
**利用圖像式深度學習開發滑坡大規模崩塌
災害特徵辨識系統之研究 II**
**Application of deep learning techniques to
large-scale landslide identification based
on images II**
(期末報告)

執行單位：國立臺灣科技大學營建系

執行期間：112 年 2 月 8 日至 112 年 12 月 31 日

計畫主持人：李安歡 教授

行政院農業委員會水土保持局 編印

中華民國 112 年 12 月



利用圖像式深度學習開發滑坡大規模崩塌災害特徵

辨識系統之研究 II

摘要

在城市化和資源開發需求不斷增長的時代，人們日益關注不穩定的氣候條件，將環境安全問題置於首要考量之中。隨著全球人口逐漸增加，越來越多的地質環境受到干擾。在這樣的情況下，自然災害對人類生命和財產安全的威脅愈發凸顯，而不同的自然災害造成各種不同形式的破壞，但更危險的是，它們常常結合產生連鎖效應。當這些災害相互堆疊形成複合型災害時，單一解決方法或理論將難以應對。

雖然台灣水土保持局已經制定了坡地保育等相關規定，但由於台灣地質相對年輕且地形陡峭，仍有可能發生無法控制的大規模崩塌，帶來災害和財產損失。坡地監測與預警系統面臨的挑戰在於監測位置並非一定能準確設置於滑動面上，因此無法收集足夠的訊號以實現預警效果。因此，本計畫接續第一年度，將加入更多圖層(安全係數圖層)以及增加數據庫，運用深度學習方法，提供更有效的辨識特徵。透過模型改進與增加特定模塊，提升深度學習訓練後的精準度，以提供更有效的災害預防和應對措施。預計將來可利用辨識後影響範圍等資訊，可進一步規劃坡地防護，將災害風險降至最低。

關鍵詞：滑坡、人工智慧、影像辨識、手機應用程式、安全係數

Application of deep learning techniques to large-scale landslide identification based on images II

Abstract

In an era of increasing urbanization and resource development demands, people are becoming more concerned about unstable climate conditions and prioritizing environmental safety issues. With the global population gradually increasing, a growing number of geological environments are being disturbed. In such circumstances, the threat of natural disasters to human life and property safety becomes more pronounced, and different types of natural disasters cause various forms of destruction. However, what is even more dangerous is that they often combine to create cascading effects. When these disasters stack up to form compound disasters, a single solution or theory becomes inadequate to cope with the situation.

Although the Soil and Water Conservation Bureau in Taiwan has already established regulations regarding slope conservation, the relatively young geology and steep terrain of Taiwan still pose the risk of uncontrollable large-scale landslides, leading to disasters and property losses. The challenges faced by slope monitoring and warning systems lie in the fact that monitoring locations cannot always be accurately placed on the sliding surface, making it difficult to collect sufficient signals to achieve effective early warning. Therefore, building upon the first year's work, this project will incorporate additional layers (safety coefficient layers) and expand the database, utilizing deep learning methods to provide more effective recognition features. By improving and adding

specific modules to the model, the accuracy of deep learning training can be enhanced, thereby offering more effective disaster prevention and response measures. In the future, it is expected that information such as the recognized impact range can be utilized for further slope protection planning, minimizing disaster risks.



Keywords: Landslide 、 Artificial intelligence 、 Image identification 、
Mobile App 、 Safety Factor

目次

摘要.....	I
Application of deep learning techniques to large-scale landslide identification based on images II.....	II
Abstract.....	II
目次.....	IV
表次.....	VI
圖次.....	VII
第一章 緒論	1
第一節 山體崩塌前後之地形特性	1
第二節 計畫主要目標	4
第二章 工作執行方法與步驟	1
第一節 深度學習技術遴選評估	1
第二節 文獻蒐集	5
第三節 現地調查以及試驗	11
第四節 圖資蒐集工作初步成果	31
第五節 圖資處理及模型訓練	37
第三章 工作進度與交付項目	1
第一節 預定進度與目前進度	1
第二節 計畫後續執行要點	3
第三節 上期期初計畫審查意見問題與回覆	4
第四節 上期期中計畫審查意見問題與回覆	6
第五節 上期期末計畫審查意見問題與回覆	15
第六節 期初計畫審查意見問題與回覆	1
第七節 期中計畫審查意見問題與回覆	2

第八節 期末計畫審查意見問題與回覆	6
第四章 結論及建議	10
第一節 結論	10
參考文獻.....	1



表次

表(1-1) 邊坡崩塌類型(楊樹榮, 2011)	2
表(3-1) 預定進度表.....	1
表(3-2) SENTINEL-2 主要波段及其對主要岩性吸收反射 特徵	3



圖次

圖(1-1) 岩石邊坡之破壞形式 (HOEK & BRAY, 2005)	3
圖(1-2) 滑坡檢測之深度學習模型	4
圖(2-1) 實例分割示意圖	2
圖(2-2) 語義分割示意圖	2
圖(2-3) 卷積神經網路(CNN)架構流程圖	5
圖(2-4) FCN 架構流程圖	6
圖(2-5) U-NET 架構流程圖	7
圖(2-6) CBAM 注意力模塊(WOO ET AL. 2018)	8
圖(2-7) SPP 空間金字塔池化層 (HE ET AL. 2015)	9
圖(2-8) 模型架構示意圖	10
圖(2-9) 阿里山青年活動中心聯外道路崩塌位置示意圖	12
圖(2-10) 阿里山青年活動中心聯外道路崩塌案	13
圖(2-11) 灰色砂岩及頁岩互層為主的崩積層土壤	13
圖(2-12) 崩塌潛勢之位置示意圖	14
圖(2-13) 大崙山聯外道路崩塌案	15
圖(2-14) 頁岩互層為主的黃壤	16
圖(2-15) 草湖溪黃竹里崩塌地位置示意圖	17
圖(2-16) 黃竹里崩塌地砂頁岩互層	18
圖(2-17) 集集隧道崩塌位置示意圖	19
圖(2-18) 集集隧道崩塌地邊坡整治	20
圖(2-19) 依各篩號土壤分類保存	21
圖(2-20) 製作試體	22
圖(2-21) 設置各項測量儀器於剪力儀	23
圖(2-22) 剪動速率為 1.5MM/MIN	23

圖(2-23) 阿里山地區直剪試驗剪應力-剪變形曲線.....	25
圖(2-24) 阿里山地區直剪試驗破壞包絡線	26
圖(2-25) 阿里山地區三軸試驗莫爾圓	26
圖(2-26) 大崙山直剪試驗剪應力-剪變形曲線.....	27
圖(2-27) 大崙山直剪試驗破壞包絡線	27
圖(2-28) 大崙山三軸試驗莫爾圓.....	28
圖(2-29) 黃竹里崩塌地直剪試驗剪應力-剪變形曲線.....	28
圖(2-30) 黃竹里崩塌地直剪試驗破壞包絡線	29
圖(2-31) 黃竹里崩塌地三軸試驗莫爾圓	29
圖(2-32) 集集鐵路隧道崩塌地直剪試驗剪應力-剪變形 曲線	30
圖(2-33) 集集鐵路隧道崩塌地直剪試驗破壞包絡線	30
圖(2-34) 集集鐵路隧道崩塌地三軸試驗莫爾圓	31
圖(2-35) ARCGIS 與 PYTHON 之應用介面	33
圖(2-36) CS 地圖圈繪示意圖	34
圖(2-37) HOST 地圖圈繪示意圖.....	35
圖(2-38) 衛星圖圈繪示意圖.....	35
圖(2-39) 水文圖層.....	36
圖(2-40) 等高線圖.....	36
圖(2-41) 地下水位及坡高示意圖.....	38
圖(2-42) 阿里山地區 APP 工具計算安全係數之結果.....	40
圖(2-43) 大崙山 APP 工具計算安全係數之結果.....	40
圖(2-44) 黃竹里崩塌地 APP 工具計算安全係數之結果.....	41
圖(2-45) 集集鐵路隧道崩塌地 APP 工具計算安全係數 之結果	41

圖(2-46) 安全係數圖層示意圖.....	42
圖(2-47) AUTOGIS 使用界面	43
圖(2-48) AUTOGIS 得出的標註圖.....	44
圖(2-49) 衛星圖會因拍攝時間不同而使用拼裝	46
圖(2-50) 衛星圖拍攝當下多雲而無法顯示地貌	46
圖(2-51) CS 5 M 地圖瑕疵	47
圖(2-52) 集集鐵路隧道崩塌地 AI 模型預測	47
圖(2-53) 集集鐵路隧道崩塌地安全係數圖層	48
圖(2-54) 阿里山山區 AI 模型預測	49
圖(2-55) 阿里山山區安全係數圖層	49
圖(2-56) 草湖溪崩塌地滑坡圈繪區域與安全係數圖層 比較	50
圖(2-57) 草湖溪崩塌地位置圖.....	51
圖(2-58) 石碇山區滑坡圈繪區域與安全係數圖層比較	52
圖(2-59) 石碇大崙山山區位置圖.....	52
圖(2-60) 訓練及驗證損失圖.....	53
圖(2-61) 拿掉高程資料之模型預測與實際滑坡比較	54
圖(2-62) 拿掉高程資料之模型訓練、驗證損失圖	55
圖(2-63) 拿掉衛星資料之模型預測與實際滑坡比較	56
圖(2-64) 拿掉衛星資料之模型訓練、驗證損失圖	56
圖(2-65) 拿掉水文資料之模型預測與實際滑坡比較	57
圖(2-66) 拿掉水文資料之模型訓練、驗證損失圖	57
圖(2-67) CS、HOST 5 M 地圖模型訓練、驗證損失圖	59
圖(2-68) CS、HOST 5 M 地圖模型預測與實際滑坡比較	59
圖(3-1) 研究流程圖.....	2

圖(3-2) 現地調查與室內試驗流程圖	2
圖(3-3) 本年度使用之輸入圖層差異	3
圖(3-4) 訓練以及驗證損失圖.....	7
圖(3-5) AI 模型測到與實際滑坡部分	8
圖(3-6) 本計畫期中報告前之流程圖	9
圖(3-7) 模型架構示意圖.....	13
圖(3-8) 本計畫分類資料過程.....	7
圖(3-9) 新竹梅花部落 AI 模型預測	8



第一章 緒論

第一節 山體崩塌前後之地形特性

在大地工程領域中，山體崩塌主要發生在邊坡的區域，大多數的邊坡不外乎是由土壤或岩石這兩種材料所組成[2]，本節中將先了解土壤及岩石邊坡的破壞形式及破壞後產生的地形特性，地形特性是在利用圖像式深度學習訓練中必要的一項重要特徵。

土壤邊坡

表(1-1)為根據中央地質調查所對於山崩的分類[1]。表中各材料的定義為，岩石為完整的塊狀(intact rock)，而工程土壤中的岩屑及土差別為，當組成邊坡的材料中有超過 80 % 的粒徑小於 2 mm 時，則歸類為土；反之則歸為岩屑。而材料的運動型態定義如下：

- 墜落：當邊坡上的材料以自由落體、彈跳或是滾動的方式向下運動
- 傾覆：指邊坡上的土石或岩塊重心超過塊體基部時，因自重產生力矩，使塊體向下驅動。
- 滑動：指材料沿著某一平面以剪切的方式移動，分為弧形及平面滑動，通常發生在坡度較緩的邊坡。
- 流動：當材料在空間中持續的移動，且速度可達每秒數公分至數百公尺，其行為如塑性流體一般。

運動型態		材料種類	
		岩石	工程土壤
			岩屑
墜落		落石	岩屑崩滑
傾覆			
滑動	圓弧形	岩體滑動	
	平面型		
流動		土石流	

表(1-1) 邊坡崩塌類型(楊樹榮 et al., 2011)

岩石邊坡


一般岩石邊坡破壞機制根據其破壞形式分為四種(1)平面滑動；(2)楔型滑動；(3)翻倒破壞；(4)圓弧滑動又說明如下及圖(1-1)所示：

(一) 平面滑動：常發生在地質不連續的情況，像是弱面與邊坡的傾向一致或是邊坡之坡角大於摩擦角，又滑動面與平面故稱為平面滑動，圖(1-1a)。

(二) 楔型滑動：當岩體被兩組弱面切割成楔形塊且兩弱面之交線在邊坡上出露，則當該楔形塊沿著此交線滑動，圖(1-1b)。

(三) 圓弧形滑動：當岩坡之弱面與邊坡的傾向相反，則其會呈翻倒墜落，產生有如落石掉落之情形，圖(1-1c)。

(四) 翻倒破壞：當其邊坡材料為非常脆弱，如高度破碎之岩體或無明顯弱面的軟岩(如泥岩)，其滑動面會有圓弧狀，圖(1-1d)。




圖(1-1) 岩石邊坡之破壞形式 (Hoek & Bray, 2005)



第二節 計畫主要目標

開發可用影像進行潛在崩塌地自動辨識的深度學習技術，利用 CS 地圖及 HOST 圖判釋出地形特徵，且能直觀的用地理參數資訊表示其特徵，再以較低成本數據資源結合本團隊開發之 AI 邊坡安全評估[5][6]手機 App 工具，進而完成邊坡破壞形式預測系統，提供使用者準確，經濟且迅速的參考依據，同時提供邊坡或潛在崩塌地檢查、預警和其他相關工程的後續應用。而本年度計畫目標如下：

- 一、改善檢測滑坡之影像辨識深度學習模型，如圖(1-2)
- 二、用於深度學習之邊坡數據收集及圖資預處理
- 三、深度學習訓練結果分析及模型評估輔以實際案例驗證其適用性



圖(1-2) 滑坡檢測之深度學習模型

第二章 工作執行方法與步驟


第一節 深度學習技術遴選評估

深度學習是人工智慧的一部份，也是機器學習的分支，利用此法能處理及計算大量的資料，深度學習也為數據科學中重要的一項因子，包含統計及預測模型。過去在處理電腦影像時利用深度學習都能得到不錯的結果，其應用範圍像是物件辨識、人臉辨識、行為辨識、圖像檢索、語義分割等(Voulodimos et al. 2018)。

在深度學習領域當中[11]，對於影像辨識技術有幾種是現今較為成熟的分別為圖像分類(Image Classification)、物件偵測(Object Detection)、實例分割(Instance Segmentation)、語義分割(Semantic Segmentation)，然而在自動滑坡的檢測上，最重要的是檢測何處為地質敏感脆弱且易崩塌區域，必須要精準圈繪出來，因此後兩者技術上較符合此次計畫需要的結果。以下為實例分割(Instance Segmentation)[7]、語義分割(Semantic Segmentation)的介紹：

一、實例分割(Instance Segmentation):

實例分割除了要進行像素級別的分類，還需要將不同的實例(對像或者物體)區分開來。實例分割可以識別並分割圖像中的多個實體，並為每個實例分配一個唯一的標識，而常用到的算法有包括Mask R-CNN、YOLO-V7等。使用實例分割的輸出結果可參考下圖(2-1):



圖(2-1) 實例分割示意圖

二、語義分割(Semantic Segmentation)

語義分割的目標是將圖像分割成不同的語義區域，每個像素被賦予一個類別標籤，表示其所屬的對象或者物體類別。語義分割只關注像素級別的分類，不考慮不同實例之間的區分，而常用到的算法包括 U-Net、SegNet 等。使用語義分割的輸出結果可參考下圖

(2-2):



圖(2-2) 語義分割示意圖

深度學習技術背景

目前，有多種軟體開發平台可供選擇，用於建立人工智慧演算法。在本計畫中我們使用免費的 Python 編程軟體作為開發平台。Python 具有許多內建的深度學習模組，適合研究人員進行分析、規劃、程式設計和測試等工作。它廣泛應用於資料分析、數值計算和演算法開發等領域。

本研究使用的 Python 版本為 3.9.7，運行於 Windows 10 環境中。Python 是由 Guido van Rossum 於 1991 年創建的程式語言，近年來受到廣泛關注，成為熱門的程式語言之一。Python 的程式碼簡潔易懂，且功能強大。除了官方提供的標準程式庫外，由於其高度相容性，Python 還累積了大量非官方的程式庫和插件，這使得開發人員能夠方便地擴充功能。Python 還具有跨平台的特性，在 Linux 和 Windows 等作業系統上都可以運行，方便開發者的使用。

在 Python 中，Keras 和 TensorFlow 是基於 Python 開發的開源深度學習程式庫。它們提供了簡單易用的介面，用戶可以通過調整層數和參數來訓練深度學習模型進行分析。

監督式學習

機器學習中一種常見且重要的學習方式，在監督式學習中，我們有一組帶有標籤(Label)的訓練資料(標籤是指預期的輸出或結果)。這些資料被視為已知的範例，並且機器學習模型的目標是學習如何從輸入資料中預測或推斷出對應的標籤。這種學習方式的目標是根據過去的經驗來學習預測未來或新的輸入。


在監督式學習中，我們將訓練資料分為特徵(Features)、標籤(Labels)兩個部分。特徵是輸入資料的屬性或描述，而標籤則是我們希望模型預測或推斷出的結果。其核心思想是通過將輸入資料與對應的標籤相關聯，建立一個函數或模型，使其能夠將新的輸入映射到正確的標籤。這種模型通常被表示為一個假設函數(Hypothesis Function)，它將輸入特徵映射到相應的輸出標籤。機器學習的目標是找到一個最佳的假設函數，以最大程度地減少模型的預測誤差。



第二節 文獻蒐集

影像辨識是深度學習中的一部份，係以電腦分析或辨識影像中的特徵，輸出的結果即為將其標示出來，而要達到此目的，需要大量的數據資料並以神經網路來訓練它。如第二章第一節-深度學習技術遴選評估，上面有提到監督式學習的部分，而本計畫亦是採用監督式學習因此在做模型訓練時，除了需要大量的資料集，還要各資料集的標籤，如此一來才能供電腦進行學習，以分析出更好的結果。


物體偵測通常利用深度學習的演算法產生需要的結果，其中卷積神經網路(CNN)是深度學習中最重要的一部份[12]，其架構主要分成三個部分：卷積層 (Convolution layer)、池化層 (Pooling layer) 以及最後一個全連接層 (Fully Connected layer)，下圖(2-3)為卷積神經網路(CNN)架構流程圖，而大多影像辨識的模型也都是以 CNN 的架構為基礎去做延伸。



圖(2-3) 卷積神經網路(CNN)架構流程圖

由第二章第一節-深度學習技術遴選評估，裡面有提到在此次計畫自動滑坡檢測的部分，以實例分割(Instance Segmentation)、語義分割(Semantic Segmentation)技術較適合分析。由於要偵測的項目只有滑坡區域而已，在分類上只有一個種類(class)，不太需要分離不同的實例，因此在實例分割上較沒有優勢存在，反而語義分割因為只需要對各像素進行分類(是否為滑坡)，在運行時間上將會快上許多。


FCN (Fully Convolutional Networks for Semantic Segmentation)為深度學習在影像分割奠定很重要的基礎，在此之前深度學習一般用在分類和檢測問題上。FCN 的主要思想就是將全連接層替換為卷積層，並且可輸入任意尺寸的影像，輸出會得到每個像素所屬的類別 dense prediction，如此一來可以將其應用於 Semantic Segmentation 任務上，同時實現了 end-to-end 訓練。



圖(2-4) FCN 架構流程圖


U-Net 是語義分割中最具有代表性的架構，原先是為生物醫學圖像分割開發的卷積神經網絡。其主要思想是通過連續的層來補充通常的收縮網絡，其中的匯集作業(Pooling Operation)代為升採樣操作。這些層成功增加了輸出的解析度。接著，一個連續的卷積層可以根據這些信息，組合成一個精確的輸出。另外，還有一個重要改變是，升採樣部分有大量特徵通道，這使得網絡可以將上下文信息傳播到更高的解析度層。因此，擴展路徑或多或少地同收縮部分對稱，並產生一個 U 形網路，故稱 U-Net。

U-NET 與傳統 FCN[9]的不同點為利用 ResNet 模塊，將淺層與深層的特徵(Feature)進行連接(Concatenate)，並以淺層資料更具有整體 Semantic 的 Feature 為概念，漸進式連接，U-Net 的架構流程圖如圖(2-5)所示：



圖(2-5) U-NET 架構流程圖


注意力模塊 CBAM(Convolutional Block Attention Module-CBAM) (Woo et al. 2018)結合空間和通道的注意力機制，通道注意力機制利用平均池化及最大池化，在空間維度上做壓縮，關注影像上重要的特徵，至於空間注意力機制是對通道做均池化及最大池化，即對通道做壓縮，最後加權得到能凸顯有效特徵之影像，並針對相對重要通道特徵給予權重，如圖(2-6)所示。



圖(2-6) CBAM 注意力模塊(Woo et al. 2018)




SPP (Spatial Pyramid Pooling-SPP) 空間金字塔池化層(He et al. 2015)架構流層如圖(2-7)所示，可接受不同圖片尺寸輸入，且輸出相同尺寸的特徵圖，因此可靈活對神經網路輸入尺寸，也避免影像在改變大小時丟失一些重要信息，加入更深層的神經網路後池化效果會更明顯，在模型應用上可加到需固定尺寸輸入全連接層之前來銜接。



圖(2-7) SPP 空間金字塔池化層 (He et al. 2015)

本計畫分析工具是採用 U-Net 作為架構之骨幹，以此來設計新的模型。以 U-Net 模型架構為核心，將淺層與深層的特徵結合，減少深層神經網路丟失淺層特徵的問題，接著在輸入與輸出層增加通道數，增進山崩與地滑敏感區特徵，並與實際況相符。

接著加入以上提到的 CBAM 模塊和 SPP，提高卷積神經網路表現能力，在不影響特徵輸入的維度下，更注重於重要特徵抑制不必要特徵，在圖像上表示相當於輸入數層的通道中，不同通道的資訊特徵給予相對應權重，符合現階段圖資的表徵，整個深度學習訓練過程如圖(2-8)，最後會得到背景與預測結果共兩通道的圖層。



圖(2-8) 模型架構示意圖

第三節 現地調查以及試驗

一、取樣

本研究將至現地調查台灣地區之邊坡，模擬邊坡檢查中，如何真實使用本計畫之 APP 技術。另外根據已知與假設條件可提供影像判釋之潛在破壞邊坡與臨界值(安全係數為 1 時)之差距，現地調查主要想取得地質強度參數及地形參數供 APP 工具使用。以其計畫成果可用於辨識後做安全性評估與驗證使用。同時對邊坡之坡高與坡角進行量測並取回現場土樣帶回實驗室進行試驗。


本計畫於上一年度已執行嘉義地區以及石碇山區邊坡現場調查工作，而今年度則是到台中山區進行，以下將統整各行程之結果。

(一) 出發前準備工作

上一年度調查已前往嘉義阿里山地區以及台北石碇山區進行邊坡調查，今年度則是到台中山區進行，然而該地區邊坡數量眾多，為有效掌握本計畫主要研究對象「潛在崩塌」，先行比對經濟部中央地質調查所於民國 103 年公布的全台山崩與地滑地質敏感區，再透過 Google 街景圖逐一過濾其地點，挑選合適對象。根據調查該地區受 88 風災影響近年來地質相對敏感產生許多邊坡滑動的案例將於行程中一併納入考量。

(二) 現勘調查及現地土樣取得-阿里山

此次之目標邊坡為一鄰近於阿里山青年活動中心的崩塌案例，如圖(2-10)所示，據附近居民所及該邊坡於 2021 年 8 月颱風期間產生大面積的崩塌造成道路中斷。本次調查將透過測距儀量測邊坡之坡高與坡角，將以單元邊坡之概念進行量測，實測結果為坡高 17 米及坡角 33° - 34° ，由於該地位處交通要道，邊坡已進行初步整治故其安全係數大於 1，上述之阿里山地區之地質敏感區因多數已進行發包施工，故未對其進行調查。



圖(2-9) 阿里山青年活動中心聯外道路崩塌位置示意圖



圖(2-10) 阿里山青年活動中心聯外道路崩塌案


由下圖(2-11)可見該地區土壤屬於灰色砂岩及頁岩互層為主的崩積層，由現場觀察中可見，此類土壤多為經過地層活動過後之剪裂帶碎屑，滲透性高的特性在經過山區大雨過後易產生崩塌。本計畫將針對此區土壤性質進行一般物性及力學試驗，已充分掌握應用於安全性驗證所需之參數。



圖(2-11) 灰色砂岩及頁岩互層為主的崩積層土壤

(三) 現勘調查及現地土樣取得-大崙山

此次另一個目標邊坡為大崙山(石碇山區)的案例，108 年 8 月水土保持局公布大規模崩塌潛勢資訊，新北市石碇區大崙山為大規模崩塌潛勢區，如圖(2-12)，東北側有一條中潛勢土石流潛勢溪流，西側與南側屬於高潛勢滑動區。該區為順向坡，過去曾發生小範圍之局部崩塌。



圖(2-12) 崩塌潛勢之位置示意圖



圖(2-13) 大崙山聯外道路崩塌案

由下圖(2-14)可見該地區土壤屬於砂岩及頁岩互層為主的黃壤，由現場觀察中可見，此類土壤多為偏軟，容易造成鬆動且滲透性高的特性在經過山區大雨過後易產生崩塌。本計畫也將針對此區土壤性質進行一般物性及力學試驗，並充分掌握應用於安全性驗證所需之參數。




圖(2-14) 頁岩互層為主的黃壤



(四) 現勘調查及現地土樣取得-草湖溪黃竹里崩塌地

於今年度本團隊將到台中山區草湖溪崩塌地進行現勘、取樣，此地往往年的颱風侵襲以及豪雨事件，造成崩塌地頭部至坡腹處部分處於裸露狀態，土砂堆積於坡趾佔據大部分河道，且上游河道左岸攻擊坡坡趾處部分既有護岸倒塌，河道亦遭土砂佔據導致縮減。



圖(2-15) 草湖溪黃竹里崩塌地位置示意圖

在草湖溪之岩性主要是以砂岩頁岩互層為主，且砂頁岩比例與砂岩單層厚度往上漸增，沈積物顆粒度也隨之變粗。砂岩呈淡青灰色或淡灰色，由細至粗粒的混濁砂岩所組成。砂岩的沉積構造主要以平行層理、低角度交錯層、圓丘狀交錯層理、波狀與壓扁狀構造為主，次生的沈積構造有崩移構造及荷重造成的球枕狀構造，本層生物擾動的現象頗為普遍，常破壞岩層中的原生沈積構造。

由於砂岩和頁岩的抗蝕力不等，且岩層為峭壁落石區，因此，容易造成鬆動且滲透性高的特性在經過山區大雨過後易產生崩塌，其現場拍攝圖(2-16)如下。



圖(2-16) 黃竹里崩塌地砂頁岩互層


(五) 現勘調查及現地土樣取得-集集鐵路崩塌地:

台鐵集集支線，於 2021 年 8 月因為邊坡坍方，導致隧道結構，遭土石擠壓變形，造成集集鐵路中斷，而 2022 年 6 月 3 日午後強降雨，使邊坡工區再度大規模崩塌。

本團隊前往此地進行現勘、取樣，根據經濟部地質調查及礦業管理中心所提供地質資料，本地為頭嵙山層，其主要是以砂岩、粉砂岩和頁岩所組成。

當地主要是淡色崩積土為主，而現場取土時也發現到若是先前經過大雨，會導致土壤偏軟，造成鬆動而容易產生崩塌。

本計畫也將針對此區土壤性質進行一般物性及力學試驗，並充分掌握應用於安全性驗證所需之參數。



圖(2-17) 集集隧道崩塌位置示意圖

如圖(2-17)可發現崩塌地剛好經過集集線鐵路隧道段，因此經過大雨產生崩塌。根據 108 年 8 月水土保持局公布大規模崩塌潛勢資訊，當地並非為崩塌潛勢區，但在大雨侵蝕下仍會發生岩屑崩滑，因此常常介於不穩定的狀態。本次調查將透過測距儀量測邊坡之坡高與坡角，實測結果為坡高 13 米及坡角 39° ，當地為交通要道且集集鐵路隧道經過，目前邊坡已整治維護，如圖(2-18)所示，因此其目前整治後安全係數已大於 1，但能需注意大雨後邊坡情形。



圖(2-18) 集集隧道崩塌地邊坡整治

二、一般物性及力學試驗

(一) 粒徑分佈試驗

利用現場取得土樣，於試驗室內進行粒徑分佈試驗，以求得該土樣之完整粒徑分佈狀況。

試驗方法：

- 1.將現地取回之土樣烘乾，初步敲碎取 1kg 左右之土樣。
- 2.將土樣倒入自#4 至#200 依序排列的篩組，以搖篩機搖篩 15 至 20 分鐘。
- 3.將各篩存留重依序紀錄，經百分比修正後將各篩停留重量合併計算，以求得各篩號存留百分比、累積存留百分比及累積通過百分比。

4.繪出該土樣之粒徑分析曲線。



圖(2-19) 依各篩號土壤分類保存

(二) 含水量試驗

利用現場取得之土樣，於試驗室內進行含水量試驗，以求得該土樣之現地自然含水量。

試驗方法：

- 1.取蒸發皿鋁杯、編號、量秤蒸發皿以及蒸發皿與土樣合計總重。
- 2.將試樣置入烘箱烘乾後將試驗放入乾燥器內冷卻至室溫。
- 3.量秤蒸發皿與乾土重後計算含水量。

(三) 直接剪力試驗


本試驗之目的為測現地試樣之抗剪強度(凝聚力及摩擦角)。本項試驗使用台科大土壤試驗室之剪力儀進行試驗，其最大水平剪力 5kN，試體尺寸於剪力盒中約為直徑 6cm×高 4.2cm。試驗時，正向力採用 1、2、4kg 其大小由面積換算，剪力採機械剪動方式，剪動速率為 1.5mm/min，在讀數期間由測

微錶測讀正向及剪向變形量，試驗至殘餘強度或剪力變形達20%即止。經過計算得其尖峰值剪應力與該組試驗之正向應力繪製迴歸線可得砂土凝聚力及摩擦角。試驗步驟依照美國材料和試驗協會(ASTM-D-3080)規定辦理。



圖(2-20) 製作試體





圖(2-21) 設置各項測量儀器於剪力儀



圖(2-22) 剪動速率為 1.5mm/min

(四) CIU 三軸壓縮強度試驗


在此試驗中，一般所之土壤試體直徑約 5 公分，高度為 10 公分。用薄橡皮膜包裹之試體置入特殊三軸室內後注滿水。經由容器內液體之壓縮對試體施加圍壓。要造成試體受剪破壞，求得土壤於飽和壓密不排水狀態下，承受不同圍壓時反映出之最大應力及對應超額孔隙水壓。利用此最大應力配合超額孔隙水壓及相對應圍壓大小繪出各階段總應力莫爾圓、有效應力莫爾圓及其破壞包絡線，並藉以求得其強度參數 c 、 ϕ 及 c' 、 ϕ' 值。藉由承受不同圍壓時所得應力-應變曲線中之最大應力值，配合相對應之超額孔隙水壓及圍壓大小繪出各階段總應力莫爾圓及有效應力莫爾圓，並以兩組莫爾圓之迴歸線為其總應力及有效應力破壞包絡線，則此二切線之截距及斜率即為其總應力凝聚力(c)及摩擦角(ϕ)和有效應力凝聚力(c')及有效摩擦角(ϕ')。



(五) 試驗結果


1. 阿里山地區

● 直剪試驗




圖(2-23) 阿里山地區直剪試驗剪應力-剪變形曲線

如圖(2-23)，採用 1、2、4 (kg/cm^2) 的正向應力來測其剪應力尖峰值，並將得到的尖峰值，並跟原先施加的正向應力作圖，可得此土壤的破壞包絡線，進而求其土壤參數 (c 、 Φ)，如下圖(2-24)，求出的 c 接近 0，而 $\phi = 38^\circ$ 。



圖(2-24) 阿里山地區直剪試驗破壞包絡線


● 三軸試驗




圖(2-25) 阿里山地區三軸試驗莫爾圓

2. 大崙山(石碇山區):

● 直剪試驗:




圖(2-26) 大崙山直剪試驗剪應力-剪變形曲線



圖(2-27) 大崙山直剪試驗破壞包絡線

圖(2-26)、(2-27)為大崙山(石碇山區)直剪試驗的結果，可得到其 c 接近於 0， $\phi = 41^\circ$


● 三軸試驗:




圖(2-28) 大崙山三軸試驗莫爾圓

3. 黃竹里崩塌地(台中山區):

● 直剪試驗:




圖(2-29) 黃竹里崩塌地直剪試驗剪應力-剪變形曲線



圖(2-30) 黃竹里崩塌地直剪試驗破壞包絡線

圖(2-29)、(2-30)為黃竹里崩塌地(台中山區)直剪試驗的結果，可得到其 c 接近於 0， $\phi = 42^\circ$ 。


●三軸試驗：




圖(2-31) 黃竹里崩塌地三軸試驗莫爾圓

4. 集集鐵路隧道崩塌地

● 直剪試驗：



圖(2-32) 集集鐵路隧道崩塌地直剪試驗剪應力-剪變形曲線




圖(2-33) 集集鐵路隧道崩塌地直剪試驗破壞包絡線

圖(2-32)、(2-33)為集集鐵路隧道崩塌地直剪試驗的結果，可得到其 c 接近於 0， $\phi = 34^\circ$

●三軸試驗：

莫爾圓破壞包絡線-集集鐵路



圖(2-34) 集集鐵路隧道崩塌地三軸試驗莫爾圓

第四節 圖資蒐集工作初步成果

本計畫主要是利用影像辨識來分辨是否為「已經崩塌」以及「高風險崩塌地」，並取用所提供的邊坡圖資中的作為訓練資料，利用深度學習技術將其特徵顯示，即可應用於找出「潛在崩塌」的圖像及對應區域[15]。


本計畫採用經濟部中央地質調查所於民國 103 年公布的全台山崩與地滑地質敏感區做為已崩及未崩區域之圈繪參考，該圖資將做為此計畫影像辨識的真實值(Ground Truth)，其可在 ArcGIS 商用軟體中開啟.shp 檔並初步以水保局全台 CS 地圖以及 HOST 地圖做為底圖進行套疊做深度學習技術開發用。

除此之外，本團隊考量多增加一些圖層，以盼在崩塌地區能有更多的特徵進行辨識，提升辨識之精準度。在有水保局提供之 CS 及 HOST 地圖做為底圖之後，參考水保局立體地形圖 HOST MAP 及 CS MAP 判釋參考指引[14]，內有提到崩塌判釋以光學影像最為適用，因此本團隊加入 ArcGIS 提供之衛星圖[13]做為輸入圖資之一進行實驗。同時也參考相關論文，提到繪製滑坡敏感圖，使用 11 種參數作為輸入圖資，因此本團隊增加論文中輸入重要的參數-水文條件、高程資料做為本計畫的輸入圖層資料。

而在本年度也將增加安全係數圖層做為參考比較，而安全係數在大地工程、邊坡穩定上是判斷當地安全性的重要因子，在安全係數的數據將是使用本團隊開發的 APP 計算而得，而此 APP 的方法以及介紹會在本章第五節-圖資處理及模型訓練裡詳細說明。

一、圖資應用軟體

ArcGIS 於 1997 年由 ESRI 公司開發，可將各種地理資訊模板化，可以將該系統視為一個繪製地圖與地理信息的基礎架構，並且可新增任何底圖，以便將各種地理資訊可視化於地圖上。ArcGIS 可選擇地圖後根據使用目的嵌入額外的工具，並內建人工智慧機器學習與開發者環境，可與本計畫中使用的 Python 建立之深度學習技術進行相互連結使用如下圖(2-35)。




圖(2-35) ArcGIS 與 Python 之應用介面


二、圖資蒐集與整合

本計畫已利用水保局提供 CS、HOST 地圖、衛星圖、等高線圖、水文圖以及山崩地滑地質敏感區已崩及未崩區域圈繪圖，共六種圖層做為訓練的圖資，並且將前五種圖層經過疊加後做為驗證的圖資，而最後一層疊加後則可當作崩塌地的真實值(Ground Truth)，即為下圖(2-36)~(2-38)黃色圈繪部分，可做為訓練集圖資進行模型訓練。


ArcGIS 為此研究中與深度學習技術在進行影像辨識及分割時所應用的 GIS 系統。本計畫訓練及驗證的各種圖資套疊在 ArcGIS 上，其結果如下圖(2-36)~(2-40)




圖(2-36) CS 地圖圈繪示意圖




圖(2-37) HOST 地圖圈繪示意圖



圖(2-38) 衛星圖圈繪示意圖



圖(2-39) 水文圖層



圖(2-40) 等高線圖

第五節 圖資處理及模型訓練


一、圖資處理

本計畫訓練模型使用之圖層於本章第三節已有提到，目前所進行的訓練以及驗證圖層使用 CS 地圖、HOST 地圖、等高線圖、水文圖、衛星圖[10]以及滑坡圈繪圖，而本年度計畫也已加入安全係數圖層，盼能提升辨識準確度。

安全係數圖層

安全係數是指一個結構或是物體所能負荷的負載可以超過預期負載的程度，在大地工程、邊坡穩定上是判斷當地安全性的重要因子，在此計畫當中，將使用的安全係數是在邊坡穩定範疇上，欲得出安全係數值，需使用數值分析軟體來獲得。

關於數值分析軟體之模型之設置，本計畫考慮地下水之影響，在 Mohr-Coulomb 破壞準則下設置 c 土壤凝聚力 (cohesion)、 ϕ 土壤摩擦角 (friction angle)、 γ 土壤單位重 (unit weight of soil)，幾何設置則如圖(2-41) 包含 β 坡角 (slope angle) 和 H 坡高 (slope high)， H_w/H 則表示地下水位。



圖(2-41) 地下水位及坡高示意圖


以上參數獲得後便可使用數值分析軟體[5][6]得出安全係數值，不同的參數進行分析，其結果也將會不同，並把分析的所有資料建立成一數據庫，此數據庫將做為 AI 模型的資料集，而本團隊使用之模型採用循環神經網路(Recurrent Neural Network, RNN)為基礎。

APP 是以人工智慧結合大數據(AI 模型)為基礎完成，本團隊將 AI 模型放入 APP 是為了方便攜帶使用，因此 APP 與 AI 模型是可以得到一樣的結果。AI 模型是用來判定所辨識出的潛在滑動面距離臨界狀況(FS=1)有多接近，然而此模型所製之圖層精準度會受到土壤強度參數與地形參數影響，因此需要現地調查與室內試驗作為輔助確認 AI 模型概估之 FS 是否合理。另外若是 APP 結合人為判斷能得到足以反映現調邊坡狀況的安全係數，將來可利用 APP 技術於現地調查時，協助初步判定量測邊坡之可能安全係數範圍與土壤參數的合理性。

關於現地勘查，本團隊以具滑動跡象之邊坡作為案例(共四處，分別位於阿里山地區、石碇地區以及本年度於台中山區與南投集集進行)，透過測距儀量測邊坡之坡高、坡角，以及直剪試驗求得之土壤凝聚力、土壤摩擦角，並於評估完地下水位後將上述參數輸入APP計算，計算後之安全係數如圖(2-42)。其中，阿里山地區之地下水位資訊為未知資訊，本團隊透過設定其地下水位 (H_w/H) 值為 0.5、0.6、0.7 計算結果，得到其安全係數接近 1，如圖(2-43)，顯示該邊坡在地下水位較高時，處於相對不穩定的狀態，因未能得知地下水位之實際情形，若能於降雨季節前進行維護，就能降低其滑動之風險，減少災難所帶來的損失。石碇地區之地下水位 (H_w/H) 則為水位觀測井測得之已知值，勘查當天之地下水位 (H_w/H) 值為 0.7，分析結果如圖(2-43)，因勘查時天氣晴朗，此結果顯示此邊坡不穩定，若當地經過降雨而導致地下水位上升，就更容易造成坡地滑動。而台中草湖黃竹里崩塌地之地下水位 (H_w/H) 亦為未知資訊，本團隊透過設定地下水位值為 0.9、0.95、1.0，得到安全係數接近 1，如圖(2-44)，現勘當天看當地先前是有崩落的跡象，但滑落過後坡角大約為 25° ，因此目前在一般情形下，此邊坡為穩定狀態，而若是發生豪大雨使地下水位接近地表才會有崩塌的危險。



圖(2-42) 阿里山地區 App 工具計算安全係數之結果



圖(2-43) 大崙山 App 工具計算安全係數之結果




圖(2-44) 黃竹里崩塌地 App 工具計算安全係數之結果




圖(2-45) 集集鐵路隧道崩塌地 App 工具計算安全係數之結果

而經過以上 App 工具分析之後，即可輸入全台各地區之參數，進而產出安全係數圖層，如圖(2-46)所示，此圖層可謂將安全係數(FS)數值可視化，以利於 AI 模型深度學習。下圖(2-46)為安全係數圖層疊加衛星圖之示意圖，在此圖層當中，安全係數(FS)值大於 2 即視為非常安全地區，圖層沒有顯示任何顏色；安全係數值介於 1.5~2，圖層顯示藍色；安全係數值介於 1.3~1.5，圖層顯示黃色；安全係數值介於 0.9~1.3，圖層顯示橘色，亦即當地邊坡有危險性，可能隨時會崩落；安全係數值小於 0.9，圖層顯示紅色，亦即當地邊坡非常危險，若是當地有人居住則需要迅速撤離，以免發生邊坡災害。




圖(2-46) 安全係數圖層示意圖

在進行訓練之前，圖資處理為重要的步驟，本團隊在各圖層圖資處理的方式，採用自行開發的資料標註系統-AutoGIS，其界面可參考圖(2-47)，可點選我們需要的輸入層，電腦便會掃描出需要的圖層，本次報告我們所使用的輸入層有 CS Map、HOST Map、衛星、水文、高程資料以及滑坡圈繪資料(label)，另外也將在本年度計畫加入安全係數圖層，而此軟體亦可掃描輸出多種圖層資料。界面的 Create Label 按鈕(圖(2-47)紅色框起來部分)，則是比對輸入層的 CS Map、HOST Map 與滑坡圈繪資料(label)的差異，利用兩圖像的差值處理得到標註圖，詳細可看圖(2-48)，以此得到訓練模型的所有圖層資料。AutoGIS 可以完成萃取多圖層資料與提取對應的標註資料，如此可解決 ArcGIS 軟體本身無法輸出多個圖層資料以及輸出之圖資無法自行調整比例尺的問題。而此次我們比例尺自訂為 1:10000，於此大小下比較適合判別滑坡發生與否，其特徵差異比較好做辨別。



圖(2-47) AutoGIS 使用界面



圖(2-48) AutoGIS 得出的標註圖

二、模型設置及訓練

本計畫利用 ArcGIS 與 Python 建立之深度學習套件，分析的工具採用 U-Net 作為架構骨幹，以此來設計新模型-smp.UNet，並以語意分割(Semantic segmentation)技術來實現，進行山崩與地滑地質敏感圖像訓練。首先將資料集 80%作為訓練資料、20%作為驗證，資料輸入時同時進行資料擴增(Data augmentation)，本計畫使用之圖資使用轉置、平移的方式可生成更多樣的資料，接著調整超參數後就進入訓練階段，而此次訓練重要的參數的部分為：

learning rate: one cycle learning

Architecture：smp.UNet

initial:0.001(max:0.001, min:0.0001), factor:0.1

optimizer:AdamW , batch size:8 , Epoch:7

目前輸入層有 CS Map、HOST Map、衛星、水文、高程資料以及滑坡圈繪資料，而安全係數圖資目前已經製作完畢，但目前正在資料處理待訓練當中，於成果報告將顯示其訓練預測結果。輸出的部分為模型預測的結果，詳細資料也放在本節第三點訓練結果與討論。


三、訓練結果與討論

本次計畫主要是接續上一年度，並且針對模型架構以及訓練時超參數的部分進行微調，以下為本次計畫進行現勘地區之預測結果。除此之外，也將輸入現勘之土壤參數，以上述提到 App 技術來呈現當地之安全係數圖，並進行對比。


而 ArcGIS 內的衛星圖層以及水保局提供之 5m CS 地圖，有部分圖資可能須予以刪除，例如衛星圖在不同時間拍攝的拼裝在一起，如下圖(2-49)、拍攝當下有多雲，無法完整呈現地貌，如圖(2-50);以及 CS 5 m 地圖之瑕疵，如圖(2-51)，這些因素將會影響模型訓練的結果。



圖(2-49) 衛星圖會因拍攝時間不同而使用拼裝



圖(2-50) 衛星圖拍攝當下多雲而無法顯示地貌




圖(2-51) CS 5 m 地圖瑕疵

由於上述因素需要大量刪減圖資，因此於本團隊進行現地勘查只有集集鐵路隧道崩塌地以及阿里山地區圖資未被刪除，可以將現地參數之安全係數圖層以及 AI 模型預測比較，以下為安全係數圖層與 AI 模型預測比較：

集集鐵路隧道崩塌地：



圖(2-52) 集集鐵路隧道崩塌地 AI 模型預測




圖(2-53) 集集鐵路隧道崩塌地安全係數圖層


圖(2-53)紅色圈繪區域為本團隊進行現勘取土所在地，經由室內試驗以及鑽探報告上獲得當地土壤參數，以此繪製之安全係數圖層。而其輸入之土壤參數為坡高(β): 27° 、地下水位(H_w/H):0.1、凝聚力(c): $2 \text{ (KN/m}^2\text{)}$ 、土壤單位重(γ): $18 \text{ (KN/m}^2\text{)}$ 、坡高(H): 60 (m) 、磨擦角(ϕ): 32° ，與圖(2-45)之 APP 數據(坡高、坡角)有些不同，原因是現勘取土是已爬到破壞區域測量，即為小範圍土坡測量安全係數，而安全係數地圖輸入值則是根據 ArcGIS 繪製之斜坡單元資料，亦即整個大邊坡之分析。

可以發現安全係數圖層與滑坡圈繪區域(Ground Truth)及 AI 預測結果大致符合，圈繪區域於安全係數圖上大多為黃色及橘色，即為安全係數值小於 1.5，而 1.5 為邊坡防護之設計規範標準。

阿里山山區：



圖(2-54) 阿里山山區 AI 模型預測



圖(2-55) 阿里山山區安全係數圖層

圖(2-55)為本團隊前往阿里山山區現勘區域，紅色區域則為現勘區域所在地(二萬坪火車站旁)，其中大部分區域在圖(2-55)外，因 ArcGIS 裁切問題導致剛好切到現勘所在區域。其中可以發現滑坡圈繪區域於安全係數圖層上大致為黃色、橘色及紅色($FS < 1.5$)，與安全


係數所代表之安全性趨勢大致吻合。

圖(2-55)之安全係數地圖，其參數為現勘後經室內試驗以及當地鑽探報告所獲得，土壤參數坡高(β): 33° 、地下水位(H_w/H):0.5、凝聚力(c): $0.1(\text{KN}/\text{m}^2)$ 、土壤單位重(γ): $19(\text{KN}/\text{m}^2)$ 、坡高(H): $17(\text{m})$ 、磨擦角(φ): 35° 。

圖(2-52)及圖(2-54)為現勘地區之山坡與地質敏感區與 AI 模型預測結果，右圖為兩者疊加結果，由此可以看出預測結果與實際值的差異，以上結果可發現在大面積的預測效果不差，大致上也已能辨識輪廓。

另外，其他現勘地區雖然沒有 AI 預測結果，但仍能與滑坡圈繪資料進行比較，以下為滑坡圈繪地區與安全係數圖層之比較：

台中草湖黃竹里崩塌地：



圖(2-56) 草湖溪崩塌地滑坡圈繪區域與安全係數圖層比較




圖(2-57) 草湖溪崩塌地位置圖


本團隊前往之現勘區域如圖(2-57)紅色圈繪區域。如圖(2-56)所示，草湖溪崩塌地之滑坡圈繪區域與安全係數圖層進行比較，發現大部分區域吻合，而現勘地點觀察亦是如此，且安全係數圖層沒有顏色($FS > 2$)之區域，大多於圈繪區域一致，為安全區域，因此此地區在安全係數圖層當中可以做為預防邊坡災害之參考。

而圖(2-56)右邊安全係數圖層之參數則是為現勘後經室內試驗以及當地鑽探報告所獲得，土壤參數坡高(β): 25° 、地下水位(H_w/H): 0.5、凝聚力(c): $0 \text{ (KN/m}^2\text{)}$ 、土壤單位重(γ): $13 \text{ (KN/m}^3\text{)}$ 、坡高(H): 80 (m) 、磨擦角(ϕ): 40° 。

石碇大崙山山區：




圖(2-58) 石碇山區滑坡圈繪區域與安全係數圖層比較



圖(2-59) 石碇大崙山山區位置圖

圖(2-59)紅色圈繪區域為本團隊前往大崙山現勘區域。如圖(2-58)所示，石碇山區之滑坡圈繪區域與安全係數圖層進行比較，發現於現勘區域之滑坡圈繪圖以及安全係數圖層有所不同，查閱先前資料得知本區屬於順向坡潛移破壞模式且變位主要發生於降雨較多的期間，因此滑動面的強度參數是關鍵，然而依照邊坡表面的檢查方式，無法取得層面參數，應該高估了磨擦角，此案例顯現本研究方法的缺點。

圖(2-58)之安全係數地圖，其參數為現勘後經室內試驗以及當地鑽探報告所獲得，土壤參數坡高(β): 26.5° 、地下水位(H_w/H):0.7、凝聚力(c):0 (KN/m²)、土壤單位重(γ):18(KN/m³)、坡高(H):60.4(m)、磨擦角(φ): 41° 。



圖(2-60) 訓練及驗證損失圖


此計畫當中目前使用之圖層有 CS 1m、HOST 1m、衛星圖、水文地圖、等高線圖以及滑坡圈繪資料(Ground Truth)，其預測顯示結果為以上現勘地區圖(2-52)、圖(2-54)所示，而其精準度的分析主要是觀察 iou loss，圖(2-60)為以上實驗結果在訓練時的訓練及驗證損失圖，可以發現在驗證損失(val iou loss)之值大約在 0.15~0.2 徘徊，亦即此模型之準確度已高達 85%。

再者，進行實驗篩選圖資，把實驗輸出準確率高的圖層保留並刪除不適用之圖層，以下為本團隊經過實驗得到之結果。

(一)圖層: CS 地圖、HOST 地圖、LABEL、衛星圖、水文圖

→ 刪除高程資料


在以上圖層疊加後，以訓練好的模型進行預測及評估，可得到輸出結果如圖(2-61)。



圖(2-61) 拿掉高程資料之模型預測與實際滑坡比較

圖(2-61)為山坡與地質敏感區與模型預測結果，右圖為兩者疊加結果，由此可以看出預測結果與實際值的差異，以上結果可發現在大面積的預測效果還不錯，大致上也已能辨識輪廓。

而在此計畫當中精準度的分析主要是觀察 iou loss，圖(2-62)為以上實驗結果在訓練時的訓練及驗證損失圖，相比於一般的損失函數此圖有上升的趨勢代表在訓練時有過擬合(over fitting)的現象發生，可能是拿掉圖層後資料量減少導致。而過擬合發生情形下，用 iou loss 計算精準度會比較不準確，因此於後續會加入更多圖資及圖層來解決。




圖(2-62) 拿掉高程資料之模型訓練、驗證損失圖

(二) 圖層: CS 地圖、HOST 地圖、LABEL、高程資料、水文圖

→ 刪除衛星圖


以上圖層疊加後，將訓練好的模型進行預測及評估，可得到輸出結果如圖(2-63)。



圖(2-63) 拿掉衛星資料之模型預測與實際滑坡比較

圖(2-63)可見在預測方面結果不是太好，山坡與地質敏感區與模型預測的重疊地區較小，由此可以推論在滑坡檢測上，衛星圖是非常重要的圖資。

圖(2-64)為訓練時的訓練及驗證損失圖，可以發現 iou loss 值比較低但一樣有過擬合的問題，因此此模型也無法用 iou loss 來得知精準度，需增加資料量來解決。




圖(2-64) 拿掉衛星資料之模型訓練、驗證損失圖

(三)圖層: CS 地圖、HOST 地圖、LABEL、高程資料、衛星圖


→ 刪除水文圖

以上圖層疊加後，將訓練好的模型進行預測及評估，可得到輸出結果如圖(2-65)。



圖(2-65) 拿掉水文資料之模型預測與實際滑坡比較

圖(2-65)實驗輸出結果也相當不錯，重疊區域相對刪除衛星圖圖層來的多，雖然有部分沒有預測精準，但在大面積滑坡的預測預測表現不差。



圖(2-66) 拿掉水文資料之模型訓練、驗證損失圖


圖(2-66)為訓練時的訓練及驗證損失圖，iou loss 與前二者相同，有過擬合現象發生，欲得知精準度需要解決過擬合問題，才能得出穩定向下的損失函數圖。

由以上實驗結果可知，雖然各模型都有過擬合現象發生，無法以 iou loss 得到正確的精準度，但在模型可視化，如圖(2-61)、圖(2-63)以及圖(2-65)的表現來看，高程資料跟水文圖相較衛星圖對於模型架構提供的資訊量較少，雖然對於預測結果沒有太大的幫助，但卻會造成過擬合問題，除非後續加入之圖資數量足夠解決此問題，才會予以刪除對預測結果較無助益之圖層。


目前本團隊正在處理待訓練安全係數圖層，因訓練圖資以及圖資前處理，像是資料擴增(Data augmentation)，需要花上幾個禮拜時間，因此加入安全係數圖層之訓練結果將於期末成果發表會將呈現之。

增加安全係數主要是來判斷當地目前邊坡的危險指標，但有些地區為「已崩落」區，在當地之坡高、坡角皆與崩塌前有所差異，在安全係數之值也會比較高，由於此地區先前為崩塌地因此在預測方面或許與滑坡圈繪區域有所差別，但安全係數確實為重要之判斷指標。

由於先前使用之圖資 CS、HOST 地圖為 1m 資料，此地圖為國家機密，依規定今年度使用完須予以銷毀，因此水保局提供 CS 5m 以及 HOST 5m 地圖，以下為使用 CS 5m、HOST 5m 以及其他圖層(水文、高程資料、衛星、滑坡圈繪區域(LABEL))地圖訓練之結果：



圖(2-67) CS、HOST 5 m 地圖模型訓練、驗證損失圖



圖(2-68) CS、HOST 5 m 地圖模型預測與實際滑坡比較

如圖(2-67)、(2-68)可以發現，由於精度沒有 1m 資料精細，因此精準度上會比較差，由圖(2-67)可以觀察 iou loss 最低值大約為 0.22，亦即此模型之精準度大約為 78%，由於安全係數地圖目前處理待訓練當中，而訓練以及調整參數尚需花一些時間，訓練結果也將於成果報告呈現，期望能再度提高精準度。



第三章 工作進度與交付項目


本計畫預定進度與目前進度分列於第一節所示，而第二節中檢討後續執行重點。

第一節 預定進度與目前進度

本計畫於本期末報告中圖資預處理已達 85%，目前已將安全係數圖層處理完畢。同時也確定模型的架構並進行增進，達預定進度 90%，正在進行的模型訓練及驗證也達 85%，如前述所示，後續將加入安全係數圖層重新進行模型訓練、驗證，而本年度則已完成現地調查。


重要工作項目	工作比重%	預定進度	112			
			1-3 月	4-6 月	7-9 月	10-12 月
現地調查	20	工作量或內容	台北地區現勘	嘉義地區現勘		
		累計百分比	30	70	100	100
圖資預處理	20	工作量或內容	安全係數圖層製作	安全係數圖層製作	安全係數圖層製作	
		累計百分比	40	80	100	100
技術開發與模型增進	20	工作量或內容	技術開發	技術增進	技術增進	技術增進
		累計百分比	30	70	90	100
模型訓練及驗證	30	工作量或內容	模型訓練	模型訓練	模型訓練及驗證	模型訓練及驗證
		累計百分比	10	55	85	100
報告與論文撰寫	10	工作量或內容	無	無	報告與論文撰寫	報告與論文撰寫
		累計百分比	0	0	50	100
累計總進度	百分比		20	61	88	100

表(3-1) 預定進度表



圖(3-1) 研究流程圖

如圖(3-1)所示，為本計畫之研究架構圖，綠色部分則為此次期末報告之進度，目前已完成圖層並準備進行訓練。紫色部分為今年度計畫完成之進度，其餘部分為上一年度完成之進度，而本團隊也將盡力完成目前尚未完成之進度，以增加實驗結果之準確度，並達成本年度之預定進度。而在現地調查與室內試驗以及室內試驗參數結果導入 APP 以計算安全係數部分則是上一年度以及本年度皆有進行，下圖(3-2)為上一年度以及本年度計畫執行現勘之流程，紫色部分同為本年度之進度，其餘部分上一年度已完成。



圖(3-2) 現地調查與室內試驗流程圖

第二節 計畫後續執行要點

期初報告繳交後，本計畫執行將規劃中部地區的現勘計畫，地點為草湖溪黃竹里崩塌地以及集集鐵路隧道崩塌地，將現勘計畫執行完畢，進行現地調查的目的在於模擬邊坡檢查中，如何真實使用本計畫之 APP 技術。另外根據已知與假設條件可提供影像判釋之潛在破壞邊坡與臨界值(安全係數為 1 時)之差距，因此現地調查主要想取得地質強度參數及地形參數供 APP 工具使用。此現勘與滑坡影像辨識之安全係數圖層有關，因此需要將現勘所取得的參數用於安全性評估與驗證使用，在技術開發與模型擬定工作中將針對選擇性能較佳的技術模型投入後續的圖資訓練中，提前進行案例驗證並持續完成文獻蒐集之工作。

本計畫將於期末報告繳交後持續進行圖資之訓練，盼能增加圖資之多樣性，以供電腦模型進行學習及判釋。而 CS 以及 HOST 地圖由於先前使用之 1m 地圖為國家機密，今年度使用完須予以銷毀，因此水保局提供 CS 5m 以及 HOST 5m 地圖，目前也以完成訓練以及預測，其結果可參考第二章第五節之訓練結果與討論。

模型訓練及驗證之內容，先行針對處理圖資訓練集的內容增加辨識時所參考的特徵值以優化目前訓練結果對整張圖進行標註之缺陷，依照進度安排於計畫執行期限內已完成本年度預定目標。



圖(3-3) 本年度使用之輸入圖層差異

第三節 上期期初計畫審查意見問題與回覆

Q1:光達圖怎麼辨識「已崩」及「未崩」區域?

A1:在山崩與地質敏感地區的資料當中，已崩塌區域與未崩塌區域，圈繪為同一種類，故利用深度學習，會透過圈繪後在光達底圖上的特徵進行山崩與敏感地區의影像辨識。

Q2:何謂特徵?

A2:特徵在深度學習當中的神經網絡，一般都以卷積層(Convolution layer)、池化層 (Pooling layer)等等作為模型架構，當中卷積層以固定的核心在圖像中每個像素做卷積運算，在經過整個神經網絡模型後會得到特徵影像(Feature Map)。

Q3:圖資時序問題?

A3:目前確定山崩與地質敏感地區的時間較 HOST 圖和 CS 圖晚，即圈繪後改變地形樣貌的問題存在。

Q4:可見光因素的影響?

A4:在 HOST 圖和 CS 圖兩種圖資當中，分別是以坡度、開闊度和坡度、曲率、高程套疊而成，只有在衛星影像、航拍等圖資會有可見光的問題。

Q5:如何界定訓練範圍?

A5:以深度學習來說訓練的資料是越多越好，但在初期測試階段以足夠的數量訓練可免去過多圖片訓練耗時的問題。

Q6:現地調查的功能?

A6:現地調查的目的在於取得實際案例的地質強度參數，可透過數值模式分析及手機 AI APP 之安全性評估與驗證影像辨識之結果。

Q7:新圖資可辨識及應用範圍?

A7:以目前進度來說，若具有相同種類的新底圖圖資即可作為辨識使

用，可以用來訓練加強模型精確度，亦或是可用來預測山崩與地質敏感區域。

Q8: HOST 圖和 CS 圖獨立或分開?

A8:目前進度是將兩者合併，將兩者套疊在一起，讓訓練時有更多的特徵能夠去辨別山崩與地質敏感區域。

Q9:是否有隱碼的問題?

A9:目前在影像處理過程中，未發現有隱碼的存在或是潛藏在圖資當中的浮水印。

Q10:為什麼不使用具有時間序列功能的 AI 技術來做訓練。

A10:首先達到訓練的精準度必須有足夠的資料，以圖像方式為基礎的訓練，目前評估有時間背景資料量不足。另外本團隊評估以安全係數為背景的 AI 訓練，需要考慮土壤不飽和所造成之影響才有力學意義，而此部份的研究本團隊仍在進行中，因此具有時間序列功能的 AI 技術應用在本期工作內容中，功效不顯著。



第四節 上期期中計畫審查意見問題與回覆

Q1:建議繪製一張研究架構圖，以呈現本計畫所使用圖資、分析工具、現調、準確性判斷及輸出結果等操作元素間之對應關聯。

A1:下圖為本團隊之研究架構圖，現有的圖資並進行訓練部分有 HOST Map、CS Map、DEM、水文資料、衛星圖，而本團隊分析工具是採用 U-Net 作為架構之骨幹，以此來設計新的模型，並以語意分割技術來實現。圖(3-1)之綠色部分為本團隊未來之計畫，也是我們要努力的部分，就目前現有的為黑色部分，而準確性判斷我們是採用 dice loss 佔 40%、focal loss 30%以及 iou loss 30%，一起訓練取最低值做為評估標準，輸出結果以及詳細數據將會放於期末報告第二章第五節訓練結果與討論。

Q2:現調目的為提供 APP 參數，然 APP 在本計畫之功能卻無法突顯請再說明。

A2:本 APP 是以人工智慧結合大數據(AI 模型)為基礎完成，因此 APP 與 AI 模型是可以得到一樣的結果。AI 模型所製之圖層精準度會受到土壤強度參數與地形參數的影響，因此需要現地調查與室內試驗作為輔助確認 AI 模型概估之 FS 是否合理。本團隊將現地調查，並進行現地試驗，其中包括阿里山山地以及石碇山區測量其土壤內摩擦角、凝聚力，以及將坡高、坡度、水位這些重要係數導入 APP 當中可得到安全係數，而此安全係數將可以進行模型訓練，以提供實例驗證。


Q3:請說明水保局 CS、HOST 圖資之基本資訊，以及作為本計畫分析之妥適性；此外，挑選中臺灣坡地為實證區之理由為何？

A3: CS 地圖結合地形高程(Height)、地形曲率(Curvature)及地形坡度(Slope)，運用不同的色調及透明度來表現地形的坡度與曲率，並將


其圖資套疊。H.O.S.T 地圖所使用之調色盤是由地形坡度及地形開闊度組成。而本計畫開始團隊確實是以中臺灣坡地為實證區，初始認為土壤概況較為相似，可減少訓練資料上特徵差異的影響，但後發現中台灣山區的訓練模型其資料量不足，因此改為全台的坡地做為實證區。

Q4:模型設置及訓練(P37)錯字及圖號錯字須改善外，針對研究成果「無法辨識...特徵」或「參教調整...成效不佳」等現況，應以量化或相關資料圖說予以佐證，單以文字描述無法理解計畫執行狀況

A4:以下為此次報告時之訓練結果，由圖(3-4)可以發現訓練成效並不佳，橘色線以及藍色線分別為驗證、訓練損失函數，其下降的量並不多，而以圖(3-5)來看，驗證結果跟基準真相(Ground truth)亦是差異極大。




圖(3-4) 訓練以及驗證損失圖



圖(3-5) AI 模型測到與實際滑坡部分

Q5:第三章第二節「後續執行要點」內容皆為期初報告後進度內容，而非期中報告所應呈現進度。

A5:本團隊於3月初左右拿到相關資料，並於4月左右將資料導進ArcGIS，而於裁切資料時發現ArcGIS無法同時將多種圖層(CS、HOST地圖)裁切下來，使標註資料無法做兩張圖層的特徵萃取(Feature extraction)，以及ArcGIS裁切資料無法設定比例尺，導致範圍過小，容易使資料皆為滑坡地區，則此資料無法進行辨識，因此本團隊為此討論近兩個月解決。而後到7月本團隊自行開發新的資料標註系統，以此來完成多圖層資料的萃取與提取對應的標註資料，如此便可自行調整比例尺以及多種圖層的截取，此為至期中報告前之進度，流程圖可參考下圖(3-6)。



圖(3-6) 本計畫期中報告前之流程圖

Q6:結論應呈現目前計畫所獲得分析成果，而非計畫目標及操作方式等資訊。

A6:謝謝委員的建議，此次報告之訓練成果可參考圖(3-4)、圖(3-5)，其輸出結果以及數據也會放於期末報告第二章第五節的訓練與結果討論。

Q7:深度學習需大量圖資進行訓練，本計畫圖資數量至少要多少?資料集訓練資料佔 90%，另 10%作為驗證，10%驗證資料如何選取?(隨機抽取?) 驗證結果正確率及誤判各多少?

A7:本計畫開始時本團隊預計從中臺灣坡地做為實證區，而其圖資數量大約有 500 張，因資料量不足以訓練模型，因此改為全台的坡地做為實證區。而圖資數量需要以訓練成果的好壞來做調整，因此本團隊也還在試最佳的圖資數量。

本團隊之資料集，訓練資料佔 80%，另 20% 做為驗證，一般會資料的選取會採用固定的隨機樹種子(Random seed)來確定輸出資料集的資料比例和內容會一樣，不過因為我們有做資料增強(Data

Augmentation)，在分割資料的部份是隨機抽取。結果於誤判這部分是做語意分割，並不是分類問題，所以沒辦法很直接地評估到底正確與失敗佔比多少。不過可以針對每一張圖對應的類別進行像素化(Pixel-wise)的分類比較。

Q8:報告書中「如下圖」請標註圖號

A8:感謝委員的提醒，此部分將會在期末報告注意。

Q9:使用參考資料前，宜先瞭解該資料之產製方式與使用情境。地調所之「山崩地滑地質敏感區」圖資，係使用歷年(約 2012 年以前)衛星影像等圖資，將歷年崩塌地點數化而得故其代表意義為歷年「已崩塌」區域，對應到 1m 之高精度地形圖(如 HOST 或 CS 地圖)上其實是「已崩塌」的地形。

A9:目前所遇到的困難點在於 ArcGIS 原本內部的設定最大只能處理(256*256)的圖資，但是在這個限制下，有可能整張圖都位於同一個崩塌地之中，因此無法有效辨識其特徵，而如果以更大範圍去圈選圖資，ArcGIS 內部設定的切割條件會跳過大部分的圖資，無法取得相應的切割圖資數量。若要避開上述二者，必須重新建立一套模型架構，因此本團隊為了解決問題，正在開發其他技術跳脫此限制，訓練與辨識也並非在 ArcGIS 之中。本團隊目前也不是使用 Mask-RCNN，目前自行開發語意分割(Semantic Segmentation)技術，同時使用台灣高速網路與運算中心的台灣杉設備，訓練一次大約要一週。

由於脫離 ArcGIS 介面，圖資也需要另外加工處理，至於圖資處理上預計會加入一層安全係數作為輸入之底圖，增進山崩與地滑地質敏感區之特徵，此部分的安全係數就是利用 AI 大數據模型為基礎，與 APP 同基礎，同時我會對照原來圈繪資料是否能與目前所套疊的資

料在實際狀況下的吻合情況。

Q10:計畫之目標為以 AI 辨識崩塌之地形特徵，似與圖 2-8 之 APP 無關？即便欲導入 APP 應該就 APP 之計算方式及目的說明清楚，不宜只秀其界面。

A10: APP 之計算方式是將相關參數(坡高、地下水位、土壤凝聚力與摩擦角、坡度、土壤單位重)利用數值分析評估出相關的 FS，不同的參數將得出不同的數據，再把先前評估的多筆資料建立成一數據庫。接下來將此做為 AI 模型的資料集，而本團隊則是採用循環神經網路(Recurrent Neural Network, RNN)為基礎之模型。本 APP 是以人工智慧結合大數據(AI 模型)為基礎完成，放入 APP 僅是為了方便攜帶使用，因此 APP 與 AI 模型是可以得到一樣的結果。本來 AI 模型是用來判定所辨識出的潛在滑動面距離臨界狀況($FS=1$)有多接近，依據目前結果本人認為必須直接導入 FS 的圖層進入訓練，本團隊也在製作中，以期結果或能提高辨識的效率與精準度。然而此 AI 模型所製之圖層精準度會受到土壤強度參數與地形參數的影響，因此需要現地調查與室內試驗作為輔助確認 AI 模型概估之 FS 是否合理。另外若是 APP 結合人為判斷能得到足以反映現調邊坡狀況的安全係數，將來或可利用 APP 技術於現地調查時，協助初步判定量測邊坡之可能安全係數範圍與土壤參數的合理性。

Q11:承上，現調工作之意義似亦與主題無關，請補充說明其關連性。

A11: 於兩次現地調查當中，分別為阿里山山坡地屬已崩塌、大崙山坡地屬大規模潛勢崩塌，將坡高、坡度、水位與大略之土壤內摩擦角、凝聚力，導入 APP 當中可得到安全係數，與往後模型訓練加入安全係數之結果做比對，提供實例驗證。

Q12: AI 訓練過程之收斂情形、訓練成果之檢核方式、精度統計等方式宜說明。

A12:收斂情形以及 AI 圈繪結果可參考圖(3-4)、圖(3-5)，圖(3-3)可以發現訓練成效並不佳，橘色線以及藍色線分別為驗證、訓練損失函數，其下降的量並不多，而圖(3-5)驗證結果跟基準真相(Ground truth)差異極大，而期末由於我們採用新的圖像辨識技術，其輸出結果以及詳細數據將會放於期末報告第二章第六節結果。檢核方式我們將採用採用 dice loss 佔 40%、focal loss 30%以及 iou loss 30%，一起訓練取最低值做為評估標準，而上述之 iou 為常見的精度統計。


Q13:訓練所使用參數、輸入層、輸出層宜說明清楚。

A13:我們訓練所使用的重要參數:

learning rate: one cycle learning , initial:0.001(max:0.001,min:0.0001) , factor:0.1

optimizer:AdamW , batch size:2 , Epoch:50

於期中報告中輸入層 HOST Map、CS Map，而期末報告中輸入層則加上 DEM、水文資料以及衛星圖，輸出層則為 AI 所圈繪出來的滑坡地區，以上資料供委員參考，而下圖(3-7)為架構表，亦供委員參考輸入輸出之圖資，而其輸出結果以及詳細數據將會放於第二章第五節的訓練與結果討論。



圖(3-7) 模型架構示意圖

Q14:前以全島 DEM 加值圖進行特徵模型訓練，是否可應用分區，或近似地質條件之區域作為獨立訓練集，搭配近似地質條件的驗證資料集，當試提高辨識成效？

A14:我們之前所使用之 DEM，欲使提高辨識成效，因為高程是需要表示所有的高度資料，而高程的變化也是檢測滑坡本身的重要要素，基於此，我們判定 DEM 有辦法提升辨識精度。

由於中臺灣坡地其圖資數量大約只有 500 張，其資料量不足以訓練模型，因此本團隊將使用全台的坡地做為實證區。

Q15:報告中目前看來使用 Mask_RCNN 為基礎發展的套件，是否其物件辨識特性，導致坡地單元的特徵紋理辨識上，效果較為不足。建議可進一步探討，辨識技術在物件邊緣測、物件紋理特徵偵測等兩種偵測的有效性或優勢，若驗證對象為已圈繪單元，辨識是否為安全或敏感邊坡，或許偏向於紋理、特徵偵測為主，因其單元邊緣

已用人工或自動圈繪。建議可進一步探討演算法優勢與可優化方式。

A15:本計畫原先是以 Mask_RCNN 為架構的基礎進行實作，但發現資料中並沒有邊界框(bounding box)，因此後來改做語意分割 (Semantic Segmentation)為基礎來實作。為克服訓練成果問題，將會改變原先模型架構增加模型的深度，以及在圖資處理方面會增加圖資種類，讓輸入層的厚度增加以改進先前的問題。



第五節 上期期末計畫審查意見問題與回覆

Q1:崩塌地型判釋之地形特徵為何？要提升精度所需的資料為何？

A1:本計畫採用地形特徵資料為山崩與地滑地質敏感區，此資料在地形特徵上有三大特性:1.由衛星、航照及光達等影像判釋曾發生土石崩塌等事件。2.潛在山崩與地滑區含順向坡地形。3.地質災害發生之影響範圍。為提升精度，目前深度學習測試結果基本需含有新型的CS、HOST地形圖，才能提供一定的精度，至於期末報告結果中，使用之衛星圖、DEM、水文圖為目前測試能達到最高精度底圖。若後續研提計畫通過，本團隊將進行以下測試以提升精度:(1)完全利用全台圖資(約 1300 張);(2)導入具有安全係數概念的圖資(本團隊預計進行);(3)還會測試所有底圖特徵貢獻的權重，並保留特徵貢獻較高的底圖。

Q2: 20*20 與 5*5 的 DEM 分析結果是否有所差異？該如何抉擇？

AI 仍然需要現場調查，如何再與既有圖資進行結合與訓練？未來如何預測？

A2: 本計畫在圖資解析度中，首先會使用較好解析度如 5*5 的 DEM、1 米的 CS、HOST 圖等，因較高解析度能更明確表示地形上的差異，在特徵表現上也能有效區分判定範圍，故以「達到最好的精度」為標準訓練模型。接續才能考慮降低解析度，嘗試以更有效率的方式達到相同訓練結果，而就目前訓練結果，20*20 DEM 已經能達到預期之效果。透過現場調查提升判定土壤參數經驗，如阿里山崩塌區土壤摩擦角目視跟手的觸覺預測與試驗結果相差不到 10%，現地調查試驗結果在後續影像辨識技術預測後能作為驗證。若後續研提計畫通過，將會利用 ArcGIS 配合斜坡單元之概念輸出幾何參數，並將其導入 APP，透過 AI 評估安全係數後產出新的訓練底

圖，取得之底圖再放入自行開發的模型架構中。

Q3:大規模崩塌通常為 10ha 以上的面積，而深度學習所需資料龐大，其精度與效率如何取捨？

A3:本計畫目前訓練圖資為 768*768，需較大資源與記憶體來訓練，相對的時間花費較長。依照過去影像辨識的處理方式，本計畫優先目的為達到最佳精度並能辨識山崩與地滑地質敏感區，若後續研提計畫通過後再透過模型改進，提升效率減少耗時。

Q4: training data 不足的部分，是否有考慮將現有 data 加入偏移、旋轉及顏色調整等方式增加 data，另外，overfitting 部分是否考慮改變模型參數等方式進行測試？

A4:目前原始資料為中部地區有五百多張，再加入資料擴增技術如問題所述偏移、旋轉等，增加八倍後總共有四千多張，後續會加入全台圖資預計將會有 1300 張圖資(未擴增情況)，另外 overfitting 部分，模型參數如學習率(learning rate)、優化器(optimizer)等經過測試為最合適目前模型的狀態，overfitting 經由本研究團隊測試討論後原因為影像資料有效特徵貢獻不足，後續將會利用 APP 之 AI 評估之安全係數作為新的訓練底圖改進 overfitting 情況。

Q5: 計畫 AI 辨識是利用全部的圖資來分析嗎？可否利用特定單一圖資來辨識，加速分析效率。

A5:目前使用圖資為台灣中部地區，後續將會增加至全台範圍，本計畫深度學習測試結果基本需含有新型的 CS、HOST 地形圖，才能提供一定的精度，若是單一圖資反而造成精度下降。另外依據經驗，目前認為耗時原因主要是圖像資料大小與模型深度造成，不過後續若測試所有底圖特徵貢獻的權重後，將可保留特徵貢獻較高的底圖，輸入模型通道數的減少也會縮減少許的訓練時間。

第六節 期初計畫審查意見問題與回覆

Q1. 目前以影像資料做為辨識資料，包括 HOST、CS 地圖與崩塌地滑地質敏感圖，應可加入多源圖資以增加準確度。

A1: 在圖資部分會加入衛星圖、20 米的 DEM 圖、ArcGIS 產製之水文圖資以及本期重點加入由 APP 內 AI 模型製作之安全係數圖層。

(補充於'預期步驟'首段及圖 13)

Q2. 第一年度計畫已產製之 APP，本年度請明確說明在 APP 精進的內容或功能。

A2: 本期之 APP 有二主要目的一、製作安全係數圖層。(補充於'預期步驟'首段)

Q3. 圖 13 之 FS 安全係數圖資如何獲得或製作，請補充。

A3: 圖 13 之安全係數圖層製作利用 ArcGIS 內部 API 將台灣山坡地化分成數個坡地單元，接著利用前述所提到之 APP 內的 AI 模型，將個別坡地單元相關參數輸入至 AI 模型當中得到安全係數於'預期步驟'首段詳細說明。

Q4. 崩塌地滑地質敏感區之製作方式係以歷年光學衛星影像去圈繪崩塌地範圍而得，如以圖資去訓練及驗證，所得結果建議稱之為山崩地滑敏感區之地形特徵，其未必為大規模崩塌。

A4: 此專業名詞，已嚴加使用並於內容中做修正。

Q5. P22 如何使用 APP 及 AI 產製安全係數，請補充。

A5: 在現地調查或工程現勘等情況下，只需打開 APP 輸入相關基本參數即可得到預測結果，如圖 17 APP 介面，AI 模型於安全係數圖層製作，將'預期步驟'說明之劃分好的坡地單元相關參數輸入至 AI 模型中做預測使用，已補充 APP 使用方法及 AI 於'手機 App 之 AI 技術'內文。

第七節 期中計畫審查意見問題與回覆

Q1:在過去幾年分別嘗試過紋理、雷達干涉、可見光分類等種種方式後，本計畫要使用高光譜遙測的手段來判釋崩塌範圍，並以多期的資訊來達成變遷分析與穩定性評估的目標。這基於三項假設:崩塌後基岩可完全裸露出來，衛星的感測器可以接收代表岩性特徵的波段，以及大氣校正可以準確地將衛星收到的訊號反演得到地表的反射率。建議執行計畫和撰寫報告書時應著眼在這三點，詳細論述，並提供充足的證據作為研究是否成功之證明。以下就這三點假設，提出關注重點:

Q1-1: 台灣地區風化嚴重，表土厚度可觀，恐非一次崩塌沖刷就會露出基岩，這可以透過現場量測地表高光譜反射頻譜資料，並與現有資料庫比對，可以判定裸露出來的究竟是不是基岩?或者還是表土?請確認。

A1-1: 以高光譜反射資料可以得知裸露出來為基岩或是表土未納入本計畫的目標，本團隊先前進行了幾次現場探勘，並沒有使用高光譜遙測當地地貌狀況，而是照實際勘查的結果進行判斷是否為基岩或表土，現地勘查的目標是希望藉由直接觀察或觸摸的方式，協助判斷可能的土壤強度參數。

Q1-2: 本研究使用 Sentinel-2 多光譜衛星 但該衛星並沒有岩性判釋需要，在 2000-2500 nm 範圍內的波段，請問究竟要使用 Sentiel-2 的哪些波段的哪些波段?這些波段對於台灣幾種主要岩性的吸收反射特徵為何?建議詳細列表討論。如果不足，應該使用哪些波段?有哪些衛星可以提供呢?

A1-2: Sentinel-2 衛星通常可用於地表分類和地質研究，但其波段不一定涵蓋所有岩性的吸收反射特徵。表(3-2)為 Sentinel-2 的主要波段以及它們對於台灣幾種主要岩性的吸收反射特徵：

名稱	波段範圍(nm)	岩性的吸收反射特徵
B1	443.9 - 496.6	適用水體和植被的分類，對岩石的吸收反射特徵有限
B2	499.6 - 596.6	可適用於植被的分類，但對岩石的吸收反射特徵較弱
B3	600.1 - 699.3	適用植被和土壤的分類，不太適合岩石的識別
B4	703.8 - 793.4	對於植被和水含量的研究較有用，對岩石的吸收反射較弱。
B5	770.1 - 893.9	用於植被和土壤性質的分析，對一些岩石有限的吸收反射特徵。
B6	922.9 - 994.1	適用於岩石和土壤的分類，但在辨識不同岩性方面可能仍有挑戰。
B7	992.1 - 1007.9	適用於水體的分析，對岩石的吸收反射有限。
B8	1007.8 - 1069.1	適用岩石和土壤的分類
B9	1373.5 - 1393.5	可適用於岩石的分類，特別是在檢測含有水分的岩石。
B10	1610.4 - 1675.7	對於檢測水分和一些氫氧化物礦物的吸收特徵有用。
B11	2071.0 - 2185.7	適用於檢測氫氧化物礦物和水含量的變化，對某些岩石和礦物有一定用途。
B12	2190.0 - 2292.9	對於檢測水分和一些礦物的吸收特徵有用，對岩性分析有貢獻。

表(3-2) Sentinel-2 主要波段及其對主要岩性吸收反射特徵

如果 Sentinel-2 的波段不足以進行岩性判釋，將可考慮其他遙感衛星，如 Landsat 系列、ASTER、或 Hyperspectral 衛星。這些衛星通常提供更多的光譜波段，以支援地質和岩性分析。

Q1-3: 附錄一提到要使用 FLAASH 模型進行大氣校正，請問模型需要的水氣波段資訊，要如何獲得 FLAASH 足以準確地將衛星收到的訊號反演得到地表的反射率嗎？請提供完整分析與詳細討論。

A1-3: 本計畫所使用的圖資除了水保署所提供(CS and HOST maps)，還使用了內政部與 ArcGIS 所能夠得到的圖資，但是在衛星圖資中有雲層明顯遮蓋而看不見地面情況的圖資則有去除，避免影響訓練成果。由於是使用既有圖資，關於大氣校正模型與水文波段在本計畫中並未著墨。

Q2: 目前使用光學衛星影像搭配 NDVI 等指數，已可快速且精準地判釋出崩塌地，故此情境似無需再用 AI 方式找出崩塌地。

A2: 使用光學衛星影像搭配 NDVI 等指數可以利用植被分布來分析已崩塌地區，而未崩塌之潛勢地區並沒有辦法完全判釋，因此衛星影像尚可成為訓練模型之因子，但還需要其他因子一起進行訓練，其辨識也將較為完整。而安全係數即可提供邊坡穩定性的資訊，將此因子進行訓練，有助於將未崩塌潛勢地區進行辨識圈繪。

Q3: 承上，本計畫建議將 AI 應用於輔助判釋 HOST 或 CS 地圖之特徵地形判讀，例如何處有崩崖、溝、古地滑地等。

A3: 本計畫旨在利用 AI 判釋崩塌地，以提供政府及社會大眾崩塌地圖，進而減少災害發生的損失，並希望所訓練出來的成果後續可對已崩或未崩危險區域，進行預測、判讀。然而依據目前訓練結果，在全部圖資都使用的情況下，才能達成超過八成的準確度，若要再進一步辨識崩崖、溝、古地滑地等，依照現有圖資與科技可能無法達成。

Q4: 未附期初審查意見之回復，請於期末報告時，連同本期中審查意見一併回復。

A4: 於期末報告已附上，而期初的審查意見大多問題與經費調整相關。

Q5: 地質地滑敏感區之範圍尺度較大，建議可針對年度事件型崩塌目錄作分析，如利用 2021 年的衛星影像及相關圖資等資料，來預測 2022 年的崩塌區域，再與 2022 年事件型崩塌目錄相互驗證，使此研究能提供防災預警之參考。

A5: 此建議可做為參考，但需要長時間進行觀察驗證，若是在崩塌危險區短時間沒有發生災害(如:地震、颱風)，造成崩塌的機率可能不高，而觀察時間長達 5~10 年以上，其參考價值將比觀察一年來的高。另外根據本計畫的經驗，拿掉任何一個圖資目前看起來都會造成訓練不成功的情況，有可能是問題過於複雜，因此只依賴衛星影像作為辨識的基礎下，有很大的可能性無法實現。

Q6: 訓練因子部分，建議補充各因子的相關性分析或檢定的量化結果。

A6: 由於在各因子進行圖像訓練時，導致圖資數量過少，因此期中報告所呈現的損失函數有過擬合現象，無法以 iou loss 來做量化分析結果，只能以圖像預測出來結果來判定好壞。而在期末報告將會試圖處理過擬合現象，以提供一個量化的數據供判釋準確度之標準。

Q7: 為因應機關組織改造，機關名稱修正為「農業部農村發展及水土保持署」，報告書封面及內文等請依本署最新範本格式撰寫，相關範本檔案請至本署電子圖書中心下載 (<https://elibrary.ardswc.gov.tw>)

A7: 謝謝提醒，將於期末報告修改。

第八節 期末計畫審查意見問題與回覆

Q1: AI 分析的全臺大規模塌，能否評估出新的未知的崩塌，作為署內評估的方向。

A1:本計畫以全台資料之 80%做為訓練集，剩下 20%圖資做為驗證集、測試集，而其中驗證集目的為 AI 評估結果與水保署提供之滑坡圈繪資料進行對比，計算出準確度;測試集則是純粹將圖資利用 AI 預測(沒有滑坡圈繪資料對比)，可做為未知崩塌地的預測。


Q2:圖像式的分析是否可以和網格式分析成果有所不同。

A2:圖像式分析主要關注處理和分析圖像或視覺數據，通常涉及計算機視覺和圖像處理技術，包括從圖像中提取特徵、識別對象、分類或檢測模式等。網格式分析則集中於處理網絡結構和數據之間的關係，是將數值資料以網格方式呈現，若是網格夠細則可呈現較清晰、準確的資訊。此二者並非不同的方法，而是呈現的概念不同，本計畫所使用的圖資皆是網格式分析而得，其中 CS、HOST 水保署有提供不同精度(1m、5m)資料，其為不同尺寸網格所呈現之差，此計畫圖像式分析為經由網格式分析所獲得圖資進行滑坡特徵的提取。

Q3:圖資預處理可事先分類資料或許可方便後續的訓練。

A3:在進行圖資預處理時，事先分類資料有助於更有效地進行後續的


訓練。本計畫在各種不同圖資有預先進行分類，如此一來將可方便後續的訓練。如圖(3-8)為本計畫之分類資料過程，而若委員所提及之圖資分類為不同類型、特性等的崩塌，以目前圖資數量尚無法做分類。



圖(3-8) 本計畫分類資料過程

Q4:AI 結果顯示出目前極限，無法在 5m 資料獲得好結果，也無法預測較深的崩塌。

A4:目前 5m 資料之準確度大於 80%，此準確度於 AI 辨識當中屬於及格邊緣。而 5m 資料可以預測較深的崩塌，但預測結果與 1m 資料比有些許落差。在台灣深層崩塌地區本團隊目前關注石碇大崙山、新竹梅花部落、南投廬山、高雄小林村，其中南投廬山與高雄小林村由於衛星或 CS 地圖圖資瑕疵因而刪除，故無法將預測結果呈現。新竹梅花部落地區是圖像式 AI 利用 5m 資料準確預測，如圖(3-9)，並非每個地區圖像式 AI 無法預測深層崩塌區。



圖(3-9) 新竹梅花部落 AI 模型預測

而石碇大崙山於報告中呈現安全係數地圖無法精準預測，其原因為現勘取土取表面土壤，經室內試驗後得出之土壤參數(c 、 ϕ)即為表層土壤參數，輸入安全係數圖層則為表層土壤之值，而此地之崩塌為大面積崩塌，其滑動面也相較其他滑坡深，需取至深層滑動面土壤才可準確分析其安全係數。

Q5:訓練資料(崩塌圖資)的品質是否有進行檢核，或許考不同類型、特性、面積的崩塌分別進行訓練。

A5:由於全台資料經檢核處理後大約有 2000 多張圖資，在深度學習中其數量不算多，若是針對不同類型、特性、面積的崩塌分別進行訓練會導致圖資不足造成過擬合(overfitting)現象，進而無法準確分析。

Q6:請補充說明報告中係使用何種衛星影像，以及是使用哪一種波段進行分類？是否影像加入其他波段來提供更多分析資訊？

A6:目前使用衛星影像圖資為 ArcGIS 內部提供，而其是使用 Sentinel-2、Landsat 等多種衛星，由於 ArcGIS 服務的數據可能會定期更新，以提供最新的高解析度影像，具體的波段配置可能會隨著數據更新而有所改變。目前遙感影像中是使用紅外線波段，紅外線對於植被、土地使用分類以及其他地表特徵的分析非常有用。目前本計畫將是依照 ArcGIS 內部數據進行分析。

Q7:建議增加安全係數分布圖、預測結果與山崩地滑敏感區之間的判釋準確度。

A7:目前安全係數所獲得之現地參數，需要現勘取土後進行室內試驗獲得，因此安全係數地圖目前只能繪製有現勘資料的地區，其他地區現地參數(土壤參數或岩石強度參數)只能以假設值輸入，若要進行安全係數分布圖與山崩地滑敏感區之間的判釋準確度，則要將完整各地的現勘資料輸出成完整之安全係數分布圖，而要完成完整之安全係數地圖尚需幾個月的時間。

第四章 結論及建議

第一節 結論

本計畫目的為開發影像辨識的深度學習技術，透過影像辨識對「已崩」及「未崩」區域或其他邊坡圖資中的特徵作為訓練用圖資，利用深度學習技術將其特徵量化，後續可用在找出「潛在崩塌」的圖像及對應區域，在開發完成並辨識潛在崩塌地的區域後可利用數值模式分析及手機 AI APP，對該地點做進一步的安全性評估與影響範圍界定，根據已知與假設條件評估潛在滑動面與臨界值(安全係數為 1 時)之差距。

期初報告整體已達預定之總進度 20%，後續工作內容也已現地調查完畢，國內外文獻回顧及圖資模型的訓練工作與案例驗證將按階段性目標達成。

截至期中報告撰寫其間本計畫已達預定之總進度 88% 左右，後續將產製安全係數圖層，並將訓練集圖資處理方式擬定後進行大量訓練，待本內容完成後對其結果進行驗證，後續將按進度表之規劃持續進行。

而截至期末報告撰寫其間本計畫已達預定之總進度 95% 左右，目前安全係數圖層已產製完畢，後續則將繼續當作訓練圖層，以增加圖資之參考性。而後也將加入此圖層來驗證是否對於判斷精準度有提升效果，由於此圖層需要大量現勘資料進行室內試驗，才能獲得當地之準確安全係數值，目前除本團隊現勘地區，其他參數是以岩坡、土坡作為合理範圍假設，若有全台灣之土壤(岩石)參數，將可得到更符合現地之值。

參考文獻

1. 楊樹榮、林忠志、鄭錦桐、潘國樑、蔡如均、李正利。臺灣常用山崩分類系統，第十四屆大地工程研討會，2011。
2. Alcántara-Ayala, I. (2002). "Geomorphology, natural hazards, vulnerability and prevention of natural disasters in developing countries." *Geomorphology* 47(2-4):107-124.
3. Chaudhuri, D., N. K. Kushwaha, A. Samal, and R. C. Agarwal. 2016. 'Automatic Building Detection From High-Resolution Satellite Images Based on Morphology and Internal Gray Variance', *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9: 1767-79
4. Gokceoglu, C. and E. Sezer (2009). "A statistical assessment on international landslide literature (1945–2008)." *Landslides* 6(4):345.
5. Lyamin, Andrei Vadimovich, and SW Sloan. 2002a. 'Upper bound limit analysis using linear finite elements and non-linear programming', *International Journal for Numerical and Analytical Methods in Geomechanics*, 26: 181-216.
6. Lyamin, AV, and SW Sloan. 2002b. 'Lower bound limit analysis using non-linear programming', *International Journal for Numerical Methods in Engineering*, 55: 573-611.
7. Ma, Haojie, Yalan Liu, Yuhuan Ren, and Jingxian Yu. 2020. 'Detection of Collapsed Buildings in Post-Earthquake Remote Sensing Images Based on the Improved YOLOv3', *Remote Sensing*, 12: 44.

8. Peduzzi, P., Deichmann, U., Dao, Q.-H., Herold, C., Chatenoux, B., De Bono, A. (2009). "2009 Global Assessment Report on Disaster Risk Reduction: patterns, trends and drivers."
9. Schuegraf, Philipp, and Ksenia Bittner. 2019. 'Automatic building footprint extraction from multi-resolution remote sensing images using a hybrid FCN', *ISPRS International Journal of Geo-Information*, 8: 191.
10. Theng, Lau Bee. 2006. 'Automatic Building Extraction from Satellite Imagery', *Engineering Letters*, 13.
11. Voulodimos, Athanasios, Nikolaos Doulamis, Anastasios Doulamis, and Eftychios Protopapadakis. 2018. 'Deep learning for computer vision: A brief review', *Computational intelligence and neuroscience*, 2018.
12. Zhang, Q., Y. Wang, Q. Liu, X. Liu, and W. Wang. 2016. "CNN based suburban building detection using monocular high resolution Google Earth images." In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 661-64.
13. Zhang, Qian-jin, and Lei Guo. 2007. "Self-enhanced SVM Extraction of Building Objects from High Resolution Satellite Images." In *Proceedings of the Second International Conference on Innovative Computing, Informatio and Control*, 13. IEEE Computer Society.
14. 林恩如、吳振佑、陳均維、林詠喬、陳國威、詹婉妤、林宥伯、林家興。立體地形圖 HOST MAP 及 CS MAP 判釋參考指引，行政院農業委員會水土保持局，2020。

15. Iqra Imtiaz, Muhammad Umar, Muhammad Latif, Rehan Ahmed, Muhammad Azam.2021.'Landslide susceptibility mapping:improvements in variable weights estimation through machine learning algorithms—a case study of upper Indus River Basin, Pakistan' . *Environmental Earth Sciences* (2022) 81:112.

