

計畫編號：ARDSWC-114-074

以機器學習方法建立結合歷史崩塌及空間
關聯性之可解釋性廣域崩塌潛勢評估模型

**Developing an interpretable machine
learning-based landslide susceptibility
assessment model considering historical
landslides and spatial correlations
(成果報告書)**

執行單位：國立台灣大學

執行期間：114 年 02 月 18 日至 114 年 12 月 31 日

計畫主持人：陳麒文 助理教授

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，僅供本署施政參考)

以機器學習方法建立結合歷史崩塌及空間關聯性之可解釋性廣域崩塌潛勢評估模型

摘要

本期計畫以事件型崩塌目錄進行崩塌評估模型的訓練，並對應事件蒐整降雨與地震等誘發因子，使模型能更直接反映誘發因子與崩塌發生的關聯性。另外，盡可能加入崩塌相關多元因子以增加模型評估依據。

本研究比較了地質分區建模以及全區統一模型的差異，結果顯示，多數集水區以分區模型表現較佳。然而，大安溪集水區出現統一模型優於分區模型之現象，推測其原因與資料量相關，仍需進一步探討其成因與改善策略。

在模型解釋能力方面，本研究導入 TabNet 與 SHAP 兩種可解釋機制。TabNet 具內在可解釋性，可提供全域與局部特徵重要性，並在不同事件中展現較前期模型更具穩定性的效能；SHAP 則能夠統計特徵數值對模型決策的具體影響方向，在防減災面向具更多分析價值。

本期計畫對崩塌評估模型的改進有利於導入未來降雨或地震情境，推估目標條件下崩塌潛勢以輔助防災單位進行風險管理與調適決策，並透過可解釋模型鎖定關鍵致災因子，作為工程改善或調適策略依據。

關鍵字：崩塌潛勢模型、特徵重要性、廣域模型、兩型崩塌、同震崩塌

Abstract

This study implements an event-based landslide catalog, a significant methodological advance over the conventional annual inventory, to train the susceptibility model. By explicitly integrating rainfall, seismic, and other event-triggered factors, the framework more accurately characterizes the causal relationship between these triggering mechanisms and landslide occurrence. Furthermore, a comprehensive set of multi-source conditioning factors was incorporated to enhance the robustness of model inference.

We compared the performance of geology-specific regional models against a single unified model across different watersheds. Results indicate that regional models generally outperform the unified approach in most areas. However, the Daan River basin shows a counter-intuitive finding where the unified model performs better, a phenomenon hypothesized to relate to sample size effects; this needs further investigation into the underlying causes and optimization strategies.

To ensure model transparency and actionable insights, two kinds of interpretability frameworks were adopted: TabNet and SHapley Additive exPlanations (SHAP). TabNet provides intrinsic interpretability, offering both global and local feature importance, and demonstrates superior performance stability across different event scenarios compared to the previous MLP baseline (mlp_his). SHAP analysis quantifies the directional contribution of specific feature values to model decisions, thereby providing a powerful analytical tool for disaster mitigation and risk analysis. This methodological improvement is crucial for scenario-based landslide

susceptibility assessment under future rainfall or earthquake projections. The derived model outputs and explanatory analyses can effectively support disaster risk management and adaptation planning, enabling the targeted identification of key contributing factors for evidence-based engineering interventions or policy-driven mitigation strategies.

Keywords : landslide susceptibility model 、 feature importance 、 Wide-area model 、 rainfall-induced landslide 、 coseismic landslide

目次

摘要	I
Abstract	II
目次	IV
圖次	VII
表次	XIV
第一章 緒論	1
第一節 計畫研究動機及目的	1-1
一、已完成之重要計畫成果摘要	1-1
二、本期計畫擬解決問題	1-3
三、研究目的	1-7
第二節 相關文獻蒐整	1-8
一、崩塌機制及衝擊	1-8
二、機器學習建置崩塌潛勢地圖	1-10
三、機器學習及深度神經網路	1-12
四、機器學習模型差異	1-17
五、特徵值選擇差異	1-20
六、可解釋性機器學習模型	1-22
第二章 工作執行步驟與方法	2-1
第一節 工作執行步驟	2-1

第二節 工作執行方法.....	2-4
一、研究區域選擇.....	2-4
二、地質條件及災害概況.....	2-7
三、崩塌資料庫的建置.....	2-15
四、訓練特徵的選擇及前處理.....	2-16
五、神經網路原理及模型設計邏輯.....	2-26
六、模型架構說明.....	2-37
七、評估方法.....	2-39
第三章 工作進度與交付項目	3-1
第一節 計畫預定進度及甘特圖.....	3-1
第二節 計畫交付項目	3-3
第四章 結果及建議	4-1
第一節 結果.....	4-1
一、研究區域歷史崩塌資料更新.....	4-1
二、模型崩塌訓練特徵更新.....	4-12
三、建立內部可解釋性模型架構.....	4-23
四、TabNet 可解釋性	4-34
五、SHAP 分析.....	4-46
六、崩塌潛勢地圖.....	4-67

七、同震型崩塌及雨型崩塌差異.....	4-68
八、小結.....	4-72
九、討論.....	4-73
十、研討會發表.....	4-75
第二節 建議.....	4-78
一、崩塌潛勢模型建立.....	4-78
二、模型加值應用.....	4-78
三、模型潛在應用.....	4-78
參考文獻.....	參-1
附錄	附錄-1

圖次

圖 1- 1 前期計畫結果展示圖	1-2
圖 1- 2 崩塌領域機器學習模型發展歷程（修改自 Tang 等，2022）	1-11
圖 1- 3 卷積神經網路模型（Qin 等人，2022）	1-18
圖 1- 4 Transformer 模型架構（Vaswani 等，2017）	1-19
圖 1- 5 崩塌評估模型使用特徵比例圖（改寫自溫振宇，2005）	1-21
圖 2- 1 研究流程.....	2-1
圖 2- 2 六大地質構造分區（Chen, 2016）及模型建置策略：(a) 單一 模型；(b) 多模型	2-2
圖 2- 3 前期計畫模型及可解釋性優化策略：(a) 前期計畫 att_his 模 型；(b) TabNet 架構（Arik 等，2020）；(c) GAMI-Net 架構（Yang 等，2021）	2-3
圖 2- 4 兩型崩塌熱力圖（統計自水保署 2004－2024 資料）	2-5
圖 2- 5 同震型崩塌熱力圖（統計自水保署 2004－2024 資料）	2-5
圖 2- 6 崩塌研究示範區域	2-6
圖 2- 7 不同介面下不同波段之反射強度（Serra-Ruiz 等，2019） ..	2-22
圖 2- 8 神經網路模型示意圖（Glosser.ca，2013）	2-26
圖 2- 9 常見自注意力機制	2-32

圖 2- 10 模型設計邏輯及資料流概念圖	2-36
圖 2- 11 ROC 曲線示意圖	2-40
圖 3- 1 計畫進度甘特圖.....	3-1
圖 4- 1 馬武溪集水區地形特徵及崩塌分布（左上：高程；右上：坡 向；左下：坡度）	4-2
圖 4- 2 旗山溪集水區地形特徵及崩塌分布（左上：高程；右上：坡 向；左下：坡度）	4-3
圖 4- 3 大安溪集水區地形特徵及崩塌分布（左上：高程；右上：坡 向；左下：坡度）	4-4
圖 4- 4 荖濃溪集水區地形特徵及崩塌分布（左上：高程；右上：坡 向；左下：坡度）	4-5
圖 4- 5 立霧溪集水區地形特徵及崩塌分布（左上：高程；右上：坡 向；左下：坡度）	4-6
圖 4- 6 水璉沿岸集水區地形特徵及崩塌分布（左上：高程；右上：坡 向；左下：坡度）	4-7
圖 4- 7 清水溪集水區地形特徵及崩塌分布（左上：高程；右上：坡 向；左下：坡度）	4-8

圖 4- 8 陳有蘭溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）	4-9
圖 4- 9 美崙溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）	4-10
圖 4- 10 立霧溪集水區(同震)地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）	4-11
圖 4- 11 模型訓練使用特徵.....	4-16
圖 4- 12 馬武溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）	4-18
圖 4- 13 旗山溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）	4-19
圖 4- 14 大安溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）	4-20
圖 4- 15 荖濃溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）	4-21
圖 4- 16 立霧溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）	4-22
圖 4- 17 馬武溪集水區各事件 AUC 圖	4-24

圖 4- 18 旗山溪集水區各事件 AUC 圖	4-25
圖 4- 19 大安溪集水區各事件 AUC 圖	4-27
圖 4- 20 荖濃溪集水區各事件 AUC 圖	4-29
圖 4- 21 立霧溪集水區各事件 AUC 圖	4-31
圖 4- 22 馬武溪集水區 TabNet 全局可解釋性圖	4-34
圖 4- 23 馬武溪集水區局部可解釋性熱區圖	4-35
圖 4- 24 旗山溪集水區 TabNet 全局可解釋性圖	4-36
圖 4- 25 旗山溪集水區局部可解釋性熱區圖	4-36
圖 4- 26 大安溪集水區 TabNet 全局可解釋性圖	4-37
圖 4- 27 大安溪集水區局部可解釋性熱區圖	4-37
圖 4- 28 荖濃溪集水區 TabNet 全局可解釋性圖	4-38
圖 4- 29 荖濃溪集水區局部可解釋性熱區圖	4-39
圖 4- 30 立霧溪集水區 TabNet 全局可解釋性圖	4-39
圖 4- 31 立霧溪集水區局部可解釋性熱區圖	4-40
圖 4- 32 水璉沿岸集水區 TabNet 全局可解釋性圖	4-40
圖 4- 33 水璉沿岸集水區局部可解釋性熱區圖	4-41
圖 4- 34 清水溪集水區 TabNet 全局可解釋性圖	4-42
圖 4- 35 清水溪集水區局部可解釋性熱區圖	4-42

圖 4- 36 陳有蘭溪集水區 TabNet 全局可解釋性圖.....	4-42
圖 4- 37 陳有蘭溪集水區局部可解釋性熱區圖	4-43
圖 4- 38 美崙溪集水區 TabNet 全局可解釋性圖.....	4-43
圖 4- 39 美崙溪集水區局部可解釋性熱區圖	4-44
圖 4- 40 立霧溪集水區(同震)TabNet 全局可解釋性圖	4-45
圖 4- 41 立霧溪集水區(同震)局部可解釋性熱區圖.....	4-45
圖 4- 42 馬武溪集水區 SHAP 全局重要性圖	4-47
圖 4- 43 馬武溪集水區地質組成及土地利用對坡度 SHAP 圖	4-47
圖 4- 44 馬武溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水).....	4-48
圖 4- 45 旗山溪集水區 SHAP 全局重要性圖	4-49
圖 4- 46 旗山溪集水區地質組成及土地利用對坡度 SHAP 圖	4-49
圖 4- 47 旗山溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水).....	4-50
圖 4- 48 大安溪集水區 SHAP 全局重要性圖	4-51
圖 4- 49 大安溪集水區地質組成及土地利用對坡度 SHAP 圖	4-51
圖 4- 50 大安溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水).....	4-52

圖 4- 51 荖濃溪集水區 SHAP 全局重要性圖	4-53
圖 4- 52 荖濃溪集水區地質組成及土地利用對坡度 SHAP 圖	4-53
圖 4- 53 荖濃溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)	4-54
圖 4- 54 立霧溪集水區 SHAP 全局重要性圖	4-55
圖 4- 55 立霧溪集水區地質組成及土地利用對坡度 SHAP 圖	4-55
圖 4- 56 立霧溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)	4-56
圖 4- 57 水璉沿岸集水區 SHAP 全局重要性圖	4-57
圖 4- 58 水璉沿岸集水區地質組成及土地利用對坡度 SHAP 圖	4-57
圖 4- 59 水璉沿岸集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)	4-58
圖 4- 60 清水溪集水區 SHAP 全局重要性圖	4-59
圖 4- 61 清水溪集水區地質組成及土地利用對坡度 SHAP 圖	4-59
圖 4- 62 清水溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)	4-60
圖 4- 63 陳有蘭溪集水區 SHAP 全局重要性圖	4-61
圖 4- 64 陳有蘭溪集水區地質組成及土地利用對坡度 SHAP 圖	4-61

圖 4- 65 陳有蘭溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、 最大 3 小時、最大 5 小時、最大 12 小時累計降水).....	4-62
圖 4- 66 美崙溪集水區 SHAP 全局重要性圖	4-63
圖 4- 67 美崙溪集水區地質組成及土地利用對坡度 SHAP 圖	4-63
圖 4- 68 美崙溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最 大 3 小時、最大 5 小時、最大 12 小時累計降水).....	4-64
圖 4- 69 立霧溪集水區(同震)SHAP 全局重要性圖	4-65
圖 4- 70 立霧溪集水區(同震)地質組成及土地利用對坡度 SHAP 圖 ...	4- 65
圖 4- 71 立霧溪集水區(同震)降雨特徵 SHAP 圖(左上至右下：降水強 度、最大 3 小時、最大 5 小時、最大 12 小時累計降水).....	4-66
圖 4- 72 崩塌潛勢地圖（以荖濃溪集水區於凱米颱風事件為例） ..	4-68
圖 4- 73 不同集水區中特徵重要性主成分分析	4-70
圖 4- 74 第一主成分及第二主成分主成分負荷圖（a：第一主成分； b：第二主成分).....	4-71
圖 4- 75 研究助理許祐誠進行口頭發表（上圖）；陳麒文教授與與會學 者合照（下圖）	4-76
圖 4- 76 Student Paper Awards 獲獎	4-77

表次

表 1- 1 前期計畫中 4 種模型架構	1-1
表 2- 1 常見激發函數說明	2-28
表 2- 2 模型代號表.....	2-36
表 2- 3 混淆矩陣.....	2-39
表 3- 1 計畫預定進度表.....	3-2
表 3- 2 計畫交付項目表.....	3-3
表 4- 1 六大地質構造分區示範研究區	4-1
表 4- 2 不同崩塌誘發因子崩塌分布坡度(單位:度)	4-12
表 4- 3 馬武溪集水區各事件 AUC 統計	4-23
表 4- 4 旗山溪集水區各事件 AUC 統計	4-24
表 4- 5 大安溪集水區各事件 AUC 統計	4-26
表 4- 6 荖濃溪集水區各事件 AUC 統計	4-28
表 4- 7 立霧溪集水區各事件 AUC 統計	4-30
表 4- 8 水璉沿岸集水區各事件 AUC.....	4-32
表 4- 9 清水溪集水區各事件 AUC.....	4-32

表 4- 10 陳有蘭溪集水區各事件 AUC.....	4-32
表 4- 11 美崙溪集水區各事件 AUC.....	4-33
表 4- 12 立霧溪集水區各事件 AUC.....	4-33
表 4- 13 崩塌位於 high 及 very high 區域的比例表.....	4-67
表 4- 14 同震型特徵 VIF 表.....	4-74

第一章 緒論

第一節 計畫研究動機及目的

一、已完成之重要計畫成果摘要

本團隊前期計畫（ARDSWC-113-069）主要目的為：一、探討將模型評估年之前的歷史崩塌作為神經網路模型特徵時，對於評估年的評估能力影響；二、研發基於自注意力機制的神經網路模型，以期改善資料網格間相關性不足的問題，並取代較受限制的斜坡單元模型；三、前述兩項目標達成後，建置並優化模型，期望能建立廣範圍且高精度的崩塌潛勢評估地圖。

針對前兩項目的，前期計畫中產製四種模型（表 1-1）並進行比較與評估。

表 1-1 前期計畫中 4 種模型架構

	不考量歷史崩塌	考量歷史崩塌
不考量空間關係	mlp_no_his	mlp_his
考量空間關係	att_no_his	att_his

在進行了前述兩個要點的評估後，於測試區（隘寮溪集水區）測試之成果如圖 1- 1a。結果顯示，將歷史崩塌作為特徵有助於提高模型預測崩塌的能力，而使用自注意力機制模型可以有效取代斜坡單元模型並在某些條件下表現出比非自注意力模型更加優良的評估能力。

各模型之崩塌潛勢地圖如圖 1- 1b, c, d。




圖 1- 1 前期計畫結果展示圖

另外，不論是否考慮空間相關性，加入歷史崩塌事件特徵能大幅提升模型評估能力（F1_score 分別於 mlp 模型及 att 模型提升 0.38 及 0.51）。而自注意力機制使模型在 precision 及 recall 中取得較好平衡並降低資料偏誤造成之缺陷且得以避免斜坡單元模型之限制，更適用於實際防減災操作。在地質差異大的區域，本研究建立的評估模型保持良好的泛用性（F1_score 維持在 0.7 左右）。評估不同年份事件，模

型在大多數情況下保持高水準表現(F1_score 維持在 0.6 以上)，具有時間泛用性。與過往的研究相比，本研究的機器學習模型能取得更穩定及良好之崩塌評估表現。實際運用上，考量到不同使用者運算資源及評估區域的不一致，建議以 att_his 模型為主要選擇、mlp_his 模型次之，而 mlp_no_his 僅適用於初步評估。

二、本期計畫擬解決問題

臺灣位於板塊交界帶，受到造山運動及熱帶/副熱帶季風氣候影響，屬於山高水急的高強度侵蝕環境，易於造成崩塌的發生(林冠瑋，2010)；並且由於大量的褶皺、斷層的演育及變質作用下地質弱面的發展，使得地質材料十分破碎，也減弱了邊坡在面臨外在因素下的抵抗崩塌能力(林慶偉，1996)。在過往，耳熟能詳的許多大規模崩塌災害，如集集地震時的草嶺崩塌(唐昭榮等，2009；李錫堤，2011)、九份二山崩塌(Wang 等，2003)、國道三號順向坡崩塌(蘇泰維等，2010；羅佳明等，2011)、莫拉克風災小林村獻肚山崩塌(李錫堤等，2009；陳樹群及吳俊鉉，2009)等，無一例外都展現了崩塌可能造成的嚴重後果。而在現今全球氣候變遷環境下，短延時強降雨及長延時的降雨事件頻發，往往也對崩塌的發生產生巨大的影響。因此，如何有效應對崩塌的發生並推動防減災策略，已成為學術研究及政府政策的重要課題。

隨著地理資訊系統（Geographic Information System，GIS）的演進以及遙測技術快速發展，如光達（LiDAR）、無人航空載具（UAV）等，使得高精度數值地形模型（DEM）愈發容易取得，伴隨大數據的發展，20 世紀中期開始便逐漸有更多利用統計方法或是遺傳算法研究各種條件：如地質、地形、降水、植被覆蓋、人類活動等因素對崩塌發生的影響，期望能夠了解崩塌行為這樣「複雜且多因素」的物理規則，以建構出崩塌發生的邊界條件。

而得益於演算法及電腦計算能力的進步，近年來透過機器學習方法有逐漸取代傳統統計方法的趨勢。Merghadi 等（2020）提及：「現今電腦計算能力發展迅速，透過機器學習方法建置崩塌潛勢地圖是趨勢，其與過往的統計或經驗方法不同，可以更有效的在複雜的崩塌機制及種類中預測崩塌事件」。機器學習方法可以透過大量的崩塌與未崩塌案例，以及與其相關的各種條件進行歸納及建模，找出人難以直觀發現的崩塌發生條件，且建置完成的模型具有快速、直觀、易操作使用的優勢。

然而，在利用機器學習預測崩塌這項工作中，前人研究甚少考量歷史崩塌再發的機制與現象，這項重要因子理應被納入考量。並且考量到崩塌發生乃連續行為：發生部啟動，途經滑動部，停止於堆積部，若以簡單的網格式資料切分研究區域，並以逐格為單位給予機器學習，

可能會導致其連續性消失而失去其物理真實的機制，過往常見之斜坡單元模型也有所限制及缺點。以上的問題分別於前期計畫中進行評估及測試。

在前期計畫中，我們了解到加入歷史崩塌事件特徵能大幅提升模型評估能力；並且使用自注意力機制考量網格資料間空間相關性後，發展的崩塌潛勢模型具有許多優點，不但解決了網格式模型缺乏網格之間的相關性而使崩塌圈繪不連續的現象，也可以有效的避免傳統利用斜坡單元的方式受到的限制。同時，經過測試發現，前期計畫開發的模型在空間泛用性上、時間泛用性上都有不錯的表現。

但後續進一步的討論及測試後發現，模型雖然在不同的測試區域能夠維持一定的評估表現，但是面對到與訓練區域地質、降水條件差異較大的測試區時，評估表現仍舊會有一定的下降。因此，欲利用此模型進行大範圍或是全台的崩塌潛勢評估，需要進一步的調整，以維持各地潛勢評估的品質。另外，在時間泛用性的討論中，我們發現了兩個問題：第一點是當使用模型評估特定年份時，若此年降水條件較為極端，如 2009 年莫拉克風災為台灣西南部帶來的大量降水，這樣的條件可能因與模型訓練時的條件相去甚遠，使得模型會無法正確地評估。第二點是我們發現，在利用 2024 年以前的觀測資料作為模型輸入針對 2024 年進行崩塌潛勢評估時，由於 2021-2023 年崩塌紀錄

數量較少，使得加入歷史崩塌作為特徵產出的崩塌潛勢評估結果，相對於實際上 2024 年面對 0403 地震、凱米颱風、山陀兒颱風及康芮颱風等致崩因素接踵而來的狀況，可能會有低估的問題。

並且，前期計畫中使用的崩塌資料是地礦中心公告之崩塌紀錄，為一整年度的崩塌判釋結果，這意味著無法確定崩塌事件的誘發因子究竟是豪雨或是地震，這可能導致模型訓練會有錯誤評估的部分。參考審查委員意見，本期將蒐整事件型崩塌資料及對應之崩塌誘發因子，分別進行討論及評估。

另外，在前期計畫中我們專注於研發評估能力較佳的模型，因此使用深度神經網路模型為基礎（黑盒子模型），對於模型評估過程中的特徵重要性及結果的解釋是以事後解釋型（post-hoc interpretability）方法為主。隨著學界對於模型可解釋性的探討愈發深入（Yang 等，2021；Fang 等，2023；Youssef 等，2023），災害防治單位在調適作為上同樣需要更多參考依據，本期計畫擬調整模型架構，建立內在可解釋性模型（intrinsic interpretability model），讓崩塌潛勢的結果更直觀的對應致災因子，有利於有關單位參考評估。

三、研究目的

- (一) 改善前期計畫中崩塌潛勢模型在不同地質條件下，評估效果出現一定下滑的問題。
- (二) 通過改良模型評估流程、崩塌資料類型以考量降水及其餘致崩因子的多元性，降低模型受訓練資料限制的問題，增加模型面對氣候變遷下極端氣候的能力。
- (三) 引入內在可解釋性模型以提升模型評估結果的可解釋性，降低前期計畫中黑盒子模型於實務運用上參考性較缺乏的問題。

第二節 相關文獻蒐整

一、崩塌機制及衝擊

崩塌係指岩層或經風化後的岩塊、岩屑、及土壤等材料，受重力影響而下滑的行為。具體來說，當坡面上的剪應力（Shear stress）大於剪力強度（Shear strength）時，便會導致岩土塊體的滑動，這樣的情形可能源自於剪應力的增加，如邊坡上新增外加载重、坡腳開挖、暫時性應力增量（地震）等；亦或是來自剪力強度的下降，如風化作用導致岩體不連續面發育、降水導致的超額孔隙水壓、頁岩層的遇水軟化等（He, 2009）。

台灣位於板塊交界帶，受到造山運動及熱帶/副熱帶季風氣候影響，形成山高水急的高強度侵蝕環境，易於造成崩塌的發生（林冠瑋，2010）；並且由於大量的褶皺、斷層的演育及變質作用下地質弱面的發展，使得地質材料十分破碎，也減弱了邊坡在面臨外在因素下抵抗崩塌的能力（林慶偉，1996）。

在過往，我們耳熟能詳許多大規模崩塌災害，如集集地震時的草嶺崩塌（唐昭榮等，2009；李錫堤，2011）、九份二山崩塌（Wang 等，2003）；國道三號順向坡崩塌（蘇泰維等，2010；羅佳明等，2011）；莫拉克風災小林村獻肚山崩塌（李錫堤等，2009；陳樹群與吳俊銘，2009），無一例外都體現了崩塌災害的嚴重性。崩塌事件時刻在人們

周遭發生著，對於人身安全及經濟有著莫大的影響。

在現今全球氣候變遷環境下，短延時強降雨及長延時的降雨事件頻發，往往也對崩塌的發生產生巨大的影響，因此，要如何應對崩塌的發生及進行防、減災在學術研究及政府政策上都是一項十分重要的議題。

在過往，對於崩塌的研究發源於案例式的研究，此類研究透過經驗歸納、野外調查、物理方法及電腦模擬等方法研究一個或多個崩落地地的崩塌發生機制及行為（李錫堤等，2009；唐昭榮等，2009；林冠璋，2010；李錫堤，2011；羅佳明等，2011；黃淳銘，2019；鄭德尉，2021），隨著遙測方法及影像的進步，也有許多人透過如航照、衛星影像及 LiDAR 等方法了解崩塌的地形特徵及變化行為（陳樹群與吳俊銘，2009；蘇泰維等，2010；謝有忠等，2017；曹博涵，2019；曹祉晏，2017；Dong 等，2014）。不過，案例式的研究受限於一定的邊界條件，可能缺乏通用性，一旦地質條件及環境有較大的改變便可能有所差異。隨著地理資訊系統（Geographic Information System，GIS）的演進以及大數據的發展，漸漸有人利用統計方法或是遺傳算法研究各種條件，如：地質、地形、降水、植被覆蓋、人類活動等因素，對於崩塌事件發生的影響（Böhner 與 Selige，2002；Guzzetti 等，2008；Saito 等，2010；Brunetti 等，2010；Shu 等，2019；Yoon 等，2019；

Chen 等，2019；Wijaya 等，2022；Pacheco Quevedo 等，2023）。在了解多數情況下崩塌發生的重要條件後，為了防、減災的目的，「崩塌潛感圖（Landslide susceptibility mapping，又稱崩塌潛勢地圖）」的概念也應運而生（Sarkar 與 Kanungo，2004；Guzzetti 等，2006；Huang 與 Zhao；2018）。

二、機器學習建置崩塌潛勢地圖

機器學習（Machine Learning）方法始於 20 世紀 50 年代，千禧年後受惠於電腦運算能力及演算法的進步，開始大量投入崩塌潛勢評估領域。Merghadi 等（2020）提及：「現今電腦計算能力發展迅速，透過機器學習方法建置崩塌潛勢地圖是趨勢，其與過往的統計或經驗方法不同，可以更有效的在複雜的崩塌機制及種類中預測崩塌事件。」簡單的說，透過大量的崩塌與未崩塌案例，以及它們所具有的各種因素組合，演算法可以進行歸納及建模並找出人類或許難以直觀發現的崩塌致災條件。同時，由於母體夠大，模型的通用性相對於案例式的研究可以更廣泛的應用在不同地區，有助於大規模的評估及檢視。Qin 等（2022）透過將不同地質條件的地區分類，並使用不同種機器學習方法分別訓練並比較，最終在中國吉林省長白山地區的崩塌圈繪任務中有良好表現。Huang 等（2022）利用機器學習方法，評估於訓練資

料中不同的圈繪方法下，模型最終的表現差異。Tang 等（2022）使用深度神經網路模型 SegFormer 對 UAV 正射影像進行判釋，於九寨溝地區取得良好的判釋成果，可以準確對震致崩塌後的地區進行自動圈繪。He 等（2023）透過結合機器學習模型及 SBAS-InSAR，建立了崩塌閾值模型，有助於建立潛在崩塌滑動區。以上案例說明了機器學習方法對於崩塌災害的各種應用。

話雖如此，機器學習領域也時刻經歷著演算法更新與模型的變革。早期的演算法如羅吉斯迴歸（Logistic regression, LR）（Verhulst, 1845）、支持向量機（Support Vector Machine, SVM）（Boser 等, 1992）及決策樹（Decision Tree）（Friedman, 1977）等，在面對崩塌這種發生原因十分複雜的事件判別時，效能受限制，漸漸地較少人使用（Merghadi 等, 2020）。（圖 1-2）




圖 1-2 崩塌領域機器學習模型發展歷程（修改自 Tang 等, 2022）

近年來，深層神經網路模型，又稱深度學習（Deep Learning）的

快速發展下，其可學習性強及非線性迴歸的特性可以更有效的歸納不同因素對於崩塌發生的影響，提高崩塌潛勢模型的評估能力(Xiao 等，2018；Dao 等，2020；Huang 等，2020；Li 等，2022)。

三、機器學習及深度神經網路

「機器學習 (Machine Learning)」一詞最早由 IBM 員工 Samuel 於 1959 年提出，其代指了他們研發的一款透過人工反饋使機器學習分析聲納訊號的實驗性學習機。Mitchell (1997) 則在其著作 *Machine Learning* 中對於「機器學習」一詞給出定義：「A computer program is said to learn from experience E with respect to some class of tasks T and performance measure P, if its performance at tasks in T, as measured by P, improves with experience E.」，簡言之，機器學習旨在透過設計演算法使機器能夠從已知資料（包含問題及答案）中分析並找出規律，並應用在對未知資料的預測，以期許能夠取代人類基於推理獲取答案的過程。機器學習方法多數是基於大量統計理論構築而成，不過由於電腦運算能力及數據科學的進步，它相較傳統統計學能夠處理更複雜、更高維度的推理任務。

現今機器學習領域依據訓練過程中是否有給予「標籤 (Label)」而分為「監督式 (Supervised) 學習」及「非監督式 (Unsupervised) 學習」。所謂標籤類似於問題的解答，一筆訓練資料對應一個標籤，

於分類問題中為資料對應的類別、決策問題中則是資料對應的是非。

「監督式學習」即透過大量的資料及標籤組，經由演算法使模型歸納並建構出兩者之間的因果關係（讓模型面對某筆資料時，得以輸出相應的標籤）。常見的監督式學習有：羅吉斯迴歸（Logistic regression，LR）、貝氏分類器（Bayes Classifier）、支持向量機（Support Vector Machine，SVM）、隨機森林（Random Forest，RF）、類神經網路（Artificial Neural Network，ANN）等，並在近代崩塌研究中被廣泛使用（Chang 等，2019；Dou 等，2019；Dao 等，2020；Pham 等，2022；Sun 等，2021；Li 等，2021；Zhou 等，2021；Qin 等，2022；Aslam 等，2023）。而「非監督式學習」則是不給予標籤，而是使用演算法將資料歸納分類或是分析資料的結構，常用於對資料有一定的理解時，解釋過於複雜的資料。常見的非監督式學習有：主成分分析（Principal Component Analysis，PCA）、潛在語義分析（Latent Semantic Analysis）、k-means 聚類（k-means Clustering）、高斯混合分布（Gaussian Mixture Distribution）等（秋庭伸也等，2021）。

而針對崩塌潛勢的分析，屬於監督式學習的範疇，而在多數的研究中，隨機森林模型及類神經網路模型被認為在這項任務中有較佳的表現。隨機森林模型憑藉其大量的決策樹及不同決策樹之間投票的評估算法，得以在複雜的問題中進行有效決策，並且由於演算法特性，

它具有較快速的訓練過程及解釋性佳等優點；而類神經網路模型則得益於多層次、網路式的架構，有大量的參數可以擬合並評估各種資料組合，並且受近年來蓬勃發展的各種網路架構及優化方法，以及電腦運算能力的增強，提供高層數「深度學習」實用化的優勢，雖然計算量較大使訓練成本較高、並且不具可解釋性，但依舊憑藉其更佳的學習表現及多樣化的運用場景而愈發受學者們青睞（Bui 等，2020）。

「類神經網路模型」及「多層感知器」有著近 70 年的發展歷史，大致發展歷程如下：

（一）早期概念：

McCulloch 與 Pitts (1943) 提出的神經元模型，他們使用「閾值」及「演算法」的概念將生物神經元的運作過程轉化為數學模型。

（二）早期發展：

Rosenblatt (1958) 提出了「感知器 (perceptron)」的概念並運用於二元分類問題，它基本建構了現今廣受運用於評估模型訓練效果的損失函數 (Loss function) 及使用梯度下降法 (gradient descent) 尋求良好模型表現的基礎框架。

（三）冬眠期：

蓬勃發展的感知器因 Minsky 與 Papert (1972) 提出其無法處理複雜問題及當年計算機運算效能無法支持等缺點而逐漸淡出機器學

習相關領域。

(四) 機器學習文藝復興

Werbos (1982) 首次應用「反向傳播演算法 (Backpropagation)」於高層次的感知器模型，使快速及有效率的調整模型權重化為可能，因而類神經網路模型又一次進入大眾視野。

(五) 卷積神經網路及遞迴神經網路

1990 年代，LeCun 等 (1989) 的卷積神經網路 (CNN) 及 Rumelhart 等 (1986) 的遞迴神經網路 (RNN) 在基礎的多層次神經網路模型加入了多樣化的架構，分別在圖像識別任務及語言建模及時間序列預測問題上得到良好的表現，並且引領了一系列以此兩者為基礎演化而成的大型模型。

(六) 深度學習、強化學習、對抗式生成網路

隨著 2000 年後電腦性能及 GPU 發展衍伸出的並行計算優勢，加上演算法架構的優化 (Hochreiter, 1991)，神經網路模型得以建構得越來越深、參數量呈指數級增長，越來越多的大型模型如雨後春筍般出現，在各式各樣的領域及任務取得更好的表現，而這種深層次的神經網路模型也逐漸被稱做「深度學習 (Deep Learning)」(LeCun, 2016)。並且透過在優良模型上運用強化學習 (Reinforcement learning) (Sutton 與 Barto, 2020)、對抗式生成網路 (Generative Adversarial Network,

GAN) (Goodfellow 等, 2014) 等手段, 使模型得以在各種新的任務和情境被使用。

綜合來說, 神經網路模型依托於其神經元及神經網路層的架構, 以前向傳播和反向傳播為基礎概念, 透過長時間的演變及各式新型算法及模型架構的出現, 可以學習和優化模型以處理各種複雜任務, 使得其在大型數據集及具高維特徵的任務中相較算法已無明顯進步空間的隨機森林模型有著更亮眼的表現; 並且因為數學基礎的特性, 與隨機森林模型是非分明的分類方法不同, 它能夠輸出不同分類的機率分布而在分類任務中有較大的使用彈性。

儘管神經網路模型相應需要更大量的運算資源而受到一定限制, 不過在 2023 年的今天, 受惠於遊戲產業及 AI 人工智慧的飛速發展, 輝達 (Nvidia Corporation) 及超微 (Advanced Micro Devices, AMD) 兩大顯示卡生產商的競爭下, 普通的消費級顯示卡的運算能力對於中小型深度神經網路模型的訓練已經足夠, 遑論工作站及專業級顯示卡, 更有甚者, 雲端工作站的發展讓資源有限的研究者也可以透過租用的方式獲取高算力的運算平台。因此, 為了對崩塌事件的發生有更加優秀的評估成果, 適合使用神經網路模型架構建置崩塌潛勢評估模型。

四、機器學習模型差異

在崩塌潛勢地圖模型的訓練過程中，現實中崩塌案例的範圍往往是不固定的，以固定的網格去分割訓練範圍可能會與現實有所差異，Arnone 等（2016）及 Huang 等（2021）便研究過不同的圈繪方式及網格解析度對訓練結果的影響，發現不佳的圈繪方法會使得空間資訊消失而降低模型的評估能力。並且，相鄰的崩塌事件可能也具有一定的相關性，我們必須考量它們互相誘發的可能。幸而受惠於影像辨識及語義分割模型等領域的發展，卷積神經網路（Convolutional Neural Network，CNN）及循環神經網路（Recurrent Neural Network，RNN）為基礎框架的深度神經網路模型蓬勃發展（圖 1- 3），它們可以透過設置卷積窗等方式提取局部的空間特徵，有效降低了具有連續性及空間相關性的致崩因子資訊消失的問題（Qin 等，2022）（圖 1- 3），但是受限於卷積窗及循環窗大小需透過人工設定，在面對規模差異較大的崩塌區域時，如何去選取適合的卷積窗及循環窗大小往往需要透過試誤法來獲得，並且可能受不同的訓練樣本有較大差異（Yi 等，2020），且由於演算法的邏輯架構，其無法並行運算的缺點會影響模型建置的效率（Vaswani 等，2017）。




圖 1-3 卷積神經網路模型 (Qin 等人, 2022)

而 Vaswani 等 (2017) 在自然語言轉譯領域發表的〈Attention Is All You Need〉，又稱為 Transformer 模型 (圖 1-4)，引領了一股新的風潮，他們使用自注意力機制 (Self-attention) 演算法有效的將序列轉序列 (Sequence to sequence) 問題中的 Sequence 進行全局相關性計算，讓 Sequence 中每一個物件都不再是獨立，而是與其餘物件有著千絲萬縷的關係，並且由於可並行運算的優點使得模型訓練效率有巨幅的提升，這對於自然語言轉譯是謂劃時代的進步，基於 Transformer 架構的模型也如雨後春筍般大量發展。




圖 1-4 Transformer 模型架構 (Vaswani 等，2017)

但是，自注意力機制適用但卻並不局限於自然語言轉譯領域，設想若將崩塌潛勢地圖的訓練區域進行適當的網格分割，展平後也可以視作一個 Sequence，透過自注意力機制便可以計算空間上不同網格之間的相關性，這對於幫助機器理解空間上不同崩塌事件之間的交互關係有著極大的幫助，並且網格切分及崩塌圈繪方式也不再是問題，因為即使在切分的過程將同一崩塌案例分割成不同網格，自注意力機制也能計算出其高度相關，使其在深度神經網路訓練時能被視為同一案例進行學習。

五、特徵值選擇差異

崩塌是一複雜的複合式事件類型，可能受到地文因子（地形、坡度、地質等）及人為因子（道路、建築開發等）和誘發因子（降水、地震等）影響，在某些特定條件下發生崩塌。

在前人研究中（Sun 等，2021；Zhou 等，2021；Aslam 等，2023），鑒於分析資料的取得及使用上的方便程度，訓練崩塌潛勢模型的資料多以來自數值高程模型計算的特徵，如坡度、坡向、地形曲度、濕度分布指數（Topographic Wetness Index，TWI）為主，輔以地質圖所得之地層、斷層、褶皺等分布資訊，加上基於衛星影像的常態化差異植生指標（NDVI）、常態化差異建地指標（NDBI）等資料，配上由行政組織取得的道路分布及氣象組織獲取的降水資料等。溫振宇（2005）統計了 1996–2005 年多篇崩塌潛勢研究相關的文章中使用的特徵，如圖 1-5。




圖 1-5 崩塌評估模型使用特徵比例圖（改寫自溫振宇，2005）

若是從宏觀角度思考，我們其實可以把崩塌的發生視作廣範圍地形的「均夷作用」，地形整體朝向平坦、穩定發展。但是這樣的作用並非一朝一夕，其演育的時間即使在台灣這樣風化、侵蝕極為快速的地區之於人類生命也可能是十分長久的。因此，為了保障人身安全，需聚焦至崩塌區域本身，一次崩塌的發生，可能使得崩塌區局部的地

質力學趨於穩定，但是不可忽視幾項隨之而來的問題：1.冠部及側崩崖失去下邊坡支撐；2.崩塌塊體經過滑動區造成的地表裸露導致失去植被及雨水易入滲；3.堆積區大量囤積鬆散的材料。在前人文獻中也對此有所論述，Lin 等（2013）及李錫堤等（2009）提到：歷史崩塌災害可能導致坡面堆積大量崩積物，即使植生復育後也有可能在臨界情況下再次發生崩塌。事實上，在工程實務上我們也隨處可見邊坡因崩塌發生而進行鋪漿、打錨釘等整治方法，為的便是防止邊坡因大量雨水入滲造成二次崩塌。

歷史崩塌造成的影響，是前文所提及，前人文獻中大量被使用的特徵無法得知的。因此，在進行崩塌潛勢評估模型的建立時，應引入過往崩塌發生的年份及範圍，才能更全面且有效的使模型歸納出足以推測崩塌的規則。葉宗鑫（2022）在其研究中曾嘗試於隨機森林（Random Forest）演算法的模型中使用歷史崩塌作為訓練特徵，並在多次特徵權重分析中確認歷史崩塌常為前 15 重要之因子，而認為歷史崩塌之於隨機森林演算法的判斷有重要影響。

六、可解釋性機器學習模型

由於深度神經網路模型受限於模型的原理，使用者往往無法得知輸入的參數實際對輸出的參數產生怎樣的影響，稱為「黑盒子模型」、

「不可解釋性模型」，近年隨著應用上的發展，為提供實際上的佐證，事後解釋性模型（post-hoc interpretability）、內在可解釋性模型（intrinsic interpretability）的研究亦逐漸成為提升模型表現外另一個研究的方向（Yang 等，2021；Fang 等，2023；Youssef 等，2023）。

以下羅列 4 種本研究蒐整之可解釋性模型相關研究：

（一）TabNet

TabNet 為 Arik 等（2020）提出的深度學習架構，專為處理結構化表格資料設計。其核心由 sequential attention 機制構成，結合 feature transformer 與 decision step 架構，使模型能在每一步僅選擇部分關鍵特徵進行後續運算。TabNet 採用 sparsemax 函數來產生稀疏的特徵遮罩（feature masks），進一步提升可解釋性與泛化能力。

可解釋性來源於每個 decision step 中所產生的特徵遮罩，可用來追蹤各筆樣本在模型預測時所關注的變因。這類遮罩可視為類似於 SHAP value 的變數重要性指標，並能以全域或局部層級進行可視化。

Yingze 等（2024）也曾在中國萬州區比較了 TabNet 架構與傳統機器學習演算法於崩塌潛勢模型的差異，驗證了 TabNet 架構的可行性及良好結果

(二) GAMI-Net

GAMI-Net(Yang 等, 2021)為一種具可解釋性之神經網路架構，融合 Generalized Additive Models(GAM)與 pairwise interaction 模型。每個輸入特徵皆對應一個主效應子網路(subnetwork)，而經挑選的重要變因對則對應至交互作用子網路，所有子網路輸出最終線性加總，形成最終預測結果。

其可解釋性體現在主效應與交互項的可視化：一維的效應函數圖（如坡度及崩塌風險）與二維交互熱圖（如坡度與坡向之聯合作用）均可提供解釋。此外，模型設計中納入 sparsity、heredity 與 marginal clarity 等結構約束，強化了模型的識別性與簡潔性。

Fang 等(2023)測試了 GAMI-Net 架構於崩塌潛勢評估領域的可用性及與傳統機器學習模型的差異，發現此架構可以在維持模型評估效果的狀況下，提供良好的崩塌影響特徵解釋，並且與專家評估有相同的結果。

就整合性而言，GAMI-Net 的模型基礎算法與前期計畫中使用的算法類型稍有不同，需要調整後才能結合，但是此架構的視覺輸出結果較 TabNet 更加完整。

(三) SNN (Superposable Neural Network)

SNN 為 Youssef 等(2023)開發的崩塌潛勢架構，其核心理念為

將每一個輸入變數分配一個獨立的子網路進行建模，最後加總所有子網路之輸出以形成整體預測結果。此架構類似於 GAM 模型，但是以神經網路為基礎，非透過平滑曲線組合而成。

SNN 的可解釋性來自每個子網路對應之特徵組合，可視為該特徵對預測值的非線性貢獻關係。透過不同子網路之間的隔離及多重組合，可以了解不同特徵及特徵組合對於崩塌發生的最終貢獻。

與前期計畫模型整合性方面，SNN 於模型架構上可以與我們的模型結合，但是由於開發環境使用 MATLAB，與我們的開發環境不同，需要進一步的模型移轉才能使用。

(四) PiML

PiML (Sudjianto 等，2023) 為一個涵蓋模型開發、後續解釋與診斷分析的工具，整合了多種內在可解釋性模型(如 GAM、GAMI-Net、EBM) 與事後解釋性模型工具(如 SHAP、LIME、PDP)，並提供包括誤差熱點識別、穩健性測試、模型公平性分析等診斷功能。

PiML 的可解釋性並非來自單一模型結構，而是透過可視化與診斷模組統一包裝黑盒或玻璃盒模型的輸出。

對於本研究模型的整合潛力，因其除了內建的幾種模型架構外，解釋性多依賴事後解釋性方法，因此 PiML 更適合作為模型後處理框架，補足前期計畫模型缺乏診斷界面的缺點。

第二章 工作執行步驟與方法

第一節 工作執行步驟

本節展示了本研究的主要研究流程，介紹了整個研究的進行邏輯及資料流向等概念。圖 2-1 為本研究主要的執行架構，包含了崩塌資料的取得、崩塌特徵的製備；研究區域的選擇（圖 2-2）及各研究區域的特徵資料前處理；基於前期計畫模型的模型優化（圖 2-3）；不同種模型建立策略及後續的評估（圖 2-2）。




圖 2-1 研究流程




圖 2-2 六大地質構造分區 (Chen, 2016) 及模型建置策略：(a) 單一模型；(b) 多模型




圖 2-3 前期計畫模型及可解釋性優化策略：(a) 前期計畫 att_his 模型；(b) TabNet 架構

(Arik 等，2020)；(c) GAMI-Net 架構 (Yang 等，2021)

第二節 工作執行方法

一、研究區域選擇

台灣由於隸屬於板塊交界帶，造山運動的持續進行造就了多變的地形條件。而由於地狹人稠的關係，丘陵及山區的坡地開發十分常見，並且在河川周遭地形，如河階及沖積扇也時常是聚落群集的地方，這樣的地區往往可能是地質敏感區，導致崩塌事件時常發生並容易造成人身安全及經濟損失。

綜觀機器學習的原理及優點，若是將全台範圍納入訓練其實是最能讓神經網路學習到所有可能性的方法，但是這樣的訓練過程將曠日廢時，不符合效益及成本，在實用性上也大打折扣。

於前期計畫中，我們選擇旗山溪集水區作為訓練區域，並於隘寮溪集水區及谷關-天輪調整池集水區進行模型表現的測試及驗證。但是我們發現在不同區域中，因為地質條件及降水條件的差異，模型不可避免的會有效能上的損失。於本期計畫中，我們依據 Chen (2016) 對台灣不同地質構造區域的劃分(海岸平原、西部麓山帶、雪山山脈、大南澳片岩帶、廬山板岩帶及海岸山脈，後稱六大地質構造分區)，統計崩塌災害發生的歷史紀錄，並將兩型崩塌及同震型崩塌分開討論(圖 2-4、圖 2-5)，並分別於六大地質分區選擇崩塌頻率及嚴重性較高的區域作為示範集水區(圖 2-6)。

雨型崩塌熱力圖




圖 2-4 雨型崩塌熱力圖（統計自水保署 2004－2024 資料）

同震型崩塌熱力圖




圖 2-5 同震型崩塌熱力圖（統計自水保署 2004－2024 資料）

研究示範區域




圖 2-6 崩塌研究示範區域

二、地質條件及災害概況

引用自 Chen (2016)，以下分別概述六大地質構造分區的特性：

海岸平原，為西部麓山帶以西的沖積平原，處於褶皺－逆衝斷層帶（西部麓山帶）前緣斷層（frontal thrust）下盤的前陸盆地，屬於構造沉降的環境。晚更新世以來，因構造產生沉陷的盆地與平原，並持續地堆積大量的沉積物，近海的平原與盆地受末次最大冰期以來海面上升與構造影響，而堆積海相與陸相交替變化的沉積層。

西部麓山帶屬於造山帶的最西側山脈，是最年輕形成的山脈，北起新北市三芝－金山，南抵高雄市鳳山丘陵，介於西部海岸平原與雪山山脈之間，由一系列褶皺與逆衝斷層構成的褶皺－逆衝斷層帶（fold-and-thrust belt）。地層以中新統至更新統為主，僅在中北部局部出露漸新統。

雪山山脈與東側脊梁山脈之間以斷層為分界，與西部麓山帶則以斷距較大的逆衝斷層為界。此區以一系列波長從數百公尺至十數公里的中尺度背斜與向斜構成的褶皺串（fold train），巨視構造呈現一大型複背斜為主。地層以始新統與

漸新統的硬頁岩與厚層變質砂岩為主。

廬山板岩帶為脊梁山脈西斜面出露的板岩層，與西側的雪山山脈以一系列斷層為分界，與大南澳片岩帶以交角不整合接觸，部分的廬山板岩帶出露於大南澳片岩帶東側鄰近花東縱谷西側，與其呈不整合沉積或斷層接觸。此區域於巨視構造上呈現一大型複向斜，兩翼地層屬於始新統治漸新統，軸部出露中新統，主要由板岩及千枚岩之地層組成。

大南澳片岩帶，又稱「大南澳變質雜岩」與「大南澳基盤雜岩」，是台灣最老的地質構造單元，上覆地層為廬山板岩帶。中視構造普遍發育褶皺、劈理與斷層，巨視構造由北至南由數個複背斜與複向斜構成。地層組成可分為西側的太魯閣帶及東側的玉里帶，主要由綠色片岩相以上變質度的片岩及大理岩所構成，時代地層可能橫跨二疊系至中新統。

(一) 海岸山脈兩型－馬武溪集水區

馬武溪流域位於海岸山脈南段，地質構造複雜，地層自低至高主要包括港口石灰岩、都巒山層、八里灣層（泰源段）、蕃薯寮層。港口石灰岩多出露於溪流下游與谷地兩側，呈塊狀灰白色岩體。其上覆的都巒山層沿山谷邊坡廣泛分布，由火山岩與凝灰岩組成，常見於中上游區域。八里灣層（泰源段）則呈帶狀分布於流域中段，包含砂岩、泥岩互層，常構成谷坡。最高位的蕃薯寮層則大面積覆蓋在上游山區與支流周邊，厚層泥質沉積紀錄了盆地大量堆積的歷史。整體岩層自溪谷下段向上游依序出現，顯示火山底盤逐漸被後期濁流沉積物覆蓋的過程。

此區災害概況：2016 尼伯特颱風泰源南溪崩塌形成堰塞湖，威脅安全；2017 年卡努颱風邊坡破壞造成道路塌陷及土石淤積。

(二) 西部麓山帶兩型－旗山溪集水區

旗山溪流域位於西部麓山帶，出露地層繁多，包括玉山主山層、十八重溪層、南莊層、長枝坑層、紅花子層、三民頁層、糖恩山砂岩、鹽水坑頁岩、隘寮腳層、六龜層、嶺口礫岩、古亭坑層。上游山區以玉山主山層與十八重溪層為主，變質砂岩與板岩構成堅硬山體。南莊層與長枝坑層則分布於中游山坡，砂岩與深灰頁岩互層，常見於溪谷斷面。再向下游過渡到紅花子層與三民頁層，多呈現較厚的頁岩與砂

岩，顯示環境逐漸趨向沉積盆地。古亭坑層則出現在流域西緣低地，以厚層泥岩形成「惡地」地形。整體上，地層由東向西、由高山至平原依序分布，呈現出麓山帶典型的構造與沉積演替。

此區災害概況：2009 年 8 月的莫拉克颱風造成高雄甲仙、小林等山區發生大規模崩塌與土石流；2016 年 9 月受梅姬颱風帶來之豪雨影響，旗山區後厝巷上方邊坡發生沖蝕。

(三) 雪山山脈雨型－大安溪集水區

大安溪流域地層由西到東分布為，白冷層、巴陵層、汶水層、碧靈頁岩與石底層南北方向互層、南莊層、卓蘭層、紅土台地堆積層，大安溪主流流經區域皆有沖積層分布。白冷層：厚層石英岩質砂岩與長石質砂岩，夾薄互層。巴陵層：硬頁岩與板岩為主。汶水層：砂岩與頁岩互層。碧靈頁岩：頁岩夾砂岩。石底層：塊狀砂岩，白砂岩，砂岩及頁岩互層，含煤層。南莊層：砂岩及頁岩互層，含煤層。卓蘭層：砂岩、泥岩及頁岩互層。紅土台地堆積層：紅土，紅壤化之礫石，砂，砂及粉砂之透鏡體。

白冷層中有大量褶皺分布，由西向東為火石山複向斜、馬陵複背斜、上谷關複向斜、谷關複背斜、麗陽複向斜、榛山背斜。萬歲山斷層是巴陵層與白冷層的分界。巴陵層與卓蘭層之間有大量斷層分布，大量斷層使出露地表的地層分布破碎。

此區災害概況：2006 年 0604 豪雨崩塌造成 13 棟房舍受損及果園損失；2009 年 8 月的莫拉克颱風造成和平鄉達觀村屋損。

(四) 廬山板岩帶雨型－荖濃溪集水區

荖濃溪位於高屏溪主流上游，大致呈東北西南走向。地層由東向西分布為，畢祿山層、大禹嶺層、潮州層、長枝坑層夾有糖恩山砂岩。畢祿山層：板岩為主間夾變質砂岩，夾有變質火成岩透鏡體。大禹嶺層：板岩、千枚岩及變質砂岩。潮州層：硬頁岩或板岩間夾透鏡狀砂岩體。長枝坑層：砂岩及頁岩互層。糖恩山砂岩：厚層砂岩和泥質砂岩。

大禹嶺層中有南北走向的丹大山複向斜。畢祿山層與潮州層之間的分界為南北走向的唯金溪斷層。大禹嶺層位於潮州層北方，分界為新關斷層。荖濃溪溪谷則有土壟灣斷層通過。長枝坑層與糖恩山砂岩的分界為高中斷層。

此區災害概況：2009 年 8 月的莫拉克颱風六龜鄉新發村新開部落大規模崩塌；2024 年凱米颱風桃源區勤和里發生土石流衝入民宅。

(五) 大南澳片岩帶雨型及同震型－立霧溪集水區

立霧溪集水區地層由西至東分布大致為，大禹嶺層、黑岩山層、碧綠層與白楊片岩互層、谷園片岩與白楊片岩互層、谷園片岩與天長大理岩互層、九曲大理岩中夾有得克利片麻岩，最東側為沖積層。大

禹嶺層：板岩、千枚岩及變質砂岩組。黑岩山層：由板岩、千枚岩、變質砂岩及變質石灰岩。碧綠層：千枚岩、變質砂岩及變質燧石組成。白楊片岩：綠色片岩、矽質片岩、層狀大理岩。谷園片岩：千枚岩、雲母片岩、石英雲母片岩。天長大理岩：透鏡狀大理岩體。九曲大理岩：層狀大理岩。得克利片麻岩：片麻岩及花崗片麻岩。

碧綠層與白楊片岩互層之間有數組褶皺。谷園片岩與白楊片岩互層中有北北東走向的洛韶斷層與狄山斷層通過。

此區災害概況：2022 年多起崩塌事件掩埋道路及隧道；2023 年杜蘇芮颱風邊坡破壞掩埋道路；2018 年 0206 地震同震崩塌；2019 年 0418 地震同震崩塌；2024 年 0403 地震同震崩塌。

(六) 海岸山脈同震型－水璉沿岸集水區

水璉沿海地區展現海岸山脈西麓多層構造，地層排列依序為八里灣層（含水璉段）、都巒山層、八里灣層通則、八里灣層泰源段、蕃薯寮層。八里灣層水璉段多出露於近海岸低地，岩性以礫岩為主。向內陸過渡至都巒山層，沿山坡零星分布，露頭常夾帶火山岩特徵。其後八里灣層及泰源段主要出現在丘陵與溪谷地帶，頁岩與砂岩互層，記錄了沉積環境的變化。最上層的蕃薯寮層則覆蓋於更內陸的高處，厚層泥岩與砂質沉積顯示遠源物質持續供應。從沿岸到丘陵，再到內陸山地，層序呈現東西向漸進分布，反映盆地沉積由近岸向內陸推移

的歷史。

此區災害概況：2024 年 0403 花蓮地震同震崩塌。

(七) 西部麓山帶同震型－清水溪集水區

清水溪流域地質由桂竹林層（含關刀山砂岩段、大窩砂岩段、十六份頁岩段）、南莊層、長枝坑層、糖恩山砂岩、隘寮腳層、錦水頁岩、卓蘭層、頭嵙山層（火炎山段）、階地堆積層與沖積層所構成。桂竹林層多出露於上游丘陵，砂岩與頁岩互層支撐谷坡。中游兩岸可見南莊層與長枝坑層，厚層砂頁岩構成主要山體。下游則轉為隘寮腳層、錦水頁岩、卓蘭層與頭嵙山層，頁岩與泥岩為主，出露於河谷側壁。靠近平原地帶則有頭嵙山層的礫岩與砂岩，形成火炎山一帶特殊地貌。最年輕的階地堆積層與沖積層分布於現代河床與河階面，直接反映河川搬運沉積作用。整體地層由上游至下游呈現東西向梯次分布，顯示河谷沿線完整的地層演替。

本區災害概況：2013 年 0602 南投地震，發生同震崩塌。

(八) 雪山山脈同震型－陳有蘭溪集水區

陳有蘭溪為濁水溪的支流，呈南北走向。地層分布由西到東為佳陽層、玉山主山層、達見砂岩、十八重溪層、南莊層、深坑砂岩、桂竹林層大窩砂岩段。佳陽層：板岩夾砂岩與粉砂岩薄層。玉山主山層：石英岩質砂岩、硬頁岩及其互層。達見砂岩：厚層部份礫石質砂岩、

硬頁岩及板岩。十八重溪層：板岩與薄層砂岩或粉砂岩互層。南莊層：砂岩及頁岩互層。深坑砂岩：厚砂岩及頁岩，含化石富集層。桂竹林層大窩砂岩段：泥質砂岩夾頁岩。

南莊層與深坑砂岩中有多組褶皺。陳有蘭溪谷中有陳有蘭溪斷層分布。

此區災害概況：2013 年 0323、0602 兩起地震造成多起同震崩塌。

(九) 廬山板岩帶同震型－美崙溪

美崙溪流域地質分布由西到東大致為九曲大理岩、谷園片岩、沖積層。九曲大理岩中有少量白楊片岩出露；谷園片岩東側夾有少量白楊片岩，西側美崙溪河谷有少量九曲大理岩出露；沖積層在美崙山則是由米崙礫岩組成。九曲大理岩：層狀大理岩。谷園片岩：千枚岩、雲母片岩、石英雲母片岩。

米崙礫岩西側有米崙斷層通過。

此區災害概況：2019 年 0418 地震同震崩塌；2024 年 0403 花蓮地震同震崩塌。

三、崩塌資料庫的建置

本研究中，利用過往的歷史崩塌事件作為機器學習模型的目標，訓練機器理解各項特徵如何組合會發生崩塌；同時在目標時段以前的歷史事件也會作為特徵用於訓練。因此，作為目標的崩塌資料庫品質直接決定了模型最終的評估能力，故在建置崩塌資料庫時的選擇十分重要。本章節將介紹崩塌資料的來源、驗證、及篩選。

(一) 崩塌資料來源

由於歷史崩塌事件經過時間的流逝，可能由於地形環境自然的演育及人為工程的整治等作為而不一定會在現今留存。因此，本研究選擇以歷年已建置之崩塌圖層資料為基準，進行後續處理。

前期計畫中，我們選擇了地礦中心的崩塌紀錄，不過面對到兩個問題：崩塌資料為整年度判釋結果，無法了解各雨場事件對崩塌災害之間的關係；資料紀錄僅記錄至 2015 年，沒有近年來的資料，無法保證面對近年來氣候變遷衝擊下的模型表現。感謝前期計畫各位審查委員意見，本期計畫我們選擇使用水保署之事件型崩塌目錄（2004 年 - 2024 年），此資料將崩塌事件明確界定至特定時間段及事件，透過將各崩塌事件對應各自的致災因素（包含降水、地震）進行訓練，以期能夠得到更加精確的崩塌潛勢評估模型。

(二) 崩塌資料處理

自水保署取得之事件型崩塌目錄原始為多邊形圖層(.shp 檔案)，本研究為增加運算效率及便於分析，將以上崩塌資料圖層另外透過空間資訊軟體(gdal 套件)再製為網格資料。

四、訓練特徵的選擇及前處理

本小節將介紹用於訓練機器學習模型的特徵來源及如何進行前處理。根據比對前人研究(Sun 等, 2021; Zhou 等, 2021; Aslam 等, 2023; 溫振宇, 2005)，在本研究中基於特徵取得途徑難易度及資料前處理方便性選用了幾種廣泛被使用且受專家認可適合進行崩塌評估的特徵：1. 地形特徵：高程、坡度、坡向、地形曲率、地形濕度指數(Topographic Wetness Index, TWI)。2. 降水特徵(雨型)：降水強度、最大 3 小時累計降水、最大 5 小時累計降水、最大 12 小時累計降水。3. 地質條件：地質組成、順向坡分布。4. 線狀構造距離：斷層距、褶皺距、道路距、河道距。5. 植被及開發：常態化差異植生指標(NDVI)、常態化差異建地指標(NDBI)、土地利用。6. 地震特徵(同震型)：地表加速度峰值(PGA)、地表速度峰值(PGV)、斷層深度。以上為基礎的訓練特徵，除此之外還會將事件前的歷史事件作為特徵。

由於在前文中提到：在神經網路架構的訓練模型中，以中尺度約 10 – 20 m 解析度的網格為單位進行訓練可以得到較佳的結果，且運算成本較能接受（Arnone 等，2016）。由於數值高程模型（Digital Elevation Model，DEM）及用於產製圖資的衛星影像解析度分別為 5 m 及 30 m 左右，考量到進行差距過大的重採樣可能產生資訊消失的問題，在本研究中選用了居中的 20 m 解析度網格作為基本單位進行訓練。以下章節中提到的網格化皆為「重採樣至 20 m」之操作。

（一）地形特徵

高程使用內政部提供之 5 米解析度 DEM，透過 SAGA9.7.1 中「Slope, aspect, curvature」函式，以「10 parameter 3rd order polygon (Florinsky 2009)」方法（Conrad 等，2015），單位為度（degree）進行運算。便可以獲得坡度、坡向、平面曲率（Plan curvature）、剖面曲率（Profile curvature）的圖資，經過網格化後便可以作為特徵使用。

另外，我們使用了 SAGA 9.7.1 的套件 Flow Accumulation (Top-Down)、Flow Width and Specific Catchment Area、Slope, Aspect, Curvature（Conrad 等，2015），並參考 Kopecký 等，（2021）的參數設定來計算代表了地形造成的溼度分布指數 Topographic Wetness Index，此指數的計算公式如下（式 1）（Böhner 與 Selige，2002）。

$$TWI_s = \ln\left(\frac{SCA_M}{\tan \beta}\right) \quad \text{式 1}$$

$$SCA_M = SCA_{max} \left(\frac{1}{15}\right)^{\beta \exp(15\beta)} \text{ for } SCA_M < SCA_{max} \left(\frac{1}{15}\right)^{\beta \exp(15\beta)} \quad \text{式 2}$$

式 1 中 TWI_s 代表特定 (specific) 集水區的溼度分布指數； SCA ($m^2 \cdot m^{-1}$) 代表特定集水面積，定義為每單位等高線寬度相應的排水面積， SCA_M 則是 SCA 的修正值； β 代表坡度。式 2 則是 SCA_M 的修正公式。其中 SCA_{max} 代表與某特定網格相鄰最大的 SCA 值； β 代表坡度。

需特別說明一點，崩塌的發生勢必會造成地形的變化，但由於本研究無法取得隨時間變化之詳細 DEM 資料，因此只能將地形相關特徵視作不隨時間變化，可能因此造成誤差。

(二) 降水特徵

在降水紀錄方面由於雨量站有紀錄缺失及空間分布不均勻等問題，在使用上相對不便。因此，本研究向臺灣氣候變遷推估資訊與調適知識平台 (<https://tccip.ncdr.nat.gov.tw/>) 申請「臺灣歷史氣候重建時資料 (TReAD) (2025)」作為歷史降水參考依據，此資料使用 WRF (Weather Research and Forecasting) 氣象模式，將歐洲中期天氣預報

中心(European Centre for Medium-Range Weather Forecasts, ECMWF) 產製的 ERA5 (ECMWF, 2017) 重分析資料進行動力降尺度, 獲得單位為 mm/hr 的 2 公里網格降雨資料 (TCCIP, 2025)。

為了讓模型了解雨場事件中的整個降雨歷程及降雨型態對於崩塌產生的影響, 我們計算了雨場事件的降雨強度, 並且為了呈現短延時強降雨及長延時降雨的差異, 另外計算了最大 3 小時累計降水、最大 5 小時累計降水及最大 12 小時累計降水。

由於平台所提供的原始資料為點格式, 本研究基於簡單克利金法, 以球形半變異模型架構為基礎, 搭配地形因子及水文守恒模型開發了客製化 Python 工具, 產製最接近現實狀態之插值結果。

(三) 地質條件

本研究使用之地質圖資料為「易淹水地區上游集水區地質調查及資料庫建置 (經濟部中央地質調查所, 2013)」發布的數化五萬分之一地質圖。此版本的地質圖相較較早版本有以下優點: 相鄰圖幅間不再因為調查計畫不同而有不吻合問題、填補了高山區域圖幅缺失、由於是數化的圖資, 透過讀取屬性表中不同屬性也能夠得知更多的資訊。

考量到台灣地層分類細緻, 常出現同年代、類似岩性的地層被劃為不同類別的情況, 因此本研究改以屬性中的「岩性及組成」作為劃

分依據，以提升模型空間通用性。而後將其進行網格化使用。

順向坡資料取自地礦中心地質雲平台之全臺順向坡分布圖，並經網格化處理後使用。

(四) 線狀構造距離

本研究仿效前人常用的線狀構造：斷層距、褶皺距、道路距、河道距。斷層及褶皺資料同(三)地質圖來源；而道路及河道取自交通部政府開放資料（交通部運輸研究所，2010）。

以上四種圖資皆為 Shapefile (.shp) 圖徽，為了理解離這些線狀構造不同距離對於崩塌行為造成的影響，參考前人研究(Sun 等，2021；Zhou 等，2021)，他們分別使用 100m 及 500m 為一單位劃分距離，由於 100m 的間距下可以有更清楚的空間解析度，因此本研究使用 QGIS 中的 Buffer 工具 (QGIS.org, 2022) 以線圖徽為中心，每 100m 為間距至 1500m 及以上共 16 類作為分類，並將其網格化後使用。

(五) 其他構造特徵

於前期計畫中，審查委員建議可以更多考量各線狀構造的的特性：如道路旁是否有道路施工、坡腳開挖等；河道旁是否有淘刷及側向侵蝕等；褶皺翼部是否有層間滑移導致的地質弱面；斷層的類型不同及斷層位態的影響。由於道路相關因素或是河道相關因素是極端區域化且較不易追蹤之資料，我們在廣範圍的統計評估中難以詳加考量。

而褶皺形成的特性，我們透過地質條件中的順向坡來納入考量，我們將全台順向坡圖層以有無分為兩類後網格化。

斷層方面，我們除了(三)的斷層資料以外，另外新增了自國家災害防救科技中心申請之台灣活動構造三維數值模型(陳宏宇, 2024)，其中收錄了 36 條活動斷層與學者研究結果認定之 16 條活動斷層中的部分斷層三維資料，透過更詳盡的斷層分布狀況，結合前人研究，我們可以對斷層破碎帶有更清楚的認知，有助於模型訓練過程中得到更全面斷層之於崩塌的影響。但是，鑒於前人及學界往往對於地震的震源及斷層機制解有不同的見解，且部分地震可能為底滑面 (Decollement) 及其延伸之盲斷層，實難以界定地震事件真實的孕震斷層。因此，本研究暫以集水區內所有通過的斷層之距地表深度作為特徵，網格化後使用。

(六) 植被及開發

植被的覆蓋及開發程度對於崩塌是否發生有很大的影響 (Pacheco Quevedo 等, 2023; Shu 等, 2019)，為了瞭解崩塌發生前植被的覆蓋及開發程度，本研究使用 NDVI、NDBI 分別作為特徵。NDVI 及 NDBI 的原理為：衛星在某些波段於不同介面上反射的回波有所差異 (圖 2- 7)，透過公式計算便可以得知特定介面於空間上的分布情形 (Crippe, 1990; Zha 等, 2003)。




圖 2-7 不同介面下不同波段之反射強度 (Serra-Ruiz 等，2019)

本研究在實務上 NDVI 及 NDBI 的產製方法為使用 Landsat 8、Landsat 7、Sentinel-2 三種衛星 (2004-2024 年時間跨度太大)，運用 Google Earth Engine 進行影像篩選、校正後，依照以下式 3、式 4 使用不同衛星中相對應的波段計算，並將結果網格化便可以使用。

$$\text{NDVI} = (\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red}) \quad \text{式 3}$$

$$\text{NDBI} = (\text{SWIR} - \text{NIR}) / (\text{SWIR} + \text{NIR}) \quad \text{式 4}$$

式 3、式 4 中 NIR 為近紅外線 (Near infrared)；SWIR 為短波紅外線 (Short-wave infrared)；Red 為紅光。

除此之外，我們向國土測繪中心申請了 108、109 年度國土利用現況調查成果，此資料記錄了地表實際的土地利用種類，與 NDVI 及

NDBI相較有更明確的人類活動影響資料，原始資料為 Shapefile(.shp)

圖徵，進行網格化後使用。

(七) 地震特徵（同震型）

本期計畫中，將兩型崩塌與同震型崩塌分開討論，在同震型崩塌中，我們自中央氣象署地震測報中心取得各崩塌事件對應之地震紀錄。PGA、PGV 等資訊則可以用於計算崩塌發生區實際接受到的能量強度，但是由於早期的紀錄中缺乏完整的 PGV 資料，因此我們僅使用三維 PGA 資料（PGA_V、PGA_EW、PGA_NS）作為破裂能量特徵原始資料為強震站資料，為求資料連續性，我們透過 ArcGIS 中的 Kriging 函數進行插值運算。將以上的資料網格化後進行使用。

(八) 特徵共線性探討

在多元迴歸分析中，若是自變數之間存在相關性，可能會產生共線性（collinearity）的問題（簡單舉例：在進行崩塌的評估時，假設自變數有降雨量、地質組成、地下水位面深度和地形等，若只想考慮地下水位面深度的影響，由於地下水位面往往與降雨量、地質組成和地形密不可分，因此可能產生矛盾的狀況）。

共線性問題在進行統計迴歸時主要有以下影響：係數估計的不穩定性、係數估計的不可靠性（係數的標準誤差增加）、解釋變數效果

的困難。因此，在多元迴歸分析中，為了避免上述問題的發生，選擇及篩選適當的自變數是提升表現的重要工作。

儘管神經網路模型並非純粹的線性迴歸模型，其中所含的係數量級也非傳統的統計模型所能比擬，所受到的影響相對較小，但是共線性問題可能也會對模型產生一定的影響（O'brien，2007）。因此，在本研究中使用變異數膨脹因子（Variance Inflation Factor, VIF）（式 5）作為討論共線性問題的參考標準。當 VIF 的值越大，則代表共線性問題越顯著（Rogerson，2001），後續結果討論中將結合 VIF 數值及模型特徵重要性結果進行討論。

$$VIF_i = \frac{1}{1 - R_i^2} \quad \text{式 5}$$

式 5 中 VIF_i 為第 i 項參數的 VIF 值， R_i^2 則是第 i 項參數的決定係數（Coefficient of determination）。

（九）特徵重要性探討

前期計畫中，我們採用了隨機森林方法對同一組訓練資料進行訓練的方式來討論特徵的重要性，是一種間接的方法。本期計畫中，我們選擇了四種可解釋性模型架構：TabNet（Arik 等，2019）、GAMINet（Yang 等，2020）、SSN（Youssef 等，2023）及 PiML（Sudjianto

等，2023）進行測試。經過測試及比較後，從開源程度、可解釋性原理及實作使用難易度考量，我們認為最適合的方法為 TabNet，不過在結合前期計畫中的模型時出現一個問題，TabNet 的可解釋性來源於其架構中自輸入到輸出端皆線性可微的設計，但是我們原本的模型，無論是 mlp_his 或是 att_his 都並非線性可微的架構，因此我們無法強行結合兩者，這樣會破壞 TabNet 的理論基礎。因此我們提出兩種方案：第一種是直接使用 TabNet 原生架構，搭配歷史崩塌資料作為特徵的資料集進行訓練。第二種是使用我們前期計劃產製的模型進行訓練，並使用事後可解釋性工具 SHAP (SHapley Additive exPlanations) (Lundberg & Lee, 2017) 針對模型判釋過程進行解釋。

五、神經網路原理及模型設計邏輯

(一) 神經網路原理

神經網路（Neural Network）（圖 2-8）是一種受啟發於人類大腦運作方式的機器學習模型，用於處理各種複雜的任務，如迴歸問題、分類問題、圖像辨識、語音辨識、自然語言處理等。以下將概述神經網路的基本架構和相關理論說明：




圖 2-8 神經網路模型示意圖（Glosser.ca，2013）

1. 神經元（Neuron）：

神經網路的基本元素是神經元，它是在模擬人類大腦中的神經元。

與人腦中神經元的樹突（Dendrite）會接收來自於連結的其他神經元

傳遞的神經傳導物質一般，每個神經元會自上一層的神經元接收多個輸入並對這些輸入進行權重加權，然後通過激活函數進行非線性轉換，最終生成一個輸出傳遞給下一個神經元。

2. 神經網路層 (Layers)：

神經網路通常由多個層組成，每一層包含一個或多個神經元。最簡易的三層神經網路模型包括輸入層、隱藏層和輸出層。輸入層用於接受原始數據，輸出層用於生成最終的預測結果，而隱藏層則通過訓練及學習獲得處理和提取數據特徵的能力。




3. 權重和偏差 (Weights and Biases)：

神經元之間的連接具有權重 (Weights)，這些權重決定了每個輸入在神經元中的重要性。這與人類神經元樹突上的受體 (Receptors) 類似，決定了受到不同來源神經傳導物質的影響程度。此外，對應神經細胞動作電位 (Action potential) 的閾值 (threshold)，每個神經元還有一個偏差 (Bias)，這個偏差可以調整神經元的活性，以更好地擬合數據。

4. 激發函數 (Activation function)：

激發函數用於引入非線性性質，允許神經網路學習複雜的關係，是深度學習發展重要的存在。常見的激發函數包括 Sigmoid、Tanh、ReLU (Rectified Linear Unit) 等，如表 2- 1。

表 2-1 常見激發函數說明

Activation function	公式	函數表現
Sigmoid	$S(x) = \frac{1}{1 + e^{-x}}$	
Tanh	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
ReLU	$ReLU(x) = \max(0, x)$	

5. 前向傳播 (Forward Propagation) :

當數據通過神經網路的不同層時，每一層的神經元將計算其輸出並將其傳遞給下一層，這個過程被稱為前向傳播，最終生成一個預測。透過前述的說明，我們可以想像在每一個神經元前向傳播的過程都是

如式 6 一般進行。同時考慮一層中每個神經元的並行運算，我們可以將其以矩陣方式表達，如式 7。在高層次、每一層神經元數量很多的情況下，整個神經網路將會有數以萬計以上的參數會隨著訓練變動，在大量訓練資料的幫助下，將可以處理十分複雜的任務。

$$a_p^{k+1} = A(w_0^p a_0^k + w_1^p a_1^k + w_2^p a_2^k + \cdots + w_n^p a_n^k + b_p) \quad \text{式 6}$$

$$\begin{bmatrix} a_0^{k+1} \\ a_1^{k+1} \\ \vdots \\ a_p^{k+1} \end{bmatrix} = A \left(\begin{bmatrix} w_0^0 & w_1^0 & \cdots & w_n^0 \\ w_0^1 & w_1^1 & \cdots & w_n^1 \\ \vdots & \vdots & \ddots & \vdots \\ w_0^p & w_1^p & \cdots & w_n^p \end{bmatrix} \begin{bmatrix} a_0^k \\ a_1^k \\ \vdots \\ a_n^k \end{bmatrix} + \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_p \end{bmatrix} \right) \quad \text{式 7}$$

式中 a 為神經元的數值、w 是權重、b 是偏差、A 是激發函數，k 代表第幾層、p 代表當前層神經元數，而 n 代表前一層中第幾個神經元。式中 w 及 b 便是隨著訓練數據的不同漸漸被訓練而改變的值，通過訓練它們將得以擬合至一定值，使得輸入的資料可以對應正確的輸出。

6. 損失函數 (Loss function)：

由於模型初始的權重跟偏差肯定無法有很好的預測表現，因此需要使用損失函數。損失函數是用以衡量模型的預測與實際值之間的誤差。訓練的目標便是最小化損失函數的值，以獲得最佳的模型。常見

的損失函數有：均方誤差（Mean Square Error，MSE）（式 8）、交叉熵（Cross-entropy）（式 9）等。

$$MSE = \frac{1}{n} \sum (y - \hat{y})^2 \quad \text{式 8}$$

$$H(p, q) = - \sum_x p(x) \log (q(x)) \quad \text{式 9}$$

式 8 中 n 代表資料筆數； y 代表一筆資料； $\hat{y}$ 代表所有資料的平均值。式 9 中 $H(p, q)$ 代表兩個機率分布的交叉熵，而 p 和 q 則代表對於同一事件的兩個機率分布。

7. 反向傳播（Backpropagation）：

反向傳播是訓練神經網路的關鍵過程。通過比較網路的預測輸出和實際值之間的損失，以式 10 到式 13 的偏微分公式(Nielsen, 2015)為基礎，反向傳播算法得以通過梯度下降（Gradient decent）、輔以優化算法逐層迭代來調整權重和偏差，並最小化損失。

$$\delta^L = \nabla_a C \odot \sigma'(z^L) \quad \text{式 10}$$

$$\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l) \quad \text{式 11}$$

$$\frac{\partial C}{\partial b_j^l} = \delta_j^l \quad \text{式 12}$$

$$\frac{\partial C}{\partial w_{jk}^l} = a_k^{l-1} \delta_j^l \quad \text{式 13}$$

式 10 到式 13 中， δ 為某一神經元的損失； C 為神經元輸出層的損失； σ 為激發函數； a 為神經元的值； z 為神經元的值 a 經過激發函數後的值； w 為權重； b 為偏差。而上下標中， L 代表輸出層； l 為神經網路的層數； j 為第 l 層的神經元數； k 為第 $l-1$ 層的神經元數。 $\odot$ 則為阿達瑪乘積 (Hadamard product)。這四式是透過微分方程對神經元損失及所有神經元中的影響因子進行評估的結果，詳細推導過程請參考 Nielsen (2015)。

8. 訓練和優化：

訓練神經網路的過程相當於利用反向傳播算法使神經網路中的所有權重和偏差組合能使損失位於最低點。考慮到損失函數可能有局部低點或是鞍點 (Saddle point)，如何有效的進行梯度下降是十分重要的過程。因此需要引入一些梯度下降優化算法，常見的優化器 (Optimizer) 包括隨機梯度下降 (Stochastic Gradient Descent, SGD)、Adam、RMSProp 等。

(二) 自注意力機制

了解神經網路模型的基本原理後，前期計畫中為建立空間相關性，使用了自注意力機制（Self-attention）進行解釋，下圖 2- 9a 及式 14 為整個自注意力機制的核心概念（改寫自 Vaswani 等，2017）。




圖 2-9 常見自注意力機制

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

式 14

於本期計畫中，我們首先嘗試了上期中表現最好的 att_his 模型，即使用自注意力機制的方法。但是發現了兩個問題點：首先，空間上的變異性，由於台灣多面環海，六大地質區皆有與海相鄰之處，特別是本次選擇的馬武溪、水璉沿岸等，我們在使用自注意力機制訓練的過程中由於資料的處理及空間上定位的需求，皆會自集水區邊界外擴一矩形進行資料製備及訓練，這使得模型在以上集水區訓練時會被海洋區域的網格影響到空間相關資訊，使得當模型運用在沒有海洋的區域時會有偏誤的現象。第二點是，因事件型崩塌案例在單一事件下崩塌面積占比很低，且為了學習到不同事件下的致災因子差異，我們的訓練、驗證及測試資料是自不同的事件中進行部分採樣後疊合的，在採樣的過程中便無法透過自注意力機制建立空間相關性（每一場事件僅有部分網格資料被用於建立資料集，空間上不連續）。鑒於上述兩個問題，我們只能捨棄 att_his 模型，轉而使用使用前期計畫中第二好的模型架構：mlp_his 作為基礎進行後續的工作。

(三) 模型設計邏輯

前期計畫中，最基本的目的是使用機器學習方法在大量數據中歸納出怎樣的特徵及組合會導致崩塌的發生，並且進一步了解兩個條件：

- 1.使用歷史崩塌事件作為特徵訓練的效果；
- 2.考量空間中相鄰網格間相關性的影響，共 4 種模型作為比較，如表 2-2 中的代號所示。

由前

期計畫中評估的結果顯示，att_his 及 mlp_his 模型具有良好的潛力，但透過前一小節及(九)特徵重要性中的說明，我們本期計畫將聚焦在 mlp_his 架構上進行延伸，並且針對 TabNet 原生模型進行討論。以下將解釋在研究各步驟的資料處理及模型設計邏輯（圖 2-10）。

首先，由於原始的資料都是空間上的某項特徵，因此多是二維的網格或圖徵檔案。本研究先將其轉化成一 20 m 網格劃分的資料格式（ $M \times N$ 個網格），每個網格帶有特徵本身的屬性，將 C 種不同特徵依空間對位疊合後，便會形成一個 (M, N, C) 的三階張量（tensor）。

下一步，我們將原始的三階張量在空間上平坦化（flatten）並標準化後取得二階張量 $((M \times N), C)$ 。

接下來，將每個網格單獨來看，可以得到一筆長度為 C （ C 種特徵）的一階張量，並且在訓練資料中可以知道每一個網格對應的實際值（定義為：發生崩塌=1；不發生崩塌=0）。將每個網格的資料依次通過全連接神經網路便可以訓練出一個檢視過 $M \times N$ 種特徵組合是否會發生崩塌並逼近實際的模型。

訓練完成後，單一模型中學習到的神經網路權重及各個神經元的閾值便可以在面對全新未知解答的特徵組合時給出一個 0 – 1 之間的數值，代表了其推測出來的崩塌潛勢。但是由於資料集建置過程中存在大量樣本下採樣的過程，單一模型可能因訓練資料產生偏誤，我們

於本期中在每一個訓練過程中都製備 5 組不同採樣方法之資料集及子模型，並將 5 個子模型的輸出結合產製出一集成式模型（ensemble model），再透過此集成式模型給出較無偏誤之評估結果。

根據本期計畫的目的，我們除了將新增的各項崩塌特徵加入至模型的訓練過程中，另外還有兩項目標：1. 解決模型於不同地質條件下的效能下降問題；2. 模型可解釋性缺乏的問題。為了達成這兩項目標，我們首先選擇了 TabNet 的架構於每個集水區訓練並比較（圖 2- 3）；而 mlp_his 架構的集成式模型則分為兩種訓練策略：將選定的各示範集水區合併作為一組資料進行單一大模型訓練（圖 2-2a），並與分別於各示範集水區訓練一個模型進行討論（圖 2- 2b）。

需要特別說明的是，在訓練過程中我們需要訓練集（更新模型）、驗證集（於訓練過程中提供驗證及調整）及測試集（模型完成後測試用）。因我們的崩塌資料庫為橫跨 20 年並有大量事件於其中，並且每個事件都有對應的降雨資料、地震資料，若切分資料集時從時間上去切分，可能會像前期計畫一樣過度關注某種條件下的崩塌案例而形成模型偏好。因此，我們是針對每一場事件進行正負資料的統計，隨機取樣後將 70%作為訓練資料下並採樣至正負資料 1:10，驗證資料及測試資料為剩下 30%各半，維持原本正負比，並將所有事件各自之訓練資料、驗證資料及測試資料進行疊合，以確保最終資料集中包含所

有崩塌案例的情況，且驗證、測試時不會與訓練資料重複。

表 2-2 模型代號表

	不考量歷史崩塌	考量歷史崩塌
不考量空間關係	mlp_no_his	mlp_his
考量空間關係	att_no_his	att_his




圖 2-10 模型設計邏輯及資料流概念圖

六、模型架構說明

(一) TabNet 原理

逐樣本的特徵選擇機制：傳統深度模型（如多層感知機）往往對所有輸入特徵一視同仁地處理，而 TabNet 通過順序注意力機制在每個決策步為每個輸入動態選取最相關的特徵子集。這種特徵選擇使模型能針對不同樣本採用不同的「關注特徵」，充分利用模型容量於當下樣本最重要的特徵上。

模仿樹模型的歸納偏置與解釋性：TabNet 的順序決策架構靈感來自決策樹的分割過程：每個決策步只考慮部分特徵，類似樹模型中在節點處基於一個特徵作分裂。並且透過架構中的稀疏特徵遮罩，讓每一步的決策更接近人類可理解的規則。

局部與全局可解釋性：TabNet 提供了兩種層級的解釋能力：第一，局部可解釋性：針對單一樣本，我們可以檢視其在各決策步的遮罩，從中了解模型對此樣本逐步使用了哪些特徵、順序如何。例如，對某一給定樣本，可視化其遮罩矩陣，即可看出模型在不同階段關注點的轉移。第二，全局可解釋性：除了逐案例分析外，TabNet 也能評估整體模型對各特徵的偏好度。藉由對所有樣本的遮罩進行統計便可以導出每個特徵對模型決策的全局重要性分數。

(二) SHAP 分析

SHAP (SHapley Additive exPlanations) 方法 (Lundberg & Lee, 2017) 的理論基礎是合作博弈論中的 Shapley 值。在模型解釋情境下，每個特徵被視為博弈中的玩家，而模型的預測輸出（相對於一個基準值）被視為總體「收益」。SHAP 將每個特徵的重要性值定義為該特徵對模型預測所做貢獻的 Shapley 值。也就是說，計算每個特徵在所有可能的特徵子集情況下「加入該特徵」所引起的預測變化，然後取加權平均。這等價於在所有可能的特徵排列中，求出該特徵對預測的平均邊際貢獻。基於經典博弈論，Shapley 值具有唯一性和公平性：滿足一組合理公正原則的分配方案只有一種，即 Shapley 值。SHAP 正是利用了這一點，在模型解釋中採用 Shapley 值來分配各特徵對單一預測結果的貢獻。如此一來，SHAP 為每個樣本的模型預測產生一組唯一確定的特徵貢獻值。

七、評估方法

在二元分類問題中，最常見的是使用根據推測及實際結果所繪製的混淆矩陣（表 2-3）及其衍生出的指標來了解模型的表現。

表 2-3 混淆矩陣

混淆矩陣		推測	
		未崩	崩塌
真實	未崩	TN	FP
	崩塌	FN	TP

本研究中，由於分析的區域及事件場次較多，考量到篇幅，主要以 AUC 數值進行模型表現之評估。

在評斷模型評估能力時，時常使用 ROC (Receiver Operating Characteristic) 曲線來評估 (圖 2-11)，ROC 是一種座標式的分析圖表，用於選擇最佳的分類模型或者在同一模型中設定最佳閾值。ROC 以 FPR (False Positive Rate) (式 15) 為橫坐標，TPR (True Positive Rate) (式 16) 為縱座標。ROC 的呈現如圖 26 所示，不同分類模型在測試集上會有不同的 ROC 曲線分布，當曲線愈趨近左上角，則模型評估能力相對越佳，反之，若模型接近圖中虛線，則代表模型幾乎不具備分類能力。因此，在使用 ROC 分析時，會以 AUC (Area Under Curve)，即曲線右下角區域的面積為參考，AUC 介於 0 - 1 之間，當 AUC 越大則模型表現越佳。

$$FPR = \frac{FP}{FP + TN} \quad \text{式 15}$$

$$TPR = \frac{TP}{TP + FN} \quad \text{式 16}$$




圖 2- 11 ROC 曲線示意圖

第三章 工作進度與交付項目

第一節 計畫預定進度及甘特圖

本計畫之甘特圖如圖 3-1 所示。並另依各項目之工作內容、工作量比例、本計畫管考事項，分配作業日程及預定進度，以利管理本計畫之執行進度，詳表 3-1。

「執行成果報告」依本計畫管考事項持續辦理，重要檢核時間點為：(1) 114 年 7 月 17 日前提送期中成果報告書；(2) 114 年 11 月 13 日前提送期末成果報告書；(3) 114 年 12 月 31 日前提送成果報告書、相關資料、結束會計報告。




圖 3-1 計畫進度甘特圖

表 3-1 計畫預定進度表

重要工作項目	工作比重%	預定進度	114			
			1-3 月	4-6 月	7-9 月	10-12 月
相關文獻收集及整理	10%	工作量或內容	相關論文收集	相關論文收集		
		累計百分比	50	100	100	100
研究區域歷史崩塌資料更新	10%	工作量或內容	研究區域規劃	歷史崩塌收集及處理		
		累計百分比	20	100	100	100
崩塌模型訓練特徵更新	10%	工作量或內容	研究區域規劃	訓練特徵收集及處理	訓練特徵收集及處理	
		累計百分比	20	60	100	100
建立內部可解釋性模型架構	15%	工作量或內容		訓練模型	比較並分析結果	
		累計百分比	0	60	100	100
建立多元致災因素決策參考	15%	工作量或內容		建立架構	比較並分析結果	比較並分析結果
		累計百分比	0	50	75	100
綜合評估單一大模型及多模型於不同地質區預測表現	20%	工作量或內容		建立單一大模型	建立多模型	綜合評估
		累計百分比	0	35	70	100
優化模型並建立次年度 6 大地質區示範案例	20%	工作量或內容	優化模型	優化模型	優化模型	優化模型並建立全台崩塌潛勢
		累計百分比	25	50	75	100
累計總進度	百分比		14	59.5	82.25	100

第二節 計畫交付項目

表 3-2 為本計畫預定工作項目及相關計畫交付項目表。

表 3-2 計畫交付項目表

重要工作 項目	工作數量				預算金額（千元）		實施地點	備 註
	單位	全程計畫 目標 114 1 月-12 月	至 113 年度 累計成果	本年度 預定目 標	水保署經 費	其他配合 經費		
相關文獻 收集及整 理	式	1	0	1			台北市	
研究區域 歷史崩塌 資料更新	式	1	0	1			台北市、高雄市、 屏東縣、宜蘭縣、 台東縣	
崩塌模型 訓練特徵 更新	式	1	0	1			台北市、高雄市、 屏東縣、宜蘭縣、 台東縣	
建立內部 可解釋性 模型架構	式	1	0	1			台北市	
建立多元 致災因素 決策參考	式	1	0	1			台北市	
綜合評估 單一大模 型及多模 型於不同 地質區預 測表現	式	1	0	1			台北市	
優化模型 並建立次 年度 6 大 地質區示 範案例	式	1	0	1			台北市	

第四章 結果及建議

第一節 結果

一、研究區域歷史崩塌資料更新

透過蒐整本署之各年度事件型崩塌目錄，我們統計了 2004 - 2024 年崩塌事件的分布狀況（圖 2-4、圖 2-5），並根據 Chen（2016）的六大地質構造分區分別選擇了其中各個具代表性的集水區作為示範研究的區域（表 4-1）。並且，將各事件分離後，我們可以了解到整個區域過去的崩塌歷程及用於訓練的歷史崩塌資料。值得注意的是，由於模型設計的關係，崩塌的舊崩、新崩及再崩等空間資訊會被模型納入考量，因此我們並不另外進行統計及特徵的區分。

表 4-1 六大地質構造分區示範研究區

	兩型	同震型
海岸平原	事件過少	事件過少
西部麓山帶	旗山溪集水區	清水溪集水區
雪山山脈	大安溪集水區	陳有蘭溪集水區
廬山板岩帶	荖濃溪集水區	美崙溪集水區
大南澳片岩帶	立霧溪集水區	立霧溪集水區
海岸山脈	馬武溪集水區	水璉沿海集水區

以下概述各集水區基礎特徵與崩塌災例之間的關係。

(一) 海岸山脈雨型－馬武溪集水區

馬武溪集水區位於海岸山脈南段，區域內高程多分布於 1000 m 以內，並且崩塌案例絕大多數也發生於 1000 m 以內之丘陵區域；坡向分布偏東南、西北向，崩塌案例以南南東方向最多；坡度分布於 0–70 度，崩塌案例以 30–40 度最多。




圖 4-1 馬武溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(二)西部麓山帶雨型－旗山溪集水區

旗山溪集水區位於高雄市山區，高程分布自 0–3500 m 逐漸遞減，崩塌案例最多分布於 1000 m–1500 m 支流邊坡；坡向分布偏西及西北西，但是主要崩塌案例分布於東南；坡度分布自 0–50 度為主，崩塌案例多位於 30–40 度。




圖 4-2 旗山溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(三)雪山山脈雨型－大安溪集水區

大安溪集水區位於苗栗縣及台中市交界，高程分布於 0－3000 m 左右，以 1500－2000 m 有最多崩塌案例；坡向以西北向較多，但崩塌案例則以東南向為主；坡度分布自 0－60 度，崩塌案例主要分布於 40－50 度。




圖 4-3 大安溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(四) 廬山板岩帶雨型－荖濃溪集水區

荖濃溪集水區同樣位於高雄市，與旗山溪集水區接壤。高程分布自 0–3500 m，崩塌案例主要分布於 1000–1500 m；坡向分布整體均衡，崩塌案例主要發生於東南向；坡度分布於 0–60 度，以 30–40 度為主，崩塌案例也多發生於 30–40 度。




圖 4-4 荖濃溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(五)大南澳片岩帶雨型－立霧溪集水區

立霧溪集水區位於花蓮縣北部，高程分布於 0–3500 m，崩塌案例主要位於 1000–1500 m；坡向分布整體均勻，崩塌案例則偏向東南方為主；坡度分布於 10–70 度左右，崩塌案例主要位於 40–50 度。




圖 4-5 立霧溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(六)海岸山脈同震型－水璉沿岸集水區

水璉沿岸位於花蓮縣濱海區域，高程以 0–500 m 為主，因此崩塌案例也都在 500 m 以下；坡向上以東南為主，但是崩塌案例主要分布於東南及西北方向；坡度分布於 0–50 度左右，以 20–30 度最多，但崩塌案例主要位於 30–50 度。




圖 4-6 水璉沿岸集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(七)西部麓山帶同震型－清水溪集水區

清水溪集水區位於雲林縣、嘉義縣及南投縣交界處，高程分布於 0－2500 m，崩塌案例主要坐落於 500－1000 m；坡向上十分均勻，但是崩塌案例多以西南向為主；坡度分布於 0－60 度左右，以 40－50 度有最多崩塌案例。




圖 4-7 清水溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(八)雪山山脈同震型－陳有蘭溪集水區

陳有蘭溪集水區位於南投縣西南，高程分布於 500－3000 m 左右，崩塌案例呈現雙峰型態，以 500－1000 m、1500－2000 m 占比較高；坡向分布均勻，以東西向微多，崩塌案例以東西東為主；坡度分布於 0－70 度，以 40－50 度有最多崩塌案例。




圖 4-8 陳有蘭溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(九)廬山板岩帶同震型－美崙溪

美崙溪集水區位於花蓮縣中部偏東，高程以 0－500 為主，零星分布至 2000 m，崩塌案例主要位於 0－1500 m；坡向分布均勻，微偏東南，崩塌案例主要位於東南東方向；坡度以 0－10 度為主，10－70 度也有少量分布，崩塌案例主要位於 50－60 度區間。




圖 4-9 美崙溪集水區地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

(十)大南澳片岩帶同震型－立霧溪集水區

基本地形條件同(五)一樣，但是同震型崩塌案例主要分布於 1000－1500 m 高程；坡向、坡度與雨型崩塌類似，主要分布於東南向、40－50 度。




圖 4- 10 立霧溪集水區(同震)地形特徵及崩塌分布（左上：高程；右上：坡向；左下：坡度）

從基礎的地形特徵及崩塌案例的統計，我們可以簡單的了解到：在不同的地質區，受控於當地的地形地貌、地質條件又或是致災因子，獲取的崩塌案例本身可能就會傾向於分布於某些特定的條件，這也可能是模型可能學習到的規律。如表 4- 2 中為我們統計了崩塌紀錄中雨型及同震型崩塌位於各地質區的坡度分布狀況，顯示除雪山山脈地質區外，同震型崩塌分布的坡度相較雨型崩塌都有更陡的趨勢，這極可能代表了不同誘發機制下的差異，若配合足夠的現地觀察或是運動學相關研究，可能可以提供更詳細的防災參考資訊。

表 4- 2 不同崩塌誘發因子崩塌分布坡度(單位:度)

	廬山板岩帶	雪山山脈	海岸山脈	西部麓山帶	大南澳片岩帶
雨型	荖濃溪	大安溪	馬武溪	旗山溪	立霧溪_雨型
	36	43	33	36	42
同震	美崙溪	陳有蘭溪	水璉沿岸	清水溪	立霧溪_同震
	52	43	42	42	51

二、模型崩塌訓練特徵更新


與前期計畫相比，本期計畫我們新增了更多的特徵，希望幫助模型對於崩塌的發生有更全面的理解，同時也能更符合專家在進行崩塌評估時在意的條件。

現地基本條件：順向坡分布，幫助模型考量現地地質弱面分布狀況；


土地利用，增加考量人類活動及開發對於崩塌事件可能造成的衝擊；斷層分布，透過台灣活動構造三維數值模型，我們可以更詳細的了解可能的斷層破碎帶及當斷層運動時可能造成的能量釋放。

同時，更嚴謹的考慮崩塌誘發因子，將崩塌發生的原因依照台灣常見的類型分為雨型與同震型：雨型因子，與前期計畫使用的月平均降水不同，本期透過時雨量資料，建立雨場事件的降水強度、最大 3 小時累計降水、最大 5 小時累計降水、最大 12 小時累計降水，更完整的呈現降雨行為及歷程對崩塌事件造成的影響；地震因子，三維 PGA 資料用以了解地表面受到地震造成之能量衝擊及方向，並且加入斷層深度資料，增加考慮同震型崩塌受斷層樣態影響誘發之關聯性。


圖 4- 11 為所有特徵之展示，圖 4- 11 A-D 為雨型特徵，雨型特徵以荖濃溪集水區 2009 年莫拉克颱風事件為例，圖中展示事件下的崩塌範圍及各特徵狀態。圖 4- 11 E 則為同震型特徵（僅列與雨型特徵不同者），以美崙溪集水區 2024 年 0403 花蓮地震為例。




A 高程、坡度、坡向、平面曲率、剖面曲率、TWI、地質組成類型



B 降雨強度、max3hr、max5hr、max12hr、NDVI、NDBI



C 順向坡、斷層距、褶皺距、河道距、道路距、土地利用類型



D 前三年崩塌範圍（2008、2007、2006）




圖 4- 11 模型訓練使用特徵

另外，製備崩塌特徵時，我們也可以透過對崩塌誘發因子的統計評估，了解崩塌災害在不同的地質區及集水區多發生在怎樣的條件下，因同震型崩塌案例較少，以下舉兩型崩塌事件進行討論，我們將集水區內所有崩塌事件（以網格為單位）的降水條件進行統計並依據數量繪製直方圖。

（一）海岸山脈雨型－馬武溪集水區

在馬武溪集水區中，觀察降雨強度及最大 3 小時累計降雨、最大 5 小時累計降雨、最大 12 小時累計降雨，發現崩塌案例集中在降雨強度每小時累計 0.5–1.0 mm，是一個極小的數值，這可能是由於降雨事件跨度時間很長，降雨強度會將極端的降雨平均掉，但是透過三種短時間時間窗，可以發現在 3 小時累計 70 mm 以上、5 小時累計 100 mm 以上及 12 小時累計 200 mm 以上時可能會有較高的機率發生崩塌。

這樣的統計結果顯示了此區域的條件下，較短的時間窗下的降雨資訊可能更適合作為崩塌之預警特徵。




圖 4- 12 馬武溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）

(二)西部麓山帶雨型－旗山溪集水區

旗山溪集水區的降水強度於 0.5 mm 以上時崩塌明顯較多，但是最大 3 小時累計降水、最大 5 小時累計降水及最大 12 小時累計降水中崩塌案例皆呈現雙峰的分布情形。我們認為這可能跟此區域有兩群崩塌事件占比較高，它們分別在不同的降雨條件下發生；又或是此集水區內因面積較大，區內不同位置有差異甚大之地質條件，這導致誘發崩塌之降雨條件差異。這個結果顯示了即使同樣的地質區內可能也會有明顯不同的崩塌降雨閾值。




圖 4- 13 旗山溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）

(三)雪山山脈雨型－大安溪集水區

在大安溪集水區中，四種直方圖的形貌相差也不大。降雨強度到達 0.75 mm、最大 3 小時累計降雨 70 mm、最大 5 小時累計降雨 80 mm 及最大 12 小時累計降雨 150 mm 以上時崩塌事件明顯增加。




圖 4- 14 大安溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）

(四)廬山板岩帶雨型－荖濃溪集水區

荖濃溪集水區與旗山溪集水區比鄰，因此同樣有類似的崩塌案例呈雙峰分布狀態，這顯示這個地區進行崩塌評估的複雜性。




圖 4- 15 荖濃溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）

(五)大南澳片岩帶雨型－立霧溪集水區

立霧溪集水區與同在東部的馬武溪不同，崩塌案例發生的降雨條件從直方圖分布中看，四種降水特徵分布情形皆類似，在降水強度 0.5 mm 以上、最大 3 小時累計 50 mm、最大 5 小時累計 100 mm 及最大 12 小時累計 180 mm 以上時，可能有較高的崩塌機率。統計上顯示這四種降雨資訊可能都可以用於建立崩塌降雨閾值。




圖 4- 16 立霧溪集水區降水特徵（左上至右下：降水強度、最大 3 小時降水、最大 5 小時降水、最大 12 小時降水）

三、建立內部可解釋性模型架構

在第二節中我們說明了使用的模型架構，分為三種：mlp_his 集成式模型於各集水區分別訓練、mlp_his 集成式模型綜合所有集水區進行訓練，此二種專注於比較針對單一地質區客製化訓練是否會更適合當地。另外也使用 TabNet 原生模型進行於各集水區分別訓練，用於與 mlp_his 架構的模型比較，加入內在可解釋性的模型表現如何。

以下我們在各個集水區、每一場事件的測試集中使用三種模型進行評估並寄算 AUC 值，在比較模型本身的能力時同時也能了解到模型是否會偏袒或在某些事件失效。

(一)海岸山脈雨型－馬武溪集水區

可以看到在馬武溪集水區中，單一集水區訓練的 mlp_his 集成式模型與單一集水區訓練的 TabNet 模型表現近似，AUC 皆接近 1，但是全區域訓練的 mlp_his 集成式模型則在某些事件有明顯的下滑。

表 4-3 馬武溪集水區各事件 AUC 統計

	separate	All	TabNet
Mean	0.9539	0.8902	0.9864
Std	0.0343	0.1473	0.0089




圖 4-17 馬武溪集水區各事件 AUC 圖

(二)西部麓山帶雨型－旗山溪集水區

在旗山溪集水區中，單一集水區訓練的 mlp_his 集成式模型及全區域訓練的 mlp_his 集成式模型都在相似的幾場事件中有顯著的下滑，與之相對，單一集水區訓練的 TabNet 模型雖也有部分事件出現下滑，但是整體表現仍優於另外兩者。

表 4-4 旗山溪集水區各事件 AUC 統計

	seperate	All	TabNet
Mean	0.8692	0.8655	0.9356
Std	0.1141	0.1219	0.0854




圖 4-18 旗山溪集水區各事件 AUC 圖

(三)雪山山脈雨型－大安溪集水區

在大安溪集水區，三種模型表現都不算特別好。但是我們可以看到明顯單一集水區訓練的 mlp_his 集成式模型比其他兩者更差，而另外兩者互為伯仲，但是表現不良的事件略有不同。這個結果可能顯示此集水區內的崩塌案例之間差異巨大，全區域訓練的 mlp_his 集成式模型透過其他集水區的案例補足了部分缺失，而 TabNet 可能因其架構優勢而降低了影響。

表 4-5 大安溪集水區各事件 AUC 統計

	separate	All	TabNet
Mean	0.7483	0.8738	0.8728
Std	0.2157	0.1143	0.1043




圖 4-19 大安溪集水區各事件 AUC 圖

(四) 廬山板岩帶雨型－荖濃溪集水區

荖濃溪集水區與旗山溪集水區類似，單一集水區訓練的 TabNet 模型整體表現優於其他兩者。

表 4-6 荖濃溪集水區各事件 AUC 統計

	separate	All	TabNet
Mean	0.8598	0.8697	0.9403
Std	0.1127	0.1045	0.0720




圖 4-20 荖濃溪集水區各事件 AUC 圖

(五)大南澳片岩帶雨型－立霧溪集水區

立霧溪集水區中，mlp_his 架構的兩種模型都在某幾個事件中失效，

TabNet 有較穩健的發揮。

表 4-7 立霧溪集水區各事件 AUC 統計

	separate	All	TabNet
Mean	0.8209	0.8040	0.8750
Std	0.1643	0.1865	0.1482

同震型崩塌由於每個集水區中使用到的斷層深度資料不一致，無法將全區域資料結合訓練，因此以下只比較單區域資料訓練的 mlp_his 集成式模型及 TabNet 模型。

(六)海岸山脈同震型－水璉沿岸集水區

表 4-8 水璉沿岸集水區各事件 AUC

Event	mlp_his	TabNet
0403 花蓮地震	0.9554	0.9636

(七)西部麓山帶同震型－清水溪集水區

表 4-9 清水溪集水區各事件 AUC

Event	mlp_his	TabNet
0602 地震	0.9776	0.9845

(八)雪山山脈同震型－陳有蘭溪集水區

表 4-10 陳有蘭溪集水區各事件 AUC

Event	mlp_his	TabNet
0327 地震	0.962	0.9948
0602 地震	0.954	0.9887

(九)廬山板岩帶同震型－美崙溪

表 4- 11 美崙溪集水區各事件 AUC

Event	mlp_his	TabNet
0403 花蓮地震	0.9504	0.9667
0418 地震	0.9721	0.9881

(十)大南澳片岩帶同震型－立霧溪集水區

表 4- 12 立霧溪集水區各事件 AUC

Event	mlp_his	TabNet
0206 花蓮地震	0.9991	0.9964
0418 地震	0.9933	0.989
0403 花蓮地震	0.9581	0.9808

在同震型事件中，很明顯可以看出，除了立霧溪集水區的部分事件外，TabNet 架構都優於我們原本的 mlp_his 架構。

四、TabNet 可解釋性

TabNet 架構在本期計畫中提供了更好的訓練結果，本小節將分別針對每個集水區展示 TabNet 給予的特徵重要性，包含全局重要性及局部重要性，其中局部重要性是可以針對任意一個樣本（網格）輸出模型在判斷時的特徵重要性，在針對小區域範圍內進行評估時，可以更仔細的了解災害機制，但考量到篇幅，這邊僅列出前 25 筆之熱區圖，每一筆就不列舉。

（一）海岸山脈雨型－馬武溪集水區

馬武溪集水區中，全局重要性顯示地質組成是用於判別崩塌時最重要的因子、高程次之，第 3 名才出現降雨因子。顯示這個集水區中可能崩塌主要發生在某些特定的不穩定地質條件下，在面對一定的降水時才會發生崩塌。




圖 4-22 馬武溪集水區 TabNet 全局可解釋性圖




圖 4-23 馬武溪集水區局部可解釋性熱區圖

(二)西部麓山帶雨型－旗山溪集水區

旗山溪集水區中，也是地質組成及南北向坡占前兩名重要，第 6 名才出現降雨強度。同樣揭露出地質條件及地形因子對於崩塌發生的重要性。




圖 4-24 旗山溪集水區 TabNet 全局可解釋性圖




圖 4-25 旗山溪集水區局部可解釋性熱區圖

(三)雪山山脈雨型－大安溪集水區

在大安溪集水區中，模型認為土地利用類型及地表植被覆蓋量是影響崩塌最重要的兩個因素，因此若要在此區進行防災作為，可能可以從這兩個方向著手。




圖 4-26 大安溪集水區 TabNet 全局可解釋性圖




圖 4-27 大安溪集水區局部可解釋性熱區圖

(四) 廬山板岩帶雨型 - 荖濃溪集水區

荖濃溪集水區中高程及最大 12 小時累計降雨較為重要，第 3 明才是地質組成，顯示荖濃溪集水區雖然與旗山溪集水區相鄰，但是它們的崩塌案例可能有著不太一樣的致災因素。說明並非空間上相近就一定會類似的行為。




圖 4-28 荖濃溪集水區 TabNet 全局可解釋性圖




圖 4-29 荖濃溪集水區局部可解釋性熱區圖

(五)大南澳片岩帶雨型－立霧溪集水區

在立霧溪集水區中，最大 12 小時累計降水最為重要，並且在前 5 名中有兩個降雨特徵，顯示這個集水區中降水與崩塌發生的相關性特別重要。




圖 4-30 立霧溪集水區 TabNet 全局可解釋性圖




圖 4-31 立霧溪集水區局部可解釋性熱區圖

(六)海岸山脈同震型－水璉沿岸集水區

在水璉沿岸集水區中，模型認為嶺頂斷層的深度變化特別重要，但是地震本身的因子排名都不算靠前。這是一個值得討論的問題，由於同震型崩塌案例都很少，有可能是崩塌案例的分布情形嚴重影響了模型的偏好。




圖 4-32 水璉沿岸集水區 TabNet 全局可解釋性圖




圖 4-33 水璉沿岸集水區局部可解釋性熱區圖

(七)西部麓山帶同震型 - 清水溪集水區

清水溪集水區中，NDVI 顯示出最高的重要性，這可能代表此區域原本裸露的區域更容易發生同震型崩塌。並且值得注意的是在 sample 23 最重要的是順向坡這個特徵，說明其可能位在順向坡區域內並且崩塌行為受此主控。




圖 4-34 清水溪集水區 TabNet 全局可解釋性圖




圖 4-35 清水溪集水區局部可解釋性熱區圖

(八)雪山山脈同震型－陳有蘭溪集水區

陳有蘭溪集水區中，坡度及 PGA_NS 佔據前兩名，說明可能在特定坡度下受到較高的南北向地動加速度更容易發生崩塌。




圖 4-36 陳有蘭溪集水區 TabNet 全局可解釋性圖




圖 4-37 陳有蘭溪集水區局部可解釋性熱區圖

(九) 廬山板岩帶同震型 - 美崙溪

美崙溪集水區中，重要的特徵為道路距、坡向等，這顯示出似乎這裡的同震型崩塌可能多發生在道路附近的南北向邊坡。但是我們似乎也不容易從這個結果看出地震本身的影響。




圖 4-38 美崙溪集水區 TabNet 全局可解釋性圖




圖 4-39 美崙溪集水區局部可解釋性熱區圖

(十)大南澳片岩帶同震型－立霧溪集水區

立霧溪集水區是本研究中同震型崩塌最多的一個，模型顯示 PGA_NS 獨占鰲頭，是判斷同震崩塌發生與否的決定性因素。但是此區域似乎南北向的坡向並沒有占比特別高(圖 4-10)，無法確定 PGA_N 為甚麼是最重要的因素，而其他兩個方向的 PGA 並沒有這樣的狀況，後續討論中會針對這個現象進行說明。




圖 4-40 立霧溪集水區(同震)TabNet 全局可解釋性圖




圖 4-41 立霧溪集水區(同震)局部可解釋性熱區圖

五、SHAP 分析

SHAP 分析是資料導向的分析方法，此處我們為盡量廣納所有資料組合的可能性，取驗證集及測試集一同進行 SHAP 的分析。而 SHAP 有一點優勢是 TabNet 不具備的，由於是資料導向，此方法可以了解到某特徵是對是否發生崩塌有正影響還是負影響，而該特徵值的變化又是如何影響模型的輸出方向。

(一)海岸山脈雨型－馬武溪集水區

馬武溪集水區中，SHAP 顯示最大 12 小時累計降水、地質條件對於模型輸出有著更大的影響。並且我們可以透過將每一個特徵單獨拿出來看，或是與某特徵合併查看。如圖 4-43 可以了解不同種類的地質組成、土地利用類型，對於模型輸出是產生正向或是負向的影響，同時也可以在圖中看到各類型分別分布於何種坡度狀態（當然也可以是其他的特徵），這有助於我們針對某一個目標區域更細緻的討論統計意義上的崩塌致災因素，以及該如何進行調整以降低崩塌風險。另外，我們也能觀察降雨特徵，如圖 4-44，有趣的是，馬武溪集水區的 SHAP 值與降水量之間在降雨強度、最大 3 小時累計降水呈現負相關趨勢，但是最大 5 小時累計降水及最大 12 小時累計降水呈現正相關趨勢。我們對此有一些可能的解釋，於後續章節中將說明。




圖 4-42 馬武溪集水區 SHAP 全局重要性圖




圖 4-43 馬武溪集水區地質組成及土地利用對坡度 SHAP 圖




圖 4-44 馬武溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(二)西部麓山帶雨型－旗山溪集水區

旗山溪集水區中，也是最大 12 小時累計降水影響最大。在土地利用上，原生裸露地等具有較高的 SHAP，同時有多位於坡度較陡之處，建議為重點考慮及改善對象。




圖 4-45 旗山溪集水區 SHAP 全局重要性圖




圖 4-46 旗山溪集水區地質組成及土地利用對坡度 SHAP 圖




圖 4-47 旗山溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(三)雪山山脈雨型－大安溪集水區

大安溪集水區依舊是最大 12 小時累計降水最為重要。區域內厚層砂岩、粉砂岩、泥岩之互層，偶夾薄層礫岩、砂岩及頁岩互層，含煤層、塊狀砂岩夾頁岩、泥質砂岩、粉砂岩及頁岩等地質組成有許多較陡的區域且 SHAP 值高，易發生崩塌。




圖 4-48 大安溪集水區 SHAP 全局重要性圖




圖 4-49 大安溪集水區地質組成及土地利用對坡度 SHAP 圖




圖 4-50 大安溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(四)廬山板岩帶雨型－荖濃溪集水區

荖濃溪集水區中，最大 12 小時累計降水也是十分重要。地質組成上有許多類別都有較高的 SHAP 值，值得留意並防範。另外與旗山溪類似，原生裸露地可能便是持續有滑動發生的地方，其再發崩塌的可能性很高。




圖 4-51 老濃溪集水區 SHAP 全局重要性圖




圖 4-52 老濃溪集水區地質組成及土地利用對坡度 SHAP 圖




圖 4-53 荖濃溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(五)大南澳片岩帶雨型－立霧溪集水區

立霧溪集水區中，最大 12 小時累計雨量仍是最重要的。並且值得留意的是，地質組成中火成岩跟火山碎屑岩的 SHAP 許多都超過 0.1 且有陡峭的地形，顯示模型在學習過去的災害歷史後，對於這樣的條件判定為較危險的區域。




圖 4-54 立霧溪集水區 SHAP 全局重要性圖




圖 4-55 立霧溪集水區地質組成及土地利用對坡度 SHAP 圖




圖 4-56 立霧溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(六)海岸山脈同震型－水璉沿岸集水區

水璉沿岸集水區中，坡度的重要性最高，次之是 TWI。這可能跟此區域多為濱海區域，僅少部分丘陵區域可以發生同震崩塌有關，並且由於地震測報中心公告之 PGA 測站點位密度不是很高，內插後在小區域內變化不大，也影響了模型學習的結果。




圖 4-57 水璉沿岸集水區 SHAP 全局重要性圖




圖 4-58 水璉沿岸集水區地質組成及土地利用對坡度 SHAP 圖




圖 4-59 水璉沿岸集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(七)西部麓山帶同震型－清水溪集水區

清水溪集水區中，PGA_V 及最為重要，並且九芎坑、大甲－彰化斷層的影響也不小，並且可以很明顯的看到這兩條斷層深度越深 SHAP 值越小，這可能說明了即使在地震報告中顯示為盲斷層的地震事件，其周遭的斷層系統也會受到一定的影響，並對地表面上的同震崩塌產生影響。




圖 4- 60 清水溪集水區 SHAP 全局重要性圖




圖 4- 61 清水溪集水區地質組成及土地利用對坡度 SHAP 圖




圖 4- 62 清水溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(八)雪山山脈同震型－陳有蘭溪集水區

陳有蘭溪集水區中，河道距及 PGA_V 佔據前兩名。其中河道距在 TabNet 的全局重要性中位於第三名，說明可能這個集水區中靠近河道的邊坡是崩塌風險十分高的。




圖 4- 63 陳有蘭溪集水區 SHAP 全局重要性圖




圖 4- 64 陳有蘭溪集水區地質組成及土地利用對坡度 SHAP 圖




圖 4-65 陳有蘭溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(九)廬山板岩帶同震型－美崙溪

美崙溪集水區中，坡度及 PGA_NS 很重要，並且同樣是坡度陡峭的火成岩區有較高的崩塌風險。




圖 4-66 美崙溪集水區 SHAP 全局重要性圖




圖 4-67 美崙溪集水區地質組成及土地利用對坡度 SHAP 圖




圖 4-68 美崙溪集水區降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

(十)大南澳片岩帶同震型－立霧溪集水區

在立霧溪集水區中，PGA_EW 及地質組成最為重要。與雨型崩塌類似，此區域的地質組成都位於前兩名，顯示出這樣的地質條件下，崩塌災害的發生很大一部分受到其影響。




圖 4-69 立霧溪集水區(同震)SHAP 全局重要性圖




圖 4-70 立霧溪集水區(同震)地質組成及土地利用對坡度 SHAP 圖




圖 4- 71 立霧溪集水區(同震)降雨特徵 SHAP 圖(左上至右下：降水強度、最大 3 小時、最大 5 小時、最大 12 小時累計降水)

六、崩塌潛勢地圖

建置好的模型在使用上，可以將評估目標的雨場或地震資料作為自變量輸入模型，模型即可輸出崩塌發生的機率值。應用上可設定機率閾值產出崩塌、不崩塌的二分類地圖；我們也可根據原始機率值進行 Natural Break 的分類計算，產出多類別的崩塌潛勢地圖(圖 4-72)。於訓練集上我們計算出各個集水區 very low、low、medium、high、very high 的機率範圍，於測試集中我們可以計算出實際崩塌位於各區域的比例，結果顯示於絕大多數研究集水區內，實際崩塌紀錄都有 7 成以上的比例位於 high 及 very high 的高崩塌潛勢區內(表 4-13)，顯示我們的模型在進行崩塌風險的評估過程中可以提供良好的參考。

表 4-13 崩塌位於 high 及 very high 區域的比例表

	雪山山脈	大南澳片岩帶	廬山板岩帶	西部麓山帶	海岸山脈
同震	陳有蘭溪	立霧溪_同震	美崙溪	清水溪	水璉沿岸
	94.1%	96.4%	82.2%	86.4%	75.9%
雨型	大安溪	立霧溪_雨型	荖濃溪	旗山溪	馬武溪
	84.9%	88.2%	93.0%	94.5%	93.7%




圖 4-72 崩塌潛勢地圖（以荖濃溪集水區於凱米颱風事件為例）

七、同震型崩塌及雨型崩塌差異

通過可解釋性模型提供的資訊，我們除了可以了解某集水區內不同崩塌特徵的重要性及可能的防災手段，也可進一步的針對同震型崩塌及雨型崩塌有更深入的討論。

因同震型崩塌及雨型崩塌於致災因子本身的差異（地震 PGA、降水因子），我們將其餘的致災因子重要性於不同集水區中排名，並根據排名進行主成分分析（圖 4-73）。透過主成分分析的結果，可以看到雨型與同震崩塌事件可以分為兩群（紅色為同震型、藍色為雨型）。其中第一主成分（PC1）包含了原始特徵數據的 28.94% 資訊，第二主成分（PC2）則包含 20.33% 資訊。在 PC1 中，大於 0 的多為雨型事件，小於 0 的多為同震型事件，顯示 PC1 可作為辨別兩型或同震型的依據；在 PC2 中則除了 Meilun_eq 外皆分布於 -3~1，顯示 PC2 或許可用於鑑別同型事件中不同地質區的特性。

觀察第一主成分及第二主成分的主成分負荷圖（PCA loading）（圖 4-74），我們可以針對不同崩塌類型及不同地質區下的崩塌行為進行定性的描述：PC1 中，地質組成、地形及 TWI 等條件顯示較高的重要性，代表在 PC1 為正的雨型崩塌事件中這些特徵顯得較為重要，而 PC1 為負的同震型事件則較受土地利用、河道距及坡度等因素控制；PC2 中，Meilun 比其他地質區都顯示出更偏向正值，最主要受到平面曲率及剖面曲率影響，顯示出這個集水區可能崩塌較傾向於發生於較崎嶇的地形。






圖 4- 73 不同集水區中特徵重要性主成分分析



a



b

圖 4- 74 第一主成分及第二主成分主成分負荷圖（a：第一主成分；b：第二主成分）

八、小結

本期計畫補足了前期計畫不足之處：

將訓練模型的崩塌資料從整年期崩塌判釋資料，更換成事件型崩塌資料，並取得事件對應的降雨、地震等致災因子資料。這樣的進步可以在模型完成後，讓災害本身與誘發因子之間的關聯性更加密切，透過未來的降雨模擬資料、模擬地震等方法，可以進行可能的崩塌災害衝擊評估。

盡可能的多方考量並加入了與崩塌相關的絕大多數資料，讓模型能夠更多面的考慮崩塌的議題。不過受限於部分資料完整性（岩石強度分級）或在訓練中使用上的難度（震源機制解），目前只能擱置一部分想法，期許未來能夠實現。

考慮了在五大地質區分別建立模型及全區域統一模型的差異，原本預想的結果是各區域分別訓練會有較好的結果，在大部分集水區內也確實是這樣沒有錯，但是在大安溪集水區可能跟資料數量有關，統一大模型反而比較好，這可能需要更進一步的研究釐清為何有這樣的現象以及解決的方法。

嘗試並建立了兩種模型可解釋方法，TabNet 架構及 SHAP 分析，TabNet 架構為前人開發的內在可解釋性模型，它由專業機器學習研究者開發的優勢使它與我們前期計畫中的模型相比，在不同事件下有更

穩定優良的表現，並且可以提供特徵全局重要性及每一個資料樣本的局部特徵重要性。但是 SHAP 方法因其資料導向的概念，可以更明確的了解到特徵的值或種類是如何影響模型決策方向，可以更明確的對防減災方法進行討論及分析。由於時間因素，我們尚未測試是否可以將 TabNet 模型做 SHAP 分析，如果可以的話結合兩者的優勢，似乎是崩塌評估及可解釋性上的最優解。

九、討論

(一) 特徵共線性問題

回到前文提及的問題，我們直觀上會認為：同震崩塌中各方向性上的 PGA，即使重要性不一，但是也應該不會相差太多，但是在太南澳片岩帶同震型－立霧溪集水區，PGA_NS 顯示十分重要，但另外兩個方向的卻不怎麼重要，這很可能是因為以下的原因：特徵共線性。下表 4-14 是針對所有同震型崩塌事件的 VIF 結果，理論上神經網路模型不太受特徵共線性問題影響，因此我們沒有特別排除 $VIF > 5$ 的特徵，但是我們可以看到三維向量的 PGA 共線性問題十分嚴重，這導致模型在訓練時隨機初始化時，可能會將這三者中任意一個作為重要因子，另外兩者的重要性因此被削弱（三者有同樣變化趨勢，模型僅考慮其中一項也可以達到考慮三種的效果）。

表 4-14 同震型特徵 VIF 表

特徵	VIF
PGA_V	277.267
PGA_NS	173.760
PGA_EW	121.690
TWI	1.998
坡度	1.683
高程	1.248
剖面曲率	1.093
平面曲率	1.052

而海岸山脈雨型－馬武溪集水區提到的降水特徵有跟 SHAP 值無相關或負相關的狀況，也可能與共線性問題相關，經測試四種降水特徵也有較高的 VIF 值。另外，降水特徵的問題也可能是因為在特徵製備時，並未限制最大 5 小時降水一定在最大 12 小時降水的時間區間中，又或是最大 3 小時降水要在最大 12 小時降水及最大 5 小時降水的時間區間中，這導致在雨場中這些降水特徵可能距離真實發生崩塌時間點有不同的差異，影響了最後的結果，這是未來可改進之處。

(二) 歷史崩塌特徵

仔細觀看兩種模型可解釋性方法的結果，不難看出前三年的歷史崩塌似乎都不是特別重要的因子，這與前期計畫中得出的結果不太一樣。我們認為這是資料不同導致的結果，前期計畫中使用的全年度崩塌資料在崩塌面積上及崩塌率上，與本期所使用的事件型崩塌資料相比都比較高，這意味這著本期的資料兩年之間崩塌區域重疊的可能性較小，也影響了歷史崩塌在新生崩塌評估時的重要性。此問題與歷史崩塌資料判釋時的團隊以及所使用的方法有很大的相關性，也告訴我們資料往往會大幅影響資料科學分析的結果。在崩塌災害評估中，精確的資料能有效提升模型的預測準確性，從而降低潛在災害風險與損失。

十、研討會發表

本團隊於 7/3 - 7/4 參與 International Conference on Earth Observations and Social Impacts (ICEO & SI 2025) 研討會。並針對前期計畫成果及本期計畫內容進行口頭發表(圖 4-75)，除展示計畫成果外，也透過與各界與會學者交換意見，以精進研究內容。除此之外，本計畫博士生研究助理許祐誠參與大會之 Student Paper Awards，有幸受大會評審青睞，獲得一等獎(圖 4-76)。



圖 4- 75 研究助理許祐誠進行口頭發表（上圖）；陳麒文教授與與會學者合照（下圖）




圖 4- 76 Student Paper Awards 獲獎

第二節 建議

一、崩塌潛勢模型建立

本期計畫中，我們測試了使用事件型崩塌目錄，於不同地質區下模型建立的方法，最佳的方法是於不同地質區建立資料、並使用 TabNet 模型進行訓練，可在給出模型特徵重要性的同時維持良好的穩定性，這樣的結果增加了我們建立全台範圍下崩塌潛勢模型的可能性。如果可以的話，結合 SHAP 分析方法，更可以資料導向的方式了解到各特徵分布對於崩塌災害發生與否的影響。

二、模型加值應用

由於篇幅限制，我們並未在報告中列出可解釋性模型或方法所有的產出，事實上，若要針對某一個特定區域進行崩塌災害的評估及可能的防減災手段，我們可以每 20*20 的網格大小逐一進行分析，了解其局部特徵重要性及可以改善的方向。

三、模型潛在應用

由於本期計畫使用的致災因素與崩塌事件在時間上的關係為同時，因此模型將更直觀的對一場強降雨或是一次地震有更好的崩塌模擬。這樣的成果在實務應用上，透過建置好的模型，將氣候變遷推估資料及相對應特徵輸入模型以建立對應年分的崩塌潛勢評估結果。可以提供

相關災害防治單位進行災害風險管理參考，並且透過可解釋性模型，能針對性的對影響崩塌發生較為顯著的因素進行工程或相應防減災調適手段。

參考文獻

1. Arik, S. O., & Pfister, T. (2020). *TabNet: Attentive Interpretable Tabular Learning* (arXiv:1908.07442). arXiv.
<https://doi.org/10.48550/arXiv.1908.07442>
2. Arnone, E., Francipane, A., Scarbaci, A., Puglisi, C., & Noto, L. V. (2016). Effect of raster resolution and polygon-conversion algorithm on landslide susceptibility mapping. *Environmental Modelling & Software*, 84, 467–481. <https://doi.org/10.1016/j.envsoft.2016.07.016>
3. Aslam, B., Zafar, A., & Khalil, U. (2023). Comparative analysis of multiple conventional neural networks for landslide susceptibility mapping. *Natural Hazards*, 115(1), 673–707.
<https://doi.org/10.1007/s11069-022-05570-x>
4. Böhner, J., & Selige, T. (2002). Spatial prediction of soil attributes using terrain analysis and climate regionalization. *Gottinger Geographische Abhandlungen*, 115.
5. Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. *Proceedings of the fifth annual workshop on Computational learning theory*, 144–152.
<https://doi.org/10.1145/130385.130401>
6. Brunetti, M. T., Peruccacci, S., Rossi, M., Luciani, S., Valigi, D., & Guzzetti, F. (2010). Rainfall thresholds for the possible occurrence of landslides in Italy. *Natural Hazards and Earth System Sciences*, 10(3), 447–458. <https://doi.org/10.5194/nhess-10-447-2010>
7. Bui, D. T., Tsangaratos, P., Nguyen, V.-T., Liem, N. V., & Trinh, P. T.

- (2020). Comparing the prediction performance of a Deep Learning Neural Network model with conventional machine learning models in landslide susceptibility assessment. *CATENA*, 188, 104426. <https://doi.org/10.1016/j.catena.2019.104426>
8. Chen, C.-W., Tung, Y.-S., Liou, J.-J., Li, H.-C., Cheng, C.-T., Chen, Y.-M., & Oguchi, T. (2019). Assessing landslide characteristics in a changing climate in northern Taiwan. *CATENA*, 175, 263–277. <https://doi.org/10.1016/j.catena.2018.12.023>
 9. Crippen, R. E. (1990). Calculating the vegetation index faster. *Remote Sensing of Environment*, 34(1), 71–73. [https://doi.org/10.1016/0034-4257\(90\)90085-Z](https://doi.org/10.1016/0034-4257(90)90085-Z)
 10. Dao, D. V., Jaafari, A., Bayat, M., Mafi-Gholami, D., Qi, C., Moayedi, H., Phong, T. V., Ly, H.-B., Le, T.-T., Trinh, P. T., Luu, C., Quoc, N. K., Thanh, B. N., & Pham, B. T. (2020). A spatially explicit deep learning neural network model for the prediction of landslide susceptibility. *CATENA*, 188, 104451. <https://doi.org/10.1016/j.catena.2019.104451>
 11. Dong, J.-J., Lai, P.-J., Chang, C.-P., Yang, S.-H., Yeh, K.-C., Liao, J.-J., & Pan, Y.-W. (2014). Deriving landslide dam geometry from remote sensing images for the rapid assessment of critical parameters related to dam-breach hazards. *Landslides*, 11(1), 93–105. <https://doi.org/10.1007/s10346-012-0375-z>
 12. Fang, H., Shao, Y., Xie, C., Tian, B., Shen, C., Zhu, Y., Guo, Y., Yang, Y., Chen, G., & Zhang, M. (2023). A New Approach to Spatial Landslide Susceptibility Prediction in Karst Mining Areas Based on Explainable Artificial Intelligence. *Sustainability*, 15(4), 3094.

<https://doi.org/10.3390/su15043094>

13. Friedman, J. (1977). A Recursive Partitioning Decision Rule for Nonparametric Classification. *IEEE Trans. Computers*, 26, 404–408.
<https://doi.org/10.1109/TC.1977.1674849>
14. Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). *Generative Adversarial Networks* (arXiv:1406.2661). arXiv.
<http://arxiv.org/abs/1406.2661>
15. Guzzetti, F., Peruccacci, S., Rossi, M., & Stark, C. P. (2008). The rainfall intensity–duration control of shallow landslides and debris flows: An update. *Landslides*, 5(1), 3–17.
<https://doi.org/10.1007/s10346-007-0112-1>
16. Guzzetti, F., Reichenbach, P., Ardizzone, F., Cardinali, M., & Galli, M. (2006). Estimating the quality of landslide susceptibility models. *Geomorphology*, 81(1), 166–184.
<https://doi.org/10.1016/j.geomorph.2006.04.007>
17. He, C. (2009). *Pu tong di zhi xue* (3 ban). Wu nan tu shu chu ban you xian gong si.
18. He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition* (arXiv:1512.03385). arXiv.
<https://doi.org/10.48550/arXiv.1512.03385>
19. He, Y., Wang, W., Zhang, L., Chen, Y., Chen, Y., Chen, B., He, X., & Zhao, Z. (2023). An identification method of potential landslide zones using InSAR data and landslide susceptibility. *Geomatics, Natural Hazards and Risk*, 14(1), 2185120.

<https://doi.org/10.1080/19475705.2023.2185120>

20. Hochreiter, S. (1991). *Untersuchungen zu dynamischen neuronalen Netzen*.
21. Huang, F., Yan, J., Fan, X., Yao, C., Huang, J., Chen, W., & Hong, H. (2022). Uncertainty pattern in landslide susceptibility prediction modelling: Effects of different landslide boundaries and spatial shape expressions. *Geoscience Frontiers*, 13(2), 101317. <https://doi.org/10.1016/j.gsf.2021.101317>
22. Huang, F., Ye, Z., Jiang, S.-H., Huang, J., Chang, Z., & Chen, J. (2021). Uncertainty study of landslide susceptibility prediction considering the different attribute interval numbers of environmental factors and different data-based models. *CATENA*, 202, 105250. <https://doi.org/10.1016/j.catena.2021.105250>
23. Huang, F., Zhang, J., Zhou, C., Wang, Y., Huang, J., & Zhu, L. (2020). A deep learning algorithm using a fully connected sparse autoencoder neural network for landslide susceptibility prediction. *Landslides*, 17(1), 217–229. <https://doi.org/10.1007/s10346-019-01274-9>
24. Huang, Y., & Zhao, L. (2018). Review on landslide susceptibility mapping using support vector machines. *CATENA*, 165, 520–529. <https://doi.org/10.1016/j.catena.2018.03.003>
25. JENKS, G. F., & CASPALL, F. C. (1971). Error on Choroplethic Maps: Definition, Measurement, Reduction. *Annals of the Association of American Geographers*, 61(2), 217–244. <https://doi.org/10.1111/j.1467-8306.1971.tb00779.x>
26. Kopecký, M., Macek, M., & Wild, J. (2021). Topographic Wetness

Index calculation guidelines based on measured soil moisture and plant species composition. *Science of The Total Environment*, 757, 143785. <https://doi.org/10.1016/j.scitotenv.2020.143785>

27. LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541–551. <https://doi.org/10.1162/neco.1989.1.4.541>
28. Li, Y., Chen, W., Rezaie, F., Rahmati, O., Davoudi Moghaddam, D., Tiefenbacher, J., Panahi, M., Lee, M.-J., Kulakowski, D., Tien Bui, D., & Lee, S. (2021). Debris flows modeling using geo-environmental factors: Developing hybridized deep-learning algorithms. *Geocarto International*, 37(17), 5150–5173. <https://doi.org/10.1080/10106049.2021.1912194>
29. Lin, C.-W., Tseng, C.-M., Tseng, Y.-H., Fei, L.-Y., Hsieh, Y.-C., & Tarolli, P. (2013). Recognition of large scale deep-seated landslides in forest areas of Taiwan using high resolution topography. *Journal of Asian Earth Sciences*, 62, 389–400. <https://doi.org/10.1016/j.jseaes.2012.10.022>
30. McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
31. Merghadi, A., Yunus, A. P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D. T., Avtar, R., & Abderrahmane, B. (2020). Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance. *Earth-Science Reviews*, 207, 103225.

<https://doi.org/10.1016/j.earscirev.2020.103225>

32. Minsky, M., & Papert, S. A. (1972). *Perceptrons: An introduction to computational geometry* (2. print. with corr). The MIT Press.
33. Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
34. O'brien, R. M. (2007). A Caution Regarding Rules of Thumb for Variance Inflation Factors. *Quality & Quantity*, 41(5), 673–690. <https://doi.org/10.1007/s11135-006-9018-6>
35. Pacheco Quevedo, R., Velastegui-Montoya, A., Montalván-Burbano, N., Morante-Carballo, F., Korup, O., & Daleles Rennó, C. (2023). Land use and land cover as a conditioning factor in landslide susceptibility: A literature review. *Landslides*, 20(5), 967–982. <https://doi.org/10.1007/s10346-022-02020-4>
36. Qin, S., Qiao, S., Yao, J., Zhang, L., Liu, X., Guo, X., Chen, Y., & Sun, J. (2022). Establishing a GIS-based evaluation method considering spatial heterogeneity for debris flow susceptibility mapping at the regional scale. *Natural Hazards*, 114(3), 2709–2738. <https://doi.org/10.1007/s11069-022-05487-5>
37. Rogerson, P. (2001). *Statistical Methods for Geography*. SAGE Publications, Ltd. <https://doi.org/10.4135/9781849209953>
38. Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
39. Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>

40. Saito, H., Nakayama, D., & Matsuyama, H. (2010). Relationship between the initiation of a shallow landslide and rainfall intensity—Duration thresholds in Japan. *Geomorphology*, 118(1), 167–175. <https://doi.org/10.1016/j.geomorph.2009.12.016>
41. Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 44(1.2), 206–226. <https://doi.org/10.1147/rd.441.0206>
42. Sarkar, S., & Kanungo, D. P. (2004). An Integrated Approach for Landslide Susceptibility Mapping Using Remote Sensing and GIS. *Photogrammetric Engineering & Remote Sensing*, 70(5), 617–625. <https://doi.org/10.14358/PERS.70.5.617>
43. Serra-Ruiz, J., Qureshi, A., & Megías, D. (2019). Entropy-Based Semi-Fragile Watermarking of Remote Sensing Images in the Wavelet Domain. *Entropy*, 21(9), 847. <https://doi.org/10.3390/e21090847>
44. Shu, H., Hürlimann, M., Molowny-Horas, R., González, M., Pinyol, J., Abancó, C., & Ma, J. (2019). Relation between land cover and landslide susceptibility in Val d’Aran, Pyrenees (Spain): Historical aspects, present situation and forward prediction. *Science of The Total Environment*, 693, 133557. <https://doi.org/10.1016/j.scitotenv.2019.07.363>
45. Sudjianto, A., Zhang, A., Yang, Z., Su, Y., & Zeng, N. (2023, 五月 7). *PiML Toolbox for Interpretable Machine Learning Model Development and Diagnostics*. arXiv.Org. <https://arxiv.org/abs/2305.04214v3>
46. Sun, D., Shi, S., Wen, H., Xu, J., Zhou, X., & Wu, J. (2021). A hybrid

- optimization method of factor screening predicated on GeoDetector and Random Forest for Landslide Susceptibility Mapping. *Geomorphology*, 379, 107623. <https://doi.org/10.1016/j.geomorph.2021.107623>
47. Sutton, R. S., & Barto, A. (2020). *Reinforcement learning: An introduction* (Second edition). The MIT Press.
 48. Tang, X., Tu, Z., Wang, Y., Liu, M., Li, D., & Fan, X. (2022). Automatic Detection of Coseismic Landslides Using a New Transformer Method. *Remote Sensing*, 14(12), 2884. <https://doi.org/10.3390/rs14122884>
 49. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). *Attention Is All You Need* (arXiv:1706.03762). <http://arxiv.org/abs/1706.03762>
 50. Wang, W.-N., Chigira, M., & Furuya, T. (2003). Geological and geomorphological precursors of the Chiu-fen-erh-shan landslide triggered by the Chi-chi earthquake in central Taiwan. *Engineering Geology*, 69(1–2), 1–13. [https://doi.org/10.1016/S0013-7952\(02\)00244-2](https://doi.org/10.1016/S0013-7952(02)00244-2)
 51. Wang, Z., & Liu, J.-C. (2019). *Translating Math Formula Images to LaTeX Sequences Using Deep Neural Networks with Sequence-level Training* (arXiv:1908.11415). arXiv. <http://arxiv.org/abs/1908.11415>
 52. Werbos, P. J. (1982). Applications of advances in nonlinear sensitivity analysis. 收入 R. F. Drenick & F. Kozin, *System Modeling and Optimization* (卷 38, 頁 762–770). Springer-Verlag. <https://doi.org/10.1007/BFb0006203>
 53. Wijaya, I. P. K., Joshi, A., Alam, M. N., Jayasinghe, S., & Laila, N.

- (2022). Climate Change Induced Landslide Susceptibility Assessment - for Aiding Climate Resilient Planning for Road Infrastructure: A Case Study in Rangamati District, Chittagong Hill Tracts, Bangladesh. *IOP Conference Series: Earth and Environmental Science*, 1091(1), 012010. <https://doi.org/10.1088/1755-1315/1091/1/012010>
54. Xiao, L., Zhang, Y., & Peng, G. (2018). Landslide Susceptibility Assessment Using Integrated Deep Learning Algorithm along the China-Nepal Highway. *Sensors*, 18(12), 4436. <https://doi.org/10.3390/s18124436>
 55. Yang, Z., Zhang, A., & Sudjianto, A. (2021). GAMI-Net: An explainable neural network based on generalized additive models with structured interactions. *Pattern Recognition*, 120, 108192. <https://doi.org/10.1016/j.patcog.2021.108192>
 56. Yi, Y., Zhang, Z., Zhang, W., Jia, H., & Zhang, J. (2020). Landslide susceptibility mapping using multiscale sampling strategy and convolutional neural network: A case study in Jiuzhaigou region. *CATENA*, 195, 104851. <https://doi.org/10.1016/j.catena.2020.104851>
 57. Yingze, S., Yingxu, S., Xin, Z., Jie, Z., & Degang, Y. (2024). Comparative analysis of the TabNet algorithm and traditional machine learning algorithms for landslide susceptibility assessment in the Wanzhou Region of China. *Natural Hazards*, 120(8), 7627–7652. <https://doi.org/10.1007/s11069-024-06521-4>
 58. Yoon, E. J., Thorne, J. H., Park, C., Lee, D. K., Kim, K. S., Yoon, H., Seo, C., Lim, C.-H., Kim, H., & Song, Y.-I. (2019). Modeling spatial climate change landuse adaptation with multi-objective genetic

- algorithms to improve resilience for rice yield and species richness and to mitigate disaster risk. *Environmental Research Letters*, 14(2), 024001. <https://doi.org/10.1088/1748-9326/aaf0cf>
59. Youssef, K., Shao, K., Moon, S., & Bouchard, L.-S. (2023). Landslide susceptibility modeling by interpretable neural network. *Communications Earth & Environment*, 4(1), 162. <https://doi.org/10.1038/s43247-023-00806-5>
60. Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583–594. <https://doi.org/10.1080/01431160304987>
61. Zhou, X., Wen, H., Zhang, Y., Xu, J., & Zhang, W. (2021). Landslide susceptibility mapping using hybrid random forest with GeoDetector and RFE for factor optimization. *Geoscience Frontiers*, 12(5), 101211. <https://doi.org/10.1016/j.gsf.2021.101211>
62. Lundberg, S., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions (arXiv:1705.07874). arXiv. <https://doi.org/10.48550/arXiv.1705.07874>
63. 王勁峰、徐成東 (2017)。地理探測器：原理與展望。《地理學報》，72(1)，116-134。
64. 交通部運輸研究所 (2010)。新世紀台灣地區交通路網數值地圖。台北市：交通部。
65. 李錫堤 (2011)。草嶺大崩山之地質與地形演變。中華水土保持學

報，42(4)，325-335。

66. 李錫堤、董家鈞、林銘郎（2009）。小林村災變之地質背景探討。地工技術，122，87-94。
67. 吳琪、周創兵、黃發明、姚池（2022）。基于双重注意力机制的滑坡识别方法优化。地质科技通报，41(2)，246-253。
<https://doi.org/10.19509/j.cnki.dzkq.2022.0053>
68. 林冠瑋（2010）。台灣地區之河流輸砂量與岩性、逕流量及地震之相關性。國立臺灣大學地質科學研究所。博士論文。
69. 林慶偉（1996）。南投縣和社地區崩塌地發育之地質影響因子。地工技術，57，5-16。
70. 林穎東、張國楨、楊啟見（2018）。利用物件式導向進行崩塌地種類判釋、復育追蹤—以高雄市寶來地區為例。中華水土保持學報，49(2)。 [https://doi.org/10.29417/JCSWC.201803_49\(2\).0004](https://doi.org/10.29417/JCSWC.201803_49(2).0004)
71. 秋庭伸也、杉山阿聖、寺田學（2021）。零基礎入門的機器學習圖鑑。台北市：采實文化。
72. TCCIP（科技部臺灣氣候變遷推估資訊與調適知識平台）（2025）。臺灣歷史氣候重建時資料(TReAD)。V1.1。臺灣氣候變遷推估資訊與調適知識平台，<https://tccip.ncdr.nat.gov.tw/>。
73. 唐昭榮、胡植慶、羅佳明、林銘郎（2009）。遽變式山崩之 PFC3D

模擬初探--以草嶺與小林村為例。地工技術，122，143-152。

74. 陳樹群、吳俊鉉（2009）。高雄縣小林村獻肚山巨型深層崩塌引致之地形變遷特性。中華水土保持學報，40（4），359-376。
75. 陳柔妃（2020）。109 年廣域大規模崩塌潛勢區時序地表變形及活動性評估。台北市：行政院農業委員會水土保持局。
76. 陳宏宇（2024）。臺灣活動構造三維數值模型。新北市：國家災害防救科技中心
77. 曹博涵（2019）。以遙測影像與數值模擬分析油車寮地滑之特性。臺灣博碩士論文知識加值系統。國立臺灣大學地質科學研究所。碩士論文。
78. 曹祉晏（2017）。應用像元分析技術判釋莫拉克風災在油車寮地區引起之山崩滑動特性探討。國立臺灣大學地質科學研究所。碩士論文。
79. 黃淳銘（2019）。結合地質模型進行三維離散元之崩塌運移數值模擬-以太麻里溪、四川新磨村、樣仔寮為例。國立成功大學地球科學研究所。碩士論文。
80. 葉宗鑫（2022）。前期崩塌與因子重要性於崩塌潛勢評估模型表現之研究。逢甲大學土木工程學系。碩士論文。

81. 溫振宇 (2005)。結合地震與颱風因子之山崩模式分析。國立成功大學地球科學研究所。碩士論文。
82. 楊樹榮、林忠志、鄭錦桐、潘國樑、蔡如君、李正利 (2011)。臺灣常用山崩分類系統。第十四屆中華民國大地工程研討會，桃園市，臺灣。
83. 經濟部中央地質調查所 (2013)。易淹水地區上游集水區地質調查及資料庫建置 (軟精裝附光碟)。臺北市：經濟部中央地質調查所。
84. 經濟部地質調查及礦業管理中心。岩石強度分布圖。地質雲。行政院
85. 經濟部地質調查及礦業管理中心。全臺順向坡分布。地質雲。行政院
86. 農業部 (2020)。山坡地土地可利用限度分類標準。山坡地保育利用條例第十六條第三項。行政院。
87. 農業部農村發展及水土保持署。93-113 年事件型崩塌目錄。行政院
88. 鄭德尉 (2021)。以有限元素法分析降雨引致邊坡破壞的漸進式過程。臺灣博碩士論文知識加值系統。國立成功大學地球科學研究所。碩士論文。

89. 謝有忠、唐昭榮、邱禎龍、陳宏仁、費立沅、陳勉銘、…、胡植慶
(2017)。莫拉克颱風受災區域潛在大規模崩塌之光達數值地形判
釋應用及地表位移觀測。工程環境會刊，37。
[https://doi.org/10.6562/JEE.201712_\(37\).0002](https://doi.org/10.6562/JEE.201712_(37).0002)
90. 羅佳明、鄭添耀、林彥享、蕭震洋、魏倫瑋、黃春銘、…、林銘郎
(2011)。國道3號七堵順向坡滑動過程之動態模擬。中華水土保持
學報，42(3)，175-183。
91. 蘇泰維、謝有忠、劉榮斌(2010)。國道3號災前災後的地形演變。
地質，29(2)，16-19。

附錄

附錄 1 地質組成對應表

礫石、砂及泥	1
石墨片岩與石英雲母片岩	2
綠色片岩、砂質片岩、層狀大理岩	3
千枚岩、雲母片岩、石英雲母片岩	4
厚層砂岩	5
厚層變質砂岩，偶夾薄層板岩	6
火山岩流、火山角礫岩與再積性火山碎屑岩	7
石墨片岩及石英雲母片岩,夾綠泥石片岩及變質燧石	8
變質基性或超基性岩	9
黏土、砂及礫	10
礫岩夾厚層砂岩	11
砂頁岩互層	12
抱球藻、有孔蟲與珊瑚石灰岩	13
安山岩質崩移岩塊	14
蛇紋岩	15
層狀大理岩	16
石英片岩或副片麻岩	17
片麻岩	18
角閃岩	19
板岩、千枚岩、變質砂岩及變質石灰岩	20
透鏡狀大理岩體	21
泥岩夾礫岩	22

板岩或千枚岩，偶夾薄層變質砂岩	23
角閃岩及角閃石片岩	24
片麻岩及花崗片麻岩	25
所夾之變質基性岩	26
所夾之硬綠泥石岩透鏡體	27
片麻岩及變質似花崗岩類	28
千枚岩、變質砂岩及變質燧石	29
石英雲母片岩	30
角閃岩或角閃石片岩	31
大理岩及石英雲母片岩	32
泥岩夾有各種不同的外來岩塊	33
泥岩與砂頁岩互層	34
石英片岩、石英岩、雲母石英片岩	35
板岩，厚層變質砂岩與板岩互層	36
砂岩及頁岩互層	37
厚砂岩及頁岩，含化石富集層	38
厚層石英岩質砂岩與長石質砂岩，夾薄互層，部份 砂岩為粗粒至小礫，頂部夾薄煤層	39
厚層砂岩、粉砂岩、泥岩之互層，偶夾薄層礫岩	40
泥質砂岩，砂岩及頁岩互層	41
礫石、砂及黏土	42
礫石，砂及黏土	43
頁岩夾薄層砂岩	44
厚層頁岩夾薄砂岩	45
板岩與薄層砂岩或粉砂岩互層	46

厚砂岩、白砂岩、及砂岩頁岩互層，含煤層	47
泥質砂岩及鈣質砂岩夾頁岩	48
砂岩及頁岩薄互層，夾數層厚砂岩	49
紅土，礫石，夾薄層砂岩	50
塊狀砂岩，白砂岩，砂岩及頁岩互層，含煤層	51
厚層頁岩偶夾薄層砂岩	52
紅土、礫石、砂、粉砂及粘土	53
硬頁岩與板岩	54
塊狀砂岩、粉砂岩及頁岩	55
砂岩及頁岩互層，含煤層	56
塊狀砂岩夾頁岩	57
泥質砂岩、粉砂岩及頁岩	58
頁岩	59
砂岩與頁岩互層	60
砂岩，泥岩，頁岩互層	61
紅土，紅壤化之礫石，砂，砂及粉砂之透鏡體	62
砂岩，泥岩，頁岩	63
砂岩及頁岩	64
礫石、砂、粉砂及黏土	65
泥質砂岩，頁岩	66
礫石夾砂岩之凸鏡體	67
礫岩，砂岩，泥岩互層	68
水體	69
厚層變質砂岩	70
砂岩、泥岩、頁岩互層	71

礫石，砂及粘土	72
泥質砂岩夾頁岩	73
礫石夾砂岩之透鏡體	74
砂質頁岩、粉砂岩及薄層粗砂岩夾薄層礫岩	75
泥岩及砂質頁岩	76
變質砂岩	77
厚層細粒砂岩夾硬頁岩	78
板岩夾砂岩與粉砂岩薄層	79
粉砂岩和頁岩薄互層	80
塊狀頁岩，偶夾薄層粉砂岩	81
厚層塊狀砂岩和泥質砂岩	82
粉砂岩夾頁岩、砂質頁岩，或與泥質砂岩互層	83
中至細砂	84
板岩及變質砂岩與板岩薄互層	85
回填砂、泥及礫石	86
砂岩、泥岩及砂頁岩的薄互層	87
石英岩質砂岩、硬頁岩及其互層	88
厚層部份礫石質砂岩、硬頁岩及板岩	89
砂、泥及礫石	90
粉砂岩、砂岩與頁岩互層	91
厚層砂岩及頁岩，偶夾薄互層與化石富集層	92
厚層礫岩間夾砂岩或泥岩凸鏡體	93
礫石、砂、泥及泥炭	94
粉砂岩及頁岩	95
塊狀砂岩，粉砂岩，砂岩夾頁岩及砂、頁岩互層	96

礫岩，間夾薄層泥質粉砂岩	97
泥質砂岩、泥質砂岩與頁岩互層	98
砂岩及砂頁岩互層	99
砂、粉砂、泥及礫石	100
泥質砂岩，粉砂岩及頁岩	101
塊狀砂岩，粉砂岩及頁岩	102
頁岩及粉砂岩	103
頁岩夾砂岩	104
泥、砂及礫石	105
頁岩間夾薄層粉砂岩	106
礫石、砂及粘土	107
下部凝灰角礫岩	108
含角閃石兩輝石安山岩	109
上部凝灰角礫岩	110
頁岩及砂岩	111
塊狀砂岩	112
砂，粉砂	113
含橄欖石角閃石輝石安山岩	114
兩輝石角閃石安山岩	115
玄武岩	116
塊狀白砂岩	117
砂岩，粉砂岩及頁岩	118
厚層細砂岩或粉砂岩、細砂岩及粉砂岩厚互層	119
頁岩和砂質頁岩	120

凝灰岩及安山岩質岩流	121
板岩夾薄層粉砂岩	122
厚層塊狀白色中至粗粒石英砂岩及板岩互層，夾綠色岩	123
砂岩、泥岩、砂頁岩互層	124
凝灰岩及玄武岩質岩流	125
厚層砂岩、粉砂岩、頁岩之互層，偶夾薄層礫岩	126
硬頁岩或板岩間夾透鏡狀砂岩體	127
透鏡狀砂岩體	128
板岩為主間夾變質砂岩，夾有變質火成岩透鏡體	129
砂岩、泥岩及頁岩互層	130
混濁砂岩間夾砂、頁岩互層及薄層礫岩	131
礫岩夾厚層至薄層砂岩	132
礫石、砂、粉砂及粘土	133
礫石夾凸鏡體砂岩	134
紅土，礫石，砂和砂及粉砂之透鏡體	135
砂	136
泥質砂岩，白砂岩及頁岩互層	137
玄武岩質凝灰岩及岩流	138
頁岩夾砂岩，含凝灰質透鏡體與海綠石層	139
厚層頁岩夾透鏡狀薄砂岩，及薄粉砂岩與頁岩互層	140
砂岩、泥岩及頁岩	141
砂岩、粉砂岩、頁岩之互層，偶夾薄層礫岩	142
厚層泥岩間夾砂岩與礫岩	143
鳳山石灰岩，生物泥粒岩或粒泥岩及生物泥礫岩或礫泥岩	144
厚層礫岩與泥岩互層，偶夾席狀或透鏡狀砂岩	145
厚層砂岩、泥質砂岩間夾有厚層的薄砂、頁岩互層，及厚層炭質頁岩夾砂岩層	146
砂岩夾頁岩	147
礫岩、砂岩、砂質頁岩和泥岩	148
青灰色泥岩偶夾薄砂岩層	149
頁岩為主，夾厚塊狀泥質粉砂岩及層狀泥質砂岩	150
塊狀頁岩	151
硬頁岩或板岩	152
厚層砂岩和泥質砂岩	153
玄武岩質火成碎屑岩和熔岩流	154

厚層粉砂岩，及粉砂岩和砂岩厚互層	155
綠色變質火成岩	156
安山岩質或玄武岩質火成岩	157
板岩、千枚岩及變質砂岩	158
頁岩和薄砂頁岩互層，夾有厚層砂礫岩透鏡體	159
結晶石灰岩	160
凝灰角礫岩	161
硬頁岩、硬頁岩與變質砂岩之薄互層	162
硬頁岩或板岩夾薄至厚層泥質粉砂岩	163
薄至厚層粉泥質砂岩與硬頁岩互層	164
硬頁岩夾薄至厚層泥質粉砂岩及細砂岩	165
兩輝石安山岩	166
紅土，礫石，砂及砂與粉砂之透鏡體	167
橄欖石普通輝石安山岩	168
砂岩及泥岩互層，上部夾礫岩層	169
泥岩，粉砂岩，頁岩及砂岩互層，夾礫石層	170
普通輝石橄欖石玄武岩	171
角閃石兩輝石安山岩	172
紫蘇輝石角閃石安山岩	173
紅土及砂	174
紫蘇輝石黑雲母角閃石安山岩	175
礫石及砂，夾砂及粉砂凸鏡體	176
砂岩及頁岩互層，夾粗粒或礫石質砂岩	177
紅土，礫石，砂及粘土	178
塊狀砂岩及頁岩	179
厚層塊狀砂岩夾頁岩	180
砂岩及頁岩互層，含薄煤層	181
硬頁岩夾薄至厚層砂岩	182
火成岩	183
頁岩、砂質頁岩及泥岩	184
厚層泥岩間夾砂岩與礫岩	185
泥岩夾砂岩	186
所夾之礫質泥岩	187
普通輝石角閃石安山岩	188
角閃石安山岩	189
大屯山凝灰角礫岩	190
石英安山岩	191

玄武岩質凝灰岩	192
砂岩，塊狀砂岩夾頁岩	193
紅土，砂，礫石，夾砂及粉砂岩凸鏡體	194
砂岩，粉砂岩，頁岩及泥岩互層，間夾礫石層	195
硬頁岩與變質砂岩之薄互層	196
安山岩質凝灰岩	197
硬頁岩夾泥質砂岩	198
煌斑岩	199
頁岩及砂質頁岩	200
玄武岩質凝灰岩及熔岩流	201
礫石，砂及泥	202
礫石、砂、泥	203
硬頁岩或板岩，偶夾薄層變質砂岩	204
砂岩及頁岩互層，夾礫石質砂岩	205
頁岩，砂質頁岩及泥岩	206
頁岩及頁岩夾薄層粉砂岩	207
所夾之石灰岩	208
泥質砂岩、砂質頁岩及厚砂岩	209
石灰岩	210
泥岩	211
砂岩	212
泥岩及砂岩互層	213
半屏山石灰岩，生物泥粒岩及礁灰岩體	214
高雄石灰岩，生物粒泥岩及礁灰岩體	215
珊瑚石灰岩岩塊	216
所夾之玄武岩	217
所夾之砂岩	218
剪動的泥岩夾各種外來岩塊	219
所夾之安山岩	220
礫岩夾砂岩	221
紅土、礫石、砂及粘土	222
所夾之蛇紋岩	223
所夾之輝長岩	224
珊瑚礁、砂及礫	225
礫岩、砂與紅土	226
顆粒石灰岩及黏結石灰岩	227
所夾之蛇綠岩	228

砂岩，底部含礫	229
厚層砂岩間夾礫岩	230
泥岩及外來岩塊	231
砂質礫岩	232
厚層砂岩及砂頁岩互層	233
藍灰色泥質砂岩或砂質泥岩	234
泥岩及粉砂岩和頁岩互層	235
火山角礫岩，凝灰岩與中酸凝灰岩	236
砂岩、粉砂岩、泥岩和頁岩之互層	237
硬頁岩、板岩、砂頁岩互層	238
再積性火山碎屑岩，凝灰質砂岩與石灰岩質礫岩	239

附錄 2 土地利用對應表

水田	1
旱田	2
果園	3
水產養殖	4
畜牧	5
農業相關設施	6
針葉林	7
闊葉林	8
竹林	9
混淆林	10
灌木林	11
其他森林利用土地	12
機場	13
一般鐵路及相關設施	14
國道	15

省道	16
一般道路	17
道路相關設施	18
港口	19
河道	20
堤防	21
溝渠	22
湖泊	23
蓄水池	24
水道	25
水例構造物	26
防汛道路	27
海面	28
商業	29
純住宅	30
混合使用住宅	31
製造業	32
倉儲	33
宗教	34
殯葬設施	35
其他建築用地	36
政府機關	37
學校	38
醫療保健	39
社會福利設施	40

公用設備	41
環保設施	42
文化設施	43
公園綠地廣場	44
休閒設施	45
礦業及相關設施	46
土石及相關設施	47
濕地	48
草生地	49
裸露地	50
營建剩餘土石收容處理相關設施	51
空置地	52
快速公路	53
水庫	54
鹽業及相關設施	55
高速鐵路及相關設施	56
捷運及相關設施	57

附錄 3 期初審查會議記錄暨回覆辦理情形

項次	審查意見	處理情形
一	除了現有的地質、地形和降水資料，建議加入道路、邊坡開發等人為因子和地震活動等因素，以更全面地評估崩塌風險。	感謝委員意見，已於內文「訓練特徵的選擇及前處理」中新增更完善的特徵。並且也將兩型崩塌與同震崩塌分開進行更縝密地討論。
二	模型中可更深入的探討資料網格間的相關性，並探討如何利用多尺度訊息整合，提升崩塌潛勢評估的精準度。另本計畫提到在不同尺度下資料之間的關聯性差異，建議可建立多尺度模型架構，以滿足不同尺度的崩塌潛勢評估需求。	感謝委員意見，考量到模型訓練所需的資料數有所限制，當資料網格太大時可能會導致模型訓練不佳的問題。本研究將會在可行的程度內盡可能嘗試多尺度的模型建置並進行評估及比較，以解決多尺度訊息差異的問題。
三	研究充分利用機器學習方法（如 Transformer 和 GAMI-Net），提升崩塌潛勢評估的精確性，但模型的實務應用細節	感謝委員意見，已於內文「模型潛在應用」補充模型建置完成後之應用面。

	說明尚顯不足。	
四	歷史崩塌資料的蒐集與更新是研究的重要基礎，但對於資料可能存在的時空偏差處理方式，文件中未明確提及。	感謝委員意見，在前期計畫中的確面臨這項問題，即所取得的歷史崩塌資料可能為單一年度整體判釋成果，無法精確對應實際降水事件。本期計畫將使用事件型崩塌目錄並搭配對應的時雨量紀錄或地震紀錄以降低時空偏差之問題。
五	四種模型（mlp_no_his、mlp_his、att_no_his、att_his）之評估比較具體，但對於適用性與限制的分析不夠全面。	感謝委員意見，已於內文「已完成之重要計畫成果摘要」進行簡單的模型描述及適用場景。
六	文件中提到模型在不同地質條件下的表現可能下降，顯示模型跨區域應用的挑戰需更深入探討。	感謝委員意見，委員提及的問題便是本期計畫擬著重解決之問題，已於內文中提出兩種解決思路（單一大模型及多模型整合），並且會重點評估後續之實際應用成效。

七	建議增加更直觀的可視化方式，如動態崩塌潛勢地圖，方便決策者快速理解和應用。	感謝委員意見，已於內文「模型潛在應用」新增計畫後期目標，考慮建立氣候變遷條件下動態崩塌成果展示方法，惟時間因素，本期計畫內無法完成。
八	建議可分配更多資源進行現地調查，驗證模型結果與實際情況的吻合程度。	感謝委員意見，本期計畫將會盡可能多地進行現地調查已評估模型結果的真實性。
九	以歷年崩塌資料進行後續的分析，必須先釐清崩塌地的舊崩、新崩、再崩等差異及範圍，以提高模型訓練的品質。	感謝委員意見，委員提及之內容實為重要影響因素，已於「研究區域歷史崩塌資料更新」新增此面向之相關說明。
十	單一大模型與多模型之參數量是否相同？統計模型的執行成果係建立在各參數的準確性，惟因計畫所選取的參數量眾多，如何保證參數數據的品質？	感謝委員意見，委員所謂「參數量」指的是特徵數量亦或是模型本身可訓練之參數量。若為特徵量，預計於單一大模型及多模型中所使用的會一致，而訓練參數量須於實際計畫進

		行過程中逐步調整及改良。參數數據的品質方面，本研究擬參考前人研究、並從統計面、技術面上多方考量數據產製的流程及結果，以力求降低數據品質不佳的可能性。
十一	圖六層次分析法未列出各層因子，實無法審視其適合性。	感謝委員意見，本研究於計畫書中擬使用之層次分析法非直接使用人為設計的層次分析法進行分析，而是將其作為一個環節結合至機器學習模型中，因此各層因子將會由模型本身透過權重、重要性評估來決定。不過透過文獻探討各種可解釋性模型架構及仔細評估後，目前將不再透過層次分析法建立可解釋性模型。

附錄 4 期末成效評核及審查意見辦理情形

項次	審查意見	處理情形
一	若未來欲建立全臺尺度之模式，請教可如何克服跨不同地質區之資料差異問題？	感謝委員意見，全台評估模式一直是受限於資料完整度及區域現況差異而難以在各區域有相同的成效。本研究嘗試了使用多個地質區的資料進行訓練、以及於各地質區進行分別的訓練的方案，結果顯示於各地質區分別建置專屬模型可以達到較好的效果。因此未來欲建置全台尺度的模式，我們認為應於一致的流程下分區施作，可最大程度的克服不同區域之資料差異問題。
二	於 SHAP 分析中，主要影響因子在各樣區間大致趨於一致，惟其後順位之因子影響性變動幅度相當大，甚至出現不	感謝委員意見，崩塌因子重要性評估結果中，確實有這樣的情況發生。針對非主要因子重要性變動幅度於不同研究區較

	同樣區影響趨勢不一致之情形，其可能原因為何？是否可從物理機制層面加以解釋？	大的問題主要是因為不同地質區本身固有條件差異所造成（第四節第一章之一），崩塌的類型及運動行為可能因為這些差異而不一致，使得最後觀察到的重要性也不同。因我們的研究本身仍屬於統計式的評估結果，若要從物理機制層面加以解釋，仍需更進一步的現地調查及案例評估。
三	水文因子之設定仍缺乏前瞻性評估，偏重理論推導；邊坡開發、地震活動等因素尚未有效納入分析	感謝委員意見，本期用於建置模型的水文因子確實仍稍嫌僵化，並且無法代表整個降雨歷程，因此未來若能以有長期地下水位面、地表逕流及雨量監測，結合側傾管及張力計等即時崩塌變位監測資料的案場作為評估的參考資料，或可達到更與現地結合的評估結果；也

		可透過結合未來氣候變遷推估資料，進行更多的崩塌潛勢加值應用。另外本期計畫中我們已經透過增加順向坡資料、調整道路距密度及使用多期 NDVI 和 NDBI 的方式盡量考慮了人為活動，未來若有邊坡開發與崩塌案例相關性的資料，我們會嘗試加入進行評估。而地震活動造成的崩塌已在本期研究中與兩型崩塌分開考慮，以 PGA 的方式納入因子考量並獨自建模。或許未來我們可以嘗試更多與其他單位合作，獲取更多崩塌案場附近之地動訊號紀錄並加以評估。
--	--	---