

第三十卷第四期
中華民國一十四年十二月

ISSN 1021-8661
DOI: 10.6574/JPRS

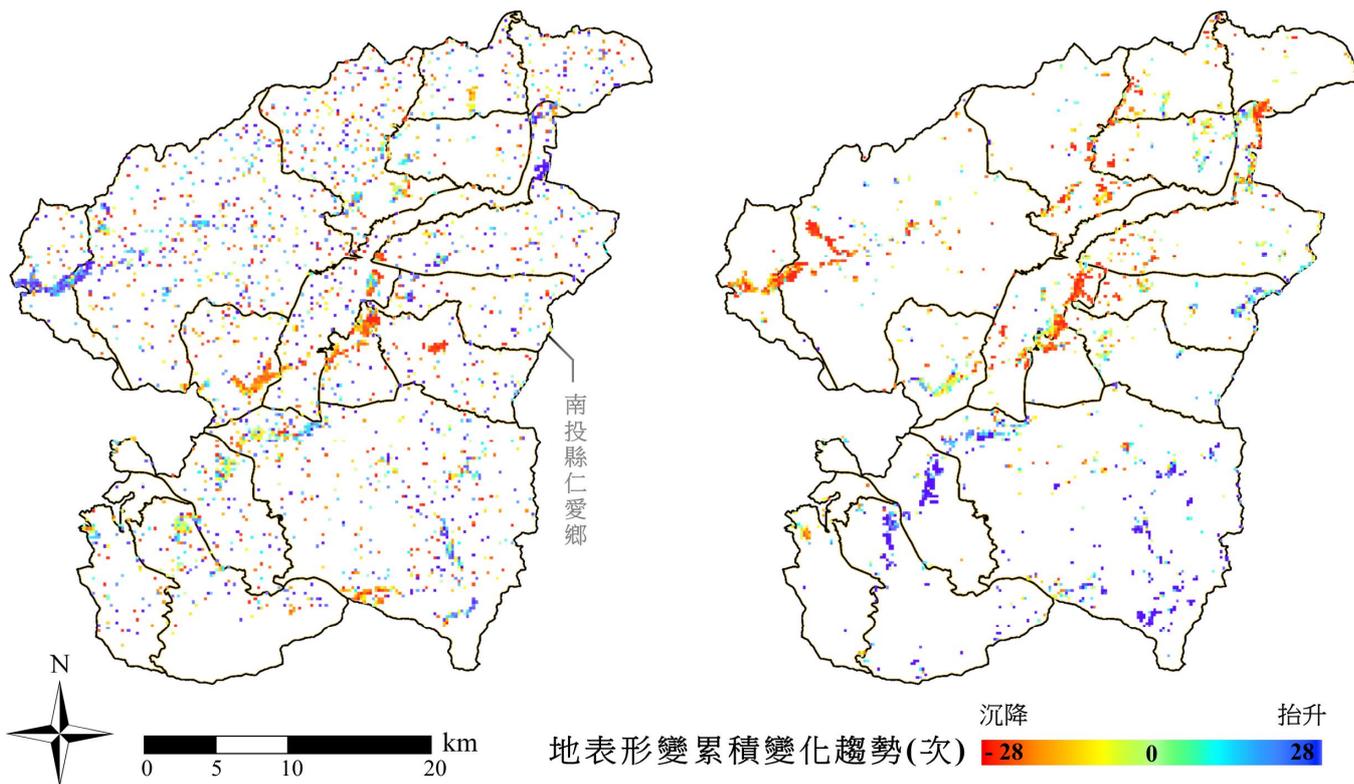


航測及遙測學刊

中華民國航空測量及遙感探測學會出版

PS-InSAR

SBAS-InSAR



Journal of Photogrammetry and Remote Sensing

Volume 30 No.4

December

2025

Published by Chinese Society of Photogrammetry and Remote Sensing

航測及遙測學刊

Journal of Photogrammetry and Remote Sensing

發行人：蔡富安

出版者：中華民國航空測量及遙感探測學會

地址：台北市文山區羅斯福路五段 113 號三樓

電子信件：csprsmail@csprs.org.tw

網址：http://www.csprs.org.tw

PUBLISHER: Fuan Tsai

PUBLISHED BY: Chinese Society of Photogrammetry and Remote Sensing

Address: 3F, No.113, Sec.5, Roosevelt Road, Taipei, Taiwan

E-mail: csprsmail@csprs.org.tw

WebSite: http://www.csprs.org.tw

總編輯：楊明德

國立中興大學土木工程學系

電話：886-4-2285-2168

電子信件：jprssubmit@gmail.com

EDITOR-IN-CHIEF: Ming-Der Yang

Department of Civil Engineering, National Chung Hsing University

Tel: 886-4-2285-2168

E-Mail: jprssubmit@gmail.com

編輯委員(依中文姓氏筆劃排列)

王素芬 (國立彰化師範大學)

王聖鐸 (國立臺灣師範大學)

史天元 (國立陽明交通大學)

何宗儒 (國立臺灣海洋大學)

林玉農 (中央研究院)

林昭宏 (國立成功大學)

林唐煌 (國立中央大學)

邱式鴻 (國立政治大學)

洪榮宏 (國立成功大學)

徐百輝 (國立臺灣大學)

張智安 (國立陽明交通大學)

莊永忠 (逢甲大學)

郭俊麟 (國立東華大學)

陳偉堯 (國立臺北科技大學)

陳國華 (國立臺北大學)

陳朝圳 (國立屏東科技大學)

曾國欣 (國立中央大學)

黃倬英 (國立臺灣大學)

蔡富安 (國立中央大學)

蔡榮得 (國立中興大學)

蘇東青 (國立金門大學)

C. Stewart (The Ohio State University) (USA)

M. Matsuoka (Tokyo Institute of Technology) (Japan)

T. Kim (Inha University) (South Korea)

EDITORIAL BOARD

S. F. Wang (National Changhua University of Education)

S. D. Wang (National Taiwan Normal University)

P. T. Y. Shih (National Yang Ming Chiao Tung University)

C. R. Ho (National Taiwan Ocean University)

Y. N. Lin (Academia Sinica)

C. H. Lin (National Cheng Kung University)

T. H. Lin (National Central University)

S. H. Chio (National Chengchi University)

J. H. Hong (National Cheng Kung University)

P. H. Hsu (National Taiwan University)

T. A. Teo (National Yang Ming Chiao Tung University)

Y. C. Chuang (Feng Chia University)

C. L. Kuo (National Dong Hwa University)

W. Chen (National Taipei University of Technology)

K. H. Chen (National Taipei University)

C. T. Chen (National Pingtung University of Science and Technology)

K.H. Tseng (National Central University)

C. Y. Huang (National Taiwan University)

F. Tsai (National Central University)

J. D. Tsai (National Chung Hsing University)

T. C. Su (National Quemoy University)

C. Stewart (The Ohio State University) (USA)

M. Matsuoka (Tokyo Institute of Technology) (Japan)

T. Kim (Inha University) (South Korea)

封面照片說明 About the Cover

圖為南投縣仁愛鄉計算 2017 年衛星雷達影像 PS-InSAR 與 SBAS-InSAR 成果之地表形變方向累積量值，旨在量化並識別區域內地表形變之長期主導方向及趨勢強度，最終得到的累積變化次數可反映地表形變趨勢，顯著的正值表示該地區具有持久的抬升情形，而顯著的負值則揭示持續的沉降變化。此外，該呈現方式能有效濾除區域中短期或隨機的形變干擾，提取出地表之長期演變動態，對於構造活動等地質災害監測與預警，具有重要的科學應用價值。

比較 PS-InSAR 與 SBAS-InSAR 技術應用於監測山區地表變位 – 以仁愛鄉為例

施竣仁¹ 莊忠翰² 蔡慧萍^{3*}

摘要

傳統崩塌監測技術與儀器受空間限制，本研究應用遙感之合成孔徑雷達干涉技術(Interferometric Synthetic Aperture Radar, InSAR)實現山區地表變位大範圍監測，採用永久散射體雷達干涉(Persistent Scatterer InSAR, PS-InSAR)與短基線子集差分干涉法(Small Baseline Subset-InSAR, SBAS-InSAR)，以臺灣南投縣仁愛鄉為示範區，透過 2017 年間 Sentinel-1A 衛星共 30 幅升軌雷達影像，比較兩種多時序 InSAR 成果於地表變位監測的適用性，並與全球導航衛星系統(Global Navigation Satellite Systems, GNSS)數據進行相關性分析。結果顯示，PS-InSAR 及 SBAS-InSAR 在 LSAN 測站皆呈現顯著正相關，相關係數分別為 0.486 及 0.399，均方根誤差為 5.004 mm 及 7.685 mm。SBAS-InSAR 能有效反映山區之實際崩塌空間分布與地表變位情況，顯示該技術對山區崩塌監測更具優勢。

關鍵詞：多時序合成孔徑干涉雷達、永久散射體雷達干涉、短基線子集差分干涉、地表變位

1. 前言

近年全球受到氣候變遷加劇影響，導致強降雨、颱風及嚴重乾旱等極端氣候事件頻率上升，進而使洪水、坡地災害及旱災成為常見的自然災害類型。其中，坡地上的土石為坡地災害的主要物質來源，當受到地震、孔隙水壓等外力作用下，易引發崩塌或液化，對當地生態環境、地表地形造成顯著不可逆轉的擾動(Wang *et al.*, 2024)。小規模的崩塌常伴隨地表覆蓋類型及植被的快速轉變(Promper *et al.*, 2014、Alcántara-Ayala *et al.*, 2006)，而大範圍的山體崩塌可能破壞區域生態系統的穩定性(Schuster & Highland, 2003)。根據美國國家航空太空總署(National Aeronautics and Space Administration, NASA)所建立的全球崩塌目錄(Global Landslide Catalog)指出，於 2014 年至 2022 年間共紀錄 9,733 起崩塌事件，對生命及經濟造成巨大損失(Froude &

Petle, 2018)，其中以亞洲地區所受影響最為嚴重(Abancó *et al.*, 2021、Ozturk *et al.*, 2022、Konishi & Suga, 2018、Lin & Wang, 2018、Nolasco-Javier & Kumar, 2018)。臺灣位處於環太平洋地震帶，崩塌潛勢極高，且地震頻繁造就複雜的地形與地質，島內山坡地面積佔總土地面積約 74%，約 2,683,770 公頃(ha)。此外，臺灣屬於副熱帶季風氣候區，年平均降雨量達 2,500 毫米，且雨季集中於五月至九月的梅雨與颱風季節，降雨時空分布不均。受限於環境和氣候條件，臺灣山區常有小規模或大範圍的地表岩體、土石滑落的地質災害(Giletycz *et al.*, 2021)，對當地居民的財產和生命構成威脅。因此，針對山坡地災害之監測、預警和預測，已成為防災應變策略中不可或缺的重要目標。

傳統邊坡監測技術常根據破壞型態與監測目的選擇合適儀器與方法。邊坡監測儀器依照潛在災害類型進行規劃設計，常見的儀器包括傾斜觀測管、

¹ 國立中興大學土木工程學系 碩士

² 國立中興大學土木工程學系 博士生

³ 國立中興大學土木工程學系 副教授

* 通訊作者, E-mail: huiping.tsai@nchu.edu.tw

收到日期：民國 114 年 05 月 16 日

修改日期：民國 114 年 06 月 30 日

接受日期：民國 114 年 07 月 18 日

地表伸縮計、孔內伸縮計、地表傾斜計及裂縫計，以此直接量測地表的變形量。根據山坡地監測準則所述，監測方式可分為人工、半自動及全自動三種，主要考慮邊坡的危害性、預算和現地條件。儘管上述方法具高準確性，但受限於布設範圍有限且成本高，難以進行大面積監測，限制其應用的可能性。

隨著現代遙測技術進展與時空解析度的提升，結合遙感數據、數值模型和崩塌影響因子，成為克服傳統監測限制的策略。空載和地面平台已廣泛應用於監測地表變形與評估災害風險(Zhao & Lu, 2018)。其中，合成孔徑雷達干涉(Interferometric synthetic aperture radar, InSAR)技術憑藉其全天候、遠程高精度獲取細微地表形變特性，克服傳統監測方法的局限，在崩塌監測中扮演重要角色(Zhou *et al.*, 2025)；此外，衍生發展的合成孔徑雷達差分干涉技術(Differential InSAR, D-InSAR)，利用雷達所採集的相位分析地表隨時間的變化，對於獲取地表垂直形變資訊具有貢獻(Maddahi *et al.*, 2024)。D-InSAR 技術分析不同時間的 SAR 影像，以此估算合成孔徑雷達視距方向(Line of sight, LOS)的高精度地表形變量，於理想條件下其精度可達公分(cm)等級(Massonnet *et al.*, 1995、Amelung *et al.*, 2000、Hung *et al.*, 2010)。然而，對於緩慢變形監測而言，基線時間過長及地表特徵劇烈變化，易導致影像同調性降低，影響干涉結果的準確性(Pathier *et al.*, 2003、Hoffmann, *et al.*, 2003)。

為克服上述限制，基於 D-InSAR 技術發展出永久散射體雷達干涉 (Persistent scatterer interferometric synthetic aperture radar, PS-InSAR)技術(Ferretti *et al.*, 2000)及短基線子集差分干涉法 (Small baseline subset-interferometric synthetic aperture radar, SBAS-InSAR)技術(Berardino *et al.*, 2002)。PS-InSAR 技術解算多時期影像中穩定且相關性高的永久散射點(persistent scatterer)，進行相位解纏(unwrapping)並分析其形變時間序列，已被證實其可有效降低非相關性及獲得具有更高可信度的長時間地表變形(Ferretti *et al.*, 2004)。此外，Hooper *et al.* (2004)改進 PS-InSAR 技術，可不用加入當地的線性平均地表變形場，即可計算地表形變

量，亦對於地表變形較不規則的地區，仍可有效獲得地表變形量(Hooper *et al.*, 2007)。SBAS-InSAR 技術則是選取相對較短的時空基線影像組合，以提升干涉精度與穩定性，同時降低相干性問題的影響，取得有效的時間序列形變量。Berardino *et al.* (2002)用 SBAS-InSAR 方法觀測義大利 Campi Flegrei 的火山，結果顯示地表變形量與 GNSS 資料高度相關。而 SBAS-InSAR 技術已逐漸成為提取時間序列地表形變最具代表性的技術之一(Tizzani *et al.*, 2007、Dong *et al.*, 2014、Zhao *et al.*, 2016、Novellino *et al.*, 2017)。

近年來，多項研究證實多時序合成孔徑雷達技術於地表變形與災害監測的可行性與應用潛力。Hussain *et al.* (2025)對巴基斯坦的公路山體滑坡進行災害監測，結合 PS-InSAR 與 SBAS-InSAR 技術，克服散射體分布稀疏與誤差累積的侷限性，結果顯示綜合兩種技術能有效識別出 36 處的潛在滑坡，年平均地表位移速率約從 57 mm (抬升)至-146 mm (下沉)。Crippa *et al.* (2021)整合 PS-InSAR 和 SqueeSAR 數據集，提出一種半自動分類法以識別緩慢變形的岩石邊坡區域；Shih *et al.* (2022)利用 PS-InSAR 識別流域大尺度的地形變形區。Defontaine *et al.* (2019)結合無人飛行系統獲得的數值地形模型(Digital terrain model, DTM)以及 PS-InSAR 技術，監測 2007 至 2011 南恆春半島的斷層活動。Hsu *et al.* (2015)整合多項監測資料與 PS-InSAR 成果，指出雲林縣境內的下陷速率深度達 7.1 cm/year，並揭示降雨量顯著影響淺層的地下水位，且此現況與地層下陷密切相關。Yang *et al.* (2019)以 SBAS-InSAR 方法，觀測雲林地區 2016 年 4 月至 2017 年 4 月的地層下陷。Zhao *et al.* (2012)基於 SBAS-InSAR 方法使用多時相 ALOS/PALSAR 影像，監測美國加州北部和俄勒岡州南部的活動崩塌及其變形，結果表明崩塌與降水量有關。

本研究以崩塌災害頻仍的臺灣中部南投縣仁愛鄉為研究區域，該鄉鎮近年因諸多環境及自然災害備受關注。2009 年莫拉克颱風造成該鄉鎮 1.8% 崩塌率(Wu *et al.*, 2011)，且統計報告指出，2015 年至 2017 年間的崩塌事件呈現快速上升趨勢，尤以

地質脆弱的投 89 線道力行產業道路為甚。此外，由於仁愛鄉地勢陡峭，傳統監測技術難以有效掌握地表形變，因此需結合其他科學化技術監測該區域的坡地變化，降低坡地災害的風險並強化人民對於自然災害的認知及應變能力和韌性措施。研究使用 Sentinel-1A 衛星於 2017 年間共 30 幅的雷達影像，並以永久散射體雷達干涉技術(PS-InSAR)及短基線子集差分干涉法(SBAS-InSAR)監測研究區域內的地表形變量。本研究的目的為：(1)以 PS-InSAR 及 SBAS-InSAR 獲取 2017 年間南投縣仁愛鄉的地表變位資訊；(2)分析 PS-InSAR 及 SBAS-InSAR 對於監測仁愛鄉的地表變化之異同，並將結果以現地之 GNSS 觀測量進行檢核，探討對於臺灣山區的地表變位情形及相關測量技術應用的可行性。

2. 材料與方法

2.1 研究流程

本研究流程如圖 1 所示。首先選定南投縣仁愛鄉作為研究區域，並蒐集研究區域內 2017 年 Sentinel-1 衛星之上升軌道雷達影像，以及設置於區域內的 GNSS 連續接收站長期監測數據。後續使用 ENVI SARscape v5.6.2(Exelis Visual Information Solutions, Boulder, CO, USA)軟體以兩種 InSAR 解算方法進行影像前處理，分別為 PS-InSAR 與 SBAS-InSAR，並搭配 SRTM-1 的數值高程模型(Digital Elevation Model, DEM)進行影像數值地形對位(Co-registration)，進而獲得具有時間序列的地表形變量。接著，將 GNSS 連續接收站的三維位移數據以投影公式轉換與雷達衛星觀測一致之視衛星(Line of Sight, LOS)方向，並針對 InSAR 資料與轉換後的 GNSS 位移量進行相關性分析與誤差評估。最終，結合政府公開之崩塌事件驗證兩種 InSAR 解算技術應用於監測山區地表變位的適用性。

2.2 研究區域

本研究區域為臺灣中部的南投縣仁愛鄉。仁愛鄉位於南投縣東部，為全臺灣面積第三大的鄉鎮級行政區，北界臺中市和平區，東鄰花蓮縣萬榮鄉及

秀林鄉，西側接南投縣魚池鄉、埔里鎮和國姓鄉，南鄰南投縣信義鄉，其地理位置如圖 2 所示。該鄉鎮總面積約為 1273.5km²，地勢起伏明顯，海拔介於 402 m 至 3570 m 間，其中約 52.8%的面積分布於 1000 m 至 2000 m 之間；坡度主要為三級坡和四級坡間，合計佔總面積的 74.22%；坡向分布平均，以北向(14.34%)及西南向(14.82%)所占比例最高。本研究針對仁愛鄉的土地利用狀況，使用 Impact Observatory 技術公司所開發的深度學習土地分類模型進行判釋，也比對國土測繪中心之土地利用圖，作為後續研究分析之參考依據；分類類別包含水體、森林、農作物、建物、裸露地和草地，其中以森林面積最廣，佔整個仁愛鄉總面積的 9 成(圖 3)。

2.3 GNSS 連續接收站觀測量

全球導航衛星系統(Global Navigation Satellite Systems, GNSS)可用於精確量測地理坐標位置，透過長期連續觀測資料提供地殼微量變動之定量資訊。本研究使用中央研究院地球科學研究所提供的 GNSS 連續接收站(以下稱 GNSS 測站)資料，該資料集已整合於臺灣 GNSS 連續觀測網平台上，目前總測站數超過 360 站。平台提供之 GNSS 觀測資料已完成去雜訊處理，解算出各測站每日 ITRF2005 坐標，可應用於偵測各地微小的地形變化。分析項目涵蓋年週期及半年週期變化量、同震位移量、震後變形與地殼運動速度及其誤差值。本研究選用仁愛鄉境內於 2017 年具有連續觀測資料的 6 處 GNSS 測站，分別為合歡山(HUAN)、惠蓀林場(HUYS)、梅峰(MFEN)、高峰(KFN2)、廬山(LSAN)、翠峰(FB02)，各接收站資訊如表 1 所示。

表 1 GNSS 連續接收站資訊

GNSS 測站名稱	代號	提供單位
合歡山	HUAN	交通部中央氣象署
惠蓀林場	HUYS	交通部中央氣象署
梅峰	MFEN	交通部中央氣象署
高峰	KFN2	內政部國土測繪中心
廬山	LSAN	中央研究院地球科學研究所
翠峰	FB02	農業部林業及自然保育署

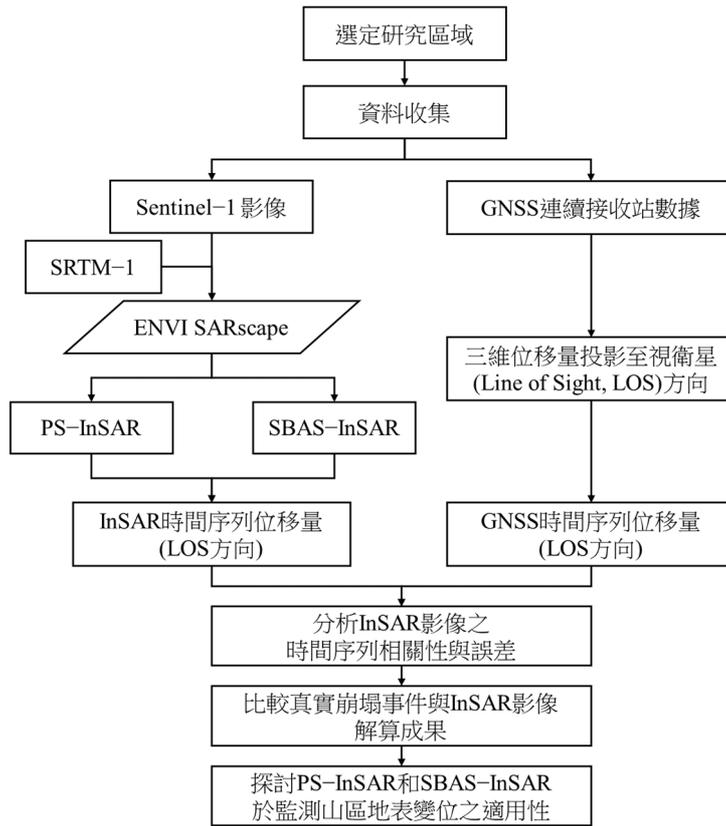


圖 1 研究流程圖

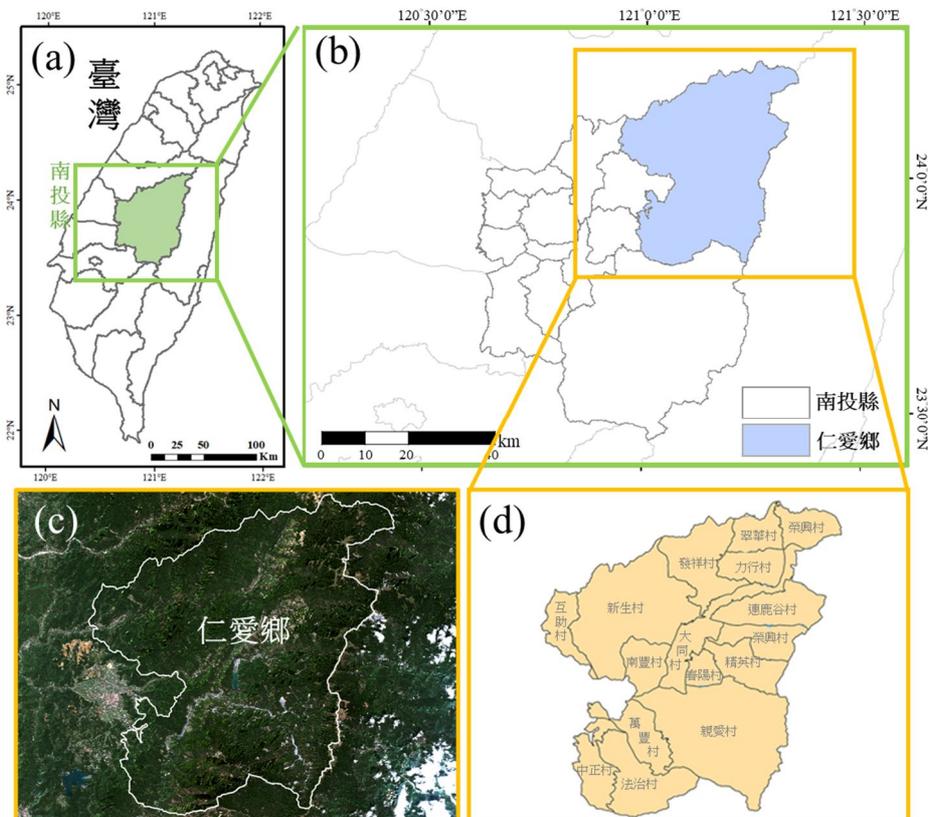


圖 2 南投縣仁愛鄉地理位置圖，(a)南投縣地理位置圖、(b)南投縣鄉鎮分布圖、(c)仁愛鄉之 Sentinel-2 衛星影像、(d)仁愛鄉之村里分布圖

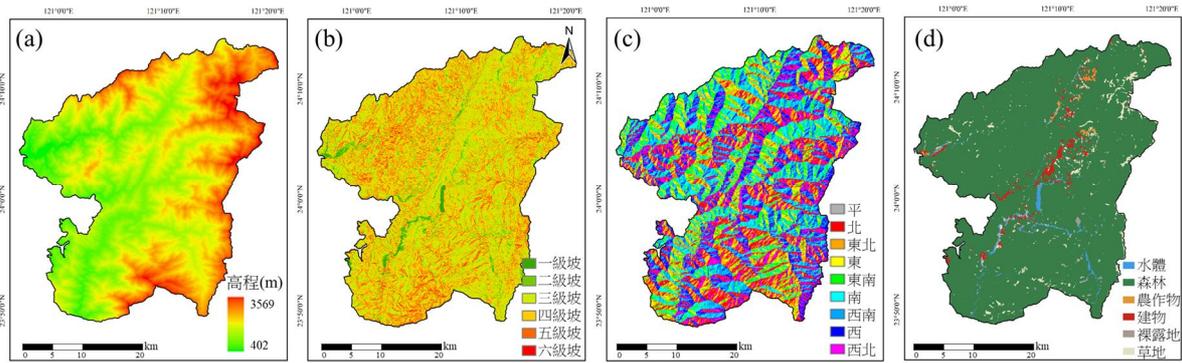


圖 3 南投縣仁愛鄉之(a)高程、(b)坡度、(c)坡向及(d)土地利用分布圖

GNSS 測站所測得之地表形變量由三個正交方向之位移組成，分別為東方(East, E)、北方(North, N)及垂直(Vertical, V)方向，水平與垂直方向的位移量可用於解釋和判讀地球表面之物理現象。然而，合成孔徑雷達干涉技術所衍生之地表位移是沿視衛星方向(LOS)的一維位移量，因此，為有效與 InSAR 和 GNSS 觀測資料進行一致性分析與驗證，須將 GNSS 觀測量轉換成 LOS 方向再與 InSAR 結果進行比較與分析，其投影公式如下：

$$GNSS_{LOS} = \sin \alpha \cdot \sin \theta \cdot N - \cos \alpha \cdot \sin \theta \cdot E + \cos \theta \cdot V \dots\dots\dots(1)$$

算式中 $GNSS_{LOS}$ 為視衛星方向的形變量， E 、 N 、 V 分別為東方、北方及垂直方向的形變量， α 及 θ 分別為沿軌道之方位角與衛星入射角。

2.4 Sentinel-1 衛星數據

Sentinel-1 衛星是由歐洲太空總署(European Space Agency, ESA)和義大利泰雷茲阿萊尼亞空間公司(Thales Alenia Space)協同建造，旨在執行哥白尼計畫之地球觀測任務，對地球表面之地表運動、土地覆蓋變化、海洋環境進行長期的監測。此星座衛星由 Sentinel-1A 與 Sentinel-1B 組成，皆運行太陽同步軌道，軌道高度為 693 km，兩者位置間隔 180 度角運行。單一衛星可每 12 日重複觀測同一區域，若兩顆衛星同時運作，則可將觀測周期縮短至 6 日。

Sentinel-1 搭載 C 波段的合成孔徑雷達感測器，具備全天候全天時的觀測能力，並以超寬測繪帶(約

400 km)拍攝高空間解析度影像。衛星搭載四種操作模式收集不同空間解析度的影像，分別為 Stripmap Mode (SM)、Interferometric Wide Swath Mode (IW)、Extra Wide Swath Mode (EW)、Wave Mode (WV)。其中，前三者可提供單極化或雙極化影像，而 WV 僅提供單極化影像。參考前人研究，臺灣地區受地形與雷達視角影響，採用升軌影像產出 InSAR 成果品質較佳(楊苡絮, 2018)。本研究統整農業部產製之事件型崩塌目錄及農業部農村發展及水土保持署(以下簡稱水保署)之「土石流及大規模崩塌防災資訊網」統計資料，發現 2017 年為本研究區域山坡地災害通報件數高峰年度之一，災情分布與坡地密切重疊。因此，本研究使用 Sentinel-1A 的上升軌道雷達影像(圖 4)，並選擇 2017 年作為代表性年度之災害分析，雷達影像收集期間自 2017 年 1 月 3 日至 2017 年 12 月 29 日，影像獲取週期為 12 天，共計 30 幅影像。選用之影像產品為 Level-1 之 IW 模式的單一視角複數資料(Single Look Complex, SLC)，其產品規格如表 2 所示。

表 2 本研究所使用 Sentinel-1 產品規格

項目	說明
軌道衛星	Sentinel-1A
影像等級	Level-1
飛行方向	上升軌道(Ascending)
採集模式	干涉寬幅模式(IW)
極化方式	VV 極化
影像波段	C 波段
回訪週期	12 天
軌道數據	69



圖 4 研究使用 Sentinel-1A 升軌影像擷取範圍

SBAS-InSAR 地表變位提取技術進行說明。PS-InSAR 技術的處理過程可分為四個主要步驟，具體過程如圖 5 所示。首先，研究選用 2017 年 7 月 14 日之影像作為超級主影像(Super master image)，設定最大時間基線為 180 天，並由超級主影像生成 29 對干涉對之時空基線圖(圖 6)，產生的空間基線主要分布在 -80~115 m 之間。接著基於 PS 候選點的差分干涉處理，推導出線性變形和高程誤差，進而獲得殘差相位圖，並進行大氣延遲和軌道相位誤差校正，擷取出地表變形之時間序列，包含線性和非線性變形分量。於第一次反演階段，使用線性模型推估殘差高度和變形速度。根據振幅分散指數，從每個 25 km² 子區域中選擇參考點，並將所有子區域的結果拼接，以建立完整之變形場。於第二次反演中，依前一階段成果估算大氣相位延遲，並使用時間高通濾波器(365 天)和空間低通濾波器(1200 m)去除大氣相位成分，最終獲得具時間序列之變形結果與速率圖層。

2.5 雷達影像前處理

本研究使用 ENVI 軟體的 SARscape v5.6.2 進行雷達影像前處理，並依據 PS-InSAR 和

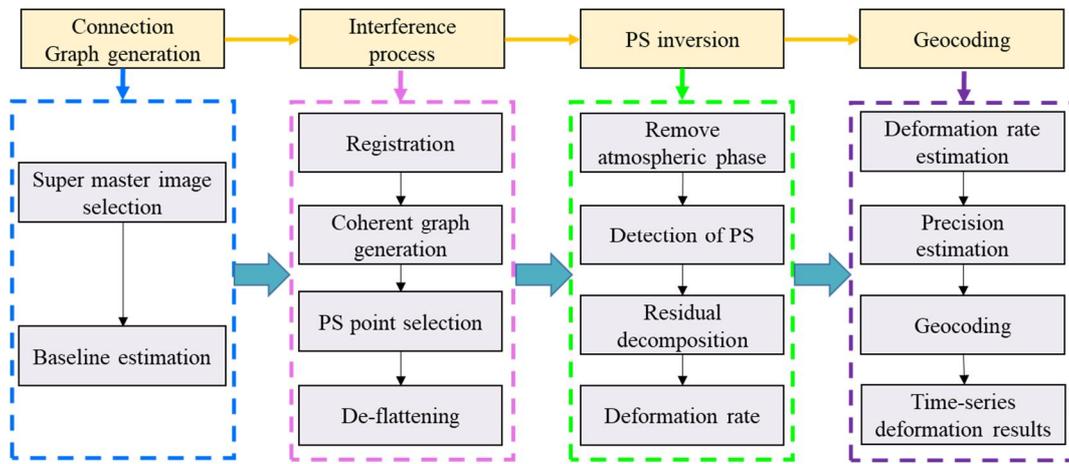


圖 5 PS-InSAR 基本流程圖 (改繪自 He et al., 2021)

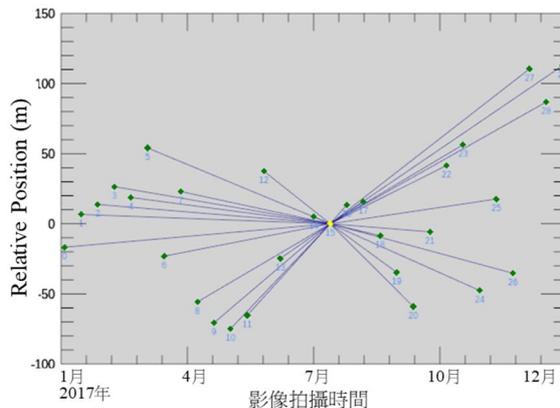


圖 6 以 PS-InSAR 生成之干涉對連接圖之時空基線圖

SBAS-InSAR 處理有四個主要步驟，詳細過程如圖 7 所示。首先，需進行基線估算並生成連接圖，本研究由系統自動選擇 2017 年 7 月 26 日的影像作為超級主圖像，設定最大時間基線為 180 天，進而生成各干涉對之空間與空間基線圖。接著需結合數值高程模型(Digital Elevation Model, DEM)進行地形校正以去除地形高程，獲得平坦地球相位。本研究選用 NASA 和國家地理空間情報局(National Geospatial-Intelligence Agency, NGA)產製之太空梭雷達地形測量任務(Shuttle Radar Topography Mission, SRTM)，使用 SRTM-1 version 3 作為地形校準的 DEM，空間解析度為 1 弧秒(約 30 m)。隨後，於範圍和方向向採用 4×1 多視角干涉處理，應用 Goldstein 濾波方法(Zebker & Villasenor, 1992)提升干涉圖的訊噪比(Signal to noise ratio, SNR)，並對

相位信號進行相位展開，捨棄相干性低或相位展開誤差大的干涉圖對(Chen *et al.*, 2013)，共計生成 126 對差分干涉圖(圖 8)。在 SBAS-InSAR 的反演過程中，選取高穩定性的地面控制點(Ground control points, GCPs)計算殘餘相位和相位斜率。本研究根據展開相位選擇變形量趨近於零的 GCPs(Ghulam *et al.*, 2015)，共納入 20 個 GCPs 以修正軌道誤差和變形反演，並以線性模型估計初始變形去除殘餘地形效應；為去除殘餘的大氣擾動和噪聲成分，利用最小二乘法和奇異值分解進行殘差相位校正，再結合多組小基線數據以推算地表變形的時間序列。為進一步提高變形的監測精度，處理中亦採用時間域高通濾波和空間域低通濾波去除大氣影響。最終對第一次和第二次 SBAS-InSAR 反演結果進行地理編碼，去除虛擬值並對變形結果進行插值。

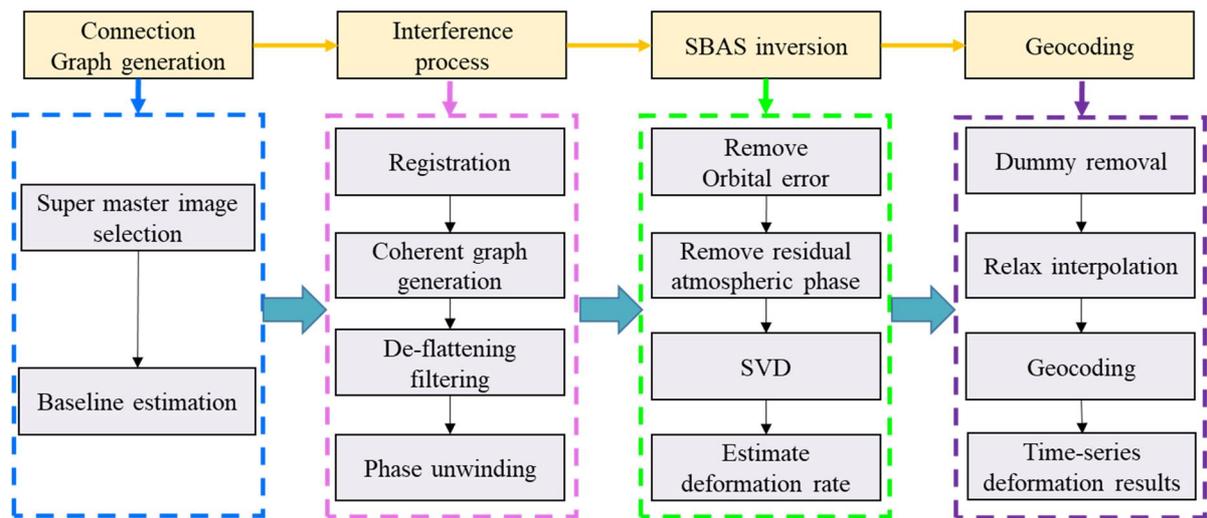


圖 7 SBAS-InSAR 基本流程圖(改繪自 He *et al.*, 2021)

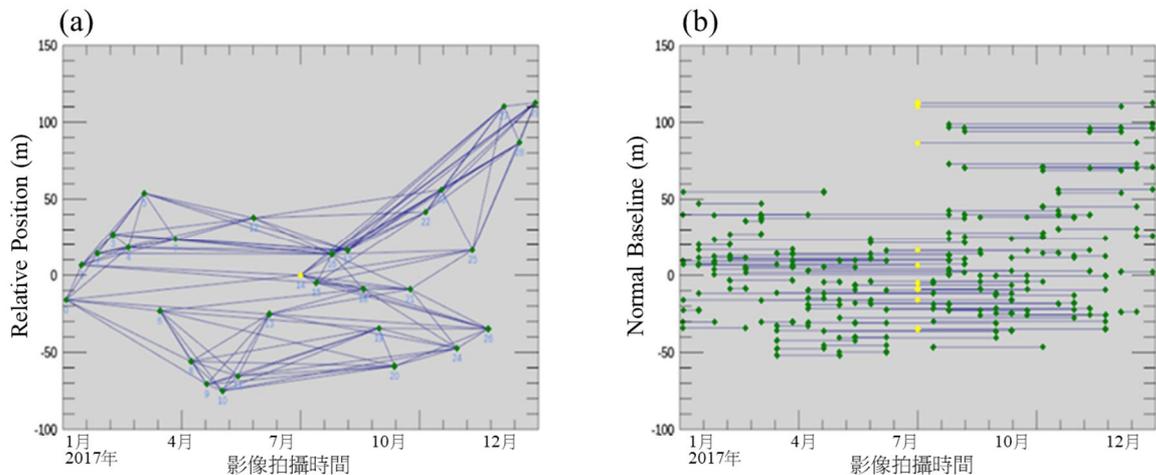


圖 8 以 SBAS-InSAR 生成之干涉對連接圖(a)時空基線圖及(b)時間基線圖

2.6 相關性分析及誤差指標

為分析 PS-InSAR 與 SBAS-InSAR 推估的地表位移量與 GNSS 測站所觀測之形變量的相關性，使用 IBM SPSS Statistics 20 (IBM, Armonk, New York, USA)軟體將 InSAR 結果與各 GNSS 測站之觀測量進行皮爾森相關性分析。其用於探討兩連續變數間的線性相關性，若兩變數間得出之相關係數絕對值越大者，表示兩者之相互共變的程度亦較大。皮爾森相關係數計算公式為：

$$r(x, y) = \frac{COV(x, y)}{S_x S_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \dots\dots (2)$$

式中 r 為相關係數，數值介於-1 到+1 之間， COV 為共變數， x_i 、 y_i 分別為 x 與 y 第 i 個參數數值， \bar{x} 為 x 的平均數， \bar{y} 為 y 的平均數。

此外，使用均方根誤差(Root mean square error, RMSE)評估 PS-InSAR 和 SBAS-InSAR 與 GNSS 測站之觀測量間差異。RMSE 可用於衡量模型預測值與實際觀測值間絕對偏差，提供以原變數為單位的平均模型誤差量。RMSE 為負向分數指標，數值越低表示擬合程度越佳。RMSE 公式如下：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \dots\dots\dots (3)$$

式中 y_i 為 GNSS 連續接收站之觀測值， \hat{y}_i 為 InSAR 的觀測值，而 n 表示觀測值之總數量。

2.7 仁愛鄉崩塌目錄

為驗證 InSAR 技術所推估之地表變位分布的準確性與適用性，本研究以兩種災害資料集做為參考依據並驗證其成果，分述如下：

- (1)彙整水保署之「土石流及大規模崩塌防災資訊網」統計資料，選取 2017 年造成仁愛鄉之重大災害事件，作為實際地質災害發生之時空依據，各災害事件時間與崩塌面積如表 3 所示。
- (2)套疊農業部產製 106 年事件型崩塌目錄，進行空間比對；該崩塌圖層是採用水保署災後衛星影像判釋崩塌地圖層和農業部林業及自然保育署衛星判釋全島崩塌地圖層所建置的災後崩塌圖所繪製而成，崩塌分布位置如圖 9 所示。

3. 結果與討論

3.1 GNSS 連續接收站之位移量轉換

Sentinel-1A 衛星於通過南投縣仁愛鄉上空進行影像擷取時，其升軌方向之入射角(θ)為 38.88°，軌道方位角(α)為 347.569°。依據衛星的幾何方位，代入投影公式計算東西向(E)、南北向(N)及垂直向(V)之三維方向的影響係數(表 4)。本研究選定 6 處位於仁愛鄉境內的 GNSS 測站，計算 E、N、V 三方向的年形變量，以及依投影公式換算 LOS 方向的觀測量，以利與 InSAR 結果進行比對，所統計之時間區間與 InSAR 影像資料之觀測時間一致，其結果如表 5 所示。

表 3 2017 年南投縣仁愛鄉崩塌事件

事件時間	事件名稱	崩塌面積 (公頃 ha)
06/01	0601 豪雨	91.72
06/13	0613 豪雨	61.83
07/29-07/31	尼莎颱風、海棠颱風	42.83
08/01	0801 豪雨	66.37
10/12	1012 豪雨	84.26

表 4 E、N、V 於 LOS 方向之影響係數

方向	投影公式	影響係數
E	$-\cos \alpha \cdot \sin \theta$	-0.613
N	$\sin \alpha \cdot \sin \theta$	-0.135
V	$\cos \theta$	0.778

表 5 GNSS 連續接收站三維方向於 LOS 方向之觀測量

接收站 代號	E 方向速率		N 方向速率		V 方向速率	
	原始觀測量	LOS 觀測量	原始觀測量	LOS 觀測量	原始觀測量	LOS 觀測量
HUAN	17.577	-10.775	7.172	-0.969	4.432	3.450
HUYS	9.903	-6.071	-0.555	0.075	0.433	0.337
MFEN	4.395	-2.694	5.483	-0.741	-2.229	-1.735
KFN2	-0.376	0.231	3.545	-0.479	6.246	4.862
LSAN	9.011	-5.524	-1.697	0.229	-2.601	-2.025
FB02	12.198	-7.477	3.049	-0.412	3.500	2.724

單位：mm/year

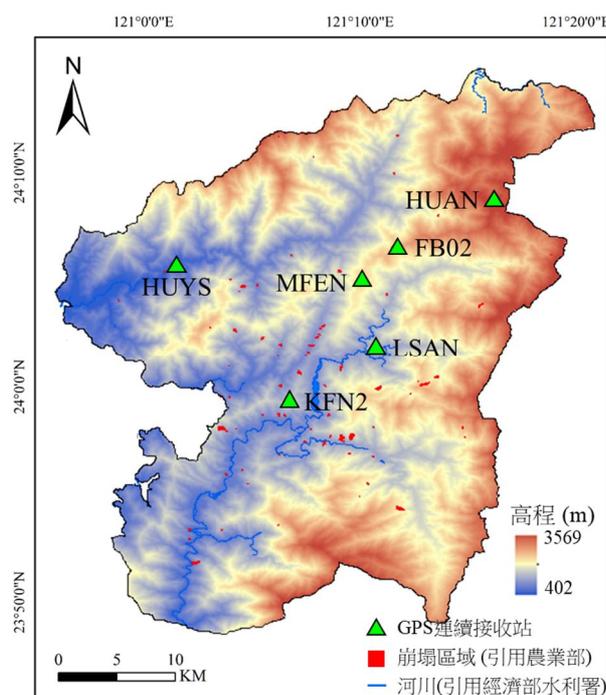


圖 9 南投縣仁愛鄉 2017 年崩塌事件分布圖

3.2 雷達影像地表位移平均速率

本研究分別應用 PS-InSAR 與 SBAS-InSAR 技術，收集 30 幅 Sentinel-1A 於 2017 年期間之南投縣仁愛鄉升軌雷達影像，並以 20 m 矩形之網格解析度計算地表位移平均速率，如圖 10 所示。PS-InSAR 解算結果顯示，研究區域內約有 49.3% 的像素呈現沉降趨勢，50.3% 的像素則顯示為抬升。其中，沉降速率較顯著的區域集中於仁愛鄉中部區域之建物區域，抬升則主要分布於河道周圍區域。相較之下，SBAS-InSAR 解算成果則顯示約有 44.4% 的像素呈現沉降，55.4% 的像素為抬升，沉降現象多分布於仁愛鄉中部及西北部之建物及草地區域，主要抬升區域則位於東北側和南部區域近河道地區。

3.3 時間序列比較

為便於觀察研究期間各時期的地表位移之變化趨勢，本研究以首幅影像(2017 年 1 月 3 日)作為基準，將其位移量設定為零，其餘影像則依此幅影像計算相對位移量。圖 11 為地表形變趨勢之方向持久性(directional persistence)指標，透過經驗設定感興趣的閾值，觀測 PS-InSAR 與 SBAS-InSAR 技術於時間序列累積變化方向的度量(Tsai *et al.*, 2014、Waylen *et al.*, 2014)，亦即當某一像素在某一時間的形變量為抬升，則該像素累加 1，反之為下沉則減 1，此分析方法有助於快速辨識研究區域內長期地表形變的主導方向(抬升或沉降)與趨勢強度。圖 12 則呈現每幅影像中抬升與沉降的像素總數量，以及兩種形變方向上之平均位移量。整體而言，兩種

InSAR 技術在仁愛鄉中部建成區，皆呈現一致且明顯的地表沉降趨勢，而在西南側與東南側河道，觀察到明顯的抬升情形，可能與沉積堆疊有關。然而，在大同村的東北側與互助村(村里位置參照圖 2)中部一帶，兩種 InSAR 技術之結果出現明顯的不一致，推測與兩種 InSAR 技術在偵測形變敏感度上之差異。PS-InSAR 於高變動或植被密集區易出現相干性不足，相較之下，SBAS-InSAR 更能擷取到 PS-InSAR 所忽略的形變訊號。綜合而言，兩種技術在空間的形變偵測能力，受到地表植被密度、環境擾動程度影響，仍可能出現結果歧異。此也揭示後續研究可收集地質、地下水等現地資料佐證，提升 InSAR 技術於地表變位監測的準確性與解釋力(圖 11)。

分析 PS-InSAR 技術之成果，在兩種形變方向上的平均像素數量約為 1330 ± 80 個，變位分布均勻，且平均位移量也呈現穩定的沉降與抬升，介於 -30mm 至 30mm 之間。其中，沉降幅度較大(-20mm 至 -30mm)的區域集中於仁愛鄉中部大同村和春陽村；抬升幅度較明顯(20mm 至 30mm)的地區則分布於仁愛鄉西部互助村。統計結果顯示，PS-InSAR 技術之抬升約佔 56%而沉降約佔 32%，其餘約 12%無明顯變形(圖 13)。在 SBAS-InSAR 技術的觀測結果中，2017 年 10 月前的沉降變動顯著且更為劇烈，沉降像素數量達 1619 個，抬升則為 406 個，此結果顯示 SBAS-InSAR 局部區域的形變更敏感。沉降變化劇烈的區域位於仁愛鄉中部以北地區，數值範圍達 -30mm 至 -50mm ，而抬升幅度較大的地區則於仁愛鄉中部以南的地區(圖 14)。進一步觀察時間趨勢，發現仁愛鄉在 3 月過後的沉降速率具有持續增加的趨勢，推測此現象與臺灣進入梅雨與颱風季節有關，降雨的增加、地下水位變動與土壤含水率變化均可能造成地表變動越加顯著。Kim *et al.* (2017) 表示降雨強度與入滲、土壤基質吸力的變化，皆與非飽和土的沉降量具有顯著影響，亦即由本研究所觀測到的 InSAR 地表變位結果，可能反映降雨期間地下水位變化所引起的地層反應。建議後續研究中可綜合分析地下水位資料，以探討地下水位變化與地表變形之關係與潛在風險。

3.4 相關性與誤差分析

為探討 InSAR 技術所推估之地表形變量與 GNSS 測站所觀測位移量之關聯性，本研究以 GNSS 測站為中心，劃設半徑 800 m 範圍，擷取該範圍內各時間點的 InSAR 形變量並計算平均值，作為該測站對應之 InSAR 形變量，進一步與 GNSS 測站的位移量進行皮爾森相關性分析，並計算對應之均方根誤差(RMSE)，如表 6 所示。整體而言，兩種技術在 6 個測站中，共出現 3 次的顯著正相關與 4 次的顯著負相關，顯示 InSAR 技術在不同地形條件之變位趨勢與大小存在差異性。在 PS-InSAR 成果中，所有位於二級坡的測站(HUAN、LSAN 及 FB02)皆呈現顯著相關，且以東南坡向的 LSAN 測站具有最高的顯著正相關(r 為 0.486)，向北坡向的 FB02 測站也為顯著正相關(r 為 0.463)，兩者的 RMSE 分別為 5.004 mm 及 4.206 mm；而 HUAN 測站為顯著負相關(r 為 -0.423)，RMSE 為 14.561 mm，揭示該測站之 InSAR 形變量與 GNSS 位移量明顯背離，但仍存有一定的訊號關聯。在 SBAS-InSAR 成果中，一級坡的 MFEN 測站中呈現最高顯著負相關(r 為 -0.607)，RMSE 為 10.047 mm，以及在二級坡的 FB02 與三級坡的 KFN2 測站呈輕微顯著負相關， r 分別為 -0.363 及 -0.378 ；此外，與 PS-InSAR 結果一致，LSAN 測站均呈現顯著正相關(r 為 0.399)，顯示該測站對兩種 InSAR 技術皆具高度匹配性。綜合而言，唯一未呈現顯著相關的測站為四級坡的 HUYS 測站，於 PS-InSAR 或 SBAS-InSAR 其相關係數接近於零(-0.070 與 -0.166)，推測可能係其森林茂密且地形坡度陡不利於雷達干涉觀測，難以從 InSAR 成果反映實際位移趨勢。

由上述結果顯示，兩種 InSAR 技術於各 GNSS 測站的相關程度並不一致，揭示其可能受限於地形因子、資料時序長度、局部相干性、資料反映的形變範圍。本研究僅對 2017 年單一年度資料進行分析，致使影像反演的地表形變量尚難以顯現穩定關聯。此外，值得關注的是，GNSS 測站測得的位移量為單點精確的變化，InSAR 訊號為平均的面域訊號，兩者在空間解析度上存在根本差異。因此，本

實驗反映兩者數據在短期觀測情境下之匹配程度限制；然而，此結果亦反映出 InSAR 技術在空間尺度觀測的優勢。後續建議可延長收集多年份的連續

資料進行驗證與比對，並納入地下水位、累積降雨等外部因子，進行深度探討與統計分析。

表 6 各 GNSS 接收站地形因子與分析成果

InSAR 方法	接收站代號	坡向	坡度等級	相關係數	RMSE (mm)
PS	HUAN	西北	二	-0.423*	14.561
	HUYS	東北	四	-0.070	5.758
	MFEN	西	一	0.213	7.181
	KFN2	東北	三	-0.290	7.464
	LSAN	東南	二	0.486**	5.004
	FB02	北	二	0.463**	4.206
SBAS	HUAN	西北	二	0.097	12.337
	HUYS	東北	四	-0.166	10.001
	MFEN	西	一	-0.607***	10.047
	KFN2	東北	三	-0.378*	8.119
	LSAN	東南	二	0.399*	7.685
	FB02	北	二	-0.363*	15.052

$p > 0.05$, $*p < 0.05$, $**p < 0.01$, $***p < 0.001$

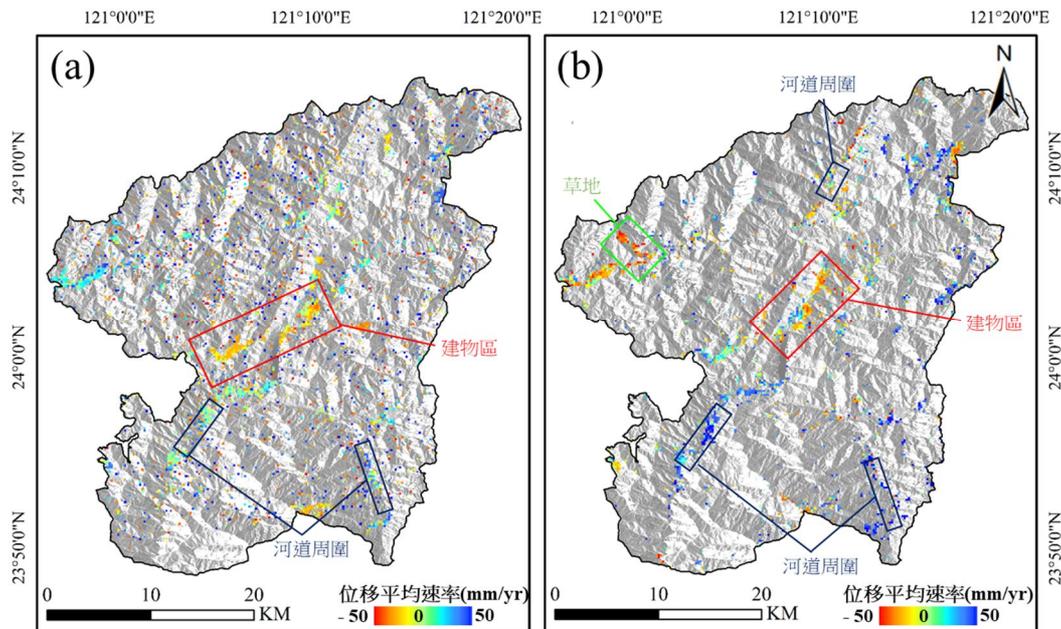


圖 10 南投縣仁愛鄉 2017 年之(a)PS-InSAR 與(b)SBAS-InSAR 地表位移平均速率

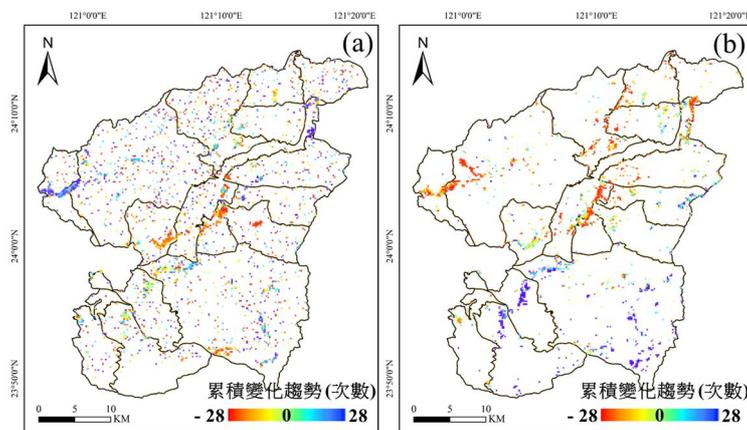


圖 11 (a)PS-InSAR 與(b)SBAS-InSAR 之 2017 年累積變化趨勢空間分布圖

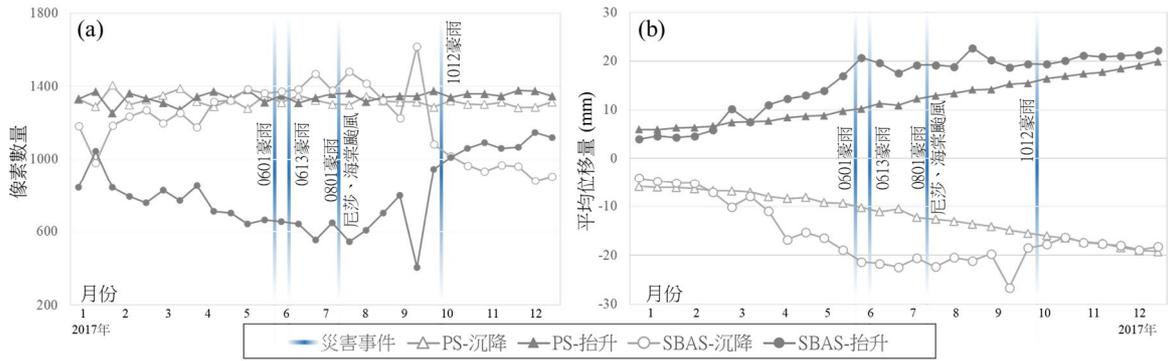


圖 12 研究期間每幅影像沉降與抬升之(a)像素數量與(b)平均位移量

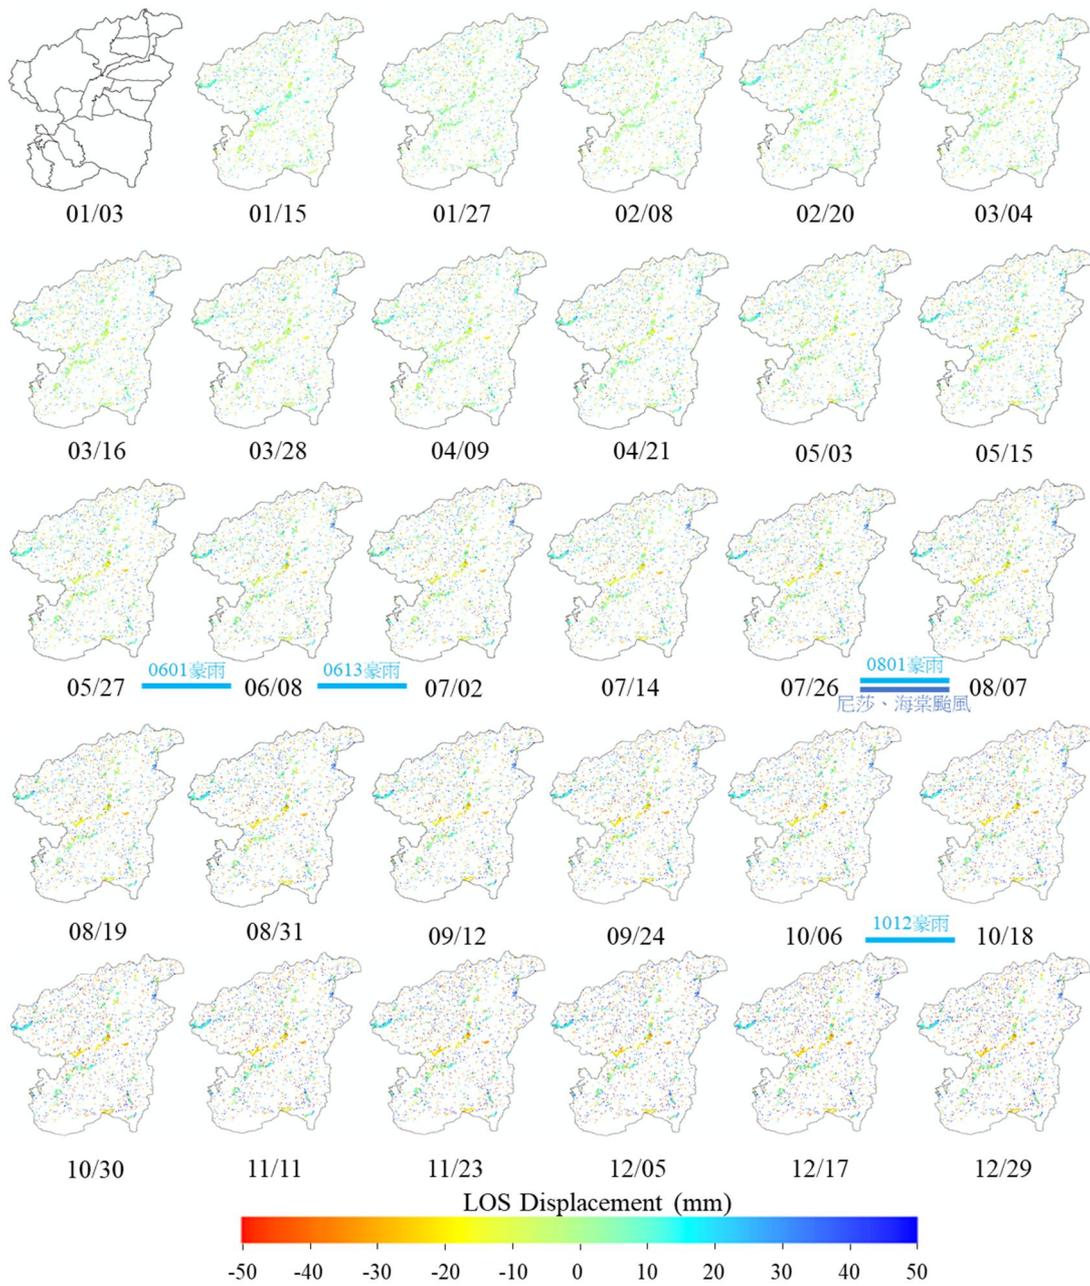


圖 13 南投縣仁愛鄉 2017 年 PS-InSAR 之時間序列成果圖

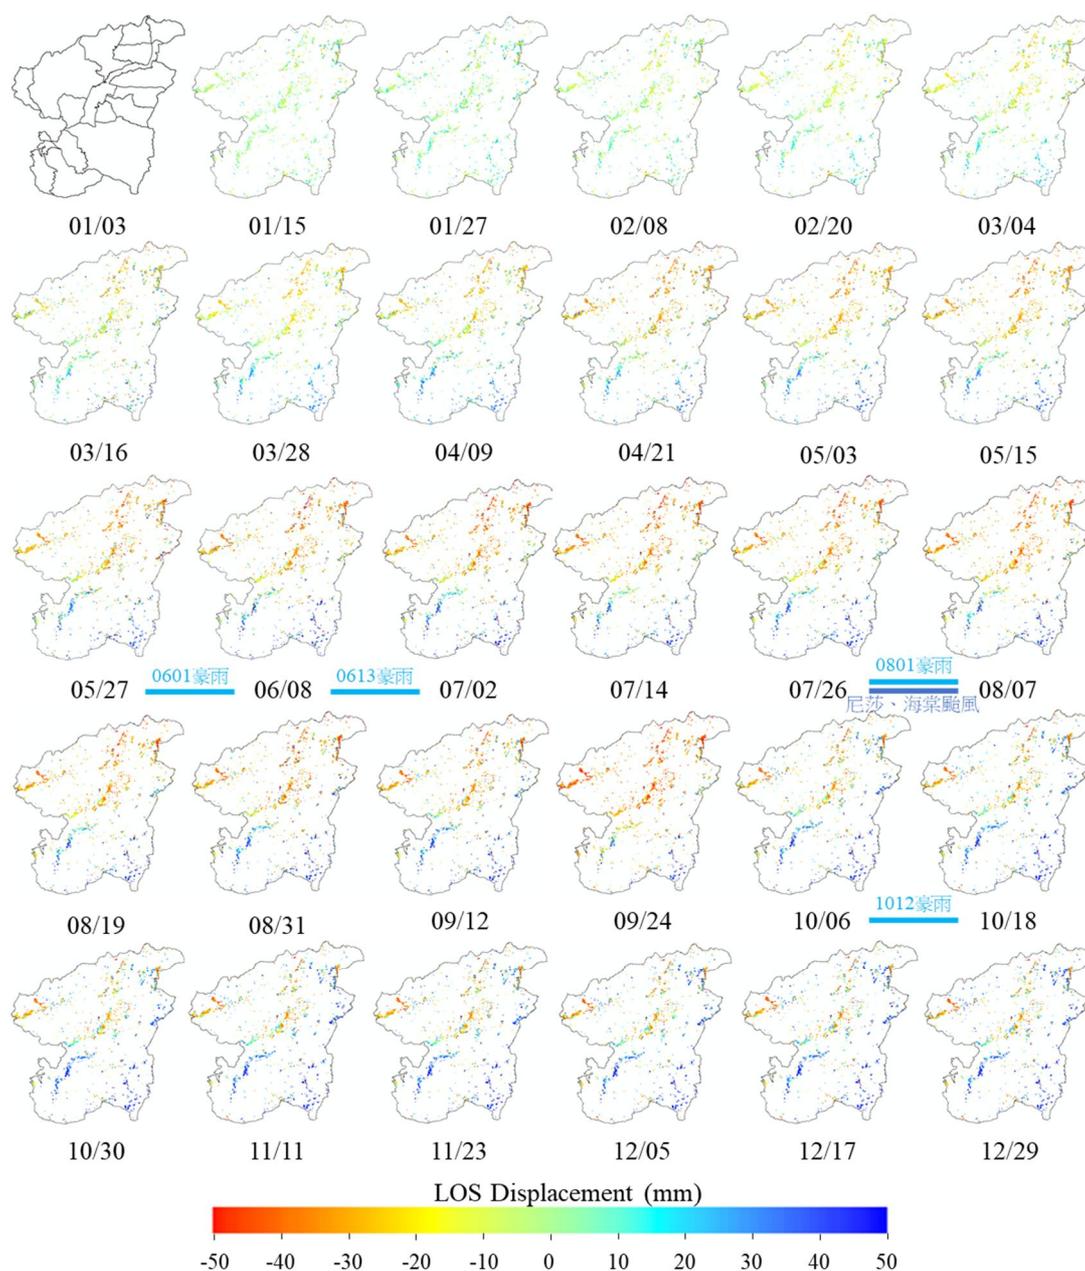


圖 14 南投縣仁愛鄉 2017 年 SBAS-InSAR 之時間序列成果圖

3.5 比較 InSAR 變位成果與事件型崩塌目錄

本研究將 PS-InSAR 與 SBAS-InSAR 技術所解算出的 2017 年地表形變資料，對各時間點之形變量取其平均值，以建立全年之平均形變分布圖，並與 2017 年事件型崩塌目錄進行空間套疊分析(圖 15)，以探討兩種 InSAR 技術對實際崩塌事件的空間偵測能力。崩塌目錄所判識範圍皆為明確可辨識之地表下陷或沉降位置，因此本研究僅提取出影像

中之沉降區域計算空間重疊面積與百分比(表 7)。統計結果顯示，2017 年事件型崩塌目錄共計判識出 92 處事件型崩塌，總崩塌面積達 131.198 ha。其中，與 PS-InSAR 所推估的沉降區域之重疊面積為 9.102 ha，重疊百分比為 6.938 %；而與 SBAS-InSAR 重疊面積則達 33.475 ha，重疊百分比為 25.515 %，明顯高於 PS-InSAR 技術。兩者成果差異推測與兩種 InSAR 技術本身的演算法特性有關，PS-InSAR 追蹤時序內穩定目標點的長期變化，對於非穩定之植被遮蔽區偵測能力弱；SBAS-InSAR 藉由放寬相

干性門檻，捕捉低穩定性之地表變化，因此在崩塌監測之空間敏感度更具優勢。

3.6 比較 InSAR 變位成果與重大災害事件-0601 豪雨

本研究進一步針對事件型崩塌目錄與 InSAR 技術之空間交集進行分析，旨在評估兩種技術對實際崩塌事件之偵測能力。為此，本研究提出三種情境進行比較：(1)同時被 PS-InSAR 與 SBAS-InSAR 偵測到的崩塌區域 ($PS \cap SBAS \cap$ 崩塌目錄)；(2)僅被 PS-InSAR 偵測到的崩塌範圍 ($PS \cap$ 崩塌目錄 - SBAS)；(3)僅被 SBAS-InSAR 偵測到的崩塌範圍 ($SBAS \cap$ 崩塌目錄 - PS)。統計結果顯示，兩種技術成功偵測出兩處崩塌事件，總覆蓋面積為 2.934 ha；而單一 InSAR 技術偵測部分，SBAS-InSAR 所偵測的獨立崩塌區面積明顯大於 PS-InSAR，多偵測出的面積達 5.76 ha，顯示 SBAS-InSAR 在監測山區崩塌具有更高的偵測能力(表 8)。

本研究針對 2017 年 6 月 1 日豪雨事件(0601 豪雨)所造成仁愛鄉春陽村與榮興村之重大崩塌進行個案分析。春陽村位在南投仁愛鄉中部地區，面積為 21.886 km²，村落聚集於北側，南側為森林，境內中部則有濁水溪流經。此次豪雨造成的災情發生於部落的聯外道路台 14 線 87 km 處，當時該地區

累積降雨達 300mm(廬山雨量站)，造成道路邊坡受張力裂縫與沖蝕作用影響而滑動，周邊擋土牆與路基毀損。本研究分析 2017 年 6 月 8 日春陽村鄰近之 PS-InSAR 與 SBAS-InSAR 位移量影像顯示，SBAS-InSAR 於春陽村崩塌區成功反演出顯著下沉變形，與崩塌事件報告之崩塌位置重疊；反之，PS-InSAR 在該區域未能有效解算(圖 16)。

榮興村位於南投縣仁愛鄉東北側，面積為 40.890 km²，大部分的土地利用類別皆為森林，零星農田散落於該村落中部地區，延台 8 線分布。0601 豪雨事件於大禹嶺雨量站量測得累積降雨達 240mm，造成碧綠溪支流上游右岸邊坡崩塌，大量土石流入河道並沖毀台 8 線 97.7 km 處之道路。分析 2017 年 6 月 8 日榮興村周圍的 InSAR 位移量可見，SBAS-InSAR 有效解算出榮興村周圍下沉之變位區；同樣地，PS-InSAR 技術在榮興村亦無法有效解算出位移量(圖 17)。

針對春陽村與榮興村兩處災害案例，分別擷取 SBAS-InSAR 解算影像於崩塌範圍內之時間序列變形成果(圖 18)，結果顯示兩村落落在經歷 0601 豪雨事件後的 5 月 27 日至 6 月 8 日影像，皆出現明顯的下沉趨勢，與實際災情具有一致性，進一步驗證 SBAS-InSAR 技術於重大災後變形監測之應用潛力。

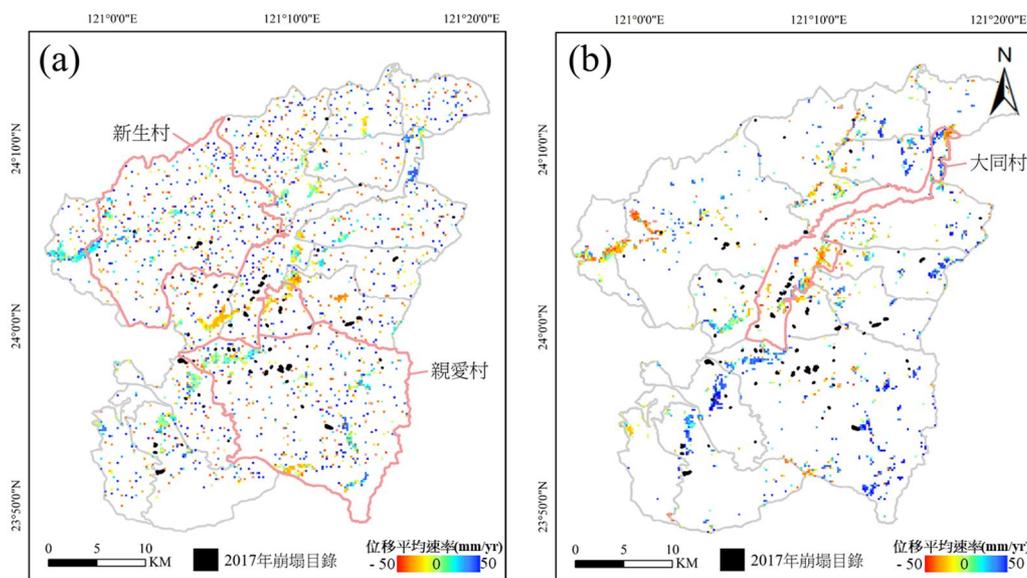


圖 15 崩塌目錄與(a)PS-InSAR 及(b)SBAS-InSAR 之地表變位套疊成果

表 7 兩種 InSAR 技術獲得的沉降變位量與崩塌目錄之重疊面積與百分比

InSAR 技術	面積 (ha)	與崩塌目錄之重疊百分比 (%)
PS	9.102	6.94
SBAS	33.475	25.52

表 8 三種情境下與崩塌目錄之重疊面積與個數

情境	面積 (ha)	崩塌位置個數
PS \cap SBAS \cap 崩塌目錄	2.934	2
PS \cap 崩塌目錄 - SBAS	7.630	9
SBAS \cap 崩塌目錄 - PS	13.390	6

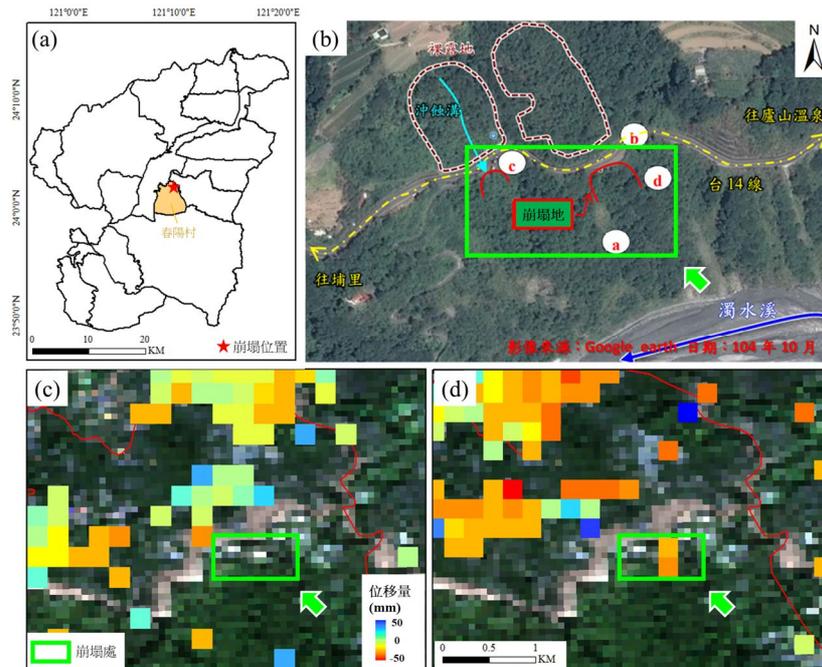


圖 16 春陽村 0601 豪雨事件成果，(a)春陽村地理位置圖、(b)崩塌位置分布圖(農業部農村發展及水土保持署，2017)、(c)與(d)分別為 2017 年 6 月 8 日影像反演之 PS-InSAR 與 SBAS-InSAR 位移分布

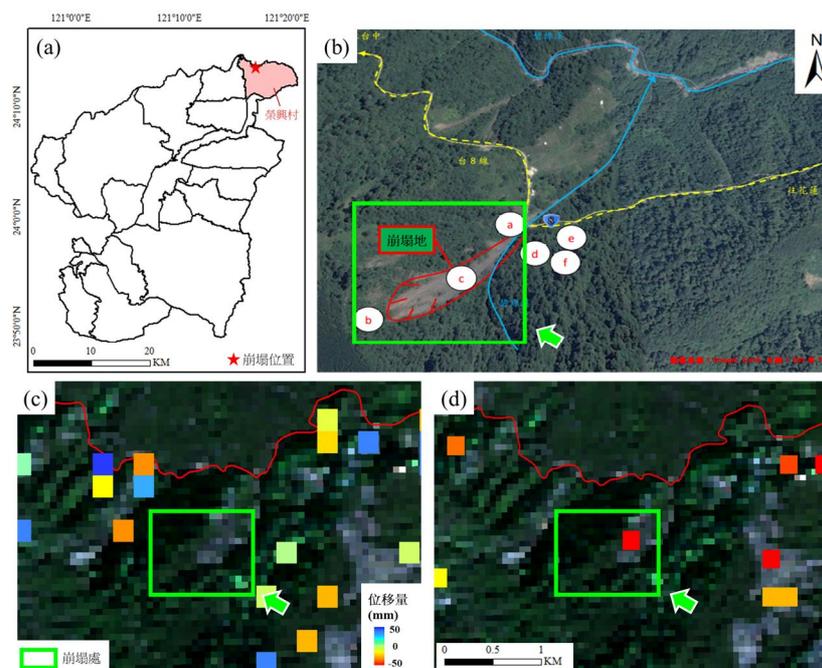


圖 17 榮興村 0601 豪雨事件成果，(a)榮興村地理位置圖、(b)崩塌位置分布圖(農業部農村發展及水土保持署，2017)、(c)與(d)分別為 2017 年 6 月 8 日影像反演之 PS-InSAR 與 SBAS-InSAR 位移分布

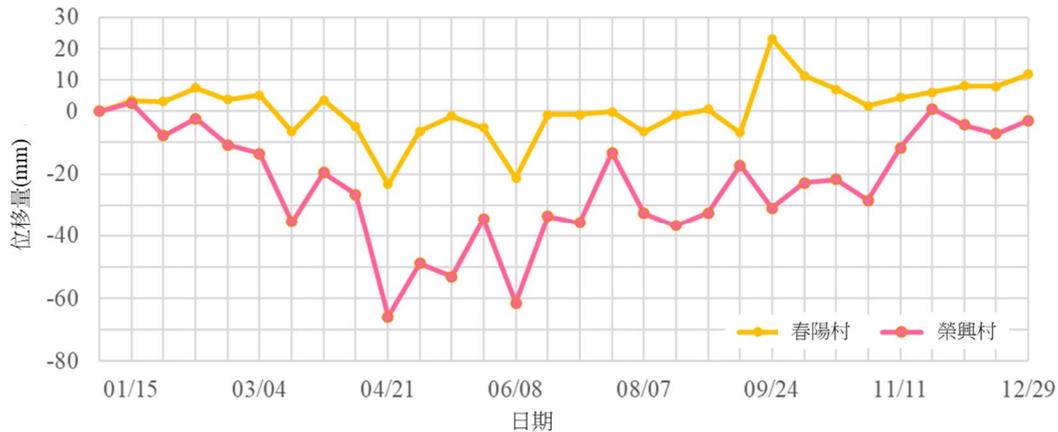


圖 18 春陽村與榮興村於崩塌處之 SBAS-InSAR 時間序列位移量

4. 結論與建議

本研究以臺灣中部南投縣仁愛鄉為研究場域，應用 2017 年間 30 幅 Sentinel-1A 升軌多時序雷達影像，分別透過 PS-InSAR 與 SBAS-InSAR 技術監測其地表形變量，探討適用於山區地表變位監測之實務方法。為驗證兩種解算地表變位技術之準確性，將 GNSS 測站所量測之變形量投影至 LOS 方向作為實際地表觀測量，並進行相關性與誤差分析。本研究分析結果顯示，GNSS 觀測量在三維投影至 LOS 方向後，各分量間對變形的貢獻比例有所差異，其中垂直分量影響來源，突顯地表變位機制對地表變形解釋的重要性。在解算成果方面，PS-InSAR 與 SBAS-InSAR 技術在仁愛鄉中部建築區與南部的河道周圍呈現一致的地表變位成果，然推測受地表環境影響，仍有部分地區反演結果出現不一致的現象；此外，在將 InSAR 成果與 GNSS 實際地表位移量進行相關性分析發現，僅有一個測站未在兩種技術上呈現顯著相關，然相關性的趨勢仍有相反的情況。故本研究推測造成此種現象可能源於兩種技術在偵測非穩定區域或高植被區域之敏感度差異，SBAS-InSAR 技術可藉由多時影像隻小基線組合提升低相干性區域的訊號。而在空間分布特徵方面，沉降區集中於在建物及草地區域，抬升則主要分布在河道兩側之河床區域。兩種解算方式皆觀測到雨季期間，仁愛鄉的沉降持續增加，可能與豪雨集中時期相關。本研究以「事件型崩塌目錄」及「重大災害事件統計」評估 InSAR 技術之適用性，結果顯

示，在兩種災害事件圖層之套疊分析中，SBAS-InSAR 技術皆表現出較佳的地表變位捕捉能力，呈現此技術對仁愛鄉崩塌動態更為敏感，更具空間偵測與崩塌災害判識能力。整體而言，本研究結果可作為評估地表變形潛勢與制定山區災防應變措施之參考，亦對地震活動、豪雨災害之監測具重要應用潛力。然而，地表變形機制複雜，研究中採用 C 波段雷達影像，未來建議可針對不同地表植被覆蓋度程度的區域，嘗試採用其他波長雷達影像，拓展 InSAR 技術於不同地貌下的應用範疇。此外，建議未來可延長觀測時間和擴大研究範圍，整合其他地球觀測資料，以提升分析結果的解釋力與精確性。

參考文獻

- 楊苡絮，2018。以 Sentinel-1A SAR 及 SBAS 方法監測雲林地層下陷，國立交通大學土木工程學系碩士論文。[Yang, Y.J., 2018. Monitoring land subsidence in Yunlin County using Sentinel-1A SAR by SBAS, Master Thesis, National Chiao Tung University, Taiwan, ROC. (in Chinese)]
- 農業部農村發展及水土保持署，2017。重大災害事件：土石流及大規模崩塌防災資訊網，<https://246.ardswc.gov.tw/Achievement/MajorDisasters>，引用 2023/3/15。[Agency of Rural Development & Soil and Water Conservation, MOA, 2017. Major Disaster Events: Debris Flow and Large-scale Landslide Disaster Prevention

- Information, Available at: <https://246.ardswc.gov.tw/Achievement/MajorDisasters>, Accessed March 15, 2023. (in Chinese)] InSAR and SqueeSAR velocity data, *Landslides*, 18(7): 2445-2463, DOI: 10.1007/s10346-021-01654-0.
- Abancó, C., Bennett, G.L., Matthews, A.J., Matera, M.A.M., and Tan, F.J., 2021. The role of geomorphology, rainfall and soil moisture in the occurrence of landslides triggered by 2018 Typhoon Mangkhut in the Philippines, *Natural Hazards and Earth System Sciences*, 21(5):1531-1550, DOI: 10.5194/nhess-21-1531-2021.
- Alcántara-Ayala, I., Esteban-Chávez, O., and Parrot, J.F., 2006. Landsliding related to land-cover change: A diachronic analysis of hillslope instability distribution in the Sierra Norte, Puebla, Mexico, *Catena*, 65(2): 152-165, DOI: 10.1016/j.catena.2005.11.006.
- Amelung, F., Jónsson, S., Zebker, H., and Segall, P., 2000. Widespread uplift and 'trapdoor' faulting on Galapagos volcanoes observed with radar interferometry, *Nature*, 407(6807): 993-996, DOI: 10.1038/35039604.
- Berardino, P., Fornaro, G., Lanari, R., and Sansosti, E., 2002. A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms, *IEEE Transactions on Geoscience and Remote Sensing*, 40(11): 2375-2383, DOI: 10.1109/TGRS.2002.803792.
- Chen, F., Lin, H., Zhou, W., Hong, T., and Wang, G., 2013. Surface deformation detected by ALOS PALSAR small baseline SAR interferometry over permafrost environment of Beiluhe section, Tibet Plateau, China, *Remote Sensing of Environment*, 138: 10-18, DOI: 10.1016/j.rse.2013.07.006.
- Crippa, C., Valbuzzi, E., Frattini, P., Crosta, G.B., Spreafico, M.C., and Agliardi, F., 2021. Semi-automated regional classification of the style of activity of slow rock-slope deformations using PS InSAR and SqueeSAR velocity data, *Landslides*, 18(7): 2445-2463, DOI: 10.1007/s10346-021-01654-0.
- Deffontaines, B., Chang, K.J., Lee, C.T., Magalhaes, S., and Serries, G., 2019. Neotectonics of the Southern Hengchun Peninsula (Taiwan): Inputs from high resolution UAS Digital Terrain Model, updated geological mapping and PSInSAR techniques, *Tectonophysics*, 767: 128149, DOI: 10.1016/j.tecto.2019.06.019.
- Dong, S., Samsonov, S., Yin, H., Ye, S., and Cao, Y., 2014. Time-series analysis of subsidence associated with rapid urbanization in Shanghai, China measured with SBAS InSAR method, *Environmental Earth Sciences*, 72: 677-691, DOI: 10.1007/s12665-013-2990-y.
- Ferretti, A., Novali, F., Bürgmann, R., Hilley, G., and Prati, C., 2004. InSAR permanent scatterer analysis reveals ups and downs in San Francisco Bay Area, *Eos, Transactions American Geophysical Union*, 85(34): 317-324, DOI: 10.1029/2004EO340002.
- Ferretti, A., Prati, C., and Rocca, F., 2000. Nonlinear subsidence rate estimation using permanent scatterers in differential SAR interferometry, *IEEE Transactions on Geoscience and Remote Sensing*, 38(5):2202-2212, DOI: 10.1109/36.868878.
- Froude, M.J., and Petley, D.N., 2018. Global fatal landslide occurrence from 2004 to 2016, *Natural Hazards and Earth System Sciences*, 18(8): 2161-2181, DOI: 10.5194/nhess-18-2161-2018.
- Ghulam, A., Grzovic, M., Maimaitijiang, M., and Sawut, M., 2015. InSAR monitoring of land subsidence for sustainable urban planning, *Remote Sensing for Sustainability*, CRC Press, Boca Raton, FL, USA.

- Giletycz, S.J., Kot-Giletycz, O., and Brown, D., 2021. Regional geology, extreme weather events and natural disasters: Environmentally-forced, involuntary settlement migrations of the indigenous people of southern Taiwan, *Tectonophysics*, 806: 228796, DOI: 10.1016/j.tecto.2021.228796.
- He, Y., Chen, Y., Wang, W., Yan, H., Zhang, L., and Liu, T., 2021. TS-InSAR analysis for monitoring ground deformation in Lanzhou New District, the loess Plateau of China, from 2017 to 2019, *Advances in Space Research*, 67(4):1267-1283, DOI: 10.1016/j.asr.2020.11.004.
- Hoffmann, J., Roth, A., and Voigt, S., 2003. Detecting coal fires in China using differential interferometric synthetic aperture radar (InSAR), *Proceedings of the FRINGE 2003 Workshop (ESA SP-550)*, Frascati, Italy.
- Hooper, A., Segall, P., and Zebker, H., 2007. Persistent scatterer interferometric synthetic aperture radar for crustal deformation analysis, with application to Volcán Alcedo, Galápagos, *Journal of Geophysical Research: Solid Earth*, 112(B7): B07407, DOI: 10.1029/2006JB004763.
- Hooper, A., Zebker, H., Segall, P., and Kampes, B., 2004. A new method for measuring deformation on volcanoes and other natural terrains using InSAR persistent scatterers, *Geophysical Research Letters*, 31(23): L23611, DOI: 10.1029/2004GL021737.
- Hsu, W.C., Chang, H.C., Chang, K.T., Lin, E.K., Liu, J.K., and Liou, Y.A., 2015. Observing land subsidence and revealing the factors that influence it using a multi-sensor approach in Yunlin County, Taiwan, *Remote Sensing*, 7(6): 8202-8223, DOI: 10.3390/rs70608202.
- Hung, W.C., Hwang, C., Chang, C.P., Yen, J.Y., Liu, C.H., and Yang, W.H., 2010. Monitoring severe aquifer-system compaction and land subsidence in Taiwan using multiple sensors: Yunlin, the southern Choushui River Alluvial Fan, *Environmental Earth Sciences*, 59(7): 1535-1548, DOI: 10.1007/s12665-009-0139-9.
- Hussain, S., Pan, B., Hussain, W., Sajjad, M.M., Ali, M., Afzal, Z., Abdullah-Al-Wadud, M., and Tariq, A., 2025. Integrated PSInSAR and SBAS-InSAR analysis for landslide detection and monitoring, *Physics and Chemistry of the Earth*, 139: 103956, DOI: 10.1016/j.pce.2025.103956.
- Kim, Y., Park, H., and Jeong, S., 2017. Settlement behavior of shallow foundations in unsaturated soils under rainfall, *Sustainability*, 9(8): 1417, DOI: 10.3390/su9081417.
- Konishi, T., and Suga, Y., 2018. Landslide detection using COSMO-SkyMed images: A case study of a landslide event on Kii Peninsula, Japan, *European Journal of Remote Sensing*, 51(1): 205-221, DOI: 10.1080/22797254.2017.1418185.
- Lin, Q., and Wang, Y., 2018. Spatial and temporal analysis of a fatal landslide inventory in China from 1950 to 2016, *Landslides*, 15(12): 2357-2372, DOI: 10.1007/s10346-018-1037-6.
- Maddahi, S., Tasan, M., and Haji-Aghajany, S., 2024. Enhancing InSAR accuracy: Unveiling more accurate displacement fields through 3-D troposphere tomography, *Journal of Atmospheric and Solar-Terrestrial Physics*, 256: 106207, DOI: 10.1016/j.jastp.2024.106207.
- Massonnet, D., Briole, P., and Arnaud, A., 1995. Deflation of Mount Etna monitored by spaceborne radar interferometry, *Nature*, 375(6532): 567-570, DOI: 10.1038/375567a0.
- Nolasco-Javier, D., and Kumar, L., 2018. Deriving the

- rainfall threshold for shallow landslide early warning during tropical cyclones: A case study in northern Philippines, *Natural hazards*, 90(2): 921-941, DOI: 10.1007/s11069-017-3081-2.
- Novellino, A., Cigna, F., Sowter, A., Ramondini, M., and Calcaterra, D., 2017. Exploitation of the Intermittent SBAS (ISBAS) algorithm with COSMO-SkyMed data for landslide inventory mapping in north-western Sicily, Italy, *Geomorphology*, 280: 153-166, DOI: 10.1016/j.geomorph.2016.12.009.
- Ozturk, U., Bozzolan, E., Holcombe, E.A., Shukla, R., Pianosi, F., and Wagener, T., 2022. How climate change and unplanned urban sprawl bring more landslides, *Nature*, 608(7922): 262-265, DOI: 10.1038/d41586-022-02141-9.
- Pathier, E., Fruneau, B., Deffontaines, B., Angelier, J., Chang, C.P., Yu, S.B., and Lee, C.T., 2003. Coseismic displacements of the footwall of the Chelungpu fault caused by the 1999, Taiwan, Chi-Chi earthquake from InSAR and GPS data, *Earth and Planetary Science Letters*, 212(1-2): 73-88, DOI: 10.1016/S0012-821X(03)00244-9.
- Promper, C., Puissant, A., Malet, J.P., and Glade, T., 2014. Analysis of land cover changes in the past and the future as contribution to landslide risk scenarios, *Applied Geography*, 53: 11-19, DOI: 10.1016/j.apgeog.2014.05.020.
- Schuster, R.L., and Highland, L.M., 2003. Impact of landslides and innovative landslide-mitigation measures on the natural environment, *Proceedings of the International Conference on Slope Engineering*, Hong Kong, China (Vol. 8, No. 10).
- Shih, D.S., Shih, S.S., Hsu, S.M., Lin, S.Y., Lin, Y., Hung, C.T., and Wang, K., 2022. A Framework for the Sustainable Risk Assessment of In-river Hydraulic Structures: A Case Study of Taiwan's Daan River, *Journal of Hydrology*, 129028, DOI: 10.1016/j.jhydrol.2022.129028.
- Tizzani, P., Berardino, P., Casu, F., Euillades, P., Manzo, M., Ricciardi, G.P., Zeni, G., and Lanari, R., 2007. Surface deformation of Long Valley Caldera and Mono Basin, California, investigated with the SBAS-InSAR approach, *Remote Sensing of Environment*, 108(3): 277-289, DOI: 10.1016/j.rse.2006.11.015.
- Tsai, H., Southworth, J., and Waylen, P., 2014. Spatial persistence and temporal patterns in vegetation cover across Florida, 1982–2006, *Physical Geography*, 35(2): 151-180, DOI: 10.1080/02723646.2014.898126.
- Wang, X., Fan, X., Fang, C., Dai, L., Zhang, W., Zheng, H., and Xu, Q., 2024. Long-term landslide evolution and restoration after the Wenchuan earthquake revealed by time-series remote sensing images, *Geophysical Research Letters*, 51(2): e2023GL106422, DOI: 10.1029/2023GL106422.
- Waylen, P., Southworth, J., Gibbes, C., and Tsai, H., 2014. Time series analysis of land cover change: Developing statistical tools to determine significance of land cover changes in persistence analyses, *Remote Sensing*, 6(5): 4473-4497, DOI: 10.3390/rs6054473.
- Wu, C.H., Chen, S.C., and Chou, H.T., 2011. Geomorphologic characteristics of catastrophic landslides during typhoon Morakot in the Kaoping Watershed, Taiwan, *Engineering Geology*, 123(1-2): 13-21, DOI: 10.1016/j.enggeo.2011.04.018.
- Yang, Y.J., Hwang, C., Hung, W.C., Fuhrmann, T., Chen, Y.A., and Wei, S.H., 2019. Surface deformation from Sentinel-1A InSAR: Relation to seasonal groundwater extraction and rainfall in Central Taiwan, *Remote Sensing*, 11(23): 2817, DOI: 10.3390/rs11232817.

- Zebker, H.A., and Villasenor, J., 1992. Decorrelation in interferometric radar echoes, *IEEE Transactions on Geoscience and Remote Sensing*, 30(5): 950-959, DOI: 10.1109/36.175330.
- Zhao, C., and Lu, Z., 2018. Remote sensing of landslides—A review, *Remote Sensing*, 10(2): 279, DOI: 10.3390/rs10020279.
- Zhao, C., Lu, Z., Zhang, Q., and de La Fuente, J., 2012. Large-area landslide detection and monitoring with ALOS/PALSAR imagery data over Northern California and Southern Oregon, USA, *Remote Sensing of Environment*, 124: 348-359, DOI: 10.1016/j.rse.2012.05.025.
- Zhao, R., Li, Z.W., Feng, G.C., Wang, Q.J., and Hu, J., 2016. Monitoring surface deformation over permafrost with an improved SBAS-InSAR algorithm: With emphasis on climatic factors modeling, *Remote Sensing of Environment*, 184: 276-287, DOI: 10.1016/j.rse.2016.07.019.
- Zhou, C., Ye, M., Xia, Z., Wang, W., Luo, C., and Muller, J.P., 2025. An interpretable attention-based deep learning method for landslide prediction based on multi-temporal InSAR time series: A case study of Xinpu landslide in the TGRA, *Remote Sensing of Environment*, 318: 114580, DOI: 10.1016/j.rse.2024.114580.

Comparison of PS-InSAR and SBAS-InSAR Techniques in Monitoring Surface Deformation in Mountainous Areas: A Case Study in Ren'ai Township

Jun-Ren Shi ¹ Zhong-Han Zhuang ² Hui-Ping Tsai ^{3*}

Abstract

Traditional landslide monitoring techniques and instruments are limited by spatial constraints. This study applies remote sensing-based Interferometric Synthetic Aperture Radar (InSAR) technology to enable large-scale surface displacement monitoring in mountainous areas. Two multi-temporal InSAR approaches—Persistent Scatterer InSAR (PS-InSAR) and Small Baseline Subset-InSAR (SBAS-InSAR)—were adopted. Ren'ai Township in Nantou County, Taiwan, was selected as the demonstration area. A total of 30 ascending Sentinel-1A radar images from 2017 were used to compare the applicability of these two methods for surface displacement monitoring, and correlation analysis was conducted with Global Navigation Satellite Systems (GNSS) data. Both PS-InSAR and SBAS-InSAR exhibited statistically significant positive correlations at the LSAN GNSS station, with correlation coefficients of 0.486 and 0.399, and root mean square errors of 5.004 mm and 7.685 mm, respectively. The SBAS-InSAR results effectively captured the spatial distribution of actual landslides and surface deformation in the mountainous area, indicating that this technique may offer greater advantages for landslide monitoring in such complex terrains.

Keywords: MT-InSAR, PS-InSAR, SBAS-InSAR, Surface Displacement

¹ Master, Department of Civil Engineering, National Chung Hsing University

² PhD Student, Department of Civil Engineering, National Chung Hsing University

³ Associate Professor, Department of Civil Engineering, National Chung Hsing University

* Corresponding Author, E-mail: huiping.tsai@nchu.edu.tw

Received Date: May 16, 2025

Revised Date: Jun. 30, 2025

Accepted Date: Jul. 18, 2025

UAV Path Determination for Visual Navigation using Deep Reinforcement Learning

Pei-Hsuan Huang^{1*} Chao-Hung Lin²

Abstract

Traditional path planning algorithms for Unmanned Aerial Vehicles (UAVs) primarily optimize for geometric metrics such as path length and energy efficiency. However, in GPS-denied environments, where external positioning is unreliable, the quality of visual localization is paramount for mission success. This study introduces a novel Deep Reinforcement Learning (DRL) framework designed to co-optimize the UAV path for both geometric efficiency and visual localization robustness. Specifically, our method integrates the density of matched image feature points, extracted from post-processed aerial imagery, directly into the planning process, ensuring the generated trajectory passes through visually rich areas that enhance navigation accuracy. To tackle the path planning challenge and address issues related to sparse rewards and unstable training, we employ an advanced DRL architecture: Noisy Dueling Double DQN with Prioritized Experience Replay (Noisy D3QN with PER). This integration leverages Double DQN to refine value estimation, Dueling DQN to improve generalization, PER to enhance sample efficiency, and Noisy Networks to promote robust and efficient exploration. The proposed framework is implemented within a simulated 2.5D environment with a customized reward function that considers both UAV state parameters and terrain features. Experimental results demonstrate that the method generates efficient, visually coherent, and dynamically smooth trajectories. Crucially, it enables path inference for multiple independent missions from various starting points after a single training session, achieving superior computational efficiency compared to traditional geometric planners. This highlights the potential of integrating visual features into a reinforcement learning-based UAV path planning to significantly enhance visual localization performance in complex environments.

Keywords: Reinforcement Learning, Unmanned Aerial Vehicle, Deep Q Network

1. Introduction

In recent years, drone warfare has emerged as a prominent trend in modern military operations, largely due to the numerous advantages offered by Unmanned Aerial Vehicles (UAVs). UAVs facilitate the execution of high-risk missions without placing personnel in direct danger, thereby significantly reducing battlefield casualties. Moreover, their modular architecture and compact design allow for rapid deployment across diverse terrains and tactical scenarios, enhancing operational flexibility. Given that many missions are conducted within adversarial territories, robust and reliable navigation systems are critical to ensuring both positional accuracy and overall mission success. UAVs primarily depend on the Global Positioning System (GPS) for positioning and navigation. However, GPS signals are inherently vulnerable to jamming, spoofing, and other electronic countermeasures frequently employed by hostile forces. As a result, the failure or disruption of UAV navigation systems may lead to mission deviation, target misidentification, and potential loss of the platform.

To address scenarios in which GPS signals are unavailable, such as during wartime or in GPS denied environments, visual navigation has emerged as a viable alternative to support UAV localization and sustain mission continuity. This method typically utilizes aerial imagery captured by UAV cameras, alongside reference orthoimages to perform image matching. By extracting feature conjugate points through image matching, the Exterior Orientation Parameters (EOP), include the camera's spatial position and orientation, can be estimated via spatial resection. This enables accurate localization in the absence of GPS.

To extract reliable and repeatable feature correspondences, recent advances in deep learning-based image matching models have played a pivotal role. SuperPoint (Detone *et al.*, 2018) is a self-supervised interest point detector and descriptor that jointly learns keypoint locations and descriptors using a fully convolutional neural network, enabling robust and efficient feature extraction in aerial imagery. LightGlue (Lindenberger *et al.*, 2023), a lightweight graph-matching framework, complements SuperPoint

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

² Professor, Department of Geomatics, National Cheng Kung University

* Corresponding Author, E-mail: hpei254@gmail.com

Received Date: Jul. 15, 2025

Revised Date: Sep. 26, 2025

Accepted Date: Oct. 16, 2025

by establishing reliable matches between feature points through attention-based architecture and adaptive filtering strategies, making it well-suited for real-time UAV visual localization. These models significantly improve the accuracy and robustness of feature point detection and matching under varying perspectives and illumination conditions, thus enhancing the reliability of visual-based UAV positioning.

When operating without GPS support, path planning becomes a crucial element in guiding the UAV to its target area. In such cases, pre-mission path planning must incorporate image feature points, as they directly influence the robustness and accuracy of visual localization. Additionally, in navigating realistic three-dimensional environments, obstacle avoidance becomes an essential constraint that must be strictly observed.

While traditional methods like Dijkstra's algorithm and A* are widely used for computing optimal paths in static environments, they often struggle with dynamic, high-dimensional spaces characteristic of complex UAV missions. Accordingly, Reinforcement Learning (RL) has emerged as a powerful paradigm for adaptive decision-making through environment interaction. The Deep Q-Network (DQN) framework (Mnih *et al.*, 2015) addresses the limitations of traditional tabular Q-Learning by integrating deep neural networks to approximate value functions, enabling learning in complex environments without exhaustive state enumeration. In the domain of path planning for autonomous systems, DRL is increasingly applied due to its adaptability to complex, constraints-rich environments (Wu *et al.*, 2023; Yao *et al.*, 2022). Specifically for UAV navigation, researchers have leveraged DRL to optimize multi-objective functions, considering factors such as distance, energy consumption, and collision penalties (Wu *et al.*, 2023). However, achieving reliable performance requires mitigating inherent DQN challenges, including Q-value overestimation, unstable learning, and inefficient exploration, which remain critical areas of research.

This research aims to design a UAV path planning system with multiple objectives, including maximizing the density of matched image feature points. Higher feature-point density enhances the chances and precision of UAV localization in signal-denied environments. To this end, an extended DQN framework is employed for path planning, followed by postprocessing with cubic Bézier curves to generate smooth trajectories suitable for real-world UAV deployment.

To address the aforementioned challenges and enhance training stability, several advanced DQN extensions have been introduced and widely studied in UAV applications. Double DQN (Van Hasselt *et al.*, 2016) mitigates the overestimation bias prevalent in

standard DQN by decoupling action selection and evaluation. Dueling DQN (Wang *et al.*, 2016) further improves generalization and learning stability by decomposing the Q-value into state-value and advantage components, a structure proven effective in complex UAV scenarios (Yao *et al.*, 2022; Huang and Li, 2023). Furthermore, Prioritized Experience Replay (PER) (Schaul *et al.*, 2016) enhances sample efficiency by focusing training on high-Temporal-Difference error experiences, a technique successfully integrated into path planning for autonomous surface vehicles (Zhu *et al.*, 2021).

Building upon this foundation, our study adopts an advanced hybrid architecture: Noisy Dueling Double DQN with Prioritized Experience Replay (Noisy D3QN with PER). This integration harnesses the stability advantages of the Dueling architecture, alleviates Q-value overestimation through Double DQN, and achieves improved sample efficiency via PER. Crucially, we incorporate Noisy Networks (Fortunato *et al.*, 2018) to replace the conventional ϵ -greedy strategy. By injecting parametric noise into the network weights, this approach fosters state-dependent exploration, which is superior for consistent and adaptive agent behavior in environments characterized by sparse rewards, a methodology relevant to UAV path planning (Villanueva and Fajardo, 2019).

Since our objective is to assist UAVs in visual navigation and localization, the reward function incorporates the density of matched feature points, UAV altitude, and obstacle constraints. This reward design enables the agent to generate feasible and reliable paths. Furthermore, our proposed DQN-based approach supports multi-UAV by generating individual paths from different starting points to a shared destination. This flexibility addresses the limitation of traditional algorithms that must regenerate the path for each new UAV configuration. The evaluation time of the Noisy D3QN with PER method also outperforms traditional approaches, reducing computational resources and improving efficiency.

2. Methodology

This research separates the workflow into three parts, the dataset preprocessing of feature points' density map, the comprehensive deep Q network model for path finding, and the post-processing for smoothing the path, shown as Figure 1 below.

2.1 Dataset and Pre-Processing

The dataset comprises two principal components. The first component is a simulated three-dimensional environment based on the DSM of National Cheng Kung University. This environment serves as the training backdrop for UAV pathfinding and provides

the foundation for acquiring image matching pairs. The second component consists of matched feature points, which are essential components guiding the UAV's pathfinding process. The matched feature points were generated utilizing SuperPoint (Detone *et al.*, 2018) for keypoint detection and LightGlue (Lindenberger *et al.*, 2023) for matching, applied to UAV acquired images alongside their corresponding reference satellite images, culminating in a robust dataset of matched points that serves as a vital visual guidance mechanism during model training. An illustrative example of a single image matching is presented in Figure 2.

Given the restricted field of view inherent to UAV imagery and the uneven distribution of feature points, directly employing raw matched pairs as model input are not suitable. To ameliorate this issue, a density map was devised to statistically depict the spatial distribution of feature points across the DSM domain. The density map construction commenced with spatial clipping of all matched points to the bounds of the DSM. Spanning an area of 1 km × 1 km with a resolution of 10 meters. Each matched point was assigned to a specific grid cell according to its easting and northing coordinates. Instead of merely counting the distribution of points within each grid cell, a Gaussian kernel density estimation was applied to render a smoother representation of each point's contribution. Each point imparted weighted values w to its neighboring grid cells, employing a Gaussian function centered at the respective point's location, characterized by a predetermined standard deviation $\sigma=1.5$ and effective radius of $\pm 3\sigma$. The weight for each cell was computed using the following equation:

$$w = e^{-\frac{dx^2+dy^2}{2\sigma^2}} \dots\dots\dots (1)$$

2.2 DQN Pathfinding

During the navigation process, the UAV must acquire a DSM of the target area, alongside a set of matching pairs of captured images within that region. This preprocessing of path planning plays a crucial role in optimizing the UAV's navigation route, enabling it to adapt to its mobility constraints while simultaneously avoiding potential collisions with the terrain or obstacles, such as buildings. This approach not only enhances the safety of subsequent tasks associated with the UAV's operational objectives but also increases the number of identifiable matching pairs, which is a primary goal of the mission. In this study, we employed Deep Q-Networks (DQN) (Mnih *et al.*, 2015) as the foundational framework. This approach synergizes the principles of the Q-learning algorithm with the strengths of deep learning to effectively address the UAV path planning challenge within a simulated three-dimensional environment.

In our implementation, the DQN designates the UAV as the agent, which engages in interactions within the environment. For each state within the environment, upon executing an action, the UAV receives a Q-value as a reward from the neural network. This Q-value serves as an indication of the potential value associated with the current state-action pair, subsequently guiding the UAV to transition to the corresponding next state. The decision-making process persists until the agent successfully reaches the designated target, a scenario referred to as an episode.

In conventional reinforcement learning applications within simpler environments, the Q-value of each state can be represented using a Q-table. However, in more complex environments, DQN utilizes a deep neural network to supplant the traditional Q-table, thereby amplifying the advantages of deep reinforcement learning. The architecture of the deep neural network consists of multiple layers of neurons, where each layer is interconnected with neurons from preceding layers. This structural characteristic enables the DQN to learn from its experiences, facilitating the optimization of policy learning. Consequently, the transformation of state representations into a value-based function emerges as the output, enhancing the overall effectiveness of the policy optimization process. Figure 3 illustrated the whole process of our adopted comprehensive DQN methods.

The key innovations of DQN are the experience replay and the target network. Each interaction that the agent has with the environment generates a series of experiences represented as (s, a, r, s') . This notation indicates the current state, the action taken by the agent, the reward received for that action, and the subsequent state following that action, respectively. These past transitions are stored in a replay buffer. During training, random mini-batches are sampled from this buffer in a process known as experience replay. This approach reduces data correlation, enhancing sample efficiency and stabilizing the learning process.

Another significant innovation in DQN is the introduction of the target network. The target network has the same neural network architecture as the primary network that is being trained. However, it operates as a separate entity, generating stable Q-values that serve as targets for calculating the loss in relation to the main network. Functioning effectively as a ground truth, the parameters of the target network are updated periodically from the main network, rather than being updated with every training iteration. This periodic update helps maintain a fixed target for the main network, preventing rapid fluctuations during the learning process.

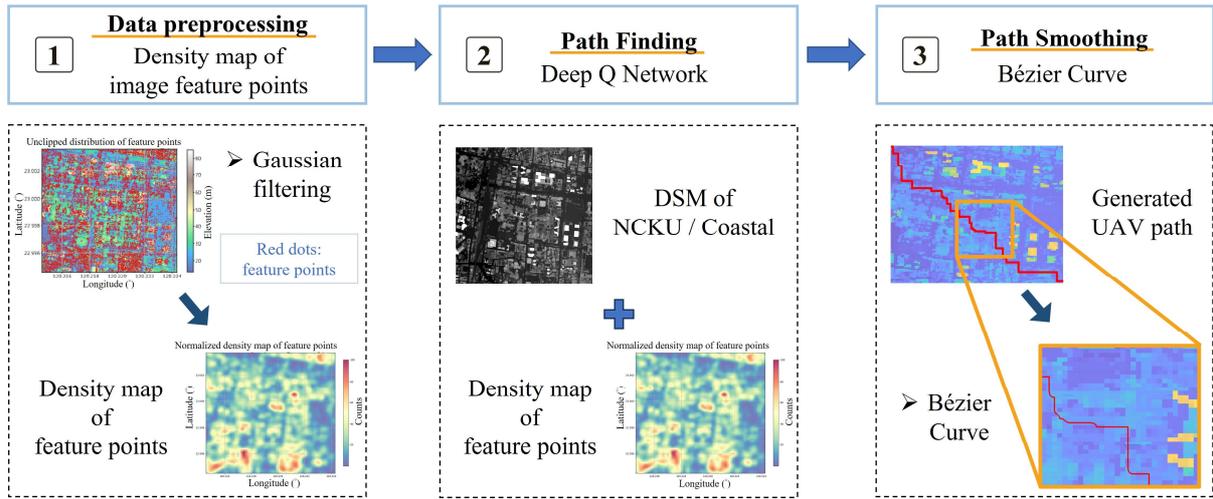


Figure 1 Overview of the path planning workflow



Figure 2 Example of a single image matching result

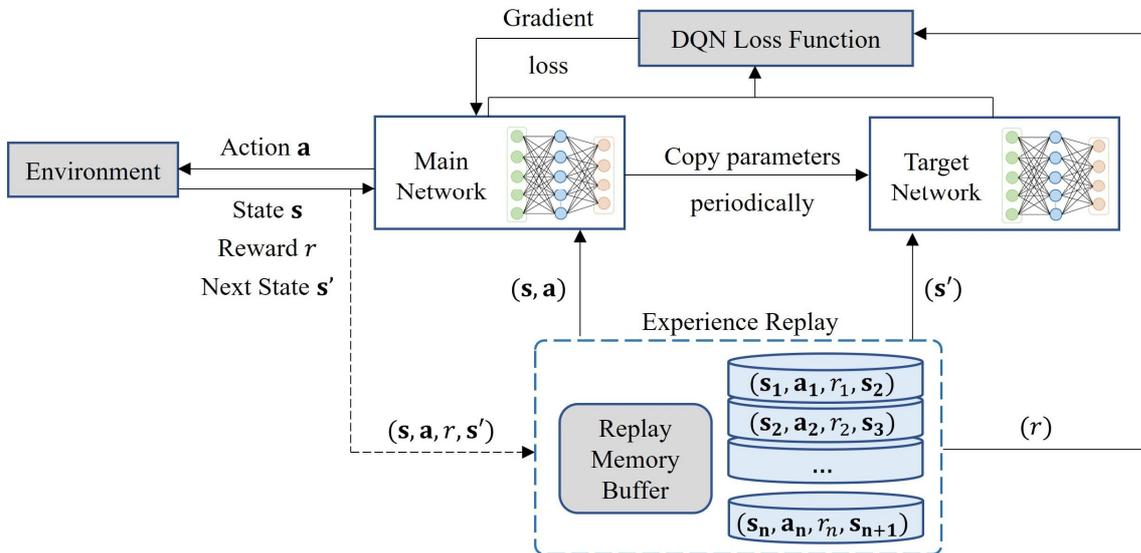


Figure 3 Workflow of the proposed DQN

To address the inherent limitations of conventional DQN, we adopt an integrated framework that incorporates four established enhancements: Double DQN (Van Hasselt *et al.*, 2016), Dueling DQN (Wang *et al.*, 2016), Noisy Networks (Fortunato *et al.*, 2018), and prioritized experience replay (PER) (Schaul *et al.*, 2016). First, the Double DQN algorithm effectively mitigates the overestimation bias associated with Q-

values updates by decoupling the action selection and evaluation processes. In this dual-network architecture, the main network is utilized for action selection, while the target network is responsible for action evaluation. This refinement promotes more accurate value estimations during learning. Second, the Dueling DQN framework distinguishes between the state value function and the advantage function, thereby enhancing the agent's capacity to evaluate states effectively, even

when the action choices exhibit minimal variation. This facilitates accelerated convergence by enabling the network to focus on the relative advantages of actions within specific states.

Third, Noisy Networks introduce adaptive exploration strategies by substituting traditional fixed exploration methods, such as epsilon-greedy strategy, with learnable stochastic noise incorporated into the network weights. The incorporation of adaptive noise enhances the exploration-exploitation balance, facilitating more efficient learning. Finally, PER enhances learning efficiency and stability by emphasizing experiences with high temporal-difference (TD) errors. This allows the agent to concentrate on transitions that provide the most significant informative value for policy updates. The collective implementation of these enhancements strengthens both the robustness and performance metrics of the baseline DQN, ultimately leading to superior decision-making capabilities in reinforcement learning environments.

2.3 Network Structure and Reward Function Design

We define the input as a DSM representing a virtual three-dimensional environment. Our network architecture is based on an integrated framework that combines noisy dueling double deep Q-network (D3QN) with PER, as illustrated above. The input consists of two channels: the DSM and a corresponding density map that encodes the spatial distribution of image feature matches. To control the UAV agent, we define six discrete actions that correspond to movement in the cardinal directions of 2.5D space: forward, backward, left, right, up, and down. These actions are treated independently and are not combined into compound vectors. This design prevents ambiguity in the output Q-values, ensuring that each predicted action value clearly corresponds to a single direction on the X, Y, or Z axis. This separation is similar to a classification task, where each class (i.e., direction) is distinctly modeled, which improves both convergence and decision accuracy. The network's output is a set of Q-values for each action, calculated through a dueling architecture that separately estimates the state value and the advantage function. The inclusion of noisy linear layers injects learnable stochasticity into the network, promoting more effective exploration during training. With this architecture, the model is better equipped to evaluate the optimal navigation action in complex 2.5D environments. The schematic diagram of the entire network architecture is shown in Figure 4.

In accordance with the established network

architecture, we have designed a bespoke reward function aimed at optimizing the path planning capabilities of the agent within a virtual three-dimensional environment. This reward mechanism is meticulously designed to achieve a harmonious balance among multiple objectives, thereby augmenting both navigation efficacy and the quality of visual localization.

The UAV agent is trained using the DQN framework, and the total reward function R is defined as

$$R = r_{obs1} + r_{obs2} + r_{step} + r_{goal} + r_h + r_{match} \dots (2)$$

where each term is delineated as follows: r_{obs1} denotes the obstacle avoidance for out of the map searching area, r_{obs2} denotes the observation penalty for colliding with obstacles, r_{step} denotes the step-reward balance, r_{goal} denotes the incentives for goal-oriented navigation, r_h denotes constraints related to excessive flying height, and r_{match} denotes the value associated with matched feature points. This comprehensive approach to reward structuring thus promotes the development of robust navigation strategies while ensuring the agent's adaptability to dynamic operational scenarios.

The function imposes penalties for collisions and for navigating into prohibited areas, thereby promoting effective obstacle avoidance strategies. Concurrently, it provides incentives for minimizing the trajectory length through the reduction of steps required to attain the target. Additionally, the reward structure is strategically formulated to diminish the Euclidean distance between the agent and the designated objective, ensuring that the agent makes consistent progress toward its goal. Significantly, to enhance positioning accuracy, the reward function further integrates the count of matched feature pairs as a positive reinforcement signal. This mechanism encourages the agent to prioritize regions rich in visual correspondences. Through this multi-faceted design, the agent is effectively motivated to assimilate and execute proficient and reliable navigation strategies amidst complex spatial constraints, thereby facilitating superior performance in pathfinding tasks.

2.4 Bézier Curve

To enhance the generated path, Bezier curve (Bezier, 1972) smoothing is used during post-processing to refine the initially rough trajectory. This technique results in a final path that is smoother and more continuous, making it more suitable for real-world UAV deployment. Such refinement is necessary because abrupt directional changes can be impractical due to the constraints of flight dynamics.

3. Experimental Results and Analysis

3.1 Preprocessing Results - Density Map of Image Matching Pairs

In Section 2.1, we provide a comprehensive overview of the dataset and the preprocessing methodologies employed, particularly highlighting the generation of matching pairs of feature points. Utilizing the Gaussian kernel process delineated in Equation 1, we transformed these matching pairs into a density map. Recognizing the significance of matching pairs of feature points in UAV path planning, we proceeded to clip the density map to produce an alternative version that omits a minor subset of the matching pairs. The two resulting datasets are designated as “Unclip” and “Clip,” respectively. This methodological step aims to assess the model’s sensitivity to variations in matching pairs and to elucidate the role of these pairs in enhancing

UAV path planning efficacy. The results arising from this preprocessing phase are compared and presented in Figure 5.

3.2 Simulation Environment Setting

The specification of parameters is a critical component in the training process of reinforcement learning algorithms. Table 1 provides a summary of the essential hyperparameters employed during the training phase. The experiments were conducted within a 2.5D simulation environment that encompassed a 1 km × 1 km area of the National Cheng Kung University campus. A DSM was utilized, configured at a spatial resolution of 10 meters, which resulted in a voxel grid with dimensions of 100 × 100 × 10; the elevation values along the z-axis were normalized by dividing the original height by 10. The UAV commenced its trajectory from the initial coordinates [1,1,3] and was tasked with reaching the target coordinates [98,98,4]. The goal was established as being within a one-pixel radius of the target location, ensuring precision in the UAV’s navigation objectives.

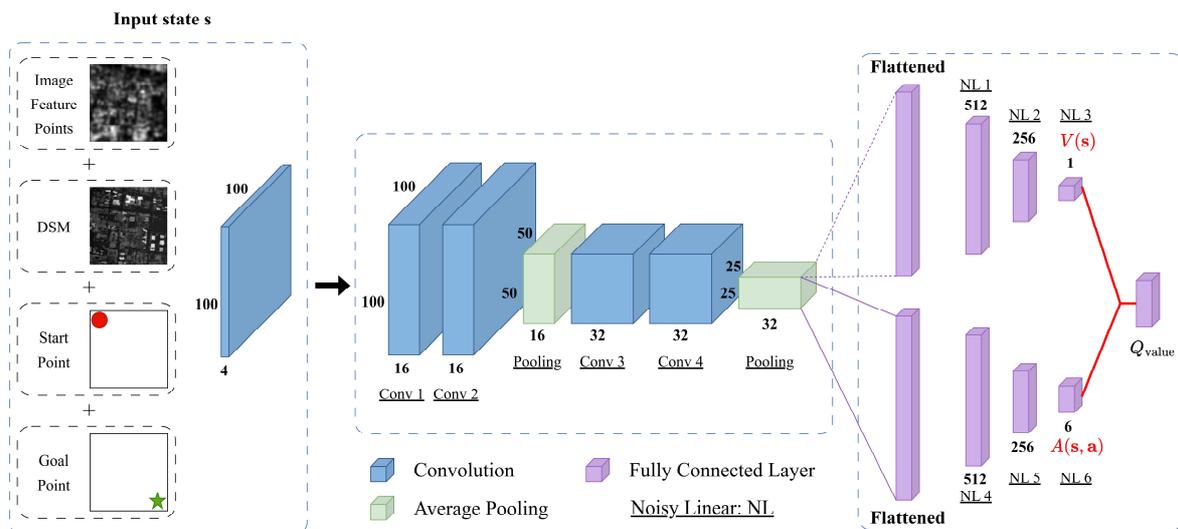


Figure 4 Proposed enforcement learning neural network structure

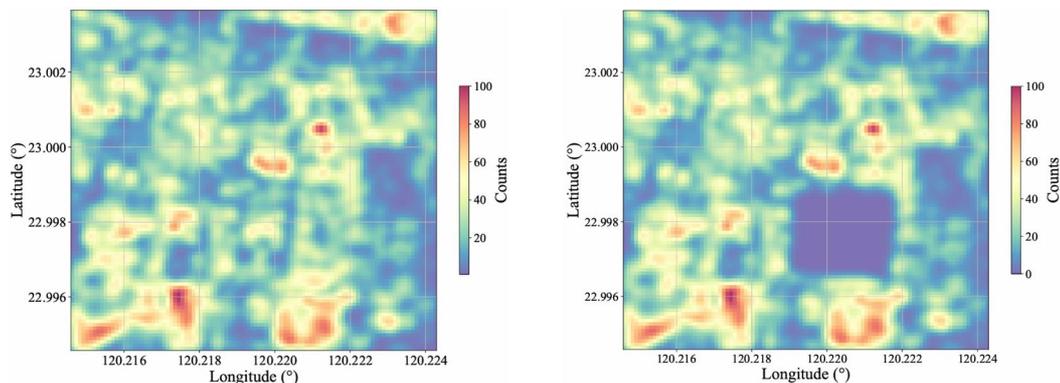


Figure 5 Left: Normalized density map. Right: Normalized clipped density map

3.3 Training Results and Analysis

Figure 6 illustrates the top view of the trajectory generated by DQN algorithm, utilizing the original unclip image feature points dataset. The path is visualized over a DSM background, with the UAV trajectory highlighted in red. The starting point is indicated in green, while the goal point is represented in blue.

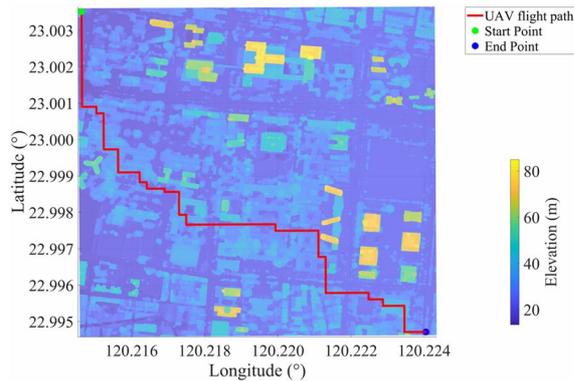


Figure 6 Topview of original DQN-generated path

Figure 7 and Figure 8 depict the UAV's trajectory in both a 2.5D view and a side perspective, respectively. These visualizations provide a comprehensive view of the UAV's movement in three-dimensional space. Notably, the side view emphasizes that the generated path navigates effectively through the terrain, successfully avoiding obstacles while maintaining an optimal altitude. This altitude maintenance is significant as it contributes to reducing the UAV's energy consumption during flight.

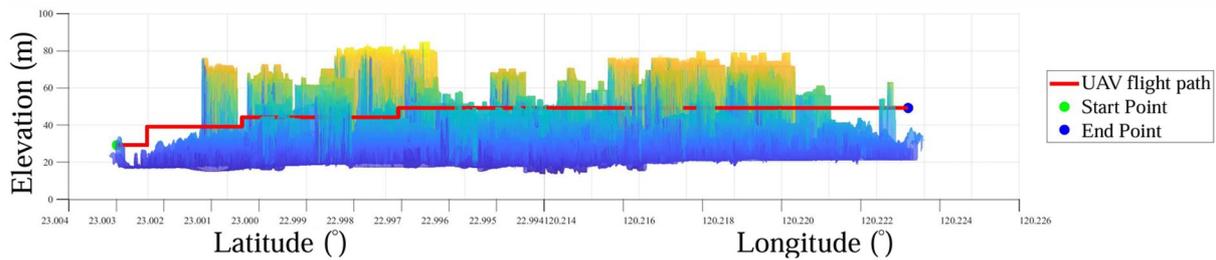


Figure 7 2.5D view of original DQN-generated path

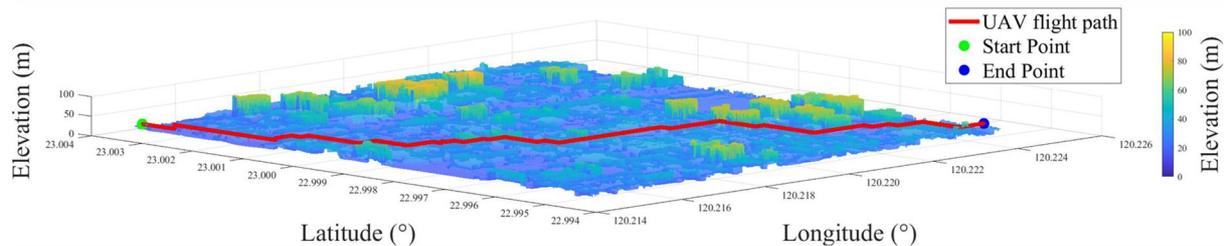


Figure 8 Side view of original DQN-generated path

The pathway design intentionally targets areas characterized by higher densities of image feature points, which have been normalized and inverted. These feature points are critical for effective visual localization and navigation tasks. To evaluate the algorithm's performance, we conducted an experiment comparing the results obtained from the original dataset against those derived from the clipped dataset. This methodological step aimed to assess the model's robustness by observing whether the path generation mechanism would actively avoid the clipped region, which now contains a reduced number of feature points. The deliberate removal of these features simulates a scenario where the UAV's visual navigation ability might be compromised. This experiment is thus designed to elucidate the role of these feature points in enhancing UAV path planning efficacy and to quantify the model's sensitivity to variations in feature point distribution.

Despite the original path traversing areas with a higher density of feature points, the clipped path also navigates through the terrain by selecting an alternative route that, while different, still encompasses regions of relatively high feature point density. This experiment demonstrates the algorithm's capability to produce a path that is both efficient and feasible, showcasing its robustness in complex path planning scenarios. Figure 9 overlays the UAV paths on the density maps corresponding to both the original and clipped image feature points datasets. The left side of the figure illustrates the path generated using the unaltered density map, while the right side presents the path derived from the clipped density map. This visual comparison effectively highlights the impact of data clipping on the UAV's path planning and navigational efficacy.

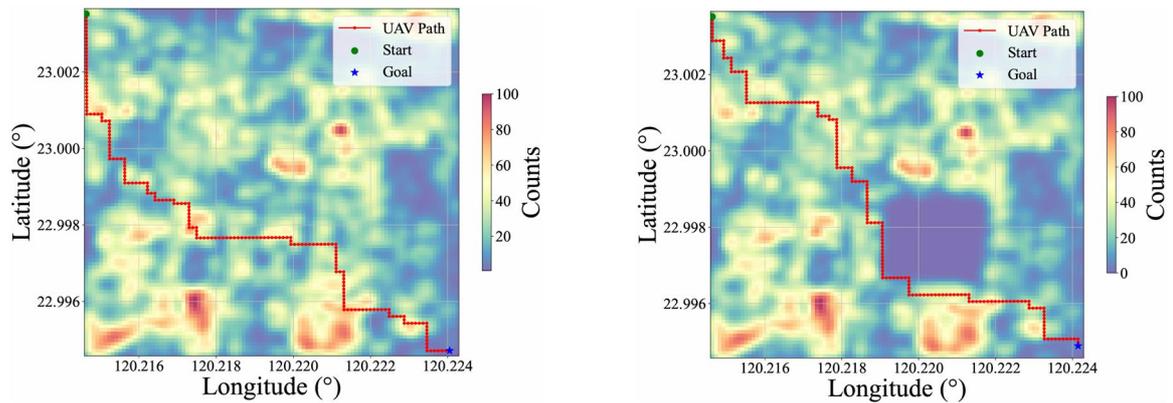


Figure 9 The comparison between two different density maps. Left: Generated path over the density map of original image feature points data. Right: Generated path over the density map of clipped image feature points data

Additionally, Table 2 outlines the training results for both the original and clipped datasets. This table includes key metrics such as path length and the average value of image feature points for each dataset. The findings indicate that the clipped data results in a slightly longer path length of 196.50 grid size compared to 196.00 grid size for the original data, accompanied by a lower average value of image feature points in the clipped data. These results suggest that while the clipping of data may yield a longer path, it still preserves a sufficient number of matching pairs. Furthermore, the results demonstrate a preference in route generation: the system tends to forgo a shorter, more direct path to the destination in favor of traversing areas with a higher average value of image feature points. This suggests that the generated route prioritizes maximizing the opportunity for successful UAV visual localization by seeking regions with richer visual features.

Table 2 Comparison of path planning metrics using original and clipped data

	Original data	Clipped data
Path length	196.00	196.50
Average image feature points value	77.10	73.63

3.4 Postprocessing Results- Path Smoothing

The properties of Bézier curves facilitate effective path smoothing, which is particularly beneficial for refining the trajectories generated by the Noisy D3QN with PER methods. The model's configuration for determining the action direction of the UAV imposes constraints that can impair its performance, often resulting in waypoints characterized by abrupt 90-

degree turns. Such sharp turns are not conducive to the UAV's motion characteristics, posing considerable challenges in real-world applications. To address this issue, we employed third-order (cubic) Bézier curves to enhance the smoothness of the generated waypoints, thereby reducing the abruptness of the turning angles. At first glance, the adjustments made through the smoothing process may appear subtle; however, a more detailed examination reveals a measurable refinement in path continuity and turning angle realism. Accordingly, Figure 10 provides a closer view of the Bézier-smoothed trajectory, specifically highlighting modifications in regions where the UAV was previously required to execute sharp turns. The application of the Bézier curve effectively mitigates these infeasible turns, yielding a more natural and dynamically viable flight path for the UAV.

3.5 Comparison with Traditional DQN Algorithms

To rigorously evaluate the effectiveness of the proposed DQN-based reinforcement learning methodologies and to analyze the impacts of reward function design, we conducted a series of simulation training and testing experiments employing four distinct algorithms: DQN, dueling DQN (DDQN), dueling doubling DQN (D3QN), and noisy D3QN with prioritized experience replay (PER) algorithm. The comparative performance assessment was grounded on four critical dimensions: average steps and path length, reward, image feature point values, and training duration. Each algorithm was subjected to a total of 1000 training episodes.

Figure 11 and Figure 12 depict the trajectories of average steps and path lengths per episode, respectively. At the onset of training, all algorithms display considerable fluctuations attributable to random exploration dynamics. Notably, the noisy D3QN with PER demonstrates a marked ability to converge rapidly

and stabilize around the 300-episode mark, resulting in both shorter and more consistent paths. The determination of convergence is primarily based on the stabilization of the average number of steps required per episode. During the initial phase, data fluctuation is expected due to random environment exploration. However, the Noisy D3QN with PER shows a frequent reduction in the magnitude and frequency of

fluctuations after a few hundred episodes. While minor, occasional spikes may still occur as the agent explores previously unknown states, the path length and steps quickly return to a stable range. In contrast, the other algorithms, DQN, DDQN, and D3QN, exhibit protracted training periods and erratic performance spikes, indicating instability in the policy update process.

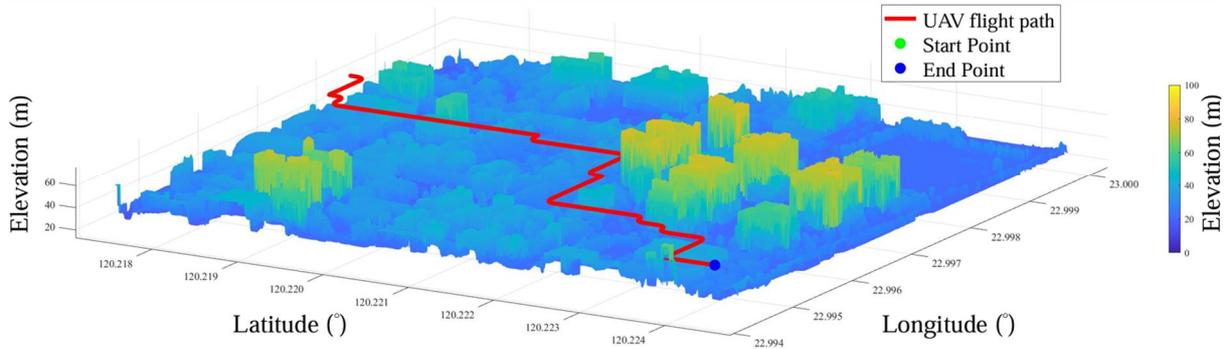


Figure 10 The detail of the Bézier-smoothed trajectory

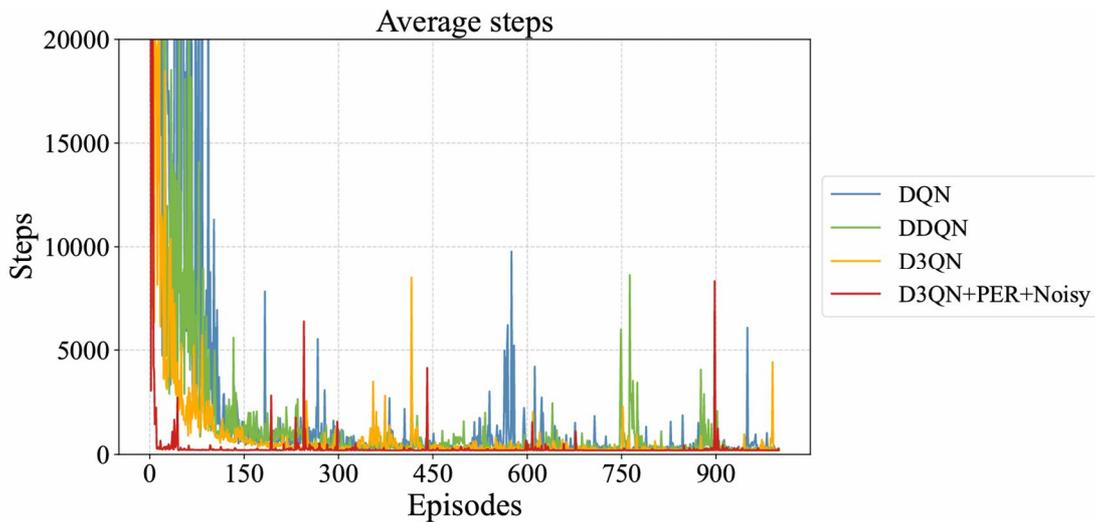


Figure 11 Average steps of generated path over episodes of the noisy D3QN with PER, D3QN, DDQN, DQN

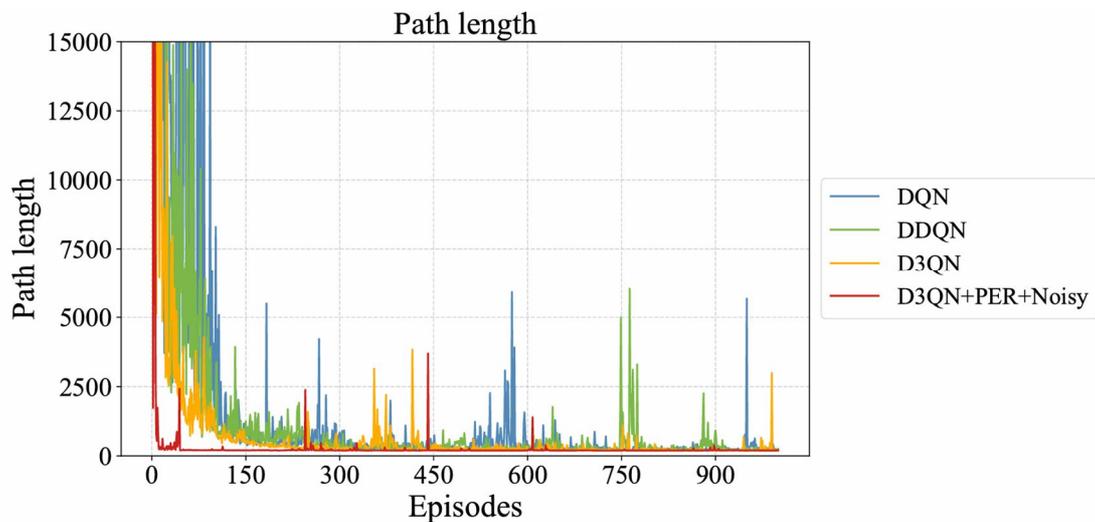


Figure 12 Path length of generated path over episodes of the noisy D3QN with PER, D3QN, DDQN, DQN

The enhanced convergence exhibited by the noisy D3QN with PER can be attributed to the synergistic interplay between PER and noisy networks. PER facilitates the prioritization of informative experiences during the replay phase, whereas Noisy Nets innovate by supplanting the traditional epsilon-greedy strategy with adaptive stochastic exploration methods. This dual combination fosters more effective policy refinements over time, culminating in reduced step counts and expedited paths toward objective attainment.

Further analysis is presented in Figure 13 and Figure 14, which outline the average reward per step alongside the total reward per episode. The DQN algorithm, lacking a dueling architecture, frequently suffers from overestimation bias, resulting in unstable and overly optimistic Q-value estimations. While DQN might yield elevated per-step rewards, its total reward trajectory is characterized by wide fluctuations and a lack of coherence. Conversely, the noisy D3QN with PER exhibits more stable total rewards over time, signifying more effective long-term strategic planning,

despite registering marginally lower average per-step returns.

Table 3 encapsulates essential performance metrics, affirming that this algorithm surpasses its counterparts across several indicators, demonstrating fewer average steps, shorter path lengths, a higher number of feature points, and expedited training times. As detailed, the Noisy D3QN with PER substantially eclipses the performance of the other algorithms across several crucial benchmarks. It achieves the lowest average steps of 396.91 and path length of 196.00, while concurrently capturing the highest number of feature points of 77.10, highlighting its efficacy in navigation and visual positioning. Additionally, it registers the fastest training time per episode of 6.56 seconds, emphasizing its computational efficiency. Although it recorded a negative total reward of 13119.49, this figure represents a significant improvement over that of DQN, illustrating a more favorable balance between penalties and rewards throughout the learning phase.

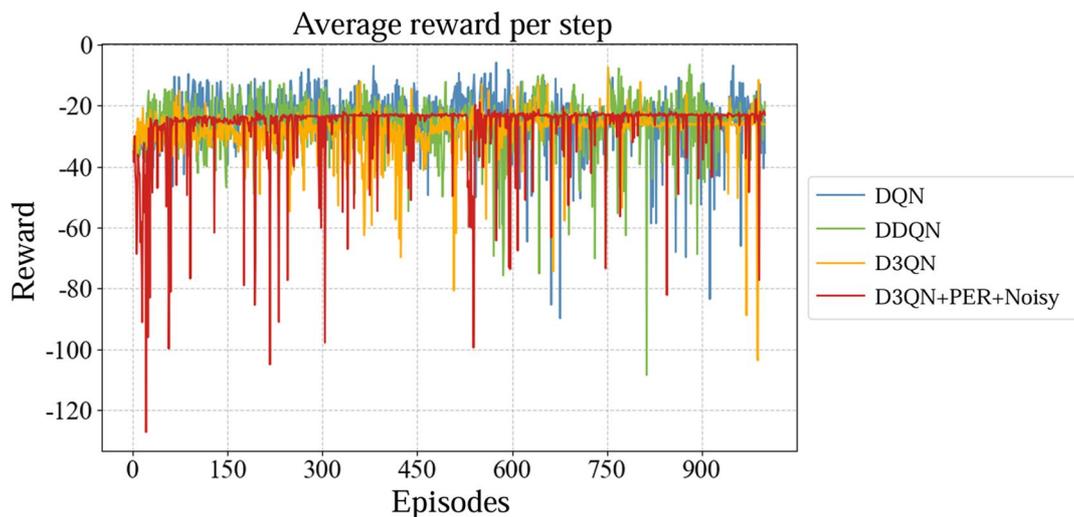


Figure 13 Average reward of generated path over episodes of the noisy D3QN with PER, D3QN, DDQN, DQN

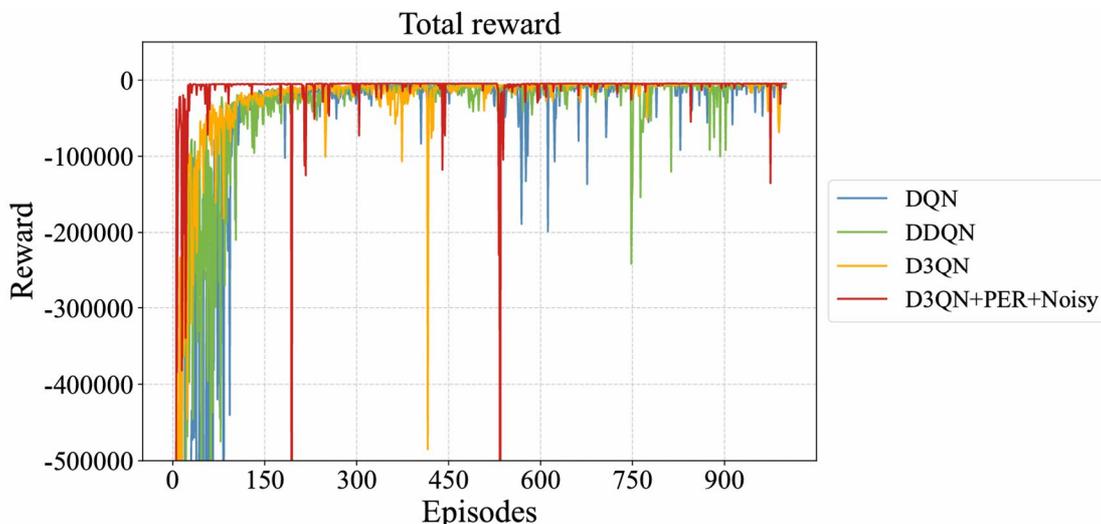


Figure 14 Total reward of generated path over episodes of the noisy D3QN with PER, D3QN, DDQN, DQN

Table 3 Performance comparison between Noisy D3QN with PER, D3QN, DDQN, DQN

Performance parameters	Noisy D3QN with PER	D3QN	DDQN	DQN
Total episodes	1000	1000	1000	1000
Average steps (per episode)	396	1309	2455	3843
Path length (single episode)	196.0	199.0	211.5	220.0
Total reward (single episode)	-13119	-39135	-71175	-115647
Average feature points (single episode)	77	71	70	75
Average training time (s)	6.56	9.75	17.07	22.74
Total training time (s)	6558.25	9754.52	17072.39	22735.01

In conclusion, the results of this investigation underscore that the integration of prioritized experience replay (PER) and noisy networks into the D3QN framework considerably enhances the learning efficiency of the agent, the quality of path planning, and its ability to perform visual localization. This evidence highlights the promising potential of advanced DQN variants for practical applications in UAV path planning within complex three-dimensional environments.

4. Conclusions

Path planning in 2.5D environments is inherently complex due to irregular terrain and the need for algorithms that manage dynamic obstacles and localization constraints. Traditional algorithms like Dijkstra, A*, and basic DQN methods are limited in such contexts, especially in terms of efficiency and adaptability. This study proposes an enhanced DQN-based framework incorporating Double DQN, Dueling Networks, Prioritized Experience Replay, and Noisy Nets. By using DSM data, image feature point density, and start/end positions as input, the system generates obstacle-aware and energy-efficient UAV trajectories suitable for visual localization. Bézier curve smoothing further improves trajectory feasibility. The framework is tailored for GPS-denied environments, enabling robust UAV localization through optimized image feature alignment. Results show improved training stability and adaptability across diverse terrain conditions. Moreover, it supports path inference from various starting points, enabling efficient individual path generation for multi-UAV navigation without frequent replanning—making it well-suited for real-time and resource-constrained scenarios. This work demonstrates that the future of robust autonomous navigation lies in learning-based planners that treat path quality and localization uncertainty as first-class citizens, moving beyond purely geometric optimality.

References

- Bezier, P., 1972. *Numerical Control: Mathematics and Applications*, John Wiley and Sons, London.
- Detone, D., Malisiewicz, T., and Rabinovich, A., 2018. SuperPoint: Self-supervised interest point detection and description, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, Salt Lake City, UT, USA, pp. 337-349, DOI: 10.1109/CVPRW.2018.00060.
- Fortunato, M., Azar, M.G., Piot, B., Menick, J., Hessel, M., Osband, I., Graves, A., Mnih, V., Munos, R., Hassabis, D., Pietquin, O., Blundell, C., and Legg, S., 2018. Noisy networks for exploration, *Proceedings of the 6th International Conference on Learning Representations, ICLR 2018 - Conference Track Proceedings*, Vancouver, Canada, DOI: 10.48550/arXiv.1706.10295.
- Huang, Z., and Li, T., 2023. Path planning for UAV assisted IOT data collection with dueling DQN, *Proceedings of the 42nd Chinese Control Conference (CCC)*, pp. 6227–6232, IEEE, Tianjin, China, DOI: 10.23919/CCC58697.2023.10240175.
- Lindenberger, P., Sarlin, P.E., and Pollefeys, M., 2023. LightGlue: Local feature matching at light speed, *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, Paris, France, DOI: 10.1109/ICCV51070.2023.01616.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A.A., Veness, J., Bellemare, M.G., Graves, A., Riedmiller, M., Fidjeland, A.K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., and Hassabis, D., 2015. Human-level control through deep reinforcement learning, *Nature*, 518(7540): 529–533, DOI: 10.1038/nature14236.

- Schaul, T., Quan, J., Antonoglou, I., and Silver, D., 2016. Prioritized experience replay, Proceedings of the 4th International Conference on Learning Representations, ICLR 2016 - Conference Track Proceedings, Caribe Hilton, San Juan, Puerto Rico, DOI: 10.48550/arXiv.1511.05952.
- Van Hasselt, H., Guez, A., and Silver, D., 2016. Deep reinforcement learning with double Q-learning, Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence, AAAI'16, pp. 2094–2100, AAAI Press, Phoenix, Arizona, USA, DOI: 10.1609/aaai.v30i1.10295.
- Villanueva, A., and Fajardo, A., 2019. UAV navigation system with obstacle detection using deep reinforcement learning with noise injection, Proceedings of the International Conference on ICT for Smart Society (ICISS), pp. 1–6, Bandung, Indonesia, DOI: 10.1109/ICISS48059.2019.8969798.
- Wang, Z., Schaul, T., Hessel, M., Van Hasselt, H., Lanctot, M., and De Frcitas, N., 2016. Dueling Network Architectures for Deep Reinforcement Learning, Proceedings of the 33rd International Conference on Machine Learning (ICML), Vol.48, New York, USA.
- Wu, X., Huang, S., and Huang, G., 2023. Deep reinforcement learning-based 2.5D multi-objective path planning for ground vehicles: Considering distance and energy consumption, Electronics, 12(18):3840, DOI: 10.3390/electronics12183840.
- Yao, J., Li, X., Zhang, Y., Ji, J., Wang, Y., Zhang, D., and Liu, Y., 2022. Three-dimensional path planning for unmanned helicopter using memory-enhanced dueling deep Q network, Aerospace, 9(8):417, DOI: 10.3390/aerospace9080417.
- Zhu, Z., Hu, C., Zhu, C., Zhu, Y., and Sheng, Y., 2021. An improved dueling deep double-Q network based on prioritized experience replay for path planning of unmanned surface vehicles, Journal of Marine Science and Engineering, 9(11): 1267, DOI: 10.3390/jmse9111267.

無人機視覺導航路徑規劃使用深度強化學習網路

黃珮瑄^{1*} 林昭宏²

摘要

傳統無人飛行載具 (UAV) 路徑規劃側重於優化路徑長度與能源效率等多種指標。然而，在無 GPS 環境中，視覺定位的品質至關重要。本研究使用深度強化學習 (DRL) 框架並引入優先經驗回放的噪聲雙決策深度 Q 網路 (Noisy D3QN with PER)，影像匹配的特徵點整合到路徑規劃中，共同優化路徑的幾何效率與視覺穩健性。此架構能有效解決稀疏獎勵和訓練不穩定問題，提高價值估計準確性與探索效率。實驗結果顯示，不僅產生高效、動態平滑且視覺連續的軌跡，並且在單次訓練後能從多個起始點推斷路徑。除了計算效率的改進，亦能提升複雜環境中視覺定位的性能與穩定性，以提高導航精度。

關鍵詞：強化學習、無人機、深度 Q 網路(DQN)

¹ 國立成功大學測量及空間資訊學系 碩士生

² 國立成功大學測量及空間資訊學系 教授

* 通訊作者, E-mail: hpei254@gmail.com

收到日期：民國 114 年 07 月 15 日

修改日期：民國 114 年 09 月 26 日

接受日期：民國 114 年 10 月 16 日

應用 Geo-AI 模型推估苗栗地區 NO₂ 濃度及影響因子貢獻解析

陳潔瑩¹ 賴忻宜¹ 曾于庭² 吳治達^{3,4,5,6,7*}

摘要

本研究以苗栗縣為示範區，整合氣象、地面監測、衛星遙測、土地利用與通霄電廠排放等多源資料，建構逐時、50 m × 50 m 解析度之 NO₂ 濃度推估模型。採用 XGBoost 演算法 SHAP 遞增篩選機制，選取一小時滯後，模型 R² 為 0.80，RMSE 為 1.78 ppb。SHAP 分析顯示 NO_x 與道路密度為最主要驅動因子，台電固定源亦具區域影響力。多層次驗證證實模型對時間、空間與高污染情境皆具穩健表現。研究展現 Geo-AI 於中小型縣市空品推估之應用潛力，亦為風險預警與污染治理提供量化依據。

關鍵詞：二氧化氮、地理人工智慧、機器學習、空間推估圖

1. 前言

空氣污染已被世界衛生組織列為全球最嚴峻的環境健康挑戰之一，而 NO₂ 更是同時兼具高社會關注度與高度健康風險的指標性污染物。NO₂ 主要產生於高溫燃燒過程，與化石燃料使用密切相關 (Vardoulakis *et al.*, 2020、Achakulwisut *et al.*, 2019)。在戶外環境中，道路交通可貢獻高達 80 % 的都市 NO₂ 濃度，燃煤或燃氣電力設施則構成重要背景來源；室內方面，燃氣爐灶、熱水器與暖爐等燃燒器具同樣能顯著升高 NO₂ 水平 (Tiotiu *et al.*, 2020)，而戶外濃度也會透過自然通風滲入室內。

NO₂ 已被確認為呼吸道刺激物，可引發急性咳嗽、喘鳴與支氣管痙攣，長期暴露則與全因死亡率與兒童氣喘顯著相關 (Qian *et al.*, 2021、Kashtan *et al.*, 2024)。全球疾病負擔研究估計，每年約有 400 萬例兒童新發氣喘可歸因於 NO₂，佔總病例數的 13 %，其中 92 % 發生於年均 NO₂ 低於世界衛生組織 (World Health Organization, WHO) 指南值 21 ppb 的

地區，突顯「低濃度亦具健康風險」的警訊 (Achakulwisut *et al.*, 2019)。長期暴露於較高 NO₂ 濃度還會導致呼氣一氧化氮 (FeNO) 上升，並使第一秒用力呼氣量 (forced expiratory volume in one second, FEV1) 和用力肺活量 (forced vital capacity, FVC) 下降。此外，孕期高暴露亦與嬰幼兒肺功能不良相關 (Tiotiu *et al.*, 2020、Vardoulakis *et al.*, 2020)。因此，降低 NO₂ 暴露已成為交通與都市環境管理的優先議題。

面對都市化、機動車輛與多元燃燒源交織的排放格局，如何在不同時空尺度上精準推估 NO₂ 濃度並量化各影響因子貢獻，已是公共衛生與環境決策的關鍵課題。近年來，地理人工智慧 (Geo-AI) 結合遙測影像、地面監測、氣象與土地利用資料，為高解析度空氣品質推估提供強大工具；然而，現有研究大多侷限於靜態特徵，較少探討排放與氣象交互作用的時間延遲 (lag effect)，亦缺乏系統化方法來解析各變數對預測結果的相對影響。

國際上，結合衛星觀測與機器學習以推估近地

收到日期：民國 114 年 07 月 11 日
修改日期：民國 114 年 09 月 03 日
接受日期：民國 114 年 10 月 15 日

¹ 國立成功大學測量及空間資訊學系 碩士生

² 國立成功大學測量及空間資訊學系 助理研究員

³ 國立成功大學測量及空間資訊學系 教授

⁴ 國家衛生研究院國家環境醫學研究所 兼任研究員

⁵ 國立中興大學永續農業創新發展中心 兼任研究員

⁶ 高雄醫學大學精準環境醫學研究中心 兼任研究員

⁷ 長庚科技大學慢性非傳染性暨健康促進研究中心 合聘研究員

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

表 NO₂ 已成主流。近年大型研究多以集成學習整合多源資料 (如衛星柱量、化學傳輸模型 (CTM)、地理與氣象)，在國家尺度以約 1 km、逐日產出地表 NO₂；例如美國全境研究以神經網路、隨機森林與梯度提升等模型集成，達到整體 $R^2=0.788$ (Di *et al.*, 2020)。在中國，全國尺度的三階段集成模型整合 OMI/TROPOMI、AOD、CTM 與高解析地理變數，於 1×1 km、逐日期間取得整體 $R^2=0.72$ 、空間 $R^2=0.85$ (Huang *et al.*, 2022)。亦有區域尺度研究以 TROPOMI 為核心，結合「氣象滯後項」與「時空項」的集成模型，10 折 $R^2=0.89$ 、時間與空間 R^2 分別為 0.71 與 0.81，顯示其在擷取短時變化與非線性耦合關係方面具體效益 (He *et al.*, 2022)。

在單一模型方面，多項研究證實，僅以單一樹系或增強式學習亦能達到穩健的 NO₂ 推估表現。日本大都市區以隨機森林為核心的時空 LURF 架構，在留一站交叉驗證下整體優於傳統線性模型，顯示單一演算法能有效擷取土地利用、排放源距離遞減與氣象要素之非線性關係 (Araki *et al.*, 2018)。於東亞尺度、以 TROPOMI 為主的研究系統比較 SVR、RF、XGBoost、LightGBM 等單一模型建立近地表 NO₂ 與 O₃ 的高空間解析度估測，結果顯示梯度提升法在多種驗證方案下具良好泛化表現，並可藉由特徵重要度解析衛星柱量與地表濃度的關聯 (Kang *et al.*, 2021)。在都會區交通主導情境中，採用隨機森林之「分段 (partition)」單一模型更能處理高、低濃度區間的結構性差異，提升 NO₂ 預測精度，較傳統單一 RF 具有顯著增益 (Kamińska, 2019)。此外，在感測器校正應用上，單一隨機森林可顯著提升低成本 NO₂ 感測器相對監測站的準確度與穩定性，支持其於實務部署的可行性 (Zimmerman *et al.*, 2018)。另有泛歐洲尺度之比較研究指出，多種單一機器學習法 (含樹系與增強式演算法) 在年均 NO₂/PM 的空間建模上優於基礎線性模型 (Chen *et al.*, 2019)，但具有地理加權的線性模型 (GWR/GTWR) 則展現出更佳或並列最佳的性能 (Shen *et al.*, 2022)，進一步凸顯單一非線性模型於廣域暴露評估的效能基準價值。

在單一學習的比較中，XGBoost 多次呈現 NO₂

的最佳或並列最佳預測力。以東亞 TROPOMI 資料同時比較 SVR、RF、XGBR、LGBMR 的研究顯示：在隨機/空間/時間三種交叉驗證下，樹系方法整體優於 SVR，而樹系中以「提升式」的 XGBR/LGBMR 表現最佳；其中針對 NO₂，XGBR 略勝並被選為後續最佳單一模型 ($R^2\approx 0.63-0.70$) (Kang *et al.*, 2021)。在短時序列預測 (如 1、8、12、24 小時同步預測) 與低成本感測器應用的情境下，研究指出 MSP 模型樹憑藉其樹狀結構效率與較強的泛化能力，在多變量建模中整體表現最佳，優於 SVM 與 ANN；相對地，ANN 在資料量相對較小且特徵多樣時較易過度擬合、表現最差。同時，納入氣象條件 (如濕度、風速) 與共存污染物 (如 SO₂) 的多變量建模可顯著提升 NO₂ 的預測精度 (Shaban *et al.*, 2016)。在空間建模領域，XGBR 的優勢仍然穩固。在中國東南沿海的區域尺度研究中，於相同資料與特徵配置下，三種單一樹系模型之表現排序一致為 XGBR > EXT (極端隨機樹) > RF (10 折交叉驗證 R^2 最高達 0.88)，再次支持 XGBR 為 NO₂ 單一演算法的領先者 (He *et al.*, 2022)。此外，在全中國 1×1 km 的長期集成研究中，雖三個單一模型 (RF/ERT/XGB) 整體 R^2 相近 (≈ 0.71)，但變數重要度分析顯示 XGBR 對 TROPOMI NO₂ 訊號的依賴度最高 (相對重要度約 43.9%)，突顯 XGBR 對衛星柱量訊號的敏感度與表徵力 (Huang *et al.*, 2022)。綜合而言，在特徵與驗證設計同質條件下，XGBR 通常能在 NO₂ 單一模型中取得最佳或並列最佳的準確度，且可配合 SHapley Additive exPlanations (SHAP) 等方法提供穩健的變數貢獻解讀 (Kang *et al.*, 2021、Hsu *et al.*, 2024)，適合作為本研究的單模基準與集成關鍵子模型。

跨國與中尺度研究普遍以「多源資料+多演算法」的集成框架顯著優於單一模型。美國全境日尺度 1 km 的研究以 NN、RF、GB 並結合 CTM/遙測等特徵建構集成，達成整體 10 折交叉驗證 $R^2=0.79$ 、空間 $R^2=0.84$ 、時間 $R^2=0.73$ ，並提供位址層級不確定度估計，適用於長短期健康研究 (Di *et al.*, 2020)。中國東南沿海的 TROPOMI 主導日尺度集成模型，納入「氣象滯後項」與「時空項」，10 折交叉驗證 $R^2=0.89$ 、時間/空間 $R^2=0.71/0.81$ ，顯示延

遲效應與相對位置編碼可顯著強化時空推論 (He *et al.*, 2022)。在中國全國 1×1 km、2013–2019 年的集成模型中，整合 OMI/TROPOMI、AOD、CTM 與高解析地理變數與三種樹系演算法，總體 $R^2=0.72$ 、空間 $R^2=0.85$ ，並於都會區進一步降維至 100 m，以捕捉道路鄰近的細尺度暴露梯度 (Huang *et al.*, 2022)。混合統計與機器學習的技術亦日益成熟：南加州以「一般化加性混合模型+集成學習+約束優化」建立 22 年雙週 NO₂/NO_x 序列，NO₂ 的集成 $R^2=0.85$ ，顯著優於初始單模型，且時間序列更平滑穩定 (Li *et al.*, 2017)。在台灣，本土 Geo-AI 已將集成混合空間模型 (EMSM) 推展至 50 m 超高解析度與分時段建模；針對 NO₂ 的日/夜兩時段模型，調整後 R^2 分別達 0.92/0.93，並驗證夜間與冬季濃度偏高之時段與季節型態，彰顯在地化集成模型對健康風險評估與政策應用的即時價值 (Babaan *et al.*, 2024)。相同 EMSM 策略也用於台灣通勤時段 O₃ 評估，在多種內外部驗證 (含極值、降雨/非降雨、平假日) 下仍維持高穩健性 (調整後 $R^2\approx 0.91$)，提供高時空解析度的暴露資訊以支援決策 (Hsu *et al.*, 2024)。

綜合而言，上述研究多在國家或大區域尺度產製日尺度網格；常用方法包含隨機森林、XGBoost、集成學習與卷積式神經網路等，證實多源資料融合對地表 NO₂ 估測之關鍵性 (He *et al.*, 2022、Huang *et al.*, 2022)。在地面監測導向的路徑中，土地利用與氣象特徵結合機器學習可有效解釋 NO₂ 的空間異質性；其中集成與混合建模能在高度非線性、多來源特徵的情境下提升穩健性，並支援後續的變數貢獻解析 (Li *et al.*, 2017、Di *et al.*, 2020)。台灣近年亦有 Geo-AI 於 50 m 生成 NO₂ 細網格並提供日/夜成果：如 Hybrid Kriging-LUR 結合 XGBoost 於 50 m 網格估計逐日 NO₂，解釋力可達 $R^2\approx 0.91$ ，並經外部、季節與城市分層等多重驗證證實模型穩健性 (Wong *et al.*, 2021)；進一步以 EMSM 建置日間/夜間 NO₂，於 50 m 解析度下調整後 $R^2=0.92/0.93$ ，呈現夜間與冬季濃度偏高之型態，顯示在本土資料條件下可達實務所需的時空解析度與準確度 (Babaan *et al.*, 2024)。

相較於多數聚焦「日尺度、 ≥ 1 km 空間解析度」

的研究，本研究於苗栗地區建置「逐時、50m×50m」之高解析度 NO₂ 模型，並引入 1–12 小時滯後資料庫以辨識短時延遲效應。流行病學證據顯示，污染物對健康影響常呈現「當日與滯後」的累積效應：以野火相關 PM_{2.5} 的全球時間序列研究為例，作者同時評估當日與單日滯後效應 (至 7 天)，並以 0–2 天移動平均為主要指標，且於敏感度分析中將最大滯後延長至 10 天以檢驗穩健性；結果顯示短期暴露對死亡風險的影響主要集中於前 0–2 天，而延長滯後窗可更全面地捕捉短期健康衝擊之輪廓 (Chen *et al.*, 2021)。基於此一證據鏈，本研究在 NO₂ 的短時暴露推估中納入多小時滯後資料庫，以提升風險評估之精確度與完整性。同時，結合 SHAP 量化氣象、土地利用與遙測等變數的相對影響 (Babaan *et al.*, 2024、He *et al.*, 2022、Huang *et al.*, 2022、Li *et al.*, 2017、Di *et al.*, 2020)，以兼顧模型之可解釋性與準確度。綜上，本研究旨在提升 NO₂ 推估的解釋力與精度，並為健康風險評估、污染管制與即時預警提供科學依據。

2. 研究材料

2.1 研究區域

本研究以臺灣中部西側的苗栗縣為對象，如圖 1 所示。苗栗縣幅員約 1820 km²，下轄 18 個鄉鎮縣市 (內政部戶政司，2023、內政部國土測繪中心，2023)，地形由西側濱海平原向東漸次過渡至丘陵與中低海拔山地，形塑出複雜的氣流場與污染傳輸路徑。縣內設有 11 座空氣品質監測站，其中 3 座為環境部常規測站，8 座為台電背景監測站；監測點位涵蓋沿海、平原與內陸谷地等多種地貌，有助於解析污染物在不同地形條件下的時空分布。

苗栗縣坐擁竹南、頭份、銅鑼等 6 座工業區，並鄰接大型天然氣複循環機組的通霄發電廠。相較於既有文獻多聚焦六都，苗栗縣雖屬非直轄市，仍受工業活動與能源設施影響，具備潛在空氣污染風險，卻常被忽略。本研究選擇苗栗作為樣區，旨在補足中小型縣市空品研究的缺口，驗證 Geo-AI 模型在複雜地形與多重排放源情境下的適用性。

本研究的資料期間設定為 2022 - 2023 年，以避開 COVID-19 防疫措施對交通流量與排放行為所造成的非常態擾動，確保基準年的排放與氣象條件具有代表性。許多研究證實，疫情期間的封城與行動限制使都會區 NO₂ 在短期內下降約 10 - 60%，並常伴隨 O₃ 上升；因此，本研究排除 COVID-19 衝擊年份，以維持模型在常態排放與氣象條件下的代表性與穩健性 (Cole *et al.*, 2020、Wang *et al.*, 2020、Petetin *et al.*, 2020、Keller *et al.*, 2021、Shi *et al.*, 2021、Yang *et al.*, 2021)。

2.2 資料庫介紹

本研究所使用之變數彙整於表 1，類別包含空氣汙染物、氣象因子、土地利用變數、衛星資料、台電因子與其他虛擬變數，以下逐一說明各類別資料。

2.2.1 空氣汙染物與氣象因子

本研究的空氣汙染物資料取自環境部開放平台，涵蓋 PM_{2.5}、NO₂、O₃、NO_x、PM₁₀ 與 SO₂ 六項指標。所有測站逐時觀測值先依 24 小時分段整理，再分別以空間克利金法 (Kriging Interpolation) 內插至 50 m × 50 m 格網，產製高解析度濃度圖層。研究的依變數為 NO₂，其餘五項汙染物作為自變數；

清理後共取得 164759 筆有效紀錄，整體缺漏率 14.5 %。

氣象資料則來自大氣科學研究與應用資料庫，處理流程與汙染物相同：逐時觀測值經克利金法內插至 50 m × 50 m，生成與汙染物圖層對應的高解析度網格。無降雨時雨量設定為 0，風向以箭矢標示方向與格點位置。

2.2.2 土地利用變數

本研究的土地利用資料同時涵蓋面狀、線狀與點狀三類空間要素。面狀部分包括農業、森林、交通、水利、建築、公共、遊憩與礦鹽等八大土地利用類型，並額外整合「工業區」圖層，將整合加工出口區、科學園區、報編工業區、農業生技園區與一般編定工業區統一編碼，以反映區域產業活動強度。線狀資料則採用路網數值圖，區分主要道路、當地道路與其他道路，作為交通排放與通風走廊的重要指標。點狀資料涵蓋各類商業與服務業據點，以及寺廟位置；後者因焚香與燒金紙為傳統文化排放來源，已被證實與 NO₂ 濃度呈正相關 (Babaan *et al.*, 2024)，故一併納入以完善空間解釋變數。圖 2 彙整上述要素：工業區以紅色面填色，道路以灰色線條表示，通霄發電廠則以符號點標示其位置。



圖 1 研究試區

表 1 本研究所用之變數清單

資料分類	資料來源	內容	時間解析度	空間解析度
空氣汙染物	環境部環境資料開放平臺	PM _{2.5} ($\mu\text{g}/\text{m}^3$)、SO ₂ (ppb)、NO _x (ppb)、PM ₁₀ ($\mu\text{g}/\text{m}^3$)、O ₃ (ppb)、NO ₂ (ppb)	每小時	50 m × 50 m
氣象因子	大氣科學研究與應用資料庫	平均溫度(°C)、平均相對溼度(%)、平均大氣壓力(hPa)、平均風速(m/s)、總降雨量(mm)	每小時	50 m × 50 m
土地利用變數	內政部國土測繪中心國土利用調查資料庫	森林、農地、水體、住宅區、商業區、工業區、工業園區、寺廟、火化場、焚化爐、道路等		50 m × 50 m
衛星資料	MODIS 全球常態化 NDVI 資料庫 (MOD13Q1)第 6.1 版	NDVI	每月	250 m × 250 m
	歐洲太空局(ESA)的哨兵 -5P 衛星 (Sentinel-5 Precursor)	對流層二氧化氮垂直柱濃度	每日	5.5 km × 3.5 km
	歐洲中期天氣預報中心(ECMWF)的第五代再分析資料	ERA5 行星邊界層 Boundary Layer Height (BLH)	每小時	0.25° × 0.25°
台電因子	台灣電力公司資料開放平台	連續排放監測系統 (CEMS)、發電量、污染物排放量	每小時	50 m × 50 m
其他	虛擬變數(節慶因子)	新年、元宵節、清明節、端午節、中元節、中秋節		

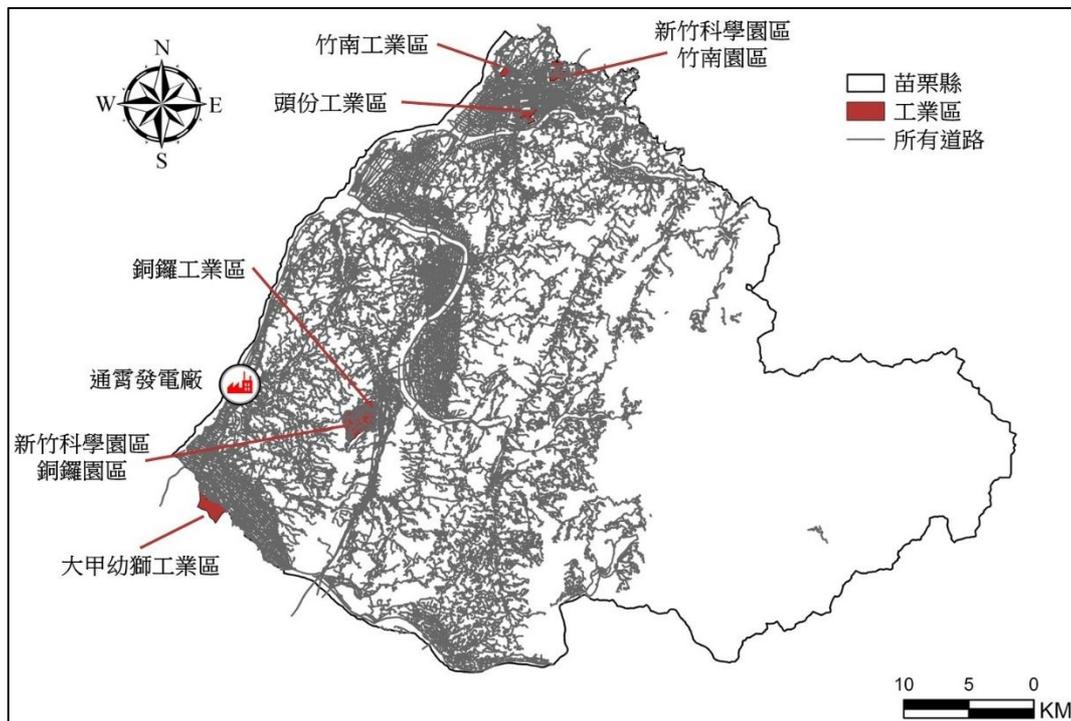


圖 2 研究區域內「點、線、面」示範圖層

2.2.3 衛星資料

本研究選用的衛星遙測變數可分為三類。第一類為綠覆度指標，採用 NASA MODIS 250 m × 250

m 解析度的常態化差值植生指數 (Normalized Difference Vegetation Index, NDVI)；該產品每月提供兩景完整覆蓋臺灣的影像，透過紅光與近紅外光反射率差異評估植被生長程度。第二類為大氣污染

指標，取用歐洲太空總署 Sentinel-5P (TROPOMI) 每日資料，擷取對流層二氧化氮柱濃度 (mol/m^2)，空間解析度為 $5.5 \text{ km} \times 3.5 \text{ km}$ ，以描繪境外輸送與整體氣膠負荷。第三類為邊界層結構參數，使用 ECMWF ERA5 再分析的行星邊界層(m)，解析度 $0.25^\circ \times 0.25^\circ$ ，時間尺度為逐時，可捕捉大氣混合作用隨時間之變化。

2.2.4 台電因子

電力相關資料由臺灣電力公司提供，內容包括：通霄電廠廠址與六座機組煙囪的精確坐標、研究期間各機組逐時的發電量與 NO_x 排放量，以及連續排放監測系統 (CEMS) 追蹤的 NO_x 排放紀錄。

2.2.5 其他

為反映傳統節慶活動帶來的短期排放衝擊，本研究參考 Hsu *et al.* (2024) 的作法，將農曆新年、元宵、清明、端午、中元與中秋六大節日設計為二元變數：節日當日標記為 1，其餘時間為 0，並納入模型。相關研究指出，焚香、燒金紙與燃放爆竹等習俗會在節慶期間造成顆粒物與氣體污染物瞬間增加，進而影響區域空氣品質。表 2 詳列六大節慶的具體日期，涵蓋節日當天及其相應的國定連假時段。

表 2 虛擬變數之日期

節慶	2022 年	2023 年
春節	1/29~2/6	1/20~1/29
元宵節	2/15	2/5
清明節	4/2~4/4	4/1~4/5
端午節	6/3~6/5	6/22~6/25
中元節	8/12~8/14	8/30
中秋節	9/9~9/11	9/29~10/1

3. 研究方法

本研究方法流程如圖 3 所示，可分為五大步驟：(1)資料庫建置；(2)時間延遲效應評估；(3)模型建構與變數篩選；(4)分層驗證；(5)變數影響度分析與高解析度 NO_2 空間推估。以下分述各環節內容。



圖 3 研究流程圖

3.1 資料庫建置

首先彙整六大資料來源：衛星、土地利用、氣象、空氣污染物、節慶活動與台電因子。所有資料經投影統一至 TWD97 / TM2 座標系，時間戳調整為臺灣標準時間並依逐時尺度對齊。各變數重採樣至 $50 \text{ m} \times 50 \text{ m}$ 格網後，剔除缺漏值與異常值，最終形成涵蓋 2022–2023 年 164759 筆時空樣本、逾 500 個候選變數的整合資料庫。

為確保不同資料源在同一空間與時間尺度下運作，所有原始變數先完成座標轉換、單位統一與標準化。土地利用相關變數進一步計算 14 種環域範圍 (50、150、250、500、750、1000、1250、1500、1750、2000、2500、3000、4000、5000 m)：

- (1) 對面狀與線狀資料 (如工業區、路網)計算「面積/長度密度」，反映排放源集中度；
- (2) 對點狀資料 (如寺廟、商服據點)計算「點密度」；
- (3) 同時求取每一格網到最近同類排放源的直線距離。

衛星資料 (NDVI、對流層二氧化氮柱濃度、行星邊界層) 則先重新取樣至 50 m × 50 m，確保解析度與格網一致。完成上述處理後，各類變數即可在統一的時空框架下供 XGBoost 模型訓練使用。

3.2 時間延遲效應評估

為捕捉 NO₂ 濃度對短期排放與氣象波動的「短尾」滯後反應，本研究先為所有隨時間劇烈變動的自變數 (例如氣象參數、機組排放量等) 建立 1-12 小時的滯後版本。對每一滯後期 (lag 1-lag 12)，計算這些變數與 NO₂ 濃度的皮爾森相關係數，並取其絕對值後的平均值，作為該滯後期的整體關聯強度指標。

皮爾森相關係數適用於衡量變數間的線性關聯，雖然其嚴格假設變數近似常態分布，但在大樣本下對偏態分布具有相當穩健性。本研究僅將相關係數用作篩選延遲效應的相對比較依據，而非進行顯著性檢定，因此即使部分變數分布未完全符合常態，仍可合理應用。最終選取平均相關性最高的單一滯後期，並僅納入該視窗下的變數進入後續 XGBoost 建模，以保留具代表性的延遲訊號，同時降低資料冗餘與模型複雜度。先前研究亦指出，在逐時或短時尺度之污染預測中納入短期滯後特徵，可更有效表徵排放與氣象的交互延遲影響並提升模型表現 (Wei *et al.*, 2021、He *et al.*, 2022)。

3.3 模型建構與變數篩選

本研究以 NO₂ 濃度作為目標變數，將其餘時空因子納為解釋變數，建立梯度提升決策樹 (XGBoost) 模型。之所以採用 SHAP，是因其 (1)基於合作賽局理論，具一致性與可加總性，能提供穩健、可比較的特徵貢獻；(2)同時給出「全域」與「個別預測」(局部)的解釋，有利於釐清不同時段、氣象條件與空間位置下之機制；(3)對樹系模型可用

TreeSHAP 快速計算，適合高維、多滯後與大量資料；(4)可輔助偏差診斷與政策溝通，提升模型的可稽核性與可用性 (García & Aznarte, 2020)。

變數挑選採用 SHAP 值遞增策略，流程如下：首先以完整模型計算各變數之 SHAP 全域重要度並依數值大小排序；接著按此順序將變數逐一加入模型並重新訓練；若新增變數使模型解釋力 (R²) 提升至少 0.01，則視為關鍵變數並予以保留。透過此遞增篩選，可在保留關鍵資訊的同時排除冗餘特徵，降低過度擬合風險並優化模型之可解釋性與穩健性。

3.4 分層驗證

為評估模型的穩健度與泛化能力，本研究規劃四套互補的驗證機制。首先，將全部資料隨機分割出 20% 作為獨立測試集，用以檢視基本預測誤差；其次，從年、月、日、時四個時間尺度比對預測與觀測值，以驗證時間一致性；第三，針對 11 座空品測站評估空間殘差分布，並探討不同區域下的敏感度；最後，結合十折交叉驗證以降低抽樣偏差，並選取濃度前 10%、20%、25% 的樣本進行極端濃度測試，檢視模型在高污染情境中的表現。

3.5 變數影響度分析與高解析度 NO₂ 空間推估

在確定模型穩健可靠後，本研究以 SHAP 值評估各變數對 NO₂ 預測的相對貢獻，並將數值轉換為百分比，以凸顯主要驅動因子。隨後擇定研究期間 NO₂ 觀測值最高的日期，將最終模型套用至完整的 50 m × 50 m 網格，逐時推估當日 NO₂ 濃度分布，生成高解析度時空圖，以輔助後續熱點檢測與風險評估。

4. 結果

4.1 NO₂ 敘述統計

表 3 彙整研究期間 NO₂ 的敘述統計結果。整體而言，NO₂ 平均濃度為 7.04 ± 3.95 ppb，範圍介於 0.0-49.6 ppb，顯示本研究區域 NO₂ 濃度在不同時段

具有相當變動性。進一步比較年度差異，2022 年平均濃度為 7.37 ± 3.97 ppb，整體高於 2023 年的 6.72 ± 3.90 ppb。四分位數亦呈現一致趨勢：2022 年的第一、第二及第三四分位數 (4.4、6.8、9.7 ppb) 均略高於 2023 年 (3.8、6.0、8.9 ppb)。這反映 2022 年在整體與分布中值上皆普遍高於 2023 年，可能與當年度氣象條件、排放量變化或區域背景污染有關。最大值方面，兩年度分別落在 47.2 與 49.6 ppb，顯示偶發性高濃度事件在不同年份皆存在。

4.2 時間延遲選擇

圖 4 顯示 NO₂ 與各自變數在 1–12 小時滯後 (lag1–lag12) 下之絕對平均皮爾森相關係數。可見相關性在 lag1 達到最高峰 (≈ 0.12 ，紅點標示)，隨滯後時間遞增而快速衰減，至 lag7 降至最低 (≈ 0.075)，其後略有回升但始終未超過 0.085。此趨勢印證 NO₂ 對短期排放與氣象變動的「短尾型」延遲特性：暴露後 1 小時即展現最大聯動，6–8 小時後影響顯著減弱。

根據絕對平均相關係數最高原則，本研究選擇 lag1 作為所有高變動變數的代表滯後期，並將該時間窗下的資料納入後續 XGBoost 模型，以捕捉最具解釋力的延遲訊號，同時避免引入冗餘滯後變數造成模型複雜度上升。

4.3 模型表現

表 4 彙整 XGBoost 模型在三種評估情境下的績效指標：訓練集 (80%)、獨立測試集 (20%)、以及十折交叉驗證 (10-Fold Cross Validation)。訓練階段模型可解釋 80% 的 NO₂ 變異 ($R^2 = 0.80$)，均方根誤差 (Root Mean Square Error, RMSE) 為 1.78 ppb，顯示在已見過的資料上具備良好擬合度。當模型應用到未參與建模的外部測試集時， R^2 下降至 0.69，RMSE 上升至 2.23 ppb，仍維持相當水準的預測能力，表示模型泛化性尚佳但略有高估趨勢。十折交叉驗證所得 R^2 (0.68) 與測試集幾乎一致，RMSE 為 2.22 ppb，進一步證實抽樣方式不同時模型的穩定性。整體而言，XGBoost 能在多時空變數環境中有效捕捉 NO₂ 濃度分布，且訓練、測試與交叉驗證結果差異不大 (R^2 僅差 0.12)，僅出現適度的擬合落差，反映所採 SHAP 遞增篩選有助抑制過度擬合並保留關鍵訊息。

圖 5 進一步以散佈圖呈現 NO₂ 的觀測值與模型預測值之間的對應關係。點位大致分布於 45° 參考線附近，顯示模型預測結果與實際觀測值整體趨勢一致。圖中亦標示 $R^2 = 0.80$ 與 $RMSE = 1.78$ ppb，與表 3 中訓練集的數值相符，直觀展現模型在資料擬合上的表現。此結果不僅呼應統計指標，也提供視覺化證據支持模型具備合理的解釋力與預測力。

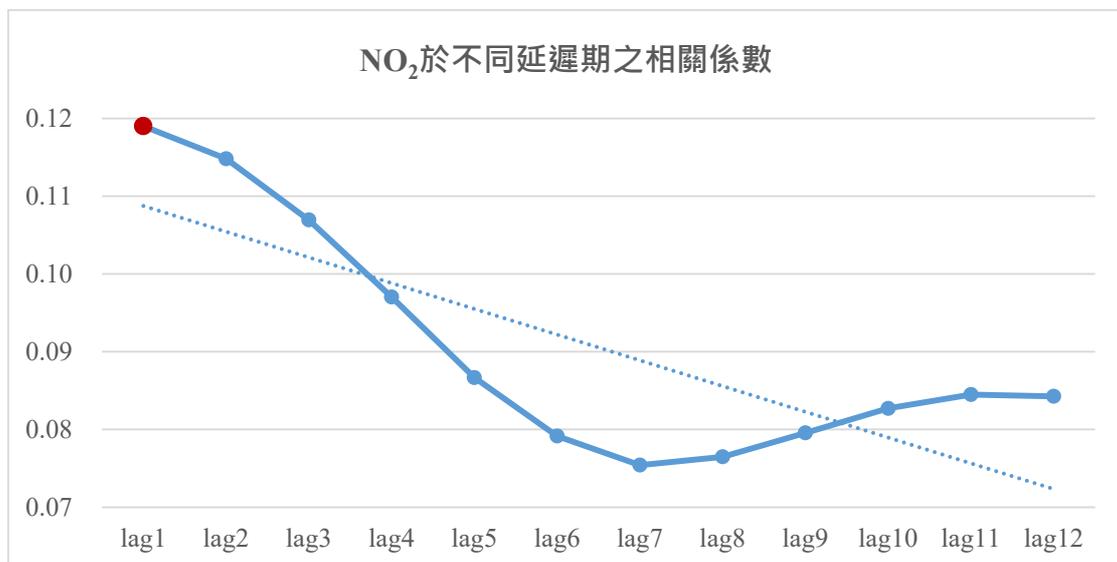


圖 4 lag1 至 lag12 之絕對平均相關係數折線圖

表 3 研究期間 NO₂ 敘述統計之結果

	平均值±標準差	最小值	第一四分位數	第二四分位數	第三四分位數	最大值
整體	7.04±3.95	0.0	4.1	6.4	9.3	49.6
2022 年	7.37±3.97	0.0	4.4	6.8	9.7	47.2
2023 年	6.72±3.90	0.1	3.8	6.0	8.9	49.6

註：單位均為 ppb，四捨五入至小數第一位。

表 4 XGBoost 模型之訓練集、測試集與十折交叉驗證表現

	R ²	Adjusted R ²	RMSE	MSE	MAE
Training	0.80	0.80	1.78	3.15	1.01
Testing	0.69	0.69	2.23	4.99	1.22
10-Fold CV	0.68	0.68	2.22	4.92	1.24

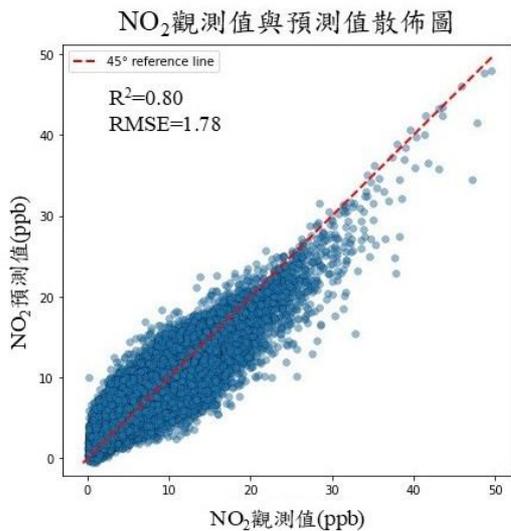


圖 5 NO₂ 原始觀測值與最終模型之預測值散佈圖

4.4 變數篩選結果與重要性比較

圖 6 以 SHAP 分析呈現最終模型的關鍵變數：在圖 6(a)中，NO_x 的 SHAP 分布最寬且均位於正值區域，顯示其濃度越高，對 NO₂ 預測的推升效應越大；所有道路環域 1000 m 位居其次，驗證交通排放為區域背景 NO₂ 的主要來源。氣溫、相對濕度與風速等氣象因子，則透過抑制或促進大氣混合作用調節 NO₂；其中高溫與低濕條件傾向升高濃度，而高風速則顯著降低濃度。

臭氧 (O₃) 則反映了 NO-NO₂-O₃ 光化學平衡，其與 NO₂ 既可能呈現正相關 (透過 O₃ 氧化 NO 生成 NO₂)，也可能因交通排放下的 O₃ 消耗作用而呈現負相關 (Crutzen, 1970)，因此在模型中成為重要的解釋變數。

植被指標 NDVI 最大值環域 5000 m 與 NO₂ 呈負相關，支持綠覆度具有稀釋與沉降作用。柱狀圖

圖 6 (b)將前十大變數的平均 SHAP 值量化，可見 NO_x (+1.52)遠高於其他因子，凸顯同源污染在短尺度內的直接影響，而交通、氣象與植被變數分別扮演次要但不可或缺的調節角色。

進一步將所有變數依屬性歸納 (表 5)，可發現空氣污染物類別占總貢獻的~42%，其中 NO_x 與 O₃ 為最具代表性的化學驅動因子；氣象因子與土地利用變數分別貢獻約 24%與 22%，顯示大氣擴散條件及交通/綠地格局共同主宰區域 NO₂ 分布；台電因子 (9%) 則反映固定源排放的區域影響力；最後，境外污染指標僅佔 3%，顯示在 2022–2023 年的苗栗背景條件下，對流層 NO₂ 柱濃度對地面濃度的直接解釋力有限。整體而言，交通相關排放 (NO_x、道路)加上氣象穩定度 (氣溫、風速、相對濕度、行星邊界層) 構成影響苗栗地區 NO₂ 的核心組合，而植被覆蓋與固定源距離則提供額外的空間異質性訊息，使模型能夠細緻捕捉高低濃度帶。

4.5 分層驗證

圖 7 與表 6 彙整模型在多層次驗證中的指標。整體而言，模型在不同時空層級與極端濃度情境皆維持良好且一致的預測能力，細部結果如下。

- (1) 時間驗證：逐日驗證的 R² 介於 0.76–0.82，對應 RMSE 1.62–1.88 ppb；逐月 R² 落在 0.71–0.88，呈現春、冬兩季較高，夏、秋稍低的季節律。兩年平均 R² 均為 0.80，RMSE 分別為 1.80 ppb (2022 年)與 1.75 ppb (2023 年)，顯示模型能穩定捕捉長週期變化。逐時尺度 R² 為 0.74–0.83，RMSE 1.44–2.01 ppb，說明模型對短時波動亦具備充足敏感度。

- (2) 極端值驗證：當樣本限制在 NO_2 濃度前 25%、20%與 10% 時， R^2 分別為 0.61、0.61、0.65；雖較全樣本略低，但各組 RMSE 皆小於 2 ppb，證實即便在高污染事件期間模型仍具可接受的預測精度。
- (3) 空間驗證 (表 6)：11 座監測站 R^2 分佈於 0.66–0.85。其中三義 (0.66)與苑裡 (0.71)因位於丘陵轉折與背風側，預測較為保守；內島里與海岸里均為 0.74，其餘測站皆 ≥ 0.75 。站點 RMSE 介於 1.54–2.13 ppb，與全區平均 RMSE 相近，顯示空間誤差無明顯集聚。

綜合上述，模型在年、月、日、時四層時間尺度的 R^2 差距不超過 0.2，RMSE 差異小於 0.6ppb；空間與極端情境驗證亦呈現穩定表現，證明 SHAP 遞增篩選與滯後優選策略有效抑制過度擬合、保留主要物理與排放訊號，使模型具備良好的預測能力與實務應用潛力。

4.6 NO_2 時空推估圖

圖 8 至圖 11 連續呈現 2023 年 2 月 1 日

0–23 時的 NO_2 推估圖，是研究期間原始觀測值最高的高污染事件日。當日 NO_2 的高濃度始終鎖定在竹南與頭份一帶，即便午間海風與高邊界層將全區大部分濃度壓至 10–20 ppb，該區仍維持 25–40 ppb 的局部熱點；傍晚邊界層收縮後，熱點更迅速堆升至 40 ppb 以上。若與圖 2 的土地利用示意相互參照，高值中心正好覆蓋竹南科學園區、竹南工業區與頭份工業區等複合產業聚落，同時也是全縣道路最密集的交通走廊。圖中灰色線網標示的主要與次要道路在竹南–頭份交會成輻射狀，連接國道一號、省道台 1 線及多條縣鄉道，使車流量遠高於其他鄉鎮。工業排放與高密度車流疊加，再加上地形開闊、海風午後轉內陸的條件，形成固定源與移動源共同推升的區域性污染。因此，高值區的空間位置並非孤立的氣象現象，而是工業區與道路網絡共同主導的結果；這也印證 SHAP 分析中「 NO_x 濃度」與「道路環域 1000m」分別排名第一、第二的重要性，兩者在竹南–頭份的高度耦合，解釋了該區日內濃度始終居高不下的原因。

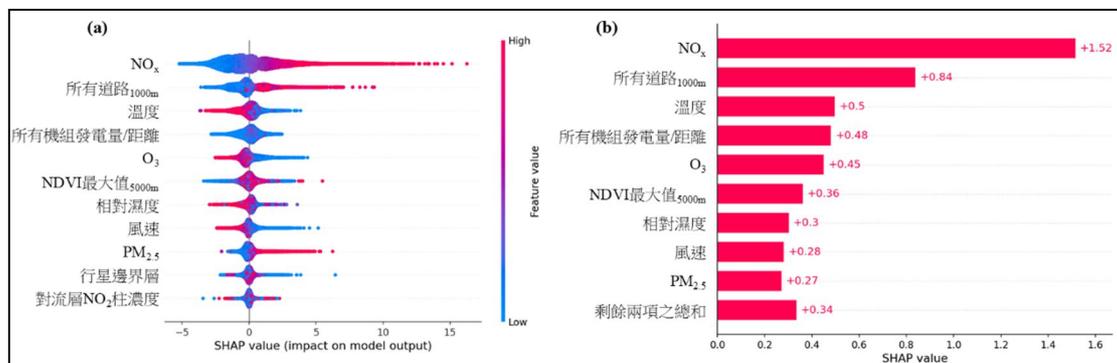


圖 6 變數 SHAP 值及作用方向：(a) 逐筆 SHAP 分布；(b) 全域平均 SAHP 值柱狀圖

表 5 變數重要性百分比

類別	百分比	變數	百分比
空氣汙染物	41.9%	NO_x	28.4%
		O_3	8.4%
		$\text{PM}_{2.5}$	5.1%
氣象因子	23.9%	溫度	9.3%
		相對濕度	5.7%
		風速	5.3%
		行星邊界層	3.6%
土地利用變數	22.5%	所有道路 1000m	15.7%
		NDVI 最大值 5000m	6.8%
境外汙染物	2.6%	對流層 NO_2 柱濃度	2.6%
台電因子	9.0%	所有機組發電量/距離	9.0%

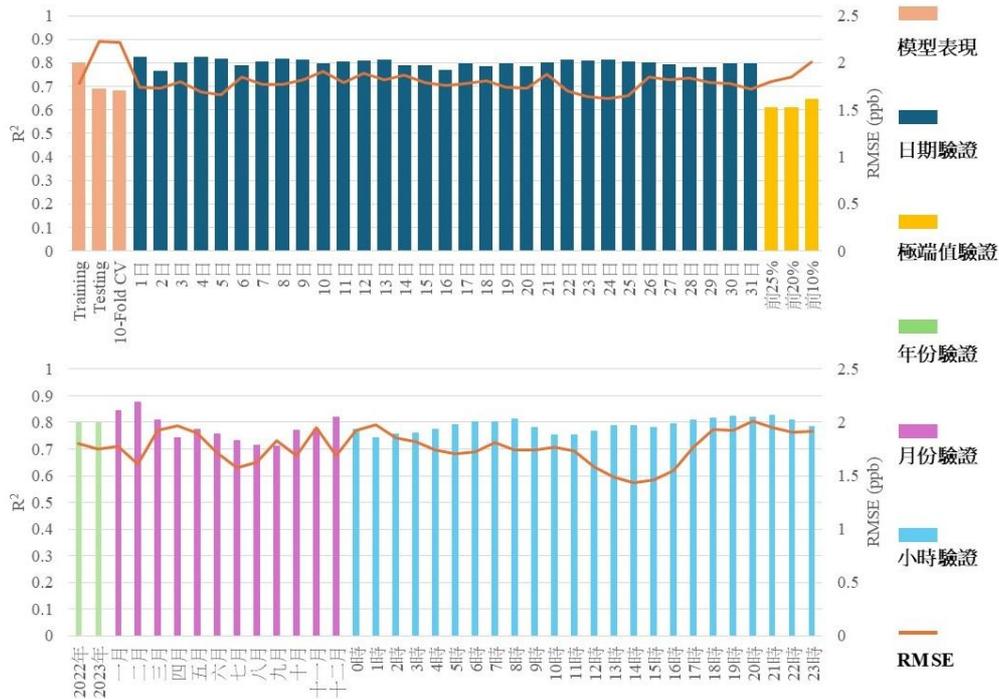


圖 7 模型多層次驗證直方圖

表 6 各測站之分層驗證

測站名	筆數	R ²	Adjusted R ²	R	MSE	RMSE	MAE
海岸里	11010	0.74	0.74	0.86	3.78	1.94	1.48
苗栗	12669	0.83	0.83	0.91	4.02	2.00	1.47
內島里	11445	0.74	0.74	0.86	2.47	1.57	1.18
三義	12864	0.66	0.66	0.81	3.32	1.82	1.32
通南	12573	0.75	0.75	0.87	2.81	1.68	1.29
通灣	12185	0.79	0.79	0.89	2.67	1.63	1.24
通霄	9387	0.80	0.80	0.90	2.47	1.57	1.18
通霄所	12606	0.80	0.80	0.89	2.36	1.54	1.17
頭份	12858	0.85	0.85	0.92	4.53	2.13	1.54
五北	12279	0.75	0.75	0.87	3.16	1.78	1.35
苑裡	11905	0.71	0.71	0.84	2.87	1.70	1.31

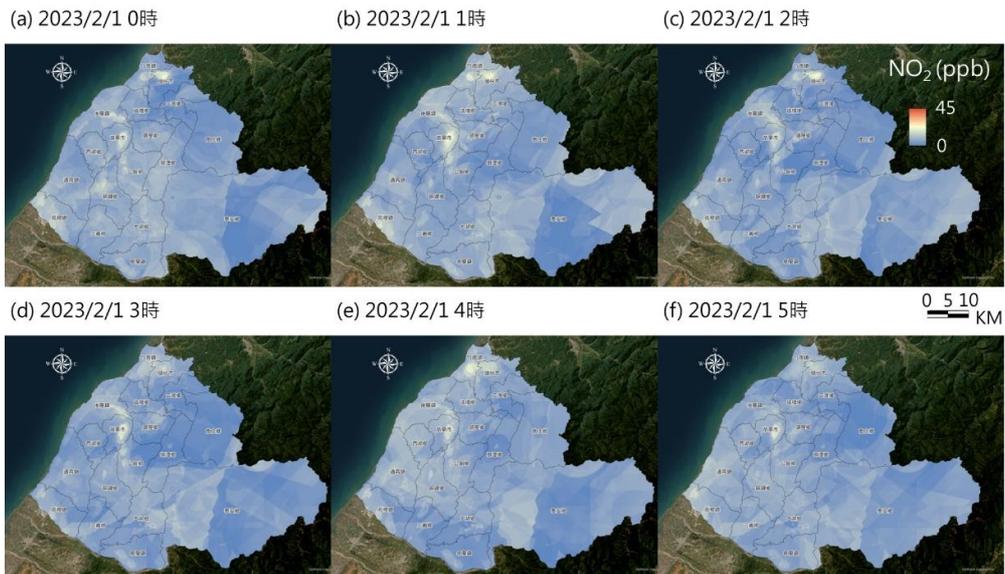


圖 8 NO₂ 2023 年 2 月 1 日 0~5 時推估圖

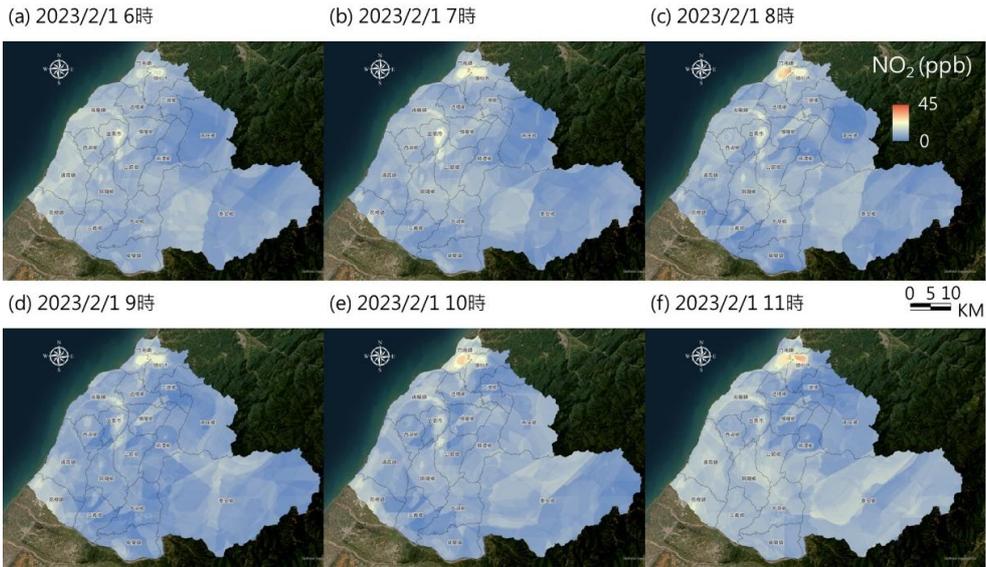


圖 9 NO₂ 2023 年 2 月 1 日 6~11 時推估圖

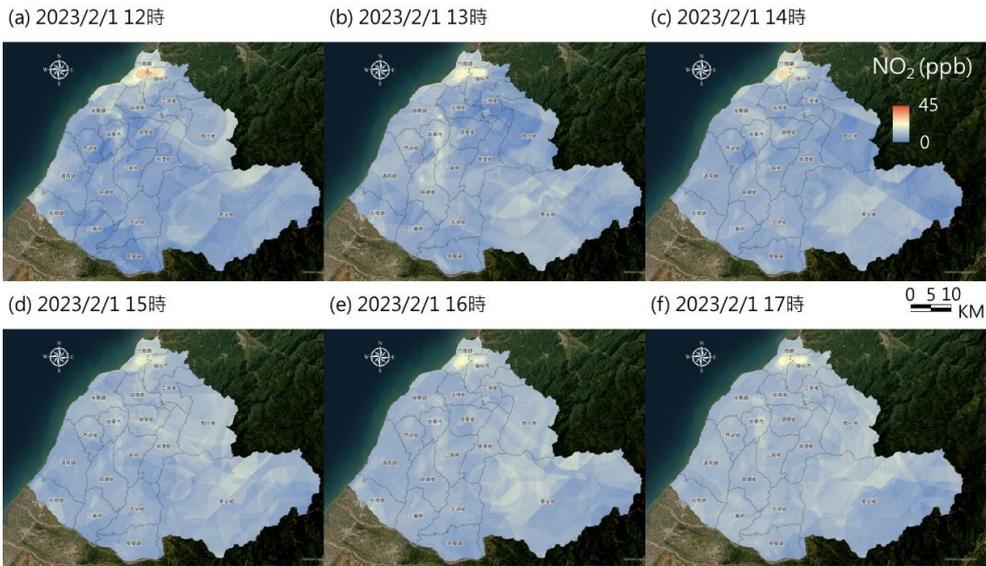


圖 10 NO₂ 2023 年 2 月 1 日 12~17 時推估圖

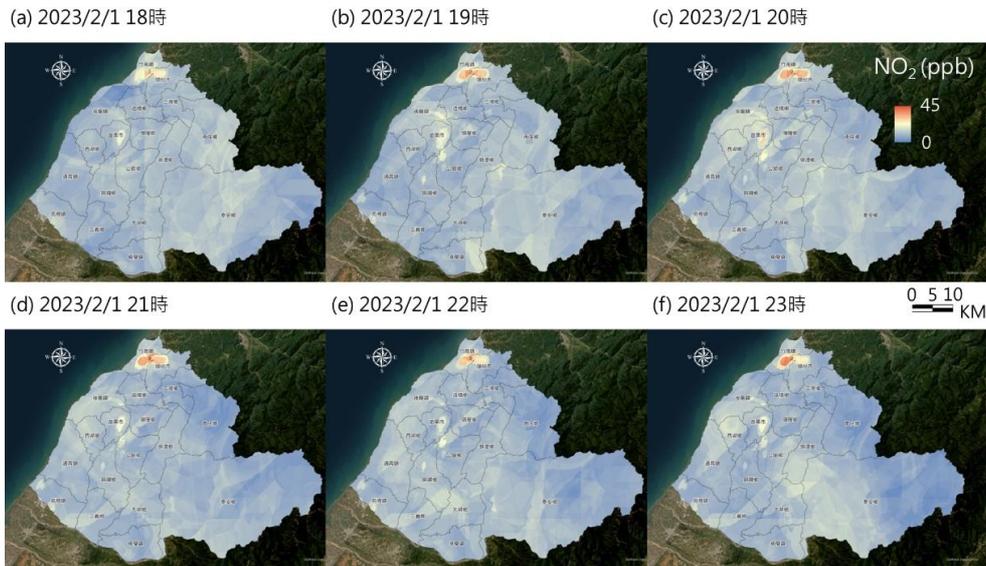


圖 11 NO₂ 2023 年 2 月 1 日 18~23 時推估圖

5. 討論

5.1 模型表現與篩選變數分析

本研究以 lag 1 為代表滯後期，結合 XGBoost 與 SHAP 遞增篩選建立 NO₂ 預測模型。訓練集、獨立測試集與十折交叉驗證的 R² 分別為 0.80、0.69、0.68，RMSE 介於 1.78–2.23 ppb；三組結果差距僅 0.12，顯示過度擬合已被抑制，模型具有良好穩定性。

在時間分層驗證中，日、月、年、時四層尺度的 R² 介於 0.71–0.88，RMSE 變化僅 0.6 ppb；即使限制至濃度前 10% 的極端事件，RMSE 仍 < 2 ppb，證明模型能穩定捕捉短-中期波動並對高污染情境保持可接受精度。空間驗證顯示 11 座測站 R² 範圍 0.66 – 0.85，除丘陵背風側的三義 (0.66) 與苑裡 (0.71) 略低外，其餘站點皆 ≥ 0.74；RMSE 1.54 – 2.13 ppb，與全區平均誤差相近，顯示空間殘差無明顯集聚。

SHAP 分析指出，NO_x (28.4%) 為首要推升因子，反映同源污染對 NO₂ 的直接影響；道路環域 1000 m (15.7%) 排名第二，驗證交通排放的重要性。整體貢獻依序為空氣污染物 41.9%、氣象因子 23.9%、土地利用 22.5%、台電固定源 9%、境外輸送 2.6%—突顯交通與擴散條件的共同主導力。

5.2 研究優勢與限制

本研究最大的優勢，在於首度於中小型縣市層級，同步整合氣象、地面監測、衛星遙測、土地利用與通宵電廠資料等五百餘項變數至 50 m × 50 m、逐時解析度的網格，並以 SHAP 遞增篩選機制在每一次特徵增刪時設定 $\Delta R^2 \geq 0.01$ 的門檻，兼顧模型效能與解釋力，同時有效抑制冗餘資訊導致的過擬合。分層驗證進一步證實模型在各種情境下皆維持穩健精度，顯示其作為政策評估與動態預警工具的可行性。然而，本研究亦存在若干限制：首先，監測站點主要分布於沿海與平原，丘陵及背風地形樣本相對不足，導致三義等站點誤差稍高，暗示地形複雜區的模型不確定性仍待下降；其次，固定源排

放係以推估瞬時排放，可能低估尖峰排放對濃度場的瞬時影響；第三，本研究時間跨度僅涵蓋 2022–2023 兩年，尚不足以解析長期的排放趨勢與氣候變化效應；最後，雖使用節慶虛擬變數扣除短期行為干擾，仍缺乏移動監測與個體暴露資料，無法直接量化健康效應或交通動態對模型的影響。

5.3 未來方向

未來研究可從資料與方法兩方面同步精進：在資料層面，建議於山區與背風側增設固定站或微型感測器，以補齊地形複雜區的觀測缺口，並持續擴充時間序列至五年以上，以利評估能源轉型與氣候變動的長期效應；同時，可引入高時空解析衛星產品，提升夜間與雲遮條件下的填補能力。在方法層面，未來可以採用「整合單一機器學習至集成混和空間模型 (Ensemble Mixed Spatial Model, EMSM)」的概念，將不同演算法的優勢匯聚於一體，以提高濃度預測的精度與穩健性。應用方面，未來可將逐時濃度與健保資料鏈結，探討不同暴露水平對急診就診、氣喘發生等健康指標的短期效應，並搭配在地政府排放管制清單，建立高頻空品預報暨早期警報系統；同時，透過將本方法移植至其他縣市，可比較不同能源結構下的排放特徵與污染熱點，進一步驗證模型並支持區域合作的污染治理策略。

6. 結論

本研究整合五百餘項多源資料，於 50 m × 50 m、逐時尺度上建構具解釋性的 NO₂ 機器學習模型，驗證顯示在時空層級皆維持 R² ≥ 0.70 且 RMSE < 2.3 ppb 的穩健表現。SHAP 解析揭示 NO_x 與交通密度為最關鍵驅動因子，與以往文獻結果一致。方法上，SHAP 遞增篩選有效平衡效能與可解釋力，為中小型縣市空品評估提供可複製的框架；應用上，逐時推估圖與特徵貢獻度可直接支援風險預警與排放管制情境模擬。

本研究亦存在限制：監測佈點與觀測期程仍有限，且瞬時固定源排放可能被低估。未來可透過增設監測據點、延長時序，並導入 EMSM 以提升外推能力與政策決策價值，為能源轉型與區域空品改善

奠定更扎實的科學基礎。此外，建議結合在地微型感測與移動監測以補足複雜地形區的觀測缺口，並在集成模型框架下強化夜間與極端天氣情境；國內既有研究亦顯示，Geo-AI 與集成式方法可在本土資料條件下產製高品質細網格成果，支援實務端之預警與管制 (Hsu *et al.*, 2022、Hsu *et al.*, 2024、Babaan *et al.*, 2024)。

參考文獻

- 內政部戶政司，2023。人口統計資料，<https://www.ris.gov.tw/>，引用 2024/04/18。 [Department of Household Registration, M.O.I., 2023. Population statistics by administrative division, Available at: <https://www.ris.gov.tw/> , Accessed April 18, 2024. (in Chinese)]
- 內政部國土測繪中心，2023。行政區域統計，<https://www.nlsc.gov.tw/>，引用 2024/04/18。 [National Land Surveying and Mapping Center, 2023. Administrative area statistics, Available at: <https://www.nlsc.gov.tw/>, Accessed April 18, 2024. (in Chinese)]
- Achakulwisut, P., Brauer, M., Hystad, P., and Anenberg, S.C., 2019. Global, national, and urban burdens of paediatric asthma incidence attributable to ambient NO₂ pollution: estimates from global datasets, *Lancet Planetary Health*, 3(4): e166-e178, DOI: 10.1016/S2542-5196(19)30046-4.
- Araki, S., Shima, M., and Yamamoto, K., 2018. Spatiotemporal land use random forest model for estimating metropolitan NO₂ exposure in Japan, *Science of The Total Environment*, 634: 1269-1277, DOI: 10.1016/j.scitotenv.2018.03.324.
- Babaan, J., Wong, P.-Y., Chen, P.-C., Chen, H.-L., Lung, S.-C.C., Chen, Y.-C., and Wu, C.-D., 2024. Geospatial artificial intelligence for estimating daytime and nighttime nitrogen dioxide concentration variations in Taiwan: A spatial prediction model, *Journal of Environmental Management*, 360: 121198, DOI: 10.1016/j.jenvman.2024.121198.
- Chen, G., Guo, Y., Yue, X., Tong, S., Gasparri, A., Bell, M.L., Armstrong, B., Schwartz, J., Jaakkola, J.J.K., Zanobetti, A., Lavigne, E., Saldiva, P.H.N., Kan, H., Roye, D., Milojevic, A., Overcenco, A., Urban, A., Schneider, A., Entezari, A., Vicedo-Cabrera, A.M., Zeka, A., Tobias, A., Nunes, B., Alahmad, B., Forsberg, B., Pan, S.C., Iniguez, C., Ameling, C., Valencia, C.D.L.C., Astrom, C., Houthuijs, D., Dung, D.V., Samoli, E., Mayvaneh, F., Sera, F., Carrasco-Escobar, G., Lei, Y., Orru, H., Kim, H., Holobaca, I.H., Kysely, J., Teixeira, J.P., Madureira, J., Katsouyanni, K., Hurtado-Diaz, M., Maasikmets, M., Ragetti, M.S., Hashizume, M., Stafoggia, M., Pascal, M., Scortichini, M., Coelho, M.D.S.Z.S., Ortega, N.V., Rytty, N.R.I., Scovronick, N., Matus, P., Goodman, P., Garland, R.M., Abrutzky, R., Garcia, S.O., Rao, S., Fratianne, S., Dang, T.N., Colistro, V., Huber, V., Lee, W., Seposo, X., Honda, Y., Guo, Y.L., Ye, T., Yu, W., Abramson, M.J., Samet, J.M., and Li, S., 2021. Mortality risk attributable to wildfire-related PM_{2.5} pollution: A global time series study in 749 locations, *Lancet Planetary Health*, 5(9): e579-e587, DOI: 10.1016/S2542-5196(21)00200-X.
- Chen, J., de Hoogh, K., Gulliver, J., Hoffmann, B., Hertel, O., Ketzler, M., Bauwelinck, M., van Donkelaar, A., Hvidtfeldt, U.A., Katsouyanni, K., Janssen, N.A.H., Martin, R.V., Samoli, E., Schwartz, P.E., Stafoggia, M., Bellander, T., Strak, M., Wolf, K., Vienneau, D., Vermeulen, R., Brunekreef, B., and Hoek, G., 2019. A comparison of linear regression, regularization, and machine learning algorithms to develop Europe-wide spatial models of fine particles and nitrogen dioxide, *Environment International*, 130: 104934, DOI: 10.1016/j.envint.2019.104934.
- Cole, M.A., Elliott, R.J.R., and Liu, B., 2020. The

- impact of the Wuhan Covid-19 lockdown on air pollution and health: A machine learning and augmented synthetic control approach, *Environmental and Resource Economics*, 76: 553-580, DOI: 10.1007/s10640-020-00483-4.
- Crutzen, P.J., 1970. The influence of nitrogen oxides on the atmospheric ozone content, *Quarterly Journal of the Royal Meteorological Society*, 96: 320-325, DOI: 10.1002/qj.49709640815.
- Di, Q., Amini, H., Shi, L., Kloog, I., Silvern, R., Kelly, J., Sabath, M.B., Choirat, C., Koutrakis, P., Lyapustin, A., Wang, Y., Mickley, L.J., and Schwartz, J., 2020. Assessing NO₂ concentration and model uncertainty with high spatiotemporal resolution across the contiguous United States using ensemble model averaging, *Environmental Science & Technology*, 54(3): 1372-1384, DOI: 10.1021/acs.est.9b03358.
- García, M.V., and Aznarte, J.L., 2020. Shapley additive explanations for NO₂ forecasting, *Ecological Informatics*, 56: 101039, DOI: 10.1016/j.ecoinf.2019.101039.
- He, S., Dong, H., Zhang, Z., and Yuan, Y., 2022. An ensemble model-based estimation of nitrogen dioxide in a southeastern coastal region of China, *Remote Sensing*, 14(12): 2807, DOI: 10.3390/rs14122807.
- Hsu, C.-Y., Lee, R.-Q., Wong, P.-Y., Lung, S.-C.-C., Chen, Y.-C., Chen, P.-C., Adamkiewicz, G., and Wu, C.-D., 2024. Estimating morning and evening commute period O₃ concentration in Taiwan using a fine spatial-temporal resolution ensemble mixed spatial model with Geo-AI technology, *Journal of Environmental Management*, 351: 119725, DOI: 10.1016/j.jenvman.2023.119725.
- Hsu, C.-Y., Xie, H.-X., Wong, P.-Y., Chen, Y.-C., Chen, P.-C., and Wu, C.-D., 2022. A mixed spatial prediction model in estimating spatiotemporal variations in benzene concentrations in Taiwan, *Chemosphere*, 301: 134758, DOI: 10.1016/j.chemosphere.2022.134758.
- Huang, C., Sun, K., Hu, J., Xue, T., Xu, H., and Wang, M., 2022. Estimating 2013-2019 NO₂ exposure with high spatiotemporal resolution in China using an ensemble model, *Environmental Pollution*, 292: 118285, DOI: 10.1016/j.envpol.2021.118285.
- Kamińska, J.A., 2019. A random forest partition model for predicting NO₂ concentrations from traffic flow and meteorological conditions, *Science of The Total Environment*, 651: 475-483, DOI: 10.1016/j.scitotenv.2018.09.196.
- Kang, Y., Choi, H., Im, J., Park, S., Shin, M., Song, C.-K., and Kim, S., 2021. Estimation of surface-level NO₂ and O₃ concentrations using TROPOMI data and machine learning over East Asia, *Environmental Pollution*, 288: 117711, DOI: 10.1016/j.envpol.2021.117711.
- Kashtan, Y., Nicholson, M., Finnegan, C.J., Ouyang, Z., Garg, A., Lebel, E.D., Rowland, S.T., Michanowicz, D.R., Herrera, J., Nadeau, K.C., and Jackson, R.B., 2024. Nitrogen dioxide exposure, health outcomes, and associated demographic disparities due to gas and propane combustion by U.S. stoves, *Science Advances*, 10(18): eadm8680, DOI: 10.1126/sciadv.adm8680.
- Keller, C.A., Evans, M.J., Knowland, K.E., Hasenkopf, C.A., Modekurty, S., Lucchesi, R.A., Oda, T., Franca, B.B., Mandarino, F.C., Díaz Suárez, M.V., Ryan, R.G., Fakes, L.H., and Pawson, S., 2021. Global impact of COVID-19 restrictions on the surface concentrations of nitrogen dioxide and ozone, *Atmospheric Chemistry and Physics*, 21(5): 3555-3592, DOI: 10.5194/acp-21-3555-2021.
- Li, L., Lurmann, F., Habre, R., Urman, R., Rappaport, E., Ritz, B., Chen, J.C., Gilliland, F.D., and Wu, J., 2017. Constrained mixed-effect models with ensemble learning for prediction of nitrogen

- oxides concentrations at high spatiotemporal resolution, *Environmental Science & Technology*, 51(17): 9920-9929, DOI: 10.1021/acs.est.7b01864.
- Petetin, H., Bowdalo, D., Soret, A., Guevara, M., Jorba, O., Serradell, K., and Pérez García-Pando, C., 2020. Meteorology-normalized impact of the COVID-19 lockdown upon NO₂ pollution in Spain, *Atmospheric Chemistry and Physics*, 20(18): 11119-11141, DOI: 10.5194/acp-20-11119-2020.
- Qian, Y., Li, H., Rosenberg, A., Li, Q., Sarnat, J., Papatheodorou, S., Schwartz, J., Liang, D., Liu, Y., Liu, P., and Shi, L., 2021. Long-term exposure to low-level NO₂ and mortality among the elderly population in the Southeastern United States, *Environmental Health Perspectives*, 129(12): 127009, DOI: 10.1289/EHP9044.
- Shaban, K., Kadri, A., and Rezk, E., 2016. Urban air pollution monitoring system with forecasting models, *IEEE Sensors Journal*, 16(8): 2598-2606, DOI: 10.1109/JSEN.2016.2514378.
- Shen, Y., de Hoogh, K., Schmitz, O., Clinton, N., Tuxen-Bettman, K., Brandt, J., Christensen, J.H., Frohn, L.M., Geels, C., Karssenberg, D., Vermeulen, R., and Hoek, G., 2022. Europe-wide air pollution modeling from 2000 to 2019 using geographically weighted regression, *Environment International*, 168: 107485, DOI: 10.1016/j.envint.2022.107485.
- Shi, Z., Song, C., Liu, B., Lu, G., Xu, J., Van Vu, T., Elliott, R.J.R., Li, W., Bloss, W.J., and Harrison, R.M., 2021. Abrupt but smaller than expected changes in surface air quality attributable to COVID-19 lockdowns, *Science Advances*, 7(3): eabd6696, DOI: 10.1126/sciadv.abd6696.
- Tiotiu, A.I., Novakova, P., Nedeva, D., Chong-Neto, H.J., Novakova, S., Steiropoulos, P., and Kowal, K., 2020. Impact of air pollution on asthma outcomes, *International Journal of Environmental Research and Public Health*, 17(17): 6212, DOI: 10.3390/ijerph17176212.
- Vardoulakis, S., Giagloglou, E., Steinle, S., Davis, A., Smeuwenhoek, A., Galea, K.S., Dixon, K., and Crawford, J.O., 2020. Indoor exposure to selected air pollutants in the home environment: A systematic review, *International Journal of Environmental Research and Public Health*, 17(23): 8972, DOI: 10.3390/ijerph17238972.
- Wang, Y., Wen, Y., Wang, Y., Zhang, S., Zhang, K.M., Zheng, H., Xing, J., Wu, Y., and Hao, J., 2020. Four-month changes in air quality during and after the COVID-19 lockdown in six megacities in China, *Environmental Science & Technology Letters*, 7(11): 802-808, DOI: 10.1021/acs.estlett.0c00605.
- Wei, J., Li, Z., Pinker, R.T., Wang, J., Sun, L., Xue, W., Li, R., and Cribb, M., 2021. Himawari-8-derived diurnal variations in ground-level PM_{2.5} pollution across China using the fast space-time Light Gradient Boosting Machine (LightGBM), *Atmospheric Chemistry and Physics*, 21(10): 7863-7880, DOI: 10.5194/acp-21-7863-2021.
- Wong, P.-Y., Su, H.-J., Lee, H.-Y., Chen, Y.-C., Hsiao, Y.-P., Huang, J.-W., Teo, T.-A., Wu, C.-D., and Spengler, J.D., 2021. Using land-use machine learning models to estimate daily NO₂ concentration variations in Taiwan, *Journal of Cleaner Production*, 317: 128411, DOI: 10.1016/j.jclepro.2021.128411.
- Yang, J., Wen, Y., Wang, Y., Zhang, S., Pinto, J.P., Pennington, E.A., Wang, Z., Wu, Y., Sander, S.P., Jiang, J.H., Hao, J., Yung, Y.L., and Seinfeld, J.H., 2021. From COVID-19 to future electrification: Assessing traffic impacts on air quality by a machine-learning model, *Proceedings of the National Academy of Sciences of the United States of America*, 118(26): e2102705118, DOI:

- 10.1073/pnas.2102705118.
- Zimmerman, N., Presto, A.A., Kumar, S.P.N., Gu, J., Hauryliuk, A., Robinson, E.S., Robinson, A.L., and Subramanian, R., 2018. A machine learning calibration model using random forests to improve sensor performance for lower-cost air quality monitoring, *Atmospheric Measurement Techniques*, 11(1): 291-313, DOI: 10.5194/amt-11-291-2018.

Application of Geo-AI Modeling to Estimate NO₂ Concentrations and Analyze Contributing Factors in Miaoli, Taiwan

Chieh-Ying Chen¹ Sin-Yi Lai¹ Yu-Ting Zeng² Chih-Da Wu^{3,4,5,6,7*}

Abstract

This study takes Miaoli County as a demonstration area to develop a high-resolution NO₂ estimation model by integrating multiple data sources, including meteorological data, ground monitoring, satellite remote sensing, land use, and data from the Tongxiao Power Plant. An hourly 50 m × 50 m resolution model was constructed using the XGBoost algorithm combined with a SHAP-based incremental feature selection mechanism, with lag1 (1-hour lag) identified as the optimal time delay. The model achieved an R² of 0.80 and an RMSE of 1.78 ppb. SHAP analysis revealed that NO_x and road density were the most influential predictors, while emissions from the power plant also exhibited regional impact. Multilevel validation confirmed the model's robustness across temporal, spatial, and high-pollution scenarios. The results demonstrate the potential of Geo-AI in air quality estimation for small and medium-sized counties and provide a quantitative basis for risk warning and pollution control.

Keywords: Nitrogen Dioxide, Geo-AI, Machine Learning, Spatial Estimation Map

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

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

³ Professor, Department of Geomatics, National Cheng Kung University

⁴ Adjunct Associate Research, National Institute of Environmental Health Sciences, National Health Research Institutes

⁵ Adjunct Professor, Innovation and Development Center of Sustainable Agriculture, National Chung Hsing University

⁶ Adjunct Research, Research Center for Precision Environmental Medicine, Kaohsiung Medical University

⁷ Joint Appointment Research, Chronic Diseases and Health Promotion Research Center, Chang Gung University of Science and Technology

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

Received Date: Jul. 11, 2025

Revised Date: Sep. 03, 2025

Accepted Date: Oct. 15, 2025

結合水文分析及 UAV 數值地表模型進行旱溪溢淹檢討

施廷儒¹ 王畊貴² 蔡慧萍^{3*}

摘要

本研究主要貢獻為應用 UAV 數值地表模型提供精細的斷面資料，針對台中旱溪進行水文分析與洪水溢淹模擬。配合台中氣象站 104 年雨量資料，以五種機率分布模型推估一日最大暴雨量，經檢定與誤差分析，對數皮爾森三型為最佳模型。以符合旱溪實況之三角形單位歷線法進行洪水模擬，並利用 HEC-RAS 進行七種重現期距模擬。研究結果發現旱溪第四段於 50 年與 100 年洪水重現期距下有溢淹情形。本研究結合 UAV 數值地表模型提供精細的斷面資料，提升模擬精度與可靠性，分析成果可提供水利單位於河道整治與防洪規劃之參考。

關鍵詞：旱溪、水文分析、UAV、數值地表模型

1. 前言

隨著工業革命後溫室氣體排放急遽上升，因此全球地表及海洋不斷升溫，然而全球暖化導致極端天氣事件日益頻繁，包含強降雨、洪水與乾旱等 (Panthou *et al.*, 2014、Zandalinas *et al.*, 2021)。根據政府間氣候變化專門委員會 (Intergovernmental Panel on Climate Change, IPCC) 報告，未來熱帶氣旋之峰值可能增加 5 至 10%，降雨量可能增加 20 至 30%。極端降雨引發洪水、旱災及邊坡滑動等災害，尤以洪水發生頻率最高，占自然災害損失約 30% (Vitousek, 1994、Mousavi *et al.*, 2011、Alfieri *et al.*, 2017、Haque *et al.*, 2019)。

臺灣地處東南亞季風氣候帶，屬高山島嶼地形，雖降雨豐沛但時空分布不均，加上河川短促流急，導致對極端降雨極為敏感 (朱芳儀等, 2018；李忠勳及葉信富, 2020)。1961 至 2015 年間，臺灣強降雨明顯增加，而中、小雨量則相對減少，導致總雨量變化不大，但降雨分布更不均。其中，最弱 10% 降雨隨氣溫上升 1°C 而減少 53%，最強 10% 則增加

78%，梅雨期總雨量也呈現下降趨勢 (蔡怡真, 2017)。觀察百年來的溫度與降雨距平資料，發現 1950 年前氣溫多低於平均、雨量變化緩和，1950 年後氣溫顯著上升，降雨型態呈現劇烈震盪，乾旱與豪雨交錯出現 (汪中和, 2015)。鍾侑達等 (2009) 對臺灣四區分析 1972 至 2007 年間雨量資料，發現中部如濁水溪與大安溪流域總雨量及降雨天數減少，但暴雨量、洪峰流量與豪雨日數皆上升，顯示雨勢更集中且時間分布不均。並且進一步利用標準化降雨指標法 (Standardized Precipitation Index, SPI) 及標準化地下水水位指標評估法 (Standardized Groundwater level Index, SGI) 指標評估顯示，中部地區氣候呈現「乾季愈乾、濕季愈濕」的極端化趨勢 (許心藜及葉信富, 2018)。

近年來無人機飛行載具 (Unmanned Aerial Vehicles, UAV) 的技術發展蓬勃，其機動性高且可快速獲取空間資訊，不受地形與環境限制，能進入傳統調查人員難以抵達的區域，已廣泛應用於水文分析。根據 Mourato *et al.* (2017) 指出，2000 至 2020 年間共計 122 項相關研究中，有 84.4% 聚焦於地表水，

¹ 國立中興大學土木工程學系 碩士

² 國立中興大學土木工程學系 博士生

³ 國立中興大學土木工程學系 副教授

* 通訊作者, E-mail: huiping.tsai@nchu.edu.tw

收到日期：民國 114 年 06 月 30 日

修改日期：民國 114 年 07 月 31 日

接受日期：民國 114 年 09 月 04 日

僅 15.6% 探討地下水，顯示地表水為研究主流，尤以洪水與水位探測為主 (Vélez-Nicolás *et al.*, 2021)。傳統洪水研究多為大尺度，缺乏小尺度地形與水文資料，而 UAV 搭配 DSM 可補足這一缺口 (Annis *et al.*, 2020)。例如在法國 Buëch 河流域，研究發現 2015 年河道較 2014 年顯著侵蝕左岸，可能危及鄰近基礎建設 (Hemmelder *et al.*, 2018)。其他如土耳其 (Akay *et al.*, 2020)、荷蘭 (Duró *et al.*, 2018)、中國 (Wang *et al.*, 2016) 等地亦有相關應用案例。在臺灣，UAV 已被應用於災後調查 (簡榮興, 2013)、水工構造物調查 (胡通哲等, 2017)、表面流速分析 (陳彥伶, 2017)、河道變遷 (謝有忠, 2016) 及輸砂量變化 (邱翰廷, 2016) 等研究。UAV 若結合 GPS 即時動態定位 (Real Time Kinematic, RTK) 技術，可產製高精度正射影像與數值地表模型 (Digital Surface Model, DSM)，並符合內政部地籍測量標準。UAV 的廣角視角及高精度成果亦有助於修正與擴充原有地形資料 (Watanabe & Kawahara, 2016)。無論為定翼機或旋翼機，在良好天氣下皆可取得高品質資料，但地面控制點分布的均勻性仍為 DSM 精度的關鍵因素 (張崑等, 2017)。因此基於上述，本研究之目的如下列所述：

- (1) 了解早溪流域雨量變化。
- (2) 分析早溪水文條件變化。
- (3) 分析在雨量和水文條件改變下，早溪哪些斷面可能發生溢淹。
- (4) 利用 UAV 協助分析並擴充早溪溢淹斷面資料。

2. 研究區域

本研究選定之早溪為烏溪中游大里溪水系主要支流之一，長 61.91 km，集水面積 134.4 km²，流經豐原區、潭子區、北屯區、北區、東區及大里區 (圖 1)，上游源自豐原山區，地勢使其河短流急，下游地勢趨緩。早期河道蜿蜒且不固定，常因豪雨改道，造成洪害。1989 年「七二七水災」後，先總統李登輝指示辦理「大里溪水系整治計畫」，涵蓋大里溪、早溪、大坑溪、葫子溪、頭汙坑溪、草湖溪等，共整治 53 km，其中早溪最重要工程為「早溪改道」，將下游截彎取直提前匯入大里溪，兩岸興建堤防，

並與大坑溪一同規劃為區域排水系統。自 1990 年改道後，未再發生洪害。

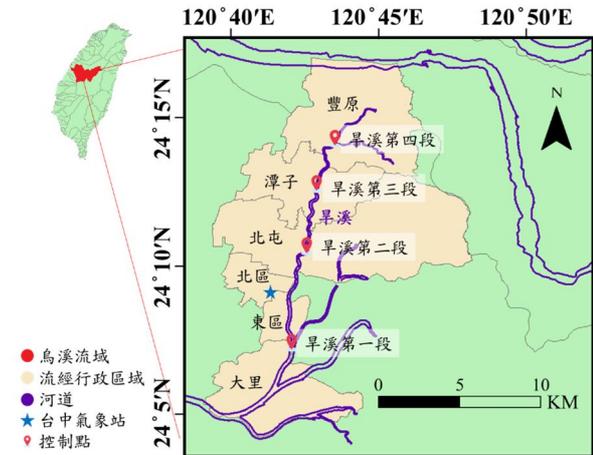


圖 1 早溪流經之行政區範圍與水文控制點分布圖

臺灣地形呈南北長、東西短，河流多短促且流急。經濟部水利署設有十個河川局負責管理，本研究區域隸屬經濟部水利署第三河川局 (三河局)，負責大安溪、大甲溪及烏溪流域的河川與海堤管理、水文資料蒐集及工程執行等業務。三河局保存大量早溪水文資料，本研究參考《水文設計應用手冊》(國立臺灣大學生物環境系統工程學系, 2001) 及 2014 年《大里溪支流早溪治理規劃檢討水文分析報告》，並與 1990 年報告結果比較，發現各控制點洪峰流量皆上升，但尚無溢淹危機。

本研究彙整 1990 年「大里溪水系整治計畫」之早溪水文控制點位置 (圖 1)，與 2014 年「大里溪支流早溪治理規劃檢討水文分析報告」之水文因子資料 (表 1)。早溪全長分為四段，設有 89 條斷面，總集水面積 134.4 km²，流路長 61.91 km²，高程差 172.406 m。早溪第一段為下游，集水面積最大、流路最長、高程差也最大；而早溪第四段為上游，集水面積最小、流路最短、高程差高居第二。

3. 研究材料

3.1 雨量資料

本研究採用台中氣象站 1921 年至 2024 年之逐日雨量作為研究資料，經整理後得圖 2。由降雨天數之時間序列分析，發現每年的降雨天數呈顯著之

負趨勢($p < 0.005$)，由年雨量之時間序列分析，發現歷年來年雨量呈不顯著之負趨勢($p = 0.750$)。平均年降雨天數為 117 天，平均年雨量為 1723.58 mm。

由於 1990 年旱溪改道，因此就其改道前後之雨量級距發生次數時間序列進行分析，雨量分級參考中央氣象局 2020 年 3 月所公布之最新定義。大雨事件次數於 1990 年前呈不顯著之負趨勢($p = 0.509$)，1990 年後呈不顯著之正趨勢($p = 0.789$)，如圖 3(a)所示；豪雨等級以上事件的次數於 1990 年前後皆不顯著之負趨勢($p = 0.825$ 以及 0.721)如圖 3(b)所示。綜合年雨量與降雨次數的分析(圖 2 與圖 3)，雖然發現年雨量不顯著之負趨勢，且降雨天數減少，但大雨事件場次呈不顯著之正趨勢，代表降雨強度變大且越發集中，日後強降雨愈強，弱降雨愈弱；乾溼對照會更加顯著。

3.2 計畫流量

計畫流量(洪峰流量分配)引用自「大里溪支流旱溪治理規劃檢討水文分析報告」之洪峰流量分配圖(經濟部水利署第三河川局, 2014)，如圖 4 所示。以重現期距 100 年為例，可見旱溪上游由北坑溪、中坑溪及南坑溪三者匯流而成，在旱溪第四段洪峰流量達 368cms，烏牛欄溪於旱溪第三段匯流，洪峰

流量達 710 cms，在旱溪第二段及第一段，沒有其他河道匯流，最後以洪峰流量 1230 cms 於斷面 78 處匯入大里溪。圖中標示旱溪各分段之頭尾斷面及各段在重現期距 100 年時的計畫流量。

3.3 斷面資料

本研究採用之 2020 年斷面資料由三河局提供，通常於 2 至 3 年便會再次施測，若期間有遇到洪害或地震等可能改變河貌之事件，酌情增加施測次數。旱溪斷面編號為 77-118，共 89 條斷面，外業人員以步行方式穿梭河道斷面，當該斷面中遇到地形起伏時，就必須量測此處之地形高程，常因人員判斷地形起伏標準不一、該地形不利於架設儀器或人員站立，導致儀器或稜鏡並未拿正等原因造成誤差。

3.4 無人飛行載具

UAV 可依飛行方式可分類為定翼機與旋翼機，前者飛行穩定但需提供跑道起飛；後者飛行穩定度較低但定點拍攝容易且機動性高。本研究因研究區域之河道兩側皆有建物鄰近，考慮空間與機動性需求，故採用 DJI Phantom 4 Pro (P4P) (DJI, Shenzhen, PRC)旋翼無人飛行載具拍攝可能溢淹之研究區域，相關設備參數規格如表 2。

表 1 旱溪各段水文因子

控制點	斷面編號	集水面積 A (km ²)	流路長 L (m)	高程差 H (m)
旱溪第一段	78~86	49.76	21.35	53.55
旱溪第二段	87~96	43.97	18.58	38.62
旱溪第三段	97~106	29.25	13.14	28.90
旱溪第四段	107~118	14.42	8.84	51.34
總和		134.4	61.91	172.41

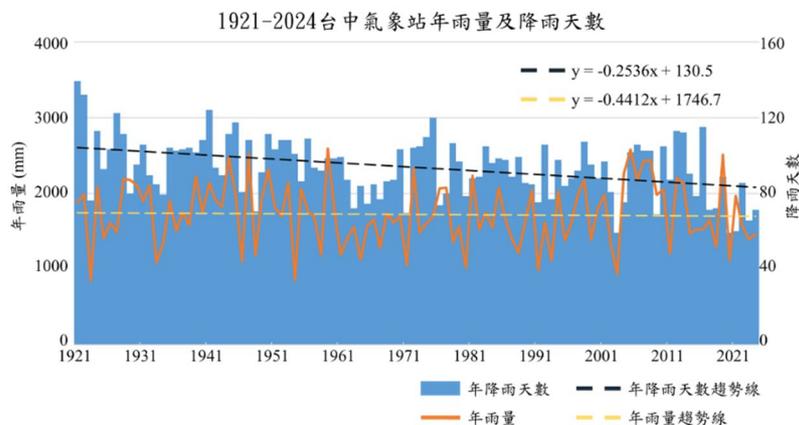


圖 2 台中氣象站 1921-2024 年降雨天數及年雨量趨勢圖

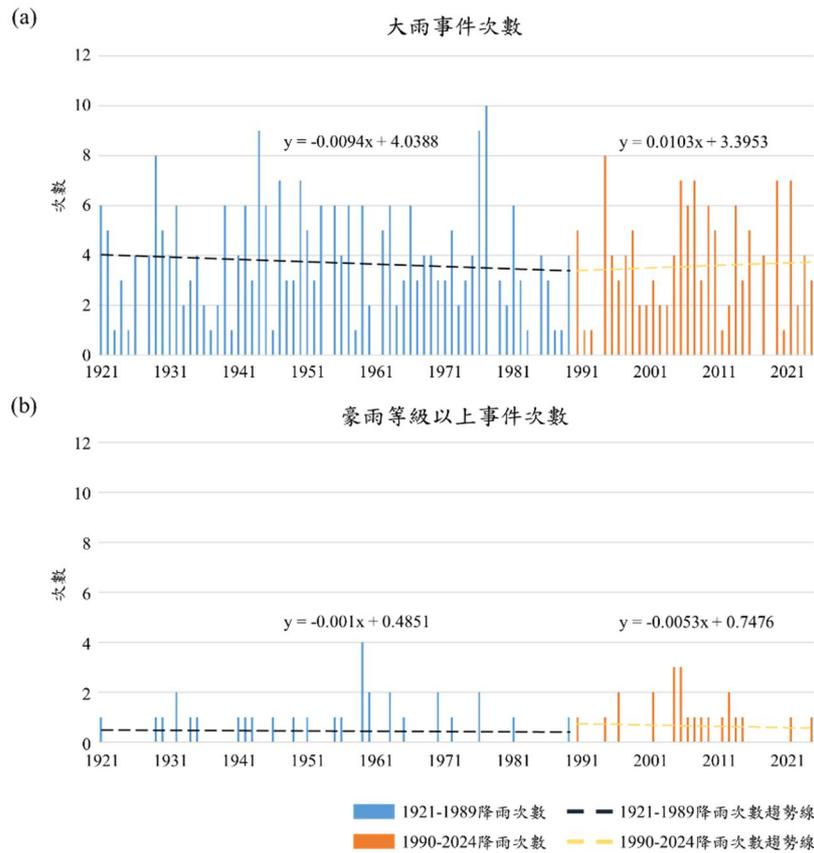


圖 3 台中氣象站 1921-2024 年雨量次數時間序列(a)大雨事件(b)豪雨等級以上事件

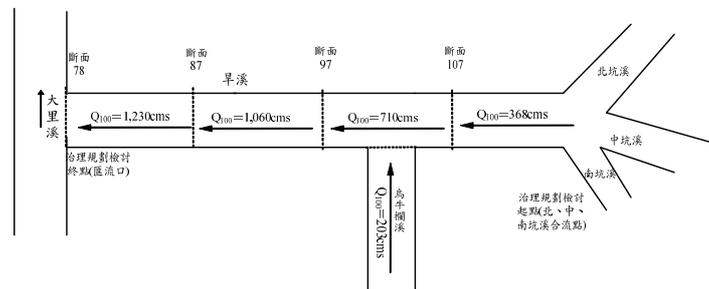


圖 4 旱溪洪峰流量分配圖(引用自經濟部水利署第三河川局，2014)

表 2 本研究採用之無人飛行載具 DJI Phantom 4 Pro 規格表

DJI Phantom 4 Pro		
項目	類別	規格
UAV	重量(g)	1388
	最大飛行高度(m)	6000
	飛行時間(min)	約 30 分鐘
	GPS 模式	GPS/GLONASS 雙模式
雲台	可控轉動範圍	俯仰：-90°~+30°
	穩定系統	3 軸(俯仰、橫滾、偏航)
相機	感光元件尺寸(mm)	13.2×8.8
	照片最大解析度(3:2)	5472×3648
	焦距(mm)	8.8
	光譜波段	可見光
	航高 20m 之地面解析度(mm/pixel)	5.4
	位元深度(bit)	8

4. 研究方法

本研究選定旱溪作為研究區域，蒐集 2014 年之計畫流量、斷面高程以及 1921-2024 年之逐日雨量。根據資料計算各機率分布模型之一日暴雨量並對其進行暴雨頻率分析(適合度分析)，決定選用何種機率分布模型，並選定 1921-2024 年內至少 6 場暴雨使用同位序平均法設計雨型。依據上述計算所得，進行至少二種雨量-逕流分析方法，計算洪峰流量並相互比較，採用與 2014 年的計畫流量較接近之流量，套入美國陸軍工程兵團的 HEC-RAS 軟體，分析各斷面溢淹情形。

根據洪水水位模擬之溢堤分析成果，將有可能發生溢堤的範圍進行航拍規劃，並通過 DJI GS Pro 軟體(DJI, Shenzhen, PRC)進行航前規劃，使用 P4P 在飛行任務獲得的圖像匯入 Agisoft Metashape Professional(Agisoft LLC, St. Petersburg, Russia)產製 DSM 及正射影像。萃取 DSM 中斷面位置之地理資訊，改正斷面資料與現地不符處及擴充斷面資料不足處，並再次使用 HEC-RAS 軟體分析改正後的斷面溢淹情形，其研究流程如圖 5 所示。

4.1 選定機率分布模型及設計雨型

本研究依循《水文設計應用手冊》之規範(國立臺灣大學生物環境系統工程學系，2001)，一日暴雨量及二日暴雨量皆採用年最大值選用法(Annual Maximum Series)(Zelenhasic, 1970)，因旱溪各段集流時間皆未超過 3 小時，故採用一日最大暴雨量。

統計分布模式除應用手冊中之四種統計分布模型：極端值一型(Extreme type-I distribution)

(Gumbel, 1958)、對數常態分佈(Lognormal distribution)(Brown & Sanders, 1981)、皮爾森三型分布(Pearson type-III distribution)(Pearson, 1895)、對數皮爾森三型分布(Log-Pearson type-III distribution)(Water Resources Council (US), 1967)外，增加常態分布(Normal distribution)(Laplace, 1810)，並使用 R Studio (R Studio, Boston, USA)模擬在不同重現期距下(Recurrence Interval)(Dalrymple, 1960)分析一日最大暴雨量。

對上述五種機率分布模型使用科司檢定(Kolmogorov-Smirnov Test, K-S Test)(Kolmogorov, 1933)及卡方檢定(Chi-square test)(Pearson, 1900)進行適合度檢定(goodness-of-fit test)，通過檢定之模型再以標準誤差(Standard Error)(Aldrich, 2010)排序優劣。

設計雨型採同位序平均法，選取至少六場峰值暴雨，計算位序百分比後重分配，並採用 24 小時同位序雨型繪製累積雨量曲線。

4.2 流量計算及溢淹模擬

根據 2012 年 8 月經濟部水利署訂定之「水文分析報告審查作業須知」規定，應至少選用二種暴雨一逕流分析方法相互比較。本研究採用合理化公式(Rational formula)(Kuichling, 1889)及三角形單位歷線法(Triangular unit hydrograph)(Mishra & Singh, 2013)計算洪峰流量，使用 AutoCAD 軟體將河心累距依各斷面劃分為斷面間距，並利用美國陸軍工程兵團的 HEC-RAS (6.0.0 Beta 3)軟體，將輸入上述流量結果、斷面資料及水理參數，其中水理參數包括採用穩定流模擬，設定上游邊界為固定流量；下游為正常水位；曼寧係數依照實際河道材質，材質主

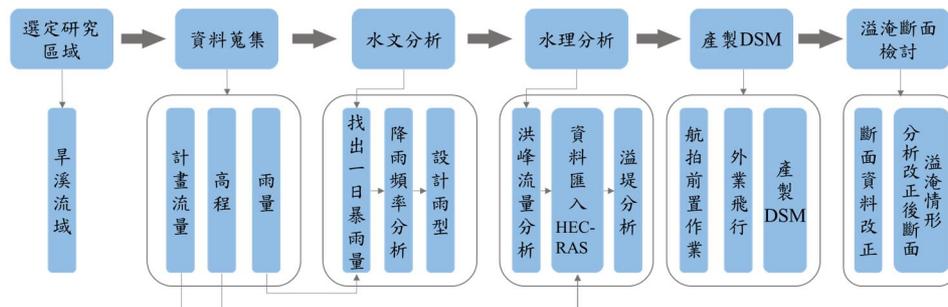


圖 5 本研究流程圖

要為稀疏草生、全面密草生以及純水泥漿平滑面，其中河道依橫斷面分成 4 等分(詳如附表 1)，斷面中河道有水面覆蓋處採用 HEC-RAS 預設值 0.03。觀察模擬能量線、水面線及臨界水深線的位置關係，與各斷面在不同重現期下之溢淹情形。

4.3 數值地表模型及斷面改正

本研究於 2021 年 7 月 30 日進行 UAV 空拍作業，考量周遭建物高度與飛行安全，航高設定為 50 m，前後與側向重疊率皆為 75%，採單網格飛行模式，覆蓋面積約 0.143 km²，共拍攝 472 張影像，地面解析度為 1.33 cm/pixel。將飛行任務獲得之影像匯入 Agisoft Metashape Professional (AgisoftLLC, St. Petersburg, Russia)進行影像匹配，並設置 19 個透空且平均分布於拍攝區域的地面控制點作為校正點，另選擇旱溪內保存良好的控制點作為檢核點(附圖 1)。地面控制點坐標透過 RTK 移動站(南方 S82, Southgnss, Guangzhou, PRC)結合 e-GNSS 虛擬測站取得，進行空中三角測量平差，建立影像與控制點之對應關係，產製數值地表模型(Digital Surface Model, DSM)與正射影像。精度檢核結果顯示，水平誤差低於 1.33 cm，垂直誤差低於 8 cm。

利用 UAV 產製之高解析 DSM，萃取對應斷面位置的高程資料，與三河局 109 年度原始斷面逐點比對，針對高程差異顯著或形態缺失的區域進行修補與擴充，並配合現地勘查進行驗證。完成修正後的斷面資料再輸入 HEC-RAS 進行洪水模擬，以比較改正前後之溢淹情形差異。

5. 研究成果

5.1 選定機率分布模型

本研究依據 1921-2024 年台中氣象站之逐日雨量，使用 R studio 軟體分別計算常態分佈、對數常態分佈、皮爾森三型分佈、對數皮爾森三型分佈、極端值一型五種機率分布模型在不同重現期距下之一日暴雨量。分析結果顯示，重現期距 25 年時，

皮爾森三型之一日暴雨量為最大，而重現期距 50 年及 100 年時，對數皮爾森三型之一日暴雨量最大(表 3)。

本研究以 K-S Test 及卡方檢定進行適合度檢定，信賴水準設定為 95% (p-value 為 0.05)，當 D_n 以及卡方值小於 5%顯著水準對應之臨界值方能通過該檢定。由表 4 得知對數常態分佈、皮爾森三型分佈及對數皮爾森分佈等三者通過卡方檢定；而使用 K-S Test 時，五種分佈模型皆可通過檢定。而上述方法僅能篩選適用之分佈模型，不能選出最適合之分佈模型。因此需再將機率分布，依模型依韋伯法(Weibull)及海生法(Hazen)，計算不同重現期距(T 值)所呈現之不同標準誤差(SE)大小作積分排序，選出最適用之機率分布模型，如表 5、表 6。標準誤差(SE)越小積分越小，代表適合度越高，應優先選擇，在兩種方法中，對數皮爾森三型皆為積分最小，因此為適合度最高之分佈模型。

5.2 洪峰流量分析

將合理化公式及三角形單位歷線法計算之洪峰流量，在不同重現期距下分段列表，見表 7。因本研究基於三角形單位歷線法由旱溪地文因子推算而成，且計算成果較合理化公式之計算成果更接近 2014 年三河局計算之成果，故採用之。

將表 7 三角形單位歷線法之洪峰流量成果與「大里溪支流旱溪治理規劃檢討水文分析報告」(三河局, 2014)內三角形單位歷線法之洪峰流量成果相互比較，見表 8。本研究成果減去河川局成果之差值，可以發現在大部分重現期距下，各斷面洪峰流量皆呈上升趨勢。

選用 2021 年 8 月 6 號至 8 月 7 號之一日大雨作為流量驗證，其累積雨量為 234 mm，介於重現期距 5 年與重現期距 10 年之間。最大瞬時流量依旱溪第一段至旱溪第四段依序為 422 cms，415 cms，398 cms 及 192 cms，仍介於重現期距 5 年與重現期距 10 年之間，見表 9。

表 3 各重現期距下之一日暴雨量

重現期距	常態分佈	對數常態	皮爾森三型	對數皮爾森三型	極端值一型
2	189.1	169.7	188.7	167.6	173.4
5	269.9	250.5	302.3	220.0	258.2
10	312.1	307.1	372.3	309.0	314.3
20	346.9	363.3	435.7	389.7	368.2
25	357.1	381.5	455.2	453.8	385.2
50	386.2	438.9	513.5	521.4	437.9
100	412.3	497.9	569.1	592.9	490.1

表 4 暴雨頻率分析成果表

	K-S Test		卡方檢定	
	D_n	5%顯著水準之臨界值	卡方值	5%顯著水準之臨界值
常態分佈	0.002		16.313	
對數常態	0.004		4.030	
皮爾森三型	0.001	0.164	5.970	7.815
對數皮爾森三型	0.007		5.162	
極端值一型	0.003		32.313	

表 5 暴雨頻率-韋伯法積分排序

	常數分佈	對數常態	皮爾森三型	對數皮爾森三型	極端值一型
SSE	147868.087	42578.932	39713.028	30628.904	385531.847
積分	4	3	2	1	5

表 6 暴雨頻率-海生法積分排序

	常數分佈	對數常態	皮爾森三型	對數皮爾森三型	極端值一型
SSE	144330.45	22645.473	24453.691	13235.087	409991.255
積分	4	2	3	1	5

表 7 洪峰流量成果

重現期距	第一段		第二段		第三段		第四段	
	合理化公式	三角形歷線	合理化公式	三角形歷線	合理化公式	三角形歷線	合理化公式	三角形歷線
2	331	262	328	255	263	201	202	93
5	434	395	430	407	345	324	265	127
10	609	607	604	469	484	464	372	184
25	769	896	887	746	711	543	546	277
50	895	1035	1019	1009	817	624	628	320
100	1028	1182	1158	1152	928	760	714	398

單位：cms

表 8 三角形單位歷線法成果比較

重現期距	第一段			第二段		
	河川局成果(A)	本研究成果(B)	差值(A-B)	河川局成果(A)	本研究成果(B)	差值(A-B)
2	236	262	+26	228	255	+27
5	440	395	-45	431	407	-24
10	576	607	+31	569	469	-100
25	747	896	+149	742	746	+4
50	871	1035	+164	870	1009	+139
100	994	1182	+188	992	1152	+160
重現期距	第三段			第四段		
	河川局成果(A)	本研究成果(B)	差值(A-B)	河川局成果(A)	本研究成果(B)	差值(A-B)
2	157	201	+44	82	93	+11
5	301	324	+23	157	167	+10
10	399	464	+65	207	214	+7
25	524	543	+19	272	297	+25
50	617	624	+7	319	340	+21
100	706	760	+54	367	398	+31

單位：cms

5.3 溢淹模擬

溢淹模擬重現期距 50 與 100 年下斷面 116 至斷面 118 水位情形如表 10 所示，在重現期距 50 年時，斷面 118 有溢淹情形；重現期距 100 年時，從斷面 116、斷面 117-2、斷面 117-5 及斷面 118 有程度不一之溢淹情形，未列入下表之斷面皆未有溢淹情形發生，表中紅燈代表有溢淹情形、黃燈代表洪水水位離左岸或右岸不足 1 m、綠燈代表洪水水位距離堤頂超過 1 m，各溢淹斷面位置如圖 6。

為避免因斷面資料空間分布不均導致在討論河道縱向方向之能量線、水面線、臨界水深線及槽底關係變化時產生過大誤差，本文於原有斷面資料基礎上，每隔 100 m 新增一內插斷面(斷面編號含* 字者)，以提升模擬精度。能量線代表總水頭之縱向變化連線，當水面線位於臨界水深線之上時為亞臨界流，反之則為超臨界流；當超臨界流轉變為亞臨界流時，部分動能轉換為位能，即產生水躍。根據模擬結果，僅在重現期距 50 年與 100 年時，旱溪第四段出現溢淹情形，故針對此段進行討論。在斷面 116.1、115.33 與 108.33 處皆觀察到水躍現象，如圖 7、

圖 8 所示。其中，水躍 A 於斷面 118.1 處水位達 211.04 m，距左、右岸堤頂皆不足 1 m，然未發生溢淹；水躍 B 則在斷面 114.1 處水位達 239.47 m，距堤頂超過 1 m，亦無溢淹；水躍 C 發生於斷面 116.05，水位為 244.88 m，右岸距堤頂不足 1 m，左

岸則超過，皆未出現溢淹情形。

5.4 斷面改正

本研究針對四個模擬重現期距 50 年下出現溢淹情形的斷面(斷面 116、117-2、117-5 及 118)提取對應斷面位置的高程剖面，並與三河局 109 年度斷面資料進行比較分析，後續再透過 HEC-RAS 進行溢淹模擬。由模擬結果及斷面變化可知(表 11 與圖 9)，本研究成果相較於三河局斷面資料有兩項優勢：其一，畫面細節更豐富，能更忠實呈現地貌；其二，可擴充斷面里程，精確描繪兩側地形。各斷面變化如下：斷面 116 新增左岸牆面(約 2 m 處)及右岸道路(約 33 至 48 m 處)，模擬後左岸無溢淹情形；117-2 則顯示左岸道路(約 0 至-10 m)高程變化顯著，牆面與右岸道路亦有所擴充；117-5 針對河道變化(2 至 10 m)細緻描繪，並補足兩岸道路(-9 至-20 m 與 40 至 50 m)；118 則發現左岸地形變化劇烈(0 至-12 m)，底部地勢相對平緩，右岸道路(19 至 40 m)更貼近實況。本研究成果不僅提升地形資訊精度，亦對水文模擬結果具實質助益，足供後續規劃參考。其中，116 與 118 與原始資料差異最大，高程修正幅度分別達約 1.5 m 與 1.8 m，主要原因多為興建變化，修正後於 50 年重現期距下，118 溢淹深度減少約 0.8 m，範圍縮減近一半；而 116 左岸經過斷面改正後，由原先有溢淹情形轉為不會溢淹，顯示斷面改正能反映真實地貌，進而呈現合理的模擬成果。

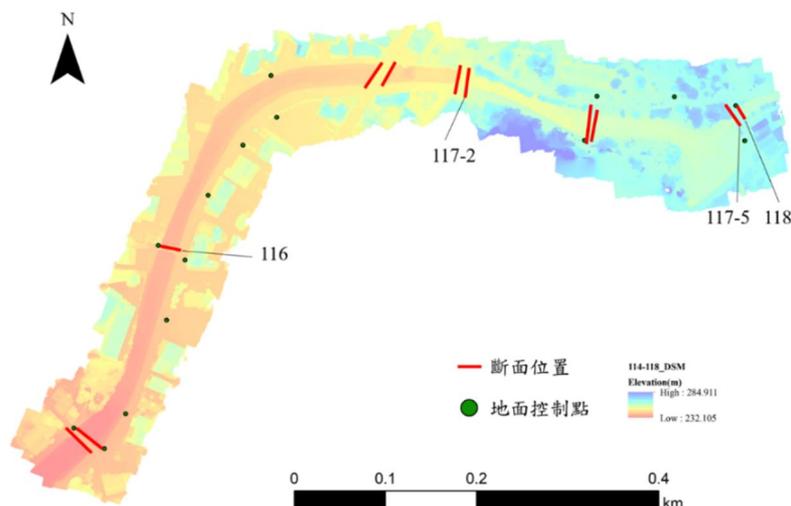


圖 6 溢淹斷面位置示意圖

表 9 2021/08/06~2021/08/07 一日大雨對應之最大流量

	第一段	第二段	第三段	第四段
重現期距 5 年	395	407	324	167
8/6~8/7 大雨	422	415	398	192
重現期距 10 年	607	469	464	214

單位：cms

表 10 重現期距 50 與 100 年下斷面 116 至斷面 118 水位情形

重現期距	斷面	洪水位	左岸高程	右岸高程	左岸溢淹	右岸溢淹
50YR	118	264.440	263.385	263.188	-1.055	-1.252
	117-5	262.650	263.176	263.437	0.526	0.787
	117-4	258.900	260.628	259.884	1.728	0.984
	117-3	256.420	260.438	259.400	4.018	2.980
	117-2	254.230	254.750	255.970	0.520	1.740
	117-1	249.620	251.311	251.263	1.691	1.643
	117	246.560	247.642	248.866	1.082	2.306
	116-1	246.320	247.642	247.230	1.322	0.910
100YR	118	264.350	263.385	263.188	-0.965	-1.162
	117-5	263.960	263.176	263.437	-0.784	-0.523
	117-4	259.870	260.628	259.884	0.758	0.014
	117-3	256.890	260.438	259.400	3.548	2.510
	117-2	254.850	254.750	255.970	-0.100	1.120
	117-1	250.260	251.311	251.263	1.051	1.003
	117	247.070	247.642	248.866	0.572	1.796
	116-1	246.830	247.642	247.230	0.812	0.400
116	243.360	243.300	243.070	-0.060	-0.290	

圖例 ●有溢淹表現 ●離堤高不足1公尺 ●無溢淹表現

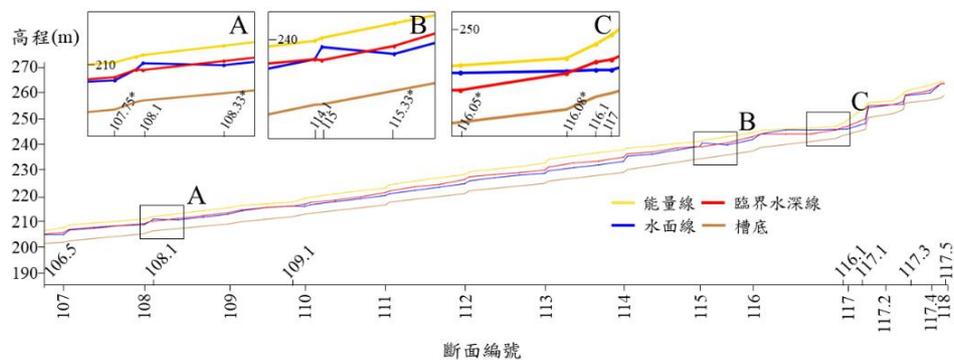


圖 7 重現期距 50 年下旱溪第四段之臨界水深縱向變化

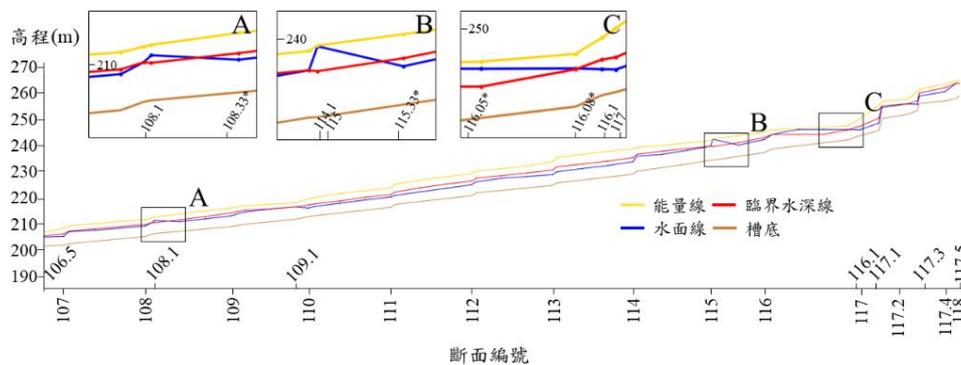


圖 8 重現期距 100 年下旱溪第四段之臨界水深縱向變化

表 11 斷面改正後之重現期距 50 年下斷面 116 至斷面 118 水位情形

重現期距	斷面	洪水位	左岸高程	右岸高程	左岸溢淹	右岸溢淹
50YR	118	264.440	263.898	262.706	-0.542	-1.734
	117-5	262.650	262.946	263.180	0.296	0.530
	117-2	254.230	254.729	255.970	0.499	1.740
	116	242.180	244.150	243.070	1.970	0.890
100YR	118	264.350	263.898	262.706	-0.452	-1.644
	117-5	263.960	262.946	263.180	-1.014	-0.780
	117-2	254.850	254.729	255.970	-0.121	1.120
	116	243.360	244.150	243.070	0.790	-0.290

圖例 ●有溢淹表現 ●離堤高不足1公尺 ●無溢淹表現

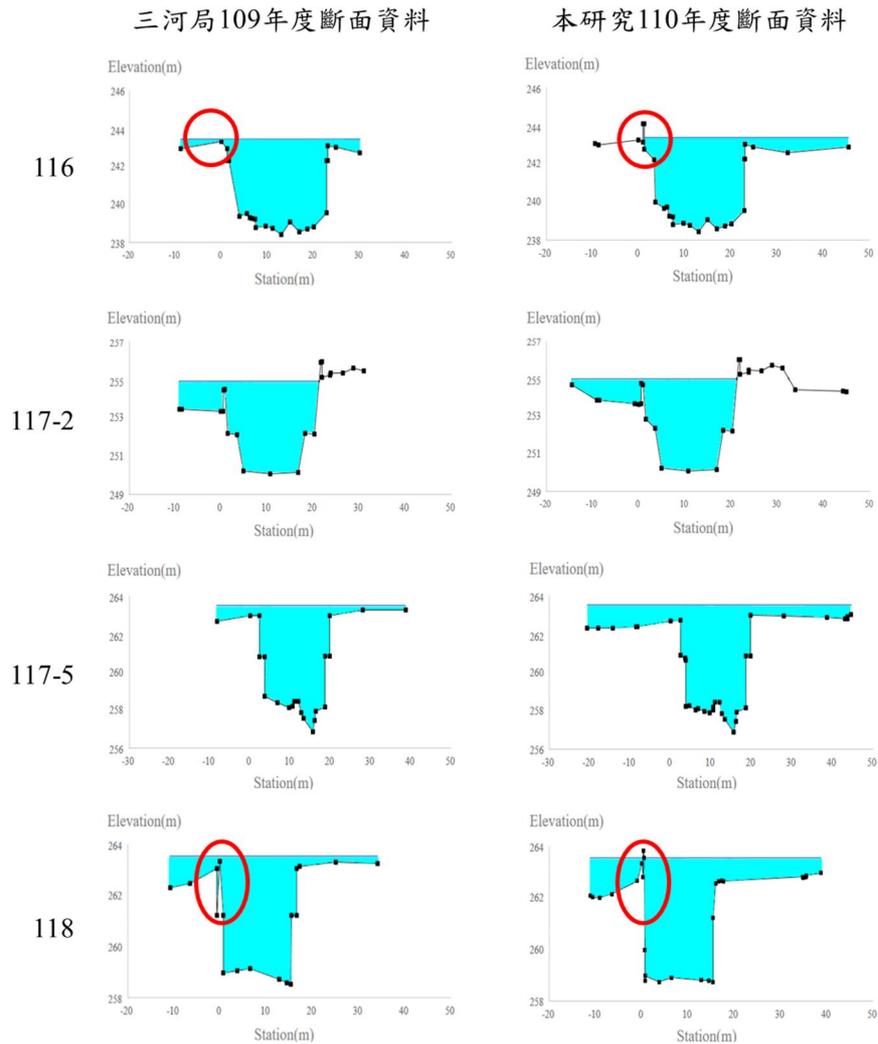


圖 9 重現期距 100 年各斷面改正前後模擬結果

6. 結論

(1) 以台中氣象站長達 104 年之日雨量進行分析，本研究發現 1990 年旱溪改道工程後，降雨型態改變。年雨量大致穩定，但顯示呈現降雨天數下降且降雨有增強狀態。

(2) 在重新審視降雨型態的變化後，再次對一日最大暴雨量進行計算。一日最大暴雨量以五種機率分布模型(常態分佈、對數常態分布、皮爾森三型、對數皮爾森三型、極端值一型)計算，並使用 K-S 檢定、卡方檢定及標準誤差做適合度分析。由分析成果得知：K-S 檢定敏感度較低，

五種模型皆通過適合度檢定，而卡方檢定篩選出三種機率分布模型(對數常態分布、皮爾森三型、對數皮爾森三型)後，經過標準誤差評估，對數皮爾森三型為最佳之機率分布模型。

- (3) 本研究採用合理化公式及三角形單位歷線法相互比較，成果顯示：三角形單位歷線法相較於合理化公式與 2014 年「大里溪支流旱溪治理規劃檢討水文分析報告」之洪峰流量成果較為接近，故採用之。
- (4) 依據三河局提供之斷面資料，使用 HEC-RAS 進行洪水模擬，得旱溪縱向能量線、水面線及臨界水深線之間位置變化，可判定旱溪為混合流況，常有水躍發生。
- (5) 本研究經由現地調查及飛行任務後發現，三河局提供之斷面資料與現地有些許出入。藉由無人機產製之 DSM 萃取斷面位置地理資訊，可將斷面資料中不合理處改正並擴充河道兩側道路之地形，有助於後續水文水理應用。
- (6) 本研究使用 HEC-RAS 進行斷面溢淹分析，成果顯示：有溢淹情形之斷面皆集中在旱溪第四段(上游)，在重現期距 2、5、10、25 年下，無斷面溢淹；重現期距 50 年時，僅有斷面 118 溢淹；重現期距 100 年時，斷面 116 至斷面 118 間有 4 條斷面有程度不一之溢淹情形。
- (7) 考量氣候變遷影響，近年豪大雨事件頻率波動大，本研究也依據台中氣象站雨量資料發現大雨事件發生的次數有增加趨勢，建議未來可持續觀察雨量變化趨勢，考量周圍保全對象，進行整治規劃，例如考慮局部加高河岸或建置親水式堤防設施，以提升防洪安全與水利規劃效益。

參考文獻

朱芳儀、吳俊毅、安軒霏、林仕修、陳樹群，2018。臺灣主要流域之河川型態及其野溪界點判定評估，中華水土保持學報，49(3)：178-186，DOI：10.29417/JCSWC.201809_49(3).0005。[Chu, F., Y., Wu, C.Y., An, S.P., Lin, S.H., and Chen, S.C., 2018. Assessing river morphology and torrent

division point of main basins in Taiwan, Journal of Chinese Soil and Water Conservation, 49(3): 178-186, DOI : 10.29417/JCSWC.201809_49(3).0005. (in Chinese)]

李忠勳、葉信富，2020。臺灣南部流域長期降雨與逕流量變異之探討，臺灣礦業，72(1)：10-24。[Lee, C.H., and Yeh, H.F., 2020. An analysis on the variation of long-term precipitation and streamflow for watersheds in southern Taiwan, Taiwan Mining Industry, 72(1): 10-24. (in Chinese)]

汪中和，2015。氣候暖化與台灣的水資源，鑛冶：中國鑛冶工程學會會刊，59(2)：11-15，DOI：10.30069/MM.201506_59(2).0001。[Wang, C.H., 2015. Climate warming and Taiwan's water resources, Mining & Metallurgy : The Bulletin of the Chinese Institute of Mining & Metallurgical Engineers, 59(2): 11-15, DOI: 10.30069/MM.201506_59(2).0001. (in Chinese)]

邱翰廷，2016。UAV 影像在河床裸露的之三為變遷偵測-以高屏溪為例，高雄應用科技大學土木工程與防災科技研究所碩士論文。[Chiu, H.T., 2017. 3-D change detection for exposed river-bed area based on UAV images-using Gaoping River as an example, Master Thesis, National Kaohsiung University of Applied Sciences, Taiwan, ROC. (in Chinese)]

胡通哲、賴進松、施上粟、韓仁毓，2017。十文溪橫向構造物改善規劃研究，農業工程學報，63(2)：78-93，DOI：10.29974/JTAE.201706_63(2).0007。[Hu, T.J., Lai, J.S., Shih, S.S., and Han, J.Y., 2017. Check dam implementation and fishways installation in the Shi-Wen River, Journal of Taiwan Agricultural Engineering, 63(2): 78-93, DOI: 10.29974/JTAE.201706_63(2).0007. (in Chinese)]

- 國立臺灣大學生物環境系統工程學系，2001。水文設計應用手冊，經濟部水利署，台北市，技術文件編號 GPN/EBN:1009005924，委辦計畫編號：MOEA/WRB-900019V2。[National Taiwan University, Department of Bioenvironmental Systems Engineering, 2001. Handbook for Hydrological Design, Water Resources Agency, Ministry of Economic Affairs, Taipei City, Technical Document No. GPN/EBN: 1009005924, Project No. MOEA/WRB-900019V2. (in Chinese)]
- 張巖、蕭宇仲、張榮傑，2017。UAV 航拍技術應用於河道變遷土砂監測和山區地形製圖之可行性分析，中華水土保持學會，48(1):1-13，DOI: 10.29417/JCSWC.201703_48(1).0001。[Chang, W., Hsiao, Y.S., and Chang, J.C., 2017. Feasibility analyses of river sediment estimation and mountain mapping by UAV techniques, Journal of Chinese Soil and Water Conservation, 48(1): 1-13, DOI: 10.29417/JCSWC.201703_48(1).0001. (in Chinese)]
- 許心藜、葉信富，2018。臺灣中部流域乾旱特徵之時空變化，作物、環境與生物資訊，15(1):1-14，DOI: 10.30061/CEB.201803_15(1).0001。[Hsu, H.L., and Yeh, H.F., 2018. Spatiotemporal variation of the drought characteristics in Central Taiwan. Crop, Environment & Bioinformatics, 15(1): 1-14, DOI: 10.30061/CEB.201803_15(1).0001. (in Chinese)]
- 陳彥伶，2017。應用 UAV-LSPIV 系統進行表面流場觀測之初步研究，國立中興大學水土保持學系所碩士論文。[Chen, Y.L., 2017. A preliminary investigation of UAV-LSPIV for measuring water surface velocities, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 經濟部水利署第三河川局，2014。大里溪支流旱溪治理規劃檢討水文分析報告(第二次修正版)，經濟部水利署第三河川局，台中市。[Water Resources Agency, MOEA, Third River Management Branch, 2014. Hydrological analysis report on the review of the management plan for the Han River, a tributary of Dali River (second revised edition), Water Resources Agency, MOEA, Third River Management Branch, Taichung City. (in Chinese)]
- 蔡怡真，2017。1961-2015 年間受全球暖化影響下台灣不同季節降雨的變化趨勢，國立中央大學大氣科學學系碩士論文。[Tsai, Y.C., 2017. Trends in seasonal rainfall in Taiwan under the influence of global warming from 1961 to 2015, Master Thesis, National Central University, Taiwan, ROC. (in Chinese)]
- 謝有忠，2016。以多期數值地形資料評估山崩區及河道地形之變遷，國立臺灣大學地質科學研究所博士論文，DOI: 10.6342/NTU201603713。[Hsieh, Y. C., 2016. Evaluation of landslide area and fluvial changes using multi-period digital elevation models, PhD Thesis, National Taiwan University, Taiwan, ROC, DOI: 10.6342/NTU201603713. (in Chinese)]
- 鍾侑達、郭峻菖、陳昶憲，2009。台灣區域降雨趨勢分析，農業工程學報，55(4):1-18，DOI: 10.29974/JTAE.200912.0001。[Jhong, Y.D., Kuo, C.C., and Chen, C.S., 2009. The temporal variation of regional rainfall characteristics in Taiwan, Journal of Taiwan Agricultural Engineering, 55(4): 1-18, DOI: 10.29974/JTAE.200912.0001. (in Chinese)]
- 簡榮興，2013。六龜紅水仙地區土石流災害之調查、模擬與重建成效，國立臺北科技大學土木與防災研究所碩士論文。[Chien, J.S., 2013. Debris flow hazard investigation, simulation, and recovery effectiveness of Hongshueisian Region, Liugui Township, Master Thesis, National Taipei

- University of Technology, Taiwan, ROC (in Chinese)]
- Akay, S.S., Özcan, O., Şanlı, F. B., Görüm, T., Şen, Ö. L., and Bayram, B., 2020. UAV-based evaluation of morphological changes induced by extreme rainfall events in meandering rivers, *Plos One*, 15(11): e0241293, DOI: 10.1371/journal.pone.0241293.
- Aldrich, J., 2010. Mathematics in the London/Royal Statistical Society 1834-1934, *Electronic Journal for History of Probability and Statistics*, 6: 1-33.
- Alfieri, L., Bisselink, B., Dottori, F., Naumann, G., de Roo, A., Salamon, P., Wyser, K., and Feyen, L., 2017. Global projections of river flood risk in a warmer world, *Earth's Future*, 5(2): 171-182, DOI: 10.1002/2016EF000485.
- Annis, A., Nardi, F., Petroselli, A., Apollonio, C., Arcangeletti, E., Tauro, F., Belli, C., Bianconi, R., and Grimaldi, S., 2020. UAV-DEMs for small-scale flood hazard mapping, *Water*, 12(6): 1717, DOI: 10.3390/w12061717.
- Brown, G., and Sanders, J.W., 1981. Lognormal genesis, *Journal of Applied probability*, 18(2): 542-547, DOI: 10.2307/3213303.
- Dalrymple, T., 1960. Flood-frequency analyses, manual of hydrology: Part 3 (No. 1543-A), U.S. Geological Survey: Washington, DC, USA.
- Duró, G., Crosato, A., Kleinhans, M.G., and Uijttewaal, W.S. 2018. Bank erosion processes measured with UAV-SfM along complex banklines of a straight mid-sized river reach, *Earth Surface Dynamics*, 6(4): 933-953, DOI: 10.5194/esurf-6-933-2018.
- Gumbel, E.J., 1958. *Statistics of extremes*, Columbia University press.
- Haque, U., da Silva, P.F., Devoli, G., Pilz, J., Zhao, B.X., Khaloua, A., Wilopo, W., Andersen, P., Lu, P., Lee, J., Yamamoto, T., Keellings, D., Wu, J.H., and Glass, G.E., 2019. The human cost of global warming: Deadly landslides and their triggers (1995–2014), *Science of the Total Environment*, 682: 673-684, DOI: 10.1016/j.scitotenv.2019.03.415.
- Hemmelder, S., Marra, W., Markies, H., and De Jong, S. M., 2018. Monitoring river morphology & bank erosion using UAV imagery—A case study of the river Buëch, Hautes-Alpes, France, *International Journal of Applied Earth Observation and Geoinformation*, 73: 428-437, DOI: 10.1016/j.jag.2018.07.016.
- Kolmogorov, A., 1933. Sulla determinazione empirica di una legge di distribuzione, *Giornale dell'Istituto Italiano degli Attuari*, 4: 83-91 (In Italian).
- Kuichling, E., 1889. The relation between the rainfall and the discharge of sewers in populous districts, *Transactions of the American Society of Civil Engineers*, 20(1): 1-56, DOI: 10.1061/TACEAT.0000694.
- Laplace, P.S., 1810. *Analytic theory of probabilities*, Paris: Imprimerie Royale, pp.1-8.
- Mishra, S.K., and Singh, V.P., 2013. *Soil conservation service curve number (SCS-CN) methodology (Vol. 42)*, Springer Science & Business Media.
- Mourato, S., Fernandez, P., Pereira, L., and Moreira, M., 2017. Improving a DSM obtained by unmanned aerial vehicles for flood modelling, *IOP Conference Series: Earth and Environmental Science*, Vol. 95, No. 2, p.022014, IOP Publishing, DOI: 10.1088/1755-1315/95/2/022014.
- Mousavi, M.E., Irish, J.L., Frey, A.E., Olivera, F., and Edge, B.L., 2011. Global warming and hurricanes: The potential impact of hurricane intensification and sea level rise on coastal flooding, *Climatic*

- Change, 104(3): 575-597, DOI: 10.1007/s10584-009-9790-0.
- Panthou, G., Vischel, T., and Lebel, T., 2014. Recent trends in the regime of extreme rainfall in the Central Sahel, *International Journal of Climatology*, 34(15): 3998-4006, DOI: 10.1002/joc.3984.
- Pearson, K., 1895. X. Contributions to the mathematical theory of evolution.—II. Skew variation in homogeneous material, *Philosophical Transactions of the Royal Society of London.(A.)*, (186): 343-414, DOI: 10.1098/rsta.1895.0010.
- Pearson, K., 1900. X. On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling, *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 50(302): 157-175, DOI: 10.1080/14786440009463897.
- Vélez-Nicolás, M., García-López, S., Barbero, L., Ruiz-Ortiz, V., and Sánchez-Bellón, Á., 2021. Applications of Unmanned Aerial Systems (UASs) in hydrology: A review, *Remote Sensing*, 13(7): 1359, DOI: 10.3390/rs13071359.
- Vitousek, P.M., 1994. Beyond global warming: Ecology and global change, *Ecology*, 75(7): 1861-1876, DOI: 10.2307/1941591.
- Wang, R.H., Zhang, S.W., Pu, L.M., Yang, J.C., Yang, C.B., Chen, J., Guan, C., Wang, Q., Chen, D., Fu, B.L., and Sang, X.J., 2016. Gully erosion mapping and monitoring at multiple scales based on multi-source remote sensing data of the Sancha River Catchment, Northeast China, *ISPRS International Journal of Geo-Information*, 5(11): 200, DOI: 10.3390/ijgi5110200.
- Watanabe, Y., and Kawahara, Y., 2016. UAV photogrammetry for monitoring changes in river topography and vegetation, *Procedia Engineering*, 154: 317-325, DOI: 10.1016/j.proeng.2016.07.482.
- Water Resources Council (US). Hydrology Committee., 1967. A uniform technique for determining flood flow frequencies (No. 15), Water Resources Council: Washington, DC, USA.
- Zandalinas, S.I., Fritschi, F.B., and Mittler, R., 2021. Global warming, climate change, and environmental pollution: Recipe for a multifactorial stress combination disaster, *Trends in Plant Science*, 26(6): 588-599, DOI: 10.1016/j.tplants.2021.02.011.
- Zelenhasic, E.F., 1970. Theoretical probability distributions for flood peaks (Doctoral dissertation, Colorado State University. Libraries).

Combining Hydrological Analysis and UAV Digital Surface Model for Han River Flood Risk Assessment

Ting-Ru Shi ¹ Geng-Gui Wang ² Hui-Ping Tsai ^{3*}

Abstract

The primary contribution of this study lies in the application of UAV-derived digital surface models (DSMs) to refine cross-sectional data for hydrological analysis and flood inundation simulations in the Han River, Taichung City, Taiwan. Based on 104 years of rainfall records from the Taichung Weather Station, the one-day maximum rainfall was estimated using five probability distribution models. Goodness-of-fit tests and error analyses identified the Log-Pearson Type III distribution as the most appropriate. Flood hydrographs were then generated using the triangular unit hydrograph method, which provides a more accurate representation of the hydrological characteristics of the Han River. Flood condition was simulated in HEC-RAS under seven recurrence intervals, with the results indicating overtopping at Section Four of the Han River under the 50- and 100-year recurrence intervals. By integrating UAV-derived DSMs to improve cross-sectional accuracy, this study enhances the precision and reliability of flood simulation outcomes. The findings provide valuable references for river management and flood mitigation planning by water resource authorities.

Keywords: Han River, Hydrological Analysis, UAV, DSM

¹ Master, Department of Civil Engineering, National Chung Hsing University

² PhD Student, Department of Civil Engineering, National Chung Hsing University

³ Associate Professor, Department of Civil Engineering, National Chung Hsing University

* Corresponding Author, E-mail: huiping.tsai@nchu.edu.tw

Received Date: Jun. 30, 2025

Revised Date: Jul. 31, 2025

Accepted Date: Sep. 04, 2025

中文稿件投稿注意事項（英文稿件請參閱下頁 Author Guidelines）

本學刊定期出版攝影測量及遙感探測領域之學術論著、技術短文(按中文及英文摘要、關鍵字、前言、材料及方法、結果、討論、參考文獻等撰寫)及應用性報導。收錄之稿件 皆經本編輯委員會安排之專家學者審查程序，並由通訊作者簽署著作權讓渡書。作者可自行聲明文稿和所屬類別，本編輯委員會將依此及審查委員意見決定收錄 文稿之類別。本學刊不接受已經刊載過之文稿，於研討會發表過之論文，經適當增補其內容者為例 外。

投稿地址為 jprsubmit@gmail.com，請以附件寄送稿件之 WORD 檔及 PDF 檔各一份。為便利編審作業，請於 PDF 稿件中移除作者資料(如姓名、服務機關、電話、及電子郵件信箱等)。稿件撰寫要點如下：

1. 頁面：採用 A4 規格頁面。
2. 字體：(1) 中文均以新細明體橫式打字；(2) 英文均以 Times New Roman 字體橫式打字。
3. 單位：內文、圖表及符號中之度量單位皆採用 SI 公制單位。
4. 首頁：首頁應含內容依次為「題目、作者姓名、摘要、關鍵詞、及作者服務機關及職稱（置於頁尾）」，接續文稿內文。
5. 末頁：末頁應含內容與首頁相同，但皆以英文書寫。
6. 題目：論文題目宜簡明，字體大小為 20 粗體，英文題目每字第一位字母以大寫字體打印。
7. 作者：作者姓名列於題目之下方，字體大小為 14 粗體，其服務機關及職稱以^{1,2,...}上標編號註記於頁尾，字體大小為 9。
8. 摘要：摘要字數以 250 字為限，字體大小為 10 粗體。
9. 關鍵詞：列出三至五個關鍵詞，字體大小為 12 粗體。
10. 章節及標題：(1) 章節標題置中，編號一律為阿拉伯數字，如 1, 2, ...，標題字體大小為 18 粗體；(2) 小節標題靠左，編號一律為 1.1, 1.2, 1.1.1, 1.1.2.....，字體大小為 14 粗體。
11. 內文：內文之長度(含圖表)以不超過 22 頁為原則，各段落第一行應縮排，字體大小為 10。
12. 數學式：所有數學式均須標式號於圓括弧內，數學式內所有符號須於符號第一次出現時，應於數學式下方逐一加以定義。
13. 圖及影像：(1) 圖及影像均須數位化置於文稿中適當位置；(2) 所有圖及影像下方須附圖流水編號及說明；(3) 本刊接受彩色圖及影像，但紙版印刷一律採灰階印刷；(4) 結尾毋加「。」及「.」。
14. 表格：(1) 表格均須數位化置於文稿中適當位置；(2) 所有表格上方須附表流水編號及說明；(3) 本刊接受彩色表格，但紙版印刷一律採灰階印刷；(4) 結尾毋加「。」及「.」。
15. 參考文獻(中、日文須英譯)：(1) 參考文獻應列於文末，文稿中未直接引用者不得列入；(2) 中文文獻需加英文翻譯，於結尾加上(in Chinese)，日文書寫同中文文獻，於結尾加上(in Japan)。先排列中、日文參考文獻，再排列英文參考文獻，其他文字參考文獻列於英文參考文獻之後；(3) 中文參考文獻以第一作者 姓名筆劃順序排列，英文參考文獻以第一作者之姓依英文字母順序排列。當作者相同時，依發表年代排列，作者及發表年代完全相同時，依日期在年代後加以 a, b, c 順序。第一作者姓名相同時，先排列單一作者之參考文獻，其次為多作者文獻；(4) 參考文獻之格式如下列：
 - 期刊論文：作者姓名，年代。文章標題，期刊名稱，卷數(期數)：起始頁數 - 結束頁數。
 - 書籍：作者姓名，年代。書名，出版者，出版地。
 - 研討論文集：作者姓名，年代。篇名，論文集名稱，發表地點，卷(期)：起始頁數 - 結束頁數。
 - 網路引用：作者姓名，年代。篇名，取自網址，檢索日期。
16. 參考文獻引用：(1) 作者為一人時，以作者全名(中文文獻)或姓(英文文獻)及發表年代，如楊明德(2007)或(楊明德，2007)、Yang (2007)或(Yang, 2007)；(2) 作者為二人時，以二作者全名(中文文獻)或姓(英文文獻)及發表年代，如楊明德及蘇東青(2014) 或(楊明德及蘇東青，2014)、Yang & Su (2014)或(Yang & Su, 2014)；(3) 作者為多人時，以第一作者全名(中文文獻)或姓(英文文獻)，之後加「等」(中文文獻)或「*et al.*」(英文文獻)及發表年代，如(楊明德等，2016)或楊明德等(2016)、Yang *et al.* (2016)或(Yang *et al.*, 2016)，「*et al.*」請以斜體；(4) 作者及發表年代完全相同時，依日期在年 代後加以 a, b, c 引用，如 Yang & Su (2008a)、Yang & Su (2008b)。

Author Guidelines

The Journal of Photogrammetry and Remote Sensing periodically publishes academic articles, technical short papers, and application reports addressing topics in photogrammetry and remote sensing. Acceptance of submitted manuscripts for publication is based on a peer-reviewing process arranged by the editorial board. A manuscript will not be formally accepted until a copyright agreement is received. Although authors can indicate their submitted manuscripts belonging to one of the categories of academic articles, technical short papers or application reports, the editorial board will make the final decision based on the suggestions of reviewers. This journal accept no paper ever been published, but a revised appropriately paper published in conference proceedings is an exception.

The manuscript submission address is jprsubmit@gmail.com. Please send your manuscript in both WORD and PDF formats via e-mail attachments. However, for blind reviewing, please eliminate author information in the PDF file. Instructions for authors to prepare a manuscript are as follows:

1. Typing format: Manuscripts should be typed single-column and double-space on A4 page size using font-type of 10pt **Times New Roman**. The pages should be numbered.
2. Units: Manuscripts must use SI (Metric) units in text, figures, or tables.
3. Cover page: The cover page should contain manuscript title, author names, abstract, key words, and author affiliations.
4. End page: The end page contains the same information as the cover page, but in Chinese.
5. Title: The title of the manuscripts should be concise and informative. Please use font size of 20pt, Bold and capitalize the initial letter of each word in the title.
6. Authors: Authors names (using font size of 14pt, Bold) are listed below the title, affiliations (using font size of 9pt, Bold) are listed at the end of the first page marked with ^{1, 2, ...}.
7. Abstract: The abstract should be shorter than 250 words and typed using font size of 10pt..
8. Keywords: Keywords (no more than 5 words) should be given and placed below the abstract (using font size of 12pt, Bold).
9. Sections and Sub-sections: Section heading (using font size of 18pt, Bold) should be centered and numbered in 1, 2... etc. Sub-sections (using font size of 14pt, Bold) are justified to the left in 1.1, 1.2, 1.1.1, 1.1.2...etc.
10. Paper length: Published papers are limited to 22 pages.
11. Equations: Type formulae and equations clearly in black and numbered in curved brackets. All symbols in equations should be clearly defined when they firstly appear in the manuscripts.
12. Figures and Tables: Figures and tables are numbered and described in short. When papers are accepted, original figures, tables, and photographs are expected for reproduction. Color figures and tables are acceptable in digital version, but they will be printed in gray levels in hard copies.
13. References: Only works cited in the text will be included. References should be cited in the text by giving the last name of the author(s) and the year of publication of the reference, such as Yang and Su (2014) or (Yang and Su, 2014). With three or more names use the form “Yang *et al.* (2016) or (Yang *et al.*, 2016)” in the text. When two or more references have the same text identification, please distinguish them by appending “a”, “b”, etc., to the year of publication. References should include the complete title(s), the number of the volume and the page(s) of the information cited. References should be listed in alphabetical order, according to the last name of the first author, at the end of the paper.

Journal of Photogrammetry and Remote Sensing

CONTENTS

Regular Papers

Comparison of PS-InSAR and SBAS-InSAR Techniques in Monitoring Surface Deformation in Mountainous Areas: A Case Study in Ren'ai Township (Jun-Ren Shi, Zhong-Han Zhuang, Hui-Ping Tsai).....	233
UAV Path Determination for Visual Navigation using Deep Reinforcement Learning (Pei-Hsuan Huang, Chao-Hung Lin).....	255
Application of Geo-AI Modeling to Estimate NO ₂ Concentrations and Analyze Contributing Factors in Miaoli, Taiwan (Chieh-Ying Chen, Sin-Yi Lai, Yu-Ting Zeng, Chih-Da Wu).....	269
Combining Hydrological Analysis and UAV Digital Surface Model for Han River Flood Risk Assessment (Ting-Ru Shi, Geng-Gui Wang, Hui-Ping Tsai)	287

航測及遙測學刊

目錄

學術論著

- 比較 PS-InSAR 與 SBAS-InSAR 技術應用於監測山區地表變位-以仁愛鄉為例
(施竣仁、莊忠翰、蔡慧萍)233
- 無人機視覺導航路徑規劃使用深度強化學習網路
(黃珮瑄、林昭宏)255
- 應用 Geo-AI 模型推估苗栗地區 NO₂ 濃度及影響因子貢獻解析
(陳潔瑩、賴忻宜、曾于庭、吳治達)269
- 結合水文分析及 UAV 數值地表模型進行旱溪溢淹檢討
(施廷儒、王畊貴、蔡慧萍)287