

計畫編號：ARDSWC-113-069

**以機器學習方法建立結合歷史崩塌及空間
關聯性的崩塌潛勢評估模型**

**A machine learning-based model for
assessing landslide susceptibility
combining historical landslides and spatial
correlations**

(成果報告書)

執行單位：國立台灣大學

執行期間：113 年 02 月 07 日至 113 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 113 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的崩塌潛勢評估模型

摘要

台灣地處板塊交界帶，受造山運動及季風氣候影響，形成高強度侵蝕環境，崩塌發生頻繁。因此，事前預警及防減災對坡地安全十分重要。隨著地理資訊系統（GIS）和大數據發展，使探討地文、水文、及人文等因子對坡地穩定的影響成為可能，其中透過機器學習建置崩塌潛勢評估模型是目前受矚目的方式之一。

傳統機器學習研究多以易取得的地形、地質、水文等資料為模型訓練特徵，但在崩塌頻發的台灣，已發生崩塌地區的穩定性及植被覆蓋相對較差，易再次崩塌。因此，本研究以歷史崩塌事件作為模型訓練的特徵之一，並探討其重要性。另外，由於崩塌事件範圍不定且規模不一，網格切分易使相鄰網格相關性消失，影響模型評估準確性。因此，本研究引入自然語言轉譯領域的自注意力機制，自動化全局考量序列中各單元相關性，以解決網格間獨立性的問題。期許能夠建立廣範圍、高精度的崩塌潛勢評估模型。

現階段結果顯示，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）。而自注意力方法使模型在 precision 及 recall 中取得較好

平衡並降低資料偏誤造成之缺陷，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。

關鍵字：崩塌潛勢、歷史崩塌、自注意力機制、機器學習、崩塌評估

Abstract

Taiwan is located at the convergence zone of tectonic plates and influenced by orogeny and monsoon climate, resulting in an environment characterized by intense erosion and frequent landslides. Therefore, proactive warning systems and disaster mitigation measures are of crucial for slope safety. With the advancement of geographic information systems (GIS) and big data, the exploration of the impact of physical, hydrological, and anthropogenic factors on slope stability has become feasible. Among them, the construction of landslide susceptibility prediction models through machine learning stands out as a currently prominent approach.

Conventional machine learning studies often utilize easily accessible topographical, geological, and hydrological data as features for the model training. However, in Taiwan, areas with historical landslides exhibit lower stability and vegetation cover, making them susceptible to recurring landslides. Hence, this study incorporated historical landslides as one of the model training features and assessed its importance. Furthermore, due to the variable extent and scale of landslides, grid partitioning can lead to the disappearance of correlation between neighboring grids, thereby affecting the accuracy of model predictions. Therefore, this research introduced a self-attention mechanism from the natural language processing domain to automatically and globally consider the correlation of each unit in a sequence to address the issue of grid independence. The goal is to establish a wide-ranging and high-precision landslide susceptibility prediction model.

The results show a substantial improvement in the model's predictive

ability after incorporating historical landslides, having significant enhancements in both precision and recall, irrespective of spatial correlation considerations (F1_scores increased by 0.38 and 0.51 in the mlp and att models, respectively). The self-attention method enables the model to achieve a better balance between precision and recall, reducing defects induced by data biases, and is more suitable for practical disaster mitigation operations. In regions with significant geological differences, the evaluation model established in this study maintains good generalizability (with F1_scores remaining around 0.7). When assessing events from different years, the model consistently exhibits high-level performance in most cases (F1_scores remain above 0.6), demonstrating temporal generalizability. In comparison to previous studies, this research achieves a more stable and robust landslide prediction performance.

keywords : landslide susceptibility 、 historical landslide 、 Self-attention 、 machine learning 、 landslide assessment

目次

摘要	I
Abstract	III
目次	V
圖次	VIII
表次	XIII
第一章 緒論	1.1
第一節 計畫研究動機及目的	1.1
一、研究動機	1.1
二、研究目的	1.2
第二節 相關文獻蒐整	1.3
一、崩塌機制及衝擊	1.3
二、機器學習建置崩塌潛勢地圖	1.5
三、機器學習及深度神經網路	1.7
四、機器學習模型差異	1.12
五、特徵值選擇差異	1.15
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	2.5
一、研究區域選擇	2.5

二、地形.....	2.7
三、地質條件.....	2.9
四、氣候及水文特性.....	2.11
五、崩塌地概述.....	2.14
六、崩塌資料庫的建置.....	2.14
七、訓練特徵的選擇及前處理.....	2.17
八、神經網路原理及模型設計邏輯.....	2.25
九、模型架構.....	2.39
十、訓練流程.....	2.41
十一、評估方法.....	2.45
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、特徵可用性.....	4.1
二、特徵共線性.....	4.1
三、特徵重要性.....	4.3
四、模型評估成果.....	4.4

五、崩塌圈繪地圖	4.7
第二節 建議	4.12
一、歷史崩塌作為崩塌預測模型特徵的重要性	4.12
二、空間關係之於推測的效果	4.13
三、模型在空間上的泛用性	4.21
四、模型在時間上的泛用性	4.29
五、研究需改善問題	4.34
參考文獻	參.1
附錄	附錄.1

圖次

圖 1- 1 崩塌領域機器學習模型發展歷程（修改自 Tang 等，2022）	1.6
圖 1- 2 卷積神經網路模型（Qin 等人，2022）	1.13
圖 1- 3 Transformer 模型架構（Vaswani 等，2017）	1.14
圖 1- 4 崩塌評估模型使用特徵比例圖（改寫自溫振宇，2005）	1.16
圖 2- 1 探討歷史崩塌運用於崩塌潛勢評估模型建置流程圖	2.2
圖 2- 2 探討應用空間相關演算法發展崩塌潛勢評估模型流程圖	2.3
圖 2- 3 崩塌潛勢評估模型優化及應用流程圖	2.4
圖 2- 4 研究區域（a）：訓練區域；（b）：測試區	2.6
圖 2- 5 研究區域高程分布（a）：訓練區；（b）：測試區	2.8
圖 2- 6 研究區域坡度分布（a）：訓練區；（b）：測試區	2.8
圖 2- 7 研究區域坡向分布（a）：訓練區；（b）：測試區	2.9
圖 2- 8 訓練區域地質圖（修改自經濟部中央地質調查所，2013）	2.10
圖 2- 9 研究區域各月份年均降水分布（統計自 2010–2014 年）（a）： 訓練區；（b）：測試區	2.12
圖 2- 10 研究區域降水分布（統計 2010–2014 年；TCCIP，2022） （a）：訓練區；（b）：測試區	2.13
圖 2- 11 不同介面下不同波段之反射強度（Serra-Ruiz 等，2019）	2.22

圖 2- 12 神經網路模型示意圖（Glosser.ca，2013）	2.26
圖 2- 13 常見自注意力機制	2.32
圖 2- 14 自注意力機制過程圖 1	2.34
圖 2- 15 自注意力機制過程圖 2	2.34
圖 2- 16 自注意力機制過程圖 3	2.34
圖 2- 17 自注意力機制過程圖 4	2.35
圖 2- 18 模型設計邏輯及資料流概念圖	2.39
圖 2- 19 自注意力模型與普通神經網路模型結構圖	2.41
圖 2- 20 訓練過程中訓練準確率（紅線）及驗證準確率（藍線）變化 圖	2.45
圖 3- 1 計畫進度甘特圖.....	3.1
圖 4- 1 模型評估能力柱狀圖	4.6
圖 4- 2mlp_no_his 崩塌潛勢圖及崩塌圈繪圖	4.8
圖 4- 3mlp_his 崩塌潛勢圖及崩塌圈繪圖	4.9
圖 4- 4att_no_his 崩塌潛勢圖及崩塌圈繪圖.....	4.10
圖 4- 5att_his 崩塌潛勢圖及崩塌圈繪圖.....	4.11
圖 4- 6 崩塌圈繪範圍比較圖（a）真實崩塌範圍；（b）mlp_his 崩塌圈	

繪範圍；(c) att_his 崩塌圈繪範圍	4.15
圖 4- 7 網格資料神經網路模型 (mlp) 與斜坡單元資料神經網路模型 比較圖	4.16
圖 4- 8 斜坡單元無歷史崩塌 (SU_no_his) 5 類崩塌潛勢地圖	4.17
圖 4- 9 斜坡單元無歷史崩塌 (SU_no_his) 崩塌圈繪地圖	4.18
圖 4- 10 斜坡單元有歷史崩塌 (SU_his) 5 類崩塌潛勢地圖	4.19
圖 4- 11 斜坡單元有歷史崩塌 (SU_his) 崩塌圈繪地圖	4.20
圖 4- 12 測試區 2 範圍：谷關、天輪調整池集水區	4.23
圖 4- 13 測試區 1 與測試區 2 模型評估結果比較圖	4.24
圖 4- 14 mlp_no_his 崩塌潛勢圖及崩塌圈繪圖 (測試區 2)	4.25
圖 4- 15 mlp_his 崩塌潛勢圖及崩塌圈繪圖 (測試區 2)	4.26
圖 4- 16 att_no_his 崩塌潛勢圖及崩塌圈繪圖 (測試區 2)	4.27
圖 4- 17 att_his 崩塌潛勢圖及崩塌圈繪圖 (測試區 2)	4.28
圖 4- 18 時間泛用性示意圖	4.29
圖 4- 19 歷史崩塌使用年份比較圖	4.31
圖 4- 20 不同年度模型評估能力比較圖	4.33
圖 4- 21 2009、2012、2015、2018 年年均降水及標準差	4.33
圖 4- 22 多元模型解	4.35

圖 4- 23 單一模型解.....	4.36
圖 4- 24 mlp_no_his 崩塌潛勢圖及崩塌圈繪圖（訓練區+荖濃溪部分範圍；2024 年度）	4.38
圖 4- 25 mlp_his 崩塌潛勢圖及崩塌圈繪圖（訓練區+荖濃溪部分範圍；2024 年度）	4.39
圖 4- 26 att_no_his 崩塌潛勢圖及崩塌圈繪圖（訓練區+荖濃溪部分範圍；2024 年度）	4.40
圖 4- 27 att_his 崩塌潛勢圖及崩塌圈繪圖（訓練區+荖濃溪部分範圍；2024 年度）	4.41
圖 4- 28 mlp_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 1；2024 年度）	4.42
圖 4- 29 mlp_his 崩塌潛勢圖及崩塌圈繪圖（測試區 1；2024 年度）	4.43
圖 4- 30 att_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 1；2024 年度）	4.44
圖 4- 31 att_his 崩塌潛勢圖及崩塌圈繪圖（測試區 1；2024 年度）	4.45
圖 4- 32 mlp_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2；2024 年度）	4.46
圖 4- 33 mlp_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2；2024 年度）	4.47

.....	47
圖 4- 34 att_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2；2024 年度）	
.....	4.48
圖 4- 35 att_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2；2024 年度）	4.49
圖 4- 36 凱米颱風桃源區勤和里土砂災例速報（資料來源：農業部農村發展及水土保持署）	4.50
圖 4- 37 凱米颱風六龜區中興里土砂災例速報（資料來源：農業部農村發展及水土保持署）	4.51

表次

表 2- 1 歷史崩塌圈繪判釋資料來源	2.16
表 2- 2 常見激發函數說明	2.28
表 2- 3 自注意力機制流程表	2.35
表 2- 4 模型代號表.....	2.38
表 2- 5 超參數設定表.....	2.42
表 2- 6 模型訓練設定表.....	2.43
表 2- 7 混淆矩陣.....	2.46
表 2- 8 模型評估能力指標表	2.46
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 共線性問題評估結果	4.2
表 4- 2 隨機森林方法評估特徵重要性	4.3
表 4- 3 各模型評估指標.....	4.6

第一章 緒論

第一節 計畫研究動機及目的

一、研究動機

崩塌是在丘陵及山區常見的自然災害之一，會導致生命損失、財產損失、及經濟衝擊，並且由於全球氣候變遷造成的影響，極端降水事件的增加進一步使更多的區域受到崩塌災害的衝擊，因此如何有效地研究並評估崩塌的發生原因及帶來的損害是全球範圍內共同面對的課題。而台灣由於本身破碎的地質條件及多樣的誘發因子，更是崩塌災害頻發的地區。

台灣現行的崩塌災害預警系統是行政院農業部農村發展及水土保持署訂定的大規模崩塌警戒系統，透過監測降雨量及地表與地層變動資料，輔以統計方法建立之降雨量及位移量警戒值，作為判斷大規模崩塌發生的警戒依據。良好的監測方式若輔以可以推測可能發生崩塌的區域的評估模型，或可增加防災減災系統的完整性。

機器學習方法中，以崩塌範圍圈繪及崩塌潛勢評估為兩大主要發展方向，但在崩塌圈繪及部分崩塌潛勢評估的研究，是利用「事件後或事件當下」的資料，這雖然提供模型較高的準確度，但受限於使用的資

料，只能做到受損害範圍的快速評估，而沒有「對未來預警」的功用。

因此，本研究旨在研究如何透過改進模型建置方法及過程，使「評估模型」具有真正猜測未知崩塌的能力並提供有效的崩塌潛勢地圖，使防、減災相關單位能夠加以參考以進行早期應對，是一亟具挑戰性的任務。

二、研究目的

- (一) 了解透過機器學習方法進行崩塌潛勢評估時，歷史崩塌事件對於崩塌發生之影響。
- (二) 透過設計並優化演算法，使崩塌預測過程得以考量崩塌行為的連續性及相關性。
- (三) 建置並優化可於事件發生前透過現有資料預先進行廣範圍且高精度的崩塌潛勢預測的機器學習模型，以期提供災害防治單位做為防減災相關政策之參考。

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（林冠璋，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；陳樹群與吳俊鎰，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塌地的崩塌發生機制及行為(李錫堤等，2009；唐昭榮等，2009；林冠瑋，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(陳樹群與吳俊鎰，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 1-1)




圖 1-1 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）。不過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）。

「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 decent）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 1-2），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 1-2），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 1-2 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 1-3)，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 1-3 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 1-4。




圖 1-4 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。不過由於演算法的不同，隨機森林演算法乃基於決策樹的集成式模型，無法得知在更加複雜且基於不同架構的深度神經網路模型中，加入考量歷史崩塌是否也能使推測崩塌的能力有所提升，此問題值得加以驗證及討論。

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，大致將介紹整個研究的進行邏輯及資料流向等概念，包含如何透過機器學習建立崩塌潛勢評估模型以了解歷史崩塌對於崩塌發育的影響（圖 2- 1）、透過自注意力機制（Self-attention）方法建立網格間空間相關性的效果（圖 2- 2）以及在不同條件下建置崩塌潛勢評估模型的優化過程（圖 2- 3）。




圖 2-1 探討歷史崩塌運用於崩塌潛勢評估模型建置流程圖




圖 2-2 探討應用空間相關演算法發展崩塌潛勢評估模型流程圖




圖 2-3 崩塌潛勢評估模型優化及應用流程圖

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（各種的地形、地質、降水條件），但是這樣的訓練時間將以週起算，不符合時間成本，在實用性上也大打折扣，因此，本研究選擇了以旗山溪集水區（圖 2- 4a）作為訓練區域（training set），其包含多種地形，並且是 2009 年八八風災受損嚴重的區域，這樣特殊的案例對於訓練資料的多樣性也有所提升。訓練區域東側為脊梁山脈，以旗山溪為分界，西側則隸屬於西部麓山帶南段（Chen 等，2016），整體呈現東北高、西南低的地形。

並且，為了測試模型的可用性，本研究還另外選擇隘寮溪集水區做為測試區域（testing set）（圖 2- 4b）。選擇此區域的原因是在前人研究中，機器學習模型評估的崩塌潛勢可能因為地質條件的巨大差距而表現不佳，因此選擇與訓練區域相鄰的區域測試或可避免這樣的問題。在

後續的研究區域介紹中，由於模型主要訓練及學習的對象是訓練區域，因此將著重於訓練區域的介紹。



(a)



(b)

圖 2-4 研究區域 (a)：訓練區域；(b)：測試區

二、地形

在訓練區域中為東北高、西南低的地形。高程分布於 25 m – 3300 m 左右，分布情形如圖 2- 5a，西側以低矮平原及丘陵地形為主，於楠梓仙溪東北側逐漸轉變為高於 1000 m 的山地。坡度分布情形如圖 2- 6a， $0 - 50^{\circ}$ （一級坡 – 五級坡）皆有分布，以三級坡及四級坡分布最廣（農業部，2020）。坡向分布則如圖 2- 7a，受河川流向及地形影響，以朝向西南西（ $240 - 270^{\circ}$ ）側的坡面為大宗。

在測試區中為東北及東南較高、西側較低的地形。高程分布於 25 m – 2700 m 左右，分布情形如圖 2- 5b，西側以低矮平原及丘陵地形為主，潮州斷層以東以隘寮北溪及隘寮南溪為局部低點，愈往東側高程漸升。坡度分布情形與訓練區域相似，不過 $10 - 20^{\circ}$ 佔比下降而 $40 - 50^{\circ}$ 佔比增加（圖 2- 6b）。坡向分布如圖 2- 7b，與訓練區相似，以朝向西南西的坡面為大宗。




圖 2-5 研究區域高程分布 (a): 訓練區; (b): 測試區




圖 2-6 研究區域坡度分布 (a): 訓練區; (b): 測試區




圖 2-7 研究區域坡向分布 (a)：訓練區；(b)：測試區

三、地質條件

在訓練區域內，以旗山溪及潮州斷層為大致分界，東側為脊山脈地質區：廬山板岩帶，西側為西部麓山帶地質區（Chen，2016）。

東側的地層由東到西以古近系古樓層（畢祿山層）及中新統早期潮州層為主，古樓層以板岩為主，偶夾薄層或厚層變質砂岩，局部夾有石灰岩；潮州層以板岩或硬頁岩夾薄層變質砂岩為主，偶夾厚層變質砂岩（Chen，2016），岩層受造山運動應力影響，多褶皺及板劈理發育（李錫堤等，2009）。

西側的地層由東到西以自中新統晚期紅花子層、長枝坑層、糖恩山砂岩、烏山層等，上新統鹽水坑頁岩、隘寮腳層、茅埔頁岩、竹頭崎層、

古亭坑層等，更新統北寮頁岩、玉井頁岩、六龜礫岩、崎頂層等，至全新統沖積層及階地堆積層皆有分布。東側主要以砂岩或砂頁岩互層為主，越往西側，如北寮頁岩或古亭坑層等則漸出現頁岩或泥岩層（圖 2-8）。受造山運動影響，多褶皺及逆衝斷層發育（Chen，2016）。

測試區由東至西地層分布為古樓層、潮州層、階地堆積層及全新統沖積層。與訓練區東側的地質條件相近。少量褶皺以東北—西南向分布。





圖 2-8 訓練區域地質圖（修改自經濟部中央地質調查所，2013）

四、氣候及水文特性

訓練區域屬於溫帶季風氣候（科本分類：Cwa、Cwb），呈現夏季高溫多雨，冬季乾燥的氣候，主要降水來源為受西南氣流帶來的水氣及颱風，降雨集中在 5 到 9 月（圖 2- 9a），年均降水約在 2800 毫米左右（統計自 2010–2014 年）。降水在空間上的分布情形如圖 2- 10a。測試區降水同樣集中在 5 到 9 月，但是降水情形與訓練區稍有不同，5 及 7 月降水佔比較訓練區低（圖 2- 9b），年均降水則在 3000 毫米左右（統計自 2010–2014 年）。在空間分布上如圖 2- 10b。

訓練區河流分布以東北–西南流向的旗山溪為主，旗山溪為高屏溪主流上游，河長約 133 公里，流域面積 2038 平方公里（圖 2- 10 藍色河網圖）。測試區的河流以隘寮溪及其支流（隘寮北溪、隘寮南溪）為主，主流河長約 69 公里，流域面積 829 平方公里。河流流向以東–西向為主（圖 2- 10 藍色河網圖）。

a



b






圖 2-9 研究區域各月份年均降水分布（統計自 2010 - 2014 年）(a)：訓練區；(b)：測試區



(a)



(b)

圖 2-10 研究區域降水分布 (統計 2010 - 2014 年; TCCIP, 2022) (a): 訓練區; (b): 測試區

五、崩塌地概述

在訓練區域中，崩塌主要發生於旗山溪兩側坡地，單一崩塌的平均面積為 $1.3 \times 10^4 \text{ m}^2$ ，最大崩塌面積 $2.7 \times 10^6 \text{ m}^2$ ，最小崩塌面積 919 m^2 。依據中央地質調查所山崩分類方法，崩塌型式以岩屑崩滑、岩體滑動為主，落石次之（楊樹榮等，2011；經濟部中央地質調查所，2022），其中岩體滑動的崩塌深度最深且崩塌範圍較大；岩屑崩滑次之，以崩積物的二次崩塌為致災主因；落石較少出現並且影響範圍不大。而測試區域中，崩塌的平均面積為 $1.5 \times 10^4 \text{ m}^2$ ，最大崩塌面積 $1 \times 10^6 \text{ m}^2$ ，最小崩塌面積 55 m^2 。崩塌型式同樣以岩屑崩滑、岩體滑動為主。

岩體滑動的崩塌發生部以溪流型崩塌為主，因研究區域多支流及溪澗，伴隨多節理、劈理的岩層特性，一旦坡腳解壓便極易產生破壞。而部分順向坡面上則因板岩裂隙破壞、或砂頁岩互層中，岩層介面的孔隙水壓在雨季驟升而易產生滑動，形成平面型崩塌(Nettleton 等, 2005)。

六、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；同時在目標年以前的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

將介紹崩塌資料的取得管道、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，本研究選擇以前人透過各種方法建置的崩塌圖層資料作為基準進行處理。

在經過比較前人研究後，本研究最終選擇使用「經濟部地質調查及礦業管理中心（原經濟部中央地質調查所（地調所），後以地礦中心簡稱）」發布的山崩雲圖台及其介接資料：多年期歷史山崩目錄。此目錄源自山崩與地滑地質敏感區劃定計畫書（經濟部中央地質調查所，2014）及山崩與地滑地質敏感區變更計畫書（經濟部中央地質調查所，2022）蒐整之多個計劃資料（如表 2-1），包含自 1980 年起至 2015 年由航空照片及衛星影像圈繪之崩塌裸露地，圈繪範圍包括崩塌區、運移區及堆積區，且地礦中心已預先刪除面積在 625 平方公尺以下的零碎崩塌。由於資料來源多樣化，某些年份可能圈繪相對不完整，因此，本研究經判斷資料完整性後刪除部分資料缺失無法覆蓋研究區域的年份，最終適合使用的年份為 1980、1990、1996、2001、2004、2005、2006、2007、2008、2009、2010、2012、2013、2014、2015 年。

表 2-1 歷史崩塌圈繪判釋資料來源

計劃名稱
民國 90 年以前判釋數化全臺山崩目錄（地調所）
都會區及周緣坡地整合性環境地質資料庫建置－坡地環境地質災害調查研究（地調所）
地質敏感區災害潛勢評估與監測－高山聚落地區地質災害基本調查（地調所）
莫拉克颱風災後重建計畫－國土保育之地質敏感地區調查分析計畫（地調所）
易淹水地區上游集水區地質調查及資料庫建置－集水區地質調查及山崩土石流調查與發生潛勢評估計畫（地調所）
山崩與地滑地質敏感區劃定資料加值建置計畫（地調所）
山崩與地滑地質敏感區進階劃定資料增建（地調所）
山崩與地滑地質敏感區變更資料更新暨準則執行檢討（地調所）
運用衛星影像於全島崩塌地判釋與災害分析（行政院農業委員會林務局）
災後衛星影像崩塌判釋報告（行政院農業委員會水土保持局）

(二) 崩塌資料處理

地礦中心在統籌建置多年期歷史山崩目錄時，各計畫中的崩塌圈繪方法是使用各年度的航空照片及衛星影像以人工（航照立體像對、航照及衛星影像）、自動判釋（衛星影像），部分輔以現地調查做初步圈繪。而地礦中心在統整各計畫成果後，進一步利用航照、高精度 LiDAR 坡度圖及 Google earth 進行檢核，另外也將平均坡度 30%（一級坡—三級坡）的崩塌地進行逐筆檢核（經濟部中央地質調查所，2022）。自地礦中心取得之成果原始為多邊形圖層（.json 檔案），本研究為增加運算效率及便於分析，故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。

七、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於崩塌評估的特徵：1. 地形特徵：高程、坡度、坡向、地形曲率（curvature）、地形濕度指數（Topographic Wetness Index，TWI）。2. 降水特徵：月均降水。3. 地質條件：地質組成。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)。

以上為基礎的訓練特徵，在考量歷史崩塌事件的訓練模型中另會加入不同年份的歷史崩塌作為特徵。

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 SAGA7.2 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 SAGA8.5.1 的套件 SAGA Wetness Index (Conrad 等，2015) 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，本研究使用臺灣氣候變遷推估資訊與調適知識平台 (<https://tccip.ncdr.nat.gov.tw/>) 產製的「臺灣歷史氣候重建日資料 (TReAD) (2022)」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/day 的 2 公里網格降水資料 (TCCIP, 2022)。

在雨量特徵的使用上，囿於崩塌資料是以年度為時間窗分割，目前難以確認各個崩塌事件對應之雨場，因此無法使用較為直接影響崩塌進程的降雨強度、降雨延時等資訊進行模型的建置。本研究認為平均降雨強度與邊坡長時間的穩定性有關，故使用月平均降水作為降水特徵，以聚焦於比較各個資料網格月平均降水的差異及對於崩塌造成的影響。

由於平台提供之原始資料為東、南、西、北各區域的 1980–2018 各年資料，因此，本研究先計算各年度的月平均降水供後續使用，並將各區域組合獲得全台範圍的各年度月均降水，而後使用 QGIS 中的不規則三角網插值 (TIN) 中 Clough-Toucher 函式 (QGIS.org, 2022) 進行插值運算，獲得網格化的月均降水分布。

(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。

考量到台灣地層劃分詳細，同年代且類似岩性的地層時有被劃歸為不同地層的現象出現，因此為了讓模型有較好的空間通用性，本研究採用屬性中的「岩性及組成」作為地質條件劃分依據，而非地層名稱。而後將其進行網格化使用。

(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) 圖徵，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，但在 100m 為間隔的情況下差異不顯著，且大於 1500m 後線狀構造對崩塌產生的影響甚微。又考量到台灣山高水急及破碎的地質條件，因此本研究使用 QGIS 中的 Buffer 工具（QGIS.org，2022）以線圖徵為中心選擇 300m、600m、900m、1200m、1500m 及以上作為分類，並將其網格化後使用。

(五) 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 2-11），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 2-11 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 5（Landsat 8 發射於 2013 年），運用 QGIS 的影像計算功能

(QGIS.org, 2022) 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。

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

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

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。

(六) 特徵可用性探討

儘管以上提及的訓練特徵都常見於前人文獻中，但為了確定各個特徵在台灣地理環境下是否實際對於崩塌地發生具有影響，本研究引入了 Frequency Ratio Method (FR) 作為評估標準，使用 Jenks 的 Natural Breaks 分類方法 (Jenks 與 Caspall, 1971) 對特徵進行分類，並透過式 5 計算出的 FR 值，代表了某一項特徵對於崩塌發生的影響程度，當其值大於 1 時表示能用於崩塌評估模型的訓練 (Li 等, 2021)。

$$FR = \frac{\text{the area of landslides in feature}_i \text{ area} / \text{the area of landslides in the study area}}{\text{the area of the feature}_i \text{ area} / \text{the area of the study area}} \quad \text{式 5}$$

(七) 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 6）作為評估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，通常以 $VIF > 5$ 作為閾值決定是否需要刪除某項參數（Rogerson，2001）。

$$VIF_i = \frac{1}{1 - R_i^2} \quad \text{式 6}$$

式 6 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）。

(八) 特徵重要性探討

由於在神經網路類型的機器學習模型中，因原理及架構的原因，我們無法直觀的了解到某一項特徵在分類過程佔的重要性。因此，本研究使用隨機森林模型作為特徵權重分析的工具。隨機森林模型是基於多組決策樹進行投票以獲取判斷基準的模型，並且決策樹的判斷是根據可直觀了解的基準進行判斷，因此得以在模型建立後，了解各項特徵對於影響崩塌發生與否的權重。本研究於透過訓練出一具有一定崩塌評估能力的隨機森林模型（F1_socre：0.587），以取得各特徵在其中所佔的重要性。這樣的方法雖然無法正確代表本研究的模型實際狀況，但是可以從另一個面向瞭解機器在面對此分類問題可能的判斷邏輯。

八、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- 12）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 2-12 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 2-2。

表 2-2 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 7 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 8。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。

$$a_p^{k+1} = A(w_0^p a_0^k + w_1^p a_1^k + w_2^p a_2^k + \dots + w_n^p a_n^k + b_p) \quad \text{式 7}$$

$$\begin{bmatrix} a_0^{k+1} \\ a_1^{k+1} \\ \vdots \\ a_p^{k+1} \end{bmatrix} = A \left(\begin{bmatrix} w_0^0 & w_1^0 & \dots & w_n^0 \\ w_0^1 & w_1^1 & \dots & w_n^1 \\ \vdots & \vdots & \ddots & \vdots \\ w_0^p & w_1^p & \dots & w_n^p \end{bmatrix} \begin{bmatrix} a_0^k \\ a_1^k \\ \vdots \\ a_n^k \end{bmatrix} + \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_p \end{bmatrix} \right) \quad \text{式 8}$$

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 9)、交叉熵 (Cross-entropy) (式 10) 等。

$$MSE = \frac{1}{n} \sum (y - \hat{y})^2 \quad \text{式 9}$$

$$H(p, q) = - \sum_x p(x) \log(q(x)) \quad \text{式 10}$$

式 9 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 10 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 (Back propagation)：

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 11 到式 14 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。

$$\delta^L = \nabla_a C \odot \sigma'(z^L) \quad \text{式 11}$$

$$\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l) \quad \text{式 12}$$

$$\frac{\partial C}{\partial b_j^l} = \delta_j^l \quad \text{式 13}$$

$$\frac{\partial C}{\partial w_{jk}^l} = a_k^{l-1} \delta_j^l \quad \text{式 14}$$

式 11 到式 14 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

在了解神經網路模型的基本原理後，接著將針對建立空間相關性最重要的自注意力機制（Self-attention）進行解釋，下圖 2-13a 及式 15 為整個自注意力機制的核心概念（改寫自 Vaswani 等，2017）。




圖 2-13 常見自注意力機制

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

式 15

圖 2-13 及式 15 中的 Q 、 K 、 V 分別代表的是 query (查詢)、key (鍵)、value (值) 的矩陣。在訓練區域中可能有 n 個網格，每一網格即為一個具有 k 維特徵的訓練樣本，神經網路就是在遍歷 n 個訓練樣本的過程透過反向傳播調整網路的權重及偏差，但是若每個網格(訓練樣本)之間具有一定的關係則無法被考量到。因此，電腦科學家建立了一套演算法以考量 n 個訓練樣本的全局相關性。方法如下：

1. 將 n 個訓練樣本 ($k \times 1$ 的向量) 皆分別乘上由函式隨機生成初始數值且可訓練的矩陣 W_q 、 W_k 、 W_v ($k \times k$ 的矩陣)，獲得每個樣本的 query、key、value ($k \times 1$ 的向量) (圖 2-14)。
2. 於第 i 個訓練樣本中將其 query 與包含自身所有訓練樣本的 key 分別做內積並過一個 Softmax 函數，獲得第 i 個樣本與所有訓練樣本的相似度指數 α (Attention score) (圖 2-15)。
3. 將每個訓練樣本的 value 乘上 α 後相加，獲得考量空間相關性後第 i 個訓練樣本的新向量 (圖 2-16)。
4. 將獲得的新向量輸入後續的神經網路模型中，透過反向傳播便可以訓練出對應此項學習任務的 W_q 、 W_k 、 W_v 三個矩陣 (圖 2-17)。




圖 2-14 自注意力機制過程圖 1




圖 2-15 自注意力機制過程圖 2

$$\sum_{j=1}^n \alpha_i^j \times v_i = a'_i$$

The diagram shows the final step of the self-attention mechanism. On the left, the mathematical expression $\sum_{j=1}^n \alpha_i^j \times v_i$ is shown. This is followed by a blue vertical rectangle labeled v_i , an equals sign, and a light gray vertical rectangle labeled a'_i .

圖 2-16 自注意力機制過程圖 3




圖 2-17 自注意力機制過程圖 4

以上的過程只描述了第 i 個訓練樣本的計算流程，若將所有個樣本向量組成一形狀為 $k \times n$ 的矩陣 I 、經過自注意力機制的新向量組成 I' ，則整個過程可以改寫為表 2-3，結合起來便是式 15：

表 2-3 自注意力機制流程表

query : $Q = W_q \cdot I$
key : $K = W_k \cdot I$
value : $V = W_v \cdot I$
$\alpha : A = softmax(\frac{Q \cdot K^T}{\sqrt{d_k}})$
p.s. d_k 為訓練樣本的維度 k ，用以調整值的大小
$I' : I' = A \cdot V$

在了解了基本的自注意力機制後，我們可以發現這樣的算法只考慮了一次不同訓練樣本之間的相關性，但是相關性這件事情的衡量基準可能不僅僅有一種，特別是在訓練樣本（ $k \times 1$ 的向量）中 k 的維度較高的情況下，若是能夠進行多方面的相關性考量將會取得更佳的效果。因此，接下來將介紹多頭自注意力機制（Multi-head attention），即圖 2- 13b 及式 16 的概念：

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_h)W^O$$

式 16

$$where head_i = Attention(QW_i^Q, KW_i^K, VW_i^V)$$

1. 如前面的方式計算出 Q 、 K 、 V 後，將 Q 、 K 、 V 分別乘上 W_i^Q 、 W_i^K 、 W_i^V ，其中 i 代表第 i 個頭（head），形成 Q_i 、 K_i 、 V_i 。
2. 在不同的頭內，分別計算自注意力機制 $Attention(Q_i, K_i, V_i)$ 以取得 I_i' ，即 $head_i$ 。
3. 將所有 head 合併（Concat），便會形成一個形狀為 $(k * i) \times n$ 的矩陣，將此矩陣與矩陣 W^O 相乘，便可以得到新的 I'' 。
4. I'' 中的各向量作為輸入進行神經網路的訓練，透過反向傳播後便可以訓練出對應此項學習任務的 W_q 、 W_k 、 W_v 、 W_i^Q 、 W_i^K 、 W_i^V 、 W^O 等所有矩陣（ i 根據不同的設定可能改變）。

本研究發現相較於普通的自注意力機制，多頭自注意力機制具有更多可以訓練與學習的參數，這樣的設計幫助模型可以更好的擬合訓

練資料，同時從更多面向完整的考量不同訓練樣本（網格）之間的相關性。因此，本研究將使用多頭自注意力機制作為自注意力的建構基礎。

（三） 模型設計邏輯

本研究中，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，因此會有共 4 種模型作為比較，後文將以表 2- 4 中的代號簡稱。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- 18)。

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徽檔案。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)。這一步驟，在有使用自注意力機制方法考慮相鄰網格影響的模型 (att_no_his、att_his) 中，會透過 Positional-encoding 的方法 (Wang 與 Liu, 2019) 替網格加入位置資訊。

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 $((M \times N), C)$ 。在這個步驟中，同時也會進行自注意力機制模型的自注意力計算並產出帶有全局相關性的訓練資料。

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 $M*N$ 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，這個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。

表 2-4 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- 18 模型設計邏輯及資料流概念圖

九、模型架構

本研究所使用的神經網路模型，其設計架構共分為兩種，分別是 attention 模型及 mlp（Multi-layer perceptron）模型（圖 2- 19）。

在圖 2- 19a 中為基於最早的 Transformer 模型(Vaswani 等, 2017)更改的 attention 模型。考量到在文字生成模型中有面對測試資料時無法概覽全局輸入的問題，原始模型具有 Encoder 及 Decoder 兩個部分及 Mask 層，但是在此研究的任務中並不需要，因此僅拆解並修改部分模型來使用。在模型中處理完的三階張量資料會自 Inputs 層輸入並進行 Positional-encoding，之後經過 Embedding 層進行展平形成二階張量，接下來輸入將進入殘差連接塊（Residual block，Add&Norm）(He 等，

2015)。在這裡資料將分為兩個部分，一部分進入多頭自注意力層 (Multi-head attention) 進行自注意力訓練並產出具全域相關性的資料，之後進行 Batch normalization 後與另一部分保持原樣的資料相加。並再進行一次 Batch normalization 後通過 ReLU 層並往後輸入。之後，輸入至包含全連接層 (Fully connected layer, Feed Forward) 的殘差連接塊進行神經網路的訓練。最後通過 Sigmoid 層後獲取機率。

在圖 2- 19b 中則是 mlp 模型的架構。資料自 Inputs 層輸入後，為了不產生資料偏誤 (Sample bias) 導致的訓練誤差，隨機選擇與崩塌網格數量一致的未崩塌網格，使資料比達到 1:1，之後經過 embedding 層進行展平形成二階張量。接著透過試誤比較後設定了神經元數量 28、128、64 的三個全連接層，並且為了避免參數過多導致的梯度爆炸及梯度消失問題 (He 等，2015)，同樣使用了殘差連接塊的方式設計。最後通過 Sigmoid 層獲取機率。模型的詳細細節請參照附錄 2。




圖 2- 19 自注意力模型與普通神經網路模型結構圖

十、訓練流程

(一) 模型超參數

所謂超參數（Hyperparameter）代表的是在各種機器學習模型中，各種架構中可以調整的參數。在多數時候，這些參數並無既定的設置，往往是通過試誤法或是經驗法選擇。因此，表 2- 5 提及的超參數乃基於前人研究（Vaswani 等，2017）並多次試誤後獲得。

表 2-5 超參數設定表

mlp		att	
activation function 1	linear	num_heads	4
activation function 2	ReLU	key_dim	128
activation function 3	ReLU	value_dim	128
units 1	28	activation function	ReLU
units 2	128	units 1	128
units 3	64	units 2	64
dropout rate	0.5	units 3	14/28
optimizer	Adam	dropout rate	0.1
		optimizer	Adam

(二) 訓練設定

在神經網路模型的訓練中，將所有的訓練資料通過神經網路，並經由反向傳遞演算法 (Backpropagation) 更新網路中的係數一次，稱為「一期 (epoch)」。並且因為硬體內存關係，在一 epoch 中通常無法同時輸入所有訓練資料，必須將其切分成一定大小的「批次 (batch)」，而由於切分的關係，則需要多次「迭代 (iteration)」後才能完成一 epoch。在訓練的過程中，如何設定 epoch 及 batch 的大小是依據硬體效能及時間成本控制所決定，本研究中的設定如表 2-6。而資料的輸入形狀則依據訓練目標（考量/不考量歷史崩塌）有所差異：

表 2-6 模型訓練設定表

模型	正負比	epoch	batch_size	input_shape
mlp_no_his	1:1	1000	128	(,14)
mlp_his	1:1	1000	128	(,28)
att_no_his	1:43	1000	128	(,14)
att_his	1:43	1000	128	(,28)

上表中的正負比代表的是二分類問題中兩型資料的比例，本研究定義崩塌為正而未崩塌為負。由於此前所提到的資料偏誤問題，mlp 模型皆經過資料隨機篩選的過程，因此正負比為 1:1；但是 att 模型由於

需要計算空間相關性，貿然進行資料篩選將會喪失空間上某些位置的網格，將不符合邏輯及目標，因此正負比維持原始資料的 1:43。

(三) 終止條件及目標

在上一節中，設定一次訓練為 1000 epoch，為的是避免神經網路參數更新次數不足無法使損失下降到好的程度，但是大量的 epoch 同時也帶來大量的訓練時間成本及模型過擬合 (Overfitting) 的風險，因此，本研究使用兩種方法來改善這個問題。

為了解決過擬合的問題，訓練過程中會將訓練資料隨機取 30% 作為驗證集 (validation set)。隨著模型的學習訓練準確率及驗證準確率同時產生變化的過程，如圖 2- 20 所示。在訓練的過程中本研究使用 ReduceLROnPlateau 及 EarlyStopping 函式 (Chollet 等人，2015)，在每一 epoch 監測驗證集準確率 (validation accuracy)，若在連續兩個 epoch 不上升，則降低學習率 (learning rate)，讓網路更新的較緩慢但精確；若在連續五個 epoch 不上升，則終止訓練過程，防止過擬合。




圖 2-20 訓練過程中訓練準確率（紅線）及驗證準確率（藍線）變化圖

十一、 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 2-7）及其衍生出的指標來了解模型的表現。前文中提及模型輸出為 0 – 1 之數值，前人多以 0.5 作為崩塌、未崩塌的分界閾值。本研究則透過訓練過程中同步進行閾值測試的方法，使模型閾值非主觀訂定，而是依模型及資料特性自動生成對應模型的閾值，因此各模型可能不同（附錄 3）。混淆矩陣（表 2-7）中的崩塌、未崩塌便是使用此閾值分類。

表 2-7 混淆矩陣

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

表 2-7 中，TN（True Negative）代表了模型推測為未崩塌且真實為未崩塌、TP（True Positive）代表了模型推測為崩塌且真實為崩塌、FP（False Positive）代表了模型推測為崩塌但真實為未崩塌，是為偽陽性，又稱 I 型錯誤、FN（False Negative）代表了模型推測為未崩塌但真實為崩塌，是為偽陰性，又稱 II 型錯誤。一個好的模型，應該在驗證集及測試集的推測結果中，兩型錯誤越小越好，因此人們常用一些指標來比較評估能力（表 2-8）（Powers，2020）。

表 2-8 模型評估能力指標表

指標	公式
accuracy(準確率)	$\frac{TP + TN}{ALL}$
precision(精確率)	$\frac{TP}{FP + TP}$
recall(召回率)	$\frac{TP}{TP + FN}$
F1_score	$\frac{2 \times precision \times recall}{precision + recall}$

表 2-8 中提到的 accuracy 是使用最頻繁，計算也方便的一項指標，但是在面對正負資料數量差距較大時可能不太具有參考意義。例如：當實際為正的資料是負的資料的 10 倍，有可能產生模型將無論正反皆辨識為正依舊能取得高 accuracy 的問題。而未崩塌面積與崩塌面積的比值也十分大，因此在本研究中僅將 accuracy 作為參考，並不會嚴格比較 accuracy 的高低。

Precision 則計算了推測崩塌事件中，實際崩塌的比例。當政策規劃或是防治工程需要參考本研究的崩塌潛勢地圖時，此項指標越高則代表被誤判成可能崩塌的區域較少，有利於減少不必要的防災支出。

Recall 計算了實際崩塌中，推測為崩塌的比例，即 recall 越高，代表崩塌被漏判的數量就越少。這項指標在崩塌推測這種類型的任務中相當重要，因為崩塌事件對於人命安全及經濟息息相關，一點點的漏判便可能造成無法挽回的損失，因此在模型評估時將十分注重這項指標。

綜上所述，無論是 precision 或是 recall 在崩塌潛勢評估的任務中都十分重要。因此，本研究主要透過 F1-score 來評判崩塌評估模型的好壞，此指標為 precision 及 recall 的調和平均數，可在分類問題中正、負類別占比差異較大，準確率（accuracy）無法有良好參考價值時，作為評估分類模型性能的主要指標。當 precision 及 recall 同時越高即會

得到較高的 F1-score，此數介於 0 – 1 之間，數值越大越好，本研究訂定 0.5 以上為模型可用之目標（Valverde-Albacete 及 Peláez-Moreno，2014；Jeni 等，2013）。

$$FPR = \frac{FP}{FP + TN} \quad \text{式 17}$$

$$TPR = \frac{TP}{TP + FN} \quad \text{式 18}$$

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，惟「優化模型並建立次年度全台崩塌潛勢地圖」項目因有
部分問題尚待解決(詳見第四章第二節之五)，本年度將無法如期完成，
詳表

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) 113 年 11 月 13 日前提送期末成果報告書；(2) 113 年 12 月
26 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	113			
			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蒐整	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
崩塌模型訓練特徵蒐整	10%	工作量或內容	研究區域規劃	訓練特徵收集及處理		
		累計百分比	20	100	100	100
訓練模型了解歷史崩塌的影響	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
訓練模型了解空間相關性對崩塌的影響	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
了解時、空狀態對於崩塌預測之影響	20%	工作量或內容			空間差異比較	時間差異比較
		累計百分比	0	0	50	100
優化模型並建立次年度全台崩塌潛勢	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	20	40	60	60
累計總進度	百分比		13	56	82	92

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 113 年 01 月至 113 年 12 月	至 112 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	73	0	台北市	
研究區域歷史崩塌 資料蒐整	式	1	0	1	73	0	台北市、 高雄市、 屏東縣、 宜蘭縣	
崩塌模型訓練特徵 蒐整	式	1	0	1	73	0	台北市、 高雄市、 屏東縣、 宜蘭縣	
訓練模型了解歷史 崩塌的影響	式	1	0	1	109.5	0	台北市	
訓練模型了解空間 相關性對崩塌的影響	式	1	0	1	109.5	0	台北市	
了解時、空狀態對 於崩塌預測之影響	式	1	0	1	146	0	台北市	
優化模型並建立次 年度全台崩塌潛勢	式	1	0	1	146	0	台北市	

第四章 結果及建議

第一節 結果

一、特徵可用性

特徵可用性的分析結果顯示，本研究選用的所有特徵皆在某一區間的 FR 指數大於 1（附錄 1），代表其與崩塌發生與否具有高度相關性，即特徵可以使用。

結果顯示，在本研究測試區域中，當高程分布於 1395–1986m；坡向 60–120°；坡度 35–47°；TWI 於 13.5–17.5；Profile curvature 在 -0.19–-0.03；Plan curvature 在 -0.18–-0.07；月均雨量在 538.22–742.17mm；地質組成為綠色變質火成岩；褶皺距、斷層距、河道距、道路距皆 <200m 時；NDVI 在 -0.13–-0.09；NDBI 在 -0.01–0.19 時，其 FR 指數有最大值，意味著在這樣的條件下，崩塌發生的可能性是相對較高的。

二、特徵共線性

特徵共線性問題分析中，為了避免特徵共線性（collinearity）問題導致模型表現不佳，引入了變異數膨脹因子（Variance Inflation Factor，VIF）作為評判特徵是否有共線性問題的標準。通過計算後得到結果如

表 4-1。本研究選用的所有特徵之 VIF 皆不超過 5，顯示各特徵之間不具有特徵共線性的問題。

表 4-1 共線性問題評估結果

特徵	VIF
高程	3.71
坡度	1.56
坡向	1.27
Profile curvature	1.01
Plan curvature	1.00
TWI	1.00
月均降水	2.22
地質組成	1.15
斷層距	1.03
褶皺距	1.05
道路距	2.01
河流距	1.30
NDVI	3.06
NDBI	3.08

三、特徵重要性

為理解各項特徵在崩塌潛勢評估模型中，對於崩塌發生與否的重要性，透過隨機森林方法進行了評估。表 4- 2 顯示了在訓練區域中各種特徵的重要性（由大到小排序），可以發現若將所有年份的歷史崩塌同時作為特徵時，包含評估年份前三年之數年份的的歷史崩塌比傳統崩塌評估模型常用的特徵更與崩塌事件的發生相關；除此之外，傳統特徵裡以與裸露地相關的 NDVI 及 NDBI 較重要，同樣可能代表過往崩塌地未復育的區域，次之為地文因子中與地形、降水相關的特徵，這方面與鄭詠心（2021）、陳柏鈞（2023）在台灣的案例中獲得的結果相同，顯示降水可能是崩塌災害中主要的啟動因素。

表 4- 2 隨機森林方法評估特徵重要性

No	Feature	Importance	No	Feature	Importance
1	2009	0.255	15	Plan curvature	0.009
2	2014	0.181	16	2005	0.008
3	2013	0.123	17	地質組成	0.007
4	2012	0.100	18	2006	0.007
5	NDBI	0.095	19	河流距	0.004
6	NDVI	0.052	20	2008	0.004
7	高程	0.035	21	斷層距	0.004
8	TWI	0.022	22	2010	0.003
9	月均降水	0.020	23	褶皺距	0.003
10	2007	0.017	24	2004	0.002
11	坡向	0.015	25	2001	0.001
12	道路距	0.014	26	1996	0.001
13	坡度	0.011	27	1980	0.001
14	Profile curvature	0.009	28	1990	0.000

四、模型評估成果

首先，本研究使用 2015 年訓練區域的崩塌資料做為訓練資料，使模型了解在 2015 年事件之前的特徵（受時間影響大的特徵有：月均降水、NDVI 及 NDBI），以及加入歷史崩塌作為特徵後對於崩塌事件發生與否的關係。

在以下的內容中，將展示表 2-4 中所提及的四種模型，並在測試區域中使用與訓練時一致的特徵種類輸入各模型進行 2015 年的崩塌推測，並與實際崩塌紀錄比對。需要注意一點，在前人研究中通常以 0.5 作為建立混淆矩陣的閾值，但是本研究將其視為一可訓練的參數，透過訓練資料可以學習出各種模型架構下適合的分類閾值（附錄 3）。

在無歷史崩塌及無空間相關模型（mlp_no_his）中，單獨使用前述傳統上常見的 14 種地文、水文、人文因子作為特徵進行訓練，並且不考慮空間上的相關性。可以發現，於測試區域中盡管 accuracy 高達 0.97 左右，但其 precision 及 recall 表現都並不算好，分別為 0.5 及 0.33，因此導致 F1-score 相應的只為 0.4（

表 4-3）（圖 4-1），模型分類評估能力不佳在推測崩塌的範圍中實

際崩塌的部分其實只占半數左右，並沒有很好的辨認出來。

有歷史崩塌及無空間相關模型（mlp_his）中，於先前的 14 種特徵外增加歷史崩塌作為訓練特徵，同樣沒有考慮空間上的相關性。在測試區域中，除了 accuracy 為 0.988，無論是 precision 及 recall 都高達 0.83 及 0.74，F1-score 也因此高達 0.78 左右（

表 4-3）（圖 4-1），模型分類評估能力表現優秀，無論在實際崩塌及未崩塌區域推測準確度都很高。

無歷史崩塌及有空間相關模型（att_no_his）則是使用基本的 14 種特徵，並且運用自注意力機制方法建立空間相關性進行訓練。在測試區域中，儘管 accuracy 仍有 0.95，但無論 precision、recall 及 F1-score 都是所有模型中表現最差的（

表 4-3）（圖 4-1），模型分類評估能力相當差。

有歷史崩塌及有空間相關模型（att_his）同時增加考量了 14 年歷史崩塌，並使用自注意力機制方法建立空間相關性進行訓練。其在測試區域具有高達 0.98 的 accuracy，並且 precision 及 recall 都有高達 0.78 以上，因應的是 F1-score 也有 0.79 左右（

表 4-3）（圖 4-1），表示模型分類評估能力極佳，無論在實際崩塌及未崩塌區域推測準確度都很高，並且實際崩塌區域被錯誤判斷的數量 mlp_his 模型更少。

表 4-3 各模型評估指標

Model	accuracy	precision	recall	F1_score
mlp_no_his	0.971	0.506	0.337	0.404
mlp_his	0.988	0.833	0.746	0.787
att_no_his	0.958	0.289	0.287	0.288
att_his	0.988	0.788	0.796	0.792

模型評估能力比較




圖 4-1 模型評估能力柱狀圖

五、崩塌圈繪地圖

在測試區域運用各訓練完成的模型進行分類後，可以獲得每一個網格中對於是否發生崩塌的機率分布，其值分布由 0 至 1，數值越大，發生崩塌的可能越高。根據訓練獲得的分類閾值可以於測試區域圈繪

推測的崩塌範圍，更直觀的對於評估結果進行解釋。

圖 4- 2 為 mlp_no_his 模型對於測試區域的崩塌圈繪範圍，可以明確看出僅在測試區東北及東南側有相對好的推測效果，但是仔細比較下會發現無論是崩塌範圍連續性及正確性都不佳。

圖 4- 3 中顯示的是測試區域使用 mlp_his 模型產製的圈繪結果，可以發現基本上這個圈繪地圖已近乎完整的判定出崩塌區域，僅有少部分 high 的推測範圍稍微過大，或是小範圍的崩塌事件沒有被推測出來。

圖 4- 4 中的結果是 att_no_his 模型於測試區域的崩塌圈繪圖，可以發現這個模型產製的地圖幾乎沒有任何可供參考的評估結果。

圖 4- 5 為 att_his 模型於測試區域的圈繪地圖，可以說是四種模型中推測評估能力最佳的模型，並且其 F1-score (0.79) 亦是四個模型中最高者。




圖 4- 2mlp_no_his 崩塌潛勢圖及崩塌圈繪圖




圖 4- 3mlp_his 崩塌潛勢圖及崩塌圈繪圖




圖 4-4att_no_his 崩塌潛勢圖及崩塌圈繪圖




圖 4- 5att_his 崩塌潛勢圖及崩塌圈繪圖

第二節 建議

本節僅針對目前計畫進行進度所獲得的結果進行討論並提出相關建議。

一、歷史崩塌作為崩塌預測模型特徵的重要性

透過前文結果中，針對 mlp_no_his 模型與 mlp_his 模型、att_no_his 與 att_his 之間的比較，可以很明顯的觀察到在加入評估年份過往的歷史崩塌作為訓練崩塌潛勢模型的特徵時，可以很有效的提升模型推測的能力。

在兩個基本 mlp 模型之間的比較中，其中的 F1_score 從 0.40 躍升至 0.78 (表 13)，AUC 也從 0.94 提升至 0.99 (圖 27a、圖 27b)，並且從各自產出的崩塌圈繪地圖可以明顯看出，mlp_his 與實際崩塌對比下明顯誤判區域更少，較主要的崩塌區域也圈繪的更完整，有更好的推測準確度。

而比較兩個包含空間資訊的 attention 模型，F1_score 從 0.28 躍升至 0.79 (表 13)，AUC 也明顯的提升約 0.11 (圖 27c、圖 27d)。另外，att_no_his 模型的表現不盡理想，其可能的原因是由於 attention 模型的運算邏輯，我們無法隨意刪減或篩選資料，導致了進行訓練的資料中崩塌與未崩塌面積的比例接近 1:43，在這樣的情況下容易發生資料偏誤

(sample bias) 問題。舉例來說，在訓練模型解決分類問題時，若某類型 A 在訓練資料中占比太高，如 $A:B:C=97:2:1$ ，則模型只要推測答案是 A，在訓練過程就可以達到 97% 的 accuracy，這樣雖然模型能夠收斂，但是其實不具有實質意義。在 att_no_his 模型中，便是遇到了資料偏誤的狀況而導致模型失去評估能力。相較之下，本研究透過增加歷史崩塌作為特徵的 att_his 模型在正負資料差距極大的情況下依舊達到了極佳的評估能力，說明了歷史崩塌在未來崩塌的發展中是一顯著的影響因素。

透過上述的比較，本研究認為有關機關在進行各式崩塌評估模型的建置時，必須考量歷史崩塌可能造成地質條件的不穩定，而影響到未來崩塌發生的狀況，若能透過資料蒐整及正確的崩塌範圍圈繪研究取得過去發生的崩塌資料，對於提升評估正確性會有明顯的幫助。

二、空間關係之於推測的效果

由於 att_no_his 模型表現不佳，在這節主要對 mlp_his 和 att_his 兩者進行空間關係之於推測效果討論。在使用了自注意力機制演算法訓練模型理解空間上不同網格之間的關聯後，雖然在 F1_score 上，mlp_his 及 att_his 差距不大，都有優異的表現（圖 4-1），但是細看可以發現，att_his 的 recall 表現比 mlp_his 佳。由於 recall 所表示的意義是，實際

崩塌中被模型成功推測為崩塌的比例，在防減災領域中，災害發生所造成的影響常是無法挽回且必須要避免的，因此常採取較保守的評估策略，即「寧可誤判，也不能漏判可能的災害」。在實務應用上，recall 更高的具空間關係的 att_his 模型應是較適合實際運用的模型。

考量空間關係的另一個優點圖 4-6 所示，圖 4-6a 為實際崩塌的範圍、圖 4-6b、c 分別為 mlp_his 及 att_his 推測的崩塌範圍，可以很明顯的看到 mlp 模型所推測的崩塌範圍有較不連續的情形，與現實狀況可能差距較大。在過去針對此問題，Chang 等人(2023)提出了一種想法，認為這是由於模型以網格為單位進行推測而產生不合現實狀況的缺點，而他們最後選用斜坡單元 (slope unit) 作為解決的方案。因此，本研究另外在原本的建模架構下改用斜坡單元為資料單位 (資料來源：水保署)，與網格單元的結果做比較，以確認何種資料格式更適合運用於崩塌潛勢的評估。

結果顯示，斜坡單元模型的各項模型評估指標皆顯著低於網格模型 (圖 4-7)，並且從崩塌潛勢地圖及崩塌圈繪地圖可以發現，不使用歷史崩塌作為特徵的斜坡單元模型 (SU_no_his)，模型評估效果非常差，基本上不具參考價值；而使用歷史崩塌作為特徵的斜坡單元模型 (SU_his) 相對可以將崩塌面積較大的幾個事件判斷出來，但是受限於

斜坡單元本身固定的形狀，當崩塌發育超越單一斜坡單元範圍時，極有可能因此出現誤判或是漏判的情況（圖 4-8 至 圖 4-11 為測試區使用斜坡單元模型評估之地圖結果）。因此本研究認為：斜坡單元囿於其既定的分割範圍，產出的崩塌潛勢評估結果可能因此受限；斜坡單元的數量相較於以網格切分同一面積的區域，資料數量較少，不利於機器模型訓練的收斂；且由於斜坡單元面積相對較大，單一單元內特徵資料應取平均或是其餘統計數值仍值得商榷。故在有良好解析度的網格資料可供建立使用時，仍應使用網格作為單位進行模型的訓練，若有崩塌圈繪範圍不連續的考量，可考慮使用本研究根據自注意力機制開發的空間相關性模型。




圖 4-6 崩塌圈繪範圍比較圖 (a) 真實崩塌範圍；(b) mlp_his 崩塌圈繪範圍；(c) att_his 崩塌圈

繪範圍

網格模型與斜坡單元模型評估能力比較




圖 4-7 網格資料神經網路模型（mlp）與斜坡單元資料神經網路模型比較圖




圖 4-8 斜坡單元無歷史崩塌 (SU_no_his) 5 類崩塌潛勢地圖




圖 4-9 斜坡單元無歷史崩塌 (SU_no_his) 崩塌圈繪地圖




圖 4-10 斜坡單元有歷史崩塌 (SU_his) 5 類崩塌潛勢地圖




圖 4-11 斜坡單元有歷史崩塌 (SU_his) 崩塌圈繪地圖

三、模型在空間上的泛用性

本研究為了防止地質條件差異較大而導致訓練區域訓練出來的模型可能無法在測試區域取得良好的表現，選擇了一個與訓練區域相鄰的、具有相似地質條件的測試區域（圖）（測試區域 2 區域概況詳見附錄）。前人研究中，絕大多數的研究者也都採用了相同的選擇標準，或是直接將訓練區域隨機進行劃分獲取測試及訓練區域，因而得以在測試區域取得不錯的評估成果（Tien Bui 等，2012；Arnone 等，2016；Xiao 等，2018；Wang 等，2019；Hong 等，2019；Dou 等，2019；Chang 等，2019；Huang 等，2020；Dao 等，2020；Huang 等，2020；Dou 等，2020；Zhou 等，2021；Huang 等，2021；Sun 等，2021；Huang 等，2022；Tang 等，2022；Fang 等，2022；Li 等，2022；Pham 等，2022；Qin 等，2022；Aslam 等，2023；Chang 等，2023）。

但是這引申出一個問題，考量到模型訓練所耗費的資料前處理、電腦運算成本，研究者不一定有能力使用大範圍的區域進行訓練建模。前述的測試區域選擇下，儘管多能使模型在測試區域有不錯的評估成果，但實務防災單位或風險控管機關所需要的是能在各處快速評估崩塌風險的模型。這些在地質特性相似的測試區域有良好表現的模型是否仍能在任意的地區做到良好的評估亦是重要的議題。本研究所使用的自

統計方法衍伸而來的機器學習方法，就是為了避免案例式崩塌分析在不同區域差異明顯的問題，應討論並確認是否達到預期目標。

為了瞭解本研究訓練的模型是否能在不同的地質及水文條件下依舊能有良好的評估能力，選擇了屬於雪山山脈地質區，位於台中市和平區大甲溪流域、德基水庫下游的谷關調整池及天輪調整池集水區做為測試區域 2（圖 4-12），以期能比較兩者之間評估結果的差異。

圖 4-13 為兩個測試區域評估的結果比較，由於 `mlp_no_his` 及 `att_no_his` 兩個模型在前文中已經討論過它們分類推測能力較差無法應用的問題，因此本研究著重於觀察 `mlp_his` 及 `att_his` 兩個模型的表現。從 `F1_score` 的表現中可以發現，兩種模型面對不同的測試區時，測試區 2 會稍遜於測試區 1，但依舊位在 0.7 左右，仍具有良好的分類推測能力。另外，比較兩個模型在面對條件迥異的測試區 2 時，`att_his` 模型分類推測效能下降幅度較小（`F1_score` 下降 0.061），而 `mlp_his` 模型效能下降幅度則較大（`F1_score` 下降 0.092）。說明基於自注意力機制所開發的模型，由於可以仔細的考量不同網格間的相關性，而較能涵蓋多樣化的崩塌類型，因此在不同區域有較佳的適應能力。

圖 4-14 至圖 4-17 為四個模型於測試區域 2 獲得的崩塌圈繪地圖成果，與前面所述一致，`mlp_no_his` 及 `att_no_his` 盡管在某些規模較大

的事件有稍微圈繪到，但仍有較多的誤判及漏判。而 mlp_his 和 att_his 則有更好的崩塌結果。




圖 4-12 測試區 2 範圍：谷關、天輪調整池集水區




圖 4-13 測試區 1 與測試區 2 模型評估結果比較圖




圖 4- 14 mlp_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2）




圖 4- 15 mlp_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2）




圖 4- 16 att_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2）




圖 4- 17 att_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2）

四、模型在時間上的泛用性

在模型訓練及測試過程中，為了達到了解「現在」已知條件對「未來」崩塌發生與否的關係，在會隨時間變化的特徵，如降水、NDVI、NDBI 等，選用的皆是推測年份前的資料。本文中的模型皆是以 2015 年前資料作為訓練資料、2015 年的崩塌紀錄作為訓練標籤，並且在 mlp_his 及 att_his 兩種模型有較佳的推測表現。透過 2015 年的訓練讓模型學習到「現在」與「未來」之間的關係之後，本節將探討這些模型是否也能在任意年份進行良好的推測（圖 4-18）。




圖 4-18 時間泛用性示意圖

本研究選擇了 2009、2012 及 2018 年為例，進行了資料準備及前處理等操作，以作為模型的推測目標年份。不過在此會出現一個問題，即在先前的訓練中使用的是 2015 年以前所有可取得的歷史崩塌資料作

為特徵，但是若要考慮不同年份，則推測年份前的歷史崩塌年份數量將有所差異，這會導致崩塌潛勢評估模型的特徵輸入數量將有所差異，無法正確推測。因此根據先前的討論結果（表 4-2），將 2015 年模型從原本使用所有歷史崩塌年份（28 個特徵）改為只使用 2012、2013、2014 年三年份的歷史崩塌（17 個特徵）進行訓練，期許這樣得以在保持推測效能的情況下在不同的年份也都能以相同的特徵數輸入並評估。

透過圖 4- 19 可以觀察在使用全部 14 年份歷史崩塌及僅使用 3 年份歷史崩塌所訓練出來的 2015 年模型在不同測試區域的差異。在僅使用 3 年份歷史崩塌作為特徵時，測試區 1 的推測表現（F1_score）基本上都維持與使用 14 年份歷史崩塌的模型相似的水準；測試區 2 的推測表現在含空間關係（att_his）下降幅度與差異不大，但是不含空間關係（mlp_his）的下降幅度就相對較大。此結果說明用較多年份的歷史崩塌進行訓練比較能取得好的結果；而使用 3 年份歷史崩塌進行訓練，雖在相似地質條件區域（測試區 1）仍能有良好表現，但是於不考量空間關係的模型中，一旦地質條件與訓練區域差異較大時表現可能較差，應視任務目標加以考量並調整訓練思路。




圖 4-19 歷史崩塌使用年份比較圖

圖 4-20 為多年份測試的結果，橫軸代表推測的年份，縱軸是推測的 F1_score，不同形狀的資料標記代表不同的模型，而實心標記為測試區 1，空心標記為測試區 2。考量到 mlp_no_his 及 att_no_his 兩個模型本就不具有良好的推測能力，這邊將只針對 mlp_his 及 att_his 進行討論。

在 2018、2012 兩年，除了 2012 年測試區 2 的 mlp_his 外，無論是在測試區 1 或是測試區 2，兩個模型的 F1_score 皆位於 0.6 至 0.7 左右，有不錯的推測能力，說明這兩個模型於 2015 年學到的崩塌因果關係在面對不同年份的推測目標時，仍能進行不錯的判斷。

而在 2009 年，無論是 att_his 或 mlp_his 模型，在測試區 1 的 F1_score

表現都降至 0.4 以下，不具良好推測能力；反之，測試區 2 的表現雖也不算佳，但仍位於 0.5 左右。這樣於測試區 1 的表現劣於測試區 2 的結果與其它年份有所不同，代表測試區 1 在當年度可能因某些原因使崩塌發生的機制與模型學習出的推測標準有極大的差異，導致判斷失準。

2009 年的莫拉克颱風為台灣中南部地區帶來非常極端的降雨，本研究比較了測試區 1 及測試區 2 的平均降水及標準差，如圖 4-21 所示。在 2009 年至 2018 年間，2009 年時兩測試區無論是月均降水的差異或是標準差的差異都是 10 年內最大，於歷史實際情況中，也能知道當年高屏地區山區是受風災導致崩塌最嚴重的區域，足以佐證的是 2009 年時測試區 1 的崩塌率為 9.7%，相較之下 2012、2015、2018 的平均崩塌率僅有 3.0%。在這樣的情況下，崩塌發生將主要受控於極端的降水事件，可能與其餘年份受多種因素共同影響而致災有所不同，導致模型透過正常年學習到的關係不適用而失去良好的推測能力。




圖 4-20 不同年度模型評估能力比較圖




圖 4-21 2009、2012、2015、2018 年年均降水及標準差

從以上的分析結果可以得知，選用 3 年份歷史崩塌作為特徵時，在 att_his 及 mlp_his 兩個模型中能在不同年份維持一定的推測表現 (F1_score:0.6 - 0.7)，其中 att_his 在不同地質條件下的穩定性較佳。不過，當模型面臨極端降水條件時，可能因為崩塌機制的差異導致模型推測失準，仍須進一步的改善。

五、研究需改善問題

本研究至此已成功建立將歷史崩塌納入訓練特徵的機器學習模型，大幅提升了模型評估崩塌發生的能力；同時評估了使用自相關模型進行網格之間相關性的優缺點，並與過往研究中常見的斜坡單元方法進行比較，自相關模型有效的提升了崩塌範圍圈繪的精準度，減少了誤判及漏判。並且也針對模型在空間上、時間上的泛用性進行討論，目前有兩點需要改善。

首先是在與訓練區不同地質條件下使用模型時，模型的表現會出現下滑，這在同樣屬於輕度變質岩區的測試區 1 及測試區 2 便可見端倪，因此如何提升不同區域的崩塌評估能力，目前有兩種思路，一是依據 Chen (2016) 的構造地質分區圖，將模型分為海岸平原地質區、西部麓山帶地質區、雪山山脈地質區、脊樑山脈地質區（廬山板岩帶）、脊樑山脈地質區（大南澳片岩帶）及海岸山脈地質區六種，並在各區域

選擇代表性集水區進行模型訓練及建置，在後續應用上則可先依據區域選用對應的模型進行評估（圖 4-22）。第二種則是在模型訓練過程中加入各構造地質區的集水區案例作為訓練資料進行訓練，使模型得以適用於不同構造地質區（圖 4-23）。




圖 4-22 多元模型解




圖 4-23 單一模型解

另外需要改善的部分是在時間泛用性討論中，可以發現由於 2009 年降雨條件較極端，使得模型針對 2009 年進行預測時不能得到良好的結果。這揭露出一個問題：本研究開發之模型受限於使用的訓練資料，當評估年的前 3 年之歷史崩塌資料中鮮少發生崩塌，並且在評估年的年度有大量短延時強降雨事件發生時，模型的效果可能因此受限，此情況於現今氣候變遷加劇情況下愈發常見。於訓練區及相鄰的荖濃溪集水區（桃源、六龜）中嘗試評估時發現，由於 2021 年至 2023 年之崩塌圈繪紀錄較為稀少，包含歷史崩塌的 mlp_his 及 att_his 模型針對 2024 年的崩塌預測顯示僅有極少數地區有發生崩塌的可能性（圖 4-24 至圖

4-27)，與水保署今年度公告之土石流及大規模重大災害事件初步報告（農業部農村發展及水土保持署，2024）（圖 4-36、圖 4-37）對比可以發現，除了 mlp_his 模型獲得的結果有正確對應上桃源區的案例（圖 4-36），六龜區案例無論是 mlp_his、att_his 模型都未能正確預測到，顯示本研究開發之模型仍有受限。

測試區 1、測試區 2 針對 2024 年的預測結果（圖 4-28 至圖 4-35），受限於本年度尚未結束，災例蒐整並未完善、崩塌圈繪資料也尚未公告，無法做直接的比對。但 2024 年度受 0403 地震、凱米颱風、山陀兒颱風、及康芮颱風多次衝擊的邊坡狀態，崩塌災害可能不如評估的結果那麼少。故或許後續須調整思路，將歷史崩塌特徵的使用方式從每一年度的崩塌圈繪外，另外新增每一年度的崩塌面積變化差異，並考慮新增除崩塌圈繪資料外，現地位移量變化的資料作為限制條件或是新增特徵。

因以上兩點仍須改進，且改進作為較耗時而仍在進行中，在改進完成前為避免產出品質尚待考驗的結果，本研究目前僅產出訓練區及兩個測試區之次年度崩塌潛勢圖，前期報告中預計完成之全台次年度崩塌潛勢圖本年度無法如期產出，須待後續補全。




圖 4- 24 mlp_no_his 崩塌潛勢圖及崩塌圈繪圖（訓練區+荖濃溪部分範圍；2024 年度）




圖 4- 25 mlp_his 崩塌潛勢圖及崩塌圈繪圖（訓練區+荖濃溪部分範圍；2024 年度）




圖 4- 26 att_no_his 崩塌潛勢圖及崩塌圈繪圖（訓練區+荖濃溪部分範圍；2024 年度）




圖 4- 27 att_his 崩塌潛勢圖及崩塌圈繪圖（訓練區+老濃溪部分範圍；2024 年度）




圖 4-28 mlp_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 1；2024 年度）




圖 4- 29 mlp_his 崩塌潛勢圖及崩塌圈繪圖（測試區 1；2024 年度）




圖 4- 30 att_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 1；2024 年度）




圖 4-31 att_his 崩塌潛勢圖及崩塌圈繪圖（測試區 1；2024 年度）




圖 4- 32 mlp_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2；2024 年度）




圖 4- 33 mlp_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2；2024 年度）




圖 4- 34 att_no_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2；2024 年度）




圖 4- 35 att_his 崩塌潛勢圖及崩塌圈繪圖（測試區 2；2024 年度）

113 年重大土砂災例最速報

凱米颱風

高雄市—桃源區勤和里





圖 4-36 凱米颱風桃源區勤和里土砂災例速報（資料來源：農業部農村發展及水土保持署）



圖 4-37 凱米颱風六龜區中興里土砂災例速報（資料來源：農業部農村發展及水土保持署）

參考文獻

1. 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>
2. 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>
3. Böhner, J., & Selige, T. (2002). Spatial prediction of soil attributes using terrain analysis and climate regionalization. *Gottinger Geographische Abhandlungen*, 115.
4. 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>
5. 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>
6. 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>

7. Chang, K.-T., Merghadi, A., Yunus, A. P., Pham, B. T., & Dou, J. (2019). Evaluating scale effects of topographic variables in landslide susceptibility models using GIS-based machine learning techniques. *Scientific Reports*, 9(1), 12296. <https://doi.org/10.1038/s41598-019-48773-2>
8. Chang, Z., Catani, F., Huang, F., Liu, G., Meena, S. R., Huang, J., & Zhou, C. (2023). Landslide susceptibility prediction using slope unit-based machine learning models considering the heterogeneity of conditioning factors. *Journal of Rock Mechanics and Geotechnical Engineering*, 15(5), 1127–1143. <https://doi.org/10.1016/j.jrmge.2022.07.009>
9. 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>
10. Chen, W. (2016). *Taiwan di zhi gai lun* (Chu ban). Zhonghua Minguo di zhi xue hui.
11. Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37–46. <https://doi.org/10.1177/001316446002000104>
12. Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., and Böhner, J. (2015): System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, Geosci. Model Dev., 8, 1991-2007, doi:10.5194/gmd-8-1991-2015.

13. Chollet, F., & others. (2015). Keras. GitHub. Retrieved from
<https://github.com/fchollet/keras>
14. 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)
15. Dao, D. V., Jaafari, A., Bayat, M., Mafi-Gholami, D., Qi, C., Moayed, 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>
16. 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>
17. Dou, J., Yunus, A. P., Bui, D. T., Merghadi, A., Sahana, M., Zhu, Z., Chen, C.-W., Han, Z., & Pham, B. T. (2020). Improved landslide assessment using support vector machine with bagging, boosting, and stacking ensemble machine learning framework in a mountainous watershed, Japan. *Landslides*, 17(3), 641–658.
<https://doi.org/10.1007/s10346-019-01286-5>
18. Dou, J., Yunus, A. P., Tien Bui, D., Merghadi, A., Sahana, M., Zhu, Z., Chen, C.-W., Khosravi, K., Yang, Y., & Pham, B. T. (2019). Assessment of advanced random forest and decision tree algorithms for modeling rainfall-induced landslide susceptibility in the Izu-Oshima

- Volcanic Island, Japan. *Science of The Total Environment*, 662, 332–346. <https://doi.org/10.1016/j.scitotenv.2019.01.221>
19. Fang, Z., Wang, Y., Duan, H., Niu, R., & Peng, L. (2022). Comparison of general kernel, multiple kernel, infinite ensemble and semi-supervised support vector machines for landslide susceptibility prediction. *Stochastic Environmental Research and Risk Assessment*, 36(10), 3535–3556. <https://doi.org/10.1007/s00477-022-02208-z>
 20. 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>
 21. 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>
 22. 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>
 23. 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>
 24. 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>
25. Glosser.ca, CC BY-SA 3.0 <<https://creativecommons.org/licenses/by-sa/3.0/>>, via Wikimedia Commons
26. He, C. (2009). *Pu tong di zhi xue* (3 ban). Wu nan tu shu chu ban you xian gong si.
27. 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>
28. 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>
29. Hochreiter, S. (1991). *Untersuchungen zu dynamischen neuronalen Netzen*.
30. Hong, H., Miao, Y., Liu, J., & Zhu, A.-X. (2019). Exploring the effects of the design and quantity of absence data on the performance of random forest-based landslide susceptibility mapping. *CATENA*, 176, 45–64. <https://doi.org/10.1016/j.catena.2018.12.035>
31. Huang, F., Cao, Z., Jiang, S.-H., Zhou, C., Huang, J., & Guo, Z. (2020). Landslide susceptibility prediction based on a semi-supervised multiple-layer perceptron model. *Landslides*, 17(12), 2919–2930.
<https://doi.org/10.1007/s10346-020-01473-9>
32. 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>
33. 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>
34. 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>
35. 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>
36. 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>
37. Jeni, L. A., Cohn, J. F., & De La Torre, F. (2013). Facing Imbalanced Data—Recommendations for the Use of Performance Metrics. 2013 Humaine Association Conference on Affective Computing and Intelligent Interaction, 245–251. <https://doi.org/10.1109/ACII.2013.47>
38. Landis JR, Koch GG. The measurement of observer agreement for

- categorical data. *Biometrics*. 1977 Mar;33(1):159-74. PMID: 843571
39. 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>
 40. LeCun, Y (2016). Slides on Deep Learning Online Archived 2016-04-23 at the Wayback Machine
 41. 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>
 42. 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>
 43. 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>
 44. 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>

45. Minsky, M., & Papert, S. A. (1972). *Perceptrons: An introduction to computational geometry* (2. print. with corr). The MIT Press.
46. Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
47. Novellino, A., Cesarano, M., Cappelletti, P., Di Martire, D., Di Napoli, M., Ramondini, M., Sowter, A., & Calcaterra, D. (2021). Slow-moving landslide risk assessment combining Machine Learning and InSAR techniques. *CATENA*, 203, 105317.
<https://doi.org/10.1016/j.catena.2021.105317>
48. Nettleton, I. M., Martin, S., Hencher, S., & Moore, R. (2005). Debris flow types and mechanisms. *Scottish road network landslides study*, 45-67.
49. Nielsen, Michael A (2015) , Neural Networks and Deep Learning, *Determination Press*
50. 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>
51. 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>
52. Pham, B. T., Phong, T. V., Nguyen-Thoi, T., Parial, K., K. Singh, S., Ly, H.-B., Nguyen, K. T., Ho, L. S., Le, H. V., & Prakash, I. (2022).

- Ensemble modeling of landslide susceptibility using random subspace learner and different decision tree classifiers. *Geocarto International*, 37(3), 735–757. <https://doi.org/10.1080/10106049.2020.1737972>
53. Powers, D. M. W. (2020). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation (arXiv:2010.16061). arXiv. <http://arxiv.org/abs/2010.16061>
54. 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>
55. QGIS.org (2022). QGIS Geographic Information System. QGIS Association. <http://www.qgis.org>
56. Rogerson, P. (2001). *Statistical Methods for Geography*. SAGE Publications, Ltd. <https://doi.org/10.4135/9781849209953>
57. 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>
58. 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>
59. 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>

60. 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>
61. 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>
62. 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>
63. 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>
64. 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>
65. Sutton, R. S., & Barto, A. (2020). *Reinforcement learning: An introduction* (Second edition). The MIT Press.
66. 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>
67. Tien Bui, D., Pradhan, B., Lofman, O., & Revhaug, I. (2012). Landslide Susceptibility Assessment in Vietnam Using Support Vector Machines, Decision Tree, and Naïve Bayes Models. *Mathematical Problems in Engineering*, 2012, 1–26. <https://doi.org/10.1155/2012/974638>
68. 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>
69. Verhulst, Pierre-François (1845). Recherches mathématiques sur la loi d'accroissement de la population. *Mathematical Researches into the Law of Population Growth Increase*. Nouveaux Mémoires de l'Académie Royale des Sciences et Belles-Lettres de Bruxelles. 18. Retrieved 2013-02-18
70. Valverde-Albacete, F. J., & Peláez-Moreno, C. (2014). 100% Classification Accuracy Considered Harmful: The Normalized Information Transfer Factor Explains the Accuracy Paradox. *PLoS ONE*, 9(1), e84217. <https://doi.org/10.1371/journal.pone.0084217>
71. 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)
72. Wang, Y., Wu, X., Chen, Z., Ren, F., Feng, L., & Du, Q. (2019). Optimizing the Predictive Ability of Machine Learning Methods for

Landslide Susceptibility Mapping Using SMOTE for Lishui City in Zhejiang Province, China. *International Journal of Environmental Research and Public Health*, 16(3), 368.

<https://doi.org/10.3390/ijerph16030368>

73. 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>
74. Werbos, P. J. (1982). Applications of advances in nonlinear sensitivity analysis. R. F. Drenick & F. Kozin, *System Modeling and Optimization* (卷 38, 頁 762–770). Springer-Verlag.
- <https://doi.org/10.1007/BFb0006203>
75. 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>
76. 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>
77. 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>
78. 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>
79. 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>
80. 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>
81. 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/10.1080/014311603004987>
82. 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>
83. 王勁峰、徐成東 (2017)。地理探测器：原理与展望。《地理学报》，

- 72(1), 116-134。
84. 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。
85. 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。
86. 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。
87. 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>
88. 林冠瑋 (2010)。陳有蘭溪流域的山崩作用在颱風及地震事件中與
河流輸砂量之相對關係。國立臺灣大學地質科學研究所。博士論
文。
89. 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。
90. 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)
91. 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。

92. TCCIP (科技部臺灣氣候變遷推估資訊與調適知識平台) (2022)。

臺灣歷史氣候重建日資料(*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/>。

93. 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。

94. 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。

95. 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。

96. 陳柏鈞 (2023)。以多個潛感因子進行機器學習演算法之邊坡滑動

潛勢分析。臺灣博碩士論文知識加值系統。國立臺灣大學工學院土木工程學系。碩士論文。

97. 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。

98. 曹社晏 (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。

99. 張家瑜 (2022)。二維卷積神經網路建置高解析度崩塌潛勢圖之研究。國立成功大學資源工程學系。博士論文。
100. 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、槎仔寮為例。國立成功大學地球科學研究所。碩士論文。
101. 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。
102. 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。
103. 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。
104. 經濟部中央地質調查所 (2014)。山崩與地滑地質敏感區劃定計畫書 (L0006 高雄市)。台北市：經濟部。
105. 經濟部中央地質調查所 (2022)。山崩與地滑地質敏感區變更計畫書 (L0006 高雄市)。台北市：經濟部。
106. 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。




107. 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。
108. 鄭詠心 (2021)。整合空間資料與隨機森林演算法比對像元式與物件式分析於崩塌潛勢評估。臺灣博碩士論文知識加值系統。
109. 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。
110. 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)
111. 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。
112. 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。
113. 農業部農村發展及水土保持署。(2024)。土石流及大規模崩塌防




災資訊網。重大災害事件。




<https://246.ardswc.gov.tw/Achievement/MajorDisasters>




附錄

附錄 1 Frequency Ratio 評估結果












NDBI




地質圖




附錄 2 模型詳細設計圖






附錄 3 驗證資料 F1_threshold 圖




附錄 4 測試區 2 基本條件及現地調查記錄


高程分布-測試區2





坡度分布-測試區2






坡向分布-測試區2





monthly precipitation-測試區2



谷關_天輪集水區年均降水分布



臺灣歷史氣候重建日資料(TreAD)
(臺灣氣候變遷推估資訊與調適知識平台 · 2022)







附錄 5 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	本計畫提到將以深度神經網路模型為崩塌預測模型，但並未提及將使用何種架構之深度神經網路模型，此外也未提到將如何改良及優化該模型使其能考量崩塌行為之連續性及相關性。	感謝委員意見，已於內文「工作執行方法與步驟」中詳述所使用之模型架構及相關統計、數學原理。
二	一般進行機器學習時，通常即會以歷史崩塌地相關資訊做為訓練資料，並與所預測新生崩塌地之間建立了關聯。本計畫欲透過機器學習了解歷史崩塌對於新生崩塌之影響，似乎並未說明此與一般方法有何區別。	感謝委員意見，監督式機器學習模型訓練過程中，需要給予「題目」及「答案」，使機器建構解釋兩者之間相關性的複雜函式。在崩塌評估任務中，「題目」往往是「地形因子、水文因子、地質因子及地文因子等」，而「答案」如委員所述是「歷史崩塌」。而本研究擬了解的是，若考慮 2015

		年，「題目」是「地形因子、水文因子、地質因子及地文因子等，加上事件前崩塌紀錄（2015 年以前）」，「答案」是「2015 年崩塌紀錄」時，訓練出之模型評估能力的改變。
三	計畫中未說明如何進行成果驗證。	感謝委員意見，已於內文「工作執行方法與步驟」說明。
四	機器學習模型之建立需大量訓練資料，計畫書中未說明訓練資料資料集的內容及格式。也未針對機器學習架構做說明。	感謝委員意見，已於內文「工作執行方法與步驟」說明。
五	如何優化模型，使其適合不同目標區域、不同年份及降雨條件，細節未描述。	感謝委員意見，因計畫進度尚未進入相關探討階段，在此簡述構想：透過多步驟或分支式訓練過程納入不同地質、地形、降水條件及年份之訓練區域，使模型儘可能學習多的樣本，以期在面對不同輸入時維

		持評估表現。詳細實施內容於施行後將於期末報告中呈現。
六	建議說明崩塌資料庫及崩塌因子(特徵)資料庫，應收集的資料面向以作為判斷崩塌潛勢評估模式的可行性。	感謝委員意見，已於內文「工作執行方法與步驟」說明。

附錄 6 期中審查會議記錄暨回覆辦理情形

項次	審查意見	處理情形
一	目前研究考慮歷史崩場事件特徵以大幅提升模型能力(F1-score)在 MLP 模型或與 attention 模型，皆獲顯著效果。尤其在 attention 模型在 precision 及 recall 有較好表現，也符合預期。	感謝委員意見，目前結果尚需進一步優化，以期具備更實用的運用場景。
二	建議針對隨機森林法所產生之特徵重要性因子進行探討(與文獻比較)，以利背後物理意義之闡述。	感謝委員意見，內文中已新增相關討論及文獻比對，惟不同案例下特徵對於崩塌發生之影響可能不盡相同，使目前結果

		仍稍嫌粗淺。我們下一步目標便是透過發展解釋性更加優良的模型，輔以詳細的現地案例探討，以了解不同區域崩塌致災因子的重要性及原因。
三	建議加入可解釋 AI 之機制，以瞭解模型之解釋能力。	感謝委員意見，已於內文中增加相關說明及文獻。本研究目的主要在探討歷史崩塌特徵及空間相關之於模型評估效能的提升，希望先精進評估的正確性，後續會再針對模型可解釋性方面進行下一步的改良。
四	P4-4 至 P4-6 排版疏漏，期末報告請修正。	感謝委員意見，已針對錯誤修正。
五	表 2-8 對於後續評估此研究的模型好壞至關重要，是否有相關文獻做為此表格的佐證？	感謝委員意見，已於內文中補上相關文獻。
六	2-47 頁提到選取指標的考量，如：此計畫僅將 accuracy 列為	感謝委員意見，已於內文中補上相關文獻。其中探討了面對

	參考，並不特別比較其數值，是否有類似研究也做過類似的決定？	不平均資料之分類問題使用 accuracy 評估可能帶來的偏誤問題。
七	使用隨機森林法做為崩塌潛勢的計算依據，為何還需要計算 FR 與 VIF 的數值？請補充說明。	感謝委員意見，計算 FR 及 VIF 數值旨在進行模型訓練前了透過簡單的統計方法評估各項特徵是否適合使用。而隨機森林法在本計畫中不是做為崩塌潛勢的計算依據，而是在神經網路模型（黑盒子模型）完成後，用於事後解釋各項特徵權重之用。主要在了解特徵各自對於崩塌發生的重要性排序。
八	地質組成的部分是以三大岩類做為區分權重的標準？還是以地調所的五萬分之一地質圖為依據？請補充說明。	感謝委員意見，已於內文第二章第二節第七段之（三）說明。本研究使用的是地調所的五萬分之一地質圖中的岩性分類，詳細類別可見附錄 1 地

		質特徵的圖表。
九	當研究區域內有許多構造線通過時，做了 buffer 之後若有兩條以上的構造線產生交集，是否會提高這個區域的風險值？	感謝委員意見，確實在多構造線或道路通過的地方對於邊坡穩定的影響可能會有疊加的效應，但如何量化其疊加的效應是另一值得探討的課題。在本研究主題方向上，目前尚無考量此效應的影響。
十	2-6 提到後續將以訓練區做為主要介紹，但圖 4-2 到 4-5 只呈現測試區的結果，建議補充說明訓練區的成果。	感謝委員意見，2-6 中提及以訓練區做為主要介紹是讓讀者得以了解模型是學習了甚麼條件下的資訊而建立的。而第四章中，因為訓練區即模型的訓練依據，用模型來預測模型的依據於邏輯上較不合理，故主要將焦點放於測試區域上。
十一	本研究計畫預計產出能「預測」未來潛在崩塌地的模型，但期中報告內文中並未說明目	感謝委員意見，於附錄 5 第二點中有針對整個模型架構的解釋、圖 4-18 中另有整個資料

	前的模型如何做到，建議補充說明。	流的說明。本研究建立之模型使用的訓練特徵皆為欲評估的目標年之前的各種特徵，對應的結果則是目標年崩塌資訊，這樣的情況下模型學習到的因果關係是這樣：模型看到 2015 年以前特徵→模型評估→模型對 2015 年的崩塌狀況給出評估的結果，應用於未來的年份則是模型看到 2025 年以前特徵→模型評估→模型對 2025 年的崩塌狀況給出評估的結果。藉此來達成所謂「預測」未來崩塌潛勢的效果。
--	-------------------------	--

附錄 7 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	訓練模型時的雨量資料是如何輸入與分隔的？	感謝委員意見，已於內文 2-7-2 中新增所使用雨量資料的詳細說明。由於本研究主要關注點

		是不同年度全年度的廣域崩塌潛勢評估，目前並非針對單一雨場或降水事件進行評估，因此雨量資料是以整年的平均月降雨量為單一特徵，照網格順序依序輸入模型訓練評估，並無不同雨場分隔的狀況。未來會考慮針對更直觀的雨場、事件對進行後續的延伸研究。
--	--	---