
**應用人工智慧技術-結合卷積網路以及
轉換學習方法進行殘坡潛勢分析**
**Residual slope susceptibility analysis
based on integrated CNN-Transformer
network**

執行單位：國立中央大學

執行期間：114年2月18日至114年12月31日

計畫主持人：姜壽浩 副教授

研究人員：呂東晟 研究助理

農業部農村發展及水土保持署 編印

中華民國 114 年 12 月

（本報告書內容及建議純屬執行單位意見，僅供本局施政參考）

應用人工智慧技術-結合卷積網路以及轉換學習方法 進行殘坡潛勢分析

摘要

台灣颱風、地震事件頻繁，致使山區崩塌成為常見之地質、土砂災害問題。殘坡係指邊坡因自然崩塌現象等因素，導致邊坡的岩石裸露或堆積殘餘土砂堆積的現象。若其邊坡具有大量之不穩定堆積土砂，後續可能於強降雨事件中成為土石流之主要供應源，對下邊坡地區造成極大危害，為集水區管理之重大問題。由於多數山區地處偏遠不易到達，加之因氣候變遷使得極端降雨事件加劇，增加了崩塌與土石流等土砂災害的危害，據此本創新研究計畫提出以人工智慧為基礎之殘坡分析方法，旨在結合先進之卷積網路(Convolution Neural Network)結合轉換學習(Transformer)方法來建構分析殘坡之潛勢，能應用於清查山區殘坡，並評估其活動性，以期能對土砂災害防治工作提供助益。

關鍵詞：殘坡、人工智慧、卷積神經網路、轉換學習、土砂災害

Residual slope susceptibility analysis based on integrated CNN-Transformer network

Abstract

Residual slope refer to geomorphic features where bedrock is exposed or residual soil and debris have accumulated as a result of natural slope failure processes. These residual deposits, if characterized by substantial volumes of unstable colluvium, may serve a primary source zones for subsequent debris flows triggered by intense rainfall events, thereby posing significant risks to downstream areas. As such, they represent a critical challenge for watershed management and hazard mitigation. Given the inaccessibility of many mountainous areas and the increasing frequency of extreme precipitation events driven by climate change, the severity and unpredictability of landslide and debris flow hazards have escalated. In response, this study proposes an innovative artificial intelligence–based framework for the assessment of residual slope hazards. Specifically, it integrates Convolutional Neural Networks (CNNs) and Transformer-based transfer learning techniques to develop a predictive model for evaluating the potential activity of residual slope. This methodology is designed to support systematic inventory mapping and activity assessment of residual slope in mountainous terrain, thereby enhancing early warning capabilities and informing sediment disaster prevention strategies.

Keywords: Residual Slope, Artificial Intelligence (AI), Convolutional Neural Network (CNN), Transformer, Sediment disaster

目次

摘要.....	I
目次.....	III
表次.....	IV
圖次.....	V
第一章 緒論.....	1-1
第一節 計畫背景	1-1
第二節 計畫目的	1-5
第二章 研究區介紹	2-1
第一節 環境資料概述	2-1
第二節 歷年崩塌	2-4
第三節 研究區殘坡	2-7
第三章 研究方法與流程	3-1
第一節 模式說明	3-1
第二節 CNN 與 Transformer 的整合方式.....	3-5
第三節 模式應用與評估	3-8
第四章 研究資料	4-1
第一節 子集水區製作	4-3
第二節 殘坡資料	4-6
第三節 SENTINEL-2 影像資料處理.....	4-7
第五章 研究結果	5-1
第一節 崩塌樣本	5-1
第二節 模式參數建立	5-4
第三節 模式預測成果	5-12
第六章 結論與建議	6-1
參考文獻.....	參-1
附錄一、子集水區靜態與動態參數空間分布圖	附-1
附錄二、研究區地質名稱與岩性說明	附-30
附錄三、模式原始碼(Matlab 範例).....	附-33
附錄四、計畫審查會議暨回覆辦理情形	附-44

表次

表 1-1 殘坡輔助判釋圖資	1-2
表 2-1 研究區域內災例清查與重大土石災害事件數	2-6
表 4-1 模式應用之靜態資料	4-2
表 4-2 模式應用之多時序資料	4-2
表 4-3 各集流面積門檻值與子集水區分割後之殘坡數	4-5
表 4-4 SENTINEL-2A 衛星波段對照表	4-8
表 4-5 2019–2024 年有效遮罩統計	4-15
表 5-1 各類崩塌之樣本數	5-2
表 5-2 模式應用使用之各項參數	5-10
表 5-3 模式預測成果	5-17
表 5-4 CNN-TRANSFORMER 與傳統機器學習模式（XGBOOST、 RANDOM FOREST）之效能比較	5-30

圖次

圖 1-1 殘坡土砂活動性評估方法示例	1-4
圖 1-2 殘坡風險評估	1-5
圖 2-1 高屏溪流域中不安定土砂集水區潛勢分級與殘坡分布圖	2-2
圖 2-2 集水區環境指標(崩塌率)與殘坡分布圖	2-3
圖 2-3 研究區內歷年崩塌事件數和面積	2-5
圖 2-4 殘坡活動度分布圖	2-9
圖 3-1 卷積神經網路結構示意圖	3-2
圖 3-2 TRANSFORMER 結構示意圖	3-4
圖 4-1 各集流面積對應之子集水區	4-4
圖 4-2 研究區子集水區面積分布	4-6
圖 4-3 SENTINEL-2 影像於山區陰影問題示意圖	4-9
圖 4-4 2016–2024 年 SENTINEL-2 影像時序與選用月份	4-12
圖 4-5 SENTINEL-2 有效性遮罩分布	4-16
圖 5-1 子集水區崩塌與殘坡活動度分布	5-3
圖 5-2 模式一崩塌與非崩塌預測成果	5-14
圖 5-3 模式二殘坡預測成果	5-15
圖 5-4 模式三殘坡活動度預測成果	5-16
圖 5-5 模式一崩塌之實際與預測成果比較	5-18

圖 5-6 模式二殘坡之實際與預測成果比較.....	5-19
圖 5-7 模式三殘坡活動度之實際與預測成果比較	5-20
圖 5-8 整合三種模式預測成果	5-22
圖 5-9 模式參數貢獻度	5-25
圖 5-10 模式預測與實際差異子集水區分布圖	5-26
圖 5-11 過度預測案例子集水區之 GOOGLE EARTH 時序影像比對)	5-28

第一章 緒論

第一節 計畫背景




台灣颱風、地震事件頻繁，致使山區崩塌成為常見之地質、土砂災害問題。若其邊坡具有大量之不穩定堆積土砂，後續可能於強降雨事件中成為土石流之主要供應源，對下游邊坡地區造成極大危害，為集水區管理之重大問題。由於多數山區地處偏遠不易到達，加之因氣候變遷使得極端降雨事件加劇，增加了崩塌與土石流等土砂災害的災害。為有效監測風險與應對災害，農村水保署不僅對全台灣的邊坡進行清查，也針對土石流的供應源分別定義了「殘坡」與「不安定土砂」兩種名詞。「殘坡」係指邊坡因自然崩塌等因素，導致岩石裸露或殘餘土砂堆積的現象；而「不安定土砂」則是指在這些殘坡或河道上，處於暫態或不穩定平衡狀態的大量土砂。一旦在降雨、地震等條件下被誘發，這些土砂的運移便可能對中下游造成災害。

根據 113 年農村水土保持署之殘坡判定手冊。殘坡土砂的判釋流程主要分為六個步驟。

(一)初判殘坡點位：透過 Google Earth Pro 的多時序高解析度衛星影像和三維地形展示平台，觀察地形變化；並參考五種常見的殘坡地形特徵（冠部崩崖、崩塌陷落崖、雙溪同源、地形錯位、崖錐堆積），標註殘坡點位。

(二)複判殘坡點位：利用 Google Earth 多時序衛星影像、H.O.S.T 地圖，確認殘坡地形特徵；同時，輔以空載光達數值地形變異分析圖 (DoD) 確認殘坡土砂的活動性(表 1-1)。

表 1-1 殘坡輔助判釋圖資(113 年農村水土保持署)

工具	圖示	說明
HOST 地圖	 	
多期衛星影像		觀察使用系統產生出的 kml 檔案內，依時間序列產生之各期影像檔觀察土砂移動變化。
空載光達數值地形變異分析圖(DoD)		兩期 LiDAR DEM 資料相減結果，紅、黃色系表示可能有堆積現象(地形低變高)，而藍、綠色系則表示可能有侵蝕(地形高變低)。

(三)影像裁切：選定關注區域的殘坡單元後，使用 Google Earth 的多邊形功能，對複判點位所使用的三種輔助判釋影像圖資 (Google

Earth 多時序衛星影像、H.O.S.T 地圖、空載光達數值地形變異分析圖 (DoD)) 進行裁切。

(四)數化殘坡特徵：將裁切後的關注區域殘坡單元影像圖資，在 Google Earth 平台上依殘坡地形特徵幾何表格進行數化。

(五)活動性與風險性判釋：利用前後兩期 H.O.S.T 地圖、空載光達數值地形變異分析圖 (DoD)以及多期衛星影像評估殘坡的活動性，以多個標準綜合判斷該殘坡在一段時間的變化程度，並分出低、中、高三個類別。

- 活動度低：當 H.O.S.T 地圖、DoD 圖層沒有地形變化，且 98 年莫拉克颱風後皆無崩塌擴大或殘坡位移的現象。
- 活動度中：當 H.O.S.T 地圖、DoD 圖層有輕微微的地表變形，如上邊坡下陷，趾部隆起，或殘坡土砂被侵蝕坡腳，或殘坡土砂有微量的變形如崩塌擴大影響到殘坡土砂的現象。
- 活動度高：DoD 呈現殘坡土砂有明顯的變形，如上邊坡下陷，趾部隆起等地形變化。判釋標準如圖所示。




圖 1-1 殘坡土砂活動性評估方法示例 (113 年農村水土保持署)

(六)風險性判釋：風險依照殘坡活動性、土砂影響範圍是否有保全對象與殘坡規模大小評估，如圖 1-2 所示，也分為高、中、低三個類別。

活動性 × 保全對象 × 規模 → 風險			
活動性低	無保全對象	-	低
	有保全對象	-	中
活動性中	無保全對象	規模小	低
		規模大	中
	有保全對象	規模小	中
		規模大	高
活動性高	無保全對象	-	中
	有保全對象	-	高

圖 1-2 殘坡風險評估(113 年農村水土保持署)

根據農村水土保持署 113 年清查資料，全台共存有 556 處(747 塊)殘坡，其中高屏溪流域以 170 處(229 塊) 殘坡佔比最高，顯示其為土砂災害高風險區。為此，本研究旨在建構一套以人工智慧為基礎的殘坡潛勢分析方法。

第二節 計畫目的

上述之《殘坡判釋手冊》主要依賴人工判讀高解析度的衛星與光達影像以及數值高程進行殘坡和不安定土砂的判釋。但此方法不僅耗時，且受限於判讀者經驗和僅使用高程相關資料和光學影像進行判釋。為突破限制，本研究計畫旨在發展一套以人工智慧為基礎的自動化分析殘坡的模式。

模式之基礎為整合多元的環境資料包含靜態之地文、地質資料，以及動態之多時期衛星影像、時序降雨及事件型崩塌目錄等，應用卷積神經網路（CNN）結合轉換學習（Transformer）的深度學習，建構殘坡潛勢模式，用以預測其活動性（高、中、低）。期望模式成果能更有效率地清查山區殘坡，以提升防災工作的效率與準確性。具體來說，本計畫將以高屏溪流域為研究區，以水保署之殘坡資料庫作為學習對象，藉此建構殘坡潛勢預測模型。研究成果將應用於分析研究區內殘坡的活動性，並進行潛在殘坡的清查研究，期望能為台灣的土砂災害防治工作能有所助益。

第二章 研究區介紹

第一節 環境資料概述

高屏溪流域主要支流為荖濃溪、楠梓仙溪以及隘寮溪等等，發源於中央山脈玉山附近，上游處在此流域東北部，地勢較高且陡峭，地形以山地為主；而下游處則在西南部，地勢較低且平緩，地形以平原為主。

根據水保署（2024，民國 113 年）之殘坡清查成果，可觀察到高屏溪流域內的殘坡主要集中於中上游地區。此一空間分布特徵與農業部農村水土保持署公布之「不安定土砂集水區潛勢分級圖」結果高度一致，顯示殘坡多位於至少屬於中至高潛勢等級之不安定土砂集水區範圍內（圖 2-1）。為界定本研究之研究區範圍，將高屏溪流域範圍、不安定土砂集水區潛勢分級圖與殘坡分布圖進行疊圖分析，篩選出符合研究目的之重點子集水區，同時參考水保署集水區環境指標中的「崩塌率（崩塌面積／子集水區總面積）」作為補充依據。根據國內相關研究（如邱晃輝等，2017；蘇玉蓮等，2021），若崩塌率超過 3%，可視為崩塌活躍或高活動區，其區域多對應於坡度陡峭、地質鬆軟與降雨集中的中上游地帶。

綜合上述依據，本研究主要以中高潛勢（含）以上等級之不安定土砂集水區與崩塌率 3% 作為子集水區崩塌活躍度之判釋閾值，據以劃定研究區域，確保分析重點聚焦於地形與崩塌潛勢最顯著之區域。

研究區面積約為 2,241 平方公里，高程範圍介於 92 至 3,944 公尺，坡度範圍為 0 至 86.4 度，平均坡度為 34.6 度。整體地形以中高海拔山區為主，地勢陡峭、谷坡深切，局部區域具有顯著起伏與坡度變化，反映出地形能量強烈與崩塌活動潛勢高的特性。




圖 2-1 高屏河流域中不安定土砂集水區潛勢分級與殘坡分布圖




圖 2-2 集水區環境指標(崩塌率)與殘坡分布圖

研究區內地質構造較為複雜。根據官方資料，區內岩性可大致分為：古生代至中生代的黑色與綠色片岩，始新世至漸新世的板岩與石英岩互層，以及中新世至上新世的砂岩與頁岩互層。沿主要河谷與山腳則分布有更新世古河流沖積層與新生代河流沖積層。岩層之風化、

破碎及節理發育，與地質構造作用、地形起伏共同影響本區崩塌及殘坡之發展。

氣候上，高屏河流域屬熱帶至亞熱帶季風氣候，乾濕季分明，年平均降雨量約 2,400–2,500 mm。每年 5 月至 10 月為主要雨季，受西南季風及颱風環流影響，降雨量約占全年總量的 80% 以上；其中 6–8 月為颱風與強對流降雨高峰期。相對地，11 月至翌年 4 月為乾季，降雨稀少且氣候穩定，地表條件變化最小。降雨在空間上受地形強烈控制，呈現東高西低分布，靠近中央山脈的迎風坡年雨量可逾 3,000 mm，而西側丘陵和平原僅約 1,500–2,000 mm。此一明顯的季節與地形差異，使流域內在強降雨事件期間極易觸發坡面崩塌與殘坡再活化，為研究區地表動態的重要氣候背景。

第二節 歷年崩塌

本研究利用事件型崩塌目錄進行分析「農業部農村發展及水土保持署 BigGIS 巨量空間資訊系統」，該資料可自 (<https://gis.ardswc.gov.tw/>) 查詢並申請取得，該資料展示了每年崩塌地的空間分布並記錄了崩塌的面積與歷經災害，其中崩塌事件的最小辨識面積為 0.1 公頃。為建立研究區域內歷年崩塌事件資料集，本研究篩選出所有完全位於研究範圍內的崩塌事件數與崩塌面積，並依年份分批匯出。同時，為補強資料的深度，亦參照土石流防災資訊網所發

布之重大災害事件報告，以 2008 年為起始年，進一步彙整出 2008 年至 2023 年各年度於研究區內發生的災害名稱及其重大土石災害數量(表 2-1)。依據統計結果，研究區域內各年份的崩塌事件數量有所差異，例如 2009 年因莫拉克颱風造成嚴重災害，其崩塌事件數多達 3856 件，其中 2022 年則未記錄到任何崩塌事件(圖 2-2)。



圖 2-3 研究區內歷年崩塌事件數和面積

表 2-1 研究區域內災例清查與重大土石災害事件數

年份	事件	日期	重災數	年份	事件	日期	重災數
2008	卡玫基颱風	07/17	13	2016	0610 豪雨	06/10	1
	鳳凰颱風	07/28	0		0629 豪雨	06/29	0
2009	莫拉克颱風	08/08	41		尼伯特颱風	07/08	0
	芭瑪颱風	10/05	0		0710 豪雨	07/10	0
2010	0726 豪雨	07/26	0		莫蘭蒂颱風	09/14	0
	萊羅克颱風	09/01	0		梅姬颱風	09/27	1
	莫蘭蒂颱風	09/09	0		艾利颱風	10/06	0
	凡那比颱風	09/19	1	2017	0601 豪雨	06/01	1
	梅姬颱風	10/22	0		0613 豪雨	06/13	0
2011	0719 豪雨	07/19	0		尼莎颱風	07/29	0
	南瑪都颱風	08/29	0	2018	0823 低壓	08/23	1
2012	0517 豪雨	05/17	0	2019	0518 豪雨	05/18	0
	0520 豪雨	05/20	0		0611 豪雨	06/11	0
	0610 豪雨	06/10	2		其它	06/27	1
	泰利颱風	06/20	0		利奇馬颱風	08/11	1
	蘇拉颱風	08/02	0		0815 豪雨	08/15	2
	天秤颱風	08/24	0		白鹿颱風	08/24	0
	天秤颱風	08/28	0	2020	0521 豪雨	05/21	0
2013	蘇力颱風	07/13	1	2021	彩雲颱風	06/04	0
	潭美颱風	08/21	0		0621 豪雨	06/21	0
	康芮颱風	08/29	0		0731 豪雨	07/31	0
	天兔颱風	09/21	0		盧碧颱風	08/07	3
2014	0520 豪雨	05/20	0	2023	卡努颱風	08/04	0
	0606 豪雨	06/06	0		其它	08/23	1
	麥德姆颱風	07/23	0		海葵颱風	09/03	0
	鳳凰颱風	09/21	0		小犬颱風	10/05	1
2015	0520 豪雨	05/20	0	2024	凱米颱風	07/25	4
	蓮花颱風	07/08	0		其它	09/22	1
	蘇迪勒颱風	08/08	0				

第三節 研究區殘坡

根據農村水土保持署之 113 年殘坡清查資料，其內容以點位屬性為核心，並結合向量圖資，完整記錄了每一處殘坡的詳細資訊。主要資料可歸納為以下四大類：

1. 地理位置描述：

- 殘坡中心位置：標示殘坡的中心點位。
- 所屬流域與編號：記錄殘坡所在的集水區及其編號。
- 殘坡土砂範圍：以多邊形（Polygon）向量圖資精確圈繪出殘坡土砂的區域。

2. 殘坡特徵描述

- 地形特徵：記錄地形特徵的種類與數量，並依其型態以線狀（Polyline）或面狀（Polygon）向量呈現，有冠部崩崖、崩塌陷落崖、雙溪同源、地形錯位、崖錐堆積共六種。
- 坡長與變位量：分別以線段（Line）記錄殘坡的長度及隨時間的變動位移量。
- 土砂估計量：包含土砂覆蓋的面積與推估的體積。

3. 活動度相關描述

- 活動度等級：判釋人員評估的活動度。

- 判釋依據：說明評估活動度時所參考的輔助圖資紀錄，方法如圖 1-1。

- 影像來源：註明進行判釋時所使用的最新影像資料來源。

4.風險度相關描述

- 風險度等級：綜合評估殘坡的致災風險（圖 1-2）。
- 風險度依據：風險等級根據「活動度」與「和保全對象的距離」綜合判斷，方法如圖 1-2。
- 保全對象資訊：記錄距離最近的保全對象名稱，以及兩者間的直線距離。

研究區內共計 168 處殘坡，其活動度分佈為：低活動度 71 處、中活動度 67 處、高活動度 30 處（圖 2-3）。而殘坡的種類以冠部崩崖佔多數，高達 76%。




圖 2-4 殘坡活動度分布圖

第三章 研究方法與流程

本研究主要目的是針對殘坡建立人工智慧模式，以高屏溪流域為研究區，針對子集水區進行殘坡潛勢（依據活動度界定）之判定。模式訓練所仰賴之輸入資料包含多源地文、地質、土壤、降雨及多時序衛星影像等包含靜態與動態多樣化資料。

第一節 模式說明

一、卷積神經網路（Convolutional Neural Network, CNN）

卷積神經網路（圖 3-1）是一種專為處理影像與結構化資料設計的深度學習架構。在崩塌或地表變動分析中，CNN 多被用於影像特徵擷取（Zhao and Cai, 2017），以利後續的模式訓練與分類。其基本結構如下：

- **輸入層（Input Layer）**：輸入影像矩陣（如衛星像素矩陣）。
- **卷積層（Convolutional Layer）**：使用濾波器（Filter）進行特徵提取。
- **池化層（Pooling Layer）**：採用最大池化（Max Pooling）或平均池化（Average Pooling）以縮減特徵維度並保留重要資訊。
- **全連接層（Fully Connected Layer）**：壓平輸出特徵以進行分類或回歸。

- **輸出層 (Output Layer)**：透過激活函數（如 Softmax）輸出分類結果。

在本研究中，CNN 的角色為從多時序影像中自動萃取地表空間特徵（如坡度形態、崩塌紋理、光譜異常），生成多年度影像特徵向量，作為後續 Transformer 模組的時序輸入。




圖 3-1 卷積神經網路結構示意圖(Zhao and Cai, 2017)

二、轉換學習(Transformer)

Transformer(圖 3-2)為一種基於自注意力機制(Self-Attention)的深度學習模型，由 Vaswani 等人於 2017 年提出 (Vaswani et al., 2017)，最初應用於自然語言處理領域。其主要優勢為能克服 RNN 與 LSTM 的長距離依賴限制，並透過平行運算顯著提升訓練效率。目前已廣泛應用於語音、影像與多模態學習中。

其核心組成包含：

- **自注意力機制 (Self-Attention)**：為每一輸入位置加權計算，捕捉序列中關鍵關聯；
- **多頭注意力機制 (Multi-Head Attention)**：多組自注意力並行運算以擷取不同特徵模式；
- **位置編碼 (Positional Encoding)**：補足模型對序列順序的感知；
- **殘差連接與層正規化 (Add & Norm)**：避免梯度消失並穩定訓練過程；
- **完全平行化運算**：提高運算效率。

在本研究中，Transformer 透過注意力機制學習多年度特徵序列之**時序依存關係**，捕捉降雨變化、坡面潛勢與崩塌活動之間的**時序互動**，最終輸出殘坡活動或穩定類別的預測結果。




圖 3-2 Transformer 結構示意圖(Vaswani et al, 2017)

第二節 CNN 與 Transformer 的整合方式

為充分整合不同型態資料的特徵，本研究提出之人工智慧模式結合卷積神經網路（Convolutional Neural Network, CNN）與轉換學習（Transformer）之機器學習架構，藉以同時掌握靜態因子、動態因子與遙測影像之空間特徵與時序變化資訊，建立 CNN-Transformer 模式架構（圖 3-3）。本研究所建構之模式架構詳細說明、訓練參數設定及 MATLAB 2024b 原始碼均詳錄於附錄三。




圖 3-3 CNN-Transformer 模式架構

本研究以子集水區（sub-watershed）為基本分析單元，輸入資料依性質分為靜態資料（Static Data）與動態／多時序資料（Transient Data）兩大類，並透過子集水區尺度之區域統計（sub-watershed zonal statistics）進行特徵彙整與融合。靜態資料包含地形（高程、坡度、坡向、曲率等）、水文（SPI、TWI、河網密度等）與地質（岩性），用

以反映地表之固有環境條件；動態／多時序資料則包含降雨（如年最大月雨量）、崩塌事件資訊（崩塌面積比例與頻率）以及多時序光學衛星影像（SENTINEL-2），用以描述雨量驅動與地表覆蓋變化所造成之時序特性。

在特徵萃取流程上，多時序光學衛星影像指標首先進入 CNN 模組，以卷積運算萃取影像之局部紋理與空間差異特徵。CNN 由多層 3×3 卷積 (Conv 3×3)、批次正規化 (Batch Normalization, BN)、ReLU 啟動函數與最大池化 (Max Pooling) 所組成，以逐層整合空間資訊並提升特徵辨識能力；其輸出再經由展平 (Flatten) 轉換為可聚合之特徵向量。CNN 所萃取之影像特徵隨後根據子集水區之 sub-watershed zonal statistics 進行子集水區尺度聚合，使影像特徵由像元層級轉換為可與其他因子對齊之子集水區尺度特徵表示。

在時間序列建模與跨模態融合上，本研究將經 sub-watershed zonal statistics 彙整後之靜態資料特徵、由 CNN 萃取並聚合後之影像特徵，以及降雨、崩塌事件等動態因子，共同組合為子集水區之特徵序列，輸入至 Transformer 模組進行學習。其中，靜態因子於序列建模時作為子集水區之固定特徵，與各時間步之動態與影像特徵共同構成 Transformer 的輸入表示。

Transformer 模組首先引入位置編碼 (Positional Encoding) 以提供序列中各時間步之相對位置資訊，並由多層重複堆疊之編碼層構成。每一編碼層包含正規化 (Norm) 與多頭自注意力機制 (Multi-head Attention)，用以建構不同時間步之依存關係與關聯強度，並搭配正規化 (Norm) 與多層感知器 (Multi-layer Perceptron, MLP) 以進行非線性特徵轉換，提升序列特徵之表示能力。透過自注意力機制，模型得以同時考量降雨、各項崩塌指標與多時序衛星影像等多源時序訊號之共同變化趨勢。

完成 Transformer 編碼後，模型進入分類模組 (Classification) 以輸出最終預測結果。分類模組依序包含平均池化 (Average Pooling) 以彙整序列維度之特徵表示，並透過批次正規化 (BN) 與全連接層 (Fully Connected, FC) 進行分類決策，最終經由 Softmax 輸出各類別之預測機率與分類結果 (Result)。

第三節 模式應用與評估

本計畫將研究區分為多個子集水區分別作為模式訓練區(training)、測試區(Testing)以及應用模式進行殘坡清查的驗證區，以評估模式之應用性。此研究將設定不同活動度的殘坡做為樣本，劃分70%的殘坡為訓練樣本與30%的殘坡為測試樣本。此外，為最大程度地降低模型對特定數據劃分的依賴性並提升其穩健性，將重複執行100次的獨立訓練與測試樣本隨機抽樣。針對模式成果，下列評估指標則將應用於量化模式正確性：

- 準確率 (Accuracy) = $(TP + TN) / (TP + TN + FP + FN)$ ：

整體正確分類的比例，但對於類別不均衡的數據較不敏感。

- 精確率 (Precision, P) = $TP / (TP + FP)$ ：預測為某類時，實際正確的比例，適用於錯誤代價高的場景（如醫療診斷）。

- 召回率 (Recall, R) = $TP / (TP + FN)$ ：真實正例中被成功預測出的比例，適用於希望避免遺漏的場景。

其中 TP (True Positive, 真陽性)：實際為正類，且被正確預測為正類的數量；TN (True Negative, 真陰性)：實際為負類，且被正確預測為負類的數量；FP (False Positive, 假陽性)：實際為負類，但被錯誤預測為正類的數量(誤報)；FN (False Negative, 假陰性)：實際為正類，但被錯誤預測為負類的數量(漏報)。

本計畫最後針對殘坡潛勢分析之清查成果，比對多時期影像以及水保署之調查資料，確認清查成果之有效性，同時進一步確認本計畫開發模式之應用價值。

第四章 研究資料

為建構同時具備潛勢判釋與活動度評估能力的模型，本研究依圖 3-3 之流程，首先將研究區依子集水區劃分為多個空間單元，並將所有輸入資料依性質分為兩大類：**靜態資料**、**多時序資料**。

其中，靜態資料（表 4-1）包括地形因子（高程、坡度、坡向、曲率）、水文因子（溪流能指數、地形濕度指數、河網密度）與地質因子（岩性），反映子集水區固有的地表環境條件；多時序資料涵蓋 2008 – 2023 年之年最大月雨量、同期間之崩塌事件（面積與頻率），以及 2019 – 2024 年 6 – 7 月崩塌指數（WLSI），用以描述環境條件與地表擾動之時間變動性；另 SENTINEL-2 衛星影像資料（2019 – 2024）採年度最低雲機率（或最低雲量）合成影像，提供反映地表紋理、植生狀態與影像穩定性之量測資訊。

表 4-1 模式應用之靜態資料

資料	資料說明	資料來源
地形	高程、坡度、坡向、曲率、	使用內政部地政司 5 公尺數值地形計算
水文	水流強度指數、地形濕度指數、水系密度	同上
地質	1/50000 地質圖(岩性)	經濟部中央地質調查所 (https://datahub.ncdr.nat.gov.tw/dataset)

表 4-2 模式應用之多時序資料

資料	資料說明	資料來源
雨量觀測資料 (2008 年~2023 年)	2.5km 氣候格點月份資料	中央氣象 CODiS 氣候觀測資料查詢服務 (https://codis.cwa.gov.tw/)
SENTINEL-2 (2019 年~2024 年)	Surface reflection 影像(Band 2、Band 3、Band 4、Band 8、Band 11)用以計算 WLSI 指數	歐洲太空總署 (EAS)(https://browser.data.space.copernicus.eu/)
事件型崩塌目錄 (2008 年~2023 年)	向量資料(polygon)	水保署 BigGIS (https://gis.ardswc.gov.tw/map)

第一節 子集水區製作

為建立適用於研究區域內的模型，本研究依據地形高程與河川流量，將研究區域劃分為適當面積的子集水區(sub-watershed)，同時考量子集水區內的資料（如坡度、坡向、曲率等）能具備足夠的代表性（網格數>30），反映其區域特性；同時每一塊殘坡皆對應至單一子集水區，並儘可能維持原始殘坡的完整性，避免同一殘坡被切割納入多個子集水區（原始殘坡處數量為 168）。最後本研究以 20 公頃、40 公頃、80 公頃、100 公頃、200 公頃、400 公頃等不同之集流面積門檻值，產製之各子集水區（圖 4-1），並統計殘坡被子集水區切割後的數量（表 4-3）。




圖 4-1 各集流面積對應之子集水區 (a) 20 公頃，(b)40 公頃，(c)80 公頃，(d)100 公頃，(e)200 公頃，(f)400 公頃

表 4-3 各集流面積門檻值與子集水區分割後之殘坡數

集流面積	子集水區數	殘坡數
20 公頃	8,253	306
40 公頃	3,878	243
80 公頃	1,882	184
100 公頃	1,469	177
200 公頃	695	150
400 公頃	356	116

本研究最終選定以「100 公頃」作為集流面積門檻值進行子集水區劃分。此門檻值可維持約八成以上殘坡單元的完整性，同時確保子集水區在地形參數與統計應用上具有足夠的代表性，圖 4-2 統計研究使用之子集水區面積分布情形，約 95%之子集水區之面積為小於 450 公頃。




圖 4-2 研究區子集水區面積分布

第二節 殘坡資料

殘坡資料為模式訓練之依據，本研究首先根據殘坡的空間位置，將其分配至對應的子集水區。若某一殘坡橫跨多個集水區，則以其面積佔比最大者為準。

由於現有的殘坡清查資料缺乏確切的形成時間，本研究透過空間疊圖分析，將崩塌事件目錄中，最早與該殘坡位置重疊的事件年份，定義為此殘坡的最早崩塌年份，同時也記錄了殘坡發生崩塌的年份，作為後續時序分析之依據。此外，部分殘坡在崩塌事件目錄中並無對應紀錄，這意味著此類殘坡可能形成於本研究的觀測期(2008 -2024)之前，或其並非由特定災害造成的崩塌事件所形成。

第三節 SENTINEL-2 影像資料處理

一、影像來源與特性

本研究主要使用 SENTINEL-2 影像之 Surface Reflectance 影像來計算各項影像指標。SENTINEL-2 衛星由 SENTINEL-2A 和 SENTINEL-2B 兩顆衛星組成，分別於 2015 年 6 月 23 日和 2017 年 3 月 7 日發射升空。單顆衛星的重複觀測週期約為 10 天。衛星感測器在軌道上接收到的是大氣層頂反射率 (Top-Of-Atmosphere Reflectance, TOA Reflectance)。大氣層頂反射率源自地表的地表反射率 (Surface Reflectance, SR) 和大氣效應 (Atmospheric Effects)。大氣效應源於太陽光在穿透大氣層及地表反射能量返回感測器過程中，與氣體分子和氣膠（例如：懸浮微粒、水滴、冰晶）發生的複雜散射與吸收。這些效應會扭曲地表物體的真實光譜特性，影響分析的準確性。

為了解決上述問題，本研究採用 SENTINEL-2 Level-2A 影像產品。此影像產品經大氣校正去除大氣效應，還原地表物體的真實反射特性，不僅能準確呈現崩塌地裸露土石、植被與周圍環境的光譜差異，提升定量分析能力，使植被、水體或土壤指數的計算更精確，有利於不同時間序列影像的變遷偵測。

受益於 SENTINEL-2 影像約 290 公里的寬幅掃描能力及其標準化的 100x100 公里瓦片分幅特性，且由於研究區域完整落於單一瓦

片範圍內。因此得以選取單一位置 51QTF 的影像瓦片進行分析（51Q 代表 UTM 座標，TF 則代表 MGRS 100km 方格識別碼）。此做法不僅確保了研究區域內所有地物在幾何與輻射特性上的一致性，也簡化了影像處理流程，有效避免了多幅影像拼接可能帶來的潛在誤差。

本研究使用 SENTINEL-2 影像之 Band2（藍光）、Band 3（綠光）、Band 4（紅光）、Band 8（近紅外光）與 Band 11（短波紅外光）五個波段（表 4-4）。其中，B2、B3、B4 為可見光，可反映地表顏色與植被特徵；B8 有助於辨識植被覆蓋與健康狀況；B11 則對土壤與水分含量變化較為敏感，可用於判別裸露地與濕潤區域。

表 4-4 SENTINEL-2A 衛星波段對照表

SENTINEL-2 波段	中央波長(μm)	解析度(m)
Band 1 – Coastal aerosol	0.443	60
Band 2 – Blue	0.490	10
Band 3 – Green	0.560	10
Band 4 – Red	0.665	10
Band 5 – Vegetation Red Edge	0.705	20
Band 6 – Vegetation Red Edge	0.740	20
Band 7 – Vegetation Red Edge	0.783	20
Band 8 – NIR	0.842	10
Band 8A –Vegetation Red Edge	0.865	20
Band 9 – Water vapor	0.945	60
Band 10 – SWIR - Cirrus	1.375	60
Band 11 – SWIR	1.610	20
Band 12 – SWIR	2.190	20

（資料來源 EAS, www.esa.int/Applications/Observing_the_Earth/Copernicus/SENTINEL-2）

二、研究區時空特性與影像品質控制

在區域尺度上，研究區幾乎全位於山區，地形起伏劇烈，地表反射受太陽入射角與地形遮蔽的共同制約。台灣地區太陽高度角具顯著季節性：夏季月份為全年最高，研究區約於 6 月中旬至 7 月上旬處於近乎太陽直射條件，此時陰影範圍可望最小化，有利於精細特徵（如殘坡與不穩定土砂）之光譜與紋理判釋。然而，在感測器與時間幾何的限制下，SENTINEL-2 為太陽同步軌道衛星，固定約於每日上午 10:30 通過台灣上空，無法取得正午時段影像；即使在夏至鄰近日期，實際影像仍非正午近垂直入射，陰影效應難以完全消除。以 2023 年 6 月 24 日（夏季高太陽高度角與 12 月 11 日（冬季低太陽高度角）對照為例（圖 4-3），前者陰影區域明顯較小，顯示夏季影像的幾何優勢。




圖 4-3 SENTINEL-2 影像於山區陰影問題示意圖

(a) 6 月 24 日影像，(b) 12 月 11 日影像

由於研究區位於地形起伏顯著的高雄山區，屬典型地形性降雨區。根據中央氣象署長期統計，該地區降雨集中於 5–9 月，其中 6–8 月為雨季高峰，降雨頻繁、濕度極高，常伴隨午後對流雲與山區霧氣生成。地形高差明顯且迎風坡廣，使雲霧生成與滯留時間長於平地，導致衛星光學影像易受厚雲、薄雲與雲影干擾，進而降低地表反射一致性與可用像元比例。

自 2019 年起，因雲機率產品（Cloud Probability）已穩定提供，各年 6–7 月皆能獲得相對良好的觀測覆蓋，具備足夠的多時序影像可供後續合成與比對。本研究因應研究區地形起伏與雲霧條件，選取每年 6–7 月作為主要分析期。此期間太陽高度角最高，可有效降低地形陰影干擾，亦為植生生長旺盛時段，有助於提升殘坡與不穩定土砂之光譜與紋理可辨識度。然而，高山區夏季午後對流雲與霧氣仍使單一期影像難以達到完全無雲覆蓋。

因上述條件和限制，本研究利用 Google Earth Engine（GEE）進行多時序雲機率分析，選取 2019–2024 年每年 6–7 月之 SENTINEL-2 Level-2A 影像作為輸入資料。於時間序列中針對每個像素取其雲機率最低之觀測，生成「年度最小雲機率合成影像」，可有效抑制雲與雲陰影干擾，確保光譜一致性與空間完整性。圖中黑框之 6–7 月段即

為最終採用的年度合成期間（2019–2024 年），作為後續崩塌潛勢分析的主要資料來源。

圖 4-4 顯示 2016–2024 年間 SENTINEL-2 影像於研究區的時序分布，橫軸為年份，縱軸為月份。橘色實心圓代表各月份可取得之 SENTINEL-2 Level-2A 影像，黑框圓則標示本研究最終選用的分析時段。




圖 4-4 2016–2024 年 SENTINEL-2 影像時序與選用月份

三、像素級整合式有效遮罩與品質評估

為確保年度影像資料在不同年份間的品質與空間一致性，本研究於像素層級建立年度整合式有效遮罩（annual valid mask），逐步排除雲覆蓋、水體與缺值等不可靠像元，以維持多時期影像分析之穩定性。具體判定流程如下：

(1).雲覆蓋排除：以 GEE 所提供之 Cloud Probability 產品為基礎，

凡雲機率（Cloud Probability）大於 20% 者，標示為無效像素。

(2).水體修正：為避免將水體誤判為雲區，輔以 NDWI（Normalized Difference Water Index）進行判定：

$$NDWI = \frac{B3 - B8}{B3 + B8} \quad (4-1)$$

若 $NDWI > -0.5$ 且雲機率介於 20% 至 30% 之間，則該像素視為水體並恢復為有效。

(3).缺值排除：若主要分析波段（B2、B3、B4、B8、B11）中任一

波段為無效值，則該像素於所有波段皆判定為無效。

(4).子集水區整體有效性：以子集水區尺度進行整體品質控管，若

區子集水區內無效像素比例超過 30%，則該子集水區於該年度

視為整區無效，所有波段均不納入後續分析。

此一層級化的判定流程可有效降低雲霧與資料缺值造成的干擾，確保年度影像於時序與空間尺度上的一致性與可比性。依據 2019–

2024 年有效遮罩統計（表 4-5），研究區整體影像品質穩定且可用性高。各年度有效像素（VAL）比例皆維持在 98.6% 以上，無效像素比例介於 0.01%–1.4%，顯示雲與缺值干擾已大幅降低。2019 與 2022 年受局部雲霧影響，無效像素比例略高；2021 與 2023 年則雲量最低，無效像素僅佔總像素的 0.03% 與 0.02%。整體而言，經最小雲機率合成與有效遮罩篩選後，研究區可穩定保留逾 98% 有效像素，顯示本研究之雲影抑制與資料篩選流程具高度一致性與可靠性。

圖 4-6 顯示 SENTINEL-2 有效性遮罩分布，淺藍色為有效像素（VAL），紅色與深紅色分別代表一般無效像素（NDV）與全無效像素子集水區（ALL_NDV）。可見區域主要集中於中海拔與南部山區，對應地形雲與霧氣滯留帶；其餘區域覆蓋完整，顯示本研究建立年度整合式有效遮罩可有效排除雲影與缺值干擾，確保後續崩塌潛勢分析的影像輸入具良好一致性與信賴度。

表 4-5 2019–2024 年有效遮罩統計

年份	無效像素數	有效像素數	無效像素比例 (%)	有效像素比例 (%)
2019	319,255	22,093,200	1.424%	98.576%
2020	68,541	22,343,914	0.306%	99.694%
2021	6,656	22,405,799	0.030%	99.970%
2022	188,669	22,223,786	0.842%	99.158%
2023	4,242	22,408,213	0.019%	99.981%
2024	27,138	22,383,517	0.121%	99.879%




圖 4-5 SENTINEL-2 有效性遮罩分布

第五章 研究結果

第一節 崩塌樣本

模式建立為以子集水區為樣本單位(共 1192 個子集水區)，以殘坡資料做為學習樣本，包含三個層級：(1)崩塌以及非崩塌，此處崩塌為指 2008 年至 2023 年曾有崩塌發生、非崩塌則為此期間從未發生崩塌。(2)在崩塌資料中，依殘坡是否存在，進一步區分為「殘坡」與「非殘坡」兩類。(3) 在殘坡資料中，依殘坡之活動程度將其區分為高、中、低三類；當同一子集水區內同時包含不同活動度之殘坡時，則以最高活動度作為該子集水區之種類樣本。

表 5-1 列出各類崩塌之樣本數。圖 5-1 為出子集水區崩塌與殘坡活動度分布，可以發現，研究區內之崩塌子集水區占比高達 83.8%，但其中殘坡僅佔 11.3%，顯示非崩塌子集水區為少數，同時殘坡亦為少數，主要多為非殘坡之崩塌(佔 72.7%)。

表 5-1 各類崩塌之樣本數

類別 (數量)		活動度	數量	比例
非崩塌			194	16.2%
崩塌 (998)	非殘坡		866	72.7%
	殘坡	低	52	4.36%
		中	50	4.19%
		高	30	2.52%




圖 5-1 子集水區崩塌與殘坡活動度分布

第二節 模式參數建立

本研究在模式應用上使用了各類參數，可分為靜態資料以及多時序之動態資料，各項參數詳述如後(見表 5-2 及附錄一)。

一、靜態資料說明

靜態資料部分包含以解析度 5 公尺之數值地形模型 (Digital Elevation Model, DEM)為基礎計算以子集水區為單位之高程、坡度、坡向等地形參數，也包含水流強度指數(stream power index, SPI)、地形濕度指數(topographic wetness index, TWI)等水文資料。

(1) 地形參數

- **高程：**本研究中的高程相關資料皆採用 5m 網格 DEM。
- **坡度：**將 DEM 利用 ArcGIS Pro 的 Slope 工具，計算出研究區內的坡度。
- **坡向：**將 DEM 利用 ArcGIS Pro 的 Aspect 工具，計算出研究區內的坡向 (Aspect) 分佈。由於坡向因其特有的環形 (Circular) 特質，若直接採用傳統的線性數值或虛擬變數 (Dummy Variables) 進行編碼，皆會破壞其在地理上的連續與漸變關係。為解決此問題，本研究使用三角函數，將坡向角度 (θ) 轉換為兩個互相獨立的連續變數：一個代表南北分量 (Northness, $\cos(\theta)$)，另一個代表東西分量 (Eastness, $\sin(\theta)$)。此方法不僅完整保留了原始坡向

的環形地理資訊，更將其線性化，使其能有效地投入後續潛勢模型進行分析。

- **曲率**：曲率的計算涉及到高程的二階導數，需去除 DEM 的雜訊（noise）和誤差來避免地形曲率值產生劇烈波動與異常。因此 DEM 利用 ArcGIS Pro 的 Focal Statistic 工具，將高程做適當的平滑處理後，再利用 Curvature 工具，計算出研究區內的坡面曲率、水平曲率、剖面曲率。

(2) 水文參數

- **水流強度指數 SPI**：水流強度指數(stream power index, SPI)，常用於河道沖蝕及地貌變遷分析，反映了水流在特定位置的做功能力，即其搬運沉積物和侵蝕地表的能力。SPI 值越高，表示該處水流的侵蝕能力越強，表示如下：

$$SPI = \ln (A_s \cdot \tan\beta) \quad (5-1)$$

其中 A_s 為比集水區面積 (Specific Catchment Area)：指每個單位等高線長度的上游集水區面積，通過集流面積 (Flow Accumulation) 乘以像元大小做近似計算； β 為坡度 (Slope)。

- **地形濕度指數 TWI**：地形濕度指數(topographic wetness index, TWI)，此指數表示地形對土壤濕度的控制，其概念為坡度陡則水迅速向下流動，因此入滲量會較低，土壤中的含水量亦可能較低；

而於低平的地方，由於坡度平緩，水留在地表面較長時間而逐漸入滲，因此土壤中的含水量可能會較高，計算如下：

$$TWI = \ln\left(\frac{A_s}{\tan\beta}\right) \quad (5-2)$$

其中 A_s 為比集水區面積 (Specific Catchment Area)：指每個單位等高線長度的上游集水區面積，通過集流面積 (Flow Accumulation) 乘以像元大小做近似計算； β 為坡度 (Slope)。

- **水系密度(River density)**：此為單位面積中之水系長度，常用於表示地形之破碎、或易受侵蝕程度。一般來說，水系密度高往往表現地形較為破碎，於地形演育過程中受到較多水系切割，公式如下：

$$D_s = \frac{L_T}{A} \quad (5-3)$$

其中 L_T 為子集水區之河川長度總和， A 為子集水區面積。

(3) 地質參數

- 地質因子部分以中央地質調查所提供之地質圖資為基礎，依據主要岩性類別進行重新分類與編碼處理。為使模型能同時辨識多重岩性組合的特徵，本研究採用 Multi-Hot 編碼 (Multi-Hot Encoding) 方式，將各子集水區內出現的岩性類別轉換為多維二進位向量，其中每一維代表一種岩性類別的存在與否。本研究共

考量 23 種主要岩性類別，可涵蓋研究區內主要的沉積岩、變質岩及風化岩型。此方法能表達混合岩層的空間分布特性，使地質特徵以向量形式參與後續 Transformer 模型的特徵加權與時序學習，地質種類及其說明見附錄二。

二、多時序資料說明

本研究使用之動態資料主要來自多時序之衛星資料所計算之影像指標、雨量以及歷年之崩塌統計，說明如後。

(1) SENTINEL-2 衛星影像

- **新型崩塌地影像指標 WLSI**：本研究沿用農村水土保持署 112 年創新研究計畫「多元衛星測量方法應用於崩塌坡面地形變遷分析與穩定性評估」所提出的**崩塌權重樣態指標 (Weighted Landslide State Index, WLSI)**。此指標經研究證明，對於崩塌坡面上之土壤岩屑與母岩有相當好的區判能力，因此將其研究成果整合至本研究的衛星影像地物判釋工作中。指標公式為：

$$WLSI = K_1 \cdot \frac{\text{Band 11} - \text{Band 2}}{\text{Band 11} + \text{Band 2}} + K_2 \cdot \frac{\text{Band 8} - \text{Band 4}}{\text{Band 8} + \text{Band 4}} \quad (5-4)$$

式中的前項(第一項)為岩屑-母岩之區判項，數值介於-1 和 1 之間，其中Band 11為短波紅外光(SWIR)的反射值；Band 2為藍

光波段(Blue)的反射值。式中的第二項 NDVI 為植生指數，藉著突顯近紅外波段與紅色波段的差異來界定植生，數值介於-1 和 1 之間，Band 8為近紅外光波段(NIR)；Band 4為紅光波段(Red)。一般來說，NDVI 小於 0 時為裸露地表或是水體，大於 0.7 時為非常茂密的植被。此外，式中之 K_1 與 K_2 分別為第一項岩屑-母岩區判項之權重以及第二項植生指數之權重，兩者相加為 1。若 K_1 與 K_2 均給定相同權重 (均為 0.5)時，可將 WLSI 數值進行不同崩塌地樣態之區分：(1)水體： <0 ，(2)母岩露頭： $0\sim0.2$ ，(3)土壤(岩屑)： $0.2\sim0.5$ ，(4)植被： >0.5 。

(2) 事件型崩塌目錄

- **時序崩塌資料：**本研究將研究區域內各年度的事件型崩塌目錄計算以子集水區為單位的每年崩塌面積、每年崩塌面積比以及崩塌頻率。
- **地文脆弱度 (Physiographic fragility, F_p)：**根據水保署研究發展平台的定義，地文脆弱度 (Physiographic fragility, F_p) 為以 1.3 公里 x 1.3 公里 的網格為單位進行全臺灣崩塌地的評估。其主要依據兩項關鍵指標都記錄於事件型崩塌目錄：每年是否發生新生崩塌，以及每年度的崩塌面積。在計算方法上，會將各年累計的新生崩塌面積和新生崩塌次數分別取自然對數。隨後，利用這兩項數據的平均

值 (μ) 和標準差 ($\pm\sigma$) 作為劃分標準，並透過矩陣方式，將每個

QPE 網格的地文脆弱度分為低、中、中高、高及極高共五個等級。

本研究為了計算出以子集水區為單位的長期崩塌指標，且須考量

到各子集水區的面積大小不一，對地文脆弱度的計算進行了調整：

累計新生崩塌面積除以該子集水區的面積後再取自然對數，即作

為各子集水區的地文脆弱度指標。

(3) 雨量資料

本研究之雨量資料來源為中央氣象署 CODiS 氣候觀測資料查詢服務所提供之 2.5 km 氣候格點月資料，建立 2008-2023 年間各子集水區之年度最大月雨量。

首先，針對各格點之月資料，先於時間軸上計算每年的最大月雨量，形成年度格點雨量資料集。接著，利用 Intersect 將年度格點資料與 1,192 個子集水區邊界進行空間疊合，篩選出研究區內所有降雨格點。若同一子集水區內包含多個格點，則取其中最大值作為代表雨量；對於未涵蓋格點之小型或邊緣子集水區，則透過 Spatial Join (Closest) 指派最近格點的值。最後，利用 Add Join 將年度雨量屬性回連至子集水區圖層，完成年度最大月雨量的空間化整合 (見附錄一)。

整合上述各項動態與靜態參數，本研究建立共 43 項參數作為模式應用之變數(見附錄一)。其中多時序資料部分本研究整合為以年為單位之年時序資料，而所有變數計算之資料依據、變數名稱則說明於表 5-2。

表 5-2 模式應用使用之各項參數

資料來源	變數名稱(子集水區為單位之統計值)	說明
子集水區	shape_area	子集水區面積(公頃)
地形參數-高程	dem_min	高程最小值
	dem_max	高程最大值
	dem_mean	高程平均值
	dem_std	高程標準差
地形參數-坡度	slope_min	坡度最小值
	slope_max	坡度最大值
	slope_mean	坡度平均值
	slope_std	坡度標準差
地形參數-坡向	aspectcos_mean	坡向南北方向平均值
	aspectcos_std	坡向南北方向標準差
	aspectsin_mean	坡向東西方向平均值
	aspectsin_std	坡向東西方向標準差
地形參數-曲率	curvature_mean	坡面曲率平均值
	curvature_std	坡面曲率標準差
	curvatureprofile_mean	剖面曲率平均值
	curvatureprofile_std	剖面曲率標準差
	curvatureplan_mean	水平曲率平均值
	curvatureplan_std	水平曲率標準差

水文參數-SPI	SPI_min	水流強度指數最小值
	SPI_max	水流強度指數最大值
	SPI_mean	水流強度指數平均值
	SPI_std	水流強度指數標準差
水文參數-TWI	TWI_min	地形濕度指數最小值
	TWI_max	地形濕度指數最大值
	TWI_mean	地形濕度指數平均值
	TWI_std	地形濕度指數標準差
水文參數-水系 密度	river_length	水系長度
	river_density	水系密度
地質參數-岩性	lithology	23 種岩性
WLSI (2019-2024)	WLSI_mean	每年 WLSI 平均值
	WLSI_std	每年 WLSI 標準差
雨量	precipitation_max	每年最大月雨量最大值
多時序崩塌 (2008-2023)	ls_true	每年崩塌發生與否
	ls_frequency	崩塌發生頻率
	ls_area	每年子集水區崩塌面積
	ls_areapercent	每年子集水區崩塌面積 比例
	ls_fragility	地文脆弱度
SENTINEL-2 Surface Reflectance (2019-2024)	Band2、3、4、8、11	CNN 提取像素層級的空 間特徵後，再以子集水 區為單位進行分區池化

第三節 模式預測成果

一、模式預測之架構與訓練策略設計

本計畫以子集水區為樣本單位進行模式應用，並以 70% 之殘坡樣本作為訓練樣本、30% 作為測試樣本，建構三層級之殘坡預測模式架構，包括：

- (1) 模式一：進行子集水區層級之崩塌／非崩塌預測；
- (2) 模式二：進行殘坡／非殘坡之分類預測；
- (3) 模式三：針對已預測為殘坡之子集水區，進一步進行殘坡活動度之分類預測。

在模式訓練與測試流程上，本研究採隨機取樣方式，依 70%：30% 之比例進行模式訓練（training）與測試（testing），並重複執行 100 次，以降低單次樣本抽樣所造成之不確定性。於各次模式預測中，模式一與模式二以機率 0.5 作為分類閾值，預測值大於或等於 0.5 者判定為崩塌（或殘坡），反之則判定為非崩塌（或非殘坡）。針對 100 次之模式成果，模式一與模式二以平均值（或相對出現次數）作為整體成果表現；模式三則以 100 次分類結果中之最多預測類別（多數決）作為最終分類結果。最終模式成果再與現地分布進行比對，並使用準確率（Accuracy）、精確率（Precision, P）及召回率（Recall）等指標，以量化模式之分類正確性。

在模型學習策略上，本研究之 loss function 設計除考量 cross-entropy 以進行分類學習外，並加入限制機制，以避免殘坡之漏估以及殘坡活動度之低估，使模型在殘坡辨識與活動度分級上呈現較為保守且一致之判別結果。此外，batch size 與 learning rate 等超參數則透過試誤方式進行調整，以取得較為合適之模型參數組合。

在各模式之執行細節上，首先針對崩塌與非崩塌進行模式一之預測。由於研究區內崩塌子集水區佔多數，雖採隨機取樣方式建立訓練與驗證樣本，仍額外加入樣本中非崩塌比例不得低於 10% 之判定機制，以避免樣本分布過度偏斜；同時，模式一中亦排除事件型崩塌目錄所衍生之相關參數（見表 5-2），其預測成果如圖 5-2 所示。其次為模式二之殘坡／非殘坡預測，同樣以隨機取樣方式建立訓練與驗證樣本，並於執行時納入表 5-2 所列之所有變數，其預測成果如圖 5-3 所示。最後，針對模式二所預測之殘坡子集水區，進行模式三之殘坡活動度分類預測，執行上亦包含表 5-2 中之所有變數，其成果為殘坡活動度之分類結果，如圖 5-4 所示。




圖 5-2 模式一崩塌與非崩塌預測成果




圖 5-3 模式二殘坡預測成果




圖 5-4 模式三殘坡活動度預測成果

二、模式預測之成果表現與評估

表 5-3 整理了三個模式之預測成果表現。三個模式之整體準確率極佳，均超過 0.9，分別為 0.96、0.93 以及 0.93。圖 5-5、圖 5-6 及圖 5-7 分別呈現模式預測崩塌、殘坡及殘坡活動度與實際情形之比對；圖 5-8 則為整合三個模式的預測結果與實際情形之比對。

表 5-3 模式預測成果

模式	預測對象	準確率 (Accuracy)	精確率 (Precision)	召回率 (Recall)
一	崩塌/非崩塌	0.96	0.92	0.94
二	殘坡/非殘坡	0.93	0.76	0.88
三	殘坡活動度	0.93	低	0.9
			中	0.74
			高	1.0

模式一之預測成果與實際情形有極高的吻合，呈多數以集水區為崩塌類別，此主要為 2009 年莫拉克颱風後造成大規模崩塌事件後的殘餘結果。




圖 5-5 模式一崩塌之實際與預測成果比較

(a)實際崩塌分布情形，(b)模式預測崩塌分布情形

模式二對殘坡的崩塌實際則較具有挑戰性，儘管研究區內多數子集水區為崩塌類別（83.8%），但僅有 11.3%之殘坡，預測成果則顯示有較明顯的過度預測情形（Precision 為 0.76），但本研究認為，在模式可信賴的前提下，未來或需仔細檢討模式二中過度預測之殘坡是否實具有成為殘坡之潛勢。




圖 5-6 模式二殘坡之實際與預測成果比較

(a)實際殘坡分布情形，(b)模式預測殘坡分布情形

模式三整體準確率為 0.93；各類別精確率（Precision）分別為低活動度 0.90、中活動度 0.74、高活動度 1.0，而召回率（Recall）在低、中、高三類皆為 1.0。混淆矩陣(表 5-3)結果顯示，實際為殘坡之子集水區在低、中、高三種活動度間皆能正確分類，且活動度類別之間未出現互相誤判，其中高活動度殘坡亦未出現誤判，顯示模式三對實際殘坡活動度具穩定之分類能力。相較之下，中活動度之精確率較低，原因在於模式三之誤判僅來自過度預測，部分實際為崩塌但非殘坡之子集水區被誤判為殘坡，且僅落在低活動度與中活動度兩類；此

結果與模式二之分析結果一致。上述過度預測之子集水區將於第四小節進一步進行判釋與檢討。




圖 5-7 模式三殘坡活動度之實際與預測成果比較

(a) 實際殘坡活動度分布情形，(b) 模式預測殘坡活動度分布情形

表 5-3 模式三混淆矩陣

實際 \ 預測	殘坡			
	無殘坡	活動度		
		低	中	高
無殘坡	842	6	18	0
活動度低	0	52	0	0
殘坡 活動度中	0	0	50	0
活動度高	0	0	0	30

整合三個模式後之預測分布與實際分布在整體空間型態上相當一致（圖 5-8），主要殘坡集中區域皆能被合理呈現；部分子集水區雖出現低至中活動度殘坡之預測差異，但整體未見顯著空間錯置，顯示模式具備區域尺度應用之可行性。




圖 5-8 整合三種模式預測成果

(a) 實際分布情形，(b) 預測分布情形

三、模式參數貢獻度

本研究以移除單一特徵/參數(Leave-one-feature-out) 重新訓練模型模式的方法來評估各參數之貢獻度，以 Important Score 作為量化指標，分析結果如圖 5-9 所示。各模式之重要參數呈現明顯差異，反映不同預測目標下，靜態與動態因子所扮演之角色並不相同。

在模式一（崩塌／非崩塌）中，參數貢獻度以地形相關之靜態因子為主，其中以坡度與坡向（東西向）具有最高的重要性，顯示在子集水區尺度下，崩塌發生與地形條件仍具有高度關聯性。相較之下，動態參數於模式一中的相對重要性較低。

在模式二（殘坡／非殘坡）中，動態參數之重要性明顯提升，其中以 WLSI（崩塌指標）及時序崩塌事件相關指標為主要貢獻因子。WLSI 為一結合可見光、近紅外光、短波紅外光波段之崩塌地影像指標，能有效區分坡面上之母岩露頭、岩屑（土壤）與植生覆蓋狀態，對於反映崩塌後坡面物質組成與地表擾動程度具有良好判釋能力。此結果顯示，殘坡之形成與判識除受地形背景控制外，亦高度依賴於坡面物質狀態與歷史崩塌行為所留下之影像特徵。整體而言，模式二中動態參數之貢獻比例約為 61.9%，高於靜態參數。

在模式三（殘坡活動度）中，參數貢獻度進一步由動態因子主導，其中以 WLSI 及年最大月雨量具有最高的重要性。由於 WLSI 能反

映坡面裸露岩屑比例與植生覆蓋變化，其數值變動可視為坡面受擾動程度與恢復狀態之綜合指標，當與降雨強度條件結合時，對於殘坡活動度之判釋具高度敏感性。模式三中動態參數之整體貢獻比例約為74.5%，顯示殘坡活動度之變化主要受坡面物質狀態與降雨條件之共同影響。

綜合而言，參數貢獻度分析結果顯示，靜態地形因子仍為崩塌判釋之基礎因素，而動態參數則為殘坡判釋及其活動度預測中的關鍵因子。




圖 5-9 模式參數貢獻度 (Important Score)

四、模式預測差異之判釋與檢討

基於前述結果可知，模式三之誤判主要來自過度預測情形，因此本研究進一步針對模式預測結果中與實際判釋不一致之子集水區進行檢視，以探討其可能成因。圖 5-10 為模式預測與實際差異子集水區之分布圖，所示皆為實際判定為崩塌但未列為殘坡，卻於模式中被預測為低或中等活動度殘坡之子集水區。此類子集水區於全域尺度下屬於少數情形，未呈現大尺度連續分布，惟局部區段仍可觀察到聚集現象。




圖 5-10 模式預測與實際差異子集水區分布圖

以下針對其中一處子集水區，依循殘坡清查手冊所採用之調查方式，利用 Google Earth 進行高解析度時序影像比對，其結果如圖 5-11 所示。顯示該子集水區於 2016（0610 豪雨事件與梅姬颱風）年及 2021（盧碧颱風）年之後有崩塌地明顯之變化（以 2017 跟 2022 影像觀察之）：比對 2014 與 2017 年影像部分坡面（淺藍與深藍方框）於 2017 年可觀察到崩塌冠部範圍向上邊坡擴大與下邊坡與河道中有土砂殘留之現象（橘色方框）。觀察 2023 之影像，則可見圖中下方河岸有新增崩塌（黃色方框），顯示坡面物質尚未完全穩定。該子集水區雖未有任何區域被清查手冊列為殘坡，但部分邊坡明顯呈現殘坡之潛勢特徵。

惟本研究目前僅針對單一子集水區進行案例檢討，後續仍需更多案例與現地資料，以進一步驗證模式對預測差異案例之判釋結果。




圖 5-11 過度預測案例子集水區之 Google Earth 時序影像比對

(上圖 2014、中圖 2017、下圖 2023)

五、模式比較

本研究以常見之 **隨機森林 (Random Forest)** 與 **極端梯度提升 (XGBoost)** 作為對照模型，比較其與所提出之 **CNN-Transformer** 在三層級預測模式中的表現，包含模式一（非崩塌／崩塌）、模式二（非殘坡／殘坡）及模式三（殘坡活動度），並以 **Accuracy** 作為評估指標。

在模式一中，三種模型皆具一定判別能力，其中 CNN-Transformer 的 Accuracy 為 0.96，高於 XGBoost(0.88) 與 Random Forest (0.83)。然而，在較為複雜的模式二與模式三中，模型表現差異明顯擴大。模式二中，CNN-Transformer 仍維持 0.93 的 Accuracy，而 XGBoost 與 Random Forest 則分別降至 0.57 與 0.43；模式三中，CNN-Transformer 同樣達到 0.93，但 XGBoost 與 Random Forest 僅為 0.23 與 0.28。

整體而言，結果顯示 CNN-Transformer 在三層級預測任務中皆具穩定且較佳的表現，尤其在殘坡判釋與活動度分類等高複雜度任務中，明顯優於傳統機器學習模式。

表 5-4 CNN-Transformer 與傳統機器學習模式（XGBoost、Random Forest）之效能比較

模式層級	模式分類	CNN-Transformer (Accuracy)	XGBoost (Accuracy)	Random Forest (Accuracy)
一	非崩塌/崩塌	0.96	0.88	0.83
二	非殘坡/殘坡	0.93	0.57	0.43
三	殘坡活動度	0.93	0.23	0.28

第六章 結論與建議

本計畫以高屏溪流域為研究區，採用 113 年農村水土保持署殘坡清查資料作為學習對象，針對流域內殘坡之潛勢與活動度進行模式建構。研究方法結合卷積神經網路（Convolutional Neural Network, CNN）與轉換學習（Transformer），並以子集水區為基本分析單元，建立殘坡潛勢及其活動度之分層式預測架構。

本研究整合靜態與動態因子，共建立 43 項參數作為模式輸入變數，並建構三類預測模式，包括（1）崩塌／非崩塌預測、（2）殘坡／非殘坡預測，以及（3）殘坡活動度分類。三個模式之整體準確率（Accuracy）均達 0.9 以上，分別為 0.96、0.93 與 0.93，顯示本研究所建構之模式具備穩定且良好之整體分類能力。其中，模式一之預測成果與實際分布高度一致；模式二與模式三則出現部分過度預測情形，主要表現為實際為崩塌但非殘坡之子集水區，被判釋為低至中等活動度殘坡。

預測結果透過數值效能評估、參數貢獻度分析、與模式比較研究等檢核，驗證三層級 CNN - Transformer 架構於殘坡判釋與活動度分析上具合理性與相對優勢，整體模式流程具備可操作性與可擴充性。其中參數貢獻度分析顯示，動態／多時序因子可有效反映降雨觸發與坡面擾動後的地表狀態變化（如植生回復程度），因此對殘坡判釋與

活動度分級具有明顯貢獻。本創新研究計畫提出之模式方法，可更有效率地支援山區殘坡清查與活動性評估，並可作為相關作業推動與資源配置之依據。

另就模式二與模式三所呈現之部分過度預測現象，本研究建議可將相關子集水區列為後續清查與追蹤之優先名單，並結合高解析度影像與現地資料，檢視坡面是否存在崩塌擴大、土砂殘留或植生回復不完全等特徵，以評估其未來演變為殘坡或活動度提升之可能性，作為精進殘坡清查與監測策略之參考，期望能為台灣的土砂災害防治工作有所助益。

參考文獻

1. 農村水保署(2024)，殘坡判定操作手冊-113 年度修訂版。
2. 莊承穎、陳振宇、詹婉妤(2024)，應用地文脆弱度建立集水區不安
定土砂潛勢分級。
3. 全臺 839 子集水區環境指標(崩塌率)，農業部農村發展及水土保
持署，BigGIS 巨量空間資訊系統。
4. 殘坡圖 (Residual Slope Map)，農業部農村發展及水土保持署技術
研究發展平台。
5. 李德福、蔡文杰、賴坤成（2013），高屏溪流域地質特性與地形穩
定性分析，中華水土保持學報，45(3)，201–216。
6. 吳俊鉉（2014）。以崩塌率為依據建構邏輯式迴歸崩塌潛勢評估
模式。中華水土保持學報，45(4)，257–265。
7. Zhao, T., & Cai, C. (2017). Deep learning in landslide detection: Using
CNNs for feature extraction and recognition. *Landslides*, 14(2), 763-
773.
8. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting
system. *Proceedings of the 22nd ACM SIGKDD International
Conference on Knowledge Discovery and Data Mining*, 785–794.
9. Fawcett, T. (2006). An introduction to ROC analysis. *Pattern
Recognition Letters*, 27(8), 861–874.
10. Copernicus Data Space Ecosystem. (n.d.). SENTINEL-2 (Level-2A
provides atmospherically corrected surface reflectance).


- 11.Zhang, S., et al. (2022). Comparing convolutional neural network and machine learning methods for landslide susceptibility mapping. *Frontiers in Environmental Science*.
- 12.Yang, Z., Xu, C., & Li, L. (2022). Landslide detection based on ResU-Net with Transformer and CBAM embedded: Two examples with geologically different environments. *Remote Sensing*, 14(12), 2885.
- 13.Cai, H., Chen, T., Niu, R., & Plaza, A. (2021). Landslide Detection Using Densely Connected Convolutional Networks and Environmental Conditions. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 5235–5247.
- 14.Bao, Y., et al. (2023). Landslide susceptibility mapping by fusing convolutional neural networks and vision Transformer. *Sensors*, 23(1), 88.
- 15.Guzzetti, F., Reichenbach, P., Cardinali, M., Galli, M., & Ardizzone, F. (2006). Estimating the quality of landslide susceptibility models. *Geomorphology*.
- 16.Saito, T., & Rehmsmeier, M. (2015). The Precision-Recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE*, 10(3), e0118432.
- 17.Liu, Z., Mao, H., Wu, C.-Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A ConvNet for the 2020s. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 11966–11976)
- 18.Touvron, H., Cord, M., Douze, M., Massa, F., Sablayrolles, A., & Jégou, H. (2021). Training data-efficient image transformers & distillation through attention. In *Proceedings of the 38th International Conference*

- on Machine Learning (ICML) (Proceedings of Machine Learning Research, Vol. 139, pp. 10347–10357). PMLR.*
19. Wu, L., Liu, R., Ju, N., Zhang, A., Gou, J., He, G., & Lei, Y. (2024). Landslide mapping based on a hybrid CNN-transformer network and deep transfer learning using remote sensing images with topographic and spectral features. *International Journal of Applied Earth Observation and Geoinformation*, 126, 103612
 20. Liu, B., Wang, W., Wu, Y., & Gao, X. (2024). Attention Swin Transformer UNet for landslide segmentation in remotely sensed images. *Remote Sensing*, 16(23), 4464
 21. Wu, X., Ren, X., Zhai, D., Wang, X., & Tarif, M. (2025). Lights-Transformer: An efficient Transformer-based landslide detection model for high-resolution remote sensing images. *Sensors*, 25(12)


附錄一、子集水區靜態與動態參數空間分布圖

高程


最小值




最大值




平均值




標準差






坡向


南北方向平均值




南北方向標準差




東西方向平均值




東西方向標準差







水平曲率平均值




水平曲率標準差






TWI


最小值




最大值




平均值




標準差






年度最大月雨量(2008~2023)


2008




2009



2010




2011



Legend


max_precipitation






年度最大月雨量(2008~2023)


2016




2017



2018




2019



Legend


max_precipitation






ls_true(崩塌發生與否，0 為否；1 為是)


2008




2009



2010




2011




ls_true(崩塌發生與否，0 為否；1 為是)


2012




2013



2014




2015




ls_true(崩塌發生與否，0 為否；1 為是)


2016




2017



2018



2019




ls_true(崩塌發生與否，0 為否；1 為是)


2020




2021



2022




2023




ls_areapercent

2008



2009



2010





2011



Legend

ls_areapercent






ls_areapercent


2016

2017




2018


2019



Legend


ls_areapercent






Is_area


2008




2009




2010




2011






ls_area


2016




2017




2018




2019







ls_frequency



ls_fragility








WLSI 平均值

2023

2024






WLSI 標準差

2023

2024



附錄二、試驗區地質名稱與岩性說明


地質名稱	說明
argillite (硬泥岩)	由泥岩或頁岩經輕度變質形成，比頁岩更堅硬且不具頁理。
slate (板岩)	由頁岩經低度變質形成，具備特有的「板劈理」，可輕易剝成薄片。
phyllite (千枚岩)	變質程度介於板岩和片岩之間，劈理面帶有絲綢般的光澤。
sandstone (砂岩)	由沙粒大小的碎屑膠結而成的沉積岩。
interbeds (互層 / 夾層)	指在一個岩層中，夾雜著另一種不同岩性的薄層。
black schist (黑色片岩)	富含碳質（如石墨）的片岩，呈現黑色。
conglomerate (礫岩)	由直徑大於 2 公釐的圓形礫石膠結而成的沉積岩。
limestone (石灰岩)	主要成分為碳酸鈣的沉積岩，常由海洋生物遺骸形成。
clay (黏土)	由極細小的礦物顆粒組成的沉積物，遇水具可塑性。

地質名稱	說明
graphitic shale (石墨質頁岩)	富含石墨的頁岩，呈現深灰色或黑色。
green schist (綠色片岩)	富含綠泥石等綠色礦物的片岩，是特定變質環境的指標。
gravel (礫石)	未經膠結的岩石碎屑，顆粒直徑通常大於 2 公釐。
indurated sandstone with interlamination of slate and carbonaceous slate (帶有板岩和碳質板岩薄夾層的硬化砂岩)	一種岩石結構，主體是硬化砂岩，其中夾有極薄的板岩層。
indurated (硬化的)	指沉積物因成岩作用變得堅硬、緻密的狀態。
laterite (紅土)	在濕熱氣候下，岩石經強烈風化形成的富含鐵、鋁氧化物的紅色土壤或岩石。
metamorphosed limestone (變質石灰岩)	由石灰岩經過變質重新結晶而成，商業上常稱為大理石。
mainly black schist (主要為黑色片岩)	一種地質描述，指某個區域的岩石組成以黑色片岩為主。

地質名稱	說明
mudstone (泥岩)	由黏土和粉砂顆粒組成的沉積岩，但不像頁岩有明顯的頁理。
phyllite with quartzitic sandstone interbeds (帶有石英砂岩互層的千枚岩)	指以千枚岩為主體，其中夾有數層石英砂岩的岩層結構。
phyllite with sandstone interbeds (帶有砂岩互層的千枚岩)	指以千枚岩為主體，其中夾有數層砂岩的岩層結構。
quartzitic sandstone (石英砂岩)	主要由石英顆粒組成的砂岩，質地非常堅硬。
siliceous schist (矽質片岩)	富含石英（二氧化矽）的片岩。
shale (頁岩)	由黏土壓實形成的沉積岩，具有薄層狀的頁理構造。

附錄三、模式原始碼(Matlab 範例)

I、模式流程圖解



II、模式學習參數設定：

- **Embedding dimension: 64**
- **Number of Attention Heads: 4**
- **Dimension of feed-forward hidden: 128**
- **Number of encoder layers: 3**
- **Number of Epochs: 25**
- **Minimum of Batch Size: 32**
- **Learning Rate: 1e-3**

III、模式範例原始碼(主程式)

```
% transformer_static_transient_final
% Single-file Transformer classifier for MATLAB (R2024b compatible).
% Uses dlarray and custom training loop — no custom layer classes required.
% Inputs:
%   - Synthetic dataset with static variables + transient (time-series) variables
%   - Trainable Transformer encoder (implemented with dlarray ops)
% Usage:
%   Save this file as transformer_static_transient_final.m
%   In MATLAB: transformer_static_transient_final

clear; close all; rng(0);

%% -----
% Synthetic dataset setup
% -----

numSamples = 1200;
seqLen = 50; % time steps
numTransientChannels = 2; % channels per time step
numStaticFeatures = 4;
numClasses = 4;

% Preallocate
X_transient = zeros(numSamples, seqLen, numTransientChannels, 'single');
X_static = zeros(numSamples, numStaticFeatures, 'single');
Y = zeros(numSamples,1);

% Generate synthetic signals where class depends on transient + static
for i=1:numSamples
```

```

t = linspace(0,1,seqLen);
% channel 1: sinusoid with class-dependent freq
freq = 2 + randi(4);
ch1 = sin(2*pi*freq*t) + 0.15*randn(1,seqLen);
% channel 2: chirp or noise depending on class
if rand < 0.7
    ch2 = chirp(t,1,1,10) + 0.1*randn(1,seqLen);
else
    ch2 = 0.5*randn(1,seqLen);
end
X_transient(i,:,1) = ch1;
X_transient(i,:,2) = ch2;
% static features: small vector correlated with random class index
cls = randi(numClasses);
base = (cls-1) * 0.4;
X_static(i,:) = base + 0.2*randn(1,numStaticFeatures);
Y(i) = cls;
end
% normalize transient per sample
for i=1:numSamples
    s = squeeze(X_transient(i,:,:));
    s = (s - mean(s,'all')) / (std(s,0,'all') + 1e-6);
    X_transient(i,:) = s;
end
% shuffle and split
perm = randperm(numSamples);
X_transient = X_transient(perm,:,:);
X_static = X_static(perm,:);
Y = Y(perm);
nTrain = round(0.7*numSamples);
nVal = round(0.15*numSamples);
Xtr_seq = X_transient(1:nTrain,:,:); Ytr = Y(1:nTrain);
Xva_seq = X_transient(nTrain+1:nTrain+nVal,:,:); Yva = Y(nTrain+1:nTrain+nVal);
Xte_seq = X_transient(nTrain+nVal+1:end,:,:); Yte = Y(nTrain+nVal+1:end);

Xtr_stat = X_static(1:nTrain,:); Xva_stat = X_static(nTrain+1:nTrain+nVal,:); Xte_stat =
X_static(nTrain+nVal+1:end,:);
%% -----

```

% Model hyperparameters

% -----

```
dModel = 64;          % embedding dimension
numHeads = 4;         % attention heads
dFF = 128;            % feed-forward hidden dim
numEnc = 3;           % number of encoder layers
numEpochs = 25;
miniBatchSize = 32;
learnRate = 1e-3;
```

%% -----

% Initialize parameters

% (all parameters stored in struct 'params' as dlarray single)

% -----

```
params = initParams(dModel, numHeads, dFF, numEnc, numTransientChannels,
numStaticFeatures, numClasses);
```

% Adam optimizer state

```
pnames = fieldnames(params);
adam.m = struct(); adam.v = struct();
for k=1:numel(pnames)
    adam.m.(pnames{k}) = zeros(size(params.(pnames{k})), 'like', params.(pnames{k}));
    adam.v.(pnames{k}) = zeros(size(params.(pnames{k})), 'like', params.(pnames{k}));
end
beta1 = 0.9; beta2 = 0.999; epsAdam = 1e-8;
iteration = 0;
```

%% -----

% Training loop

% -----

```
numBatches = floor(nTrain/miniBatchSize);
for epoch=1:numEpochs
    fprintf('Epoch %d/%d\n', epoch, numEpochs);
    % shuffle training set
    idx = randperm(nTrain);
    Xtr_seq = Xtr_seq(idx,:,:); Xtr_stat = Xtr_stat(idx,:); Ytr = Ytr(idx);
    for b=1:numBatches
        iteration = iteration + 1;
        batchIdx = (b-1)*miniBatchSize + (1:miniBatchSize);
        Xb_seq = Xtr_seq(batchIdx,:,:);    % [B x T x C]
        Xb_stat = Xtr_stat(batchIdx,:);    % [B x S]
```

```

Yb = Ytr(batchIdx); % [B x 1]
% dlarray formatting:
% transient: channels x seqLen x batch -> (C x T x B)
Xdl = dlarray(permute(Xb_seq,[3,2,1]), 'CBT');
% static: features x batch (S x B)
Sdl = dlarray(Xb_stat,'CB');
% labels one-hot: classes x batch
T = onehotencode(categorical(Yb), 2); % expand along 2nd dim (columns)
Tdl = dlarray(T); % transpose to [numClasses x B]
% forward + gradients
[loss, grads, logits] = dlfeval(@modelLoss, params, Xdl, Sdl, Tdl, dModel, numHeads,...
                                dFF, numEnc);

% Adam update
fields = fieldnames(params);
for f=1:numel(fields)
    name = fields{f};
    g = grads.(name);
    m = adam.m.(name); v = adam.v.(name);
    m = beta1*m + (1-beta1)*g;
    v = beta2*v + (1-beta2)*(g.*g);
    mHat = m/(1-beta1^iteration);
    vHat = v/(1-beta2^iteration);
    params.(name) = params.(name) - learnRate * mHat ./ (sqrt(vHat) + epsAdam);
    adam.m.(name) = m; adam.v.(name) = v;
end
if mod(iteration,20)==0
    probs = softmax(extractdata(gather(logits)),1);
    [~,pred] = max(probs,[],1); [~,truec] = max(extractdata(gather(Tdl)),[],1);
    acc = mean(pred==truec);
    fprintf(' Iter %d: Loss %.4f, Batch Acc %.2f%%\n', iteration, ...
            double(gather(extractdata(loss))), acc*100);
end
end

% validation
valAcc = evaluateModel(params, Xva_seq, Xva_stat, Yva, dModel, numHeads, dFF,
numEnc);
fprintf(' Validation Accuracy: %.2f%%\n', valAcc*100);
end

```

應用人工智慧技術-結合卷積網路以及轉換學習方法進行殘坡潛勢分析

```
%% -----  
% Test  
% -----  
  
testAcc = evaluateModel(params, Xte_seq, Xte_stat, Yte, dModel, numHeads, dFF, numEnc);  
fprintf('\nTest Accuracy: %.2f%%\n', testAcc*100);
```

IV、模式內部 function

```
function acc = evaluateModel(params, X_seq, X_stat, Y, dModel, numHeads, dFF, numEnc)  
  
    numSamples = size(X_seq,1);  
    correct = 0;  
  
    for i = 1:numSamples  
        % Prepare darray  
        x = darray(permute(X_seq(i,:,:), [3 2 1]), 'CBT'); % CxTxB  
        s = darray(X_stat(i,:)', 'CB'); % SxB  
        logits = transformerForward(params, x, s, dModel, numHeads, dFF, numEnc);  
        [~,pred] = max(extractdata(gather(logits)), [], 1);  
        if pred == Y(i)  
            correct = correct + 1;  
        end  
    end  
  
    acc = correct / numSamples;  
end  
  
function params = initParams(dModel, numHeads, dFF, numEnc, numTransientChannels, numStaticFeatures, numClasses)  
  
    % embed transient channel -> dModel (applied per timestep)  
    params.Win = darray(initializeGaussian([dModel, numTransientChannels]));  
    params.bin = darray(zeros(dModel,1,'single'));  
    % static projector: static vector -> dModel  
    params.Wstatic = darray(initializeGaussian([dModel, numStaticFeatures]));  
    params.bstatic = darray(zeros(dModel,1,'single'));  
    % encoder layers params  
    for l=1:numEnc  
        params(['Wq_' num2str(l)]) = darray(initializeGaussian([dModel, dModel]));  
        params(['Wk_' num2str(l)]) = darray(initializeGaussian([dModel, dModel]));  
        params(['Wv_' num2str(l)]) = darray(initializeGaussian([dModel, dModel]));  
        params(['Wo_' num2str(l)]) = darray(initializeGaussian([dModel, dModel]));
```

```

params(['ln1_gamma_' num2str(l)]) = darray(ones(dModel,1,'single'));
params(['ln1_beta_' num2str(l)]) = darray(zeros(dModel,1,'single'));
params(['W1_' num2str(l)]) = darray(initializeGaussian([dFF, dModel]));
params(['b1_' num2str(l)]) = darray(zeros(dFF,1,'single'));
params(['W2_' num2str(l)]) = darray(initializeGaussian([dModel, dFF]));
params(['b2_' num2str(l)]) = darray(zeros(dModel,1,'single'));
params(['ln2_gamma_' num2str(l)]) = darray(ones(dModel,1,'single'));
params(['ln2_beta_' num2str(l)]) = darray(zeros(dModel,1,'single'));

end

% output head
params.Wout = darray(initializeGaussian([numClasses, dModel]));
params.bout = darray(zeros(numClasses,1,'single'));

end

function [loss, grads, logits] = modelLoss(params, Xdl, Sdl, Tdl, dModel, numHeads, dFF, numEnc)

% Forward pass
logits = transformerForward(params, Xdl, Sdl, dModel, numHeads, dFF, numEnc);

% Compute cross-entropy loss
loss = crossentropy(logits, Tdl,'DataFormat','CB');

% Compute gradients
grads = dlgradient(loss, params);

end

function A = initializeGaussian(sz)
scale = 0.02;
A = single(scale*randn(sz));

end

function Y = layerNorm(X, gamma, beta, epsilon)
% X: dModel x T x B
% gamma, beta: learnable scaling and bias, size [dModel x 1]
% epsilon: small number to avoid divide-by-zero
if nargin < 4
epsilon = 1e-5;
end

% Compute mean and variance along feature dimension (rows)
mu = mean(X, 1); % 1 x T x B
sigma2 = var(X, 0, 1); % 1 x T x B

% Normalize
Xhat = (X - mu) ./ sqrt(sigma2 + epsilon);

```

```
% Apply scale and shift
Y = gamma .* Xhat + beta;          % broadcasting gamma, beta along T x B

end

% Model Gradients
% -----
function [grad, loss] = modelGradients(net, dLXs, dLXt, Y)

    outputs = forward(net, dLXs, dLXt);

    Y = onehotencode(Y,1)';

    loss = crossentropy(outputs, Y, "TargetCategories", "independent");

    grad = dlgradient(loss, net.Learnables);

end

function out = multiheadAttention(params, x, layerIdx, numHeads)

% x: dModel x T x B

[dModel, T, B] = size(x);

dk = dModel / numHeads;

% Linear projections

Wq = params(['Wq_' num2str(layerIdx)]);
Wk = params(['Wk_' num2str(layerIdx)]);
Wv = params(['Wv_' num2str(layerIdx)]);
Wo = params(['Wo_' num2str(layerIdx)]);

% Flatten batch for linear layers

xflat = reshape(x, dModel, T*B);

Q = Wq*xflat; K = Wk*xflat; V = Wv*xflat;

% Reshape to [dk x numHeads x T x B]

Q = reshape(Q, dk, numHeads, T, B);
K = reshape(K, dk, numHeads, T, B);
V = reshape(V, dk, numHeads, T, B);

% Output container

attnOut = zeros(dModel, T, B, 'like', x);

for b = 1:B

    for h = 1:numHeads

        Qh = squeeze(Q(:,h,:,:),b)); % T x dk
        Kh = squeeze(K(:,h,:,:),b)); % T x dk
```

```

Vh = squeeze(V(:,h,:b)); % T x dk

% Attention scores

scores = Qh * Kh' / sqrt(dk); % T x T

% Softmax along rows (classic numeric)

weights = exp(scores) ./ sum(exp(scores), 2); % T x T

% Attention output

att = weights * Vh; % T x dk

% Assign back, merge heads

attnOut((h-1)*dk+1:h*dk, :, b) = att; % dk x T

end

end

% Final linear projection

attnOut = reshape(attnOut, dModel, T*B);

out = Wo * attnOut;

out = reshape(out, dModel, T, B);

end

%% Positional encoding (sin/cos) dModel x T
%% -----

function P = positionalEncoding(dModel, T)

P = zeros(dModel, T, 'single');

for p = 1:T

    for i = 1:dModel

        if mod(i-1,2) == 0

            P(i,p) = sin((p-1) / (10000^((i-1)/dModel)));

        else

            P(i,p) = cos((p-1) / (10000^((i-2)/dModel)));

        end

    end

end

P = darray(P);

end

% Transformer Encoder Block Constructor
% -----

```

```

function layerGraphOut = transformerBlock(name, dModel, numHeads, dff)

    import matlab.internal.lang.capability.Capability

    import nnet.cnn.layer.*

    mha = multiheadAttentionLayer(numHeads, dModel, ...
        Name=name+"_mha");

    ln1 = layerNormalizationLayer(Name=name+"_ln1");
    ln2 = layerNormalizationLayer(Name=name+"_ln2");

    ffn = [
        fullyConnectedLayer(dff, Name=name+"_fc1")
        reluLayer(Name=name+"_relu")
        fullyConnectedLayer(dModel, Name=name+"_fc2")
    ];

    layerGraphOut = layerGraph([
        additionLayer(2, Name=name+"_add1")
        additionLayer(2, Name=name+"_add2")
    ]);

    layerGraphOut = addLayers(layerGraphOut, mha);
    layerGraphOut = addLayers(layerGraphOut, ln1);
    layerGraphOut = addLayers(layerGraphOut, ln2);
    layerGraphOut = addLayers(layerGraphOut, ffn);

    % Skip connection 1
    layerGraphOut = connectLayers(layerGraphOut, name+"_mha/out", name+"_add1/in1");
    layerGraphOut = connectLayers(layerGraphOut, name+"_ln1/out", name+"_add1/in2");

    % FFN skip connection
    layerGraphOut = connectLayers(layerGraphOut, name+"_fc2", "add2/in1");
    layerGraphOut = connectLayers(layerGraphOut, name+"_ln2", "add2/in2");
end

function logits = transformerForward(params, Xdl, Sdl, dModel, numHeads, dFF, numEnc)

    [C, T, B] = size(Xdl);

    % input embedding (per timestep)
    Xflat = reshape(Xdl, C, T*B); % C x (T*B)
    E = params.Win * Xflat + params.bin; % dModel x (T*B)

```

```

E = reshape(E, dModel, T, B); % dModel x T x B

% positional encoding
pos = positionalEncoding(dModel, T); % dModel x T
pos = reshape(pos, dModel, T, 1);

x = E + pos; % broadcast pos

% encoder stack
for l = 1:numEnc
    attOut = multiheadAttention(params, x, l, numHeads);
    x = layerNorm(x + attOut, params.(['ln1_gamma_' num2str(l)]), params.(['ln1_beta_' num2str(l)]));
    y = fullyConnect(x, params.(['W1_' num2str(l)]), params.(['b1_' num2str(l)]));
    y = gelu(y);
    y = fullyConnect(y, params.(['W2_' num2str(l)]), params.(['b2_' num2str(l)]));
    x = layerNorm(x + y, params.(['ln2_gamma_' num2str(l)]), params.(['ln2_beta_' num2str(l)]));
end

% temporal pooling (mean over time)
pooled = mean(x,2); % dModel x 1 x B
pooled = reshape(pooled, dModel, B);

% static projection
Snum = extractdata(Sdl); % Convert to numeric
staticProj = params.Wstatic * Snum; % Wstatic: [dModel x numFeatures]
staticProj = staticProj + params.bstatic; % Bias addition
staticProj = darray(staticProj); % Convert back to darray

% fuse (addition)
fused = pooled + staticProj;

% classification head
logits = params.Wout * fused + params.bout; % numClasses x B
end

```

附錄四、計畫審查會議暨回覆辦理情形

一、期中審查會議紀錄暨回覆辦理情形

	審查意見	回覆辦理情形
報告內容審查意見：		
一	本報告書內多為概念介紹、名詞定義、資料搜集，對模式建立過程描述較少，初步結果也只有少少的四張圖與一個表，應加強描述本研究之貢獻內容。	感謝委員建議。本報告已於「研究方法」與「研究資料」兩章節中補充並強化模式建立流程與建構方式之說明。
二	試驗區以高屏溪流域為主，並引用「農業部農村發展及水土保持署 BigGIS 巨量空間資訊系統」之資料，惟資料中事件報告是有時間性，本研究初步結果卻只有一張圖，並未說明是何時間的崩塌及殘坡預測成果，請加強。	感謝委員建議。本研究之年度預測結果係以逐年模型推估後取平均，其平均值僅作為長期相對潛勢分布之指標，用以呈現多年期間持續具高潛勢特徵之區域，而非實際年度崩塌機率之平均值。為避免誤解，相關說明已於第五張第三節補充註明。
三	模式驗證成果如表 5-3，只分為崩塌/非崩塌及殘坡/非殘坡，太過粗糙，不易辨別辨識成果，應有其他評量指標顯示模式表現狀況。	感謝委員建議。成果以準確率、精確率、召回率來呈現模式(一與二)表現成果，針對活動度預測成果則以三總活動度類別分別計算上述指標；另，圖 5-2 及圖 5-3 以機率來表示模式成果，圖 5-3 以預測分類來表現活動度預測之分布。
四	AI 或機器學習於坡地潛勢辨識研究已有眾多國際期刊論文發表，目前研究報告僅羅列二篇期刊論文，應加強文獻探討之工作。	感謝委員建議。已加強文獻探討於研究方法章節，惟目前無針對「殘坡」此對象進行潛勢分析或模式預測之文獻。

	審查意見	回覆辦理情形
五	圖 5-2 崩塌預測成果顯示整個流域皆屬崩塌類別，其可信度待討論，應有更多說明。這樣的成果對水保工作幾乎無任何參考價值。	感謝委員提醒。雖然潛勢預測整體偏高，但係反映試驗區內潛在殘坡廣泛存在與再滑動潛能之特性。相關說明與結果詮釋已於第五張第三節第一小節中補充，以釐清模型之預測目標與應用範疇。
六	第六章缺乏對下半年工作之詳細規劃，不知期末可否達成目標。	感謝委員建議。本研究順利完成預期目標，除完成殘坡與活度動預測模式之試驗，針對模式開發工作，本研究亦提供原始碼於附錄三。
七	圖 2-1 高屏溪流域不安定土砂集水區潛勢分級；本署已不採用此圖資，有關流域歷年崩塌分級，建議改用「集水區環境指標(崩塌率)」作為參考(詳參 BigGIS 圖臺/核心圖層/水文與集水區/全臺 839 子集水區)。	感謝委員建議。本研究已依建議修正內容，除說明不安定土砂集水區潛勢分級圖僅作早期對照外，並於第二章第一節新增「集水區環境指標(崩塌率)」作為主要依據，以界定試驗區範圍與崩塌活躍程度。
八	P.4-5 第二節各集水區殘坡體積如何計算？另，P5-8~5-9 模式應用參數，為何未列殘坡數量、面積、體積及活動性？	感謝委員提醒。本研究所使用之殘坡體積資料係引用水保署殘坡清查成果中，依《113 年殘坡操作判定手冊》所提供之「崩塌體積-面積關係式」 $V_L = 0.1025 A_L^{1.401}$ 其中， V_L 為殘坡體積 (m^3)， A_L 為殘坡面積 (m^2)。各集水區之殘坡總體積則為區內所有殘坡體積之加總。
九	請補充說明模式雨量所用資料來源。	感謝委員建議。已於第五章第二節之雨量資料部分補充說明模型輸入之雨量資料來源與前處理方式。

	審查意見	回覆辦理情形
十	本計畫所稱之殘坡，依圖 5-2、圖 5-3 之預測成果，與農村水保署定義之殘坡似有極大不同，兩者之差異，請再強化說明。	感謝委員提醒。本研究之「殘坡」係以水保署殘坡清查資料為基礎，並以子集水區為分析單位，透過模式一先預測具崩塌潛勢之水區，再以模式二辨識其中多年期仍維持高潛勢者，作為「潛在殘坡」。與水保署以高程變化與現地調查判釋之成果不同，本研究著重於利用遙測與多時序因子推估長期不穩定趨勢，屬方法與尺度延伸之應用。
十一	P5-1 研究結果崩塌數量達 998 處，該崩塌之最小面積為何(2 公頃以上?)。	感謝委員提問。由於地形資料、SENTINEL-2 衛星資料之解析度均為 10 公尺x10 公尺，配合水保署之崩塌目錄資料，本研究處理之最小崩塌面積為 0.1 公頃。
十二	本計畫模式一預測子集水區崩塌，模式二預測殘坡，後續加入衛星影像資料能否自動預測殘坡位置。	感謝委員提問。根據模式建構資料，除於後續加入衛星影像外，仍需加入雨量分布資料、更新的崩塌目錄等動態資料進行預測。

二、期末審查會議紀錄暨回覆辦理情形

	審查意見	回覆辦理情形
報告內容審查意見：		
一	是否可評估各種資料層級對模型預測效果之貢獻程度？	感謝委員建議。已於成果報告書第五章第三節中之第三小節補充。
二	論文中指出模式二與模式三存在過度預測之情況，基於模式可信賴之前提，是否應進一步評估這些殘坡發展之潛勢？是否有實際案例可供確認？	感謝委員建議。已於成果報告書第五章第三節中之第四小節補充過度預測之潛勢與實際案例。
三	建議呈現混淆矩陣之分析結果。	感謝委員建議。已於第五章第三節中之第二小節補充。
四	關於模式於未來應用時，其所需之時間尺度為年雨量或事件雨量？亦即，是否可使用時雨量進行預測？另就模式預測輸出而言，係量化判斷集水區是否發生崩塌或殘坡，抑或可進一步定位至集水區內實際發生崩塌之位置？	感謝委員提問。本計畫現階段模型定位為子集水區尺度之長期潛勢／活動度分級，降雨採用長期統計指標（如年最大月雨量）以支援年度更新與作業整合；惟崩塌觸發與事件內短延時累積雨量關聯更直接，故未來若以事件預警為目標，可評估改採事件尺度時間序列（含時雨量）作為輸入，並需同步調整事件定義與驗證設計。本計畫現階段模式輸出以子集水區尺度量化判斷其是否具崩塌／殘坡潛勢及活動度等級，主要用於清查排序與資源配置，無法直接定位至集水區內實際崩塌發生之精確位置。

	審查意見	回覆辦理情形
五	本方法與本署既有殘坡判釋流程可如何相輔相成，並融入既有作業流程？	感謝委員建議。本方法除針對過度預測之子集水區，依殘坡手冊所述之 DoD 與 H.O.S.T. 判釋方法進行複判外，亦可依本計畫模型輸出結果，提供高活動度及高潛勢區之優先查核排序，以支援年度清查之資源配置。
六	透過本分析可結合各類地文因子探討殘坡分布情形，對水保署坡地管理具參考價值；後續可嘗試不同地形分區或集水區尺度之分析，以完備整體分析範圍。	感謝委員建議。考量本研究參數貢獻度分析顯示，殘坡判釋與活動度分級主要受動態／多時序因子影響，靜態地文因子相對不具主導性，因此分析單元未必需採子集水區進行聚合；加以子集水區大小不一且形狀不規則，易造成聚合偏差並稀釋區內動態訊號（如多時序 SENTINEL-2 植生回復／裸露變化），後續可評估改採固定格網作為基本分析單元，以提升可比性並強化區內熱點呈現。由於殘坡資料為面狀圖資，格網標籤可透過格網與殘坡面交集計算覆蓋比例建立，並視需要採覆蓋率門檻以降低邊界噪音。
七	靜態參數是否僅受地形變數影響，尚有再行檢討之必要。	感謝委員建議。現階段靜態因子除 SPI、TWI 等 DEM 衍生指標外，亦已納入河道密度與岩性，故並非僅受地形影響；惟仍可能受構造／斷層、土壤或崩積物性質、土地利用及坡腳／河岸侵蝕等長期控制因子影響。後續將視資料可得性評估補強相關代表性指標，並

	審查意見	回覆辦理情形
		以貢獻度/敏感度分析檢核其增益。
八	殘坡活動僅以降雨因子（如月最大雨量）作為考量，是否足以描述殘坡之活動度？	感謝委員提醒。僅以降雨因子（如月最大雨量）不足以完整描述殘坡活動度。降雨主要反映外在觸發強度，而活動度亦與坡面擾動後之地表狀態與恢復程度相關。故本研究結合降雨因子與多時序 SENTINEL-2 影像所萃取之地表狀態特徵（如植生回復、裸露比例及其時間變化）進行活動度分級，以避免僅以單一降雨指標取代活動度判釋；參數貢獻度分析亦顯示「年最大月雨量」與「WLSI」為關鍵因子，因此外在驅動與地表狀態需同時考量。另本模式著重於建立長期、多年度且一致性的資料蒐整與自動化流程，並透過年度（或固定週期）更新以追蹤活動度變化趨勢，提升清查與管理作業效率與一致性。
九	潛勢預測模型之預測期間長度為何，建議加以說明。	感謝委員建議。本研究模型輸出為長期潛勢分級而非逐年事件預報，故不設定「預測至某一年」之固定預報期。其結果係基於可得之 2008-2023 年降雨／崩塌背景因子與 2019-2024 年多時序 SENTINEL-2 地表特徵，推估各子集水區之相對潛勢；其適用期間為截至 2024 年之基準結果，並建議以年度更新方式維持其時效性

	審查意見	回覆辦理情形
		(遇重大災害事件亦應提前更新)。未來若取得更新年度之 SENTINEL-2 影像與動態因子，可依相同流程重新萃取特徵並進行推論。
十	動態因子於不同時間尺度下之選用方式為何？若資料不足時，應如何處理或補足？	感謝委員提問。動態因子可依應用目標分為「長期更新」與「事件觸發」兩種時間尺度選用；本計畫現階段以支援年度（或固定週期）更新為主，故優先採用能穩定取得且可跨年比較之統計指標（如年/季/月尺度之極值或累積量），並搭配多時序 SENTINEL-2 地表狀態指標（如 WLSI、NDVI 類及其變化）。若未來目標轉向事件層級，則可改以事件窗內之延時累積雨量（含時雨量）與事件前後之影像變化作為時間序列輸入。