

## 利用深度學習精進坡地社區自主防災之崩塌風險評估模式計畫編

號：SWCB-111-240

執行單位：逢甲大學

計畫主持人：逢甲大學土木工程學系 李秉乾教授

共同主持人：逢甲大學都市計畫與空間資訊學系 雷祖強教授

協同主持人：逢甲大學營建及防災研究中心 謝孟勳研究助理教授

協同主持人：逢甲大學地理資訊系統研究中心 黃亦敏研究助理教授

協同主持人：逢甲大學地理資訊系統研究中心 方耀民研究副教授

協同主持人：逢甲大學土地管理學系 周天穎教授

### 摘要

由於全球氣候變遷與溫室效應的影響，導致極端降雨事件頻傳，民國 98 年莫拉克颱風即為強降雨事件的明顯案例，造成臺灣中南部山區遭受嚴重災情，此一事件亦突顯大規模崩塌所造成之災害，未來恐對臺灣山坡地聚落造成嚴重災害威脅。因此，為預防未來豪大雨或颱風來襲時可能造成之災害，有必要針對山坡地的易崩特性、崩塌風險及警戒機制等課題進行更深入的研析。

而過去本計畫已於相關計畫發展崩塌風險警戒機制模式，透過崩塌風險的三項因子(危害度、易損性以及暴露量)整合於塌風險評估模式，其可有效掌握到個別因子的影響性，即降雨時序特徵對地面環境的影響性(危害度)、地面環境對於降雨的承受能力(易損性)以及保全對象所在的位置(暴露度)；在地面環境對於降雨的承受能力(易損性)之研究中，仍有幾個研究問題有待解決：1. 本研究主要是基於單一坡面單元之數據組成並透過統計分析模式所建立之分析模型，這可能存在忽略坡面單元間之空間相關性的問題，因此難以探索整個集水區之坡面單元間之整體崩塌變化且對於崩塌變異不明顯之坡面單元亦可能於分析模型過程中被忽略，這可能引起一些潛在之威脅未被預測到或是單一坡面間之數值組成之同質性較高，而產生過多崩塌發生之不合理誤判產生。2. 當不易變動之因子(空間關聯特徵、地文潛勢)資料建立完畢後，對於具有時空變異特性之降雨因子資料庫於模式之角色就相當重要，我們認為崩塌災事件的發生有次序性關係，也就是當降雨發生後，其規模由小到大，當降雨規模達到一定程度後(誘因條件滿足)，再加上不同集水區的環境條件的組合關係(潛因條件滿足)後，就會發生崩塌事件。因此本計畫將導入時序性深度學習以及圖像深度學習以改善模型對於降雨引致的崩塌潛勢於未知的降雨雨場中，萃取出關鍵之降雨誘發牽動關係，增加模型對於雙參數雨量時空因子之敏感性，使模式本身的預測能力可以再提高。

最後，完成了崩塌潛勢評估模型之優化、更新崩塌風險警戒機制以及訂定一套崩塌風險指標警戒門檻後，為了能夠有效地應用於災害應變管理，本計畫將崩塌災害警戒管理落實於自主防災為主要目的，將進行自主防災崩塌警戒發布管理流程設計並嘗試落實坡地崩塌評估模式於社區自主災害警戒應用於高風險潛勢社區，並規劃相關避難路線及崩塌風險地圖等，進而達社區自主避災、防災及減災的目標。

**關鍵詞：**坡面單元、崩塌、深度學習、警戒管理、自主防災

## Applying deep learning to improve the landslide risk assessment model for disaster resistant communities

Due to the impact of global climate change and the greenhouse effect, extreme rainfall events are frequent in recent years. Typhoon Morakot in 1998 was an example of heavy rainfall events, which caused severe disasters in the mountain areas of central and southern Taiwan. This event also highlighted the large-scale landslide and its serious impacts. Therefore, to prevent future disasters that may be caused by heavy rains or typhoons, it is necessary to conduct a more in-depth study and analysis on the potential and risk of landslides, and early warning systems.

In the past, the research team has developed a landslide risk evaluation and warning model in related projects. The three factors of landslide risk (hazard, vulnerability, and exposure) are integrated into the landslide risk assessment model, which can effectively understand the individual factors, such as the impact of the temporal characteristics of rainfall on the local environment (hazard), the local environment's ability to withstand rainfalls (vulnerability), and the location of the protected objects (exposure). In the research of vulnerability, there are still several research problems to be solved: 1. The previous research model was mainly based on the data composition of a single slope unit. This may have the problem of ignoring the spatial correlation between slope units, so it is difficult to explore overall variation of the entire catchment area. The variation between slope units may also be ignored in the analysis, which may cause some potential threats to be unpredicted, or the numerical composition of slope units is relatively homogeneous, resulting in unreasonable landslide potential estimation. 2. After the data of stable factors (i.e., spatial correlation characteristics and geological potential) are established, the role of the rainfall database with spatiotemporal variation characteristics in the model is very important. It is assumed that the occurrence of collapse events is in sequential relationship, that is, when the rainfall occurs and the scale of rainfall reaches a certain level (triggering conditions), with the environmental vulnerability (potential conditions), there will be a landslide. Therefore, this project will introduce time-series and image deep learning methods to improve the model's performance for rainfall-induced landslide in the unknown rainfall field, and to extract the key influence relationship. The improved sensitivity of factors can further improve model's ability of landslide prediction.

Finally, after completing the optimization of the landslide potential assessment model, updating the landslide warning mechanism, and setting landslide risk indicator thresholds, this plan will implement the landslide disaster management and design the warning issuing process for disaster resistant communities. The proposed landslide potential model will be introduced to the communities with high-risk of landslide disasters, and the evacuation maps and landslide potential maps will also be prepared. The goal of disaster avoidance, prevention, and mitigation for a community will be achieved in the end.

**Keywords:** slope unit, landslide, deep learning, warning system, disaster resistant

## 一、前言

由於全球氣候變遷與溫室效應的影響，導致極端降雨事件頻傳，民國 98 年莫拉克颱風即為強降雨事件的明顯案例，造成臺灣中南部山區遭受嚴重災情，此一事件亦突顯大規模崩塌所造成之災害，未來恐對臺灣山坡地聚落造成嚴重災害威脅。因此，為預防未來豪大雨或颱風來襲時可能造成之災害，有必要針對山坡地的易崩特性、崩塌風險及警戒機制等課題進行更深入的研析。

而過去本計畫已於相關計畫發展崩塌風險警戒機制模式，透過崩塌風險的三項因子(危害度、易損性以及暴露量)整合於塌風險評估模式，其可有效掌握到個別因子的影響性，即降雨時序特徵對地面環境的影響性(危害度)、地面環境對於降雨的承受能力(易損性)以及保全對象所在的位置(暴露度)；在地面環境對於降雨的承受能力(易損性)之研究，並已透過時序特徵深度學習以及建構集水區坡面單元圖像之空間關聯性去進行崩塌潛勢評估模型的優化，以增加模型在災害應變時之適配性，並將此模型更新於本計畫發展之崩塌風險警戒機制模式之後，下一個階段則是設定崩塌警戒門檻。在崩塌防災的課題中，設定崩塌警戒是未來發展的趨勢，但在決定崩塌警戒模式的研究中，仍有許多因素有待克服。目前眾多研究中，仍以降雨促使崩塌為主要的研究對象，普遍採用歷史事件之速報資料來評估崩塌雨量警戒值，因此其對於無速報資料之行政區無法有效之訂定警戒值，且因近年來受極端氣候常態化影響其不確定性增加，作為減災策略擬定之依據尚有許多不足之處，因此本計畫初步透過雙參數因子的條件下( $I_{max}$  與  $R_{te}$ )分別取得崩塌危害度以及坡地易損性之評估指標，對評估崩塌風險警戒具有較全面的考量，而其必須考慮不同指標及其對崩塌之影響性，這些指標門檻的決定(量化)及資料蒐集，亦是本計畫研究過中要解決的難題。

最後，完成了崩塌潛勢評估模型之優化、更新崩塌風險警戒機制以及訂定一套崩塌風險指標警戒門檻後，為了能夠有效地應用於災害應變管理，本計畫將整合大規模崩塌監測資訊，其中將配合農委會水保局「氣候變遷下大規模崩塌防滅災計畫」於 2020 年完成全臺 36 處大規模崩塌高風險區研究調查，建立防滅災監測、預警系統及示範區，而共三處大規模崩塌影響範圍於本計畫研究區域(陳有蘭溪、荖濃溪以及旗山溪集水區)內，並針對各大規模崩塌高風險區所建置簡易觀測系統數據，掌握大規模崩塌潛勢區，如下圖 1-1，根據影響範圍劃定、細部監測區位及觀測儀器之監測資料，與本計劃模型之颱風豪雨實測警戒趨勢進行比較，研析崩塌發生的誘發機制，供作為應變機制修正參考，以提高模型預警啟動機制的準確度。

## 二、工作項目與內容

本計畫主要之工作流程如圖 1 所示，進而完成以下工作項目，以達成本年度之計畫目標。

- (一) 崩塌以及降雨規模關聯特徵樣本擴增
- (二) 廣域崩塌風險警戒機制模式優化
- (三) 多元尺度崩塌警戒應用管理
- (四) 智慧防災網絡設計規劃

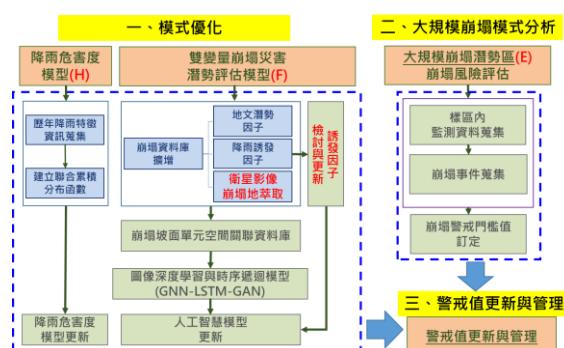


圖 1 本年度工作項目與流程

### 三、計畫研究成果

#### (一) 崩塌以及降雨規模關聯特徵樣本擴增

本計畫研究地區包含陳有蘭溪集水區、荖濃溪集水區、旗山溪集水區及等三個集水區，進行坡地易損性分析前須建立集水區各類環境因子資料，集水區資料蒐集自林務局農林航測所繪製之陳有蘭溪集水區、荖濃溪集水區和旗山溪集水區之相關地文、水文地理資訊圖資以及水土保持局全國集水區圖層，採用圖層範圍包括主、次、子集水區範圍圖、河系圖等地理資訊基本圖資。在集水區環境因子方面，本計畫藉由網格資料庫建置各類環境因子屬性、植生變異因子、驅動因子及崩塌事件等資訊。環境資料庫以 20m x 20m 之網格尺度使不同集水區範圍內所有屬性因子鏈結並進而透過坡面單元之繪製，將資料庫進行尺度之轉換以作為後續模型建置之分析單元，環境資料庫細分為四個部分：1. 環境潛勢因子；2. 前期擾動誘發因子；3. 降雨驅動因子及 4. 崩塌資訊。

依據坡面單元之劃設及篩選程序，陳有蘭溪集水區劃分完成之坡面單元總計有 6,651 個坡面單元。荖濃溪集水區劃分完成之坡面單元總計有 21,279 個坡面單元。旗山溪集水區劃分完成坡面單元總計有 10,985 個坡面單元，如下圖 2 所示。

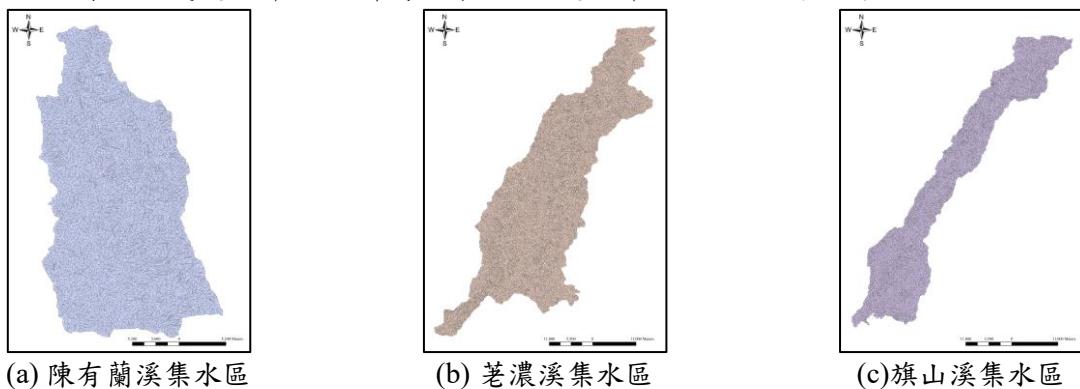


圖 2 各集水區之坡面單元分布圖

#### 1. 崩塌降雨危害評估模型建立

由於土石流潛勢溪流都在山區，要實際量測土石流發生前溪流溝床內土體的孔隙水壓及地下伏流水狀況困難度很高，而降雨資料的取得又比孔隙水壓及地下伏流水資料來的容易。因此，在過去的研究中，大部份的研究人員都藉由土石流發生之前的降雨量（前期降雨）來間接說明土體的含水狀況（即孔隙水壓），直接探討降雨條件與土石流發生之關係，並利用降雨條件建立土石流發生降雨警戒關係式。因此本計畫團隊同理在分析崩塌災害發生降雨特性時，通常需考量崩塌發生當時的直接誘發雨量（包括降雨強度與當場累積雨量）及間接激發雨量（如前期降雨）。

其中以 10 年間降雨資料作為建立雨量等比率曲線模式之基礎，歷史雨量資料庫依新年度持續更新，以反映近年氣候變化；透過將雨量資料先進行雨場分割，建立各雨場之 ( $\ln R, \ln I$ ) 雨型組數據，並建立各重點聚落中歷史雨場之時雨量及有效累積雨量之聯合機率質量函數，將各雨量站民國 99 至民國 111 年之資料進行標準化等處理後，並基於全部無事件雨場之雨型組 ( $\ln R_{ti}, \ln I_{tj}$ ) 之聯合累積分布函數定義如下：

$$F_{\ln R_t, \ln I_t}(\ln R_t, \ln I_t) = \sum_{i=1}^{i: \ln R_{ti} \leq \ln R_t} \sum_{j=1}^{j: \ln I_{tj} \leq \ln I_t} p_{\ln R_t, \ln I_t}(\ln R_{ti}, \ln I_{tj}) \quad (1)$$

本計劃基於 10 年雨量資料雨場之雨型組  $\ln R_t$  與  $\ln I_t$  聯合機率質量函數計算成果代入(1)式進行計算，建立  $FLR, LI(\ln R, \ln I)$ ，透過各雨量站 10 年間雨量資料建立之三維空間歷史雨場聯合累積分布函數圖，並將其三維空間映射至二維空間，以建立各聚落鄰近雨量站之歷史雨場( $I_{11} - R_{te}$ )等比率曲線圖，以下以豐丘重點聚落管理單元最鄰近之

瑪家雨量站繪製各歷史雨場等比率曲線圖如下圖 3 所示：

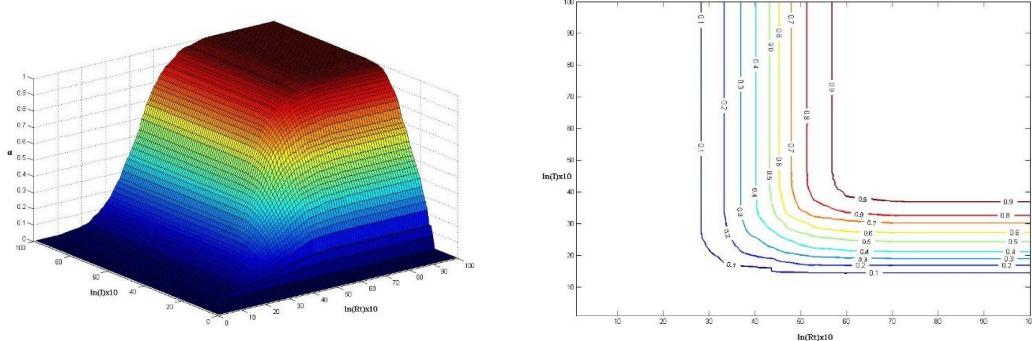


圖 3 豐丘雨量站降雨危害度曲面

## 2. 植生樣態資料更新

崩塌資料庫中對於各事件之植生狀況，以事件前期之衛星影像資料利用 ERDAS Imagine 計算不同影像時期的 NDVI 值並使資料網格化。而本計畫建立之崩塌事件資料庫及環境因子資料庫中，對於現地環境條件和植生現況等變動因子需定期予以更新至最新環境資料，因此，為掌握本年度計畫重點聚落之坡地植生環境狀況作為崩塌評估模式之修正參考，必須針對研究區域蒐集本年度汛期前可取得之衛星影像並分析其植生現況。新的植生分析結果會使聚落坡面單元之崩塌植生因子產生變化。因此，屬變動因子的植生現況分析係本計畫重要工作，目前已自太空遙測中心取得本年度(2022 年 01 月 16 日以及 2022 年 3 月 15 日之 SPOT7 衛星影像)，並完成 111 年度研究區之植生分析所示。本計畫中屬變動之崩塌植生因子並已同步更新，且重新定義了各集水區坡面單元之坡面類別屬性，以利於模型訓練參數之更新，下錯誤!找不到參照來源。為各集水區之 111 年度汛期前衛星影像植生特徵分析圖。



圖 4 各集水區 2021 年汛期前植生現況分析

## 3. 坡地崩塌風險評估指標警戒值訂定機制

在完成上述降雨危害評估模型之更新以及自適性坡地崩塌潛勢評估模型之優化後，在實際逐時降雨之應用上，由於兩者間考量之空間尺度不同，管理單元尺度中以鄰近之雨量站所建立之降雨危害評估模型作為降雨危害評估指標之參考，以下圖 5 為例，一個事件之逐時降雨( $I_i, R_i$ )於降雨危害評估模型將會產生逐時之降雨危害評估值( $H_i$ )，

圖 5 之綠色趨勢線所示，而自適性坡地崩塌潛勢評估指標則以管理尺度單元內之坡面單元經過數值統計作為該單元之潛勢值依據，以下圖 6 為例，一個事件之逐時降雨( $I_i$ ,  $R_i$ )於自適性坡地崩塌潛勢評估模型將會於各坡面單元產生逐時之自適性坡地崩塌潛勢評估值( $F_i$ )，但基於管理單元需一個崩塌潛勢代表值，本計畫初步先以該管理單元下之坡面單元的逐時潛勢值進行算術平均數作為該管理單元之坡地崩塌潛勢評估值( $F_i$ )，如圖 6 之綠色趨勢線所示。

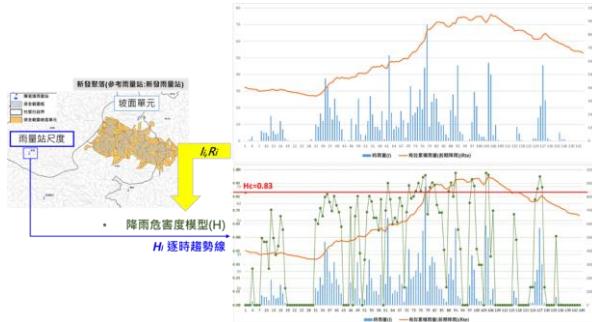


圖 5 降雨危害評估模型應用示意圖

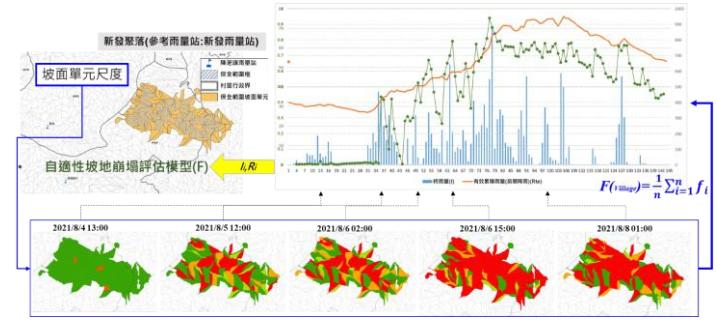


圖 6 自適性坡地崩塌潛勢評估模型應用示意圖

在界定各聚落所位在之村里降雨危害度最小致災門檻值(HC)，則採用位於該聚落之行政區界(鄉鎮界)速報資料，其提供著該重點聚落實際發生崩塌災害之時間點以及雨量資料，本計畫用速報資料所記錄時機點之雨量資料於歷史降雨比率曲線(H)，即可在圖面上點繪出最小致災門檻曲線，以訂定降雨危害警戒值(HC)；而在崩塌潛勢機率最小致災門檻值(FC)，本計畫針對各尺度管理單元所訂定之崩塌評估指標警戒值邏輯設計，而如同土石流潛勢溪流訂定的標準，以有保全對象之溪流去進行潛勢評估，並以當年度以及前五年度之全島崩塌地圖進行崩塌紀錄比對，其可於每年滾動性檢討，將各管理單元內前五年崩塌資料庫於崩塌潛勢評估模型(F)進行測試，並求取最佳崩塌分類切割閥值(g-mean)作為管理單元之崩塌潛勢最小致災警戒值(FC)，其具有考量模式分類崩塌以及實際崩塌資訊最合宜之崩塌切割值，具有大數據崩塌雨量數據對警戒管理內容進行警戒值訂定模型之參考依據。

根據上述對本團隊已針對計畫南部集水區之 13 處具崩塌潛勢重點聚落進行降雨危害度最小致災警戒值(HC)以及崩塌潛勢最小致災警戒值(FC)訂定，並持續於各年度透過雨量資料庫的擴增更新以及現況植生更新，進而更新降雨危害度最小致災警戒值(HC)以及崩塌潛勢機率最小致災警戒值(FC)，如下表 1 所示，以後續應用於行政區警戒發布機制研析。

表 1 13 處南部集水區重點聚落村里崩塌與降雨警戒機率表(111 年度)

重點聚落			對應雨量站	HC	FC
鄉(鎮、區)	村(里)	聚落			
桃源區	寶來里	竹林(16、17 鄉)	高中 C1V231	0.81	0.57
桃源區	寶山里	新藤枝	御油山 C1V300	0.81	0.72
桃源區	寶山里	舊藤枝	御油山 C1V300	0.81	0.61
桃源區	梅山里	梅山口	梅山 C1V200	0.95	0.71
桃源區	寶山里	寶山	御油山 C1V300	0.81	0.65

桃源區	寶山里	萬山里1鄰萬山巷	寶山 O1V510	0.83	0.63
茂林區	萬山里	新庄里司馬路	萬山 C0V790	0.72	0.53
杉林區	新庄里	寶山里2鄰寶山巷	龍泉寺 81V870	0.81	0.67
信義鄉	神木村	神木	神木村 C0H9A0	0.82	0.62
信義鄉	豐丘村	豐丘(信義)	豐丘 C1I290	0.84	0.64
那瑪夏區	瑪雅里	瑪雅	那瑪夏國中 81V830	0.92	0.68
那瑪夏區	達卡努瓦里	達卡努瓦	達卡努瓦 (民生)C1V160	0.92	0.66
那瑪夏區	南沙魯里	南沙魯	那瑪夏國中 81V830	0.92	0.67
甲仙區	東安里	白雲巷	新發 C1V590	0.92	0.66
六龜區	新發里	新發部落山邊	新發 C1V590	0.83	0.66
六龜區	興龍里	新開部落(26鄰)	新發 C1V590	0.83	0.66

## (二) 廣域崩塌風險警戒機制模式優化

### 1. 高時間解析度之崩塌序列特徵模型

過去研究在建立崩塌評估模型過程中，面臨分析對象資料集的資料量不足的問題，如模擬崩塌敏感性的早期方法是基於實地調查，而此類技術成本高昂且因場地而異。另外，在目前所能取得的全島崩塌地圖之崩塌資料的時間尺度(以年為單位)上也往往難以與實際降雨資料的時間尺度做為比對以及驗證，這也在模型對於實際的崩塌發生時間點基本上是無法詳細得知，近而無法探索坡面單元的時序特徵變化。為此本計畫與國家太空中心合作，取得年度間的衛星影像，並透過深度學習技術進行崩塌地判釋，進以擴增年度間的崩塌特徵時序特徵(圖 7)，並串連目前以完成的模型架構，以提高模型的適配性。

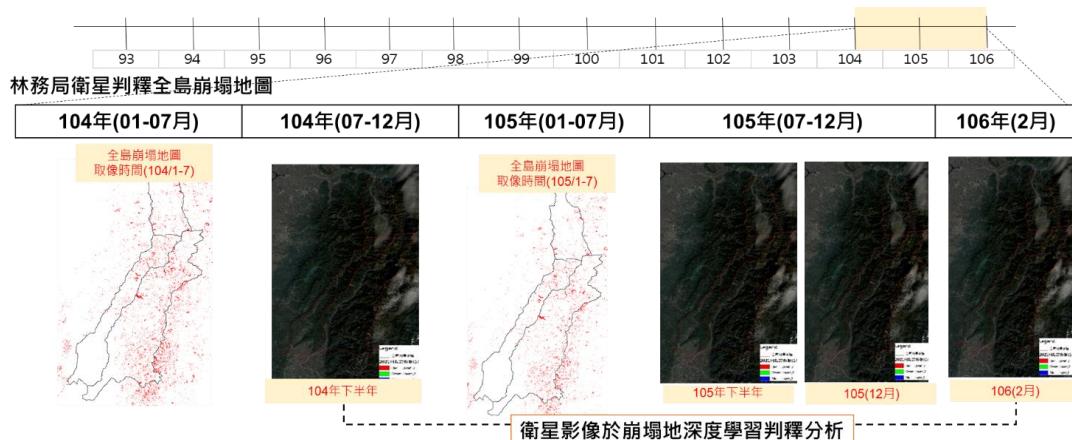


圖 7 衛星影像深度學習判釋分析於擴增崩塌時序特徵樣本

### 2. 資料集及標籤準備

在模型訓練時有兩個準備，第一，我們期待模型從影像數值中，直接辨識真正的為崩塌區塊，因此，訓練用與測試用的影像會取自不同網格，確保模型沒有學習過該網格的資料。因此，在同一時期的衛星影像中，會切分為概念上南、北兩個資料集，交替作為訓練集進行訓練。目前使用的網格資料如表 3-10，G033、G034 因顏色偏差過大資料

崩塌標籤極少，未採用於本次訓練中，G046、G064 兩個網格內未涵蓋崩塌標記資料，因此也不採用於本次訓練中。訓練用資料集每 256x256 取出一圖塊，每塊移動 64 pixel，測試用資料集每 256x256 大小的圖塊，每塊移動 256 pixel，資料數量詳列於表 2 中。

表 2 FS-2 衛星圖資一覽表

資料及類型	圖資時間	網格編號	圖塊單元數量
訓練集	2015 年 12 月 19 日	G047	13,500
訓練集	2015 年 12 月 19 日	G048	23,227
訓練集	2015 年 12 月 19 日	G049	27,920
訓練集	2015 年 12 月 13 日	G065	12,949
測試集	2015 年 12 月 19 日	G050	2,064
測試集	2015 年 12 月 19 日	G051	547
測試集	2015 年 12 月 13 日	G066	707
測試集	2015 年 12 月 13 日	G067	464
測試集	2015 年 12 月 13 日	G068	47
未採用	2015 年 12 月 31 日	G033	
未採用	2015 年 12 月 31 日	G034	
未採用	2015 年 12 月 19 日	G046	
未採用	2015 年 12 月 13 日	G064	

第二，針對可能是復原地、或可能是陰影的部分進行標籤平滑化(label smoothing)。觀察資料時，人眼可見衛星影像中的崩塌地與正常地的顏色數值，顏色上都偏綠，差異在樹的密度在不一樣，因此，對於目前已有崩塌標記的圖塊單元，為避免訓練時可能會發生的過擬和狀況，目前的衛星影像共有四個通道(channel)，分別為紅(R)、綠(G)、藍(B)、以及 NIR，在此預先做了兩個判定，當 G 通道數值大於 R 通道 1.5 倍時，該地可能為已經開始復原的地區，原本標示為崩塌的地方會由數值 1 降為 0.8。當整體數值量偏低時 G、R、B 三個通道相加數值小於 150 時，該地有可能是陰影，原本標示為崩塌的地方會由數值 1 降為 0.6。

### 3. 崩塌地偵測模式

本次使用以 U-Net 為基礎修改的網路結構，如圖 8 所示，模型輸入為 256x256x4 pixel 大小的單元圖塊，輸出為 256x256x2 的辨識結果，模型對輸入影像進行下採樣(down sampling)與上採樣(up sampling)，逐步萃取出影像特徵，下採樣主要使用 5x5x64 的卷積，下採樣後的影像特徵，會將其送至上採樣後同樣大小的輸入，再次執行上採樣。模型在訓練時會對資料進行資料增強(Data augmentation)，隨機在每個通道乘上 0.9~1.1 不等的數值，對顏色進行一定程度的偏差；同時，在每個資料點隨機加上  $\pm 2.55$  之間的數值，數值範圍限制在 0-255，正規化至 0-1 後送入模型。

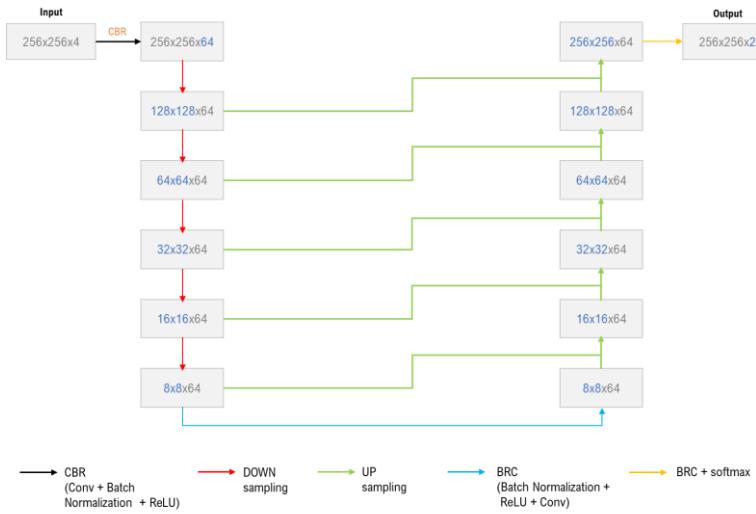


圖 8 邊坡崩塌偵測網路架構圖

#### 4. 崩塌地偵測模式

經由模式測試與修正後，門檻值採用 0.92 進行崩塌地釋，結果表示模型所判定崩塌地的部分有 80% 是可信的，約可涵蓋所有崩塌地中的 45%，其中，與崩塌地的面積涵蓋率約為 40%。若觀察所有門檻值的 IoU，本模型最高值為 50%，挑選此門檻值可達模型最佳表現的八成。判釋結果如下所示：

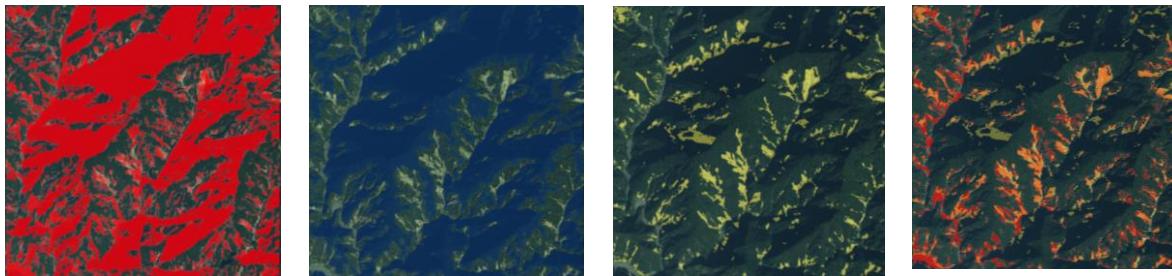


圖 9 崩塌地判釋結果

本次使用衛星影像訓練模型取出圖中可能為崩塌的區塊，由辨識結果可見，模型辨識結果可達一定準確程度，可快速地提供研究人員在取得衛星影像後的崩塌地標記，在未來亦可納入其他不同的衛星影像資料，作為風災後快速評估各流域崩塌之情況。

### (三) 多元尺度崩塌警戒應用管理

#### 1. 大規模崩塌資訊應用

由於本計畫之研究區域集中於陳有蘭溪集水區、荖濃溪集水區以及旗山溪集水區，因此本計畫先於研究區域內選擇三處大規模崩塌監測點位做為整合監測於坡地物聯網的先期研究標的，並整合樣區內測站之各項監測資訊資訊，進行數值分析，並應用於本計畫設計之自主防災模式進行驗證。樣區內測站資訊包含：編號 D382(寶山)、編號 D021(新庄)、編號 D048(萬山)。各區域各項資訊與監測資料如圖 10 所示。三個測站中皆包含 4 種物理量的監測資訊：雨量、地下水位、地表傾斜變位、GPS 地表變位，根據其監測的物理量，我們可將監測物理量與坡面滑動之關係進行分類。

在雨量與地下水位的部分，這兩種物理量皆為主要影響坡面是否穩定的外在影響因素，因此較適合用於早期預警使用，如本計畫使用的雨量指標等。而坡地地下水位若在降雨時無法有效排出，其地下水位將會不斷上升，針對地下水位的變化對坡面的影響，傳統上則可透過邊坡穩定模擬分析(slope stability analysis)，模擬坡面的安全係數

(factor of safety)，並以安全係數做為崩塌預警的指標，但由於過去現場監測資料較難取得，因此此類預警方法較少使用。

反之，地表傾斜變位與 GPS 地表變位則用於感測坡面是否已發生滑動，並可用於判斷當下是否正處於移動的狀態，因此較適合用於建立緊急疏散的指標，當坡面已在滑動且有持續加速的跡象時，即使其他早期預警如降雨及地下水所建立的指標未達到警戒(如非降雨造成的崩滑)也必須盡速撤離。

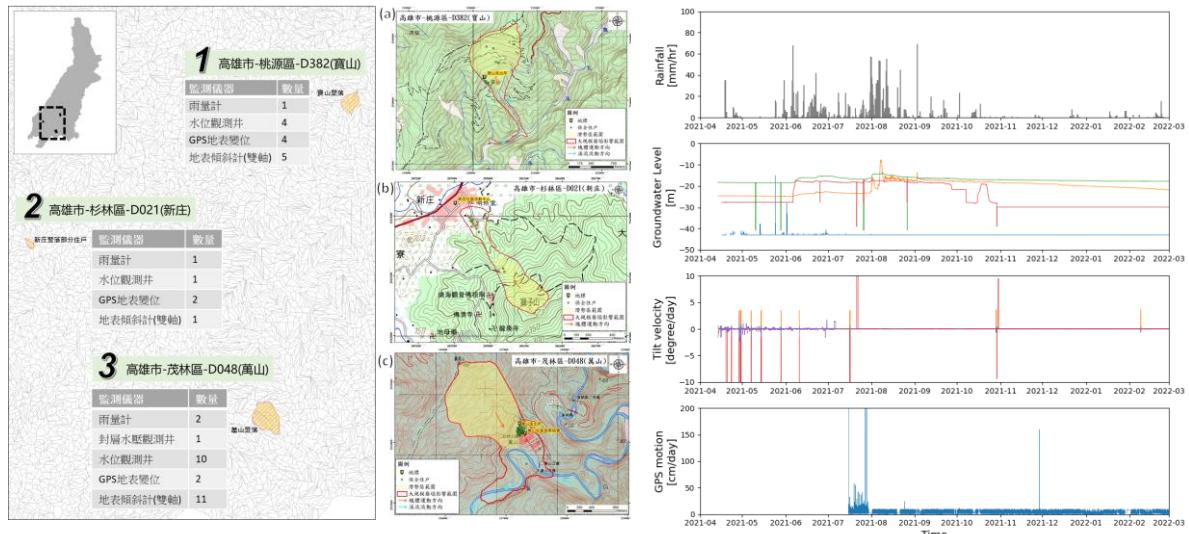


圖 10 大規模崩塌測站資訊

## 2. 坡地社區崩塌風險警戒發布以及大規模崩塌監測研析

在颱風豪雨事件逐時實測模擬中，本計畫團隊利用前期計畫所挑選南部集水區之 1 處 1 處大規模崩塌潛勢區域(寶山聚落)，作為崩塌防災社區管理可行性評估之對象，並實測模擬去年度(110)之盧碧颱風暨 0806 水災的逐時降雨的社區崩塌風險警戒發布管理推播試作，在雨場開始前，所需關注之對象為 1. 重點社區鄰近之雨量站，2. 重點社區範圍內所有之坡面單元，3. 重點聚落之崩塌風險警戒機制圖，如下圖 11 及圖 12 所示：

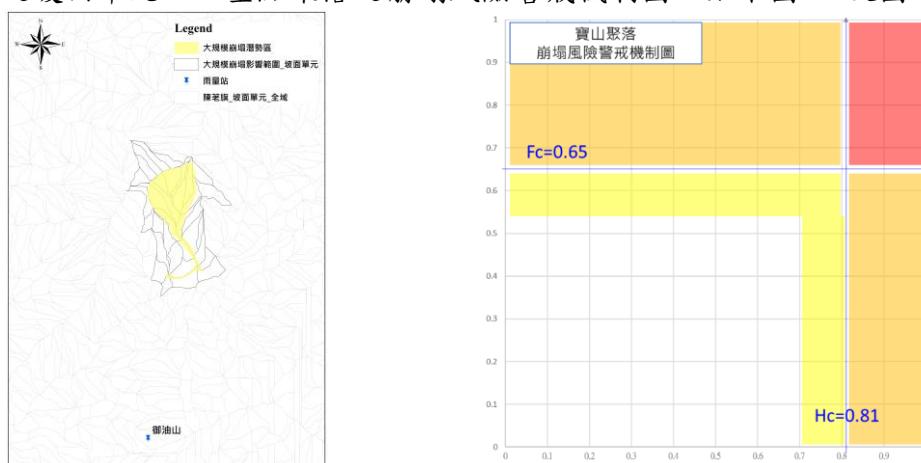


圖 11 社區內坡面單元資訊

圖 12 聚落崩塌風險警戒機制圖

寶山聚落的監測點位共有四處，每處皆設有地下水位觀測井與傾斜儀，而在其中編號 01、02、03 則有設置 GPS 座標變位監測，雨量計則僅設在編號 01 的測站，詳細位置與儀器設置分布如圖 4-19。在測試的事件中，其實山聚落參考雨量站寶山測站於 0731

豪雨事件之最大有效累積雨量約達 531 毫米，於盧碧颱風及 0806 水災事件之最大有效累積雨量約達 875 毫米，兩次事件期間最大之時雨量約達 70 毫米。而針對大規模測站之雨量計與臨近氣象站之雨量計進行崩塌潛勢分析比較中，若採用大規模崩塌測站，可提前四小時進入紅-2 警戒，且警戒結束時間與氣象站結果相同(如：圖 13 所示)，顯示可提前提供預警資訊供業務單位進行疏散參考。

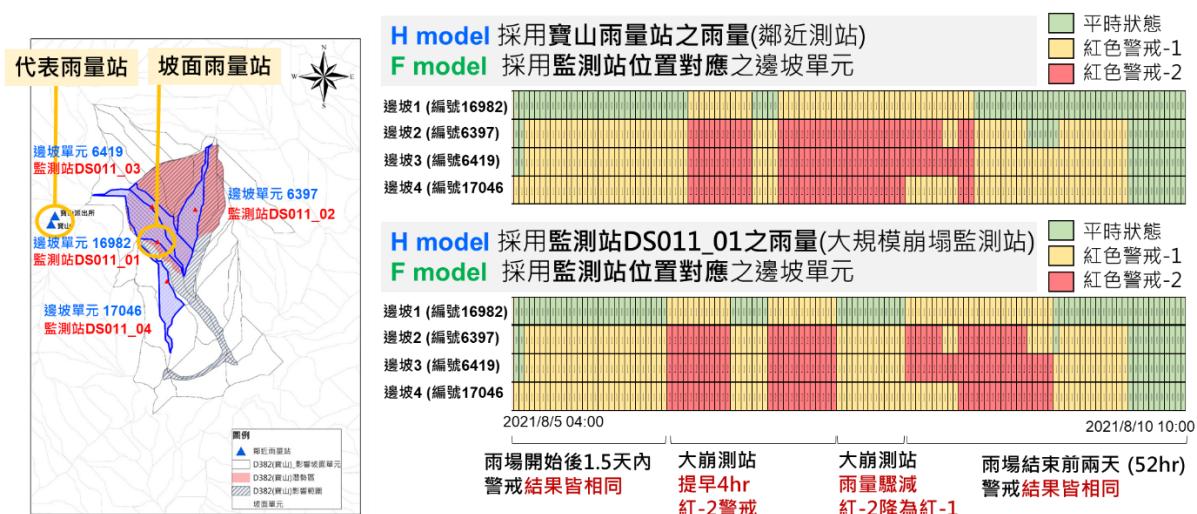


圖 13 寶山聚落於盧碧颱風暨 0806 水災之雨量站差異

#### (四) 智慧防災網絡設計規劃

「智慧防災」並沒有一個正式的定義，但通常指稱包含自動監測、遠距傳輸、具備遠端監控等功能的防災監測應變系統，可協助決策者或權責單位提昇災害預防、應變及搶救復建之機能的一套系統或平台。基本上「智慧防災」的「智慧」要能體現判斷及預警自動化，並進一步能預測災害的發生。結合本計畫歷年主辦多項關於坡地社區坡地崩塌風險評估模型之研發，以及相關警戒管理值之訂定，並以重點聚落/社區進行驗證實測工作經驗。本計劃初擬能夠整合本計畫研究能量以及相關政府之監測數據資料，初擬山坡地社區智慧防災物聯網架構，內容分為(1) 監控感測器、(2) 巨量資料、(3) 雲端運算以及(4) 區域通報機制等，以提供使用者整合的場域即時監測資料以及簡潔且具有防災意義性的場域資訊

藉由資通訊技術、邊坡即時監測與大數據分析平台，可於遠端與網路架構下即時掌握邊坡動態與警戒資訊，並進行即時大數據分析、坡面崩塌風險評估與結果視覺化呈現，以提供系統化、科學化的防災管理資訊，建構山坡地社區邊坡崩塌智慧防災物聯網雛形(如下圖 14 所示)，此外透過整合多元崩塌資訊來源，能夠提供使用者端更多元的服務，亦介接防救災相關公開資料，如氣象局即時雨量以及國家災害防救科技中心公開示警訊息，提前因應可能發生之災害，協助防救災資源調度、避難警戒操作參考。

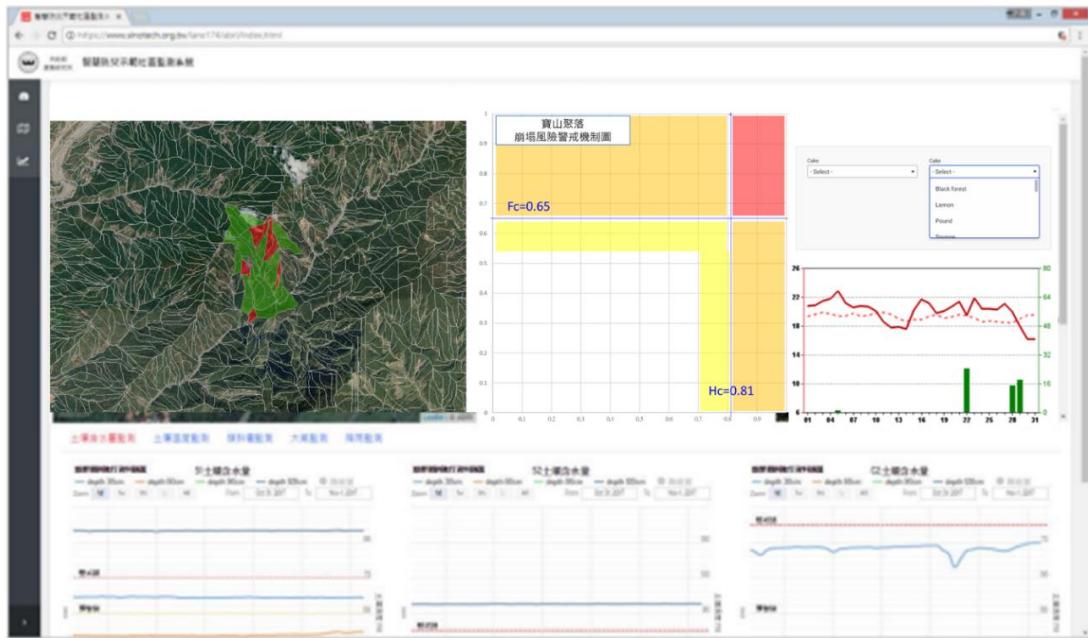


圖 14 即時監測資料展示規劃示意圖

本計畫在初擬崩塌警戒物聯網資訊平台之架構，展示利用系統化操作方式協助自主防災崩塌警戒發布之可行性，同時該警戒模組已納入不同尺度行政區以及社區警戒範圍，故可於災害應變期間，配合各級政府單位以及社區管理層級提供崩塌警戒資訊(圖 15)。未來可經由增加境內受崩塌潛勢影響的保全聚落數目，進一步了解各行政區內的「崩塌熱區」，同時突顯本研究計畫所規劃多尺度崩塌警戒流程的實用性，達到「精準防災」的目標。

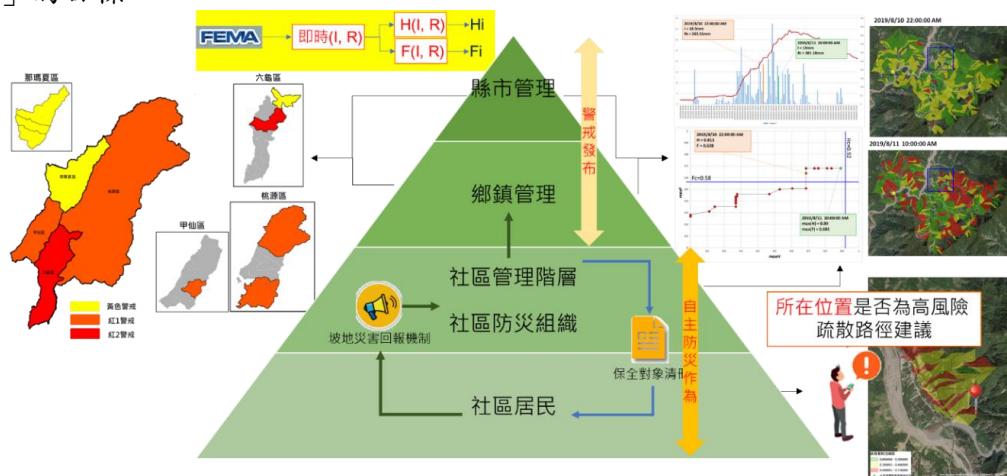


圖 15 崩塌自主防災架構圖

#### 四、結論與建議

1. 本計畫已完成針對研究區內陳有蘭溪集水區、荖濃溪集水區、旗山溪集水區之三處大規模崩塌潛勢區之模型更新(降雨危害評估模型(H))以及 2022 年度植生更新於坡面崩塌評估模型(F)。
2. 本計畫已完成與國家太空中心之 103 年 12 月、104 年 10-12 月與 105 年 2 月衛星影像蒐集，三個集水區共需取得 13 個區塊的衛星影像資料影像包含四個波段，分別

為紅、藍、綠與近紅外波段，影像類型包含 multispectral (MS)、panchromatic (PAN)、Pansharpen Multispectral (PMS) 等，並已完成衛星影像深度學習之崩塌判釋模型架構設計，並透過模式分析，可快速取得崩塌地位置。並考量於後續研究中，納入崩塌潛勢區評模型中進行整合運用。

3. 本計畫完成樣區內 13 處重點聚落社區崩塌風險指標警戒值訂定與分析。經由案例 110 年盧碧颱風暨 0806 豪雨事件進行自主防災風險警戒管理發布試作，其中各雨量站資訊透過本計畫所建立之崩塌風險警戒機制模式後，經降雨危害 H 以及崩塌潛勢 F 之推估比率後，取得各時段之警戒狀態，其說明了本計畫所發展之風險警戒模式之適用性，並於坡面風險地圖進行空間視覺化展示，可提供後續崩塌防災應用之重要參考。
4. 本計畫完成整合大規模崩塌監測資訊，結合自主防災風險警戒模式，整合智慧防災網路，透過視覺化呈現之方式，呈現大規模崩塌各項測站監測資訊與自主防災風險警戒模式中各項數值之關聯與變化。目前以雨量計資訊有正相關之關係。由於今年樣區內並致災雨量事件發生，以致各項監測資訊皆穩定，無法有效看出其差別，團隊將於後續擴大樣區範圍，持續蒐集大規模崩塌數據進行後續觀察與應用。
5. 本計畫完成智慧防災物聯網初步規劃，透過監控感測器、巨量資料、雲端運算、區域通報機制四大資料之整合，提供使用者整合的場域即時監測資料以及簡潔且具有防災意義性的場域資訊。
6. 由於本年度計畫樣區內並無重大颱風豪雨事件發生，故採用 110 年盧碧颱風暨 0806 豪雨事件進行各項驗證與資訊比較案例。
7. 本計畫旨在藉由空間資料搭配序列颱風挾帶豪雨導致的已知崩塌事件和範圍，以不確定型和優化型的空間資料探勘技術萃取崩塌潛勢條件，進行風險預警應變之應用，後續將持續透過構建更複雜的深度網絡，在能夠在獲取到新的資料後再次調整自身參數，以保持良好的推估模式及精準度。
8. 在崩塌防災的課題中，設定崩塌警戒是未來發展的趨勢，本計畫也將納入大規模崩塌監測資訊作為類別歸屬問題以進行警戒訂定之調整，進而透過科學統計分析之概念建立一套社區尺度可用的崩塌災害防災預警與警戒模式。

## 參考文獻

1. 吳俊傑(1997)。台灣地區之氣象災害。土木工程技術，1(2)，47-66。
2. 李秉乾、劉純之、雷祖強、謝孟勳、黃亦敏、方耀民、周天穎、連惠邦(2014)。易損性曲線於坡地崩塌警戒模式應用與坡地巨災保險研析。行政院農業委員會水土保持局，委託計畫成果報告。

3. 林恩如、劉正千、張智華、鄭依凡、柯明勳 (2013)。運用福衛二號高時空分辨率多光譜影像於臺灣全島崩塌地判釋與災害分析。航測及遙測學刊 17(1): 31-51。
4. 林榮章(1999)。都會區多解像力遙測影像之紋理分析，國立中興大學土木工程學系碩士論文。
5. 洪如江、林美聆、陳天健、王國隆（2000）。921 集集大地震相關的坡地災害，坡地破壞特性，與案例分析。地工技術，81：17～32。
6. 張石角(1987)。山坡地潛在危險之預測及其在環境影響評估之應用。中華水土保持學報，18(2)：41–48。
7. 張石角(1998)。雪霸國家公園地質災害敏感地區之調查與防範研究(大雪山地區)。國家公園學報，8(2)，100–121。
8. 莊永忠、廖學誠、詹進發(2011)。反演法於邊坡穩定參數之推導-以蓮華池集水區為例。地理學報 第六十二期：127-153 (2011)。
9. 陳紫娥(1993)，台灣山坡地工程與環境地質調查與評估法之比較研究。「工程環境會刊」第 13 期，第 26-46 頁。
10. 陳樹群、蔡喬文、陳振宇、陳美珍 (2013)，「筒狀模式之土壤雨量指數應用於土石流防災警戒」，中華水土保持學報，44(2)，131-143。
11. 黃臺豐(1999)。瑞里地震誘發之山崩。國立中央大學應用地質研究所，碩士論文。
12. 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系博士論文。
13. 廖軒吾(2000)，集集地震誘發之山崩，國立中央大學地球物理研究所碩士論文。
14. 蕭芝昀(2008)。壽豐溪集水區崩塌地變遷及特性之研究，國立東華大學自然資源管理研究所碩士論文。
15. 謝孟勳(2013)。以網格集群最大概似法建立建築物易損性曲線及其用於震災緊急運送路徑之選擇。逢甲大學土木及水利工程博士學位學程博士論文。
16. A. Tibaldi, L. Ferrari, G. Pasquare. (1995). Landslides triggered by earthquakes and their relations with faults and mountain slope geometry: an example from Ecuador. *Geomorphology*, 11 (1995), pp. 215-226.
17. Atluri, G., Karpatne, A. and Kumar. V., 2018, Spatio-Temporal Data Mining: A Survey of Problems and Methods, *ACM Computing Surveys*, vol. 51, no. 4, Article 83.
18. Armanious, Karim, (2019). MedGAN: Medical image translation using GANs. *Computerized Medical Imaging and Graphics*, 101684.
19. Arora, M. K., Das Gupta, A. S. and Gupta, R. P., (2004), An artificial neural network approach for landslide hazard zonation in the Bhagirathi (Ganga) valley, Himalayas, *International Journal of Remote Sensing*, Vol. 25(3), pp. 559-572.
20. Baeza, C. and Corominas, J., (2001), Assessment of shallow landslide susceptibility by means of multivariate statistical techniques, *Earth Surface Processes and Landforms*, Vol. 26, pp. 1251-1263.
21. Baret, F., Jacquemoud, S., & Hanocq, J. (1993). The soil line concept in remote sensing. *Remote Sensing Reviews*, 7(1), 65–82.
22. Campbell, R. H. 1975. Soil slips, debris flows and rainstorms in the Santa Monica Mountains and vicinity, Southern California. U. S. Geological Survey Professional Paper 851: 51.
23. Carrara A, Guzzetti F, Cardinali M, Reichenbach P (1999) Use of GIS technology in the prediction and monitoring of landslide hazard. *Nat Hazards*, 20:117-135.

24. Carrara, A. (1988). Drainage and divide networks derived from high-fidelity digital terrain models. NATO ASI series. Series C, Mathematical and Physical Sciences, 223: 581-597.
25. Carrara, A., Guzzetti, F., Cardinali, M., Reichenbach, P. (1999). Use of GIS Technology in The Prediction and Monitoring of Landslide Hazard. *Natural Hazards*, 20: 117–135.
26. Chang, K.T., Wan, S., Lei, T.C. (2010). Development of a spatial decision support system for monitoring earthquake-induced landslides based on aerial photographs and the finite element method. *International Journal of Applied Earth Observation and Geoinformation*, 12, 448-456.
27. Chang, T.C. and Chao, R.J. (2006). Application of back-propagation networks in debris flow prediction. *Engineering Geology*, Vol. (85), pp. 270-280.
28. Chou, W.C., W.T. Lin\*, C.Y. Lin, (2007), Application of fuzzy theory and PROMETHEE technique to evaluate suitable ecotechnology method: A case study in Shihmen Reservoir Watershed, Taiwan, *Ecological Engineering*, Vol. 31, pp. 269-280.
29. Chung, C. F. and Fabbri, A. G., (1993), The representation of geoscience information for data integration, *Nonrenewable Resources*, Vol. 2(3), pp. 122-139.
30. Crozier, M. J., and T. Glade. (1999). Frequency and magnitude of landsliding: Fundamental research issues. *Zeitschrift für Geomorphologie N. F.* 115: 141-55.
31. Chen, Y. C. and Lee, C., 2018, An Efficient Mechanism for Compensating Vague Pattern Identification in Support of a Multi-Criteria Recommendation System, *Journal of Information Science and Engineering*, vol. 34, no. 6, pp. 1633-1653.
32. Chen, Y. C. and Lee, Chiang. 2016. Skyline Path Queries with Aggregate Attributes. *IEEE Access*. vol. 4, pp. 4690-4706. (SCI, Q1)
33. Chen Y. C. and Li D. C. 2020. Selection of key features for PM2.5 prediction using a wavelet model and RBF-LSTM. Accepted by *Applied Intelligence*.
34. Dong, J., Burnham, J. G., Boots, B., Rains, G. and Dellaert, F., 2017, "4d crop monitoring: Spatio-temporal reconstruction for agriculture," Proceeding on IEEE. Int. Conf. on Robotics and Automation (ICRA), pp. 3878-3885.
35. Douzas, G., Bacao, F. and Lasta, F., 2018, Improving imbalanced learning through a heuristic oversampling method based on k-means and SMOTE, *Information Sciences*, vol. 465, pp. 1-20.
36. Einstein, H. H., (1988), Landslide risk assessment procedure, *International Symposium on Landslide*, Lausanne 2(1), pp. 75–90.
37. Elanayar, S. V. T. and Shin, Y. C. 1994. Radial basis function neural network for approximation and estimation of nonlinear stochastic dynamic systems. *IEEE Transactions on Neural Networks*, vol. 5, no 4, pp. 594-603.
38. Ermini, L., Catani, F. and Casagli, N., (2005), Artificial Neural Networks applied to landslide susceptibility assessment, *Geomorphology*, Vol. 66, pp. 327-343.
39. Fernández-Steeger, T. M., Rohn, J. and Czurda, K., (2002), Identification of landslide areas with neural nets for hazard analysis, *Proceedings of IECL*, Balkema, Netherland, pp. 163-168.
40. Fookes, P.G., Sweeney, M., Manby, C.N.D., Martin, R.P. (1985). Geological and Geotechnical Engineering Aspects of Low-cost Roads in Mountainous Terrain. *Engineering Geology*, 21: 1–152.
41. Fernandez, A., Garcia, S., Herrera, F. and Chawla, N. V., 2018, SMOTE for learning from imbalanced data: progress and challenges, marking the 15-year anniversary, *Journal of Artificial Intelligence Research*, vol. 61.

42. Gunturk, B., Batur, A., Altunbasak, Y., Hayes, M. H. I. and Mersereau, R., 2003, Eigenface-domain super resolution for face recognition, *IEEE Trans. on Image Process*, vol. 12, no. 5, pp. 597-606.
43. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y., (2014), Generative adversarial nets. Arxiv:1406.2661.
44. Guzzetti, F., S. Peruccacci, M. Rossi, and C. Stark.2007: Rainfall thresholds for the initiation of landslides in central and southern Europe. *Meteor. Atmos. Phys*: 98: 239–267.doi:10.1007/s00703-007-0262-7.
45. Guzzetti, F., S. Peruccacci, M. Rossi, and C. P. Stark. 2008. The rainfall intensity-duration control of shallow landslides and debris flows: An update. *Landslides* 5: 3–17.
46. Guo, Z., Wan, Y. and Ye, H., 2019, A data imputation method for multivariate time series based on generative adversarial network, *Neurocomputing*, vol. 360, pp. 185-197.
47. Hansen, A., (1984), Landslide hazard analysis, in *Slope Instability* (Brunsden, D. and Prior, D.B. eds.), John Wiley and Sons, New York, pp.523-602.
48. Hsieh, M.H., Lee\*, B.J., Lei, T.C. and Lin, J.Y., (2013). Development of medium and low-rise RC building fragility curves based on the Chi-Chi Earthquake data. *Natural Hazards*, DOI: 10.1007/s11069-013-0733-8. (In press).
49. Hsu, C. C., Lee, C. Y., & Zhuang, Y. X. (2018). Learning to Detect Fake Face Images in the Wild. In 2018 International Symposium on Computer, Consumer and Control (IS3C) (pp. 388-391). IEEE.
50. He, Y., Song, K., Dong, H. and Yan, Y., 2019, Semi-supervised defect classification of steel surface based on multi-training and generative adversarial network," *Optics and Lasers in Engineering*, vol. 122, pp. 294-302.
51. Ishibuchi, H., Kwon, K., and Tanaka, H.1995. A learning algorithm of fuzzy neural networks with triangular fuzzy weights. *Fuzzy Sets and Systems*. vol. 71, no. 3, pp. 277-293.
52. Jang, J. S. R. and Sun, C. T. 1993. Functional equivalence between radial basis function networks and fuzzy inference systems. *IEEE Transactions on Neural Networks*. vol. 4, no. 1, pp. 156-159.
53. Jiang, W., Hong, Y., Zhou, B., He, X. and Cheng, C., 2019, A GAN-based anomaly detection approach for imbalanced industrial time series, *IEEE Access*, vol. 7, pp. 143608-143619.
54. Joo, D., Kim, D., & Kim, J. (2018). Generating a Fusion Image: One's Identity and Another's Shape. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 1635-1643).
55. Kanungo, D. P., Arora, M. K., Sarkar, S. and Gupta, R. P., (2006), A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas, *Engineering Geology*, Vol. 85, pp. 347-366.
56. Karacan, L., Akata, Z., Erdem, A., & Erdem, E. (2016). Learning to generate images of outdoor scenes from attributes and semantic layouts. *arXiv preprint arXiv:1612.00215*.
57. Keefer, D. K., (2000), Statistical analysis of an earthquake-induced landslide distribution - the 1989 Loma Prieta, California event, *Engineering Geology*, Vol. 58, pp. 231-249.
58. Keefer, D.K. (1984). Landslides caused by earthquakes. *Geological Society of America Bulletin* 95(4): 406–421.

59. Koukis, G., Ziourkas, C. (1991). Slope Instability Phenomena in Greece: A Statistical Analysis. *Bulletin of the International Association of Engineering Geology*, 43, 47-60.
60. Lee, C. H. and Teng, C. C. 2000. Identification and control of dynamic systems using recurrent fuzzy neural networks. *IEEE Transactions on Fuzzy Systems*. vol. 8, no. 4, pp. 349-366.
61. Li, M., Wang, L., Yan, J., Zhang, H., Zhang, L., Zhang, L., 2018, The Study of Traffic Flow Information Completion Based on GAN Algorithm, Proceeding on IEEE Int. Conf. on Data Driven Control and Learning Systems.
62. L. Xiao, Y. Zhang, G. Peng, (2018). Landslide susceptibility assessment using integrated deep learning algorithm along the China-nepal highway. *Sensors*, 18 (12) (2018), p. 4436.
63. Lambe, T. W. and Whitman, R. V., (1979), Soil mechanics, Wiley, New York, pp. 553.
64. Lee, S. and Sambath, T., (2006), Landslide susceptibility mapping in the Damrei Romel area, Cambodia using frequency ratio and logistic regression models, *Environmental Geology*, Vol. 50, pp. 847-855.
65. Lei, T. C., Wan, S., Chou, T. Y., and Pai, H. C., (2011). The Knowledge Expression on Debris Flow Potential Analysis through PCA+LDA and Rough Sets Theory- A Case Study of Chen-Yu-Lan Watershed, Nantou, Taiwan. *Environmental Earth Sciences*, Vol. 63(5), pp. 981-997.
66. Lei, T.C., Huang, Y.M., Lee, B.J., Hsieh, M.H. and Lin, K.T., (2014). Development of an empirical model for rainfall-induced hillside vulnerability assessment: a case study on Chen-Yu-Lan Watershed, Nantou, Taiwan, *Natural Hazards*. 74, 341-373. (SCI/IF= 1.639 /Ranking=73/172=42%)
67. Liu, X., Yue, Z.Q., Tham, L.G. and Lee, C.F., (2002), Empirical assessment of debris flow risk on a regional scale in Yunnan Province, southwestern China, *Environmental Management*, Vol. 30(2), pp. 249–264.
68. Lun-Wei Wei, Chuen-Ming Huang, Hongey Chen, Chyi-Tyi Lee, Chun-Chi Chi, and Chen-Lung Chiu. 2018. Adopting the I3-R24 rainfall index and landslide susceptibility for the establishment of an early warning model for rainfall-induced shallow landslides. *Nat. Hazards Earth Syst. Sci.* 18, 1717–1733, <https://doi.org/10.5194/nhess-18-1717-2018>.
69. Muhammad Mukhlisin, Siti Jahara Matlan, Mohamad Jaykhan Ahlan, Mohd Raihan Taha. 2014. Analysis of Rainfall Effect to Slope Stability in Ulu Klang, Malaysia. *Jurnal Teknologi*. 72:3(2015) 15–21.
70. Montoya-Domínguez, J. D., García-Aristizábal, E. F. & Vega-Posada, C. A. 2016. Effect of rainfall infiltration on the hydraulic response and failure mechanisms of sandy slope models. *Revista Facultad de Ingeniería*. 25 (43), 97-109. DOI: 10.19053/01211129.v25.n43.2016.5302
71. MAO, Xudong; LI, Qing; XIE, Haoran. (2017). Aligngan: Learning to align cross-domain images with conditional generative adversarial networks. *arXiv preprint arXiv:1707.01400*.
72. Mezaal M.R., Pradhan B., Sameen M.I., Mohd Shafri H.Z., Yusoff Z.M. (2017). Optimized Neural Architecture for Automatic Landslide Detection from High-Resolution Airborne Laser Scanning Data. *Appl. Sci.* 2017;7:730. doi: 10.3390/app7070730.
73. Mohammad, Y., MaTsumoto, K., and Hoashi, K. 2018. Deep feature learning and selection for activity recognition. *Proceedings on Annual ACM Symposium on Applied Computing*, 2018.

74. Montgomery, D. R., and W. E. Dietrich. (1994), A physically-based model for the topographic control on shallow landsliding. *Water Resource Research* 30 (4): 1153-71.
75. Nel Caine. (1980). The Rainfall Intensity - Duration Control of Shallow Landslides and Debris Flows. *Geografiska Annaler: Series A, Physical Geography*, Volume 62, P23-27.
76. Newmark, N. M., (1965), Effects of earthquakes on dams and embankments, *Geotechnique*, Vol. 15, pp. 139-160.
77. Nguyen, K. T., Dinh, D. T., Do, M. N. and Tran, M. T., 2020, Anomaly Detection in Traffic Surveillance Videos with GAN-based Future Frame Prediction, *Proceedings on Int. Conf. on Multimedia Retrieval*, pp. 457-463.
78. Odena, A., Olah, C., & Shlens, J. (2017, August). Conditional image synthesis with auxiliary classifier gans. In *Proceedings of the 34th International Conference on Machine Learning-Volume 70* (pp. 2642-2651). JMLR. Org.
79. O'Loughlin, E. M. (1986), Prediction of surface saturation zone in natural catchments by topographic analysis. *Water Resources Research* 22 (5): 794-804.
80. Osanai, N., T. Shimizu, K. Kuramoto, S. Kojima, and T. Noro. 2010. Japanese early-warning for debris flows and slope failures using rainfall indices with Radial Basis Function Network. *Landslides*.7: 1–14.doi:10.1007/s10346-010-0229-5.
81. Pradel, D. & Raad, G. 1993. Effect of Permeability on Surficial Stability of Homogeneous Slopes. *Journal of Geotechnical Engineering, ASCE*. 119(2): 315–332.
82. Panizzo, A., Bellotti, G. and Girolamo, P. D., (2002), Application of wavelet transform analysis to landslide generated waves, *Coastal Engineering*, Vol. 44(4), pp. 321–338.
83. Pareschia, M. T., Santacroce, R., Sulpizio, R. and Zanchetta, G., (2002), Volcaniclastic debris flows in the Clanio Valley (Campania, Italy): insights for the assessment of hazard potential, *Geomorphol*, Vol. 43, pp. 3-4.
84. Polemio, M. and Sdao, F., (1999), The role of rainfall in the landslide hazard: the case of the Avigliano urban area (Southern Apennines, Italy), *Engineering Geology*, Vol. 53(3-4), pp. 297-309.
85. Pradhan, B. and Lee, S., (2009b), Delineation of landslide hazard areas on Penang Island, Malaysia, by using frequency ratio, logistic regression, and artificial neural network models, *Environmental Earth Science* Vol. 60(5), pp. 1037-1054.
86. Pradhan, B., (2011), Use of GIS-based fuzzy logic relations and its cross application to produce landslide susceptibility maps in three test areas in Malaysia, *Environmental earth sciences*, Vol. 63 (2), pp. 329-349.
87. Reed, S. E., Akata, Z., Mohan, S., Tenka, S., Schiele, B., & Lee, H. (2016). Learning what and where to draw. In *Advances in Neural Information Processing Systems* (pp. 217-225).
88. Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. Lecture Notes in Computer Science(), vol 9351. Springer, Cham.
89. Rupke, J., Cammeraat, E., Seijmonsbergen, A. C. and Van, W. C. J., (1988), Engineering geomorphology of the widentobel catchment, appenzell and sankt gallen, switzerland. A geomorphological inventory system applied to geotechnical appraisal of slope stability, *Engineering Geology*, Vol. 26(1), pp. 33-68.
90. Rahardjo, H., Li X. W., Toll D. G. and Leong E. C. 2001. The Effect of Antecedent Rainfall on Slope Stability. *J. Geotech and Geological Eng. Netherlands*.19:371-399.

91. Szegedy, Christian, et al. "Rethinking the inception architecture for computer vision." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
92. Santacana, N., De P. A., Baeza, B., Corominas, J. and Marturi, J., (2003), A GIS based multivariate statistical analysis for shallow landslide susceptibility mapping in La poblada de Lillet area (Eastern Pyrenees, Spain). *Natural Hazards*, Vol. 30, pp. 281-295.
93. Stevenson, P.C., (1977), An empirical method for the evaluation of relative landslide risk, *Bulletin of the International Association of Engineering Geology*, Vol. 16, pp. 69–72.
94. Sani, S., Wiratunga, N., Massie, S. 2017. Learning deep features for knn based human activity recognition. *Proceedings of the International Conference on Case-Based Reasoning Workshops*, pp. 95-103.
95. Trigo R. M., Ze`zere J.L., Rodriguez M.L., Trigo I.F. 2005. The influence of the north Atlantic oscillation on rainfall triggering of landslides near Lisbon. *Nat Hazards* 36:331–353.
96. Tsaparas, I., Rahardjo, H., Toll, D.G., and Leong, E.C. 2002. Controlling parameters for rainfall-induced landslides. *Comput. Geotech.* 29: 1–27.
97. Tsaparas, I., Rahardjo, H., Toll, D.G. and Leong E.C. 2003. Infiltration Characteristics of Two Instrumented Residual Soil Slopes. *Can. Geotech J.* 40: 1012–1032.
98. T. Schlegl, P. Seeböck, S.M. Waldstein, U. Schmidt-Erfurth, G. Langs. (2017). Unsupervised anomaly detection with generative adversarial networks to guide marker discovery. *International Conference on Information Processing in Medical Imaging*, Springer (2017), pp. 146-157
99. Tan, W. R., Chan, C. S., Aguirre, H. E., & Tanaka, K. (2017). ArtGAN: Artwork synthesis with conditional categorical GANs. In 2017 IEEE International Conference on Image Processing (ICIP) (pp. 3760-3764). IEEE.
100. Takahashi, S., Chen, Y. and Tanaka-Ishii, K., 2019, Modeling financial time-series with generative adversarial networks, *Physica A: Statistical Mechanics and its Applications*, vol. 527, Article 121261.
101. Tibaldi, A., (1995), Morphology of pyroclastic cones and tectonics. *Journal of Geophysical Research*, v. 100, no. B12, p.24521-24535, doi:10.1029/95JB02250.
102. Varnes, D.J., (1984) *Landslide Hazard Zonation: A review of Principles and Practice*, UNESCO Press, Paris, pp.63.
103. Wieczorek, G., and T. Glade.2005. Climatic factors influencing occurrence of debris flows. Jakob, M. and Hunger, O., Eds. *Debris-flow Hazards and Related Phenomena*. 325–362.
104. Wan, S., Lei, T.C., and Chou, T.Y., (2010), A Novel Data Mining Technique of Analysis and Classification for Landslide Problems. *Natural Hazards*, 52, 211–230.
105. Wan, S., Lei, T.C., and Chou, T.Y., (2012), A landslide expert system: image classification through integration of data mining approaches for multicategory analysis. *International Journal of Geographical Information Science*, 26, 747-770.
106. Wang, H. B. and Sassa, K., (2005), Comparative evaluation of landslides susceptibility in Minamata area, Japan, *Environmental Geology*, Vol. 47, pp. 956-966.
107. Wieczorek, G. F. 1987. Effect of rainfall intensity and duration on debris flows in Central Santa Cruz Mountains, California. *Geological Society of America Reviews in Engineering Geology* 7: 93-104.
108. Wu, Q., Wang, P., Shen, C., Reid, I., & van den Hengel, A. (2018). Are you talking to me? reasoned visual dialog generation through adversarial learning. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 6106-6115).

109. Xiao, J., and A. Moody. 2004b. Photosynthetic activity of US biomes: responses to the spatial variability and seasonality of precipitation and temperature. *Global Change Biology* 10:437–451.
110. Xu, D., Wei, C., Peng, P., Xuan, Q., Guo, H., 2020, GE-GAN: A novel deep learning framework for road traffic state estimation, *Transportation Research Part C: Emerging Technologies*, vol. 117, Article 102635.
111. Yesilnacar, E. and Topal, T., (2005), Landslide susceptibility mapping: a comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey), *Engineering Geology*, Vol. 79, pp. 251-266.
112. Yin K. L. and Yan, T. Z., (1988), Statistical prediction models for slope instability of metamorphosed rocks, *Proceedings of the International Symposium on Landslides*, Vol. 5, pp. 1269-1272.