
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
**Application of deep learning techniques
to large-scale landslide identification based
on images**
(成果報告)

執行單位：台灣科技大學營建系

執行期間：111 年 01 月 18 日至 111 年 12 月 31 日

計畫主持人：李安叡 副教授

行政院農業委員會水土保持局 編印

中華民國 111 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

摘要

在對城市化和資源開發的需求不斷增長的時代，人們越來越擔心不穩定的氣候條件，環境安全問題則成為優先考量。隨著世界人口通過在現有地區過度開發或無人居住地區逐漸減少，越來越多的地質環境受到干擾，在這種情況下，自然災害是對人類生命和財產安全最具威脅性的影響之一。不同的自然災害造成不同型態的破壞，但更危險的是，它們往往會組合產生連鎖效應。當它們都疊加在一起產生複合型災害，然而這類災害卻不容易用單一解決方法或理論來處理。

雖然水保局已經規範坡地保育等相關要求，但台灣地質較為年輕及地形較陡峭，仍可能導致不可控的大規模崩塌產生的災害與財產損失。現行的挑戰對坡地監測與預警系統在於監測位置不一定準確設置在滑動面上，因此不一定能蒐集到足夠訊號達到預警效果。因此，本計畫旨在利用深度學習方法，利用圖像進行邊坡災害自動檢測。同時提供可能山體滑坡量及其影響範圍，此資訊可作為後續其他利用之參考。

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

Abstract

People are increasingly worried about unstable climatic conditions in the age of growing demand for urbanization and resource development, and environmental safety issues have become a priority. As the world population gradually decreases in existing regions or unmanned residential areas, more and more geological environments are disturbed. Natural disasters are one of the most threatening to human life and property safety. Different natural disasters cause different types of damage, but more dangerous is that they tend to combine chain effects. This disaster is not easily treated with a single solution or theory.

Although the Water Protection Bureau has regulated slope conservation and other related requirements, Taiwan's relatively young geology, and steep terrain may still lead to uncontrollable large-scale landslides resulting in disaster and property damage. The current challenge for slope monitoring and early warning system is that the monitoring location may not be accurately set on the sliding surface, and therefore may not be able to collect enough signals to achieve the early warning effect. Therefore, this project aims to use deep learning methods to automatically detect slope hazards using images. The information can be used as a reference for other applications later.

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

目次

摘要.....	I
Abstract.....	II
目次.....	III
表次.....	IV
圖次.....	V
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	3
第二章 工作項目與執行方法	1
第一節 深度學習技術遴選評估	1
第二節 文獻蒐集	3
第三節 現地調查以及試驗	9
第四節 圖資蒐集工作初步成果	25
第五節 圖資處理及模型訓練	36
第三章 工作進度	1
第一節 目前進度報告	1
第二節 期初審查意見問題與回覆	4
第三節 期中審查意見問題與回覆	6
第四章 結論	18
第一節 結論	18
參考文獻.....	19

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

(以下略)

圖次

圖(1-1)岩石邊坡之破壞形式 (Hoek & Bray, 2005).....	3
圖(1-2)自動滑坡檢測技術的深度學習模型架構.....	4
圖(2-1) 卷積神經網路(CNN)架構流程圖.....	4
圖(2-2)區域卷積神經網路(R-CNN).....	5
圖(2-3) Faster R-CNN 架構流程圖.....	5
圖(2-4) Fast R-CNN 架構流程圖.....	6
圖(2-5) Mask R-CNN 架構流程圖.....	7
圖(2-6)FCN 架構流程圖.....	7
圖(2-7) U-NET 架構流程圖.....	8
圖(2-8) 模型架構示意圖.....	9
圖(2-9) 阿里山青年活動中心聯外道路崩塌案位置示意圖.....	11
圖(2-10) 阿里山青年活動中心聯外道路崩塌案.....	11
圖(2-11) 灰色砂岩及頁岩互層為主的崩積層土壤.....	12
圖(2-12) 大崙山崩塌潛勢之位置示意圖.....	13
圖(2-13) 大崙山聯外道路崩塌案.....	13
圖(2-14) 頁岩互層為主的黃壤.....	14
圖(2-15) 阿里山地區 App 工具計算安全係數之結果.....	16
圖(2-16) 大崙山 App 工具計算安全係數之結果.....	16

圖(2-17) 地下水位及坡高示意圖.....	17
圖(2-18) 依各篩號土壤分類保存.....	18
圖(2-19) 製作試體.....	19
圖(2-20) 設置各項測量儀器於剪力儀.....	19
圖(2-21) 剪動速率為 1.5mm/min.....	20
圖(2-22) 阿里山地區直剪試驗剪應力-剪變形曲線.....	21
圖(2-23) 阿里山地區直剪試驗破壞包絡線.....	22
圖(2-24) 阿里山地區三軸試驗軸差應力-應變曲線.....	22
圖(2-25) 阿里山地區三軸試驗莫爾圓.....	23
圖(2-26) 大崙山直剪試驗剪應力-剪變形曲線.....	23
圖(2-27) 大崙山直剪試驗破壞包絡線.....	24
圖(2-28) ArcGIS 與 Python 之應用介面	26
圖(2-29) 基隆市圈繪區域.....	27
圖(2-30) 新北市圈繪區域.....	28
圖(2-31) 台北市圈繪區域.....	28
圖(2-32) 桃園區圈繪區域.....	29
圖(2-33) 新竹區圈繪區域.....	29
圖(2-34) 苗栗區圈繪區域.....	30
圖(2-35) 台中區圈繪區域.....	30

圖(2-36) 彰化區圈繪區域.....	31
圖(2-37) 南投區圈繪區域.....	31
圖(2-38) 雲林區圈繪區域.....	32
圖(2-39) 嘉義區圈繪區域.....	32
圖(2-40) 台南區圈繪區域.....	33
圖(2-41) 高雄區圈繪區域.....	33
圖(2-42) 屏東區圈繪區域.....	34
圖(2-43) 宜蘭區圈繪區域.....	34
圖(2-44) 花蓮區圈繪區域.....	35
圖(2-45) 台東區圈繪區域.....	35
圖(2-46) 標註圖層合併後結果.....	37
圖(2-47) 標註滑坡圈繪區域過大.....	37
圖(2-48) AutoGIS 使用界面.....	38
圖(2-49) AutoGIS 得出的標註圖.....	38
圖(2-50) 模型預測與實際滑坡部分.....	40
圖(2-51) 訓練以及驗證損失圖.....	41
圖(2-52) 公開資料集做 segmentation 結果---1.....	42
圖(2-53) 公開資料集做 segmentation 結果---2.....	42
圖(2-54) 衛星圖會因拍攝時間不同而使用拼裝.....	43

圖(2-55) 衛星圖拍攝當下多雲而無法顯示地貌.....	44
圖(2-56) 修改模型架構後預測與實際滑坡部分.....	44
圖(3-1) 期末報告流程圖.....	1
圖(3-2) 研究架構圖(綠色部分為未來規畫).....	2
圖(3-3) 訓練以及驗證損失圖.....	8
圖(3-4) AI 模型測到與實際滑坡部分.....	8
圖(3-5) 本計畫期中報告前之流程圖.....	9
圖(3-6) 模型架構示意圖.....	14

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中，大多數的邊坡不外乎是由土壤或岩石這兩種材料所組成，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。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	土
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, 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 2.1(a)。
- (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 2.1(b)。
- (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 2.1(b)。
- (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 2.1(d)。




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，以較低成本數據資源結合本團隊開發之AI邊坡安全評估手機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。本年度目標如下：

- 一、檢測滑坡之影像辨識深度學習技術開發與模型擬定(圖1-2)。
- 二、用於深度學習之邊坡數據(光達數值地型圖)採集及預處理。
- 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安全性



圖(1-2)自動滑坡檢測技術的深度學習模型架構

第二章 工作項目與執行方法

第一節 深度學習技術遴選評估

深度學習為機器學習及人工智慧的一部份，利用此法能處理及計算大量的資料，而深度學習也為數據科學中重要的一項因子，其中包含了統計及預測模型。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)。

初期針對用於自動滑坡檢測技術的幾種深度學習技術，包括卷積神經網絡(CNN)及基於區域的卷積神經網絡(Mask R-CNN)等.....，並且將比較不同的技術性能，利用本團隊先前在建物辨識及監督式學習的經驗中可對本計劃新開發的技術中其隱藏層數量及圖相框定做優化。將選擇具有最佳性能的模型作為基於山體滑動辨識的模型。在此階段，數據集預計將分為三個部分，70%用於訓練，驗證 20%，測試 10%。期望通過利用水保局 CS 地圖亦或是 HOST 地圖(20M、6M、1M)作為辨識基準來實施自動滑坡檢測的功能。

深度學習技術背景

現今軟體開發平台多元，為實現模型建立，本研究使用常用的開源軟體 Python 作為編程軟體，建立人工智慧演算法；Python 屬於免費軟體及商業軟體中工程常用的開發程式，內建的深度學習模組繁多且完整，適用於研究者分析規劃、程式設計及測試維護等功能，目前已廣泛應用於資料分析、數值計算與演算法開發等領域。本研究模型利用 Python 3.9.7 版進行開發與運算，建構於 Windows

10 環境中。

Python 由荷蘭的 Guido van Rossum 在 1991 年創造，近年來廣受各界青睞，更是熱門的程式語言之一。身為高階程式語言，Python 的程式代碼簡潔易懂且功能強大；除去標準的官方程式庫，因自身相容性很高的緣故，累積大量的非官方的程式庫插件，且具有跨平台的作業系統在 Linux 與 Windows 上都可運行，供程式開發者方便使用。其中，Keras 與 Tensorflow 為基於 Python 所建立的開放深度學習程式庫，已將訓練深度學習模型所需的輸入層、隱藏層、輸出層寫入，使用者透過調整層數及參數即可進行分析。

監督式學習

若想利用衛星像進行建物辨識，以往是利用監督式的機器學習從衛星影像中自動萃取建物並產生預期的結果，而這項技術通常需預先將訓練集提供給機器學習的演算法以供模型進行建物辨識(Theng 2006) (Schuegraf and Bittner 2019)。有些學者則提出利用不同機器學習的方法進行建物辨識；Chaudhuri 等人(Chaudhuri et al. 2016)形態學及內部灰色變異量(internal gray variance)研發一套自動建物辨識的系統，此技術適合應用在場景中的物件，利用空間及光譜的特性在光學相互作用下產生影像，步驟如下：(1)定向型態的增強(2)內部灰色方差基於多種子的聚類技術(multiseed-based clustering technique using internal gray variance) (3)陰影辨識(4)利用建物邊緣和陰影的位置信息減少誤報(5)自適應閾值的分割技術(adaptive threshold based segmentation technique)，結果顯示該技術既有效且準確。

另外由支持向量機所提出的建物辨識，其過程分為以下三個步


驟 (Zhang and Guo 2007)。首先，利用具有適應性的二維 Otsu 演算法將影像分為建物區及非建物區。其次，分割的區域利用二階高斯馬可夫隨機場進行模擬，其中包含了六個特徵向量元素。最後，在區域類別中利用支持向量機訓練特徵向量。不過此法受制於影像的比例及角度，且對於形狀及觀察位置也非常敏感。有鑑於此，近年來深度學習在建物辨識的發展上已呈現出不錯的成果(Ma et al. 2020) (Zhang et al. 2016)逐漸取代機器學習，不過大部分所提出的方法較適合應用在從衛星影像中進行辨識而非分割技術。

第二節 文獻蒐集

物體偵測(Object Detection)是影像處理中的一項技術，係以電腦分析影像中的物體，並標示出來，這需要大量的影像數據以神經網絡訓練它。物體偵測通常利用深度學習的演算法產生需要的結果，其中有卷積神經網路(CNN)、區域卷積神經網路(RCNN)、Mask R-CNN、Faster R-CNN 等，介紹如後。

一、卷積神經網路(CNN)


CNN 一直以來是深度學習中最重要的一部份，CNN 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)，圖 2-1 呈現卷積神經網路(CNN)架構流程圖，許多影像辨識的模型也都是以 CNN 的架構為基礎去做延伸，如 R-CNN、Fast R-CNN、Faster R-CNN、Mask R-CNN。簡言之，CNN 為利用一個核心濾鏡(Kernel) 針對原始影像，重新產生另一個簡化過的特徵影像 (Feature Map)，並提取影像特徵的新興自動識別方法。




圖(2-1) 卷積神經網路(CNN)架構流程圖

二、R-CNN技術


區域卷積類神經網路 (Region-based Convolutional Neural Networks, R-CNN)是最初的代表演算法之一 (Girshick et al., 2014)，此演算法的主要目標為利用 Region of Interest (RoI) 邊界框來進行物件偵測及評估 RoI 卷積類神經網路的精度，如圖 2-2 所示。因此 R-CNN 係使用稱為 RoIPool 的方法提升精度和計算速度，而後 Faster R-CNN 也加入了該方法，稱為區域提案網路 (Region Proposal Network, RPN) (Ren et al., 2015)，以影像作為輸入資料，並使用卷積類神經網路，輸出檔為矩形的目標框，如圖 2-3 所示。最後，每一個目標框都有分數，其中分數最高的框則為偵測演算法的目標物件。因此，Faster R-CNN 有穩定及算法更快的特性在各種應用領域中廣泛被使用。而 Fast R-CNN 也採用同樣的 Region of Interest (RoI) 邊界框，再提取特徵後加入 RoI Pooling 對整張圖像擷取對應的特徵，最後在完全連接層利用 softmax 和線性迴歸層同時返回邊界框，相較於 R-CNN 只用一個模型就實現特徵提取及分類(如圖 2-4)。



圖(2-2)區域卷積神經網路(R-CNN)




圖(2-3) Faster R-CNN 架構流程圖



圖(2-4) Fast R-CNN 架構流程圖

三、Mask R-CNN 技術


Mask R-CNN 是一種能夠有效地檢測圖像中的物件,同時為每個案例生成高品質 segmentation mask 的技術。Mask R-CNN 是 Faster R-CNN 的延伸技術,不同之處在於 Mask R-CNN 自 Faster R-CNN 演算法中之 RoI 步驟裡新增預測遮罩(Mask)區域面積的方法,增加些微計算量標記出目標物件的輪廓,同時在不影響演算法精度的條件下,保持穩定的運算速度,相較於 Faster R-CNN,Mask R-CNN 多了一個分支(如圖 2-5),這個分支用於預測 object mask 與現有分支並行進行邊界框識別。



圖(2-5) Mask R-CNN 架構流程圖

四、FCN (全卷積網路) 技術


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(2-6) FCN 架構流程圖


五、U-NET 技術:

U-NET 與傳統 FCN 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，整體以 Graph model 呈現會形成一個 U 型網路，故稱 U-NET。



圖(2-7) U-NET 架構流程圖

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，並以語意分割(Semantic Segmentation)技術來實現，下圖(2-8)為本計畫的模型架構示意圖：



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。

本計畫執行嘉義地區以及石碇山區邊坡現場調查工作，以


下將統整此次行程之結果。

(一)出發前準備工作

本次調查將前往嘉義阿里山地區以及台北石碇山區進行邊坡調查，然而該地區邊坡數量眾多，為有效掌握本計畫只要研究對象「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案位置示意圖



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) 大崙山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)APP 技術

圖(2-15)、(2-16)為本團隊現地勘查時所用之 APP，此 APP 以數值分析軟體分析而得之結果作為訓練 AI 模型之數據，透過撰寫 iOS 介面，使工程師在無法連接上網路之情境，也能快速與有效的概估該邊坡之安全性。

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(2-17) 包含 β 坡角 (slope angle) 和 H 坡高 (slope high)， H_w/H 則表示地下水位。


關於現地勘查，本團隊以具滑動跡象之邊坡作為案例 (共兩處，一處位於阿里山地區，而另一處位於石碇地區)，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 (2-15)和圖(2-16)。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(2-15)，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。而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(2-16)，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。



圖(2-15) 阿里山地區 App 工具計算安全係數之結果



圖(2-16) 大崙山 App 工具計算安全係數之結果



圖(2-17) 地下水位及坡高示意圖

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(2-18) 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(2-19) 製作試體



圖(2-20) 設置各項測量儀器於剪力儀



圖(2-21) 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(2-22) 阿里山地區直剪試驗剪應力-剪變形曲線

如圖(2-22)，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(2-23)，求出的 c 接近 0，而 $\phi = 38^\circ$ 。




圖(2-23) 阿里山地區直剪試驗破壞包絡線

●三軸試驗



圖(2-24) 阿里山地區三軸試驗軸差應力-應變曲線




圖(2-25) 阿里山地區三軸試驗莫爾圓


圖(2-24)、(2-25)為三軸試驗的結果，可得到其 $c=0$ ， $\phi=34.7^\circ$

(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， $\phi = 41^\circ$

至於三軸試驗的部分，目前也正在進行當中，將會在期末現場報告附上數據。


第四節 圖資蒐集工作初步成果

本計畫旨在透過影像辨識對「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。

本計畫擬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，該圖資可在 ArcGIS 商用軟體中開啟.shp 檔並初步以水保局全台 CS 地圖做為底圖進行套疊做深度學習技術開發用。

一、圖資應用軟體

ArcGIS 由美國的 ESRI 公司於 1997 年開發，將地理空間的各種資訊模版化，可以將該系統視為一個繪製地圖與地理信息的基礎架構，可以新增任何底圖，並在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(2-28)。




圖(2-28) ArcGIS 與 Python 之應用介面


圖資蒐集與整合

本計畫透過光達數值地表模型圖並經圈選後的已崩塌或未崩塌之特徵，利用深度學習模型大量訓練此一圈選特徵來建立辨識系統，光達數值地表模型圖相較於傳統的光學或正射影像較不受植被影響，並且可以完整表現出地表的特徵，本計畫欲使用水保局 CS 地圖亦或是 HOST 地圖做為訓練及驗證用的圖資。


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。本計畫展示圖資套疊及應用成果如下圖(2-29)~(2-45)，主要分類為各縣市的山崩與地滑地質敏感區及水保局 CS 地圖套疊圖資。本計畫的研究區域主要就是以可能崩塌範圍為目標，為使深度學習之模型達到一定的精準度需要大量的圖資進行訓練，後續將進行研究如何裁切全島的樣張使電腦進行學習，而今年度原先計畫之分析挑選中台灣之山坡地為研究及驗證區域，但發現中台灣的圖資數量不夠，因此本團隊決定直接使用全台灣的資料一起進行。




圖(2-29) 基隆市圈繪區域



圖(2-30) 新北市圈繪區域




圖(2-32) 台北市圈繪區域




圖(2-32) 桃園區圈繪區域




圖(2-33) 新竹區圈繪區域




圖(2-34) 苗栗區圈繪區域




圖(2-35) 台中區圈繪區域




圖(2-36) 彰化區圈繪區域




圖(2-37) 南投區圈繪區域




圖(2-38)雲林區圈繪區域




圖(2-39) 嘉義區圈繪區域




圖(2-40) 台南區圈繪區域



圖(2-41) 高雄區圈繪區域



圖(2-42) 屏東區圈繪區域



圖(2-43) 宜蘭區圈繪區域



圖(2-44) 花蓮區圈繪區域



圖(2-45) 台東區圈繪區域

第五節 圖資處理及模型訓練

一、圖資處理


本計畫原先以精度 1m 之水保局 CS 及 HOST 地圖為基準進行後續流程。而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，而原先使用 CS 及 HOST 地圖則為尚可，因此本團隊加入 ArcGIS 提供之衛星圖做為輸入圖資之一進行實驗。

同時參考相關論文[15]提到繪製滑坡敏感圖，將使用 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。

在圖資進行訓練前，圖資處理是相當重要的步驟，本計畫原先利用 ArcGIS 內部資料進行合併圖層(圖(2-46))，但 ArcGIS 本身無法輸出多個圖層資料，並且裁切圖資的部分無法調整地圖比例尺，使圖資上有滑坡的圈繪的區域過大，容易使模型無法判釋滑坡與非滑坡之差異，如圖(2-47)。基於此，本團隊需另外找尋其他方式來解決。

經過討論，本團隊開發出一套新的資料標註系統-AutoGIS，其界面可參考圖(2-48)，可點選我們需要的輸入層，電腦便會掃描出需要的圖層，本次期末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)，而此軟體亦可掃描輸出多種圖層資料。界面的 Create Label 按鈕(圖(2-48)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(2-49)，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(2-46) 標註圖層合併後結果



圖(2-47) 標註滑坡圈繪區域過大



圖(2-48) AutoGIS 使用界面



圖(2-49) 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，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預處理，如轉置、平移等，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


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

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

輸入層有 CS Map、HOST Map、衛星、水文、高程資料以及滑坡圈繪資料。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

本次計畫輸出驗證結果如下圖(2-50)，圖(2-50a)為驗證集原圖，圖(2-50c)為實際滑坡的部分(Ground Truth)，圖(2-50b)為模型預測出來的結果。可以發現實際滑坡面積非常大，模型只有預測邊緣的部分，雖說其中一小部分有被偵測，但整體效果仍然不佳。




圖(2-50) 模型預測與實際滑坡部分

除了上述輸出的結果圖不佳之外，我們以數據量化的方式呈現，如圖(2-51)訓練以及驗證損失圖所示，橘色線以及藍色線部分分別為驗證、訓練損失函數，無論是訓練還是驗證損失，收斂情形不甚理想，將所有訓練樣本訓練 50 次(Epoch = 50)時，損失曲線(loss function)上的數值仍然在 0.4 ~ 0.5 之間，亦即精度大約只有一半，結果不甚理想。雖有收斂趨勢，但本次訓練本團隊使用台灣高速網路與運算中心的台灣杉設備，訓練一輪(50 epoch)大約要一週，在收斂不佳的情形，多做訓練只是多花時間金錢，對於結果沒有太大的助益。




圖(2-51) 訓練以及驗證損失圖

為找出訓練成效不彰的原因，同樣模型使用 U-Net 作為架構之骨幹，小幅修改其中架構，來實現其他資料。本團隊使用網路上的公開資料集，將這些資料輸入模型當中，其成果如下圖(2-52)、(2-53)



圖(2-52) 公開資料集做 segmentation 結果---1



圖(2-53) 公開資料集做 segmentation 結果---2

上兩張圖(2-52)、圖(2-53)在大部分街景中的物件辨識皆準確，甚至連雜訊較多的影像也能辨識出物件大部分輪廓，此模型分辨得相當理想。

基於使用不同的資料集，其辨識的成果相當好，可以判斷滑坡訓練成效不彰的原因有可能是圖資的部分，目前我們圖資資料的部分有 600 筆，經過資料的擴增(如轉置、平移等)，大約有數千筆的資料可以做為訓練圖資，或許增加圖資資料能夠使結果更好。

另外也有可能是 ArcGIS 內的 HOST Map、CS Map 以及衛星圖發生的時間有所差異，若是拍攝到較晚期的衛星圖，可能已經在滑坡圈繪區域滑落過，因此衛星圖會測不到滑坡，導致影響訓練結

果。或是有些衛星圖本身圖資並不是太理想，例如不同時間拍攝的拼裝在一起，如圖(2-54)，以及拍攝當下有多雲，無法完整呈現地貌，如圖(2-55)。後者部分本團隊也預計將不理想的衛星圖資汰除掉，試試看會不會提升精度，若依舊起色不大，將捨棄掉衛星圖圖層。




圖(2-54) 衛星圖會因拍攝時間不同而使用拼裝



圖(2-55) 衛星圖拍攝當下多雲而無法顯示地貌

除了衛星圖的部分，本團隊也將對於其他圖層進行逐一的測試，若是效果相較其他圖層有明顯落差也會將其汰除掉，同時，本團隊在模型架構中進行修改，以同圖(2-52)、(2-53)之模型架構進行滑坡的實作，結果可如圖(2-56)



圖(2-56) 修改模型架構後預測與實際滑坡部分


圖(2-56)中預測結果(Prediction)已經與實際滑坡發生地區(Ground Truth)有相似之處，大致上大範圍的潛勢崩塌區已能辨識輪廓，與前次預測(如圖(2-50))有明顯進步，而目前僅針對資料進行訓練及預測，尚未進行精度統計，更改模型架構後訓練中所使用的參數本團隊尚在整理當中，將於期末現場報告提及。

第三章 工作進度


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 目前進度報告

本計畫於本期末報告中文獻蒐集已達原本預定之進度，同時將模型技術背景以 U-Net 架構擬定，其中架構部分需要小幅修改，呈獻的結果也許會更好。圖資部分目前已有 CS Map、HOST Map、衛星、水文以及高程，未來也將預計加入 FS 圖層以求訓練精度更加。下圖(3-1)為本計畫到目前為止之流程圖，圖(3-2)為本計畫研究之架構圖以及表(3-1)預定進度表以供參考。



圖(3-1) 期末報告流程圖



圖(3-2) 研究架構圖(綠色部分為未來規畫)

重要工作項目	工作比重%	預定進度	111			
			1-3 月	4-6 月	7-9 月	10-12 月
現地調查	20	工作量或內容	無	嘉義地區現勘	中部地區現勘	北部地區現勘
		累計百分比	0	40	80	100
文獻蒐集	15	工作量或內容	文獻蒐集	文獻蒐集	文獻蒐集	文獻蒐集
		累計百分比	30	70	100	100
技術開發與模型擬定	25	工作量或內容	技術開發	模型擬定	模型擬定	模型擬定
		累計百分比	30	70	80	100
圖資模型訓練及案例驗證	30	工作量或內容	無	圖資模型訓練	案例驗證	成果整合
		累計百分比	0	55	85	100
報告與論文撰寫	10	工作量或內容	無	無	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

期初報告繳交後，本計劃執行將規劃嘉義區的現勘計劃，並於期中之後進行第二個現勘，地點為大崙山，以確保期末之執行進度，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。此現勘與圖像辨識所需的影像無關，但是此現勘所取得的參數可用於辨識後做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；對於目前擁有的已圈繪圖資將探討如何裁切或進行資料增強達適當的尺寸及畫素以供前述所開發之模型進行訓練快速的抓取並量化各項特徵；提前進行案例驗證並持續完成文獻蒐集之工作。

本計畫將於期中報告繳交後持續進行圖資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。同時將進行第二次的現地調查計畫進一步提升將 APP 工具應用於現地坡檢之流程並完成前一次調查中取樣之土壤的試驗。依照進度安排於計畫執行期限內已完成本年度預定目標。

第二節 期初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、開闢度和坡度、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。

第三節 期中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(3-2)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 loss30%，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(3-3)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，而以圖(3-4)來看，驗證結果跟基準真相(Ground truth)亦是差

異極大。




圖(3-3) 訓練以及驗證損失圖



圖(3-4) 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(3-5)。



圖(3-5) 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(3-3)、圖(3-4)，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(3-2)、圖(3-3)，圖(3-2)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(3-3)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(3-6)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(3-6) 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。

第四節 期末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。

第四章 結論

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%，後續工作內容將針對兩處的現地調查進行排程，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 55% 左右，後續將訓練集圖資處理方式擬定後將進行大量訓練，待本內容完成後對其結果進行驗證。同時挑選山坡地結合 APP 工具進行安全評估。後續將按進度表之規劃持續進行。

期末報告已達到預計之進度，並且有訓練的成果，而要使成果更好，下期計畫能夠多增加 FS 圖層以及再修改模型架構，期望能夠有更準確的結果。

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.