

計畫編號：ARDSWC-113-084

數位孿生聚落防災物聯網監測平台之研究
Development of IOT-based Digital Twin
Monitoring Platform for Settlement
Disaster Prevention
(成果報告)

執行單位：國立陽明交通大學

執行期間：113 年 2 月 07 日至 113 年 12 月 31 日

計畫主持人：林子剛 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，僅供本局施政參考)



數位孿生聚落防災物聯網監測平台之研究

摘要

臺灣位處亞熱帶地區，又因地處於大陸冷氣團和太平洋暖氣團交互影響的地帶，容易產生長時間降雨的梅雨季以及因颱風來襲時出現的強降雨情形。除了降雨，臺灣因地理位置而頻發的地震容易產生敏感地層帶，該區域容易因為強降雨發生而連帶產生崩塌地質災害，造成社會生命以及財產的損失。臺灣位於板塊交界帶，經常有地震事件的發生，過去也常因其地文特性使得颱風來襲或是降雨強度提高時容易發生崩塌事件。本計畫選用高雄六龜區作為研究範圍，因 98 年莫拉克颱風造成六龜趨嚴重損害，尤其以寶來國中及寶來國小鄰近地區有大範圍崩塌，使本計畫研究區域著重於此。期以研究範圍之環境因子分析結合人工智慧相關技術，在強降雨或是強震發生後，以人工智慧模型來預測各區域潛在的崩塌發生機率，以利即時做出災害應變措施以及預先的決策準備。執行階段發現所得出的崩塌預測因子值會有鑑別度不足的問題，解決方法包含將網格範圍擴大，可能擴大範圍至 100mX100m 或是 200mX200m，詳細數據將在測試後決定；增加降雨時間序列多樣性，像是將時間以 6 小時回推的方式創造出更多的時間序列；訂定有效的因子值，更好的因子值設定可以更有效的預測崩塌。

關鍵詞：數位孿生、聚落防災、長短期記憶網路、類神經網路、坡地崩塌預測



Development of IOT-based Digital Twin Monitoring Platform for Settlement Disaster Prevention

Abstract

Taiwan is located in the subtropical region and is influenced by both continental cold air masses and Pacific warm air masses, resulting in prolonged rainy seasons and heavy rainfall during typhoon seasons. In addition to rainfall, Taiwan's geographical location makes it prone to frequent earthquakes, which can create sensitive geological zones more likely to experience landslides during heavy rainfall, causing significant loss of life and property. Taiwan's position on tectonic plate boundaries results in frequent earthquakes, and its geological characteristics make it susceptible to landslides during typhoons or heavy rainfall. This project focuses on the Liouguei District in Kaohsiung. Particularly, the Liouguei District was severely affected by Typhoon Morakot in 2009, especially around the vicinity of Baolai Junior High School and Baolai Elementary School, where extensive landslides occurred. Therefore, the research area is focused on this region. The goal is to combine environmental factor analysis with artificial intelligence technology to predict potential landslide occurrences in different areas after heavy rainfall or strong earthquakes, aiding in real-time disaster response measures and preemptive decision-making. During the implementation phase, it was found that the derived landslide prediction factor values lacked sufficient discernibility. The

solutions are to expand the grid range, possibly to 100m x 100m or 200m x 200m, with specific data to be determined after testing, increase the diversity of the rainfall time series by creating more time series by rolling back time in 6-hour intervals, and establish effective factor values, as better factor value settings can more effectively predict landslides.

Keywords: Insufficient discrimination of collapse predictor values, expansion of data grid, diversity of time series, effective factor values



目次

摘要.....	I
Abstract.....	III
目次.....	V
表次.....	VII
圖次.....	IX
第一章 緒論	1-1
第一節 計畫欲解決的問題	1-1
第二節 計畫範圍	1-2
第三節 執行流程與計畫目標	1-5
第二章 文獻回顧	2-1
第一節 類神經網路 (Artificial Neural Network).....	2-1
第二節 長短期記憶模型 (Long Short-Term Memory , LSTM).....	2-4
第三章 模型訓練資料庫建立	3-1
第一節 選定研究範圍	3-1
第二節 基本資料庫說明	3-2
第三節 資料量化與因子解算	3-4
第四節 DEM 模型 20m x 20m 網格	3-7
第五節 網格資料庫建置	3-8
第六節 崩塌坡地資料庫建立成果	3-11
第四章 模型測試與訓練	4-1
第一節 模型建置流程	4-1
第二節 LSTM 網路建置.....	4-1
第三節 網路訓練和驗證	4-4
第四節 網路測試以及優化	4-5

第五節	人工智慧模型建置與訓練初步結果	4-7
第六節	ANN 模型建置與訓練結果.....	4-16
第七節	小結	4-23
第五章	高 133 線凱米颱風監測與分析	5-1
第一節	背景介紹期程規劃	5-1
第二節	監測系統規劃與選定雨量站	5-2
第三節	氣象資訊推估與分析	5-3
第四節	凱米颱風期間的雨量觀測與分析	5-4
第五節	凱米颱風期間的雨量觀測與分析	5-6
第六章	結論與未來展望	6-1
第一節	結論	6-1
第二節	未來展望	6-2
參考文獻.....		參-1
附錄一、研提計畫書審查意見暨回覆辦理情形		附錄-1
附錄二、期中審查會議紀錄暨回覆辦理情形		附錄-5
附錄三、期末審查會議紀錄暨回覆辦理情形		附錄-8

表次

表 3-1 降雨時間序列資料.....	3-13
表 3-2 地震報告資料.....	3-14
表 3-3 地震震度時間序列資料.....	3-15
表 3-4 數值化呈現的網格坡向.....	3-17
表 3-5 數值化呈現的網格坡度.....	3-18
表 3-6 數值化呈現的網格高程.....	3-19
表 4-1 降雨與地震震度預測因子值.....	4-17
表 4-2 ANN 訓練資料.....	4-18
表 4-3 網格預測崩塌機率.....	4-18





圖次

圖 1-1 莫拉克颱風當月雨量資料.....	1-1
圖 1-2 研究區域範圍	1-3
圖 1-3 高雄市-六龜區-D015 位置圖.....	1-4
圖 1-4 六龜區-D015 坡地範圍內道路狀況.....	1-4
圖 1-5 六龜區-D015 GOOGLE EARTH 立體地形圖	1-5
圖 1-6 計畫執行流程圖	1-6
圖 2-1 類神經網路架構示意圖	2-2
圖 2-2 FNN 模型架構圖	2-3
圖 2-3 遞迴式神經網路架構示意圖	2-4
圖 2-4 LSTM 網路架構示意圖	2-5
圖 3-1 研究區周邊斷層分布圖	3-2
圖 3-2 QGIS 操作介面示意圖.....	3-4
圖 3-3 72 小時每小時累計雨量資料示意圖	3-5
圖 3-4 地震歷史紀錄資料示意圖 3.....	3-6
圖 3-5 20 公尺 x20 公尺網格示意圖	3-8
圖 3-6 坡向資料.....	3-9
圖 3-7 坡度資料.....	3-10
圖 3-8 高程資料.....	3-10
圖 3-9 高雄六龜區寶來國中、國小附近之崩塌區示意圖.....	3-11
圖 3-10 民國 110 年盧碧颱風造成之崩塌範圍示意圖	3-12
圖 3-11 98 年莫拉克累計降雨時間序列.....	3-13
圖 3-12 地震測報中心的震度資料.....	3-14
圖 3-13 52 周每周最大 PGA 歷時	3-15
圖 3-14 臺灣坡向分布圖	3-16

圖 3-15 六龜地區網格坡向圖	3-16
圖 3-16 六龜地區網格波度圖	3-18
圖 3-17 HDR 檔案中的網格平均高程數據	3-19
圖 3-18 臺灣高程陰影圖	3-20
圖 4-1 LSTM 模型架構概述示意圖	4-3
圖 4-2 RELU 激發函數示意圖	4-3
圖 4-3 SIGMOID 激發函數示意圖	4-4
圖 4-4 訓練曲線圖收斂示意圖	4-5
圖 4-5 崩塌機率預測結果可視化	4-7
圖 4-6 第一次降雨訓練圖	4-10
圖 4-7 第一次地震訓練圖	4-10
圖 4-8 第二次降雨訓練圖	4-11
圖 4-9 第二次地震訓練圖	4-11
圖 4-10 第三次降雨訓練圖	4-12
圖 4-11 第三次地震訓練圖	4-12
圖 4-12 第四次降雨訓練圖	4-13
圖 4-13 第四次地震訓練圖	4-14
圖 4-14 第五次降雨之訓練圖	4-15
圖 4-15 第五次地震震度訓練圖	4-15
圖 4-16 降雨 LSTM 訓練集	4-16
圖 4-17 地震 LSTM 測試集	4-16
圖 4-18 混淆矩陣圖	4-19
圖 4-19 ROC 曲線圖	4-20
圖 4-20 崩塌預測圖	4-21
圖 4-21 崩塌前期熱點圖	4-21

圖 4-22 崩塌中期熱點圖	4-22
圖 4-23 崩塌後期熱點圖	4-22
圖 5-1 高 133 線道因土石流崩坍整修施工照	5-1
圖 5-2 區域調查範圍內水系圖	5-3
圖 5-3 研究區域周遭現有雨量站空間分布	5-4
圖 5-4 高 133 地區雨量站選取位置	5-5
圖 5-5 高 133 地區凱米颱風雨量分佈	5-5





第一章 緒論

臺灣位處於板塊交界帶，地震的頻發使得該區域之地層敏感度高，當強降雨事件發生時容易造成崩塌地質災害的發生，2009 年莫拉克颱風來襲，在短短幾天內便下了臺灣一整年的降雨量(如圖 1-1)，因為持續性降雨使得溪水暴漲、多處崩塌以及大規模山崩等連續發生之地質災害造成多達 474 人遭到活埋。因此本計畫使用降雨歷時資料以及地震歷史資料做為時間序列因子，坡度、高程、坡向、植被狀況等做為環境因子，藉由量化分析此兩種因子做為人工智慧模型的輸入資料，能以分割單位為目標進行崩塌積率的預測，提供災害應對的參考依據，並即時的做出更有效的災害應對措施。

2009年8月阿里山氣象站逐日雨量資料




圖 1-1 莫拉克颱風當月雨量資料

資料來源：Billy Pan 部落格文章，撰寫時間：2011 年 8 月 27 日，
網址：<https://billypan.pixnet.net/blog/post/37230455>

第一節 計畫欲解決的問題

本計畫擬解決問題，聚落位置山區，經常可能因為豪大雨導致邊

坡沖刷土石或造成泥流，因此導入 5D 創新技術，建立具備數位孿生功能的監測平台，可有效掌握聚落邊坡的安全，並且透過監測感測器回傳警戒值與行動值，可提醒聚落民眾提前做好防災準備工作，有效建立完善韌性聚落災害防護網。為預防以及減少崩塌帶來的損害，本計畫擬以人工智慧協助預測崩塌發生的潛在機率，配合具備數位孿生功能的監測平台，實現即時的災害評估。該人工智慧模型能對每單位網格進行崩塌機率預測，模型輸入為時間序列因子和環境因子，其中時間序列因子需由一長短期記憶模型(Long Short-Term Memory, LSTM)所判定。時間序列資料有一定的潛在特性是人為判讀難以發覺，每一筆時間序列資料之型態會受其特性所影響，例如：降雨延時、降雨強度等等，而 LSTM 根據降雨資料以及歷史地震分布時間序列資料之特性來找出該時間序列之潛在特性並判定時間序列因子。隨後結合該因子以及其他環境因子做為計算崩塌機率的輸入資料，以該輸入資料做為前饋式神經網路的訓練資料建置一崩塌機率預測模型，其中環境因子包含地質特性產生之地文因子。

為以人工智慧技術建立一崩塌機率預測模型，本團隊進行一系列資料收集以及模型建置與測試流程，透過資料的量化與分析結合人工智慧相關技術建立一有效之預測模型，提供一區域崩塌發生機率預測之有效依據。

第二節 計畫範圍

本計畫針對高雄六龜區，進行資料收集以及量化分析，本區因四面坡度起伏大，經歷強降雨後容易發生崩塌，且寶來國中及國小四周(圖 1-2)曾發生多起崩塌，特此選定此區作為本計畫之研究範圍。六龜

區-D015(圖 1-3)為一畚箕形之邊坡(圖 1-4)，坡面面向西北方，上邊坡坡度明顯較下邊坡陡峭，應是受到崩塌土石堆積於下邊坡之影響。由 D015 坡向圖(圖 1-5)亦可觀察到，D015 邊坡之上方由主稜線區隔、其坡面面向西北方，目前 D015 圈繪範圍之北邊界為一條蝕溝、南邊界為一凸坡，中央有一條發達大型蝕溝，邊坡之潛在滑移主要係沿坡向發生，以及蝕溝下切後沿兩側方向局部破壞。



圖 1-2 研究區域範圍

資料來源：本計畫繪製




圖 1-3 高雄市-六龜區-D015 位置圖

資料來源：本計畫繪製




圖 1-4 六龜區-D015 坡地範圍內道路狀況

資料來源：本計畫繪製




圖 1-5 六龜區-D015 google earth 立體地形圖

資料來源：本計畫繪製

第三節 執行流程與計畫目標

本計畫主要配合農業部農村發展及水土保持署 113 年度創新研究計畫之「軟體防災與新興科技應用」領域，發展或研究可供聚落(或社區)居民自行監測與研判聚落危險性之防災監測方式(或儀器)，讓居民隨時了解聚落環境狀況，以落實自主防災意識。

透過收集坡地之地文資料以及時間序列資料，建立基本資料庫與聚落 3D 虛擬模型，並利用 LSTM 模型對時序資料解算出時間序列因子。結合地文資料整理而成之環境因子以及解算出之降雨時序因子、地震歷史時序因子，利用前饋式類神經網路來計算每個大小為 10m*10m 之網格崩塌機率，達成坡地崩塌風險評估，再配合佈署於當地的感測器及測站，使用物聯網即時將資料傳輸並解析，以利協助

強降雨或地震發生時崩塌發生之預警，並提供更即時的救災規劃資訊，降低坡地崩塌的負面影響以及保障人民的財產生命安全，執行流程如圖 1-6 所示。




圖 1-6 計畫執行流程圖

資料來源：本計畫繪製

預期達成之計畫目標如下。

- 一、資料蒐集整理：從各機關資料開放平台(政府資料開放平台、國土測繪圖資服務雲、Codis氣候觀測資料查詢服務、中央氣象署地震測報中心等)或文獻中蒐集研究範圍內各類地文資料以及時間序列資料。
- 二、建立基本資料庫：運用QGIS等地理資訊軟體，將各類圖資(高程圖、坡向圖等)進行數值化，建立聚落防災數位孿生物聯網監測系統之基本3D模型。結合時間序列資料(降雨歷時、地震歷史紀錄)，

整理並記錄上述地文資料和時序資料，並建立長短期記憶模型。以時序資料訓練模型，預測出時間序列因子。

三、風險評估成果檢視：建立前饋式類神經網路模型，使用資料庫中崩塌發生之歷史事件為訓練資料，訓練一類神經網路模型之權重，使其能準確結合各項因子來預測崩塌機率。使用的因子包括地文因子以及由長短期記憶模型所得之時間序列因子，進行坡地發生崩塌之機率預測並顯示於網格資料中。

四、預期成果：評估模型準確度，並說明該模型可能運用範圍以及未來展望，將最佳化後的模型投入聚落防災數位孿生物聯網監測系統中，配合當地自動監測站，以即時之降雨歷時、地震歷時等資料，以長短期記憶模型所得之時間序列因子，預測未來坡地坍塌之機率，以期該研究成果成為災害預警及即時救災之依據。





第二章 文獻回顧

第一節 類神經網路 (Artificial Neural Network)

類神經網路又別名人工神經網路，在認知科學之領域中，是一種模仿生物大腦運作的機器學習方式。在人類大腦中主要由神經元和突觸所形成，而每個神經元都有其階層性，連結強度也大不相同。而類神經網路就是利用電腦來模擬人類大腦的運作方式，一般而言分為前饋式類神經網路和遞迴式類神經網路。前饋式類神經網路的訊號傳遞只有單方向，不會構成迴圈，又能依據其複雜度分為單層前饋式類神經網路和多層前饋式網路兩種，早期所使用的感知器皆屬於單層式，其分為兩個層次，分別為輸入層和輸出層，因架構較為簡單最多僅能處理較不複雜的非線性問題；而多層式意即不同層的神經元彼此有關聯，架構如(圖 2-1)所示。

其架構可以分為輸入層(Input Layer)、隱藏層(Hidden Layer)、以及輸出層(Output Layer)。由輸入層接收輸入模型之資料，透過集成函數(Summation Function)及權重參數(Weight)進行資料累加運算與資料權重調整，再將計算之結果傳入隱藏層；資料由輸入層傳入隱藏層，並經由激發函數(Activation Function)等非線性函數，進行資料維度轉換、閾值判定等多種不同之運算，再藉由損失函數(Loss Function)反饋給神經元，對梯度進行最佳化，調整模型參數。最後輸出層負責輸出結果，並可依據目標需求調整輸出資料的形式，達成數值回歸或資料分類之工作。




圖 2-1 類神經網路架構示意圖

資料來源：神經網路架構圖-

<https://nccur.lib.nccu.edu.tw/bitstream/140.119/35873/6/25700606.pdf>

根據隱藏層的設計，類神經網路又可分為前饋式類神經網路 (Feedforward Neural Network, FNN) 和遞迴式類神經網路 (Recurrent Neural Network, RNN)。FNN 的資料傳遞方向只有單一方向，不會構成迴圈，又能依據其複雜度分為單層式 FNN 和多層式 FNN，早期所使用的感知器皆屬於單層式，僅將層次分為輸入層和輸出層，只能處理較不複雜的非線性問題；而多層式意即不同層的神經元互有關連性，能夠更具關連程度給予下一層更具備資料特性之輸出。

多層前饋式類神經網路能夠經由不同層神經元關聯性，將多維的輸入資料映射至輸出值上，因此本計畫採用 FNN 做為崩塌機率預測模型的訓練架構(如圖 2-2)。




圖 2-2 FNN 模型架構圖

資料來源：本計畫繪製

為了考量多維資料之前後關聯，RNN 中的神經元輸出之資料會回傳至同一層的神經元(圖 2-3)，以此方式上一時刻的資訊回傳至網路中，使網路能考慮前一時刻網路產生之輸出值，該流程使得類神經網路具備記憶性，能儲存並回饋至下一筆的資料處理中，其應用也可以擴展到與時間序列或有前後關聯的預測上。遞迴式類神經網路的應用也不限於任何領域及型態，如於 2001 年，張等人將其用於推估精確度較不易掌握的河川流量推估。於 2017 年，鄭將遞迴類神經網路應用在複雜、非線性且非穩態的匯率預測；苟等人將其運用在社交網路中消息爆發的傳播過程預測。本計畫中應用之 LSTM 即屬遞迴式類神經網路中的一個分支，其相較於遞迴式類神經網路，LSTM 透過四個閥門控制記憶單元的記憶功能，以解決梯度消失(vanishing gradient problem)以及梯度爆炸(exploding gradient problem)的問題。




圖 2-3 遞迴式神經網路架構示意圖

資料來源：心理學維基百科

第二節 長短期記憶模型 (Long Short-Term Memory , LSTM)

LSTM 為 RNN 的一種，具備儲存前一次隱藏層輸出值的功能，使得每次輸出值不僅受到當前輸入值的影響，更會根據前一次的儲存參數進行調整，攜帶舊有記憶訊息進入下一層神經元，這樣的記憶傳遞使得模型可以有效捕捉長期依賴關係（如圖 2-4）。由於 RNN 架構中的網路權重在反向傳播過程中會不斷傳遞與相乘，這可能導致梯度爆炸或梯度消失的問題，使得網路訓練困難，模型表現不佳。

為了解決這些問題，LSTM 在 RNN 的基礎上增加了三個閥門控制記憶單元，分別為輸入閥(input gate)、輸出閥(output gate)、遺忘閥(forget gate)，輸入閥決定是否將資料寫入記憶單元，輸出閥控制其他神經元是否從記憶單元中將值讀出，遺忘閥控制過去記憶資料並決定是否保存或刪除。各閥門的激活權重由類神經網路在訓練過程中學習，因此若加上原始資料之輸入值的閥門，對於整個 LSTM 系統共有四

個輸入值以及一個輸出值。

輸入閥通過一個 sigmoid 層來篩選哪些值將被更新到記憶單元；輸出閥則同樣通過 sigmoid 層來決定哪些部分的記憶將被輸出；遺忘閥則控制記憶單元內部狀態的更新程度，選擇性地忘記一些不再需要的信息。這種設計有效防止了梯度消失問題，並允許模型在長時間序列中保持穩定的記憶和輸出。




圖 2-4 LSTM 網路架構示意圖

資料來源：Water Quality Prediction Based on LSTM and Attention Mechanism: A Case Study of the Burnett River, Australia

首先，在某個時間步幅 t 下之輸入值會如式 1 中的 $\tanh$ 函數來控制。

$$j_t = \tanh(W_x X_t + W_{hj} h_{t-1} + b_j) \quad (1)$$

式 1 中 j_t 為輸入值通過 $\tanh$ 之結果， X_t 為 t 時刻之輸入值， h_{t-1} 則為 $t-1$ 時刻之短時記憶，也就是 $t-1$ 時刻 LSTM 之輸出值， b_j 為偏差值。而另外三個閥門則是由 sigmoid 函數控制，由 0 或 1 來界定閥

門的開啟或是關閉，輸入閥、遺忘閥、輸出閥分別以式 2、3、4 表示。

$$i_t = \text{sigmoid}(W_{xi}X_t + W_{hi}h_{t-1} + b_i) \quad (2)$$

$$f_t = \text{sigmoid}(W_{xf}X_t + W_{hf}h_{t-1} + b_f) \quad (3)$$

$$o_t = \text{sigmoid}(W_{xo}X_t + W_{ho}h_{t-1} + b_o) \quad (4)$$

其中 i_t 、 f_t 、 o_t 分別為輸入值通過輸入閥、遺忘閥、輸出閥之結果。

此外，長時記憶 c 以式 5、6 來表示。

$$c_t = f_t \circ c_{t-1} + i_t \circ j_t \quad (5)$$

$$h_t = \tanh(c_t) \circ o_t \quad (6)$$

其中 c_t 和 c_{t-1} 為 t 時刻和 $t-1$ 時刻之長期記憶，而 $\circ$ 符號代表阿達瑪積，為矩陣運算中的逐項乘積， h_t 則為 LSTM 在 t 時刻之最後輸出值。計算出 c_t 值後，即可當作下一時刻的長時記憶輸入值，且 c_t 值再由 $\tanh$ 函數和輸出閥的控制值 o_t 相乘，即可得到則為 t 時刻輸出值 h_t 。且新的輸出值 h_t 不僅會成為該神經元下一個時刻的輸入值，更會遞迴至同一隱藏層的其他神經元以及下一個隱藏層之神經元，以此方式不斷遞迴下去。

第三章 模型訓練資料庫建立

第一節 選定研究範圍

本計畫在高雄六龜區內，將針對鄰近寶來國中、國小以及其他鄰近荖濃溪之區域選取，因本處位於荖濃溪自寶來急轉而來的凹岸處，暴雨時大量洪流沖刷亦對坡腳產生強有力的淘蝕，對邊坡的穩定性亦有相當大的影響。且歷年位於本區的崩塌事件眾多，將提高蒐集資料的多樣性。若能找出時間序列資料與該地區環境因子的崩塌關係，將能提前預防並提供更快速的救災。基於上述原由，本研究團隊選取臺灣高雄六龜地區崩塌相對密集的區域作為本計畫之研究範圍。

本研究區內由潮州斷層(圖 3-1)貫穿，為逆移斷層兼具左移性質，呈南北走向。斷層可以分為 2 段：北段由高雄市六龜鄉寶來村向南延伸至屏東縣三地門鄉大津村，長約 28 公里，本段又稱土壟灣斷層，南段由大津村向南延伸至枋寮鄉加祿村，長約 61 公里，總長約 89 公里。潮州斷層為高角度向東傾斜的逆移斷層，兼具左移性質。因研究區域位於荖濃溪自寶來急轉而來的凹岸處，且由斷層貫穿，導致本地崩塌事件頻繁。

透過政府開放資料平台及國土測繪圖資服務雲，獲取選定區域圖層以及周邊相關地質、水文等地理資訊圖層，以獲取訓練模型所需要之地文資料。這些資料將包括該地區的地質構造、土壤類型、坡度、植被覆蓋率等資訊，進一步分析這些因子與崩塌之間的關係。

此外，我們將使用 CODiS 平台來獲取得各個測站的降雨資料，以一小時之時雨量資料為單位整理成降雨時序資料。這些資料將有助於了解降雨強度、頻率與崩塌發生之間的關聯性。同時，結合由中央

氣象署地震測報中心之測站所得地震資料，組成地震時序資料，以分析地震活動對該區域崩塌的影響。

在數據蒐集和整理完成後，我們將應用先進的機器學習算法進行模型訓練，建立崩塌預測模型。模型將根據所蒐集到的歷史數據進行訓練，以期能準確預測未來可能發生的崩塌事件。研究結果不僅可以提高災害預警的準確性，還能為政府和相關部門提供科學依據，進行防災減災的規劃與決策，最終達到減少災害損失、保護人民生命財產安全的目的。



圖 3-1 研究區周邊斷層分布圖

資料來源：本計畫繪製

第二節 基本資料庫說明

為了進行人工智慧分析，需先建立基本資料庫。本計畫將結合環境因子和時間序列因子進行坡地崩塌機率評估，分別進行兩者的基本

資料收集，以作為後續模型預測崩塌潛在機率所使用的輸入資料。

在環境因子的部分，將蒐集相關地質、水文等地理資訊、集水區基本圖資等資料，並使用內政部之數值高程模型，結合 QGIS (圖 3-2)等地理資訊軟體，獲取高程、計算坡度等各項地形參數，將其整理成 20mX20m 網格資料庫。這些網格資料庫將連結研究範圍內之各項屬性因子，建置環境因子資料，其中包含坡度、高程、坡向、斷層、地理地質、以及經過實地探訪所調查之植被情況。崩塌歷史事件資料將採用土石流及大規模崩塌防災資訊網之相關調查報告作為參考資料。

時間序列因子方面，將採用長短期記憶模型 (LSTM) 來進行估算。首先，將使用該區域數年來之地震歷史資料，經過資料處理後組成一時間序列，這些資料即是地震時間序列資料。降雨資料則使用來自 CODiS 的月資料報表，根據每一筆崩塌事件發生時間向前擷取 72 小時之雨量資料，作為該崩塌事件之相應降雨時間序列。在崩塌機率預測時，將使用當下之前六小時雨量資料作為時間因子判定的時序資料。

為了將時間序列資料之特徵轉換成利於模型預測崩塌機率之數值特性，需將時間序列資料解算成時間序列因子。本計畫將使用長短期記憶模型 LSTM 來進行因子解算。這些資料和模型將被整合到我們的人工智慧系統中，旨在提高崩塌預測的準確性，並為政府和相關部門提供可靠的科學依據，用於防災減災的規劃與決策。




圖 3-2 QGIS 操作介面示意圖

資料來源：本計畫繪製

第三節 資料量化與因子解算

崩塌潛在機率預測模型需接收時間序列因子和環境因子這兩類數值化數據，才能根據模型權重進行機率預測。時間序列因子的解算需使用降雨資料和地震紀錄資料兩項資料，並依照以下步驟進行整理以及解算。

一、降雨資料

(一) 針對研究區域的崩塌事件，以歷年崩塌事件發生之時間，如 98 年莫拉克颱風造之崩塌，以當時最大降雨量作為崩塌之時間，往前回推 5 周(840 小時)，並將其以滑動窗口的形式，以步長為 1 小時，切割成 769 筆 72 小時每小時累計降雨量(圖 3-3)，並將其作為訓練之輸入。

(二) 去除 769 筆內的最後一筆每小時累計降雨時間序列，將剩餘

768 筆做為 LSTM 之輸入資料，並以崩塌事件紀錄之崩塌地區當作訓練標籤進行模型訓練。

- (三) 降雨因子值根據累計降雨量的變化、均值和標準差計算，並隨崩塌時間接近增加權重，給定 LSTM 訓練資料之因子值。
- (四) 對模型測試結果以及模型訓練收斂性進行評估，確認模型解算出之時間序列因子為有效後，完成時間序列因子解算模型的建置。
- (五) 模型訓練完成後，將選定地區之崩塌前 72 小時降雨序列資放入模型，所得出之結果作為後續崩塌機率預測模型之輸入資料。




圖 3-3 72 小時每小時累計雨量資料示意圖

資料來源：本計畫繪製

二、地震資料

- (一) 將待測時間段前五年(260 周)之每周最大 PGA 歷時資料，利用滑動窗口，以步長為一周，切割成 209 筆 52 周每周最大 PGA

歷時資料(圖 3-4)，整理為時間序列資料。

- (二) 去除 209 筆內的最後一筆每小時累計降雨時間序列，將剩餘 208 筆做為 LSTM 之輸入資料，並以崩塌事件紀錄之崩塌地區當作訓練標籤進行模型訓練。
- (三) 地震因子值基於震度的最大值、平均值和變化量來設定，簡化計算並保留地震強度的影響，給定 LSTM 訓練資料之因子值。
- (四) 對模型測試結果以及模型訓練收斂性進行評估，確認模型解算出之時間序列因子為有效後，完成時間序列因子解算模型的建置。
- (五) 模型訓練完成後，將選定地區之崩塌前 52 周地震強度序列資放入模型，所得出之結果作為後續崩塌機率預測模型之輸入資料。




圖 3-4 地震歷史紀錄資料示意圖 3

資料來源：本計畫繪製

環境因子的組成包括坡向、坡度以及高程等地文資料。由於各項數

據的量級差異較大，直接輸入模型可能導致高量級屬性對結果產生偏倚，因此在進行模型訓練前，需先對這些資料進行標準歸一化處理。通過將數據轉換至相同範圍，能確保各屬性對預測結果的影響力均衡，避免某一屬性因數值過大或過小而主導模型判斷，同時也有助於加快模型的收斂速度並提高訓練穩定性。

第四節 DEM 模型 20m x 20m 網格

數值高程模型（Digital Elevation Model, DEM）是通過有限的地形高程數據實現對地面地形的數字化模擬，使地形表面形態能夠以數字化表達，為一種以一組有序數值形式表示地面高程的一種實體地面模型。為了將資料有效量化，以利於人工智慧模型進行機率預測，本計畫將前面小節提及之因子與 DEM 做結合，形成以網格為單位的資料集合。本計畫將使用 20m x 20m 的網格大小(圖 3-5)作為分析的最小單元。在這些網格中，每個單元將包含多個環境因子和時間序列因子的數據。環境因子包括坡度、高程與坡向等地理資訊；時間序列因子則包括前 72 小時的時雨量資料和近五年來該區每周最大 PGA 歷時且距離目標測站 30 公里以內的地震資料。這些網格化的數據集合將被輸入到人工智慧模型中進行崩塌潛在機率的預測。在模型訓練和測試的過程中，我們將根據預測結果進行誤差分析，評估模型的準確性和穩定性。如果預測結果的誤差較大，我們將根據分析結果調整網格大小，重新劃分網格並重新進行模型訓練，以找到一個最適當的網格維度作為資料集合的大小。為了確保數據的全面性和準確性，本計畫將持續蒐集和更新相關的地理資訊和時間序列數據。新的數據將被整合到現有的網格資料集合中，並根據新的數據對模型進行重新訓練

和優化，以提高模型預測的準確性和穩定性。為了實現這一目標，本計畫將利用先進的地理資訊系統（GIS）工具，如 QGIS，來處理和分析數值高程模型和其他地理數據。這些工具能夠有效地管理和分析大量的地理數據，並將其轉換為模型訓練所需的格式和結構。




圖 3-5 20 公尺 x20 公尺網格示意圖

資料來源：本計畫繪製

第五節 網格資料庫建置

崩塌機率預測模型和時間序列因子解算模型都需要訓練樣本資料做為輸入資料，因此我們需預先建立一以網格維度大小為單位之資料庫，將蒐集而來之資料和網格單位做有效的結合。各資料初步預想之結合方式如下所列，其步驟以及方法將會在之後的結果評估中做適當調整以利於模型訓練之收斂性與成效。

一、降雨資料：收集研究區域中心最近之雨量降雨測站之資料。

二、地震歷史紀錄：使用研究區域中心最近且資料齊全之地震測站資料，並假設網格所接收到的地震震度與測站相同。

三、坡向：選取網格範圍內之九個可能坡向之比例中最大者做為該往個的代表坡向(如圖3-6)，九個可能坡向包含平地、東、西、南、北、東北、東南、西北、西南。根據內政部所提供的網格數值模型地形資料，內容包括透過顏色表達網格地形分布的GRD檔案及單純儲存崩塌文字資料像是平面座標系、圖幅西南偶E座標、圖幅西南偶N座標等等的HDR檔案，將GRD檔匯入QGIS後儲存成tiff檔，並使用內建的程式將tiff檔轉成shp檔後即可利用QGIS內建的坡向分析程式可以將用顏色表達的地形分布圖以數值化的方式呈現。

坡向類別	格點百分比	格點面積 (平方公尺)
平地	0.00000000	0.0
北	0.00000000	0.0
東北	0.00000000	0.0
東	0.00000000	0.0
東南	0.00000000	0.0
南	0.00000000	0.0
西南	0.00000000	0.0
西	0.00000000	0.0
西北	1.00000000	3600.0

圖 3-6 坡向資料

資料來源：本計畫繪製

四、坡度：根據範圍內的坡度分級(圖3-7)和面積占比之乘積決定該網格範圍之平均坡度。根據內政部所提供的網格數值模型地形資料，內容包括透過顏色表達網格地形分布的GRD檔案及單純儲存崩塌文字資料像是平面座標系、圖幅西南偶E座標、圖幅西南偶N座標等等的HDR檔案，將GRD檔匯入QGIS後儲存成tiff檔，並使

用內建的程式將tiff檔轉成shp檔後即可利用QGIS內建的坡度分析程式可以將用顏色表達的地形分布圖以數值化的方始呈現。

坡度	格點百分比	格點面積 (平方公尺)
一級坡	0.0	0.0
一級坡	0.0	0.0
三級坡	0.1875	1200.0
四級坡	0.1875	1200.0
五級坡	0.25	1600.0
六級坡	0.375	2400.0
七級坡	0.0	0.0

圖 3-7 坡度資料

資料來源：本計畫繪製

五、高程：網格內之所有高程點之高程值平均做為網格高程(圖3-8)。根據內政部所提供的網格數值模型地形資料，內容包括透過顏色表達網格地形分布的GRD檔案及單純儲存崩塌文字資料像是平面座標系、圖幅西南隅E座標、圖幅西南隅N座標等等的HDR檔案，將GRD檔匯入QGIS後儲存成tiff檔，並使用內建的程式將tiff檔轉成shp檔後即可直接查看網格高程。

#	X	Y	Z
1	240918.794782	2679330.200675	994.423328
2	240881.738297	2679312.886241	988.456267
3	240883.892369	2679273.873819	1001.108777
4	240947.097293	2679289.004315	1027.32126
5	240927.461434	2679252.173044	1007.581902

圖 3-8 高程資料

資料來源：本計畫繪製

第六節 崩塌坡地資料庫建立成果

本計畫採用聚落防災數位孿生物聯網監測系統，配合人工智慧協助預測崩塌發生的潛在機率分析功能，建立可即時評估聚落邊坡災害平台。因此在資料庫建立上，需考量聚落地區的特性，本計畫選定實證場域為六龜地區聚落，主要原因六龜地區被四周及坡以上之坡度包圍，導致颱風來襲或發生強降雨時，常有崩塌、地滑等土砂災害。因此選定為六龜地區聚落建置崩塌網格資料庫地區，目前總共收集崩塌的網格資料數量 9,740 格。

以下為高雄六龜區資料建置資料庫過程為例，總共有 1548 格網格資料，選定區域為寶來國中、國小附近的崩塌地區(如圖 3-9)，崩塌時間為 2021 年盧碧颱風造成。



圖 3-9 高雄六龜區寶來國中、國小附近之崩塌區示意圖

資料來源：本計畫繪製

從數位發展部的政府資料開放平台下載事件型崩塌目錄，內容包

含 20 公尺網格數值模型資料總共 37,180 格網格，利用 QGIS 內建的網格繪製程式設定邊界及網格長度和寬度分別為 20 公尺繪製網格，找到崩塌區域及網格重疊部分後將其他網格刪除，只留下崩塌附近網格(如圖 3-10)，作為環境因子的蒐集及分析對象，各項環境因子蒐集後之資料分述如下。




圖 3-10 民國 110 年盧碧颱風造成之崩塌範圍示意圖

資料來源：本計畫繪製

一、降雨資料

作為時間序列因子的一部分，透過觀測資料查詢系統獲取並整理崩塌事件前 5 周(840 小時)之每小時降雨資料。研究範圍切割成 20m x 20m 的網格後，對每個崩塌事件年進行累計降雨量轉換，以最大時降雨量作為崩塌時間點。採用滑動窗口法，步長設為 1 小時，將 840 小時累計降雨量資料切割為 769 筆 72 小時的每小時累計降雨資料(表 3-1)，以供後續長短期記憶模型模型 (Long Short-Term Memory, LSTM)解算時間序列因子，為確保訓練數據的有效性，將每筆資料中的崩塌時間前 72 小時數據剔除，形成每年 768 筆 72 小時的每小時累計降雨資料(圖 3-11)作為模型訓練的輸入數據。之後，使用各崩塌年份的預測資料，即剔除崩塌時間前 72 小時的降雨數據，作為模型的

預測之輸入，以解算該地區的崩塌因子。

表 3-1 降雨時間序列資料

小時 滑動次數	0	1	2	3	4
16	0.5	6.5	37.5	39	39
17	6.5	37.5	39	39	39.5
小時 滑動次數	5	6	7	8	9
16	39.5	45.5	45.5	45.5	46
17	45.5	45.5	45.5	46	47

資料來源：本計畫整理




圖 3-11 98 年莫拉克累計降雨時間序列

資料來源：本計畫繪製

二、地震紀錄

作為時間序列因子的一部分，通過中央氣象署地震測報中心的地震報告資料(表 3-2、圖 3-12、表 3-3)，查詢選定區域中距離崩塌中心最近且資料最完整的地震測站，獲取每個崩塌事件發生前 5 年的每周最大 PGA（Peak Ground Acceleration）數據。根據不同年份的崩塌事

件，分別收集其發生前 5 年的每周最大 PGA 歷時數據，並以滑動窗口法進行處理，步長設為 1 周，整理成 209 筆包含 52 周每周最大 PGA 的時間序列資料(圖 3-13)，以供後續 LSTM 解算時間序列因子，在模型訓練過程中，將每筆崩塌事件的資料中崩塌發生前一年（即前 52 周）數據剔除，剩下的 208 筆數據用於訓練模型。訓練完成後，利用被剔除的前一年的資料作為模型的預測輸入，以解算該地區的崩塌因子。

表 3-2 地震報告資料

震央距離	震度	最大	最大加速度 (gal = cm / s ² > 2)		
		PGA	垂直	南北	東西
6.98	3	24.1	6.04	24.1	20.82

資料來源：地震測報中心




圖 3-12 地震測報中心的震度資料

資料來源：中央氣象署地震測報中心

表 3-3 地震震度時間序列資料

震度 滑動次數	0	1	2	3	4	5	6	7	8	9
37	0	23.54	8.72	0	0	0	0	0	0	0
38	0	0	23.54	8.72	0	0	0	0	0	0

資料來源：本計畫整理




圖 3-13 52 周每周最大 PGA 歷時

資料來源：本計畫繪製

三、坡向

為考量的環境因子其中之一，根據內政部所提供的網格數值模型地形資料，內容包括透過顏色表達網格地形分佈的 GRD 檔案及單純儲存崩塌文字資料像是平面座標系、圖幅西南偶 E 座標、圖幅西南偶 N 座標等等的 HDR 檔案，利用 QGIS 內建的坡向分析程式可以將 GRD 檔中用顏色表達的地形分佈圖以數值化的方始呈現，最後再透過地圖顏色調整做出臺灣坡向分布(如圖 3-14)，以取得目標區域的坡向資料，並彙整入資料庫和其他地文資料一起量化成環境因子，高雄

六龜地區坡向圖(如圖 3-15)及數值化呈現的坡向表格(如表 3-4)如下。




圖 3-14 臺灣坡向分布圖

資料來源：本計畫繪製




圖 3-15 六龜地區網格坡向圖

資料來源：本計畫繪製

表 3-4 數值化呈現的網格坡向

網格	坡向	網格	坡向
1	338.9377	7	126.3251
2	355.1035	8	124.5929
3	143.5009	9	130.9311
4	143.1634	10	135.1532
5	133.4126	11	135.6270
6	130.0665		

資料來源：本計畫整理

四、坡度

為考量的環境因子其中之一，根據內政部所提供的網格數值模型地形資料，內容包括透過顏色表達網格地形分佈的 GRD 檔案及單純儲存崩塌文字資料像是平面座標系、圖幅西南隅 E 座標、圖幅西南隅 N 座標等等的 HDR 檔案，利用 QGIS 內建的坡度分析程式可以將 GRD 檔中用顏色表達的地形分佈圖以網格(如圖 3-16)及數值化的方式呈現(如表 3-5)，以取得目標區域的坡度資料，並彙整入資料庫和其他地文資料一起量化成環境因子。




圖 3-16 六龜地區網格坡度圖

資料來源：本計畫繪製

表 3-5 數值化呈現的網格坡度

網格	坡度	網格	坡度
1	40.8831	7	48.4582
2	19.8152	8	49.1925
3	34.7663	9	53.0935
4	49.5896	10	56.6320
5	48.2407	11	56.6349
6	48.5838		

資料來源：本計畫整理

五、高程

為考量的環境因子其中之一，根據內政部所提供的網格數值模型地形資料，內容包括透過顏色表達網格地形分佈的 GRD 檔案及單純儲存崩塌文字資料像是平面座標系、圖幅西南隅 E 座標、圖幅西南隅 N 座標等等的 HDR 檔案，而網格中心高程數值包含在 HDR 檔案中(如圖 3-17)，也可以利用 QGIS 內建的高程分析程式可以將 GRD 檔中用顏色表達的地形分佈圖以數值化的方始呈現(如圖 3-18)，以取得目標區域的高程資料，並彙整入資料庫和其他地文資料一起量化成環境因子。

	fid	VALUE	_count	_sum	_mean
1	1	1070.19995117	1	1070.1999511...	1070.1999511...
2	2	1066.42004395	1	1066.4200439...	1066.4200439...
3	3	1061.81005859	1	1061.8100585...	1061.8100585...
4	4	1055.80004883	1	1055.8000488...	1055.8000488...
5	5	1046.07995605	1	1046.0799560...	1046.0799560...
6	6	1028.19995117	1	1028.1999511...	1028.1999511...
7	7	1008.60998535	1	1008.6099853...	1008.6099853...
8	8	1004.41998291	1	1004.4199829...	1004.4199829...
9	9	1017.98999023	1	1017.9899902...	1017.9899902...
10	10	1035.70996094	1	1035.7099609...	1035.7099609...
11	11	1049.98999023	1	1049.9899902...	1049.9899902...
12	12	1046.20996094	1	1046.2099609...	1046.2099609...
13	13	1035.08996582	1	1035.0899658...	1035.0899658...
14	14	1024.01000977	1	1024.0100097...	1024.0100097...
15	15	1014.01000977	1	1014.0100097...	1014.0100097...
16	16	1003.29998779	1	1003.2999877...	1003.2999877...
17	17	990.02001953	1	990.02001953...	990.02001953...
18	18	976.20001221	1	976.20001220...	976.20001220...
19	19	961.7199707	1	961.71997070...	961.71997070...
20	20	944.98999023	1	944.98999023...	944.98999023...
21	21	928.09997559	1	928.09997558...	928.09997558...
22	22	913.98999023	1	913.98999023...	913.98999023...
23	23	904.48999023	1	904.48999023...	904.48999023...
24	24	913.40997314	1	913.40997314...	913.40997314...
25	25	926.32000732	1	926.32000732...	926.32000732...
26	26	937.60998535	1	937.60998535...	937.60998535...
27	27	943.90997314	1	943.90997314...	943.90997314...
28	28	948.59997559	1	948.59997558...	948.59997558...
29	29	953.5	1	953.5	953.5
30	30	958.40002441	1	958.40002441...	958.40002441...
31	31	963.91998291	1	963.91998291...	963.91998291...

圖 3-17 HDR 檔案中的網格平均高程數據

資料來源：本計畫繪製

表 3-6 數值化呈現的網格高程

網格	高程	網格	高程
1	2072.03	7	2078.19
2	2056.92	8	2099.91
3	2054.91	9	2116.83
4	2057.12	10	2137.57
5	2054.53	11	2165.19
6	2065.42		

資料來源：本計畫整理



圖 3-18 臺灣高程陰影圖

資料來源：本計畫繪製



第四章 模型測試與訓練

第一節 模型建置流程

使用 LSTM 模型對時間序資料進行解算並得出時間序列因子，配合地文資料整理而成之環境因子，最後利用前饋式類神經網路來計算每格大小為 20m*20m 之網格崩塌機率，如圖 1-6 流程圖所示。

第二節 LSTM 網路建置

本計畫使用 TensorFlow 框架構建深度學習模型，針對降雨和地震數據的時間序列進行因子解算及崩塌因子的預測。TensorFlow 作為開源框架，具備高度擴充性，有效支持深度學習模型的構建、測試與評估，從而提升模型在複雜數據中的適應性。

模型首先通過 Normalization 層對數據進行標準化，以確保數據的穩定性和一致性。接下來，模型包含兩層 LSTM 層結構(圖 4-1)。第一層 LSTM 設有 128 個單元，並設置為輸出完整的序列結果，用於捕捉輸入數據中的長期依賴性。第二層 LSTM 則包含 64 個單元，僅輸出最後的序列結果。兩層 LSTM 後分別接有 BatchNormalization 和 Dropout 層，BatchNormalization 層穩定數據分佈、加速收斂，而 Dropout 層則隨機屏蔽部分神經元，減少過擬合現象，增強模型的泛化能力。

接著，模型增設了一層 32 單元的 Dense 層，使用 ReLU 激活函數(圖 4-2)增強非線性特徵的表示能力，並再次加入 Dropout 層以進一步減少過擬合的風險。最終輸出層為 1 個單元，採用 Sigmoid 激活函數(圖 4-3)，將輸出值限制在 0 到 1 之間，以適合崩塌因子的概率預測需求。Sigmoid 函數能將輸出值映射至概率範圍，便於進行崩塌風

險的評估和解釋，使模型結果更具解釋性。

為了進一步優化模型性能，選用 Huber Loss 作為損失函數，該損失函數在大誤差時提供穩健的計算方式，提升模型的穩定性。優化器選擇 Adam，學習率設為 $1e-4$ 。此外，引入 EarlyStopping 和 ReduceLROnPlateau 回調函數，EarlyStopping 在 50 個 epoch 無改善後提前停止訓練並恢復最佳權重，ReduceLROnPlateau 則在無改善時減少學習率，以進一步提升模型的收斂性和穩定性。

此設計結合多層 LSTM、Dense、BatchNormalization 和 Dropout 層，使模型在處理非線性特徵學習和時間序列數據時具有優勢，最終達成高準確性的崩塌風險預測目標。由於模型的預測目標為數值 0~1 之因子值，因此選擇使用 Huber Loss 損失函數，以平衡對異常值的穩健性與訓練效率。Huber Loss 在誤差小於特定閾值時，行為類似於均方誤差(Mean Squared Error, MSE)，但在誤差超過閾值時，則轉為線性損失，減少了對異常值的敏感性。這有助於提升神經網路學習的穩定性，避免因異常值而導致的學習偏差。其計算公式如下：

$$L_{\delta}(y, \hat{y}) = \begin{cases} \frac{1}{2}(y - \hat{y})^2, & \text{if } |y - \hat{y}| \leq \delta \\ \delta * \left(|y - \hat{y}| - \frac{1}{2}\delta\right), & \text{otherwise} \end{cases} \quad (7)$$

其中， y 為目標真正的實際值， $\hat{y}$ 為類神經網路的輸出值， δ 為閾值，用來決定轉折點。此損失函數在誤差較小時保持 MSE 的優點，當誤差較大時則減少梯度，使模型更穩定。

模型使用的評估指標為均方根誤差(Root Mean Squared Error, RMSE)以及決定係數(Coefficient of Determination, R^2)，RMSE 衡量預測值與實際值的平均偏差，反映預測誤差的量級，數值越小表示預測

更接近實際值。 R^2 評估模型解釋數據變異的能力，範圍為 0 到 1，數值越接近 1，表示模型能更好地解釋輸入數據與結果間的關聯性。這兩個指標便於量化模型性能及調整效果，提供可靠的比較基準。其計算如下式所示：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

其中， y_i 是實際值， $\hat{y}_i$ 為預測值， n 為樣本數量。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

其中， y_i 是實際值， $\hat{y}_i$ 為預測值， $\bar{y}$ 是實際值的平均值， n 為樣本數量。

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 72, 128)	66,560
batch_normalization (BatchNormalization)	(None, 72, 128)	512
dropout (Dropout)	(None, 72, 128)	0
lstm_1 (LSTM)	(None, 64)	49,408
batch_normalization_1 (BatchNormalization)	(None, 64)	256
dropout_1 (Dropout)	(None, 64)	0
dense (Dense)	(None, 32)	2,080
dropout_2 (Dropout)	(None, 32)	0
dense_1 (Dense)	(None, 1)	33

Total params: 355,761 (1.36 MB)
 Trainable params: 118,465 (462.75 KB)
 Non-trainable params: 384 (1.50 KB)
 Optimizer params: 236,932 (925.52 KB)

圖 4-1 LSTM 模型架構概述示意圖

資料來源：本計畫繪製

ReLU
 $\max(0, x)$




圖 4-2 ReLU 激發函數示意圖

資料來源：本計畫繪製

Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$




圖 4-3 sigmoid 激發函數示意圖

資料來源：本計畫繪製

第三節 網路訓練和驗證

在 LSTM 的訓練與測試過程中，使用資料庫中不同時段的降雨和地震紀錄時間序列作為樣本資料。隨機選取 80%的樣本作為訓練樣本，其餘 20%作為測試樣本。每筆樣本包含降雨時間序列、地震紀錄時間序列及相應的崩塌事件類別標籤。標籤的設定為：若該時段網格發生崩塌事件，則標籤值設為 1；若無崩塌事件，則標籤值設為 0。

訓練樣本經由嵌入層轉換後，進入 LSTM 網路進行多次訓練與測試，並根據訓練結果生成包含訓練損失和驗證損失的 epoch-loss 曲線圖（圖 4-4）。此曲線圖將訓練曲線和驗證曲線合併在一張圖上，便於觀察訓練過程中的趨勢與收斂情形。

若曲線隨著 epoch 數逐漸收斂，表示模型的權重調整能有效映射輸入與輸出之間的關係；反之，若訓練曲線收斂但驗證曲線未收斂，則可能出現過擬合，說明模型的複雜度過高，受到訓練集中極端數據點的影響，導致預測效果下降。

為了進一步優化損失曲線，模型設置了 BatchNormalization 層以穩定數據分佈，加速收斂；並加入 Dropout 層，隨機屏蔽部分神經元以防止過擬合現象，提升模型的泛化能力，使模型在新數據上的預測

更加準確穩定。




圖 4-4 訓練曲線圖收斂示意圖

資料來源：本計畫繪製

第四節 網路測試以及優化

在 LSTM 模型訓練完成指定的迭代數（epoch）後，訓練過程便會結束。然而，若訓練與驗證的損失曲線未呈現收斂趨勢，則需要進行以下調整來優化模型性能：

- 一、調整模型訓練超參數，例如增加或減少迭代次數（epoch）、調整學習率（learning rate）、修改激活函數類型、改變 LSTM 層與 Dense 層中的神經元數量，或是增加或減少隱藏層的數量，以提升模型的收斂性。
- 二、調整 LSTM 層的序列輸入長度及其維度，嘗試不同的向量長度以改善模型對序列資料的表達能力，增強收斂效果。
- 三、調整時間序列的取樣頻率或間隔數，優化輸入時間序列的設置，使得資料能夠更精確地表達序列趨勢。

四、改善資料的量化方式，調整輸入時間序列的擷取範圍，確保資料量化過程中的特徵保留，以提升模型在非線性資料處理上的適應性。

五、若出現過擬合現象，可透過增加訓練資料量或增強Dropout層（如在LSTM層和Dense層之間加入適當的Dropout），以降低模型的複雜度或控制模型的方差，使其能更好地泛化。

當訓練過程中的損失曲線圖顯示收斂且未出現過擬合時，則表示模型在訓練階段表現良好。此時，可將剩餘的 20%測試資料集輸入至模型，以評估其在未知數據上的表現。預測結果會與真實標籤進行誤差分析，透過誤差結果來評估模型的最終效果。若測試階段誤差過大，可能是由以下原因導致：

- 一、雖然訓練曲線趨勢收斂，但仍未達到理想的收斂階段，建議增加訓練的epoch數以進一步優化模型表現。
- 二、訓練集和驗證集的分割過程存在不當，可能導致過擬合未在曲線圖上充分表現，進而影響測試效果。
- 三、資料分割未完全隨機，導致相似特徵的數據集中於同一數據集，影響模型在測試階段的泛化能力。

當測試結果表現良好後，即可根據模型所解算的時間序列因子結合環境因子，進行崩塌風險的預測，並通過可視化流程實現崩塌範圍的即時顯示（圖 4-5）。




圖 4-5 崩塌機率預測結果可視化

資料來源：本計畫繪製

第五節 人工智慧模型建置與訓練初步結果

在本計畫中，透過使用資料庫中的地震與降雨時間序列數據，並結合歷史崩塌事件及其範圍作為訓練目標，建構 LSTM 模型來預測時間序列因子。為了提升模型準確性，對資料進行了擴增處理，利用滑動窗口技術和數據回推的方式增加樣本數目，使模型獲得更具代表性的訓練資料。解算出的時間序列因子結合地質特性和即時地表情況等環境因子，進行崩塌機率的預測。

一、資料處理方法

- (一) 降雨時間序列：收集5周（840小時）的每小時累計降雨量，利用滑動窗口技術將數據切割成72小時的累計降雨量，以步長1小時滑動，形成769筆72小時的降雨數據。此方式提供了大量多樣化的訓練資料，適合於LSTM模型的時間序列分析。
- (二) 地震震度時間序列：將5年（260周）的每周最大PGA（Peak Ground Acceleration）數據，利用滑動窗口技術將數據切割成52周的最大PGA歷時，以步長1周滑動，生成209筆52周的PGA

數據序列。這樣的處理方式保留了地震數據的時間依賴性，適合於長期依賴關係的因子解算。

二、因子值計算方式

為了提高模型的準確度，對降雨和地震數據各自訂定了適合的因子值計算方法，並根據時間序列的精度和特徵設定了不同的因子值分配方式：

（一）降雨時間序列因子值計算

由於降雨數據的精度較高，因而採用更為複雜的因子值計算方式。首先，對正規化的累計降雨數據進行反標準化，得到原始降雨量數據。接著，計算降雨時間序列中相鄰時間點的變化量，並對每個樣本的變化量進行累計，以獲得該樣本的累計變化量。對於每個樣本，根據累計變化量與均值及標準差的關係，將因子值計算為以下三種情形。

$$fator_i = \begin{cases} \frac{total_changes_i}{mean_rainfall + 2 * std_rainfall} & \text{if } total_changes_i > mean_rainfall + 2 * std_rainfall \\ \frac{total_changes_i}{mean_rainfall + std_rainfall} & \text{if } mean_rainfall < total_changes_i \leq mean_rainfall + 2 * std_rainfall \\ \frac{total_changes_i}{mean_rainfall} & \text{if } total_changes_i \leq mean_rainfall \end{cases} \quad (10)$$

其中 $total_changes_i$ ，表示樣本 i 的累計降雨變化量， $mean_rainfall$ 和 $std_rainfall$ 分別是所有樣本累計變化量的均值和標準差。計算後的因子值被限制在 $[0.0, 1.0]$ 的範圍內，以確保合理性。最終，為了增加時間序列中靠近崩塌事件的影響，根據樣本時間位置加入時間權重，使得靠近崩塌事件的因子值更高。最終調整後的因子值為

$$adjusted_fator_i = fator_i * time_weight_i \quad (11)$$

（二）地震震度時間序列因子值計算

由於地震數據的精度較低，因而採用較簡化的因子值計算方式。首先，將正規化後的 PGA 數據進行反標準化，並計算每個樣本的最大 PGA 值、累計變化量和平均 PGA 值。然後，根據下列公式計算地震因子：

$$\begin{aligned} Factor = & 0.5 * \frac{Max\ PGA}{Max\ PGA\ Baseline} + 0.3 * \frac{Mean\ PGA}{Mean\ PGA\ Baseline} \\ & + 0.2 * \frac{Total\ Change}{Total\ Change\ Baseline} \end{aligned} \quad (12)$$

目前訓練的 9740 筆網格資料皆來自高雄六龜區，其中包含 3265 格崩塌網格及 6475 格未崩塌資料，經滑動窗口後的雨量資料，每個地區都各有 769 筆 72 小時的降雨時間序列資料，所以 4 個地區總共會有 3076 筆資料。地震資料而是每個地區 209 筆 52 周的地震震度時間序列資料，所以總共會有 836 筆資料。

在本計畫中，每筆資料包含對應崩塌區域之網格數，且降雨和地震震度資料皆經過滑動窗口處理後整合成一個 Excel 檔案，作為模型訓練的輸入。具體而言，每筆降雨時間序列資料，包含經滑動窗口後的 769 筆的 72 小時累計時降雨量，而每筆地震震度時間序列資料，包含經滑動窗口後的 209 筆的 52 週最大 PGA 歷時數據。將降雨與地震 LSTM 預測後的因子值，分配於各崩塌區，總計有 9740 組網格資料，其中 7792 筆為訓練資料，1948 筆為測試資料。

訓練方法上，將滑動窗口處理後的降雨與地震數據整合為單一 Excel 文件，並直接用於 LSTM 模型的訓練。經過訓練後的模型，將使用崩塌發生前的 72 小時降雨資料或 52 週地震震度資料作為預測輸入。模型預測出的因子值將依據不同區間的設定，分配至對應網格內，以反映每個區域的崩塌風險。

透過訓練得出第一次降雨訓練圖(如圖 4-6) 與地震訓練圖(如圖 4-7)，藍色及橘色線分別代表訓練集和驗證集，在理想情況下我們會希望兩條線能收斂至同一 Loss 值(也就是 Mean Square error)，降雨訓練圖中，損失在訓練初期迅速下降，顯示模型學習效果良好，但在約第 50 個 epoch 出現顯著的驗證損失上升，隨後再次下降並趨於穩定。地震訓練圖顯示損失整體呈下降趨勢，但驗證損失波動明顯，顯示模型在某些 epochs 有不穩定的驗證表現，但隨著訓練進行，驗證損失逐漸接近訓練損失，反映出模型學習效果的逐步改善。




圖 4-6 第一次降雨訓練圖

資料來源：本計畫繪製




圖 4-7 第一次地震訓練圖

資料來源：本計畫繪製

重新訓練得出第二次降雨訓練圖(如圖 4-8)與地震訓練圖(如圖 4-9)，降雨訓練圖中，訓練損失快速下降並在較低值保持穩定，但驗證損失在整個過程中波動較大，並且在較高水平徘徊，顯示出模型可能存在過擬合現象，導致驗證數據上的泛化性能不佳。地震訓練圖顯示，訓練損失隨著 epochs 的增加逐步下降，說明模型在學習過程中有持續優化。然而，驗證損失波動顯著，特別是在中期出現多次急劇上升，這表明模型在某些 epoch 對驗證數據表現不穩定，可能受到數據異質性或過擬合的影響。綜合來看，這些圖指出模型在訓練過程中有學習能力，但需要進一步調整以減少驗證損失的波動，以提升模型的泛化能力和穩定性。




圖 4-8 第二次降雨訓練圖

資料來源：本計畫繪製




圖 4-9 第二次地震訓練圖

資料來源：本計畫繪製

重新訓練得出第三次降雨訓練圖(如圖 4-10)與地震訓練圖(如圖 4-11)，降雨訓練圖中，訓練和驗證損失在前期迅速下降，模型在學習初期有顯著的優化效果。隨著訓練進行，損失逐漸收斂並在低值處穩定，但驗證損失仍然有一定波動，顯示模型在驗證數據上有時表現不穩定。地震訓練圖中，訓練和驗證損失同樣在早期快速下降，說明模型在早期學習階段取得良好效果。後期，驗證損失在低值範圍內波動，整體趨勢與訓練損失較接近，表明模型泛化能力較佳。綜合來看，這兩張圖顯示模型在訓練過程中能夠有效學習，且整體泛化能力尚可，但驗證損失的波動顯示仍有調整空間以進一步提高穩定性。




圖 4-10 第三次降雨訓練圖

資料來源：本計畫繪製




圖 4-11 第三次地震訓練圖

資料來源：本計畫繪製

觀察前三次訓練的結果，都沒有發現較好的結果，因此在第四次的訓練時，對針對降雨時序資料以及模型進行一些微調，新增 BatchNormalization 和 Dropout 的正則化技術，以及 EarlyStopping 和 ReduceLROnPlateau 來防止過擬合並穩定學習率。訓練得出第四次降雨訓練圖(如圖 4-12)與地震訓練圖(如圖 4-13)，降雨訓練圖中訓練損失(藍色曲線)和驗證損失(橙色虛線)在初期迅速下降，表明模型在初始階段學習速度較快。隨著訓練的進行，損失曲線逐漸趨於平穩，並且在 20 個 epochs 後，兩條曲線非常接近，顯示出模型的訓練和驗證性能良好，泛化能力較強。地震訓練圖中，訓練損失隨著 epochs 增加持續下降，但有些波動。驗證損失也在早期急劇下降，並在整個過程中保持在較低的水準，顯示出模型在驗證集上的表現穩定。然而，這張圖中驗證損失的波動相對較小，顯示出模型在訓練後期維持了穩定的泛化效果。




圖 4-12 第四次降雨訓練圖

資料來源：本計畫繪製




圖 4-13 第四次地震訓練圖

資料來源：本計畫繪製

第五次訓練調整模型學習率以及 batchsize，訓練得出第五次降雨訓練圖(如圖 4-14)與地震訓練圖(如圖 4-15)，訓練損失（藍色曲線）和驗證損失（橙色虛線），降雨訓練圖中，訓練損失（藍色曲線）在初期迅速下降，並趨於穩定，表明模型在訓練集上學習效果良好，驗證損失（橙色虛線）在初期有較大波動，隨著訓練進行，波動逐漸減少，但在整個過程中仍然保持波動，顯示出模型在驗證集上的穩定性略有不足。這可能是由於數據異質性或驗證集樣本較少造成的。地震訓練圖中，訓練損失曲線同樣顯示出快速下降並趨於平穩，說明模型在訓練過程中逐漸學習到最佳參數。驗證損失在初期有明顯波動，後續逐漸趨於穩定，但波動依然存在。這表明模型在某些訓練階段無法穩定地泛化到驗證集上，可能需要進一步調整參數或進行更好的資料預處理。兩張圖均表明模型在訓練初期有良好的學習表現，但在驗證集上的損失存在波動。這顯示模型雖然能夠有效地學習訓練資料，但在驗證集上泛化性能不夠穩定，可能需要對模型結構、正則化技術或數據進行優化，以減少波動並提升驗證表現的穩定性。

因這兩次結果所得出之評估指標，是目前效能最好之訓練，分別

為降雨訓練(RMSE: 0.1300, R^2 : 0.8388), 地震訓練(RMSE: 0.0513, R^2 : 0.8922)。因此使用第五次訓練的模型當成最終預測因子值的模型，觀察降雨 LSTM 訓練集(圖 4-16)以及地震 LSTM 訓練集(圖 4-17)這兩張圖展示了模型在預測因子值上的良好表現，尤其是在中低範圍內的預測準確度相當高。整體上，模型在大多數情況下能夠接近理想的預測表現，顯示出其在預測任務中的穩定性與可信度。即便在高值範圍內存在少量偏差，模型依然展現出相當的泛化能力，為未來的應用提供了良好的基礎。




圖 4-14 第五次降雨之訓練圖

資料來源：本計畫繪製




圖 4-15 第五次地震震度訓練圖

資料來源：本計畫繪製




圖 4-16 降雨 LSTM 訓練集

資料來源：本計畫繪製




圖 4-17 地震 LSTM 測試集

資料來源：本計畫繪製

第六節 ANN 模型建置與訓練結果

在處理 LSTM 訓練資料時，將 840 小時的每小時累計降雨歷時資料，使用滑動窗口切割成 769 筆 72 小時的累計降雨歷時序列。移除最後一筆（第 769 筆）後，作為 LSTM 模型訓練完成後的預測輸入，預測降雨因子。隨後，將此預測結果應用於 ANN 模型中，以預

測 9740 個網格的降雨因子值(如表 4-1)。

地震訓練資料為 260 周的每周最大 PGA 歷時，使用滑動窗口切割成 209 筆 52 周的每周最大 PGA 歷時，並將這些數據用於 ANN 模型的訓練，最終用於預測 9740 個網格的地震因子值(如表 4-1)。

表 4-1 降雨與地震震度預測因子值

	降雨預測因子值	地震震度預測因子值
1	0.753069699	0.620396256
2	0.753069699	0.620396256
3	0.75306952	0.620396256
4	0.75306952	0.620396256
5	0.753069341	0.620396256
6	0.753069341	0.620396256
7	0.753069222	0.620396256
8	0.753069162	0.620396256
9	0.753069162	0.620396256
10	0.753069043	0.620396256

資料來源：本計畫整理

ANN 的環境因子如第三章所述，坡向是使用 QGIS 軟體內建的分析工具，利用周邊 8 個網格推斷出中間網格的坡向數據，最終得到每個網格對應的坡向值。坡度同樣使用 QGIS 軟體內建工具進行分析，根據範圍內的坡度分級和面積占比的乘積計算網格範圍內的平均坡度，最終得出每個網格對應的坡度值。高程數據則是通過 GRD 檔案轉換後，獲得每個網格的高程值。為了訓練模型，使用崩塌數據標記網格是否發生崩塌，崩塌網格標記為 1，未崩塌網格標記為 0。這些環境因子結合降雨和地震震度的因子值，構成了 ANN 模型的完整訓練資料。

此過程確保了模型所使用的輸入數據來源的完整性和專業性，提供了足夠的空間來捕捉各種環境條件對預測結果的影響，有助於提高模型在預測崩塌風險時的準確度和可靠性(如表 4-2)。

表 4-2 ANN 訓練資料

	降雨因子值	地震震度因子值	坡度	坡向	高程	崩塌
1	0.753069699	0.620396256	40.88310242	338.9377747	2072.03	0
2	0.753069699	0.620396256	19.81529617	355.1035156	2056.92	0
3	0.75306952	0.620396256	34.76631927	143.5009918	2054.91	0
4	0.75306952	0.620396256	49.58966827	143.1634522	2057.12	0
5	0.753069341	0.620396256	48.24071884	133.4126282	2054.53	0
6	0.753069341	0.620396256	48.58384323	130.0665741	2065.42	0
7	0.753069222	0.620396256	48.45828247	126.325119	2078.19	0
8	0.753069162	0.620396256	49.19252777	124.592926	2099.91	0
9	0.753069162	0.620396256	53.09357071	130.9311066	2116.83	0
10	0.753069043	0.620396256	56.63201141	135.153244	2137.57	0

資料來源：本計畫整理

ANN 模型的訓練過程將 9740 筆數據分為 7792 筆訓練資料和 1948 筆驗證資料。訓練過程中，epochs 設定為 1000，並應用了 EarlyStopping 和 ReduceLROnPlateau 回調函數，以確保模型在驗證損失不再改善時自動停止訓練，並調整學習率以優化訓練效果。訓練完成後，模型被匯出並保存。隨後，使用相同的 ANN 訓練資料作為輸入，預測出崩塌機率，最終得出 9740 格網格的預測崩塌機率結果(如表 4-3)。

表 4-3 網格預測崩塌機率

	預測崩塌機率
1	0.168041289
2	0.009230353
3	0.432273269
4	0.282905191
5	0.342261642
6	0.338175625
7	0.312283695
8	0.310419023
9	0.26262489
10	0.168041289

資料來源：本計畫整理

不同閾值下的混淆矩陣(如圖 4-18)展示了模型在各種情況下的穩定表現和靈活調整能力，能在真陽性(True Positive)、真陰性(True

Negative)、偽陽性(False Positive)和偽陰性(False Negative)之間取得良好平衡。這些結果表明模型具有良好的預測性能，能根據需求進行最佳化調整，以實現最佳預測效果。程式會使用基於 ROC 曲線的損失最小化閾值選擇方法，自動尋找最佳閾值，使得 $(1 - \text{TPR}) + \text{FPR}$ 最小，以達到最佳分類表現。TPR (True Positive Rate，真陽性率) 表示模型正確識別正類別的比例，計算方式為 $\text{TP} / (\text{TP} + \text{FN})$ 。FPR (False Positive Rate，偽陽性率) 表示模型將負類別錯誤分類為正類別的比例，計算方式為 $\text{FP} / (\text{FP} + \text{TN})$ 。ROC 曲線(圖 4-19)的 AUC 值為 0.88，證明模型在區分正負類別上具有高準確性。




圖 4-18 混淆矩陣圖

資料來源：本計畫繪製




圖 4-19 ROC 曲線圖

資料來源：本計畫繪製

利用本計畫建置的模型，輸入任一網格在特定時間點之前的地震和降雨歷時數據，並結合該網格的地形和地貌特性，即可預測該網格的崩塌機率；透過對所有網格進行相同操作，可獲得整個區域的崩塌潛勢預測結果，如圖 4-20 所示，預測結果與實際崩塌事件具有相似的分佈趨勢。崩塌機率的分佈圖中，顏色從綠到紅依次表示崩塌機率從低到高，中間過渡顏色為黃色。在崩塌前期(圖 4-21)，幾乎所有網格皆為綠色，顯示整體處於穩定狀態；隨著時間推移，崩塌中期(圖 4-22)部分網格逐漸出現紅色，顯示局部地區因降雨強度增加或地震影響累積而逐漸失穩，有潛在危險；到了後期(圖 4-23)，紅色範圍標示的區域崩塌風險極高，處於臨界狀態，可能隨時發生崩塌。這樣的顏色漸變能有效描述崩塌風險的演變過程，幫助預測未來趨勢並輔助防災決策。




圖 4-20 崩塌預測圖

資料來源：本計畫繪製




圖 4-21 崩塌前期熱點圖

資料來源：本計畫繪製




圖 4-22 崩塌中期熱點圖

資料來源：本計畫繪製




圖 4-23 崩塌後期熱點圖

資料來源：本計畫繪製

第七節 小結

本計畫之模型建置與訓練過程，涵蓋了 LSTM 和 ANN 模型的結構、數據處理方式、訓練策略及結果評估。LSTM 模型主要用於處理降雨和地震的時間序列數據，通過捕捉其長期依賴性來進行因子解算，ANN 模型則結合環境因子如坡度、坡向及高程，進一步預測每個網格的崩塌機率。這種多層次結構設計，使模型能夠更準確地反映複雜的自然現象。

在訓練過程中，資料經過詳細的預處理與切割，使用滑動窗口技術生成多筆樣本，以提高訓練數據的多樣性。LSTM 模型通過 BatchNormalization 和 Dropout 層穩定數據分佈並防止過擬合，結合 EarlyStopping 和 ReduceLROnPlateau 等回調函數進一步優化學習過程，確保模型在最佳權重下停止訓練。經過多次訓練和調整後，模型最終在測試中顯示出良好的預測性能，不僅在 RMSE 和 R^2 指標上達到高準確度，ROC 曲線的 AUC 值也高達 0.88，證明了模型在區分正負類別方面的優異能力。

結果顯示模型具備出色的預測準確性和穩定的學習能力，尤其在降雨和地震引發的崩塌風險預測中具有顯著應用潛力。這表明所建置的模型不僅適用於目前的研究範圍，未來還可擴展應用至其他地區或不同自然災害場景中，增強其實用性與可靠性。為了進一步鞏固模型的穩定性和應用廣度，未來可考慮擴展訓練數據集以涵蓋更豐富的樣本特徵，並透過優化模型結構和參數來持續提升泛化能力和預測表現的穩定性，從而在實際應用中提供更準確和可靠的崩塌風險預測。



第五章 高 133 線凱米颱風監測與分析

第一節 背景介紹期程規劃

高 133 線道因土石流崩坍整修施工，如圖 5-1 所示，顯示了施工期間的狀況，反映了該地區地質的脆弱性以及進行整修的必要性。高 133 線位於高雄市六龜區，是一條極具地質敏感性的道路，經常受到極端氣候的影響，尤其在颱風和強降雨事件中更是經常發生崩塌。因凱米颱風的豐沛降雨量，造成土石流崩，災後崩坍整修施工照如圖 5-1 所示，顯示了施工期間的狀況，反映該地區地質的脆弱性以及進行維護監測的必要性。高雄市六龜區地形特性複雜，周邊環繞著荖濃溪，屬於高屏溪流域的支流，匯聚了大量的水流，形成了一個地質敏感區域。該地區的崩塌風險不僅受到河川沖刷影響，更受到山坡地的坡度、植被覆蓋狀況等多方面因素影響。



圖 5-1 高 133 線道因土石流崩坍整修施工照

資料來源：本計畫繪製

高 133 線作為六龜區內的重要交通幹道，連接著不老溫泉和寶來溫泉，並承載著大量的交通流量，其安全狀況直接影響居民及遊客的生命財產安全。因此，持續進行道路沿線及周邊邊坡的監測，以及實施有效的防災措施，對於確保高 133 線道路的安全至關重要。本次研

究針對高 133 線道，特別是在凱米颱風期間，分析其降雨和崩塌風險的特性，並建立相應的監測系統，以便為未來的災害應變提供科學依據。

第二節 監測系統規劃與選定雨量站

區域調查範圍內水系分布，如圖 5-2 所示，包含雨量站選定和周邊水系的分布情況。為深入了解高 133 線的崩塌風險，本研究針對高 133 線道的橋梁與邊坡進行監測系統的規劃，並選取了鄰近的四個雨量站進行資料收集，以掌握降雨對邊坡穩定性的影響。

- 一、高中站 (O1V54)：位於北側，平均年雨量為2891毫米，距離約3.13公里。此站提供該區域北方的降雨資料，有助於分析北側來水對道路邊坡的潛在影響。
- 二、新發站 (C1V590)：位於西南側，平均年雨量為3275毫米，距離約6.03公里。此站的資料可以反映西南側地形的降雨情形，該區域地形相對平緩，但降雨量高，容易導致地下水位上升。
- 三、寶山站 (O1V51)：位於南側，平均年雨量為3635毫米，距離約5.04公里。該站為研究區域的降雨資料中年雨量最高的雨量站，顯示南側邊坡在降雨時具有較高的崩塌潛勢。
- 四、藤枝站 (C1V600)：位於東側，平均年雨量為3298毫米，距離約6.37公里。東側的降雨資料對於理解荖濃溪的匯水情況至關重要，尤其是在颱風期間可能會導致溪流暴漲，進一步影響邊坡穩定性。

這些雨量站的位置涵蓋了研究區域周邊的不同方向和不同高程，提供了全面的降雨數據支持，有助於對高 133 線道沿線邊坡的穩定性

進行全面的風險評估。




圖 5-2 區域調查範圍內水系圖

資料來源：高雄市六龜區高 133 線道路(3K+800~4K+250)重建工程地質敏感區基地地質及安全評估結果報告

第三節 氣象資訊推估與分析

研究區域周遭現有雨量站的空間分布，如圖 2-3 所示，顯示雨量站的位置和分布，便於推估過程的理解。降雨量是影響邊坡崩塌的主要誘發因子之一，尤其在短時強降雨事件發生時，容易改變邊坡的臨界條件，例如土壤飽和度、孔隙水壓力、土壤摩擦力等，從而引致邊坡崩塌。本研究通過克利金(Kriging)方法推估高 133 線道路區域的歷史降雨特性，這種方法依據協方差函數進行空間建模和預測，能夠產生最優線性無偏估計，進一步提高推估精度。




圖 5-3 研究區域周遭現有雨量站空間分布

資料來源：本計畫繪製

透過鄰近雨量站的觀測資料，結合克利金法進行推估，建立了包括 1 小時、3 小時、6 小時、12 小時及 24 小時的降雨特性資料。這些降雨數據提供了豐富的參考，幫助判斷高 133 線沿線邊坡在不同強度降雨條件下的穩定性。此外，根據水利署的淹水警戒模式，本研究也建立了高 133 線道的降雨警戒值，當觀測到的降雨量達到警戒值時，將啟動一級或二級預警，並進一步調整應變措施。

第四節 凱米颱風期間的雨量觀測與分析

高 133 地區雨量站選取位置，如圖 5-4 所示，顯示了本研究所選取的雨量站分布，為後續分析提供了基礎。凱米颱風期間的雨量分布，如圖 5-5 所示，直觀顯示颱風期間的雨量分布情況，支持分析內容。

凱米颱風期間，高 133 線地區受到了顯著的降雨影響。根據鄰近雨量站的觀測資料，分析顯示，颱風侵襲期間，該地區的降雨量在短時間內急劇增加，達到了高峰。尤其是在寶山站和新發站，記錄到的日降雨量均超過 400 毫米。研究結果表明，在凱米颱風期間，高 133 線道路沿線邊坡的穩定性受到嚴重挑戰，根據降雨數據推估，建議將日降雨警戒值設定為 460 毫米，並在達到警戒值前提前 12 小時發出預警，以提升區域的安全管理能力。




圖 5-4 高 133 地區雨量站選取位置

資料來源：本計畫繪製




圖 5-5 高 133 地區凱米颱風雨量分佈

資料來源：本計畫繪製

根據四個雨量站的歷史最大降雨數據，建立了高 133 線的崩塌風險預警模型。該模型能夠有效結合降雨資料和邊坡地質特性，提前評估邊坡崩塌的可能性。在凱米颱風期間的雨量數據中發現，當日降雨量超過 460 毫米時，邊坡的崩塌風險顯著增加，因此需在此基礎上制定更為嚴格的應變措施。

第五節 凱米颱風期間的雨量觀測與分析

以高 133 線為基礎，本研究欲設計一套完整的聚落監測平台，旨在達到即時監控和預警的效果，並未來可延伸至其他地區。監測系統包括多個感測器，分別安裝於道路沿線的不同位置，用於監測邊坡移動、降雨量變化、土壤飽和度等參數，這些感測器數據將通過物聯網技術進行即時傳輸並集中至監控中心，整合即時監測數據與本研究開發的分析演算法進行自動處理和預警信號的發送。該物聯網系統不僅能夠快速傳遞災害資訊，還能與地方政府及應變單位進行聯動，確保在災害發生前能有效採取緊急措施，減少對聚落和交通的衝擊。本研究未來計劃將此系統擴展至其他類似高風險地區，進一步完善監測技術和應變流程，提升整體防災能力。

第六章 結論與未來展望

第一節 結論

本研究設計了一個數據收集和分析模型，使用長短期記憶網路(LSTM) 及前饋式類神經網路進行培訓與測試，以預測坡地不穩定之崩塌風險。通過最新的地理和時間序列資料並進行訓練，建立了一個具有一定效能的模型來評估崩塌風險。

研究結果顯示，隨著數據量的增加，模型在測試中展現出穩定的準確度，對於預測崩塌風險具備一定的效用。調整時間序列、優化訓練次數及應對緊急變化的調整策略均有助於模型的表現提升。模型的穩定性和預測準確度在不斷測試和優化過程中得到改善，顯示其在多變環境中的應用潛力。這些結果證明，將時間序列因子與地理環境因子結合的策略，是進行崩塌風險評估的可行方法。

此外，模型在捕捉長期和短期依賴性方面有其優勢，能夠有效處理不同時間尺度的資料。這樣的特點有助於在多變的氣候條件下提供更具有實用性的風險預測。模型在實際應用中可作為一種輔助工具，為相關部門提供數據支持，幫助制定更加精確的應對策略和防災措施。這將有助於提高整體防災能力，減少潛在災害對生命財產的威脅。

本研究的結果雖然展現出初步的成功，但在實施中仍面臨一些挑戰，如數據的可得性和模型的泛化能力。未來若能克服這些限制，模型的應用價值將進一步提升，並有望在更廣泛的地理和環境條件下推廣使用。

第二節 未來展望

未來研究可著重於擴大地理資料的範圍，增加資料量以適應更複雜的場域，提升模型在高崁岩地區的應用。此過程中，結合虛擬地理技術以改善資料的呈現和應用效果，將是值得探索的方向。

在聚落防災方面，未來可進一步強化模型在即時預警系統中的應用，結合物聯網技術實現災害監控和實時數據回饋，以協助聚落居民及時了解周邊環境狀況並採取必要的防護措施。這種結合將提高防災措施的及時性和精準度，促進社區防災意識的培養與自主管理。

為進一步提升模型的準確度，未來應考慮引入更多多元數據源，如高解析度的遙測影像和氣象預測數據，以豐富輸入特徵。此外，探索更複雜的深度學習架構，如混合模型或注意力機制，以加強模型在複雜場景中的表現。加強模型在不同場域的測試和驗證，也將有助於提升其泛化能力和穩定性。

此外，可逐步加入不同時間序列的分析，提升模型對多變資料的適應性，並進一步展現崩塌風險評估的可視化效果。這將有助於改善模型的實用性，促進災害預警和應變效率的提升。

未來亦可探討模型在不同水文條件和共益場域中的應用，確保其在多樣環境中的穩定性，並持續更新以應對潛在的變化和挑戰。

參考文獻

1. Gers, Felix. Long short-term memory in recurrent neural networks. Diss. Verlag nicht ermittelbar, 2001.
2. Graves, Alex. "Generating sequences with recurrent neural networks." arXiv preprint arXiv:1308.0850 , 2013.
3. Hebb D. O. "The organization of behavior: A neuropsychological theory", John Wiley & Sons, New York, 1949.
4. Kawakami, Kazuya. "Supervised sequence labelling with recurrent neural networks." Ph. D. thesis, 2008.
5. Rosenblatt F. "The perceptron: A probabilistic model for information storage and organization in the brain", Psychological Review, Vol. 65, No. 6, pp. 386-408, 1958.
6. 笥程成、秦宇君、田甜、伍大勇、劉悅、程學旗(2017)。「一種基於 RNN 的社交消息爆發預測模型」。軟體學報，28，頁 3030-3042。
7. 張斐章、黃浩倫、張麗秋(2001)。「回饋式類神經網路於河川流量推估之應用」。農業工程學報，47，頁 32-39。
8. 鄭允中(民 106)。「基於長短期記憶遞迴類神經網路之新台幣兌美元匯率預測模型」。國立台灣大學，碩士論文。
9. Hochreiter S., & Schmidhuber J. "Long short-term memory", Neural Computation, Vol. 9, No. 8, pp.1735-1780, 1997.
10. 莫拉克颱風。檢自 [https://zh.wikipedia.org/zh-tw/%E9%A2%B1%E9%A2%A8%E8%8E%AB%E6%8B%89%E5%85%8B_\(2009%E5%B9%B4\)](https://zh.wikipedia.org/zh-tw/%E9%A2%B1%E9%A2%A8%E8%8E%AB%E6%8B%89%E5%85%8B_(2009%E5%B9%B4))
11. 交通部中央氣象署。檢自 <https://www.cwa.gov.tw/V8/C/>.
12. 交通部中央氣象署。檢自 <https://www.cwa.gov.tw/V8/C/>.
13. CODis 氣候觀測資料查詢。檢自

<https://codis.cwa.gov.tw/StationData>.

14. 政府資料開放平台。檢自 <https://data.gov.tw/>.
15. 活動斷層 GIS 查詢系統。檢自 <https://faultgis.gsmma.gov.tw/gis/>
16. 地質雲加值應用平台。檢自
<https://www.geologycloud.tw/map/Stratum/zh-tw>
17. 莊竣凱，「應用長短期記憶神經網路於地震特性預測模組與智慧型隔減震控制系統之研發與實驗驗證」，國立陽明交通大學，碩士論文，民國一百一十年。
18. 張皓惇，「類神經網路及條件式生成對抗網路模型應用於橋柱損傷推定與橋柱影像生成之研究」，國立陽明交通大學，碩士論文，民國一百一十一年。
19. 國有林大規模崩塌潛勢區減災策略研擬及安全監測成果報告，高133(大地篇幅)。



附錄

附錄一、研提計畫書審查意見暨回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
業務單位(組、中心、小組)審查意見		
壹、為配合本署業務需求，計畫內容建議調整(或納入後續執行評估參考)部分		
一	本計畫以最佳化後模型投入聚落防災數位孿生物聯網監測系統中，配合當地自動監測站，結合及時降雨歷時地震歷時，預測未來坡地崩塌之機率，作為災害預警之參考。	感謝委員意見。
二	可再增加期刊發表。	感謝委員意見，已於全程目標中新增目標(4)於計畫完成後將本年度研究成果撰寫，預計於 114 年發表刊登一篇期刊文章。
三	聚落防災物聯網監測的確是一個坡地災害監測的重要方法，計畫書中所選擇之高雄六龜區-D009竹林大規模崩塌曾因莫拉克颱風超大豪雨，導致區域內美瓏山西側坡地發生多處崩塌，造成道路中斷、民宅掩埋和民眾罹難，是一個合適的研究地點。主持人在人工智慧跨領域技術於土木工程之應用上有很傑出的表現，就土木工程結構領域的監測檢測方面，研究團隊的能力亦是一時之選。	感謝委員意見。

項次	審查意見	回覆辦理情形
四	目前國內針對大規模崩塌區之研究以及既有監測與聚落防災物聯網監測的創新研究，最缺乏的是實際到現地經實際調查、詳細了解邊坡變形機制後，將對的儀器設置在合適的地方，以計畫書目前的流程、作法與經費編列，是以建立平台為研究主軸，沒有真正的進行聚落防災物聯網監測，不會有真正的資料輸入與展示，農村發展及水土保持署所關注的邊坡，可能很難具體表現數位孿生工具與方法的防災成效。如果能夠尋求與主持人陽明交通大學同系的翁孟嘉教授合作，因其研究之花蓮瑞穗舞鶴大規模崩塌已有較好的變形監測成果與地質模式，或許可以作為本研究配置物聯網監測的好的案例場所。	感謝委員意見，本計畫團隊選定研究範圍高雄市六龜區的寶來里，目前已有裝設相關監測儀器，並由高雄市政府支持本研究團隊取得監測數據進行後續研究分析，本研究團隊亦同意至現場實際調查、詳細了解邊坡變形機制，另會再與翁教授了解與取得相關可用數據並納入後續分析。
五	如前所述農村發展及水土保持署所關注的邊坡，以自然邊坡為主，其不若人工構造物的結構、組成、材料都是已知，監測位置、合適儀器比較容易決定，因此要推廣聚落防災物聯網監測比較合適的是人工邊坡，例如土石大壩的邊坡、高速公路、鐵路的回填土邊坡，建議研究團隊可以思考尋求相關業主主管機關的支持，作為發展先進防災物聯網監測與平台建立的實驗場域。	感謝委員意見，本團隊與高雄市政府有密切合作關係，本計畫選定之研究範圍目前已取得自然邊坡的資料，作為後續研究分析應用。

項次	審查意見	回覆辦理情形
六	建議可將研究計畫單獨撰寫，精簡計畫說明書內容，研究計畫圖文同時呈現，以利閱讀研究。	感謝委員意見，目前因系統欄位填入並自動生成計畫書，因此圖與文字無法同時輸入於系統當中。
七	計畫中可看到運用各單位資訊平台所提供之資料，似乎沒有本署建置BigGIS系統所提供之資料，若系統提供之資料有符合研究需求，建議可多利用BigGIS系統。	感謝委員意見，申請計畫書中表達不夠精準，已修正說明本團隊會應用 BigGIS 系統。
八	本計畫採用聚落防災數位孿生物聯網監測系統，配合人工智慧協助預測崩塌發生的潛在機率分析功能，建立可即時評估聚落邊坡災害平台。	感謝委員意見。
九	若可針對崩塌/滑動風險較高的邊坡，在特定位置設置光達，以固定時間頻率掃描，應可如計畫所提方式建立時間序列資料，判斷邊坡的狀況。此方式較目前採用的定點（如傾斜管、伸張計等）或衛星影像，效率更高或精度更高。	感謝委員意見，本團隊選定研究範圍之高雄市六龜區寶來里周邊已有裝設光達設備進行監測，本研究將會應用該設備監測數據，建置即時監測系統，建立時間序列資料判斷邊坡狀況。
十	無論是否未來能設定警戒、警報的門檻，都可以先建立此種觀測技術。日後再針對現場的坡地特性探討如何設定警戒、警報的機制與數值門檻。	感謝委員意見，遵照辦理。
十一	唯在本計畫期間，除建立基本的監測機制外，若要針對降雨延時、降雨強度等資料探討，則會遇到降雨資料代表性的問題。必要時，在集水區中必須自設雨量觀測設備。	感謝委員意見，本研究選定研究範圍之區域，高雄市政府已有裝設與雨觀測設備，將會蒐集監測數據進行後續研究。

項次	審查意見	回覆辦理情形
十二	計畫內容文字相關單位如交通部中央氣象署、農村發展及水土保持署等請修正為最新單位之名稱，土石流防災資訊網請修正為土石流及大規模崩塌防災資訊網。	感謝委員意見，遵照辦理已修正。
貳、有關計畫書格式及經費審查部分：		
一	本計畫請以補助經費730仟元調整編列。	感謝委員意見，遵照辦理。
二	本年度執行期限請修正為自113年2月7日至113年12月31日。(10.9個月)。薪俸、保險、退休離職儲金、主持人費、兼任研究助理，請以計畫執行期限10.9個月內編列。年終獎金亦配合計畫期程。	感謝委員意見，遵照辦理。
參、請計畫團隊於113年2月26日下班前依照審查意見修正計畫，並於本署補助計畫管理作業系統內回傳修正內容。		
主計室審查意見		
一	P、1執行期限：本年度計畫自113年01月01日請修正113年02月至07日。	感謝指導，已修正執行期限。
二	預算明細表補充說明：物品：「1.文具用品……移列雜支項下，2.電腦周邊……4.物聯網平台……請量化」。	感謝指導，已補充預算明細表中，物品量化說明，且將文具用品移列雜支項下。
三	雜支請量化，運費請編於28-40運費項下。	感謝指導，已補充雜支量化說明，並將運費移列至28-40運費項下。

附錄二、期中審查會議紀錄暨回覆辦理情形

項次	審查意見	回覆辦理情形
一	本期中報告初步完成研究區高雄區六龜區之基本資料庫建立、LSTM網路模型建立及訓練、六龜區D015潛在大規模崩塌之崩塌地形特徵圈繪(註:為林務局依據光達微地形特徵所判釋出之大規模崩塌潛勢區之一),與原計畫書所選擇之高雄六龜區,D009竹林大規模崩塌(農村水保署管轄)曾因莫拉克颱風超大豪雨,導致區域內美隴山西側坡地發生多處崩,造成道路中斷、民宅掩埋和民眾罹難,是一個合適的研究地點,有所不同。因涉及未來監測平台資料取得與及時反映評析,建議同意研究團隊以寶來里為研究區。	在蒐集政府開放資料平台上的歷史崩塌事件後,發現原研究區域 D009 竹林大規模崩塌區的崩塌事件記錄不足。起初計畫選擇此區作為大規模崩塌潛勢區之一,嘗試進行崩塌預測,但由於歷史資料不夠充分,因此更改了研究區域範圍,並以新的研究區域為基礎,繼續發展本計畫的實施內容。新的研究區域選擇具有更多可用的歷史數據,這將有助於提高模型的預測精度,並提供更可靠的崩塌風險評估。 在新的研究區域內,將結合降雨、地震等環境因子,建立一個能夠即時監測和評估的綜合系統。隨著數據的進一步增強和監測系統的優化,期望此研究成果未來可作為其他相似地區的災害預測參考,逐步推廣以達成更廣泛的防災效益。

項次	審查意見	回覆辦理情形
二	目前關於寶來里研究區D015潛在大規模崩塌之崩塌地之現地調查資料、監測儀器項目、內容等真實物聯網監測平台之資訊揭露不多，D015潛在大規模崩塌之崩塌地目前活躍分區分塊情形，比較難以具體想像數位孿生平台的施行狀況與願景。	以研究區域為基礎，將該區域的降雨和地震特徵與環境因子（如坡度、坡向、高程等）作為預測依據，進而計算當地的崩塌機率。由於各研究區位於六龜區境內，降雨及地震特徵變異不大，期望能以此研究為基礎，發展覆蓋整個六龜區山區的監測系統。針對特定高風險區域，將配置雨量計和地震儀等精密監測儀器，以便在關鍵環境因子變化時提供即時數據，精確評估災害風險，並實現預警。 未來，此系統可進一步擴展應用於其他相似地區，以支持防災決策，並結合數位孿生技術构建虛擬模擬平台，為地質災害的預測和風險管理提供科學依據，最終達成提升區域災害應變能力的目標。
三	摘要中述明本計畫選用台中市后里區、屏東縣車城鄉、高雄六龜區作為研究範圍，惟後續報告書研究範圍僅有高雄六龜區，仍請團隊在檢視並修正。	感謝委員意見，已修正。
四	機關名稱報告書內仍有舊機關名稱，建議團隊在逐一檢視並修正，例P1-5。	感謝委員意見，已修正。
五	P5-3缺表頭:計畫時程表(甘特圖)中僅有預定進度，缺實際進度及權重資料與計畫期程有誤7/1~12/31，應修為2/7~12/31，仍請團隊在檢視並修正。	感謝委員意見，已修正。

項次	審查意見	回覆辦理情形
六	報告書全文內頁請參照本署報告書範本修正本署機關名稱(如內首頁、P1-5...等)。	感謝委員意見，已修正。
七	P.I中文摘要「....本計畫選用台中市后里區、屏東縣車城鄉、本計畫選用高雄六龜區作為研究範圍...」本計畫選用字句重複，請修正。	感謝委員意見，已修正。
八	P.1-1，圖1-1，資料來源為部落格文章，建議補充作者姓名及該文章撰寫時間點。	感謝委員意見，已補充圖 1-1 資料來源為：Billy Pan 部落格文章，撰寫時間：2011 年 8 月 27 日，網址： https://billypan.pixnet.net/blog/post/37230455 。後續將針對所有引用的資料進行檢查，確保符合引用規範。
九	中央氣象局已改制為中央氣象署，機關名稱請修正(如P1-5，P-3-2等)。	感謝委員意見，已修正。
十	P.3-1，高雄縣六龜鄉寶來村，請修正為高雄市。	感謝委員意見，已修正。
十一	P.3-3，「....土石流防災資訊網...」名稱請修正為土石流及大規模崩塌防災資訊網。	感謝委員意見，已修正。
十二	數字高程模型（Digital Elevation Model, DEM），建議使用常用名稱數值高程模型。	感謝委員意見，已修正。

附錄三、期末審查會議紀錄暨回覆辦理情形

項次	審查意見	回覆辦理情形
一	目前本研究在崩塌預測因子鑑別度不足的問題上，所提出之改善方案為何？	本計畫旨在設計一智慧監測平台，以現地環境資料作為預測依據。所採用之降雨時序資料，來源為政府開放資料平台提供之崩塌事件資訊。針對各年份引發崩塌事件之降雨過程，回推5周（即840小時）作為取樣範圍。目前已取得四件崩塌事件的相關資料，分別為98年、104年、105年及110年。初步分析顯示，預測因子識別度不足可能與資料跨度分散有關。未來可考慮採用更長時間範圍的數據，例如十年每小時降雨歷時及十年每周最大PGA歷時，並納入更多環境因子，如地質條件、植被覆蓋及土壤液化等，作為模型訓練依據，以提升模型的可靠性與預測因子值之識別度，進一步增強研究成果的說服力。
二	本研究建置模型以輸入任一網格在特定時間點之前的地震和降雨歷時數據，可預測該網格的崩塌機率，其中在降雨歷時數據之時間長度如何決定？	網格內降雨歷時數據的長度可由計畫研究員自行決定，不設限制。通常而言，降雨歷時越長，結合環境因子後輸入人工智慧模型，所獲得的數據將更具說服力。此外，以98年的大規模崩塌事件為例，該事件造成坡地的坡度、植被及土壤等環境因子發生變化。因此，若使用更早年份的崩塌事件數據，必須配合該年的環境因子進行分析。因此，對於此模型而言，降雨歷時數據的長度應與崩塌事件發生的時間相匹配，並結合該時間的環境因子，以達到最佳效果。
三	本模式以預測日期的前72小時降雨及前一年地震資料為輸入	未來可將模型建置為實時接收研究區內的監測數據，包括降雨歷時資料、地震數據及環境因子等。降雨歷

項次	審查意見	回覆辦理情形
	值，若於預測未來發生機率，將輸入甚麼資料？	時數據可每日更新，提供前三天的每小時累計降雨量歷時；地震數據則可每周更新，提供該周前一年內的每周最大 PGA 歷時。這些數據將作為輸入，傳入經訓練的模型，即可實時預測當天研究區的崩塌機率。
四	模式中之主要產出一崩塌機率定義為何？因輸入資料有多種尺度資料，該機率是空間機率？時間機率抑或其他？	主要產出的崩塌機率定義為研究範圍內各網格單位發生崩塌的可能性，該機率是基於時間序列因子（如降雨和地震歷時）與環境因子（如坡度、坡向、高程）計算得出的綜合性指標。由於輸入資料包括多種尺度（如時間序列和空間數據），該崩塌機率應視為空間機率，因為其計算目的是針對每個網格的崩塌風險進行評估，並以空間範圍內的風險分布為核心。時間序列資料主要用於提取時間相關特性，但最終的機率呈現是針對網格的空間分布進行預測。
五	地形因子：坡向、坡度同時也存在時變性，這部分的資料該如何更新？	地形因子的時變性可透過多源數據和技術手段進行動態更新。例如，定期使用遙感技術獲取高分辨率的衛星影像或無人機影像，進一步處理生成數位高程模型（DEM），即可更新坡向與坡度等地形參數。此外，對於變化顯著的區域，可利用地面測繪技術如全站儀、差分 GPS 或激光雷達進行精細測量，捕捉崩塌、侵蝕或地震引發的地形變化。這些數據與歷史地形資料結合，能有效補充模型的時空動態性，確保地形因子隨環境變化而準確更新。
六	建議持續研究，落實推廣到分署。	非常感謝，會持續精進本研究。