或加權錯合(misfit)，其通式如式 4.5-1。其中 W 為對角矩陣對角線上的純量權值， m 為模型參數向量， B 為複數值矩陣，上標 H 指共軛轉置， x^{raw} 為觀測值。

$$m = (B^H W B)^{-1} B^H W x^{raw} \quad \text{式 4.5-1}$$

潮位分析項目：(1) 以統計方法計算潮位站之平均潮位及平均高潮間隙、(2) 利用調和分析法，將觀測資料之潮汐訊號解析出來，以獲得不同分潮的振幅及相位延遲及(3) 利用調和分析後所獲得獲得主要分潮之潮位振幅及相位角。

基隆潮位站音波式、壓力式及雷達式水位計開始觀測時間分別 2015 年 2 月 3 日、2014 年 9 月 25 日及 2015 年 4 月 10 日。潮位分析數據採用 6 分鐘潮位資料，即為每 10 秒取樣一次，每 6 分鐘之 36 筆取樣資料平均值。音波式及雷達式於 2015 至 2018 年有較長時間缺乏資料，為避免因觀測數據不一致造成三種水位計之差異，基隆潮位站分析期間統一由 2019 年 1 月

1 日 00:00 開始分析，音波式、壓力式及雷達式分析至 2022 年 10 月 31 日 23:54，圖 4.5-4 至圖 4.5-8 分別為音波式、壓力式及雷達式水位計潮位變化。其中，2021 年 9 月 12 日至 10 月 14 日壓力式水位計故障或受淤泥覆蓋，導致水位偏高，數據如圖 4.5-7 所示，壓力式水位計剔除此區間數據；2022 年 7 月 5 日雷達式水位計故障，經詢問氣象局預計修復但尚未安排修復日期，雷達式水位計剔除此區間數據。

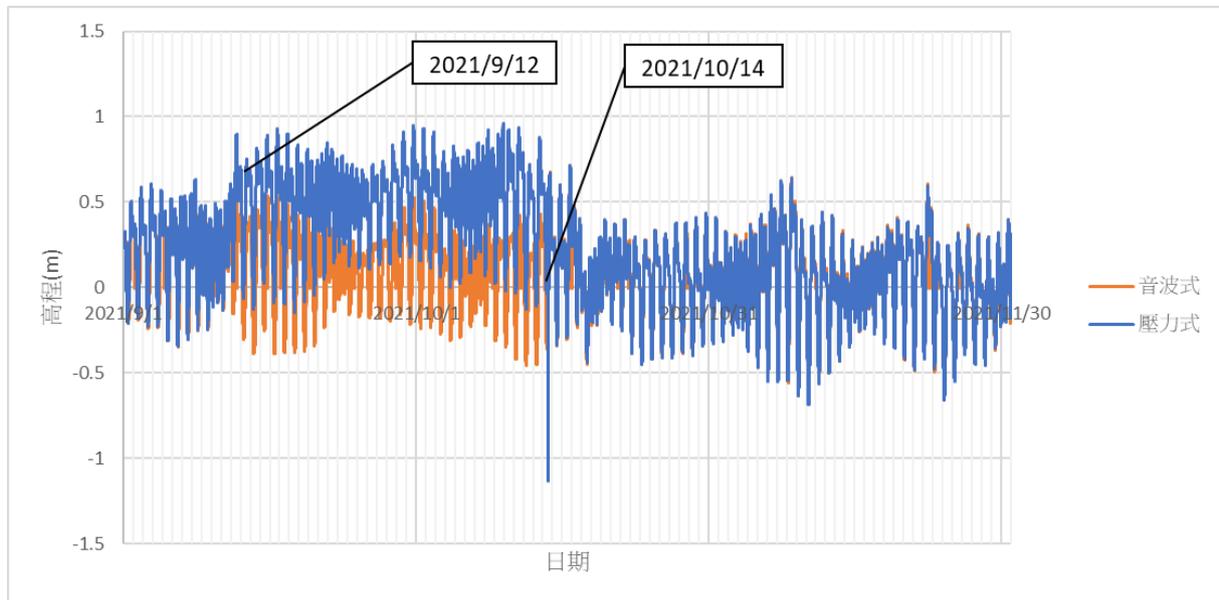


圖 4.5-4、基隆潮位站壓力式及音波式水位計 2021/9/12 至 11/30 潮位數據

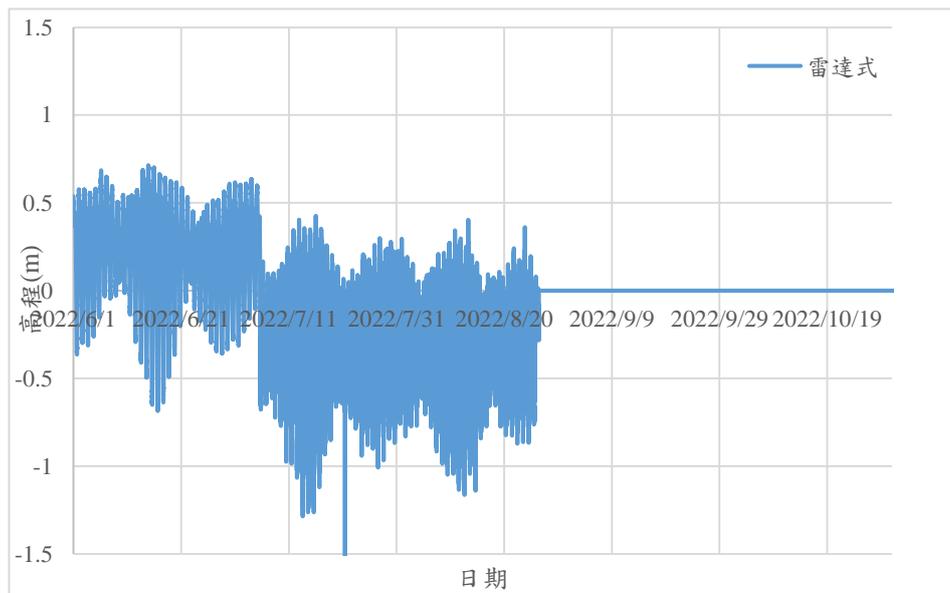


圖 4.5-5、基隆潮位站雷達式水位計 2022/6/1 至 10/31 潮位數據

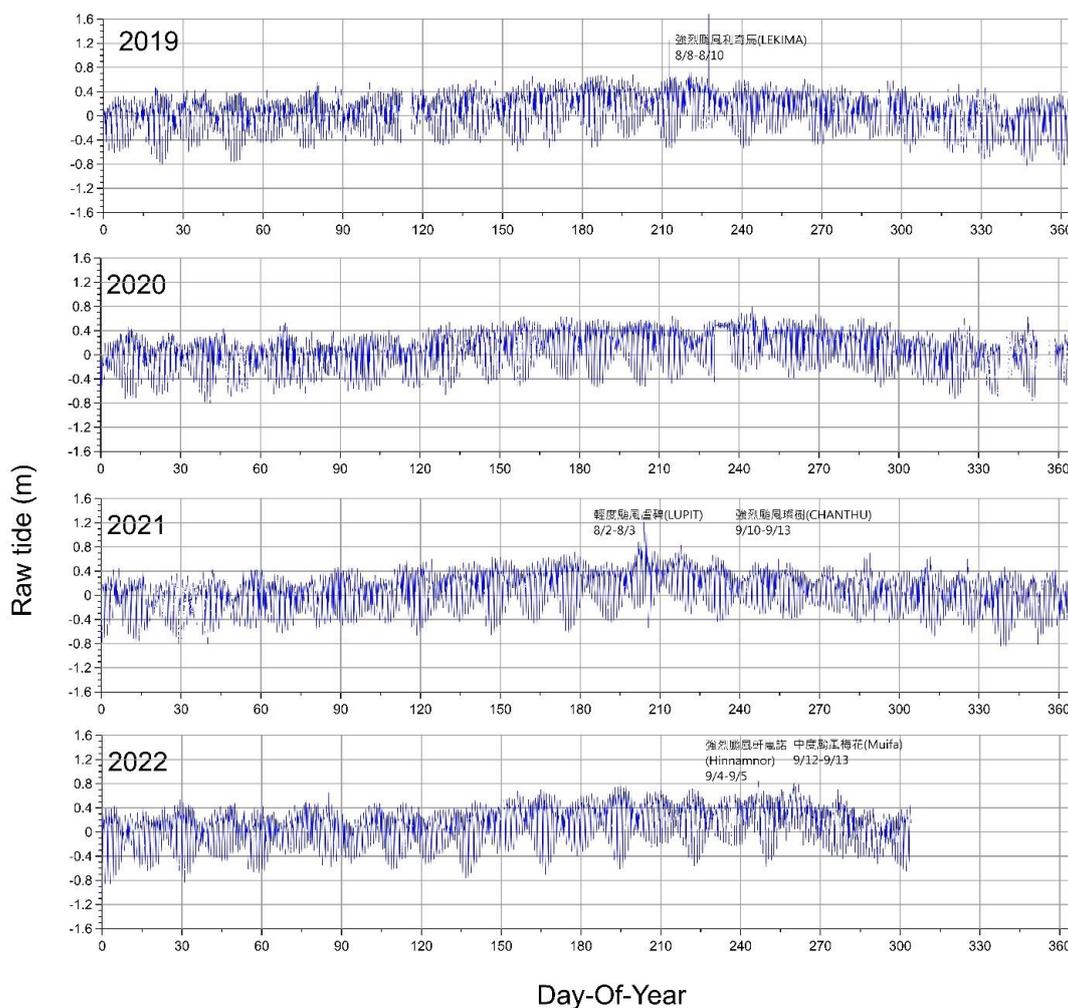


圖 4.5-6、基隆潮位站音波式水位計歷年潮位變化

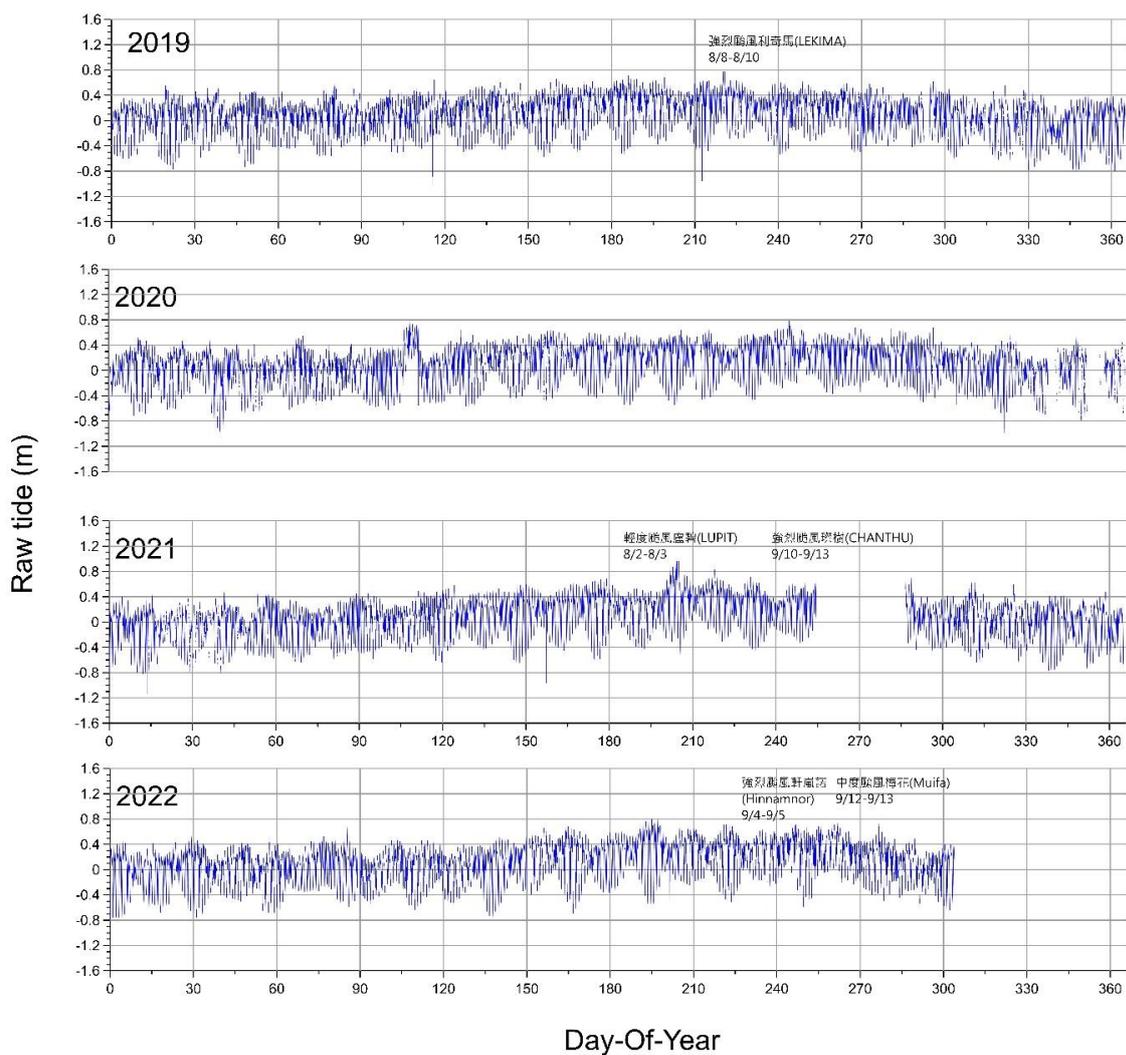


圖 4.5-7、基隆潮位站壓力式水位計歷年潮位變化

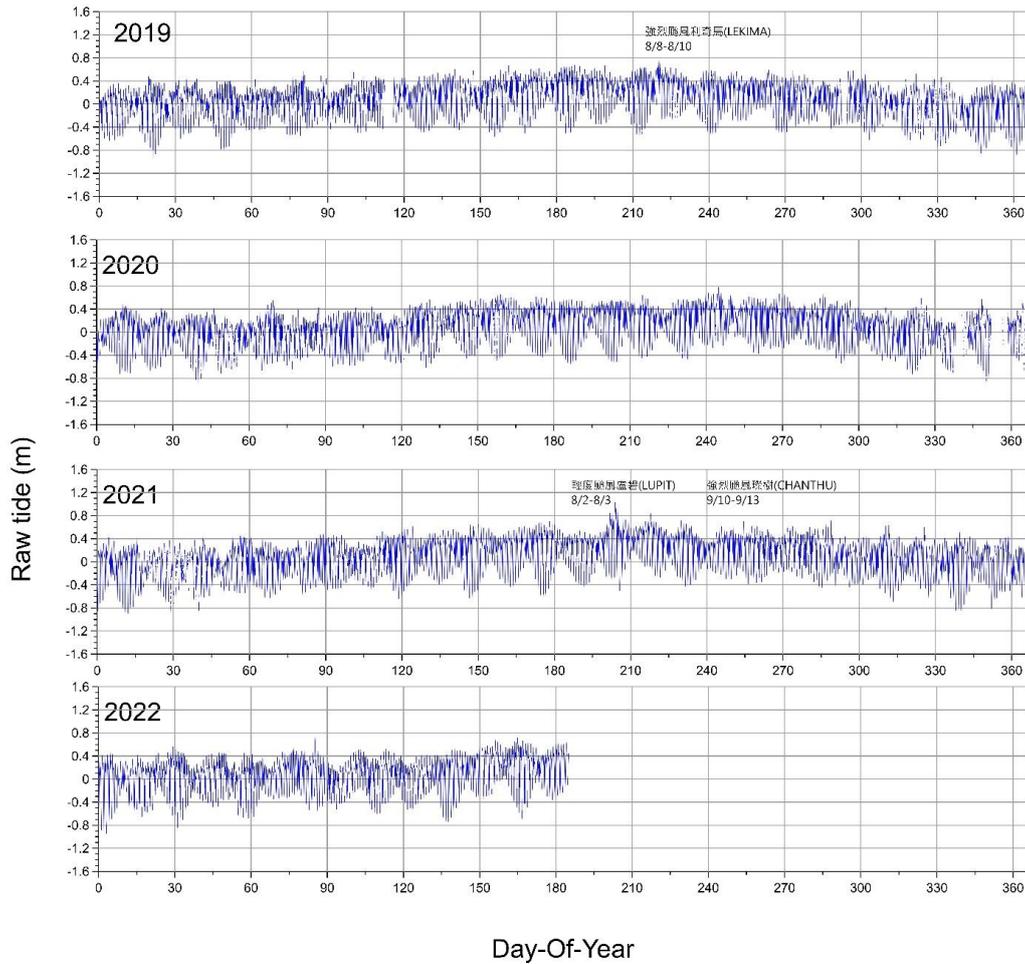


圖 4.5-8、基隆潮位站雷達式水位計歷年潮位變化

潮位數據經調和分析信噪比(SNR)大於 20，95%信心區間，共解析出 61（音波式）、61（壓力式）及 58（雷達式）個主要分潮，各分潮之頻率、振幅、振幅誤差、相位角、相位角誤差與信噪比詳見附件 B。主要分潮為頻率接近 $1/24$ （約 0.042），即為 24 小時附近之全日潮 K1、O1 與 P1，以及頻率為 $1/12$ （約 0.083），即為 12 小時附近之半日潮 M2、S2 與 N2，其振幅及相位角如表 4.5-3。三個水位計 24 小時附近之全日潮及 12 小時附近之半日潮振幅及相位角相近，振幅差值約 0~4 mm，相位角差值約 0~2 度。音波式、壓力式及至雷達式水位計觀測數據與調和分析之重組潮位時序如

圖 4.5-9 至圖 4.5-11 所示。

表 4.5-3、基隆潮位站各水位計主要分潮比較

	分潮	音波式		壓力式		雷達式	
		振幅 (mm)	相位角 (deg)	振幅 (mm)	相位角 (deg)	振幅 (mm)	相位角 (deg)
全日潮	K1	191±0.5	226±0.2	190±0.3	226±0.1	191±0.4	226±0.1
	O1	155±0.5	194±0.2	155±0.3	193±0.1	156±0.3	194±0.1
	P1	65±0.5	221±0.4	62±0.3	222±0.3	63±0.4	222±0.3
半日潮	M2	203±0.8	260±0.2	206±0.6	258±0.1	207±0.6	258±0.1
	S2	67±0.8	258±0.6	69±0.6	257±0.5	69±0.5	257±0.5
	N2	55±0.8	234±0.7	56±0.6	233±0.6	56±0.6	233±0.6

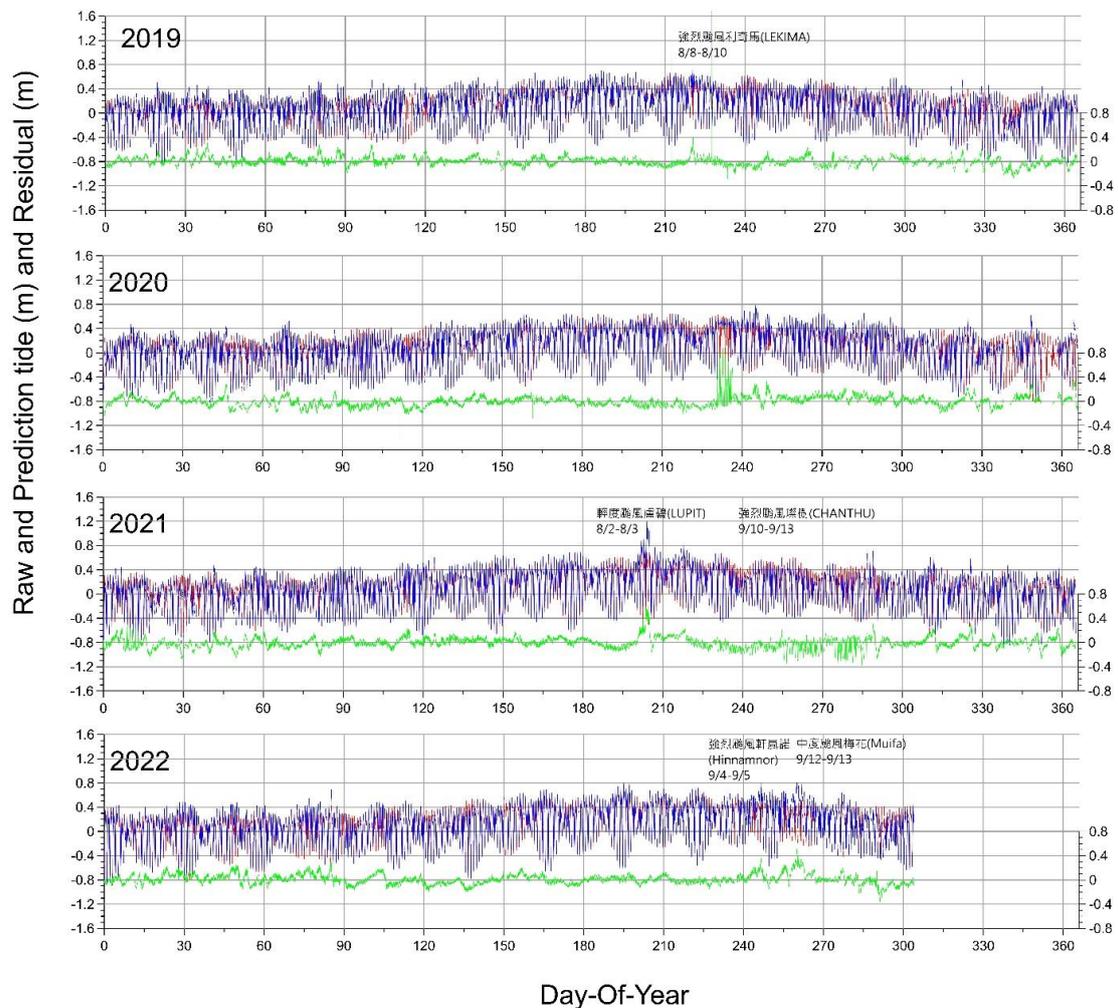


圖 4.5-9、基隆潮位站音波式水位計觀測數據與調和分析重組潮位時序圖

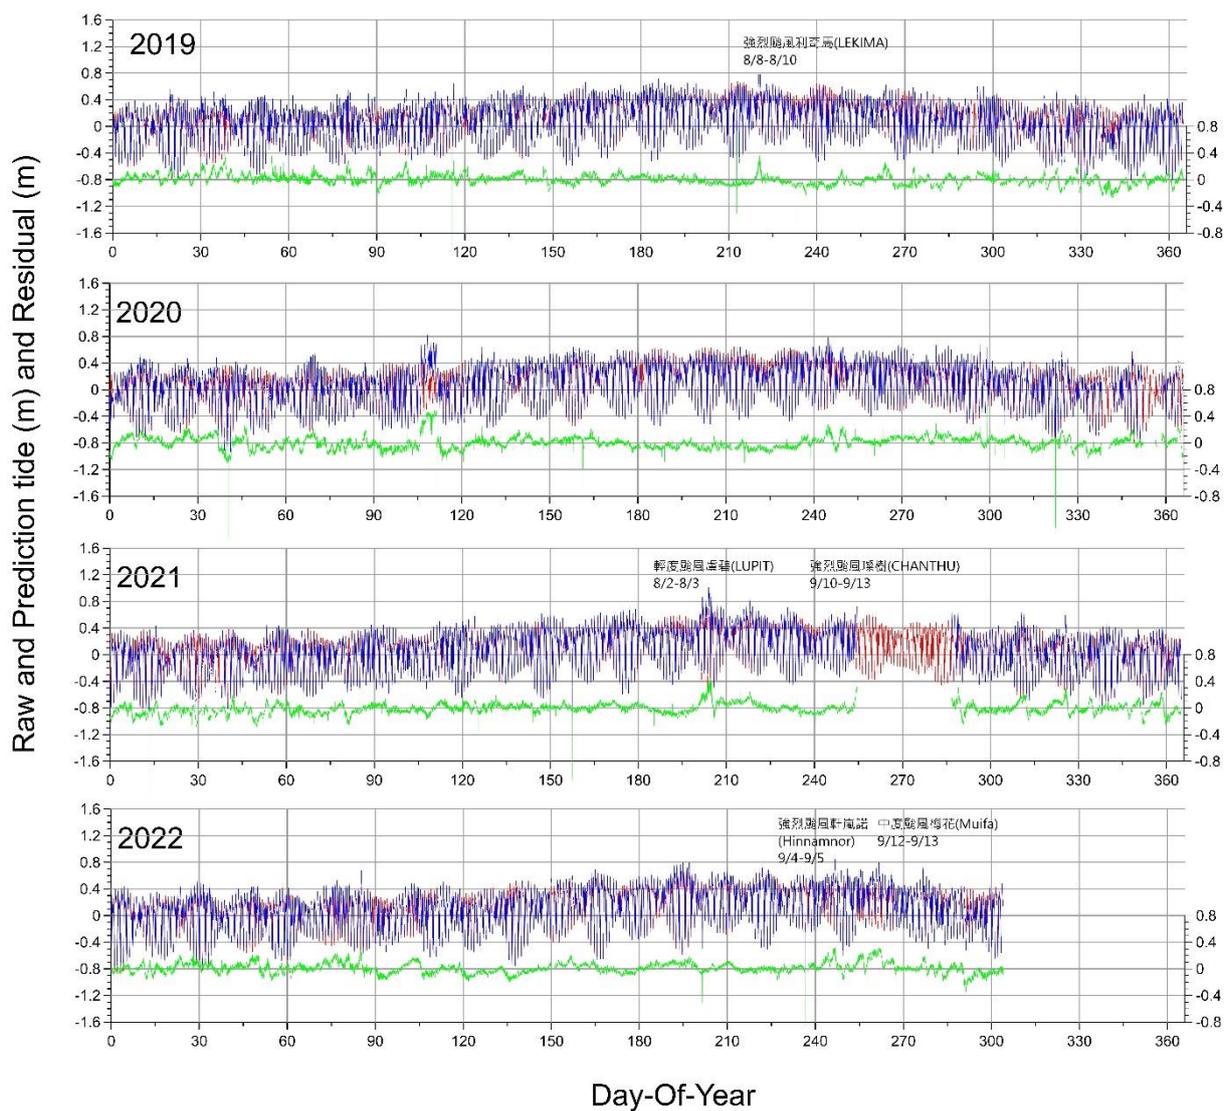


圖 4.5-10、基隆潮位站壓力式水位計觀測數據與調和分析重組潮位時序圖

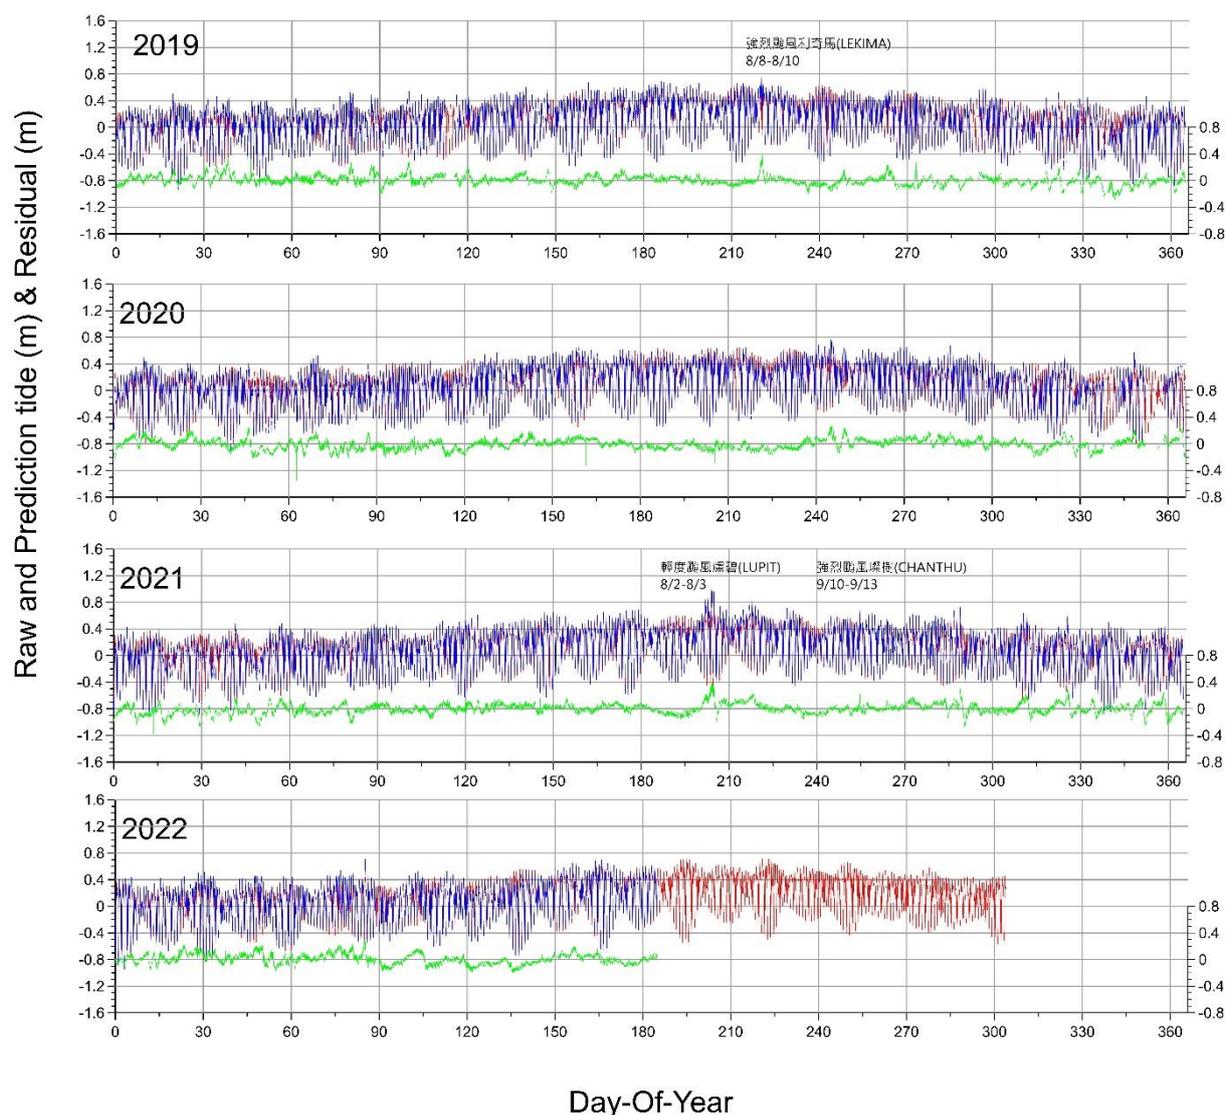


圖 4.5-11、基隆潮位站雷達式水位計觀測數據與調和分析重組潮位時序圖

基隆新設潮位站多年期水位計計算平均海水面高，如表 4.5-4 所示，其中觀測值平均為觀測量之算術平均，分潮重組為將潮位數據 UTide 進行調和分析，計算觀測時間範圍內各分潮重組後之平均海水面高。三種水位計中重組值最高的是雷達式水位計，其次為壓力式，最低是音波式，分別為 0.1003、0.0946 及 0.0894 m，差值約在 5-10 mm；比較觀測值平均與分潮重組平均之差值約 19 mm。

表 4.5-4、基隆潮位站水位計平均海水面高（單位：m）

潮位數據 2019/01/01 00:00- 2022/10/31 23:54	音波式 (S)	壓力式 (P)	雷達式 (R)	S-P	S-R	P-R
觀測值平均(m)	0.0823	0.1012	0.0819	-0.019	0.000	0.019
標準偏差(m)	0.2776	0.2678	0.288			
分潮重組後平均(m)	0.0894	0.0946	0.1003	-0.005	-0.0109	-0.006
觀測值平均與重組平均 之差值(m)	-0.0071	0.0066	-0.0184			

本項工作以前述分析出之調和常數進行未來 19 年之潮位重組，區間為 2022 年 11 月 1 日至 2041 年 10 月 31 日，建立三個水位計天文潮之深度基準，取得最低天文潮水位，時間解析度皆為 6 分鐘一筆，共計 1,665,600 筆，音波式、壓力式及雷達式水位計最低天文潮位分別為 -0.8698、-0.9036 及 -0.8695 公尺（表 4.5-5）。

表 4.5-5、基隆潮位站水位計最低天文潮水位（單位：m）

音波式(S)	壓力式(P)	雷達式(R)	S-P	S-R	P-R
-0.8698	-0.9036	-0.8695	0.0338	-0.0003	-0.0341

本項工作另逐年計算各潮位計觀測量之算術平均，以 UTide 進行當年度調和分析計算分潮重組後之平均海水面高，其結果如表 4.5-6 所示。由表 4.5-6 可見，2019 及 2020 年壓力式、音波式及雷達式分潮重組之平均海水面差值 3-12 mm。2021 年因壓力式水位計於 9 月 12 日至 10 月 14 日故障，

此區間有颱風且為往年潮位較高之期間，缺少這段時間之潮位數據，使得該年度觀測值及分潮重組後平均均略低於 2019 及 2020；雷達式水位計觀測值及分潮重組後平均略高於 2019 及 2020 年，推測可能原因颱風期間靜水井可能有較多漂流物。

表 4.5-6、基隆潮位站逐年水位計平均海水面高（單位：m）

年度	項目	S	P	R	S-P	S-R	P-R
2019	觀測值平均	0.0869	0.0991	0.0906	-0.0122	-0.0037	0.0085
	標準偏差	0.2727	0.2714	0.2741			
	分潮重組後平均	0.0897	0.1024	0.0936	-0.0127	-0.0039	0.0088
2020	觀測值平均	0.0913	0.1052	0.0945	-0.0139	-0.0032	0.0107
	標準偏差	0.2805	0.2775	0.2789			
	分潮重組後平均	0.0839	0.0957	0.0888	-0.0118	-0.0049	0.0069
2021	觀測值平均	0.0894	0.0793	0.1079	0.0101	-0.0185	-0.0286
	標準偏差	0.284	0.2885	0.2891			
	分潮重組後平均	0.0916	0.084	0.1109	0.0076	-0.0193	-0.0269

以量測方式而言，音波式水位計屬於直接量測儀器裝置，因傳導介質之溫度、濕度會影響音波的傳導，需做溫度及濕度的校正，設計上亦包含這些改正的考量；雷達式水位計與音波式水位計很相近，使用雷達波亦受傳導介質之影響；壓力式水位計屬於間接量測，利用感測器感應海水位升

降產生之壓力變化，將所量測之壓力值轉換成水位高度。音波式及雷達式不因海水比重、溫度等影響測量。

以環境而言，基隆新設潮位站於颱風期間，靜水井容易帶入汙泥及垃圾，音波式導音管受到汙泥阻塞之威脅嚴重，現維護時以濾網加強防止汙泥進入導音管，近兩年較無阻塞問題。壓力式水位計於汙泥淤積嚴重時，會覆蓋住感測器，導致無法量測水深，或因汙泥與海水密度不同，影響壓力值換算水位高度，長期受汙泥影響易造成感測器故障，2021 年 10 月 14 日將感測器提高 0.185 公尺，將持續觀測是否仍受淤泥淤積影響；雷達式則常因靜水井內之漂浮性垃圾產生觀測異常，颱風期間影響尤劇。以基隆新設潮位站而言，汙泥及垃圾影響壓力式及雷達式潮位計之穩定，目前以音波式為主，壓力式為輔助系統。基隆新設潮位站站除蒐集分析潮位數據外，音波式、壓力式及雷達式共站提供科學教育應用

4.5.2 配合內政部及國立海洋科技博物館，規劃水深與高程測量相關成果發

表之科學教育教材，並舉辦 1 場次（至少 6 小時）之科教活動；受邀

參加活動對象需經內政部同意

科學教材配合建置於海科館之潮位站及鄰近之臺灣水準原點為主題，內容包含水準原點、潮汐及高程測量，對象為高工學生，活動安排三場科普演講及海洋科技博物館三個展廳導覽介紹，科普演講由國立陽明交通大學土木系張智安教授分享高程與潮位測量、及由太空看海洋；氣象局海象

測報中心滕春慈主任分享潮位與波浪觀測，活動課程表如表 4.5-7。

本年度於 9 月 30 日由大安高工（老師與學生共 72 位）及南港高工（老師與學生共 36 位）共 108 位一同參與，研習營活動照片如圖 4.5-12。

表 4.5-7、科教活動預定議程

時間	內容	主講人
08:30-09:00	報到	
09:00-09:30	高程與深度	陽明交大 史天元教授
09:30-10:20	潮位站/水準原點 參觀導覽	陽明交大 史天元教授 張智安教授
10:20-11:20	潮位與波浪觀測	中央氣象局 滕春慈主任
11:20-12:20	由太空看海洋	陽明交大 張智安教授
12:20-13:20	午餐	
13:20-16:00	深海探勘/海洋科學/ 船舶與海洋工程導覽	陽明交大史天元教授、張智安教授、王慧蓉工程師 海洋科技博物館講師



(a) 水準原點介紹



(b) 潮位與波浪觀測



(c) 由天空看海洋



(d) 船舶與海洋工程



(e) 頒發研習營證書

圖 4.5-12、研習營活動紀實

4.5.3 蒐集本案相關之航遙測技術與應用文件，製作科學教育數位課程教材 1 式，並舉辦 1 場次（至少 6 小時）之科教活動；受邀參加活動對象需經內政部同意

本團隊與國立中央大學太空及遙測研究中心-資源衛星接收站合辦，規劃航遙測技術與應用相關成果，並以衛星遙測科技應用案例進行說明。本次活動至少 6 小時，參加活動之對象以高中（職）、國中、國小現職教師為主，於 8 月 24 日完成活動辦理，議程如表 4.5-8，並採實體課程方式舉辦。透過案例探討、課程實作觀摩等活動，達到研究成果分享、協助科普

課程設計、提升遙測及空間資訊科技研究及應用科教活動支援及紮根之目標。本次活動報名人數 55 名，實際報到人數 35 名，活動照片如圖 4.5-13。

表 4.5-8、科教活動議程

時間	主題	授課教師
09:00~09:30	學員報到	
09:30~09:40	開場	林唐煌主任 蔡富安教授
09:40~10:40	衛星遙測簡介	蔡富安教授
10:40~10:50	休息	
10:50~12:20	影像變遷分析簡介及實作	徐筱柔小姐
12:20~13:00	交流及用餐	
13:00~14:30	影像地物分類簡介及實作	黃瓊民小姐
14:30~14:40	休息	
14:40~16:10	地理資訊系統應用及繪圖	戴于恒助理工程師
16:10~16:40	心得與座談	蔡富安教授



(a) 太遙中心主任開場與課程-衛星遙測簡介



(b) 課程-影像變遷分析與影像地物分類



(c) 課程-地理資訊系統應用

圖 4.5-13、科教活動上課照片

4.6 成果發表及技術交流

本團隊完成之研究成果發表及技術交流包含：

- (一) 本團隊完成期刊及論文（含 SCI 等級）投稿共 4 篇，分別為(1) International Society for Photogrammetry and Remote Sensing 2022，題目為 Landslide Inventory Mapping From Landsat-8 NDVI Time Series Using Adaptive Landslide Interval Detection、(2) International Journal of Applied

Earth Observation and Geoinformation，題目為 Comparison between image- and surface-derived displacement fields for landslide monitoring using an unmanned aerial vehicle、(3) Journal of the Chinese Institute of Engineers，題目為 Effectiveness of the red-edge band of RapidEye in land cover classification、(4) 航測及遙測學刊，題目為以高解析衛星影像輔以深度學習建置三維房屋模型。投稿證明請參考附件 C。

(二) 本團隊分別成立 GeoAI@NCU 及 GeoAI@NYCU 實驗室，成立目的為：(1)研發三維國土形變與空間智能分析之相關智慧製圖技術、(2)推動智慧製圖與空間資訊領域產業之聯結。GeoAI 實驗室團隊專注於智慧製圖技術之發展，並推動與空間資訊領域之聯結。

4.7 成果效益評估與計畫進度管考

依據科技計畫績效管考平臺(<http://gstp.stpi.narl.org.tw>)提供格式，配合內政部辦理本計畫「科技發展計畫績效評估作業」自評作業需求，參考內政部提供之相關績效作業範本，填寫本計畫相關成果效益報告書、績效指標、佐證資料、政府科技發展計畫績效評估；另配合將本計畫各期資訊登載政府研究資訊系統(GRB, <https://www.grb.gov.tw/>)，且將登載結果繳附於各期工作成果，並適時接受諮詢。

4.8 工作會議

本團隊定期召開工作會議，並適時接受諮詢。每次工作會議需提供會議紀錄。其中 2 次需邀請專家學者（名單已與內政部討論）參與交換意見，並作為後續應用方向或執行參考，所需費用由本團隊負擔。目前共召開 9 次工作會議，於 9 月 26 日邀請政治大學邱式鴻教授與 10 月 18 日邀請臺灣師範大學王聖鐸教授參與會議，工作會議舉辦時間如表 4.8-1，工作會議相關內容請參考附件 D。

表 4.8-1、工作會議舉辦時間表

	時間	備註
1	111 /03/07	邀請內政部地政司-吳俊毅、鄒芳諭參與
2	111 /04/27	邀請內政部地政司-吳俊毅、鄒芳諭參與
3	111/05/19	邀請內政部地政司-吳俊毅、鄒芳諭參與
4	111/06/29	邀請內政部地政司-吳俊毅、鄒芳諭參與
5	111/07/28	邀請內政部地政司-吳俊毅、鄒芳諭參與
6	111/08/25	邀請內政部地政司-鄒芳諭參與
7	111/09/26	邀請內政部地政司-鄒芳諭與政治大學-邱式鴻教授參與
8	111/10/18	邀請內政部地政司-吳俊毅、鄒芳諭與臺灣師範大學-王聖鐸教授參與
9	111/11/14	邀請內政部地政司-吳俊毅、鄒芳諭參與

第五章 結論

本次期末報告執行 3.1 節詳列之各工作項目，並依 3.2 節規劃之工作進度執行工作項目，以確保計畫執行符合預定規劃進度。本計畫目前執行成果總結如下：

1. 應用人工智慧發展衛星影像地表形變分析技術與應用

(1) 利用雷達衛星影像發展長期地表形變自動化智慧分析技術：本項工作完成使用 StaMPS 方法與 AI 預測所產生的之 PSInSAR 成果，並對都市、城鎮、鄉村、港灣與橋梁等區域進行精度檢驗，最後透過 GNSS 資料檢測上述兩種方法之成果。

未來規劃：透過 AI 替換 StaMPS 的 PS 點選取，增加更多年期的 PSInSAR 分析，豐富機器學習之訓練資料模型，以提升 AI 預測 PS 點之精度與作業效率。

(2) 精進機器學習於高解析光學影像地表形變分析技術：本項工作完成使用光學影像、光學加雷達影像、TerraSAR-X 影像三種影像來源進行模型訓練，並透過訓練模型預測地表形變區域與精度評估，且產製光學影像 5100 組訓練影像、光學加雷達影像 3600 組訓練影像、TerraSAR-X 影像 500 組訓練影像。

未來規劃：優化光學影像之訓練資料，目前為針對崩塌區域進行訓練，

思考加入其它訓練物件以提昇偵測精度，如雲、河谷等的物件，以及增加前、後期影像資料，豐富訓練所需資料。

(3) 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取：本項工作完成利用 AI 技術進行影像解析度 0.7 公尺之 Pleiades 影像與解析度 1.5 公尺之 SPOT-6 影像兩組資料之房屋區域與道路區域自動化萃取。成果顯示使用 Pleiades 影像進行房屋區偵測精度明顯優於 SPOT-6 之成果，整體精度優於 82%。

未來規劃：因特殊屋頂形狀之房屋與偵測不完整或相連之區域經正規化與約化處理後，房屋區域與真實狀況會有所差異。未來規劃將評估特殊屋頂形狀之房屋正規化約化精進處理或其模塑時精化之程序，以建置符合品質之房屋模型。道路偵測成果則持續開發與精化道路向量化處理，作為未來建模之應用。

(4) 擴充衛星影像智慧加值應用與後續推動可行性評估：本項工作完成彙整加值應用案例、智慧加值應用可行性評估與加值應用整合平臺評估。因 Data Cube 具有相當彈性的功能擴充性，可客製化演算法進行資料加值處理，對於衛星影像智慧加值應用而言肯定具有相當的價值，建議後續之應用處理能基於類似之平臺來進行發展。

未來規劃：增加擴充性較優之平臺以進行評估，或是針對 Data Cube 進行深入研究，規劃 Data Cube 於衛星影像之加值應用功能，以及推

廣、深入高中或大學課程教育中，如微課程等，豐富影像分析之演算法，以提升衛星影像智慧加值應用可行性。

2. 應用人工智慧發展航遙測影像辨識技術與應用

(1) 建立航遙測影像地表三維形變智慧分析技術：本項工作完成多時期航遙測影像地表三維形變智慧分析技術，自動化萃取三維地表位場，並驗證技術可行性。

未來規劃：本項技術使用無人機影像建立地表三維形變，隨著無人機光達技術的發展，未來規劃針對無人機光達點雲發展地表三維形變技術。

(2) 建立航遙測影像智慧辨識訓練資料集，須對不同類型之資料集進行整理並分析其適用性，探討結合影像與高程模型於地表分類之效益：本項工作完成航遙測影像及對應高程模型之國際房屋偵測標竿資料集蒐集，已蒐集五個國際公開標竿資料集，比較與分析各標竿資料集的內容與特性，並選定 AOIO 訓練資料集於房屋智慧辨識。

未來規劃：隨著開放資料的發展，有更多的國際標竿資料集公開共享，為能掌握最新資料集，本項工作規劃持續更新及評估國際標竿資料集。

(3) 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效：本項工作完成房屋智慧判釋技術，採取資料融合技術整合多光譜

正射影像及 DSM，比較單一多光譜正射影像與資料融合技術的精度，並進行遷移式學習及直接訓練之比較分析。實驗展示多空間解析度 AIOI 國際開放資料集對臺灣建築物判釋有基礎的能力，透過遷移式學習可有效提升對臺灣建築物的判釋能力，使誤授與漏授皆低於 10%。

未來規劃：因 DSM 改正正射化影像之房屋邊界會有局部變形，未來規劃發展房屋邊界正規化技術，以提升房屋邊界的正確性。

(4) 精進航遙測影像結合測量實施工作之智慧整合應用：本項工作完成精進無人機測繪技術於「人孔調查」的可行性，並以無人機不同影像空間解析度(2、5、10cm)進行人孔智慧判釋試辦。實驗成果顯示，在 2cm 與 5cm 的空間解析度下，獨立驗證區的偵測成果之成功率及正確率均達到 89%；在人孔中心坐標與現地測量成果比較，三種空間解析度的平面均方根誤差小於 10cm，高程均方根誤差小於 20cm。因此建議人孔尺度的智慧辨識採用優於 5cm 空間解析度之影像。

未來規劃：為提升人孔智慧辨識的泛用性，未來規劃增加不同場域的資料，精進智慧辨識模型，供後續測量製圖加值應用。

3. 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦

(1) 利用雷達衛星影像地表形變分析，建立臺灣各地初步形變分析圖資，至少包含全臺灣 C-波段多時期雷達影像，及選定之災害潛勢區域

L-波段與 X-波段雷達影像：本項工作完成 C 波段-全臺灣 PSInSAR 相對形變速率觀測（2017-2021 五年期）、X 波段-臺北港填海造陸區、L 波段高雄美濃地震事件(2016)試辦作業。

未來規劃：配合內政部辦理，並依研究之技術（衛星與航遙測影像智慧分析）進行相關試辦作業，以確認研究技術之可行性。

(2) 以兩年內高解析（2 公尺或更優）光學衛星影像進行數值地表模型(DSM)變異分析，發展利用衛星影像進行 DSM 變異以協助光達修測規劃之方法與作業程序：本項工作完成試辦區地形變異分析，比對立體像對產製之數值地表模型與前期之空載光達所產製數值地表模型，以 1/5000 圖幅為單元進行評估，了解其地形變異程度，並依照評估之指標篩選建議更新之圖幅。本項工作試辦區圖幅範圍為 684 幅，經分區評估有 43 幅之地表形變大於門檻值，建議更新圖幅佔試辦區圖幅比例分別約為 6.3%。參考本案之試辦經驗，擬定衛星影像數值地表模型變異分析及更新建議作業程序，提出作業流程執行方式及所需相關資料。

未來規劃：本項工作訂定利用衛星影像協助光達修測規劃之方法與作業程序，並已完成 3 個試辦區之測試。未來可在光達修測數值地表模型工作執行前，先以本項工作規劃作業程序分析建議更新之圖幅，再依實際作業情況進行通盤考量，規劃光達修測數值地表模型之目標區

域。透過此方式可優先修測地表變異較大區域，針對有需要之區域及時提供最新之數值地表模型。

(3) 航遙測影像分析與辨識之結果，精進與坡地防災應用平臺進行整合，其整合方案須與內政部討論後辦理：本項工作完成利用 GEE 平臺發展坡地防災應用，發展以時序多光譜衛星影像與 DEM 高程資訊之崩塌地偵測技術，並以物件式之分類以解決前年度之混合像元問題，另外本年度分別建置機器學習(ML-based)與深度學習(DL-based)崩塌地偵測程序，並探討不同分割單元與 DEM 融合策略對崩塌判釋之影響。成果顯示無論是機器學習或是深度學習模型在大面積崩塌地之判釋成果相當（皆優於前年度），但 DL-based 模型能獲得較 ML-based 模型低之誤授率、更高之 IoU 值以及較低之預測耗時。DEM 融合策略與所使用之深度學習網路相關，而實驗結果顯示以雙變量之 DEM 特徵融合策略能在 LSTM 模型獲得較穩定之模型訓練過程，亦能獲得較低之漏授率。

未來規劃：目前時序資料崩塌地偵測技術之瓶頸為光學多光譜影像之空間解析度，現階段物件式分割受限於 Landsat 30m 影像解析度，導致後續判釋成果未能與林務局崩塌判釋資料之細緻度相比，未來規劃使用 Sentinel-2 或更高空間解析度之影像進行崩塌地偵測之坡地防災應用。

(4) 以臺灣地區航遙測影像進行地物辨識與分類，辦理區域範圍至少為五千分之一圖幅 10 幅（含）以上：本項工作完成 23 幅房屋區域智慧判釋及變遷偵測，本年度使用 DSM 改正正射影像，並整合 DSM 建立房屋智慧判釋方法，「跨年度智慧房屋預測」之 F1-Score 精度評達 90%；22 幅圖幅房屋變遷偵測精度整體精度達 75%，變遷錯誤偵測多數發生在物件面積相對較小的房屋。研究成果可進一步應用於計算各圖幅房屋變遷率，探討各圖幅房屋改變比例，以利圖資更新作業參考使用。

未來規劃：本年度正射影像及 DSM 來自 Taiwan eMap 測製使用的航照影像，正射影像及 DSM 細緻度受影像比例尺及航帶側向重疊率限制，未來可測試使用 1/1000 數值地形圖對應之大比例尺的航照影像，提升正射影像及 DSM 細緻度對提升智慧判釋成果之效益。

4. 評估智慧物聯網之防災整合應用技術

(1) 模擬基於感測器與模型資料，發展智慧建築等適地性應用：本項工作完成整合城市資訊、物聯網及都市淹水模式建立導航防救災之模擬應用等，並藉由模擬顯示此些資源與技術之整合對發展智慧城市應用之潛力與重要性。

未來規劃：配合內政部規劃之各期主題，進行相關技術、感測器等研究之模擬。

(2) 模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術：本項工作完成改進前期（109、110 年）發展之跨 CCTV 攝影機移動物件追蹤技術，包含替換為更強健之追蹤器，以及加入物件分類至身份辨識程序，提升此技術成果之精度。

未來規劃：精進物件追蹤技術，加強物件分類、分類篩選機制與特徵匹配等技術，以提升跨 CCTV 攝影機移動物件追蹤技術。

(3) 以實際場域進行適地性服務應用試辦：本項工作完成以桃園高鐵捷運站 A18 站為試辦場域，並以物件追蹤及人類行為辨識建立捷運車站智慧防救災通報系統為主題，建立骨架行為辨識方法與分類、監視影片之離線分析等實際應用。

未來規劃：使用骨架姿態特徵直接判斷異常與否進行通報，再離線將其行為分類，以減少即時運算的運算量，所謂異常的行為亦不再侷限於事先界定的幾種類別。

5. 數據分析與科教活動

(1) 持續分析基隆潮位站數據，包含調和分析、平均海水面、最低天文潮面等之計算，並比較共站不同潮位計觀測值之差異：本項工作完成基隆潮位站音波式、壓力式及雷達式潮位計至 2022/10/31 的潮位數據收集及分析，並完成基隆潮位站共站不同潮位計觀測值之差異分析。

未來規劃：持續收集基隆潮位站三種潮位計數據並進行潮位數據分析。

(2) 配合內政部及國立海洋科技博物館，規劃水深與高程測量相關成果發表之科學教育教材，並舉辦 1 場次（至少 6 小時）之科教活動：本項工作已於 9 月 30 日在國立海洋科技博物館完成科學教育活動，共 108 位師生共同參與研習營活動。

未來規劃：配合內政部辦理水深與高程測量相關之科學教育活動。

(3) 蒐集本計畫相關之航遙測技術與應用文件，製作科學教育數位課程教材 1 式，並舉辦 1 場次（至少 6 小時）之科教活動：本項工作規劃航遙測技術與應用相關成果，並以衛星遙測科技應用案例進行說明。活動共 35 位高中（職）、國中、國小現職教師參與，並於 8 月 24 日完成活動辦理。

未來規劃：配合內政部辦理衛星遙測科技應用相關之科學教育活動。

6. 成果發表及技術交流

(1) 本團隊完成期刊及論文（含 SCI 等級）投稿共 4 篇，分別為(a) International Society for Photogrammetry and Remote Sensing (ISPRS)，題目為 landslide inventory mapping from landsat-8 ndvi time series using adaptive landslide interval detection、(b) International Journal of Applied Earth Observation and Geoinformation，題目為 Comparison between

image- and surface-derived displacement fields for landslide monitoring using an unmanned aerial vehicle、(c) Journal of the Chinese Institute of Engineers, 題目為 Effectiveness of the red-edge band of RapidEye in land cover classification、(d) 航測及遙測學刊, 題目為以高解析衛星影像輔以深度學習建置三維房屋模型。

(2) 分別成立 GeoAI@NCU 及 GeoAI@NYCU 實驗室, 持續研發三維國土形變與空間智能分析之相關智慧製圖技術, 以及推動智慧製圖與空間資訊領域產業之聯結。

未來規劃：配合內政部辦理相關研究成果發表、推動國土形變與空間智能分析之相關智慧製圖技術。

參考文獻

- 1、內政部，(2011)。一千分之一數值航測地形圖測製作業規定。
- 2、內政部營建署，(2020)。公共設施管線資料標準 2.0 版。
- 3、國土測繪中心，(2020)。109 年度多旋翼機航拍與影像處理及設備維護作業採購案，工作總報告。
- 4、陳棋炫、王婷慧、蘇俊陽、趙韋安、陳勉銘、費立沅，(2017)。利用多時期山崩目錄評估山崩發生度-以曾文水庫集水區為例，工程環境會刊，(36)，49-66。
- 5、臺北市政府都市發展局，(2004)。臺北市一千分之一數值地形圖編碼及圖式，URL: <http://www.map.udd.taipei.gov.tw/讀圖手冊.pdf>
- 6、臺灣資通產業標準協會，(2020)。高精地圖圖資內容及格式標準，TAICS TS-0024 v1.0。
- 7、戴于恒，(2016)。應用合成孔徑雷達差分干涉技術監測山崩之潛移現象—以九份及烏來地區為例。
- 8、簡留玄，(2020)。結合永久散射體雷達差分干涉法與全球衛星定位系統計算地表三維變形。國立中央大學土木工程學系碩士論文，桃園縣。
- 9、Achanta, R., & Susstrunk, S. (2017). Superpixels and polygons using simple non-iterative clustering. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 4651-4660).
- 10、Al-Najjar, H. A., Kalantar, B., Pradhan, B., Saeidi, V., Halin, A. A., Ueda, N., & Mansor, S. (2019). Land cover classification from fused DSM and UAV images using convolutional neural networks. Remote Sensing 11(12): 1461.
- 11、Audebert, N., Saux, B. L., & Lefèvre, S. (2016). Semantic segmentation of earth observation data using multimodal and multi-scale deep networks. In Asian conference on computer vision (pp. 180-196). Springer, Cham.
- 12、Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. arXiv preprint arXiv:1803.01271.
- 13、Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., & Heynen, M. (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. ISPRS Journal of photogrammetry and remote sensing, 58(3-4), 239-258.
- 14、Bewley, A., Ge, Z., Ott, L., Ramos, F., & Upcroft, B. (2016). Simple online and realtime tracking. In 2016 IEEE international conference on image processing (ICIP) (pp. 3464-3468). IEEE.
- 15、Blomley, R., & Weinmann, M. (2017). USING MULTI-SCALE FEATURES FOR THE 3D SEMANTIC LABELING OF AIRBORNE LASER SCANNING DATA.

- ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences, 4.
- 16、Bradbury, K., Brigman, B., Collins, L., Johnson, T., Lin, S., Newell, R., ... & Xi, Y. (2016). Aerial imagery object identification dataset for building and road detection, and building height estimation. figshare. Collection. <https://doi.org/10.6084/m9.figshare.c.3290519.v1>.
 - 17、Cao, Z., Simon, T., Wei, S. E., & Sheikh, Y. (2021). "OpenPose: Realtime Multi-Person 2D Pose Estimation Using Part Affinity Fields," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 43, no. 1 (pp. 172-186).
 - 18、Chen, J., Lu, Y., Yu, Q., Luo, X., Adeli, E., Wang, Y., ... & Zhou, Y. (2021). Transunet: Transformers make strong encoders for medical image segmentation. arXiv preprint arXiv:2102.04306.
 - 19、Christ, M., Braun, N., Neuffer, J., & Kempa-Liehr, A. W. (2018). Time series feature extraction on basis of scalable hypothesis tests (tsfresh—a python package). *Neurocomputing*, 307, 72-77.
 - 20、Codiga, D. L. (2011). Unified tidal analysis and prediction using the UTide Matlab functions.
 - 21、Deijns, A. A., Bevington, A. R., van Zadelhoff, F., de Jong, S. M., Geertsema, M., & McDougall, S. (2020). Semi-automated detection of landslide timing using harmonic modelling of satellite imagery, Buckingham River, Canada. *International Journal of Applied Earth Observation and Geoinformation*, 84, 101943.
 - 22、Dronedeploy. (2019). DroneDeploy Segmentation Benchmark. <https://github.com/dronedeploy/dd-mlsegmentation-benchmark>. Accessed on:2022.03.30.
 - 23、Duan, H., Wang, J., Chen, K., & Lin, D. (2022). PYSKL: Towards Good Practices for Skeleton Action Recognition. arXiv preprint arXiv:2205.09443.
 - 24、Duan, H., Zhao, Y., Chen, K., Lin, D., & Dai, B. (2022). Revisiting skeleton-based action recognition. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 2969-2978).
 - 25、Ferretti, A., Prati, C., Rocca, F. (2000). Nonlinear subsidence rate estimation using permanent scatterers in differential SAR interferometry, *IEEE Trans. On Geosci. and Remote Sensing*, 38 (5), 2202 – 2212.
 - 26、Foga, S., Scaramuzza, P. L., Guo, S., Zhu, Z., Dille Jr, R. D., Beckmann, T., & Laue, B. (2017). Cloud detection algorithm comparison and validation for operational Landsat data products. *Remote sensing of environment*, 194, 379-390.
 - 27、Foreman, M. G. (1977). *Manual for Tidal Heights Analysis and Prediction*, Pacific Marine Science Report 77-10, Institute of Ocean Science, Patricia Bay, Sidney, BC, Canada, 97.

- 28、Foreman, M. G., Cherniawsky, J. Y., & Ballantyne, V. A. (2009). Versatile harmonic tidal analysis: Improvements and applications. *Journal of Atmospheric and Oceanic technology*, 26(4), 806-817.
- 29、Foreman, M.G. (1978). Manual for tidal currents analysis and prediction. Pacific Marine Science Report 78-6, Institute of Ocean Sciences, Patricia Bay, Sidney, BC, 57.
- 30、Gibril, M. B. A., Bakar, S. A., Yao, K., Idrees, M. O., & Pradhan, B. (2017). Fusion of RADARSAT-2 and multispectral optical remote sensing data for LULC extraction in a tropical agricultural area. *Geocarto international*, 32(7), 735-748.
- 31、Goldberg, H. R., Wang, S., Christie, G. A., & Brown, M. Z. (2018). Urban 3d challenge: building footprint detection using orthorectified imagery and digital surface models from commercial satellites. In *Geospatial informatics, motion imagery, and network analytics viii* (Vol. 10645, p. 1064503). International Society for Optics and Photonics.
- 32、Goldberg, H., Brown, M., & Wang, S. (2017). A benchmark for building footprint classification using orthorectified rgb imagery and digital surface models from commercial satellites. In *2017 IEEE Applied Imagery Pattern Recognition Workshop (AIPR)* (pp. 1-7). IEEE.
- 33、Gómez-Chova, L., Tuia, D., Moser, G., & Camps-Valls, G. (2015). Multimodal classification of remote sensing images: A review and future directions. *Proceedings of the IEEE*, 103(9), 1560-1584.
- 34、Gordon, D., Farhadi, A., & Fox, D. (2018). Re3: Real-Time Recurrent Regression Networks for Visual Tracking of Generic Objects. *IEEE Robotics and Automation Letters*, 3(2), 788-795.
- 35、Guzzetti, F., Mondini, A. C., Cardinali, M., Fiorucci, F., Santangelo, M., & Chang, K. T. (2012). Landslide inventory maps: New tools for an old problem. *Earth-Science Reviews*, 112(1-2), 42-66.
- 36、Handwerger, A. L., Jones, S. Y., Huang, M. H., Amatya, P., Kerner, H. R., & Kirschbaum, D. B. (2020). Rapid landslide identification using synthetic aperture radar amplitude change detection on the Google Earth Engine. *Natural Hazards and Earth System Sciences Discussions*, 1-24.
- 37、He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).
- 38、He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- 39、Herrera Herrera, M. (2019). Landslide detection using random forest classifier. (Master's Thesis, Delft University of Technology). Retrieved from:

<https://repository.tudelft.nl/islandora/object/uuid:52fe6b3b-ec0b-4cad-b51d-7798830688a4?collection=education> .

- 40、Hooper, A., Zebker, H., Segall, P., Kampes (2004). B., A new method for measuring deformation on volcanoes and other natural terrains using InSAR persistent scatterers. *Geophys. Res. Letter*, 31, L23611, doi:10.1029/2004GL021737.
- 41、Jahan, F., Zhou, J., Awrangjeb, M., & Gao, Y. (2018). Fusion of hyperspectral and LiDAR data using discriminant correlation analysis for land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3905-3917.
- 42、Jang, J.H., Chang, T.H., Chen, W.B. (2018). Effect of inlet modelling on surface drainage in coupled urban flood simulation. *J. Hydrol.*, 562, 168-180.
- 43、Jang, J.H., Hsieh, C.T., Chang, T.H. (2019). The importance of gully flow modelling to urban flood simulation. *Urban Water Journal* 16(5), 377-388.
- 44、Karim, F., Majumdar, S., Darabi, H., & Chen, S. (2017). LSTM fully convolutional networks for time series classification. *IEEE access*, 6, 1662-1669.
- 45、Le Saux, B., Yokoya, N., Hänsch, R., & Prasad, S. (2018). 2018 IEEE GRSS data fusion contest: Multimodal land use classification [technical committees]. *IEEE geoscience and remote sensing magazine*, 6(1), 52-54.
- 46、Leffler, K. E., & Jay, D. A. (2009). Enhancing tidal harmonic analysis: Robust (hybrid L1/L2) solutions. *Continental Shelf Research*, 29(1), 78-88.
- 47、Liu, Z., Zhang, H., Chen, Z., Wang, Z., & Ouyang, W. (2020). Disentangling and unifying graph convolutions for skeleton-based action recognition. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 140-149).
- 48、Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3431-3440).
- 49、Long, Y., Xia, G. S., Li, S., Yang, W., Yang, M. Y., Zhu, X. X., ... & Li, D. (2021). On creating benchmark dataset for aerial image interpretation: Reviews, guidances, and million-aid. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 4205-4230.
- 50、Marcos, D., Volpi, M., Kellenberger, B., & Tuia, D. (2018). Land cover mapping at very high resolution with rotation equivariant CNNs: Towards small yet accurate models. *ISPRS journal of photogrammetry and remote sensing*, 145, 96-107.
- 51、Massonnet, D., Feigl K.L. (1998). Radar interferometry and its application to changes in the Earth's surface. *Rev. Geophys.*, 36 (4), pp. 441-500.
- 52、Ortner, M., Descombes, X., & Zerubia, J. (2007). Building outline extraction from digital elevation models using marked point processes. *International Journal of Computer Vision*, 72(2), 107-132.

- 53、Parmar, V., Bhatia, N., Negi, S., & Suri, M. (2020). Exploration of optimized semantic segmentation architectures for edge-deployment on drones. arXiv preprint arXiv:2007.02839.
- 54、Pawlowicz, R., Beardsley, B., & Lentz, S. (2002). Classical tidal harmonic analysis including error estimates in MATLAB using T_TIDE. *Computers & Geosciences*, 28(8), 929-937.
- 55、Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., & Carvalhais, N. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195-204.
- 56、Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.
- 57、Rottensteiner, F., Sohn, G., Gerke, M., & Wegner, J. D. (2013). ISPRS Test Project on Urban Classification and 3D Building Reconstruction.
- 58、Rottensteiner, F., Sohn, G., Gerke, M., & Wegner, J. D. (2014). ISPRS semantic labeling contest. ISPRS: Leopoldshöhe, Germany, 1, 4.
- 59、Rottensteiner, F., Sohn, G., Jung, J., Gerke, M., Baillard, C., Benitez, S., & Breitkopf, U. (2012). The ISPRS benchmark on urban object classification and 3D building reconstruction. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences I-3* (2012), Nr. 1, 1(1), 293-298.
- 60、Song, Y. F., Zhang, Z., Shan, C., & Wang, L. (2022). Constructing stronger and faster baselines for skeleton-based action recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- 61、Stone, H. S., Orchard, M. T., Chang, E. C., & Martucci, S. A. (2001). A fast direct Fourier-based algorithm for subpixel registration of images. *IEEE Transactions on geoscience and remote sensing*, 39(10), 2235-2243.
- 62、Sun, MSc. X (Faculty of Geo-Information Science and Earth Observation (ITC), University of Twente). (2021). Building outline extraction of Enschede, the Netherlands using aerial images and digital surface models. DANS. <https://doi.org/10.17026/dans-248-n3nd>.
- 63、Sun, Z., Ke, Q., Rahmani, H., Bennamoun, M., Wang, G., & Liu, J. (2022). Human action recognition from various data modalities: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- 64、Tai, Y. H., Chang, L. Y., & Tsai, F. (2018). Multi-Temporal Ground Deformation Monitoring for Mt. Agung, Indonesia Using Persistent Scatterer Interferometry. In: *EGU General Assembly Conference Abstracts*. 2018. p. 3830.
- 65、Teo, T. A., & Shih, T. Y. (2013). Lidar-based change detection and change-type determination in urban areas. *International Journal of Remote Sensing*, 34(3),

- 968-981.
- 66、Thielicke, W., & Stamhuis, E. (2014). PIVlab—towards user-friendly, affordable and accurate digital particle image velocimetry in MATLAB. *Journal of open research software*, 2(1)
- 67、Tran, D., Bourdev, L., Fergus, R., Torresani, L., & Paluri, M. (2015). Learning spatiotemporal features with 3d convolutional networks. In *Proceedings of the IEEE international conference on computer vision* (pp. 4489-4497).
- 68、Tsai, F., & Tai, Y. H. (2019). Fast Land Deformation and Damage Assessment After the 2018 Hualien Earthquake in Taiwan Using Multi-Source Remote Sensing Data. *AGUFM*, 2019, 2019: NH31F-0912.
- 69、Wang, Y., Zorzi, S., & Bittner, K. (2021). Machine-learned 3D building vectorization from satellite imagery. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 1072-1081).
- 70、Wojke, N., Bewley, A., & Paulus, D. (2017). Simple online and realtime tracking with a deep association metric. In *2017 IEEE international conference on image processing (ICIP)* (pp. 3645-3649). IEEE.
- 71、Xie, M., Esaki, T., & Zhou, G. (2004). GIS-based probabilistic mapping of landslide hazard using a three-dimensional deterministic model. *Natural Hazards*, 33(2), 265-282.
- 72、Xu, Y., Du, B., Zhang, L., Cerra, D., Pato, M., Carmona, E., ... & Le Saux, B. (2019). Advanced multi-sensor optical remote sensing for urban land use and land cover classification: Outcome of the 2018 IEEE GRSS data fusion contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(6), 1709-1724.
- 73、Yan, S., Xiong, Y., & Lin, D. (2018, April). Spatial temporal graph convolutional networks for skeleton-based action recognition. In *Thirty-second AAAI conference on artificial intelligence*.
- 74、Zheng, L., Shen, L., Tian, L., Wang, S., Wang, J., & Tian, Q. (2015). Scalable person re-identification: A benchmark. In *Proceedings of the IEEE international conference on computer vision* (pp. 1116-1124).
- 75、Zivkovic, Z. (2004). Improved adaptive Gaussian mixture model for background subtraction. In *Proceedings of the 17th International Conference on Pattern Recognition*, 2004. *ICPR 2004*. (Vol. 2, pp. 28-31). IEEE.

其他相關資料及附件

附件 A：各期成果審查意見與回覆

附件 B：基隆潮位站潮位調和分析主要分潮表

附件 C：期刊或研討會投稿證明

附件 D：工作會議紀錄

附件 A：各期成果審查意見與回覆-第 1 期成果審查意見與回覆

	意見	意見回應
1	有關「1.3 未來規劃與構想」表 1.3-1 工作項目「應用人工智慧發展衛星影像地表形變分析技術與應用」第 1 點細項工作，請補充說明 111 年啟動機器智慧學習參數最佳化之所使用之方法及預期成果；「應用人工智慧發展航遙測影像辨識技術與應用」第 4 點細項工作，111 年非評估使用無人機輔助道路普查測量作業，請對應 4.2.4 內容修正；「衛星與航遙測影像智慧分析、辨識與製圖防災整合應用」第 1 點細項工作，請配合本案今(111)年規格書補充辦理面積(100 平方公里變成 200 平方公里)。(P.5、7)	已補充 4.1.1 細項工作：啟動智慧參數學習的工作，快速的機器學習進行永久散射體自動辨別，結合人工智慧技術，找出最佳的雷達永久散射體來進行處理分析，縮短影像處理的時程，並減少失敗重試的機會。修正 4.2.4 與 4.3.1 內容。
2	有關 4.1.1 利用雷達衛星影像發展長期地表形變自動化智慧分析技術 1 節，請補充敘明機器學習所使用之方法及實際應用之預期成果。(P.23-24)。	本項工作使用目前在影像分割任務上精度及效能表現較佳的全卷積神經網路 U-Net 架構來進行永久散射體之辨識工作，該模型已廣泛被應用到醫學、衛星等方面的影像辨識，藉由此模型辨識後的成果影像，可大幅減少 PSInSAR 分析與尋找永久散射體所耗費的時間。
3	有關 4.1.4 擴充衛星影像智慧加值應用與後續推動可行性評估 1 節，請補充整合平臺簡介及加值應用推動可行性評估方式，提出分析項目及評估指標等。(P.29)	整合平臺建議可以採用 Open Data Cube 系統，Data Cube 在國際間已開始推動，建置即可分析資料並同時可提供服務之衛星影像資料倉儲模型。國內目前有中央大學太遙中心以及國家太空中心在 Data Cube 領域進行相關的研究應用與開發。 太遙中心建置之 Data Cube 系統配合接收站 SPOT 直接接收任務，支援 SPOT 影像匯入作業，現有 SPOT 影像資料將處理為大氣層頂反射率產品，並匯入系統中作為即可分析資料提供使用者可直接進行分析的影像，進行線上即時如 NDVI 或淹水判釋等加值應用之影像運算。

	意見	意見回應
4	有關 4.2.2 建立航遙測影像智慧辨識訓練資料集 1 節，請補充說明本年度係更新 110 年所蒐集之 10 個國際標竿訓練資料集內容，或是另外蒐集新的訓練資料集，若為新的訓練資料集請於工作計畫書補充說明資料集相關內容。(P. 33)。	110 年所蒐集之 10 個國際標竿訓練資料集僅有遙測影像，為滿足訓練資料集同時包含遙測影像及數值地表模型，本年度係另外蒐集 5 個新的國際標竿訓練資料集，包含 DroneDeploy、Duke University: Aerial Imagery Object Identification、2018 IEEE GRSS Data Fusion、ISPRS: Urban Modelling and Semantic Labelling 及 USSOCOM Urban 3D Challenge 標竿資料集。
5	有關 4.2.3 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效 1 節，請補充擬使用圖資來源及種類，另外會使用哪些國際及臺灣訓練資料集進行房屋辨識工作。(P. 34-36)。	擬使用圖資來源包含國外公開資料訓練料集及臺灣訓練資料集，圖資種類為航空影像。國內原始資料分別來自國土測繪中心及農航所，本團隊進行加值處理建立臺灣訓練資料集，以利房屋智慧辨識分析。 國際訓練資料集擬使用 Duke 大學建置之 Aerial Imagery Object Identification 資料集進行房屋辨識工作，初步觀察此資料集，房屋類別較為多元且有不同密度，故選用此資料集進行測試。 臺灣訓練資料集使用圖資來源與種類包含：(1)內政部國土測繪中心提供之 106 年及 108 年臺灣通用電子地圖；(2)農航所提供之臺灣通用電子地圖對應數位航空影像。本團隊使用農航所數位航空影像產製智慧判釋所需之正射影像及對應影像密匹配數值地表模型，再配合國土測繪中心臺灣通用電子地圖之房屋圖層建置臺灣訓練資料集。
6	有關 4.3.2 以兩年內高解析光學衛星影像進行 DSM 變異分析 1 節，本年度辦理範圍是否可連結前年度辦理之南部及中部區域，請於工作計畫書說明。(P. 41-42)	已調整本年度試辦區域範圍，由 3,600 平方公里增加至 5,000 平方公里。

	意見	意見回應
7	有關 4.4.1 模擬基於感測器與模型資料發展智慧建築等適地性應用 1 節，有關高精度都市淹水模擬及防救災導航應用，請補充說明今年度擬辦理之區域。(P. 53-54)	本項工作以發展模擬應用為主要工作，考量因受限場地而無法進行物聯網應用之困擾，因此以模擬方式於 Unity3D 環境中進行各種物聯網應用之施作。前 2 年分別為智能居家與火災為模擬應用，今年度則以淹水與救災為應用模擬主題，申請臺南善化區之水文資料，並在 Unity3D 環境中，建置與申請資料相似之環境，進行淹水模擬並探討各種物聯網應用之可行性。
8	有關 4.5.2 及 4.5.3 科教活動部分，請補充因應新冠肺炎疫情之備選方案及期程規劃。(P. 64-65)	4.5.2 於海科館舉辦之科教活動如因疫情關係，造成學生無法離校校外科活動。本團隊將採用赴校教學。選擇兩所學校，安排半日科教演講。 4.5.3 製作科學教育數位課程教材之科教活動如因疫情關係，將以網路視訊方式辦理科教活動。

	意見				意見回應
9	工作計畫書（初稿）部分內容修正如下，其餘內容請再詳校：				已修正文字內容。
頁碼	原內容	建議修正	備註		
12、47	語義空間資訊 語義分割	語意空間資訊 語意分割	文字修正		
28	粹區	萃取	文字修正		
48	物聯網、及領域應用模型	物聯網及領域應用模型			
53	將向 貴司申請水文資訊相關之 DEM	將向內政部申請水文資訊相關之 DEM			
58	比對影像挑選、及特徵匹配等步驟	比對影像挑選及特徵匹配等步驟			
67	技術人員包技士(佐)	技術人員包含技士(佐)			
多頁	平台	平臺	文字修正		
多頁	判識	判釋	部分為判釋、部分為判釋，請統一		

各期成果審查意見與回覆-第 2 期成果審查意見與回覆

	意見	意見回應
劉委員正倫		
1.	P.30 於 4.1.2 節精進機器學習於高解析光學影像地表形變分析技術部分，為何會想要在今年度加入前、後期雷達影像資料進行分析？而從 P.36 初步分析可知，加入雷達影像成果均較僅使用光學影像之成果為差，可能原因係雷達影像空間解析度過低。後續是否有方法可改善，使增加雷達影像後之成果優於僅使用光學影像之成果嗎？	本項工作初始構想為增加影像資料於訓練模型中，以輔助、分析地表形變區域。使用光學影像進行模型訓練，但是能蒐集到對應時間區段之雷達影像空間解析度較低，造成分析成果較差。若是能提升雷達影像的解析度，預計能提昇成果預測。
2.	P.40 所述內容提到使用武漢大學提供之衛星影像房屋資料集訓練神經網路模型 U-Net，是否適當？另敘及「從成果可明顯看出，Pleiades 衛星影像因空間解析度較高 測試例一分類房屋區域成果較為細緻。…若要以偵測之房屋區來重建房屋模型，本項工作提出之方法利用 Pleiades 衛星影像所萃取之房屋區域較為適當。」，衛星影像解析度較高萃取成果較好，此論述不是必然之結果嗎？	已修正敘述。若考慮資料取得成本與偵測成果差異，兩種不同解析度之衛星影像可適用於房屋與道路偵測，此分析於報告中已補充。
3.	P.52 表 4.2-2、比較人工量測與 PIV 萃取三維地表位移量，請補充說明人工量測點有多少點？	測試區中可清楚量測的人工構造物只有一個處，因此人工量測點僅有一點。
4.	P.61 表 4.2-5、國際標竿資料集基本資料與表內欄位名稱「公共基準資料集」不一致，請修正一致。	已修正。
5.	P.72 圖 4.2-20、TransUnet 模型在修正資料高差移位後的預測成果，其中(b)圖紅色框是代表什麼意思？請補充說明。	當正射影像有房屋高差移位時，房屋標籤相對於正射影像會有少量的偏移，造成標籤範圍涵蓋不完全的問題，圖(b)紅色框為房屋高差移位的範例展示，圖(b)是有房屋高差移位現象的正射影像。

	意見	意見回應
6.	<p>P.77 敘及「本項工作蒐集 36 幅無人機正射影像。…影像原始空間解析度為 2cm 空三定位精度小於 10cm，…」請補充說明此無人機正射影像從航拍規劃到完成正射影像之相關資訊，以利了解整個過程所需耗費之時間與成本。另請補充說明，後續使用空間解析度為 5cm、10cm 之正射影像，是如何得到的？</p>	<p>無人機正射影像作業程序簡要說如下：根據施測範圍，依空間解析度需求，規劃航高及 80% 重疊率之飛行任務，並沿測區起終點規劃布設地面控制點及檢核點，控制測量採 e-GNSS 測量。經由航測影像處理軟體的空三及正射化作業完成正射影像之產製。</p> <p>為評估不同解析度之影像對偵測能力的影響，使用 QGIS 的 Batch Processing 批次內插影像解析度，影像內插採用 Cubic Interpolation 方法。</p>
7.	<p>請補充說明為何 P.80 表 4.2-10、人孔偵測之成果(獨立驗證)內之人孔數量相較於 P.79 表 4.2-9、原始與增益後之人孔資料之數量少很多之原因？另於 2cm 空間解析度之預測成果中，所有人孔類別之漏授和誤授皆小於 12%，該成果品質是好的嗎？請補充說明。</p>	<p>獨立驗證區是利用原始的人孔數量做精度評估，增益 (Augmentation) 是為了增加深度學習訓練樣本的數量，增益後的人孔資料是作為人孔訓練資料使用。</p> <p>本項工作分析不同空間解析度對人孔的影響，在 2cm 空間解析度中，成功率與正確率皆大於 89%，前後分別表示「人孔是否被成功偵測」與「自動萃取人孔是否正確」。</p>
8.	<p>P.81 表 4.2-11、智慧辨識與人工數化資料的距離差異，此處建議人孔尺度之智慧辨識應採用優於 5cm 空間解析度之影像(人孔智慧辨識漏授率為 14.75%，自動化偵測與人工數化成果之均方根誤差已大於 9 公分)，該成果品質可提供後續應用嗎？請補充說明。</p>	<p>無人機影像與人工智慧技術之智慧整合可「輔助」人孔調查測量施測作業，因道路人口數量較多，若能先採自動化作業快篩出人孔，可提升人工判釋效率。</p> <p>試辦作業顯示，2cm 空間解析度下自動化辨識人孔，約有 89% 的可滿足精度規範，應可以輔助人孔調查測量作業，提升作業效能。</p>

	意見	意見回應
9.	<p>因自動化偵測與人工數化成果之距離差異，並非製圖規範之 20 公分絕對精度要求，建議應進行自動化偵測或人工數化成果與實際地測成果之比較分析，以利評估本項工作於實務上之真正可行性與精度。</p>	<p>本項工作於 111 年 8 月 30 日進行現地 e-GNSS 測量，共測得 100 點。將現地測量的孔蓋中心的三維坐標與不同 AI 模型和不同影像空間解析度的共六次自動化偵測結果的孔蓋中心進行比較，在均方根誤差中，平面誤差在 2cm 空間解析度中，誤差約為 6cm，並隨著空間解析度的下降增加誤差量，在 10cm 空間解析度時，均方根誤差約為 10cm；而高程誤差在不同空間解析度下約為 15cm。</p>
10.	<p>P.84 圖 4.3-1、全臺灣五年多時期形變監測試辦成果與 P.85 圖 4.3-2、全臺降軌 PSInSAR 衛星視角方向變形量三維拆解成果圖應是同一成果，只是分別用雷達衛星視角方向(LOS)變形量與結合 GNSS 觀測之垂直形變量分析，建議應修正圖名符合其實際內涵。另圖 4.3-2 之 color bar 仍是用「LOS Velocity」表示，請釐清後修正。</p>	<p>已修正圖文內容。</p>
11.	<p>P.88 敘及「由於立體像對產製數值地表模型其精度大約為 5 公尺左右，取其 2 倍 10 公尺作為地表形變之高程變化門檻值。」，相關門檻值對未來用衛星影像協助光達修測之規劃，請評估實務執行之可行性。</p>	<p>相關門檻值之設定，主要參考試辦區之測試成果，觀察本案使用之衛星影像及分析程序可得之崩塌規模。</p>
12.	<p>P.94 敘及「本年度(111)工作目標為發展物件式(Object-based)時序多光譜衛星影像崩塌變異分析，…。」惟 4.3.3 節內容和物件式(Object-based)似無關聯，請補充說明。</p>	<p>4.3.3.2 節新增物件分割程序說明及各演算法細節。本項工作整合數值地形模型及拼接無雲衛星影像進行影像分割，以影像分割產生物件(Object)單元，時序多光譜衛星影像之崩塌偵測採用物件為單元進行分析。</p>

	意見	意見回應
13.	P.104 敘及「TSF 算法僅從 44 個崩塌地中正確偵測到的 3 個，而 LID 算法成功判釋了 18 個崩塌變異地」，建議可列表說明 44 個崩塌地面積大小與是否被偵測成功情形，以利和表 4.3-3 對照。另真實場景中之崩塌面積平均值為 2,738 平方公尺，僅約為 3 個 Landsat-8 像元大小，可否改以對於大於 2,800 平方公尺(3 pixels)之崩塌區域，進行 TSF 和 LID 之偵測比較，請補充說明。	已更新內容，並透過大面積（大於 1 公頃）與全部面積崩塌地之漏授率及誤授率量化分類成果。
14.	4.2.3 節建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效(P.74)敘及「評估視覺展示以及精度分析成果，使用 RGB+DSM 影像都優於只使用 RGB 影像，因此後續會選用資料整合方式及完整的臺灣資料集」和 4.3.5 節以臺灣地區航遙測影像進行地物辨識與分類(P.111)敘及「因此，使用 DSM 與 DSM 改正正射影像進行房屋偵測的效果會優於僅使用臺灣通用電子地圖正射影像」，本年度執行至最後皆使用 DSM 改正正射影像進行房屋偵測，該 2 小節最後結果會有何不同？請補充說明。	4.2.3 節為建立房屋偵測技術，評估使用不同輸入資料及方法偵測房屋區域之能力，確立房屋偵測使用的深度學習術。 而 4.3.5 節是使用前後期 DSM 改正之正射影像進行房屋變遷應用試辦，利用 4.2.3 節建立的技術進行房屋變遷試辦作業。
曾委員義星		
1.	圖 1.2-1 與表 1.3-1 之相對關係為何？本計畫為第 3 年期，應著重於應用試辦，各試辦範疇應詳細說明，如：多大面積、多少時間之影像、目標成效、目前成果、實用性評估及未來推廣之可行性，以供機關參考；另若未來規畫辦理成果發表，該試辦內容及成果皆為重要資料。	由於工作項目較多，因此藉由圖 1.2-1 表示各工作項目之內容與關連，如技術評估、研究技術等，若其研究技術有進行試辦，則可了解其試辦工項。表 1.3-1 則為各個工作項目之現況與未來發展與建議。
2.	P.38、39 提到利用衛星影像進行 DSM 產製部分，前期使用 SPOT 6/7、後期使用 Pleiade，其準確性應補充數據比較及文字說明，非僅用圖片顯示。另應將成本納入考量，若未來擴大範圍辦理時，經濟效益如何？請補充說明。	已補充說明。

	意見	意見回應
3.	P.98 圖 4.3-13 之 NDVI TimeSeries 僅使用 2016 一年份數據，邊坡變異應將時間拉長作長期研究，請說明比較前後期 NDVI 值利用 AI 方式是否提高邊坡變異偵測正確性。	期末報告內容已更新，並以四年 (2015-2018) 為單位進行崩塌地時間序列偵測研究。
4.	P.42 提到建立 Data Cube 系統，未來專案資料是否可開放使用？未來是否會納入試辦規劃中，需要多長時間規劃、包含多少影像及規格如何？	本項工作目前僅評估加值整合應用之可行性，因此嘗試比較目前主流的系統於此情境之適用性。章節中提到的資料為自太遙中心 DataCube 系統提取的範例。如須納入試辦規劃可能會需要至少一年的時間來建置系統與匯入歷史影像，另外加值應用的開發也會需要更多時間。影像的規格並無任何限制，但是演算法的可用性會取決於影像是否提供需要或足夠的波段，以內建的 NDWI 應用為例，普通的 4 波段光學影像便無法提供偵測水體所需要的波段資料，而是要如 Landsat 這類更多波段的影像資料才能使用。
5.	P.150 提到雷達式潮位站常因漂浮性垃圾產生觀測異常，潮位站是否應有濾網可過濾？基隆新設潮位站以音波式為主，壓力式為輔，為何雷達式不用？為何成果不好？請補充說明。	潮位站靜水井與港口連通處有設置簡易的濾網避免垃圾進入，惟颱風時仍難以避免，因此，雷達式水位計在這個場址並不適用。基隆新設潮位站站除蒐集分析潮位數據外，音波式、壓力式及雷達式共站提供科學教育應用。
王委員聖鐸		

	意見	意見回應
1.	P.36 僅使用光學衛星影像來辨識崩塌區比加入雷達影像後辨識成果更佳，第 2 期成果報告書認為是解析度問題，崩塌區之大小是否超過 15 公尺？單純使用雷達影像之效果如何？請補充說明。	因使用的標籤是源自於光學影像所標記，雖崩塌區範圍部分會超出 15m，但不會有數百公尺以上的大型崩塌範圍，若僅使用雷達影像，有許多小範圍的崩塌地僅被數個雷達影像像素所覆蓋，無法有效預測。
2.	P.39 圖 4.1-12、三維點雲成果及圖 4.1-13、數值地表模型重建成果請補充圖例，右上角 SPOT6/7 異軌影像產製 DSM 中出現很多黑色區塊，這些黑色區塊是匹配失敗嗎？請補充說明。	黑色區域是匹配失敗無匹配點之區域，已補充說明。
3.	P.89 圖 4.3-7、數值地表模型地表形變之圖例，請修正為正值在上、負值在下，且盡量以同色相表達同一方向。另外圖 4.2-4、4.2-5、4.2-9 請一併修正。(P.49、50、53)	已修正。
4.	P.40 機器學習模式分類之房屋區係以 DSM 來進行分類，是否有以三維點雲分類之測試案例？	房屋區偵測之訓練資料本案使用國際 AI 訓練資料集進行訓練。由於使用國際 AI 訓練集無影像對應之 DSM 資訊，故在本案中無利用 DSM 納入 AI 學習。未來若有適用之資料，可嘗試整合影像與 DSM 資訊進行 AI 分類測試。
5.	P.58 表 4.2-3 有關地物分類「健康的草」與「不健康的草」、「停車場 1」與「停車場 2」之差異為何？請補充說明。	Jahan et al., (2018)採用高光譜影像分辨健康的草皮(即「健康的草」)與枯萎的草皮(即「不健康的草」)，該研究同時整合光達資料，故可細分停車場為平面與高架停車場(「停車場 1」)及有車子佔用的停車格(「停車場 2」)。

	意見	意見回應
6.	P.120 善化區之下水道系統之建置比例為何？圖資完整度如何？一維之明渠管流模組是否符合水流實況？是否有可能透過攝影機來偵測路面積水或淹水，以提供更即時且密切之監測？	善化區下水道系統資料於開放資料平台獲取，為 109 年度資料，詮釋資料註記為每年檢測之資料，完整度應為良好。所使用的淹水模型考量二維漫地流及一維明渠管流，包含側溝及下水道之尺寸、高度、坡度等資訊。本團隊初步評估以攝影機偵測積水在天候狀況不佳時較難提供精確的淹水狀況判斷，但未來或可進行細部探討。
7.	從 4.2 節開始之小節標題比較像內文而非標題，請修正。	各工項（含各小節）標題皆為工作案規格書內容，為了符合規格書之工項，且避免後續驗收作業困難，因此本團隊暫不更動各工項標題文字。
邱委員式鴻		
1.	P.18、19、22 依照表 3.3-1 各期程成果繳交項目，以及表 3.2-1 預定工作表（請將此表中第一欄工作項目欄位補上「%」符號）相對應，工作團隊於短時間內完成諸多工作項目，期中報告內容也符合進度要求，值得肯定。	已補充「%」符號於欄位中。
2.	本專案各工作項中若使用到深度學習方法，建議將訓練資料中之訓練和驗證資料筆數，以及測試資料筆數說明清楚；而所有訓練和測試資料之影像大小亦建議說明清楚；成果中建議說明訓練後之驗證精度，若有測試資料，建議亦說明預測精度。如圖 4.1-4 說明 U-Net 模型(P.27)，惟未說明輸入影像大小為 512x512 或 256x256 像元。	
2-(1)	4.1.1 節利用雷達衛星影像發展長期地表形變自動化智慧分析技術工作項中，於 P.29 中雖說明 35 張差分干涉影像中平均選取 12 張干涉圖以做為代表訓練資料進行機器學習，但應不是整張影像而是切割成如 512x512 像元訓練，是否會有訓練資料不足之問題？	是由整組 35 差分干涉影像中依時間平均選取其中 12 張後再切成 512*512*12 的大小進行訓練，且使用數組不同地點與時間段的差分干涉影像。
2-(2)	4.1.2 節精進機器學習於高解析光學影像地表形變分析技術工作項中，建議於 P.32 補充說明。	已補充內容於 4.1.2 節。

	意見	意見回應
2-(3)	4.1.3 節發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取工作項，建議於 P.40 補充說明。	已補充說明。
2-(4)	4.2.3 節建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效工作項中，建議於 P.74 補充說明。	已將精度評估公式補充在表格中。
2-(5)	4.3.5 節以臺灣地區航遙測影像進行地物辨識與分類，辦理區域範圍至少為五千分之一圖幅 10 幅（含）以上，辦理區域需與內政部討論選定且得洽內政部協助提供必要之既有測繪圖資工作項中，P.113 將來採用卷積神經網路(CNN)時，建議說明訓練資料中之訓練和驗證資料筆數及測試資料筆數；而所有訓練和測試資料之影像大小亦建議說明清楚。	22 幅 Taiwan eMap 作為訓練與驗證，另 1 幅 Taiwan eMap 作為獨立檢核。影像裁切大小為 224x224 pixel，水平與垂直重疊率皆為 112 pixels 一共有 154683 張訓練影像與 38671 張驗證影像。
3.	本專案各工作項中若使用到深度學習方法，建議仍需將使用之模型以圖示方式，如圖 4.1-4、U-Net 模型示意圖方式呈現，如 P.30 提到 ConvLSTM U-Net、P.58 提到 CNN、P.77 提到之 Mask-RCNN 等。	已補充模型示意圖於章節中。
4.	有關遷移式學習之運用方式及利用不同資料執行深度學習時所涵蓋地面解析解析度不同之問題：	
4-(1)	4.1.3 節發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取工作項中，機器學習演算法為利用武漢大學提供之衛星影像房屋資料集訓練神經網路模型 U-Net，是否利用遷移式學習訓練增加泛用性？另衛星影像地面解析度不同如何解決？	房屋區偵測有利用遷移式學習訓練。房屋區偵測訓練集有涵蓋不同之影像解析度，故可同時適用不同影像解析度之分類；道路區偵測則各自使用相對應影像解析度之資料進行訓練與分類，以解決不同解析度之問題。

	意見	意見回應
4-(2)	4.2.2 節建立航遙測影像智慧辨識訓練資料集，須對不同類型之資料集進行整理並分析其適用性，探討結合影像與高程模型於地表分類之效益工作項中，對於五個國際公開標竿資料集，比較與分析各標竿資料集之內容與特性，於 P.67 中說明，本項工作選擇 AIOI 資料集作為後續建立航遙測自動化地物智慧辨識與分類深度學習模型之訓練資料，但訓練完程之模型是否適用於臺灣，跟使用資料、空間解析度、場景類別、建物分布型態有關，是否可使用遷移式學習解決此問題？過程中如何克服不同地面解析度？將來測試時，應多加注意。	AIOI 為國外資料集，在遷移式學習的過程中是扮演提供良好初始值的角色，再利用此良好初始值及臺灣進行訓練。實驗中以 AIOI 資料集進行臺灣正射影判釋的成效不佳，但經過遷移式學習後，可大幅提升臺灣正射影像的判釋效果，驗證遷移式學習的可行性，此外，遷移式學習的較直接訓練有更佳的運算效能。
5.	4.2.1 節建立航遙測影像地表三維形變智慧分析技術工作項中，利用 PIV 方法偵測水平及高程移位，證實 DSM 偵測山坡地表二為形變之可行性，惟 DSM 經匹配後可能出現誤匹配點，對於此類錯誤，有何機制解決？請補充說明。	為減少影像匹配錯誤的影響，研究中計算視窗內 DSM 的平均值代表該視窗的高程值，而非直接內插該點位的高程值。
6.	4.2.3 節建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效工作項中，已使用 DSM 正射糾正，為何還會有建物外牆誤判？(P.72)另 DSM 之空間解析度為何？是否經編修去除錯誤點？	本年度使用 DSM 改正正射影像，而前一年度（110 年）使用有房屋高差移位的正射影像，此建物外牆誤判是使用前一年度（110 年）進行判釋，目的是比對有無使用 DSM 改正對成果的影響，實驗分析成果顯示，無 DSM 改正會產生較大的房屋偵測錯誤。 密匹配點雲內插為 25cm 空間解析度的 DSM，使正射影像和 DSM 有一致的空間解析度進行整合。 DSM 採用自動化雜訊過濾，未進行人工編修。

	意見	意見回應
7.	P.79 本年度工作以 Mask-RCNN 深度學習模型進行人孔物件偵測時，為何需使用遷移式學習？如何使用？請補充說明。	遷移式學習的優點是可以提升深度學習參數收斂的速度，在訓練資料集龐大時，具有減少運算量的優勢。本項工作有使用 COCO 資料集產生的預訓練模型做為人孔偵測的初始模型。
8.	利用本工作案是否能建立臺灣地區建物變遷偵測之多元資料集供學術單位研究之用？請補充說明。	本案申請的正射影像及臺灣通用電子地圖房屋區域都不是公開資料，故只能取得計畫授權使用。
趙委員鍵哲		
1.	雷達差分干涉，永久散射體係關鍵特徵，是否應對永久散射體作等級區分。	目前的永久散射體演算法沒有針對等級做區分。不過可以也確實應該區分等級，原因是目前主流的 PSInSAR 其實並採用非絕對穩定，而僅是相對穩定的像素進行計算，此類像素在實際應用上稱作 Distributed Scatterer(DS)，如果能對永久散射體進行一定程度上的分級，後續還能思考如何利用這樣的分級來改善資料處理中的錯誤，例如相位解纏的錯誤等。
2.	第 2 期成果報告書提到透過點雲、正射影像萃取，可建立三維建物模型，目前欲建立何種等級之三維建物模型？請補充說明。	預計未來可建置滿足 OGC CityGML LOD-1 規範的三維模型，已補充說明。
3.	計畫中提到雷達影像、光學影像、雷達影像加光學影像 3 種方式作形變分析，惟於同一任務下（如：同一地區、同一時間），3 種方式所作之形變分析各自特性或差異性為何？優劣點是否有互補性？請補充說明。	因雷達影像解析度低，且標籤是針對光學影像所產生，僅使用前後期低解析度的前後期雷達影像無法有效預測成果。原先試想因雷達具有穿透雲層與植被的特性，可輔助找出光學影像未找出的崩塌地。

	意見	意見回應
4.	有關 4.2.4 節人孔蓋偵測部分，人孔蓋有不同形態，亦有不同尺寸，是否將該變因列入偵測成功率？請補充說明。	人孔蓋依據下水道工程設施標準規定，目前在國內的人孔蓋以圓形或矩形為主，本項工作依據道路或人行道，將人孔蓋分類為三種。受影像空間解析度限制，無人機影像中未能呈現人孔蓋紋理，故無法細分人孔蓋的型態。
5.	本專案人工智能實驗室已成立，目前是否已鎖定未來產學合作之對象，請補充說明。	本計畫有產學合作之公司，並且針對計畫之相關技術進行探討、開發等後續合作。
6.	本專案各開發工具目前是否具有完全自主性？請補充說明。	本案核心技術為自主開發，具有相當高程度的自主性。
7.	本案各工項之架構連結缺乏，應補充各工項關聯性分析、3 年完成工項成果及後續建議。	將於期末報告中補充未來發展及建議內容。
陳專門委員杰宗		
1.	本專案主要著重於技術建立及應用試辦，是否有可供地政司或測繪中心實地應用之技術，俾與業務面結合，請團隊補充說明應用之可行性及建議。	已補充工項發展評估於表 3.2-2 中。
2.	今年為本案 3 年期計畫之最後一年，請團隊於期末報告補充本案未來發展及建議。	將於期末報告中補充未來發展及建議內容。
內政部地政司		
1.	P.12 於第 2 章背景分析提到「臺灣地處歐亞大陸、太平洋及菲律賓三大板塊聚合交界處，地質條件複雜。」應修正為「臺灣地處歐亞大陸及菲律賓海兩板塊聚合交界處，地質條件複雜。」	已修正文字內容。
2.	P.53 圖 4.2-9、各年度計畫建置之地表位移場，其中圖(e)圖名應修正為「第三年度計畫：Image+DSM-PIV 三維位移場」。	已修正文字內容。
3.	P.84 圖 4.3-1、全臺灣五年多時期形變監測試辦成果，應明確寫出是哪個時間之成果，建議修正為「全臺灣 5 年(2017-2021)多時期形變監測試辦成果」。	已修正文字內容。

意見		意見回應			
4.	第 2 期成果報告書部分內容建議修正如下，其餘內容文字及字型排版請再詳校：			已修正文字內容。	
	頁碼	原內容	建議修正		備註
	多頁	U-net	U-Net		應一致
	28	程果	成果		
	38	110度	110年度		
	60	加入DSM資料對於...	加入DSM資料，對於...		
	81	智慧辨識因採用優於5cm	智慧辨識應採用優於5cm		
	86	去年試辦區黃色區域為...	去年試辦區，黃色區域為...		
	86	程序作業化以利後續...	程序作業化，以利後續...		
	104	多數崩塌相對與影像...	多數崩塌相對於影像...		
150	將感測器提供0.185公尺	將感測器提高0.185公尺			

各期成果審查意見與回覆-第 3 期成果審查意見與回覆

	意見	意見回應
邱委員式鴻		
1.	本案為 3 年期計畫之第 3 年，本年執行約 8 個月，如期完成諸多工作項目，且規劃未來可發展之方向，期末報告書內容完備，團隊之付出先予以肯定。部分成果已具實用價值，如 4.3.5 節工作項，未來如何落實，可請相關單位思考。以下 6 點建議供廠商考慮修正，3 點問題請廠商說明。建議如下	
1-1	將計畫書中、英文摘要移至圖表文目錄之前。	已修正內容位置。
1-2	本案諸多工作項目使用深度學習或機器學習，而其訓練資料會影響後續之成果，如何確保訓練資料正確無誤，部分已於文中說明；而未說明之處建議於文中適度說明，如 4.1.1 節利用雷達衛星影像發展長期地表形變自動化智慧分析技術未說明，請於報告書中補充。	目前訓練資料使用的 PS 點位主要來自 PSInSAR 程式之演算法進行判定，該程式設有判定 PS 點的相位穩定性統計門檻值，目前作為訓練資料使用的門檻設定適合大多數的地表環境使用，在 PS 篩選完畢後，人工可簡易判斷 PS 選點的正確性；觀察 PS 點多落於建築、房舍等強反射物上即可確保訓練資料大多正確。
1-3	4.1.2 節精進機器學習於高解析光學影像地表形變分析技術中，P.43-44 中訓練資料分別有光學影像導出之 7 種特徵、雷達影像 sigma0 波段及地形之坡度資訊作為訓練資料，請於報告書中說明為何使用？如地形之坡度於 P.44 說明其與地表形變有關故加入，其他特徵之說明建議於報告中補充。	判斷地表有無崩塌，地形之坡度資訊可以有助於分辨裸露地與崩塌地的作用，前後期之特徵影像可以有效判斷地形是否改變。
1-4	4.1.3 節(1)資料及研究區域小節中，所指匹配影像中之 1 張影像進行融合與正射改正，係指圖 4.1-30 即為正射影像嗎？圖 4.1-29 數值地表模型(DSM)之地面解析度為何？(P.55) 針對此工作之未來規劃是否可能加入 DSM 資料？(P.248)	圖 4.1-30 是正射影像，兩組 DSM 地面解析度分別為 1.5 與 5m，已補充說明。未來預計整合 DSM 資料建置 OGC CityGML LOD-1 規範的三維模型。
1-5	於第五章結論之未來規劃，建議將 4.1.4 節工作項目深入高中或大學課程教育中，如微課程。(P.248)	已補充內容於未來規劃。

	意見	意見回應
1-6	4.3.2 節中圖 4.3-21 流程圖中各作業階段所使用之軟體，請於報告書中補充說明；其他工作項目中，使用相關之軟體亦建議於報告書中補充說明。(P.142)	已補充使用軟體於步驟中。
2.	4.1.1 節 P.31 說明以 StaMPS 產出之 PS 點與雷達差分干涉圖做為訓練資料，然圖 4.1-9 顯示 StaMPS 選出大量之 PS 點位於海上(P.34)，是否已確認訓練資料正確無誤？請於報告書中說明。	StaMPS 選取 PS 點之方法為透過統計多時期影像各像元的相位穩定度來區分是否為永久散射體，當影像數量減少時統計樣本也減少，會使得 PS 點選取的正確性相對下降，一般而言 PSInSAR 需要至少 20 張影像才能得到合理的 PS 點位置，因此本工項於產生訓練資料時採用 35 張影像條件將更為嚴格。圖 4.1-9 為僅採用 12 張影像來判斷 PS 點位置與變形量，可以預期由於影像數量太少，StaMPS 計算出來的 PS 點位置與變形都相對不可靠，因此更能凸顯本工作項目開發方法的優勢：透過以訓練好的模型，PSInSAR 不再需要數量巨大的資料集便能做出合理的 PS 判斷，並計算出相似的變形量成果。
3.	4.1.2 節精進機器學習於高解析光學影像地表形變分析技術中，(1)工作僅於 P.45 簡略說明使用訓練資料，惟如何產生訓練資料及確保訓練資料無誤並未說明，另是否因未確保訓練資料之正確性，才導致預測成果未達理想（見表 4.1-3 及表 4.1-4）？此外，光學影像及雷達影像如何正確套疊或對位？其成果是否影響後續機器學習成果？(2)TerraSAR-X 試驗 (P.50)，無量化分析，而表 4.1-5 中指出使用 2 種特徵，是哪 2 種，以上請團隊於報告書中補充說明。	訓練資料標籤是比較前後期光學影像，透過人工圈選產生。在套疊上是將雷達影像投影至光學影像坐標上，也因此會產生雷達影像常見的前波縮短、倒置、陰影等幾何扭曲問題，使成果無法達到預期。 TerraSAR-X 使用 HH 與 HV 偏極，因僅使用單一時期的紋理影像，預測成果無法達到預期，僅進行定性評估成果。

	意見	意見回應
4.	4.2-3 節中，為何使用 DSM 改正正射影像後，於圖 4.2-20(b)會有建物外牆出現？(P.97) 另遷移式學習過程中使用多少筆臺灣地區之訓練資料？實際而言約需幾筆資料足夠遷移式學習？請於報告書中補充說明。(P.102)	圖 4.2-20(b)是僅使用 DTM 進行改正之正射影像，不是 DSM 改正正射影像，此圖測試 TranUnet 偵測有高差移位屋頂面的能力。 為使用相同條件比較直接訓練及遷移式學習，遷移式學習仍使用 22 幅進行訓練(80%)與驗證(20%)，另 1 幅進行獨立檢核。
曾委員義星		
1.	本案係以研發概念出發，再評估將成果應用，應給予肯定，該類研究應持續發展。	感謝委員提供建議與肯定。
2.	研究測試工作，光學影像加入雷達影像進行形變分析，惟成果不佳，雷達影像可排除雲的問題，建議可持續整合兩者影像，兩者多時期影像先行個別分析，再進行整合分析地表形變。雷達影像進行干涉分析，作為相關資訊進行整合訊息，是否有助於提升山區變形偵測，請於報告書中補充說明。	因訓練用的崩塌地標籤是透過高解析的光學影像所圈選，大多是小面積的崩塌，若只使用前後期雷達影像進行訓練，無法有效辨別地表形變。 雷達干涉成果可能可以協助判斷，由於目前應用的區域多為植被茂密的山區，植被會導致干涉成果不佳，若採用干涉成果或許可以考慮同時加入干涉相關性來作為判斷干涉分析成果可靠性的參考依據。
3.	請團隊補充說明本案各工作項目之橫向連結，理論方法可否互相借鏡，成果能否相互介接使用，另物件辨識亦可敘明航遙測影像及無人機影像之搭配性。	於機器學習部分，運用之理論皆可相互參考，對於提升訓練有所幫助則可加入使用；若是目的相同，最後產製之成果才較有可能相互介接使用。未來會將此建議納入研究考量。
劉委員正倫		

	意見	意見回應
1.	<p>本案許多章節內容皆有說明精度評估結果，如：表 4.1-1、表 4.1-7、表 4.1-9、表 4.2-6、表 4.2-9、表 4.3-5 等，惟未能於相關表格處說明各指標之定義、計算公式與評估說明（例如：數值越大越好或越小越好），以致於較難閱讀（於 P.190 才出現詳細說明，惟仍有欠缺，如：Accuracy）。建議在全文開始時，就能完整說明精度評估各指標之定義、計算公式與評估說明。此外，精度評估指標部分英文、部分中文，建議統一寫法。</p>	<p>已統整精度評估指標寫法，相關精度評估指標列於表 4.1-1 與公式於表 4.1-2。</p>
2.	<p>P.22-24 表 3.2-2 列出本案各工項發展評估內容，值得肯定，惟部分內容與本文各章節內容及第五章結論內容，似有未盡一致之處，建議全面檢視後修正。另 16 個工項自評結果只有 5 個「已成熟」，其他皆為「發展中」；其中很多皆是使用之雷達或光學影像解析度較差，未達到預期成果。未來是否需使用高解析度雷達或光學影像進一步研究，值得審慎評估。</p>	<p>已補充、統整內容，未來將評估是否使用高解析度雷達分析。</p>
3.	<p>P.41-42 敘及「透過 AI 替換 StaMPS 的 PS 點選取方式...，大幅降低求得時間，並提高作業效率」，惟未說明到 P22 所敘及「...，目前僅能投入最多 12 張影像進行評估，對於更大量的資料計算仍須尋求改良方案。」，請補充說明，以利了解目前方式之限制。</p>	<p>目前機器學習階段受到資料量與記憶體容量之限制，投入訓練的影像最多為 12 張，目前的訓練模型與 PS 預測成果已經相當不錯，我們不清楚如果能使用更多影像來做機器學習是否能在進一步提高精度，但礙於硬體限制目前無法執行相關的試驗。</p>
4.	<p>P.65 表 4.1-9 道路萃取成果精度測試例一、二成果沒有多少差異，可能原因為何？（對照前項房屋區域萃取是用試例一之高解析度影像），請於報告書中補充說明。</p>	<p>已補充說明。</p>
5.	<p>4.1.4 節雖然只是可行性評估，惟 3 年下來僅簡單敘述說明成果，且列舉之應用範例無任何內容說明，建議應強化加值應用及整合平臺之評估內容。(P.66-68)</p>	<p>已修正內容。</p>

	意見	意見回應
6.	P.69 敘及「未來成果應用可輔助林務局、水土保持局等相關政府單位應用...」，且應用面多位於山林區、坡地區，惟此技術如何推廣至所述政府機關？未來有機會運用在相關機關實務工作上嗎？若未能推廣至相關政府機關使用，未來還需要再進行以無人機光達點雲發展地表三維形變技術嗎？請團隊於報告書中補充說明。	已修改為「未來成果應用可輔助坡地地表位移偵測，利用多時期航拍影像與 DSM，有助於快速執行大面積山林地區監測與管理工作」。無人機影像攝影測量已普及化至許多監測相關工作，若地表位移量大於攝影測量定位精度，本項技術有機會推度應用在相關作業中。無人機光達為無人機測量的重要發展方向，裸露地使用無人機影像攝影測量即足夠，無人機光達在密林區較有優勢。
7.	109 至 111 年這 3 年來所收集整理與分析之國際標竿資料集，要如何提供國內相關機關及學界使用？請團隊於報告書中補充說明。	這些國際標竿資料集均為開放資料，可經由網路免費申請下載使用，本項工作重要貢獻為系統性收集航遙測國際標竿資料集，橫向比較各國際標竿資料集的適用性，以利國內相關機關及學界選定適用的國際標竿資料集，有利後續發展航遙測自動化房屋智慧辨識與分類技術。
8.	P.113 文內敘及產生人孔資料筆數，與表 4.2-13 數字不一致，請檢視後修正。	已修正。
9.	P.114 敘及「...，也將 2、5、10 cm 的空間解析度整合為一個模型，並預測不同空間解析度...」，請補充說明其意義及處理過程。另評估結果建議採用優於 5cm 空間解析度影像，惟報告中未能看出製作 2cm 或 5cm 空間解析度之影像成本相差多少？另 P.117 提出本方法可以輔助人孔調查測量作業，惟與實際地面測量之效益評估未詳加分析，請補充說明。	因無人機攝影測量時，同一任務之影像空間解析度會受到不同航高影響，故設計具有多重影像空間解析度的整合模型。 影響製作 2cm 或 5cm 空間解析度影像的成本為無人機資料獲取，2cm 空間解析度影像需設計較低航高或使用較長焦距的相機，影像資料量較多，作業時間也較長。 無人機人孔偵測對重劃區域地面測量有一定程度的助益，無法完全取代現地測量，但可以快速獲取大範圍的人孔資料，輔以人工確認檢視，以提升測量實施作業的效率。

	意見	意見回應
10.	4.3.1 節(1)利用 C 波段多時期雷達影像製作全臺多時期變形監測已有具體結果，請說明未來內政部可以如何運用此技術發布全臺每年監測成果，至於(2)X 波段與(3)L 波段試辦，未能說明試辦區域選擇之依據及試辦結果未來可以應用之方向，請補充說明。(P.119)	(1)建議內政部可以每年定期蒐集並處理一定時間段(如一年或兩年)的影像資料，其成果可以藉由 GIS 平台作為工具發佈。 (2)試辦區域之選擇主要為符合內政部對工作項目要求之雷達影像解析度，再考慮同時存在已知或正在發生的災害、潛在災變之地區 (3)三年計畫結果顯示 L 波段對於地震災害等事件型的目的觀測能力相對較佳、且不需要太高的觀測頻率便能有效計算地表變形，而 C、X 波段相對需要較高的觀測頻率來維持資料品質，因此適合長時間持續監測的案例。
11.	4.3.2 節已完成利用衛星影像協助光達修測之方法與作業程序，敘及「由於立體像對產製數值地表模型其精度大約為 5 公尺左右，取其 2 倍 10 公尺作為地表形變之高程變化門檻值，及大面積崩塌超過 10 公頃或土方量達 10 萬立方公尺或崩塌深度在 10 公尺以上。」此精度對未來用衛星影像協助光達修測規劃，實務上可用性應不高，因光達產製之數值地形模型成果為 1 公尺；另對於所述大面積崩塌等情形，行政院農業委員會水土保持局在事件發生後皆會進行崩塌區域之監測分析，所需之上開資訊，該局已皆可提供，請再檢視說明。(P.128)	本項工作目的在於利用衛星立體像對，大範圍快速篩選地表形變區域，提供優先進行光達修測之目標區。另本項工作偵測之地表變形除大面積崩塌外，也包含大規模森林砍伐、人為之挖方填方及原有崩塌區域再次崩塌等情形，可與行政院農業委員會水土保持局進行之崩塌區域監測分析結果相互整合，提供更完整之地表形變資訊協助光達修測規劃。
12.	P.197 敘及「若排除 16m ² 的變遷，...」，請說明 16m ² 是如何得到？另若變遷區大於 16m ² 之變遷，整體精度可達 75.82%，成果應還不算好？此頁文字內容與表 4.3-17 數字不一致，請檢視修正。	16m ² 是指排除 4m x 4m 的物件，現有變遷成果整體精度約 75%，未來將在精進變遷分析技術，在變遷分析中導入深度學習技術。已修正數據的一致性。
13.	P.203 敘及「...從 OpenStreetMap 萃取路網結構，...」，為何團隊不直接使用內政部國土測繪中心 e-MAP 路網，請團隊釐清後補充說明。	已於內文加註未來亦可使用 e-MAP 路網。

	意見	意見回應
14.	P.219 敘及「...，而由團隊成員演示的異常行為也大多皆有偵測到，...」，惟報告內容無說明有哪些演示及偵測結果，請於報告書中補充說明。	已於內文補充說明。
15.	P.244 請團隊修正第 1 篇論文表示方式，與其餘各篇一致，另第 3 篇論文題目，似乎和本案研究內容無關聯，請檢視確認。	已修正內容。
王委員聖鐸		
1.	本案工作項目繁雜，且多數工項具有前瞻研發性質，執行團隊成果豐碩，為未來實務應用提供非常有價值之參考，應給予執行團隊高度肯定！	感謝委員給予建議與肯定。
2.	P.22-24 表 3.2-2 有整理工作項目之自我評估表非常好，請團隊進一步說明「發展中」是指尚須發展哪些項目？	已補充說明於自我評估表中。
3.	P.61 請團隊詳細說明房屋區分類成果「正規化」與「約化」之目的與流程。	已補充說明。
4.	P.65 路寬分級僅列出 ≤ 3 、4、5、 ≥ 6 公尺，惟此分級似乎僅為巷道，是否可參考一般道路分級或將 ≥ 6 公尺之等級再細分為 6-10、11-20、 ≥ 20 公尺，另道路偵測是針對像元評估或是針對 polyline 來評估？請補充說明。	已補充說明。
5.	P.78 圖 4.2-9(f)三維位移場之箭頭是指平面或三維方向？請團隊於報告書中補充說明。	圖 4.2-9(f)箭頭方向指平面位移，底圖顏色為高程方向位移。
6.	P.83 表 4.2-3 中「合成草」是指人工草皮嗎？請團隊釐清後補充說明。	原文為 Grass Synthetic，已修正為人工草皮。
7.	P.97 使用 DSM 改正正射影像進行 TransUnet 模型偵測房屋，似乎可有效改正高差位移影響，是否套疊過 1/1000 地形圖比對其是否真的符合建物框？	本研究使用臺灣通用電子地圖的建物圖層進行套疊分析。
8.	P.111 圖 4.2-33 中符號設計僅「電信」，建議註記說明。	已修改為電信人手孔圖例製作符號。

	意見	意見回應
9.	P.113 辨識成功率與空間解析度明顯正相關，空間解析度超過 10 公分後辨識成功率不到一半，5 公分大約在 70-80% 之間，是否代表未來 UAV 空間解析度應該要小於 5 公分才適合人孔辨識作業？人孔若出現彩色或不同紋理，是否會影響辨識成果？請補充說明。	經實驗分析，無人機影像應優於 5cm 才能得到優於 80% 的成功率，故建議未來無人機影像應優於 5cm。目前試辦區無彩色人孔樣本，故無法辨識彩色人孔。
10.	P.133 提及「為了解地表高程變異程度以使用於未來空載光達測製工作之規劃，以 1/5000 圖幅為單元進行評估，評估之指標包括累計地表形變區域面積及累積增減高度。」同一 1/5000 圖幅內累積增減高度是否會相消？請團隊於報告書中補充說明。	高程增加及減少為分別統計，可避免累積增減高度相消造成之誤判情形。
11.	P.204-206 以 Unity 引擎將感測器建置到模擬環境，請問目前蒐集之資料是否有呈現出淹水模式 COS-Flow 之不足，而可進一步修正模式？	目前並未發現 COS-Flow 模式之不足，僅未來或可針對其運算效率進行討論，評估其近即時運算之可能性。
12.	P.216 於桃園高鐵捷運站 A18 站以物件追蹤及人類行為辨識建立車站智慧防救災通報系統，建議先定義「異常事件」才能評估偵測效益，請團隊於報告書中補充說明。	已於內文補充說明。
王司長成機		
1.	表 3.2-2 工作項目自我評估表中各工作項目如何導入至目前相關單位之工作專案，請團隊補充說明。	已補充說明於自我評估表中。
內政部地政司		
1.	4.1.3 節發展多元衛星影像智慧處理與立體重建技術，請補充房屋輪廓正規化與約化處理成果之量化指標，以利了解是否能夠應用本案技術於房屋輪廓萃取。	已補充說明。

	意見	意見回應																								
2.	P.109 引用「內政部『一千分之一數值航測地形圖測製作業規定』（內政部國土測繪中心，2011）」，應修正為作者為「內政部」；對應於考文獻第 1 項，作者應併同修正為「內政部」。	已修正文字內容。																								
3.	P.111 內文第 2 段引用出處為「國土測繪中心，2020」，惟參考文獻未有此出處，請再檢視後修正。	已補充於文獻中。（國土測繪中心，2020，109 年度多旋翼機航拍與影像處理及設備維護作業採購案，工作總報告。）																								
4.	P135 圖 4.3-15 累積增減高度統計之水平軸—圖幅序號未顯示值域，請於報告書中補充。	已更新增加值域之圖片。																								
5.	P190-191 式 4.3-1 至式 4.3-6 及圖 4.3-47 混淆矩陣為本案各項成果之量化指標，請於前面章節先行敘明，以利讀者了解相關統計指標之涵義。	已補充相關說明於表 4.1-1 與公式於表 4.1-2 中。																								
6.	P202-207 有關 4.4.1 節進行都市地區淹水模擬應用，請於報告書中補充說明水利 DEM 對於本案淹水模式之助益。	水利 DEM 提供溢堤線、閘門、海堤等邊界條件，可節省模式建模時人工判斷的耗時。已於報告書中補充說明。																								
7.	第 3 期成果報告書部分內容建議修正如下，其餘內容文字及字型排版請再詳校： <table border="1" data-bbox="284 1196 842 1630"> <thead> <tr> <th>頁碼</th> <th>原內容</th> <th>建議修正</th> <th>備註</th> </tr> </thead> <tbody> <tr> <td>30</td> <td>最後會得到...</td> <td>最後會得到...</td> <td>刪除空格</td> </tr> <tr> <td>43</td> <td>共生矩阵</td> <td>共生矩陣</td> <td></td> </tr> <tr> <td>229</td> <td>2015年4月10</td> <td>2015年4月10日</td> <td>漏字</td> </tr> <tr> <td>229</td> <td>剷除</td> <td>剔除</td> <td></td> </tr> <tr> <td>多頁</td> <td>GPS</td> <td>GNSS</td> <td></td> </tr> </tbody> </table>	頁碼	原內容	建議修正	備註	30	最後會得到...	最後會得到...	刪除空格	43	共生矩阵	共生矩陣		229	2015年4月10	2015年4月10日	漏字	229	剷除	剔除		多頁	GPS	GNSS		已修正文字內容。
頁碼	原內容	建議修正	備註																							
30	最後會得到...	最後會得到...	刪除空格																							
43	共生矩阵	共生矩陣																								
229	2015年4月10	2015年4月10日	漏字																							
229	剷除	剔除																								
多頁	GPS	GNSS																								

附件 B：基隆潮位站潮位調和分析主要分潮表

基隆潮位站音波式水位計調和分析主要分潮表

UTide Cnstit	Frequency (cph)	Amplitude (mm)	Amp_err (mm)	Phase (deg)	Pha_err (deg)	SNR
M2	0.081	203.0	0.84	259.6	0.24	224962
K1	0.042	190.7	0.51	226.4	0.16	539480
O1	0.039	154.9	0.51	194.0	0.18	348995
SA	0.000	151.6	4.21	200.8	1.68	4974
S2	0.083	67.4	0.91	257.7	0.63	21170
P1	0.042	64.5	0.48	220.8	0.40	68470
N2	0.079	55.3	0.82	234.1	0.78	17441
SSA	0.000	31.9	4.72	274.3	7.20	175
Q1	0.037	31.6	0.44	174.5	0.97	20035
MU2	0.078	24.4	0.89	126.0	1.78	2898
K2	0.084	19.7	0.82	250.2	2.24	2245
NO1	0.040	11.8	0.52	206.4	2.45	1972
NU2	0.079	10.9	0.77	264.6	3.97	768
M4	0.161	10.8	0.26	261.9	1.47	6435
J1	0.043	10.4	0.48	246.4	2.34	1853
L2	0.082	9.6	0.82	359.7	12.07	526
2N2	0.077	9.3	0.78	195.3	4.71	554
MS4	0.164	8.0	0.25	287.0	1.49	3876
H1	0.080	7.8	0.89	256.2	5.85	294
S1	0.042	6.7	0.45	34.9	3.94	862
M3	0.121	6.5	0.25	168.6	2.44	2508
EPS2	0.076	6.2	0.66	87.7	8.08	339
LDA2	0.082	6.2	0.88	12.3	7.00	194
RHO1	0.037	6.2	0.44	179.4	4.94	759
H2	0.081	5.3	0.69	260.3	8.12	227
2Q1	0.036	4.9	0.49	166.9	5.89	378
PI1	0.041	4.7	0.45	245.0	5.68	415
OO1	0.045	4.7	0.48	269.3	5.59	357
T2	0.083	4.4	0.73	211.7	10.85	140
TAU1	0.039	4.2	0.53	136.0	6.38	239
SIG1	0.036	4.2	0.49	146.1	7.34	281
MN4	0.160	4.1	0.26	246.2	3.41	969

UTide Cnstit	Frequency (cph)	Amplitude (mm)	Amp_err (mm)	Phase (deg)	Pha_err (deg)	SNR
MSN2	0.085	3.9	0.83	252.3	10.42	83
PHI1	0.042	3.9	0.50	258.2	6.84	228
PSI1	0.042	3.8	0.46	276.1	7.41	267
CHI1	0.040	3.0	0.48	207.1	10.87	152
M6	0.242	2.8	0.12	222.6	3.00	2275
MK4	0.164	2.7	0.22	272.5	4.94	604
SK3	0.125	2.5	0.28	344.0	5.75	304
GAM2	0.080	2.5	0.82	335.9	15.82	35
2MS6	0.244	2.5	0.14	290.5	3.63	1243
MKS2	0.081	2.5	0.73	206.0	17.63	43
ETA2	0.085	2.4	0.79	255.2	19.05	34
MK3	0.122	2.2	0.29	263.8	6.61	233
R2	0.083	2.1	0.75	131.6	21.56	30
SO1	0.045	2.1	0.44	295.6	14.22	82
S4	0.167	1.9	0.20	321.5	7.08	375
MO3	0.119	1.9	0.26	310.8	9.83	199
2MN6	0.240	1.8	0.13	189.2	4.70	650
ALP1	0.034	1.5	0.47	133.6	19.24	40
THE1	0.043	1.4	0.47	260.2	18.15	36
2MK6	0.245	1.2	0.13	251.6	6.91	368
BET1	0.040	1.2	0.44	184.6	21.16	28
SN4	0.162	1.1	0.23	244.8	12.41	81
SK4	0.167	1.0	0.27	297.6	15.28	49
SO3	0.122	0.9	0.26	276.8	17.47	49
2SK5	0.208	0.5	0.14	214.8	15.68	55
MSK6	0.247	0.4	0.15	355.1	29.89	30
M8	0.322	0.4	0.05	209.2	7.57	227
2SM6	0.247	0.4	0.15	344.6	22.05	24
2MK5	0.203	0.4	0.14	126.0	21.16	28

基隆潮位站壓力式水位計調和分析主要分潮表

UTide Cnstit	Frequency (cph)	Amplitude (mm)	Amp_err (mm)	Phase (deg)	Pha_err (deg)	SNR
M2	0.081	205.5	0.55	257.7	0.13	542385
K1	0.042	189.8	0.31	225.7	0.11	1429074
O1	0.039	155.1	0.28	192.6	0.13	1179265
SA	0.000	146.4	4.72	203.1	1.82	3692
S2	0.083	68.5	0.55	257.0	0.49	60379
P1	0.042	62.3	0.31	222.0	0.34	159488
N2	0.079	55.7	0.57	233.2	0.55	37202
Q1	0.037	31.8	0.34	174.0	0.59	33798
SSA	0.000	31.2	4.73	280.8	8.59	167
MU2	0.078	24.9	0.63	125.0	1.23	5977
K2	0.084	19.5	0.58	247.7	1.35	4411
NO1	0.040	11.7	0.28	206.2	1.81	6588
NU2	0.079	11.2	0.53	264.5	2.79	1686
M4	0.161	11.0	0.19	258.2	1.15	12421
J1	0.043	10.4	0.34	246.8	1.73	3507
2N2	0.077	9.6	0.53	198.5	3.22	1271
L2	0.082	9.4	0.70	358.8	5.19	695
MS4	0.164	8.3	0.21	282.0	1.41	5976
M3	0.121	6.6	0.16	165.7	1.42	6806
LDA2	0.082	6.2	0.60	5.1	5.12	407
EPS2	0.076	6.1	0.62	87.3	5.33	376
RHO1	0.037	6.0	0.32	178.3	2.99	1362
H1	0.080	5.4	0.61	217.1	6.24	309
S1	0.042	5.1	0.33	253.6	3.37	909
OO1	0.045	5.1	0.30	272.3	4.25	1077
MKS2	0.081	4.6	0.54	174.9	7.33	287
2Q1	0.036	4.6	0.38	163.0	4.45	568
PI1	0.041	4.4	0.30	224.3	4.46	820
MN4	0.160	4.1	0.23	242.0	2.77	1208
MSN2	0.085	3.7	0.50	249.3	8.30	217
SIG1	0.036	3.7	0.29	153.2	5.19	627
T2	0.083	3.6	0.59	231.4	8.41	138
TAU1	0.039	3.5	0.35	149.5	5.49	385
PSI1	0.042	3.3	0.39	303.4	6.63	273

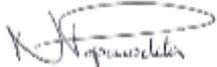
UTide Cnstit	Frequency (cph)	Amplitude (mm)	Amp_err (mm)	Phase (deg)	Pha_err (deg)	SNR
M6	0.242	3.0	0.12	218.0	2.44	2486
PHI1	0.042	2.9	0.36	224.3	7.54	254
CHI1	0.040	2.8	0.32	203.1	7.06	290
MK4	0.164	2.6	0.18	265.5	4.01	810
2MS6	0.244	2.5	0.11	283.8	3.18	1827
ETA2	0.085	2.3	0.56	261.9	13.11	64
SO1	0.045	2.0	0.32	294.1	11.27	140
MK3	0.122	1.8	0.14	250.6	5.85	648
2MN6	0.240	1.8	0.14	181.5	3.99	651
H2	0.081	1.7	0.54	237.3	18.24	37
MO3	0.119	1.5	0.17	318.7	5.44	311
S4	0.167	1.4	0.21	296.9	7.74	186
R2	0.083	1.4	0.49	182.5	25.93	31
BET1	0.040	1.3	0.35	201.6	13.10	58
ALP1	0.034	1.3	0.34	153.4	14.32	55
SK4	0.167	1.2	0.21	301.9	9.50	134
THE1	0.043	1.1	0.37	244.8	17.30	36
SK3	0.125	1.0	0.15	296.8	9.03	180
2MK6	0.245	1.0	0.12	238.1	7.55	260
UPS1	0.046	1.0	0.31	278.9	18.24	41
SN4	0.162	0.8	0.19	239.0	12.95	75
2MK5	0.203	0.7	0.10	101.1	6.64	190
SO3	0.122	0.7	0.17	269.7	13.13	64
M8	0.322	0.5	0.04	198.5	5.25	545
2SM6	0.247	0.4	0.12	340.9	21.88	41
2SK5	0.208	0.2	0.08	146.5	25.37	24
3MK7	0.283	0.1	0.06	332.0	22.73	22

基隆潮位站雷達式水位計調和分析主要分潮表

UTide Cnstit	Frequency (cph)	Amplitude (mm)	Amp_err (mm)	Phase (deg)	Pha_err (deg)	SNR
M2	0.081	206.6	0.55	258.0	0.14	536530
K1	0.042	191.1	0.36	226.1	0.11	1087073
O1	0.039	156.1	0.32	193.6	0.12	919619
SA	0.000	151.9	4.86	200.4	1.55	3758
S2	0.083	68.9	0.50	257.0	0.45	74406
P1	0.042	62.7	0.37	222.4	0.33	112867
N2	0.079	56.0	0.55	233.3	0.60	39707
Q1	0.037	32.3	0.34	174.9	0.69	34960
MU2	0.078	25.3	0.58	125.9	1.25	7266
SSA	0.000	24.9	4.62	283.2	9.17	111
K2	0.084	19.2	0.60	249.1	1.86	3859
NO1	0.040	12.0	0.31	205.8	1.67	5694
NU2	0.079	11.5	0.58	265.0	2.61	1512
M4	0.161	11.1	0.23	258.6	1.27	8652
J1	0.043	10.8	0.33	245.9	1.55	4152
L2	0.082	9.9	0.64	359.1	5.47	934
2N2	0.077	9.3	0.56	193.1	3.43	1081
MS4	0.164	8.5	0.22	282.3	1.40	5724
LDA2	0.082	6.9	0.59	7.7	4.29	530
M3	0.121	6.7	0.16	167.2	1.29	6422
EPS2	0.076	6.7	0.59	90.5	4.95	495
RHO1	0.037	6.1	0.31	179.5	3.14	1492
H1	0.080	5.5	0.42	216.3	6.51	645
OO1	0.045	5.1	0.30	275.6	3.77	1119
S1	0.042	4.9	0.35	256.8	3.92	726
2Q1	0.036	4.8	0.35	166.3	4.00	733
MKS2	0.081	4.8	0.64	176.0	5.46	219
PI1	0.041	4.8	0.35	224.6	3.31	714
T2	0.083	4.3	0.47	238.5	7.58	327
MN4	0.160	4.2	0.20	244.8	2.97	1660
SIG1	0.036	4.1	0.26	147.1	4.66	990
TAU1	0.039	4.0	0.33	151.7	4.43	575
MSN2	0.085	3.9	0.57	248.9	8.69	182
PSI1	0.042	3.7	0.37	301.1	5.32	384

UTide Cnstit	Frequency (cph)	Amplitude (mm)	Amp_err (mm)	Phase (deg)	Pha_err (deg)	SNR
CHI1	0.040	2.9	0.37	207.8	7.25	245
M6	0.242	2.8	0.13	218.3	2.54	1774
PHI1	0.042	2.8	0.35	226.1	7.10	247
MK4	0.164	2.5	0.20	267.9	4.79	626
ETA2	0.085	2.5	0.60	252.8	14.96	64
MK3	0.122	2.4	0.18	260.5	4.18	700
2MS6	0.244	2.4	0.12	287.9	2.79	1449
SO1	0.045	2.1	0.33	287.6	9.47	154
H2	0.081	2.0	0.61	252.9	15.94	43
2MN6	0.240	1.7	0.13	182.7	4.12	689
MO3	0.119	1.7	0.17	306.8	4.76	389
BET1	0.040	1.6	0.34	205.8	13.71	79
S4	0.167	1.5	0.21	301.1	8.13	200
ALP1	0.034	1.4	0.35	129.8	12.46	62
SO3	0.122	1.3	0.16	270.1	6.69	247
SK4	0.167	1.3	0.25	298.0	9.18	99
SK3	0.125	1.3	0.16	300.0	7.00	236
THE1	0.043	1.1	0.33	217.9	17.24	46
SN4	0.162	1.1	0.22	233.7	11.57	101
2MK6	0.245	1.0	0.10	242.3	6.00	403
UPS1	0.046	0.8	0.29	277.3	22.69	32
2MK5	0.203	0.5	0.09	95.2	10.11	114
M8	0.322	0.5	0.05	193.5	5.40	377
2SM6	0.247	0.4	0.12	351.3	19.29	36

附件 C：期刊或研討會投稿證明

1	投稿 2022 ISPRS，題目：LANDSLIDE INVENTORY MAPPING FROM LANDSAT-8 NDVI TIME SERIES USING ADAPTIVE LANDSLIDE INTERVAL DETECTION
<div data-bbox="1161 510 1295 622"></div> <div data-bbox="300 689 667 846"><p>Prof. Tee-Ann Teo National Yang Ming Chiao Tung University Department of Civil Engineering No. 1001, University Road Hsinchu 30010 China Taipei</p></div> <div data-bbox="1056 645 1295 801"><p>ISPRS2020 c/o ENSG 6-8 avenue Blaise Pascal Cité Descartes 77420 Champs-sur-Marne France</p></div> <div data-bbox="1056 824 1295 846"><p>SIRET : 838 550 762 00010</p></div> <div data-bbox="1056 869 1295 891"><p>Nice, France, 31/May/2022</p></div> <div data-bbox="300 922 539 945"><p>To Whom It May Concern</p></div> <div data-bbox="300 981 1248 1025"><p>This is to confirm that Prof. Tee-Ann Teo is welcome to participate in XXIV ISPRS Congress 2022, to be held in Nice, France, 6 - 11 June 2022.</p></div> <div data-bbox="300 1034 1248 1093"><p>Please note that registration fees, travel, living and accommodation expenses will not be supported by the conference organisers.</p></div> <div data-bbox="300 1115 1216 1258"><p>Prof. Tee-Ann Teo is author/co-author of the following accepted contribution(s): LANDSLIDE INVENTORY MAPPING FROM LANDSAT-8 NDVI TIME SERIES USING ADAPTIVE LANDSLIDE INTERVAL DETECTION Author(s): Wen, Tsung-Han; Teo, Tee-Ann Presenting Author: Teo, Tee-Ann Submission Type / Conference Track: TCIII-Remote Sensing</p></div> <div data-bbox="300 1272 689 1294"><p>We look forward to seeing Prof. Tee-Ann Teo.</p></div> <div data-bbox="300 1303 459 1326"><p>With kind regards,</p></div> <div data-bbox="322 1348 539 1415"></div> <div data-bbox="300 1429 577 1550"><p>Prof. Nicolas Paparoditis Director, XXIV ISPRS Congress Director, ENSG Director, IGN-France E-mail: isprs-cd@isprs.org</p></div>	

2	投稿 International Journal of Applied Earth Observation and Geoinformation，題目為 Comparison between image- and surface-derived displacement fields for landslide monitoring using an unmanned aerial vehicle
<p>T.A.TEO</p> <hr/> <p>寄件者: em.jag.0.7d9e2e.5fb7cfc4@editorialmanager.com 代理 International Journal of Applied Earth Observation and Geoinformation <em@editorialmanager.com> 寄件日期: 2022年8月27日星期六 下午 9:44 收件者: Tee-Ann Teo 主旨: Confirming submission to International Journal of Applied Earth Observation and Geoinformation</p> <p>*This is an automated message.*</p> <p>Comparison between image- and surface-derived displacement fields for landslide monitoring using an unmanned aerial vehicle</p> <p>Dear Prof. Teo,</p> <p>We have received the above referenced manuscript you submitted to International Journal of Applied Earth Observation and Geoinformation.</p> <p>To track the status of your manuscript, please log in as an author at https://www.editorialmanager.com/jag/, and navigate to the "Submissions Being Processed" folder.</p> <p>Thank you for submitting your work to this journal.</p> <p>Kind regards, International Journal of Applied Earth Observation and Geoinformation</p> <p>More information and support</p> <p>You will find information relevant for you as an author on Elsevier' s Author Hub: https://www.elsevier.com/authors</p> <p>FAQ: How can I reset a forgotten password? https://service.elsevier.com/app/answers/detail/a_id/28452/supporthub/publishing/kw/editorial+manager/</p> <p>For further assistance, please visit our customer service site: https://service.elsevier.com/app/home/supporthub/publishing/. Here you can search for solutions on a range of topics, find answers to frequently asked questions, and learn more about Editorial Manager via interactive tutorials. You can also talk 24/7 to our customer support team by phone and 24/7 by live chat and email.</p> <p>This journal uses the Elsevier Article Transfer Service. This means that if an editor feels your manuscript is more suitable for an alternative journal, then you might be asked to consider transferring the manuscript to such a journal. The recommendation might be provided by a Journal Editor, a dedicated Scientific Managing Editor, a tool assisted recommendation, or a combination. For more details see the journal guide for authors.</p> <p style="text-align: center;">1</p>	

3

投稿 Journal of the Chinese Institute of Engineers，題目為 Effectiveness of the red-edge band of RapidEye in land cover classification

T.A.TEO

寄件者: Journal of the Chinese Institute of Engineers <onbehalfof@manuscriptcentral.com>
寄件日期: 2022年9月18日星期日 上午 9:59
收件者: tateo@nycu.edu.tw
主旨: Journal of the Chinese Institute of Engineers - Manuscript ID TCIE-2022-0076.R3 has been submitted online

17-Sep-2022

Dear Professor Teo:

Your manuscript entitled "Effectiveness of the Red-Edge Band of RapidEye in Land Cover Classification" has been successfully submitted online and is presently being given full consideration for publication in Journal of the Chinese Institute of Engineers.

Your manuscript ID is TCIE-2022-0076.R3.

Please mention the above manuscript ID in all future correspondence or when calling the office for questions. If there are any changes in your street address or e-mail address, please log in to ScholarOne Manuscripts at <https://mc.manuscriptcentral.com/tcie> and edit your user information as appropriate.

You can also view the status of your manuscript at any time by checking your Author Centre after logging in to <https://mc.manuscriptcentral.com/tcie>.

Thank you for submitting your manuscript to Journal of the Chinese Institute of Engineers.

Sincerely,
Journal of the Chinese Institute of Engineers Editorial Office

4 投稿航測及遙測學刊，題目為以高解析衛星影像輔以深度學習建置三維房屋模型



Tsai, Fuan <ftsai@g.ncu.edu.tw>

航測及遙測學刊投稿_稿件111S1902著作權轉讓同意書簽圖

航測及遙測學刊編輯處 <jprssubmit@gmail.com>

Tue, Sep 20, 2022 at 3:47 PM

To: 蔡富安老師 <ftsai@csrsr.ncu.edu.tw>

Cc: 總編輯mdyang <mdyang@dragon.nchu.edu.tw>

蔡富安教授 您好：

本處已收到您投寄之「以高解析衛星影像輔以深度學習建置三維房屋模型」稿件，並編號此文件為：111S1902

註：參與111年碩士論文獎之作品

此篇文章已經過編輯委員會初步審視，現將邀請委員進行文章評審，在此之前需麻煩您簽署著作授權同意書，以維護雙方之權益。

著作授權同意書之檔案如附件，簽署完成後請將紙本寄至下方通訊處，掃描之電子檔請寄至 jprssubmit@gmail.com 信箱

寄件地址：11681 台北市文山區羅斯福路五段113號3樓

收件人：中華民國航空測量及遙感探測學會 吳岱評小姐

聯絡電話：02-86633469

此致，順頌
道 祺

航測及遙測學刊編輯處 敬啟
編輯處秘書 鄭心潔

 著作授權同意書(吳岱一).docx
22K

附件 D：工作會議紀錄

**111 年度三維國土形變及空間智能分析技術發展工作案
第一次工作會議紀錄**

壹、時間：111 年 03 月 07 日 15:20

貳、地點：遠端視訊會議

參、出席人員：

內政部地政司

吳俊毅、鄒芳諭

國立中央大學太空及遙測研究中心

蔡富安、黃智遠、劉建良、
戴于恒、劉育青

國立陽明交通大學土木工程學系

張智安

肆、會議內容：

一、成果繳交與日期提醒

- 工作畫書(4/1)與期中(7/8)、期末報告(11/25)繳交期限提醒

二、工項說明與預期成果說明

- 說明各工項內容變化、預定之工作內容與預期成果

三、討論工項試辦內容

(1) 雷達衛星影像地表形變分析之試辦

- X-波段選定以臺北港為試辦區域（2021~2022 影像資料）
- L-波段選定以高雄美濃地震為試辦區域（2016 影像資料）

(2) 以兩年內高解析光學衛星影像試辦數值地表模型變異分析

- 選定之試辦區域介於去(2021)年度計畫中部與南部試辦區兩個地點之間，以山區為優先且範圍大於 3,600 平方公里，詳細區域則於工作計畫書與四月份工作會議報告

(3) 航遙測影像分析與辨識之結果

- 試辦區域選定中部山區，影像來源取自林務局提供之崩塌相關影像等開放資料

(4) 物聯網-以實際場域進行適地性服務應用

- 會後將與內政部建築研究所進行試辦區域與試辦內容討論，以確定後續場域與物聯網應用是否能配合
- 試辦區域與應用將於建研所討論後，並取得內政部同意後才進行試辦

(5) 科教活動

- 於期末報告繳交之成果，在數位課程教材的資料繳交至少提供講師教材之簡報轉影像撥放光碟

四、其他事項

- 於期中報告前，預先規劃 112 年可進行之研究與應用
- 整理與構思今年計畫，並提供相關技術於其他單位實際使用

伍、散會：下午 16 時。

簽到簿

The screenshot displays a Google Meet interface during a video conference. The main window shows three participants in a grid view. On the right, a 'Messages in Call' (通話中的訊息) sidebar is open, displaying a sign-in log (簽到簿) with the following entries:

- 允許所有人傳送訊息 (Allow everyone to send messages) - [checked]
- Alec Huang 下午 3:53 中央大學 黃智遠 簽到
- 張智安 下午 3:53 陽明交大 張智安 簽到
- 內政部 下午 3:54 內政部地政司 吳俊毅 簽到 內政部地政司 鄒芳瑜 簽到
- 你 下午 3:55 中央大學 蔡嘉安 簽到 中央大學 劉建良 簽到 中央大學 戴于偉 簽到 中央大學 劉育青 簽到

At the bottom of the sidebar, there is a text input field labeled '傳送訊息給所有人' (Send message to everyone) and a send button.

111 年度三維國土形變及空間智能分析技術發展工作案

第二次工作會議紀錄

壹、時間：111 年 4 月 27 日上午 11 時

貳、地點：遠端視訊會議

參、出席人員：

內政部地政司

吳俊毅、鄒芳諭

國立中央大學太空

蔡富安、黃智遠、戴于恒、劉育青

國立陽明交通大學

張智安

肆、會議內容：

一、工項進度說明

1. 應用人工智慧發展衛星影像地表形變分析技術與應用

(1) 精進機器學習於高解析光學影像地表形變分析技術

- 使用雷達影像替代高解析光學影像對地表進行形變分析。
- 將前後期雷達影像經由深度學習模型 U-Net 進行影像分割，再加入隨機森林(Random Forest)演算法進行模型訓練。

(2) 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取

- 測試區域：新竹。
- 延續 110 年度計畫成果，以立體對匹配點雲、DSM 與影像光譜資訊萃取特徵區域。
- Pleiades 衛星影像 3 張，SPOT-6/7 衛星影像 17 張。

2. 應用人工智慧發展航遙測影像辨識技術與應用

(1) 建立航遙測影像地表三維形變智慧分析技術

- 使用質點影像量測法（地表形變技術），比較人工量測與 PIV 自動化偵測成果。

- 以 PIV 技術匹配前後期 DSM，分析高程位移量。
 - 應用 PIV 技術於影像與 DSM 偵測坡地地表位移場。
- (2) 建立航遙測影像智慧辨識訓練資料集
- 結合航遙測影像與高程模型於地表分類之效益。
 - 國際標竿資料集比較。
- (3) 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效
- 比較修正高差移位後的影像辨識成果差異。
- (4) 精進航遙測影像結合測量實施工作之智慧整合應用
- 將航遙測影像導入測量實施工作：以偵測人孔蓋為例。
 - 影像區域為臺中市水湳經貿園區，面積 84 公頃。
 - 使用 QGIS 的 Batch Processing 批次處理影像解析度。
3. 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦
- (1) 雷達衛星影像地表形變分析之試辦
- X-波段選定以臺北港為試辦區域（2021~2022 年影像資料），預計期末前可蒐集 20 張影像。
 - L-波段選定以高雄美濃地震為試辦區域（2015/11/26 與 2016/02/18 影像資料），進行差分干涉來計算 2016 年美濃地震的地表形變量。
- (2) 以兩年內高解析光學衛星影像試辦數值地表模型變異分析
- 連結 110 年度中部及南部試辦區，面積約 5,000 平方公里（詳見簡報 P.37）。
 - 現有數值地表模型產製及分析比對程序整理。
- (3) 航遙測影像分析與辨識之結果
- Landsat-8 衛星影像以資料集方式匯整於 GEE 平臺。
 - 崩塌參考資料：林務局年度衛星判釋全島崩塌地圖。
 - 增加時間序列區間偵測演算法與精度評估。

(4) 以臺灣地區航遙測影像進行地物辨識與分類試辦

- 建立房屋智慧判釋訓練及檢核資料集。
- 以 DSM 改正之正射影像降低房屋高差移位影響。

4. 評估智慧物聯網之防災整合應用技術

(1) 模擬基於感測器與模型資料，發展智慧建築等適地性應用

- 針對都市淹水之防救災導航進行模擬應用。
- 申請臺南善化區 HydroDEM。
- 建立 Unity 模擬環境，語意網連結及淹水區域導航指引。

(2) 發展具跨影像區域分析及物件追蹤之智慧防救災整合技術

- 改進追蹤器及外觀特徵匹配程序。
- 加入 YOLO 物件辨識分類。

(3) 以實際場域進行適地性服務應用

- 桃園捷運公司：考慮建立人員移動追蹤、異常行為判釋、以及隨身物品遺漏等應用（初步獲得同意）。
- 臺北捷運公司：北捷廁所之廁間使用狀態、建立手機 APP 提供「最速廁所指引應用」等（仍在聯繫溝通中）。

5. 數據分析與科教活動

(1) 持續分析基隆潮位站數據

- 設置於基隆市長潭里海洋科技博物館園區範圍內。
- 完成 2021/11/01 至 2022/02/28 潮位數據蒐集。

(2) 海科館科教活動

- 暫定 9 月底、10 月初辦理，8 月底學校開學後洽詢。

二、其他事項：無。

伍、散會：下午 12 時。

簽到簿

The screenshot shows a Google Meet interface with a sign-in log. The main window displays a grid of participants: 張智安, Alec Huang, 吳俊毅, 內政部地政司, Fuan Tsai, and 你. A chat window on the right lists the sign-in log with timestamps.

允許所有人傳送訊息

只有這場通話的參與者可以查看訊息，且訊息會在通話結束後刪除。

Fuan Tsai 上午11:31
蔡富安 簽到

張智安 上午11:31
張智安簽到

吳俊毅 上午11:32
吳俊毅 簽到

內政部地政司 上午11:32
鄒芳諭 簽到

你 上午11:32
戴子恒 簽到
劉育青 簽到

Alec Huang 上午11:54
黃智遠 簽到

傳送訊息給所有人

111 年度三維國土形變及空間智能分析技術發展工作案

第三次工作會議紀錄

壹、 時間：111 年 05 月 19 日 11:00

貳、 地點：遠端視訊會議

參、 出席人員：

內政部地政司

吳俊毅、鄒芳諭

國立中央大學太空及遙測研究中心

蔡富安、黃智遠、劉建良、
戴于恒、劉育青

國立陽明交通大學土木工程學系

張智安

● 會議內容：

一、 工項進度說明

(1) 應用人工智慧發展衛星影像地表形變分析技術與應用

1. 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取
 - 使用 Pleiades 衛星影像 3 張，SPOT-6/7 衛星影像 17 張，進行特徵分析、三維點雲匹配與建置數值地表模型
 - 後續工作預計為輪廓處理、三維點雲分群與機器學習分析影像資訊

(2) 應用人工智慧發展航遙測影像辨識技術與應用

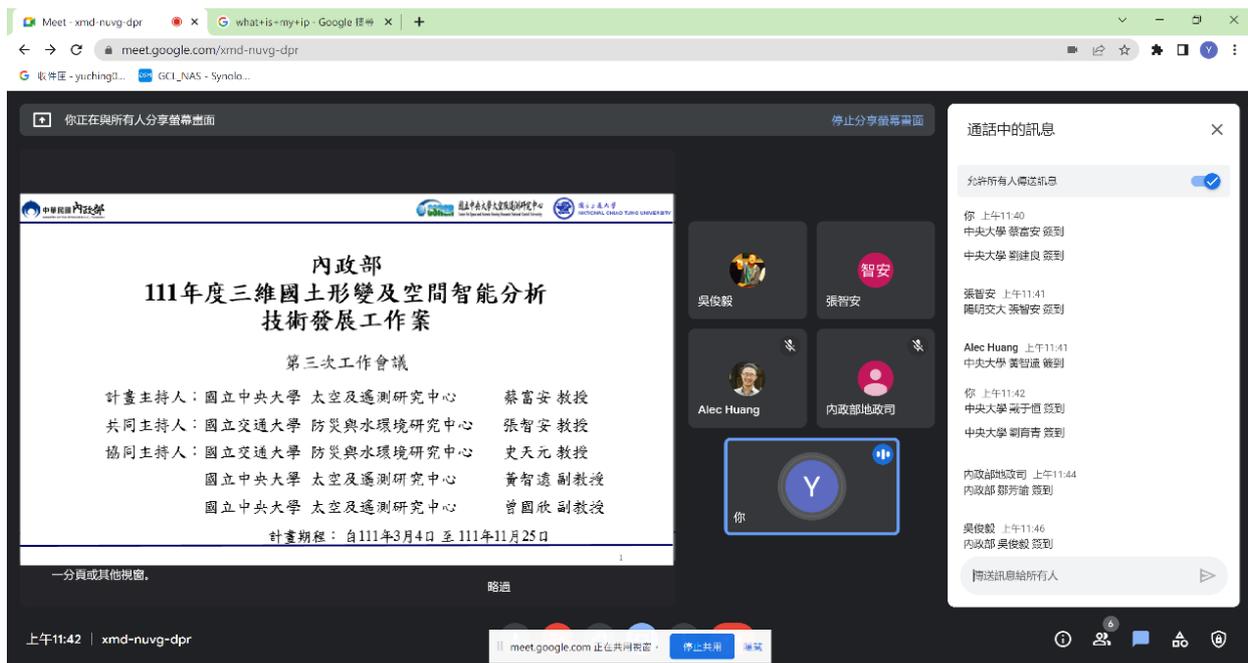
1. 建立航遙測影像智慧辨識訓練資料集
 - 探討結合航遙測影像與高程模型於地表分類之效益
 - 橫向比較與分析國際開放標竿資料集
 - 使用 AIOI 資料集為深度學習模型之訓練資料
2. 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效

- 以傳統 UNet 進行修改，加入 Transformer 增強高維度特徵分析
 - 使用修正高差移位資料集進行訓練，並提供正確框選屋頂範圍
 - 使用蒐集之 AIOI 資料集進行測試
3. 精進航遙測影像結合測量實工作之智慧整合應用
- 已產生不同空間解析度之影像
 - 將人工數化完成轉成深度學習所需的：訓練、驗證與獨立驗證(進行處理中)
- (3) 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦
1. 航遙測影像分析與辨識之結果
- 建立基於局部極值的時間序列區間偵測演算法
 - 使用時間序列區間偵測演算法分析
 - TSF(110)與 LID(111)
 - 後續將進行分割產生光譜相似的區域物件(Object)、引入 DEM 高程資訊、加入 Sentinel-2 多光譜衛星影像資料集與應用 GEE python API
2. 以臺灣地區航遙測影像進行地物辨識與分類試辦
- 建立房屋智慧判釋訓練及檢核資料集
 - 已產生 DSM 及 DSM 改正之正射影像及 DSM
- (4) 評估智慧物聯網之防災整合應用技術
1. 模擬基於感測器與模型資料，發展智慧建築等適地性應用
- 高精度淹水模擬：COS-Flow 模式模擬都市淹水
 - 防救災導航應用：Unity 建立模擬環境，語意網連結及淹水區域設定導航指引
2. 發展具跨影像區域分析及物件追蹤之智慧防救災整合技術
- 使用 DeepSORT 追蹤器
 - 透過卡曼濾波及匈牙利演算法進行物件之跨幀追蹤

- 以卷積類神經網路模型萃取物件外觀特徵
 - 進行 RE³ 與 DeepSORT 比較分析
3. 以實際場域進行適地性服務應用
- 選定與桃園捷運公司合作
 - 建立人員移動追蹤、異常行為判釋及隨身物品遺漏等應用
 - 與桃捷溝通研擬試辦規模、實施方法（溝通洽詢中）

二、 其他事項

- 無
- 散會(11:50)
- 簽到資訊



111 年度三維國土形變及空間智能分析技術發展工作案

第四次工作會議紀錄

壹、 時間：111 年 06 月 29 日 11:00

貳、 地點：遠端視訊會議

參、 出席人員：

內政部地政司

吳俊毅、鄒芳諭

國立中央大學太空及遙測研究中心

蔡富安、黃智遠、劉建良、
戴于恒、劉育青

國立陽明交通大學土木工程學系

張智安

● 會議內容：

一、 工項進度說明

(1) 應用人工智慧發展衛星影像地表形變分析技術與應用

1. 利用雷達衛星影像發展長期地表形變自動化智慧分析技術

- 篩選雷達影像中擁有高相關性的像素為永久散射體，以此為對象來分析誤差與解算地表形變量
- 35 對差分干涉影像進行 PSInSAR 處理，挑選 12 張影像進行類神經網路訓練，挑選 12 張影像套用類神經網路模型

2. 精進機器學習於高解析光學影像地表形變分析技術

- 針對去年試辦區域，另外加入雷達影像訓練資料進行偵測
- 光學影像包含 Green band、Red band、NIR band、PAN band、Entropy、Energy、NDVI，雷達影像包含 Sigma0

3. 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取

- 使用 Pleiades 衛星影像 3 張，SPOT-6/7 衛星影像 17 張，進行特徵分析、三維點雲匹配與建置數值地表模型

- 透過機器學習演算法進行房屋分類(SPOT-6/7)與萃取(Pleiades)
- (2) 應用人工智慧發展航遙測影像辨識技術與應用
1. 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效
 - 以傳統 UNet 進行修改，加入 Transformer 增強高維度特徵分析，提供更完整的細節辨識與特徵專注能力
 - 使用 4.2.2 節收集之 AIOI 資料集進行訓練，臺灣 DSM 改正正射影像進行預測
 - 使用 RGB+DSM 影像進行建築辨識有助於辨識地面與建築物的高度差，更容易將低矮建築分離
 - 修改模型架構加入 DSM 分析資料
 2. 精進航遙測影像結合測量實工作之智慧整合應用
 - 針對不同空間解析度(2、5、10cm)的影像進行訓練與驗證
- (3) 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦
1. 利用雷達衛星影像地表形變分析，建立臺灣各地初步形變分析圖資
 - 完成全臺灣 C-波段多時期雷達影像地表形變分析，使用 Sentinel-1 (2017/01~2021/12，共 128 張影像)與 GNSS (2017/01~2021/12)進行分析
 2. 以兩年內高解析光學衛星影像進行數值地表模型(DSM)變異分析
 - 2022/6/22 拍攝局部區域之 SPOT-6/7 立體像對，並完成 DSM 產製，其餘區域已優先排程拍攝中
 3. 以臺灣地區航遙測影像進行地物辨識與分類試辦
 - 完成測試區新竹縣市，共 23 幅資料前處理作業
 - 建立房屋變遷偵測程序
- (4) 評估智慧物聯網之防災整合應用技術
1. 模擬基於感測器與模型資料，發展智慧建築等適地性應用
 - 資料蒐集，包含地政司水利 DEM (臺南善化區) OSM 街道路網、水利署水位監測站等與氣象局雨量站

2. 發展具跨影像區域分析及物件追蹤之智慧防救災整合技術

- 目前同類別不同物件之特徵萃取網路，現有資料集不符需求，因此進行 RestNet 訓練資料蒐集
- 採用 DeepSORT+YOLO 偵測類別並追蹤，得到同類別不同物件的多張影像

3. 以實際場域進行適地性服務應用

- 加入以人體骨架辨識人類行為的技術
- 規劃異常行為通報應用，並以 Line Bot 聊天機器人進行訊息通知
- 行程安排，7 月場勘（桃捷 A19 站）與討論攝影機位置、購買設備佈設感測器，7 月至 9 月為程式開發與雛形測試，10 月至 11 月進行現場應用測試及評估

(5) 數據分析與科教活動

1. 持續分析基隆潮位站數據

- 完成 2021/11/01-2022/05/30 潮位數據蒐集及分析，包含音波式、壓力式與雷達式
- 整體而言，建議基隆新設潮位站以音波式為主，壓力式為輔助系統

2. 海洋科技博物館之科教活動

- 暫定 9 月底 10 月初辦理，如仍因疫情學生無法離校，將採用赴校教學，選擇兩所學校，安排半日科教演講

3. 衛星遙測科技應用之科教活動

- 規劃 8 月中至 8 月底辦理，採實體課程方式舉辦

二、 其他事項

- 無
- 散會(12:00)
- 簽到資訊

Meet - xmd-nuvg-dpr

meet.google.com/xmd-nuvg-dpr

Alec Huang 正在分享螢幕畫面

內政部 111 年度三維國土形變及空間智能分析 技術發展工作案

第四次工作會議

計畫主持人：國立中央大學 太空及遙測研究中心 蔡富安 教授
共同主持人：國立交通大學 防災與水環境研究中心 張智安 教授
協同主持人：國立交通大學 防災與水環境研究中心 史天元 教授
國立中央大學 太空及遙測研究中心 黃智遠 副教授
國立中央大學 太空及遙測研究中心 曾國欣 副教授

計畫期程：自 111 年 3 月 4 日 至 111 年 11 月 25 日

智安

還有另外 4 位使用者

你

通話中的訊息

你 上午 11:37
中央大學 蔡富安 簽到
中央大學 劉建良 簽到
中央大學 劉育青 簽到

張智安 上午 11:38
張智安 簽到

戴于恒 上午 11:38
中央大學 戴于恒 簽到

內政部地政司吳組長俊毅 上午 11:38
內政部 吳俊毅 簽到

內政部地政司 上午 11:38
內政部 鄧芳諭 簽到

Alec Huang 上午 11:57
中央大學 黃智遠 簽到

傳送訊息給所有人

上午 11:43 | xmd-nuvg-dpr

111 年度三維國土形變及空間智能分析技術發展工作案

第五次工作會議紀錄

壹、 時間：111 年 07 月 28 日 11:00

貳、 地點：遠端視訊會議

參、 出席人員：

內政部地政司

吳俊毅、鄒芳諭

國立中央大學太空及遙測研究中心

蔡富安、劉建良、戴于恆、
劉育青

國立陽明交通大學土木工程學系

張智安

● 會議內容：

一、 工項進度說明

(1) 應用人工智慧發展衛星影像地表形變分析技術與應用

1. 利用雷達衛星影像發展長期地表形變自動化智慧分析技術

- 預計後續工作為對 U-Net 模型準確度評估、以 U-Net 模型獲得之像元進行變形解算、比對 AI 變形與傳統變形計算成果

2. 精進機器學習於高解析光學影像地表形變分析技術

- 原先概念為使用高解析 TerraSAR-X 雷達影像，觀察前後期雷達影像各偏極上之變化，找出崩塌地
- 後來測試方法為使用雷達影像替代高解析光學影像對地表進行形變分析，以機械學習的方式，將前後期雷達影像經由深度學習模型 U-Net 進行影像分割
- 受資料限制，預計使用單一時段雷達影像與其他地理資料，包含 TerraSAR-X 偏極、坡度、DEM

3. 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取

- 透過機器學習與演算法進行房屋區分類
- 道路物件訓練集蒐集，包含國際公開 AI 訓練資料集蒐集、臺灣地區道路區域影像與標示
- 預計後續工作為房屋輪廓後處理、道路物件訓練資料蒐集與分類、三維點雲分群、精度評估與分析

(2) 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦

1. 利用雷達衛星影像地表形變分析，建立臺灣各地初步形變分析圖資
 - X-波段，規劃利用空中巴士公司 (Airbus) X 波段雷達衛星 TerraSAR-X 影像進行分析，Stripmap 模式，具備 3 米解析度之觀測能力
 - L-波段，規劃利用日本太空總署(JAXA) L 波段雷達衛星 ALOS-2 影像進行分析，採用 Ultra-Fine 模式，具備 2.5 米解析度之觀測能力
 - 高雄美濃測試區，規劃採用影像拍攝日期 2015/11/26 與 2016/02/18 進行差分干涉來計算 2016 年美濃地震的地表變形量
2. 以兩年內高解析光學衛星影像進行數值地表模型(DSM)變異分析
 - 2022/7/12 及 2022/7/24 完成拍攝作業，補齊 2022/6/22 未拍攝之區域，並進行方位重建及 DSM 產製處理

(3) 數據分析與科教活動

1. 衛星遙測科技應用之科教活動
 - 規劃 8 月 24 日辦理，採實體課程方式舉辦，目前已開放高中職、國中、國小老師報名，待報名人員名單確定後再交由內政部承辦人員確認

二、 其他事項

- 無
- 散會(11:20)
- 簽到資訊

The screenshot shows a Google Meet session. The main content is a presentation slide with the following text:

內政部
111年度三維國土形變及空間智能分析
技術發展工作案
第五次工作會議

計畫主持人：國立中央大學 太空及遙測研究中心 蔡富安 教授
共同主持人：國立交通大學 防災與水環境研究中心 張智安 教授
協同主持人：國立交通大學 防災與水環境研究中心 史天元 教授
國立中央大學 太空及遙測研究中心 黃智遠 副教授
國立中央大學 太空及遙測研究中心 曾國欣 副教授

計畫期程：自111年3月4日至111年11月25日

On the right side, there is a list of participants: 智安 (張智安), 內政部地政司-吳俊毅, 內政部地政司, and 你 (Y).

The chat window on the right shows the following messages:

通話中的訊息
允許所有人傳送訊息
只有這場會議的參與者可以查看訊息，而且訊息會在會議結束後刪除

你 上午11:08
中央大學 蔡富安 簽到
中央大學 謝建良 簽到
中央大學 戴子信 簽到
中央大學 謝育青 簽到

張智安 上午11:13
陽明交大 張智安 簽到

內政部地政司 上午11:13
內政部 吳俊毅 簽到
內政部 鄧芳瑜 簽到

傳送訊息給所有人

111 年度三維國土形變及空間智能分析技術發展工作案

第六次工作會議紀錄

壹、 時間：111 年 08 月 25 日 11:00

貳、 地點：遠端視訊會議

參、 出席人員：

內政部地政司

鄒芳諭

國立中央大學太空及遙測研究中心

蔡富安、黃智遠、劉建良、
戴于恒、劉育青

國立陽明交通大學土木工程學系

張智安

● 會議內容：

一、 工項進度說明

(1) 應用人工智慧發展衛星影像地表形變分析技術與應用

1. 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取
 - Pleiades 房屋區域輪廓正規化與約化處理
 - 道路物件訓練像集蒐集，國際公開 AI 訓練資料集蒐集與臺灣地區道路區域影像與標示
 - 初步道路分類成果

(2) 應用人工智慧發展航遙測影像辨識技術與應用

1. 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效
 - 修改模型架構加入 DSM 分析資料，架構由原來的 RGB 改成 RGB +DSM
 - 比較 2 種架構之現象觀察，根據測試成果在後續的訓練都將使用加入 DSM 的模型架構
 - 使用臺灣的正射影像進行直接訓練

2. 精進航遙測影像結合測量實工作之智慧整合應用

- 提供不同空間解析度之無人機正射影像偵測人孔位置
- 取得偵測成果的高程資料（平均高程值為正規化前的人孔蓋）
- 2、5、10cm 空間解析度整合成一個資料集進行處理
- 完成空間解析度 2、5、10cm 的訓練及獨立驗證區之預測
- 預計 8/30 進行現場測量之精度驗證（使用 eGNSS）

(3) 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦

1. 以兩年內高解析光學衛星影像進行數值地表模型(DSM)變異分析

- 於 2022/6/22、2022/7/12 及 2022/7/24 完成拍攝作業，並進行 DSM 產製處理

2. 航遙測影像分析與辨識之結果，精進與坡地防災應用平臺進行整合，其整合方案須與內政部討論後辦理

- 進行分割產生特徵相似的區域物件(Object)，再以物件為單元進行判釋，以改善像元式判釋之椒鹽效應並降低混合像元造成之影響
- 研究分析三種不同理論基礎之物件單元：斜坡單元(Slope Unit, SU)、Simple Non-Iterative Clustering (SNIC)、Multiresolution Segmentation (MRS)
- IoU 精度評估，SNIC 及 MRS 加入 SU 資訊進行分割都有提升精度，其中 MRSxSU1K 的分割精度最佳
- 探討不同物件分割方式對崩塌地判釋之優劣，分別對 SU1K、MRS_w99 及 MRSxSU1K_w99 進行機器學習分類，以 IoU>50 之數據進行模型訓練與測試

3. 以臺灣地區航遙測影像進行地物辨識與分類試辦

- 建立房屋智慧判釋訓練及檢核資料集，比較本年度與前期成果之改進

(4) 評估智慧物聯網之防災整合應用技術

1. 模擬基於感測器與模型資料，發展智慧建築等適地性應用

- 建置 DEM+高架道路與建物與建物屋頂資料
- 進行淹水深度模擬與 Unity 路徑規劃
- 2. 模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術
 - 開發同類別不同物件之特徵萃取網路
 - RestNet 訓練資料蒐集，初步成果可有效分辨不同物件
- 3. 以實際場域進行適地性服務應用
 - 使用站內現有 CCTV
 - 於本地端分析及警示
 - 完成試辦地點場勘，正在進程式開發與測試
- (5) 數據分析與科教活動
 - 1. 海洋科技博物館之科教活動
 - 暫定 9 月底 10 月初辦理，已開始聯繫及協調場地、講員及學校
 - 2. 衛星遙測科技應用實務教育推廣工作坊之科教活動
 - 於 8 月 24 日完成活動辦理，採實體課程舉辦，報名人數 55 位，實際參加人數 35 位
- (6) 提送國內外期刊或研討會論文文稿至少 4 篇(期中已投稿一篇)
 - 8 月底會投稿 International Journal of Applied Earth Observation and Geoinformation，題目 Comparison between image- and surface-derived displacement fields for landslide monitoring using an unmanned aerial vehicle.

二、 其他事項

- 將邀請邱式鴻老師參與 9 月份工作會議
- 散會(11:40)
- 簽到資訊

Meet - xmd-nuvg-dpr x 新分頁 x | +

meet.google.com/xmd-nuvg-dpr

Meet

內政部
111年度三維國土形變及空間智能分析
技術發展工作案

第六次工作會議

計畫主持人：國立中央大學 太空及遙測研究中心 蔡富安 教授
共同主持人：國立交通大學 防災與水環境研究中心 張智安 教授
協同主持人：國立交通大學 防災與水環境研究中心 史天元 教授
國立中央大學 太空及遙測研究中心 黃智遠 副教授
國立中央大學 太空及遙測研究中心 曾國欣 副教授

計畫期程：自111年3月4日至111年11月25日

1

通話中的訊息

張智安 上午11:33
陽明交大 張智安 簽到

你 上午11:33
中央大學 蔡富安 簽到
中央大學 戴于恆 簽到
中央大學 劉育青 簽到

劉建良 上午11:34
中央大學 劉建良 簽到

內政部地政司 上午11:43
內政部地政司 鄒芳諭 簽到

Alec Huang 上午11:43
中央大學 黃智遠 簽到

傳送訊息給所有人

上午11:37 | xmd-nuvg-dpr

111 年度三維國土形變及空間智能分析技術發展工作案

第七次工作會議紀錄

壹、 時間：111 年 09 月 26 日 11:00

貳、 地點：遠端視訊會議

參、 出席人員：

內政部地政司

鄒芳諭

國立中央大學太空及遙測研究中心

蔡富安、劉建良、戴于恒、
劉育青

國立陽明交通大學土木工程學系

張智安

國立政治大學地政學系

邱式鴻

● 會議內容：

一、 工項進度說明

(1) 應用人工智慧發展衛星影像地表形變分析技術與應用

1. 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取
 - 道路物件訓練像集蒐集，臺灣地區道路區域影像與標示
 - 道路分類成果與精度評估

(2) 應用人工智慧發展航遙測影像辨識技術與應用

1. 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效
 - 根據測試成果在後續的訓練都將使用加入 DSM 的模型架構
 - 使用 AIOI 資料集訓練後的權重進行臺灣正射影像遷移式學習，以及使用臺灣的正射影像進行直接訓練
 - 遷移式學習初始化，採用在 4、7、14 次的存檔模型作為初始模型，使用臺灣資料集進行遷移式學習

- 整體評估結果，4 epoch 時最佳，但是辨識完整性 14 epoch 最佳
2. 精進航遙測影像結合測量實工作之智慧整合應用
- 利用影像密匹配獲得的地面高程，依據人孔偵測範圍，計算人孔區域內高程的中位數(Median)，作為人孔高程
 - 精度評估，包含人工量測無人機正射影像之人孔二維坐標，以及現地 eGNSS 測量人孔三維坐標。
 - 在無人機影像空間解析度為 2cm 時，獨立檢核區的偵測率及正確率均達到 90%，人孔中心坐標與人工數化成果比較，平面均方根誤差小於 10cm，高程均方根誤差小於 20cm
 - 建議人孔尺度的智慧辨識採用優於 5cm 空間解析度之影像
- (3) 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦
1. 雷達衛星影像地表形變分析之試辦
- 臺北港填海造陸區 (X 波段)，進行影像及變形量時間序列分析
2. 以兩年內高解析光學衛星影像進行數值地表模型(DSM)變異分析
- 比對 SPOT-6/7 立體對產製與空載光達所產製之 DSM，高程差大於 10 公尺，以形態學開啟運算進行過濾
 - 地表形變評估門檻，累計地表形變區域面積大於 20000 平方公尺、累積增減高度大於 20000 公尺，試辦區之 684 幅中 43 幅之地表形變大於門檻
 - 衛星影像 DSM 變異分析及更新建議作業程序，包含數值地表模型產製、比對分析與建議更新區域評估
3. 航遙測影像分析與辨識之結果，精進與坡地防災應用平臺進行整合，其整合方案須與內政部討論後辦理
- SNIC 整體分割成果不佳；MRS 整題精度較 SU 與 SNIC 佳。SNIC 及 MRS 加入 SU 資訊進行分割都有提升精度，其中 MRSxSU1K 的分割精度最佳
 - 使用與崩塌參考資料 IoU 大於 50% 之分割物件進行模型訓練，其測試資料預測結果顯示：PCA 後精度皆有顯著提升、加入 DEM 特徵皆能降低漏授及誤授誤差、在高重疊率之良好資料集中各分割方式皆能有效分辨崩塌與非崩塌之物件

4. 以臺灣地區航遙測影像進行地物辨識與分類試辦

- 以 DSM 改正之正射影像降低房屋高差移位影響
- 建立房屋變遷偵測程序
- 進行房屋偵測精度與房屋變遷精度評估

(4) 評估智慧物聯網之防災整合應用技術

1. 模擬基於感測器與模型資料，發展智慧建築等適地性應用

- 進行淹水深度模擬與 Unity 路徑搜尋功能

2. 模擬基於三維圖資與路網資訊整合路側影像感測器，發展具跨影像區域分析及物件追蹤之智慧防救災整合技術

- 採用 DeepSORT+YOLO 偵測類別並追蹤，得到同類別不同物件的多張影像，持續擴增訓練資料集，以更有效的分辨不同物件

3. 以實際場域進行適地性服務應用

- 已可有效抓取人體骨架，進行行為判讀（走、跑、跳等），目前於階梯上行行為誤判較多，仍需調整

(5) 數據分析與科教活動

1. 海洋科技博物館之科教活動

- 暫定 9 月 30 日辦理，包含大安高工建築科 71 位師生與南港高工土木科 36 位師生

(6) 提送國內外期刊或研討會論文文稿至少 4 篇

- 已完成 3 篇投稿，加上期中投稿 1 篇，已完成投稿進度

二、 其他事項

邱式鴻教授建議、意見與回覆		
	意見	意見回覆
1	臺北港填海造陸區部分，根據雷達影像，是否能觀察天然氣與儲油槽細部變化？	由於此區域處於正在興建中，根據影像資料有發現類似設施，但不能確定是否為天然氣與儲油槽，但能就影像資料進行此區域的變形量時間序列分析。

2	地表形變評估門檻部分，其 10 公尺門檻是否有所依據，高程差是否為累積總和？	主要為參考水保局在大規模崩塌之定義(崩塌深度為 10 公尺)。皆為累計面積與累積高度累計計算，此工作項目為快速偵測處理，讓相關單位能了解圖幅中地表之變化，以便後續應用，透過這些累積的數值變化(),在某種程度上已足以代表體積上的變化。
3	物聯網試辦部分，是否有針對意外的行為模式或行動不便、輪椅、拐杖等使用者進行安全性上之情境模擬？	今年度規劃以基本行為模式為主，如坐、走、跑、跳等動作，後續再透過這些動作於不同場域中發展應用，以延伸、偵測更多的行為模式。
4	於 4.2.3 在修改模型架構加入 DSM 分析部分，為何不透過 DSM-DEM 進行分析？	若是使用 DSM 偵測 DEM 會不準確，且光達資料採樣時間比較不密集，會造成錯誤之成果，所以於現有模型架構加入 DSM 資料，改成 RGB+DSM 進行分析。
5	於 4.3.3 提到使用 Object-based 部分，前幾年是否有使用 AI 方式去偵測?為什麼需要使用到 AI 技術？	去年為 pixel-based 方式偵測，成果上會有誤判，今年改成 Object-based 方式效果提升許多。林務局目前以人工的方式進行判釋坡地防災(使用 2 公尺高解析衛星影像)，所以本項工作為嘗試用高光譜解析資料分析處理，以增加自動化處理作業。

- 散會(12:05)
- 簽到資訊

會議標題: 內政部 111年度三維國土形變及空間智能分析技術發展工作案 第七次工作會議

計畫主持人: 國立中央大學 太空及遙測研究中心 蔡富安 教授
 共同主持人: 國立交通大學 防災與水環境研究中心 張智安 教授
 協同主持人: 國立交通大學 防災與水環境研究中心 史天元 教授
 國立中央大學 太空及遙測研究中心 黃智遠 副教授
 國立中央大學 太空及遙測研究中心 曾國欣 副教授

計畫期程: 自 111年3月4日 至 111年11月25日

通訊中的訊息

允許所有人傳送訊息

你 中午12:00
 中央大學 蔡富安 簽到
 中央大學 劉建良 簽到
 中央大學 戴于恒 簽到
 中央大學 劉勇青 簽到

Shih Hong Chio 中午12:00
 政治大學 邱式溝 簽到

內政部地政司鄒芳論 中午12:00
 內政部地政司 鄒芳論 簽到

張智安 中午12:00
 陽明交大 張智安 簽到

傳送訊息給所有人，系統也會一併錄製訊息。

111 年度三維國土形變及空間智能分析技術發展工作案

第八次工作會議紀錄

壹、 時間：111 年 10 月 18 日 13:00

貳、 地點：遠端視訊會議

參、 出席人員：

內政部地政司

吳俊毅、鄒芳諭

國立中央大學太空及遙測研究中心

蔡富安、黃智遠、劉建良、
戴于恒、劉育青

國立陽明交通大學土木工程學系

張智安

國立臺灣師範大學地理學系

王聖鐸

● 會議內容：

一、 工項進度說明

(1) 應用人工智慧發展衛星影像地表形變分析技術與應用

1. 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取
 - Pleiades 影像例房屋偵測精度評估
 - SPOT 影像例道路物件訓練像集蒐集與分類
 - 道路分類成果與精度評估

(2) 應用人工智慧發展航遙測影像辨識技術與應用

1. 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效
 - 使用正射影像配合 DSM 進行訓練在整體評估較佳，加入 DSM 有辦法改善低層建築辨識與建築物間遮蔽處
2. 精進航遙測影像結合測量實工作之智慧整合應用
 - 在無人機影像空間解析度為 2cm 時，獨立檢核區的偵測率及正確率均達到 90%，人孔中心坐標與人工數化成果比較，平面均方根

誤差小於 10cm，高程均方根誤差小於 20cm

- 影響偵測成果的主要因素：遮蔽（完整性）、空間解析度（細緻度）
- 影響中心坐標的主要因素：連續人孔之分割
- 建議人孔尺度的智慧辨識採用優於 5cm 空間解析度之影像

(3) 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦

1. 雷達衛星影像地表形變分析之試辦

- 坡地滑動監測（L 波段），高雄美濃測試區，採用影像拍攝日期 2015/11/26 與 2016/02/18 進行差分干涉來計算 2016 年美濃地震的地表變形量

2. 以兩年內高解析光學衛星影像進行數值地表模型(DSM)變異分析

- 依作業程序共完成 3 個試辦區
- 以目前建議之變異門檻進行分區評估分析

3. 航遙測影像分析與辨識之結果，精進與坡地防災應用平臺進行整合，其整合方案須與內政部討論後辦理

- 資料匯整於 GEE 平臺，包含 Landsat-8 衛星影像、DEM、崩塌參考資料
- 進行測試區的模型訓練與獨立驗證，並探討不同物件分割方式對崩塌地判釋之優劣

4. 以臺灣地區航遙測影像進行地物辨識與分類試辦

- 進行房屋偵測精度與房屋變遷精度評估，以及人工數化與 AI 偵測變遷對照

(4) 評估智慧物聯網之防災整合應用技術

1. 以實際場域進行適地性服務應用

- 進行人類行為分析演算
- 管理者系統建置、增添硬體設備、試辦區現場攝影機串流測試

(5) 數據分析與科教活動

1. 海洋科技博物館之科教活動

- 9 月 30 日完成辦理，包含大安高工建築科 71 位師生與南港高工土木科 36 位師生

(6) 提送國內外期刊或研討會論文文稿至少 4 篇

- 已投稿 4 篇期刊論文，完成計畫之投稿進度

二、 其他事項

王聖鐸教授建議、意見		
	意見	意見回覆
1	DSM 變異分析的門檻值如何訂定？	門檻值為 110 年提出，為參考水保局「大規模崩塌災害防治行動綱領」中之大規模崩塌的定義。主要為用衛星產製新的 DSM，比對內政部同地區現有的最新的光達，資料可能為去年甚至是 5 年前的光達資料，所以透過此工作協助未來光達做 DSM 修測時，評估優先進行修測之區域。
2	在物聯網-淹水模式中，感測器資料是否會影響到模式？透過 YOLO 進行物件追蹤，能否透過人工介入方式去修改 YOLO 之類別？	感測器資料為建立模式之訓練資料，當模式建完成後，會根據蒐集到的資料即時去判斷淹水區域。運行 YOLO 時為自動判斷，建議的方式為提前蒐集各種影像進行訓練，再去判別物件，並無透過 YOLO 判斷出物件後，再根據類別進一步修改。
3	在物聯網-捷運站試辦部分，於樓梯上滑倒或手扶梯跑步，是否能當危險動作部分偵測？	這部分不能單純用單一動作看待，未來會考慮用情境模式進行測試，如攻擊模式(攻擊+跌倒動作)，今年仍以單人動作測試。
4	DSM 變異偵測部分，解析度為何？是由光達產製而成？	DSM 由航照影像經過密匹配產製而成，內插成 25CM 解析度。
5	人孔蓋是否全部都有偵測到？人孔蓋沒有被偵測到的原因？	有 89% 是成功被偵測，於成功被偵測中有超過 90% 滿足規範。沒有被偵測到主要有 3 個原因，(1)遮蔽，人孔蓋有部分被遮蔽、(2)形狀改變，上面覆蓋沙土或草、(3)反差過低，路面顏色與人孔蓋相近。

內政部地政司建議、意見		
	意見	意見回覆
1	盤點各工作項目研究發展的等級，包括(1)已成熟，可供產業使用、(2)發展中，經精進後，可作為後續應用、(3)先期研究，需經過幾年發展研究，才能作為後續應用。	將提供表格說明各工項之研究發展等級。

2	於 DSM 變異偵測手冊中加入門檻值來源說明。現階段為使用 SOPT6/7 影像，若是使用其他的影像來源，可以進行變異偵測嗎？	將補充來源說明於手冊中，門檻值為參考水保局「大規模崩塌災害防治行動綱領」中之大規模崩塌的定義。影像來源不限制，只要符合 DSM 產出之要求即可，使用 SOPT6/7 立體對主要原因為成本較低。
3	在物聯網淹水模擬模組中，使用水利 DEM 需要進行修正嗎？	可直接使用水利 DEM 資料於模組中。
4	捷運試辦部分，電腦硬體等部分如何配置？危險動作如何告知管理者？	將放置較高配備電腦與 5 公尺網路線於捷運站中，以利程式即時進行影像分析運作。若偵測到危險行為，系統會發出警告聲音提醒。
5	人孔蓋部分，若使用航照影像可否進行偵測？	航照影像為 10CM 解析度，對照研究內容，10CM 解析度偵測正確率約為 60-70%。
6	房屋變遷偵測中，房屋區塊較小部分，是否可以設定門檻值將小區域部分過濾，以提升偵測正確性？	可以設定門檻值以提升正確性，本項工作都進行偵測，才提出小面積區域之情況。目前偵測成果多為遺漏，而非誤受。

- 散會(14:20)
- 簽到資訊

內政部
111年度三維國土形變及空間智能分析
技術發展工作案
第八次工作會議

計畫主持人：國立中央大學 太空及遙測研究中心 蔡富安教授
共同主持人：國立交通大學 防災與水環境研究中心 張智安教授
協同主持人：國立交通大學 防災與水環境研究中心 史天元教授
國立中央大學 太空及遙測研究中心 黃智遠副教授
國立中央大學 太空及遙測研究中心 曾國欣副教授

會議時間：111年10月18日 計畫期程：自111年3月4日至111年11月25日

下午1:11 | xmd-nuvg-dpr

通話中的訊息

Fuan Tsai 下午1:09
中央大學 蔡富安 簽到

張智安 下午1:10
陽明交大 張智安

內政部地政司鄒芳論 下午1:10
內政部 鄒芳論 簽到

Sendo Wang 下午1:10
臺師大 王聖輝 簽到

你 下午1:11
中央大學 劉建良 簽到
中央大學 戴子恒 簽到

你 下午1:31
中央大學 劉建良 簽到
中央大學 戴子恒 簽到

Alec Huang 下午1:31
中央大學 黃智遠 簽到

內政部地政司鄒芳論 下午1:46
內政部地政司 黃俊毅 簽到

傳送訊息給所有人

111 年度三維國土形變及空間智能分析技術發展工作案

第九次工作會議紀錄

壹、 時間：111 年 11 月 14 日 11:00

貳、 地點：遠端視訊會議

參、 出席人員：

內政部地政司

吳俊毅、鄒芳諭

國立中央大學太空及遙測研究中心

蔡富安、黃智遠、劉建良、
戴于恒、劉育青

國立陽明交通大學土木工程學系

張智安

● 會議內容：

一、 工項進度說明

(1) 應用人工智慧發展衛星影像地表形變分析技術與應用

1. 利用雷達衛星影像發展長期地表形變自動化智慧分析技術

- 機器學習進行永久散射體自動辨別，找出最佳的雷達永久散射體來進行處理分析

2. 精進機器學習於高解析光學影像地表形變分析技術

- 以三種影像來源進行模型訓練與形變預測

3. 發展多元衛星影像智慧處理與立體重建技術，進行特徵目標物之萃取

- 房屋區與道路區機器學習演算法建立
- Pleiades 與 SPOT-6/7 衛星影像於房屋區與道路區偵測之測試

4. 擴充衛星影像智慧增值應用與後續推動可行性評估

- 彙整增值應用案例
- 智慧增值應用與增值應用整合可行性評估

(2) 應用人工智慧發展航遙測影像辨識技術與應用

1. 建立航遙測自動化地物智慧辨識與分類技術，並評估其精度與成效
 - 遷移式學習初始化
 - 遷移式學習獨立檢核評估指標
2. 以臺灣地區航遙測影像進行地物辨識與分類試辦
 - 房屋變遷精度評估（全區）
 - 房屋變遷精度評估（全區，不含小於 16m²的變遷）

(3) 衛星與航遙測影像智慧分析、辨識與製圖防災整合應用案例試辦

1. 雷達衛星影像地表形變分析之試辦
 - C 波段-全台灣 PSInSAR（2017-2021 五年期）
 - X 波段-台北港填海造陸區
 - L 波段-高雄美濃地震事件(2016)
2. 以兩年內高解析光學衛星影像進行數值地表模型(DSM)變異分析
 - 擬定衛星影像 DSM 變異分析及更新建議作業程序

(4) 評估智慧物聯網之防災整合應用技術

1. 發展具跨影像區域分析及物件追蹤之智慧防救災整合技術
 - 可辨識不同人的 ResNet-設定相似度門檻以區分不同人
 - 區分 Class - 一致性差異
2. 以實際場域進行適地性服務應用
 - 管理者系統建置
 - 現場攝影機串流測試
 - 應用介面介紹

(5) 數據分析與科教活動

1. 持續分析基隆潮位站數據
 - 潮位數據經調和分析信噪比(SNR)大於 20，95%信心區間

- 三種水位計中分潮重組值及觀測值平均最高的是雷達式水位計，其次為壓力式，最低是音波式
- 分潮重組分別為 0.0894(音波式)、0.0946(壓力式)及 0.1003(雷達式) m，差值約在 5-11 mm

(6) 成果發表及技術交流

1. 以航遙測及空間數據為主題發展人工智能實驗室，強化產學合作

- 分別成立 GeoAI@NCU 及 GeoAI@NYCU 實驗室
- 發展智慧製圖技術，並推動與空間資訊領域之聯結

二、 其他事項

- 散會(11:50)
- 簽到資訊

The screenshot shows a Google Meet interface. The main window displays a presentation slide with the following content:

內政部
111年度三維國土形變及空間智能分析
技術發展工作案
第九次工作會議

計畫主持人：國立中央大學 太空及遙測研究中心 蔡富安 教授
共同主持人：國立交通大學 防災與水環境研究中心 張智安 教授
協同主持人：國立交通大學 防災與水環境研究中心 史天元 教授
國立中央大學 太空及遙測研究中心 黃智遠 副教授
國立中央大學 太空及遙測研究中心 曾國欣 副教授

會議時間：111年11月14日 計畫期程：自111年3月4日至111年11月25日

The chat window on the right shows a list of participants and their join times:

- Fuan Tsai 上午11:14 中央大學 蔡富安 簽到
- 你 上午11:14 中央大學 劉萬壽 簽到
- 張智安 上午11:48 陽明交大 張智安 簽到
- Alec Huang 上午11:48 中央大學 黃智遠 簽到
- 內政部-鄒芳論 上午11:49 內政部 鄒芳論 簽到
- Chien-Liang Liu 上午11:49 中央大學 劉建良 簽到
- 內政部地政司-吳佳毅 上午11:49 內政部 吳佳毅 簽到
- 鄒于恒 (Constantine VI) 上午11:49 中央大學 鄒于恒 簽到