
**坡地災害辨識電腦視覺模式精進
與應用評估**

**Improvement of computer vision model for
slope land disasters identification based on
existing closed-circuit television system
and the assessment of application
(成果報告)**

執行單位：逢甲大學

執行期間：112年02月08日至112年12月31日

計畫主持人：陳昶憲 特聘教授

農業部農村發展及水土保持署 編印

中華民國 112 年 12 月

(本報告書內容及建議純屬執行單位意見，僅供本局施政參考)



坡地災害辨識電腦視覺模式精進

與應用評估

摘要

本研究續以農業部農村發展及水土保持署創新研究計畫案「電腦視覺於坡地災害應用先期研究」(計畫編號：SWCB-111-059)之成果基礎上，以實務應用為目標擬定三大目標精進電腦視覺於坡地災害辨識模式並予以實踐應用。本研究首以進行坡地災害影像資料庫樣本之精煉作業，將樣本資訊聚焦於災害重點區域；其二探討深層網路於坡地災害辨識能力並建置穩健之深度學習模式；最後根據辨識模式及實際應用需求建構即時 CCTV 坡地災害監測網站。

本研究完成坡地災害影像資料庫精煉化作業並進行 LRCN 架構下之各模式(LSTM+CNN、LSTM+VGG16、LSTM+VGG19 及 LSTM+ResNet)之測試，根據測試結果證實經由影像聚焦於坡地災害特徵可提升模式訓練之精準度；於深層網路坡地災害辨識能力上，深層網路 ResNet 在有限資源訓練下的辨識能力可達(90.57%)優於 LSTM+CNN、LSTM+VGG16、LSTM+VGG19，在驗證影像上也能正常辨識出坡地災害，但其所需之訓練成本(時間與 GPU 資源)也相對較高；於模式的實際應用上，本研究已建構 CCTV 坡地災害監測網之頁面架構，完成本研究在現有 CCTV 資源架構下加值 CCTV 應用價值之目的，本研究所設計之坡地災害電腦視覺辨識模式及其應用架構，可提供相關研究之設計參考。

關鍵詞：電腦視覺、影像辨識、深度學習、坡地災害監測



Improvement of computer vision model for slope land disasters identification based on existing closed-circuit television system and the assessment of application

Abstract

This study builds upon the achievements of the innovative research project "A study on the establishment of computer vision for disaster identification based on existing closed-circuit television system" (Project Code: SWCB-111-059) by the Soil and Water Conservation Bureau. With practical applications as the objective, this research aims to enhance the computer vision-based slope disaster recognition model and implement it in practice. The study initially refines the sample data in the slope disaster image database, focusing on crucial disaster areas. Secondly, it explores the capabilities of deep neural networks in slope disaster recognition and establishes a robust deep learning model. Finally, based on the recognition model and practical application requirements, an real-time CCTV slope disaster monitoring website is constructed.

This study has refined the image database for slope disaster research and conducted tests on various models within the LRCN framework (LSTM+CNN, LSTM+VGG16, LSTM+VGG19, and LSTM+ResNet). According to the results, focusing image analysis on the characteristic features of slope disasters can enhance the precision of model training. In terms of the capability of deep learning networks to recognize slope disasters, the deep learning network ResNet exhibited superior recognition abilities (90.57%) under limited resource training compared to

LSTM+CNN, LSTM+VGG16, and LSTM+VGG19. It also reliably identified slope disasters in validation images. However, the training costs (time and GPU resources) required for ResNet are comparatively higher. In practical applications, this research has established a structural framework for a CCTV slope disaster monitoring network, enhancing the application value of existing CCTV resources. The computer vision recognition model for slope disasters designed in this study, along with its application architecture, can provide a reference for the design of related research.

Keywords: computer vision, image recognition, deep learning, slope disaster monitor



目次

摘要.....	I
Abstract.....	III
目次.....	V
表次.....	VII
圖次.....	VIII
第一章 前言.....	1-1
第一節 計畫緣起與目的	1-1
第二節 計畫目的	1-1
第三節 計畫工作項目	1-2
第四節 研究方法	1-2
第二章 工作方法及步驟.....	2-1
第一節 文獻探討	2-1
第二節 坡地災害影像庫樣本精煉	2-3
第三節 電腦視覺坡地災害辨識模式與精進	2-6
第四節 影像資料蒐集自動化	2-7
第五節 線上即時坡地災害影像觀測系統功能與雛型建構 ..	2-12
第三章 工作進度與交付項目	3-1
第一節 計畫甘特圖	3-1
第二節 計畫交付項目	3-3
第四章 期末成果	4-1
第一節 坡地災害影像庫樣本精煉成果	4-1
第二節 電腦視覺坡地災害辨識模式與精進成果	4-11
第三節 影像資料蒐集自動化成果	4-25
第四節 線上即時坡地災害影像觀測系統建構成果	4-27

第五章 結論與建議	5-1
第一節 結論	5-1
第二節 建議	5-3
參考文獻	參-1
附錄	附錄-1
附錄一、期初審查會議紀錄回覆辦理情形	附錄-1
附錄二、期中審查會議紀錄回覆辦理情形	附錄-4
附錄三、期末成效評核及審查意見回覆辦理情形	附錄-10



表次

表 2-1	網路媒體影像資訊	2-4
表 2-2	OpenCV 物件追蹤演算法	2-5
表 2-3	ResNet 不同深度架構.....	2-6
表 2-4	農村水保署土石流潛勢溪流監測站資訊	2-7
表 2-5	公路總局道路監視影像資訊	2-9
表 3-1	預定執行工作進度表	3-2
表 3-2	精煉影像資料庫結構	3-3
表 3-3	各模式最佳成果檔案對照	3-4
表 4-1	類別編號.....	4-2
表 4-2	訓練影像精煉成果	4-2
表 4-3	訓練樣本組合	4-10
表 4-4	各模式使用精煉前、後樣本比較	4-11
表 4-5	模式調校參數組合	4-13
表 4-6	參數調校成果	4-13
表 4-7	LSTM+ResNet 訓練成果.....	4-21
表 4-8	LSTM+ResNet50 辨識成果.....	4-22
表 4-9	地圖平臺介接電子地圖樣式	4-29
表 4-10	模式實際應用於 CCTV 辨識成果.....	4-32
表 5-1	精煉影像訓練成果比較	5-1
表 5-2	模式調校參數組合成果比較	5-1

圖次

圖 1-1	本研究流程圖	1-3
圖 2-1	影像精煉程序與成果示意圖	2-5
圖 2-2	Javascript 程式碼片段範例	2-11
圖 2-3	電腦視覺災害決策平臺架構初稿	2-12
圖 4-1	LSTM+ResNet 架構.....	4-21
圖 4-2	擷錄影像儲存資料夾結構與內容	4-25
圖 4-3	系統工作排程器固定執行影像爬蟲作業	4-26
圖 4-4	農村水保署 CCTV 開放資料 json 格式示意	4-28
圖 4-5	Sqlite 資料庫儲存示意	4-28
圖 4-6	CCTV 列表與操作介面	4-28
圖 4-7	網頁服務平臺介面	4-31
圖 4-8	跳出視窗呈現成果	4-31



第一章 前言

第一節 計畫緣起與目的

本研究為農業部農村發展及水土保持署（以下簡稱農村水保署）2022 年補助之「坡地災害辨識電腦視覺開發之研究」成果延伸研究，前期研究在大署的致力協助下，已能成功完成既有坡地災害類別的影像識別，但在實務應用上，仍須考量既有監控攝影機(closed-circuit television, CCTV)的取樣速度(包含即時傳輸)、影像品質，以及除了辨識標的(災害)以外、而可能誤判為災害的影像類別，做進一步的分析與模式的調教，以「瞭解坡地災害辨識電腦視覺開發研究」，可能受到的物理或模式極限限制，並提出可能的克服方法，為實務應用上最後一哩路的鋪陳。

於先期計畫以 CNN、VGG-16 及 VGG-19 等不同深度之卷積網路架構進行測試，在成果中透過 Grad-CAM 可視化模式觀注熱區發現各模式所專注之區域各有所異同，因此於今年度計畫中，本研究欲嘗試更複雜且深層的深度學習網路殘差神經網路 (Residual Network, ResNet) 進行精進研究，最後透過網路服務方式實測模式的整體運作，並建置網頁服務探討系統在實際應用上的可行性。

第二節 計畫目的

本研究為持續精進坡地災害辨識電腦視覺模式並延續「坡地災害辨識電腦視覺開發之研究」所提之三大問題再加以深入。

一、政府單位為能防範重大災情，各重大排水渠道、橋樑、河川、國道及省道皆陸續架設CCTV監視設備以行監控，在眾多的即時影像呈現中，坡地災害發生的進程卻不易在同步的多鏡頭前以肉眼

監控過程發現，並進而發出警訊；因此，若在以不變更現有硬體架構前題下，透過軟體手段提升現有監視系統並賦予坡地災害辨識能力，於災時得以即時提供示警，是值得解決的問題之一。

二、配合第一項目，得以提升現有監視系統資訊，快速且有效掌握災害地區現況，得以有效運用有限資源，為決策者所關切重點及當前所需，於即時提供災害規模影像予以下達決策，防止災損擴大，前題是需有系統介面可提供相關情資，因此規劃建構符合坡地情資研判需之介面是值得討論的課題。

三、藉由應用情境設計進行所建構之模式應用性與發展性之探討。

第三節 計畫工作項目

依據本研究緣起及目的，本研究擬行之工作項目如下：

- 一、坡地災害影像資料庫樣本精煉 (refinement)。
- 二、精進坡地災害電腦視覺辨識模式與發展。
- 三、探討基於網頁服務之線上即時坡地災害影像觀測系統功能與離型建構。

第四節 研究方法

本研究根據計畫工作項目與需求，規劃本研究流程(如圖 1-1 所示)並以對應章節進行撰述；首先就坡地災害辨識電腦視覺開發之研究所建構之坡地災害影像資料庫之影像透過 OPENCV 提供之影像追蹤演算方式進行精煉化作業，使影像庫內之影像更聚焦於坡地災害本體，除了原有之影像外，本研究持續進行蒐集農村水保署、交通部公路總局所公開之 CCTV 資訊及網路媒體所發布之坡地災害影像並發

展自動化爬蟲程式，以完成年度項目(1)之需求；同時透過文獻探討，探究現有常見的深度學習架構與具備時間與空間相關之卷積網路架構或方法，以修正或提出坡地災害行為辨識模式，並配合項目(1)之成果完成年度目標(2)；在完成項目(1)與項目(2)之目標時即可解決擬解決問題 1 與 2，本研究再使用網頁服務平臺建置達到項目(3)所需之介面平臺並予以完成擬解決問題 3 之需求，藉以達到智慧型坡地災害監測之目標。




圖 1-1 本研究流程圖



第二章 工作方法及步驟

本章內容將就研究方法中所述之項目進行詳細說明，各項目之實際操作步驟分述於下：

第一節 文獻探討

本研究蒐集國內、外在電腦視覺及坡地災害監測等相關文獻進行歸納與探討，藉由相關著作、學術論文、期刊、政府出版品、報章雜誌與網路資料等文獻，進行閱覽、整理、描述、分類、歸納及分析，瞭解現有電腦視覺及坡地災害監測上的應用與方法限制，從中探討深度學習於電腦視覺模式發展之方向。

深度學習於影像識別上主要係以卷積神經網路 (Convolutional Neural Network, CNN) 為核心架構，由於影像辨識多屬於歐式空間問題，因此 CNN 能夠很輕易且有效地進行演算與解決，但面對日趨複雜的影像辨識問題，逐漸由淺層網逐步邁向深層網路，而深度學習模式主要是於 2012 年由 Alex 學者所提出後極其迅速發展，在新的技術被提出時，皆伴隨新的網路架構及更深的網路訓練方法，在圖像辨識領域中創造新的準確率紀錄，CNN 能如此蓬勃發展也有賴於圖形處理器 (Graphics Processing Unit, GPU) 計算能力的支持及便利的開源工具 (例如 Tensorflow、PyTorch) 提供各式神經網路的建置與實踐，讓研究人員進行研究、測試、部屬乃至實用。在深度學習部分可分為影像預處理 (data pre-processing stage)、訓練 (training stage)、測試 (testing stage) 等三階段 (Kuo, 2016)，其影像預處理階段分為影像處理與資料增強處理，透過該階段測試模式對推論目標所需的特徵類別與個數，以提升模型效能；訓練階段以前置影像處理，建置 ResNet CNN 模型，以前兩階段方式重複操作，直到模型達到合理精確度完

成 ResNet CNN 模型；模型建置完成後，針對未參與模式訓練的影像，亦即測試資料 (testing data)，透過建置完成的模式，就影像進行特徵提取後進行推論目標值 (即為 CCTV 影像內容辨識) 的推論。

在電腦視覺發展上，目前以單一影像中之內容物為主要辨識標的，故需透過大量物品影像資料輔助深度學習模式進行物品特徵訓練，但在現實狀況上往往會碰到訓練影像不足問題，針對影像資料缺乏問題進而發展出各種生成對抗網路 (Generative Adversarial Network, GAN) 模型臨摹真實資料以擴充訓練資料，但生成對抗網路所產製之成果一樣需使用大量樣本進行訓練，根據 NVIDIA 的經驗通常是需要 5-10 萬張影像才能夠訓練出一個高品質的 GAN 模型 (Salian, 2020)，其提出自適性鑑別增強技術 (Adaptive Discriminator Augmentation, ADA) 進行少量樣本影像的旋轉、縮放、色偏、降尺度等以擴增影像資料集，但還是需要有千張影像作為基礎，此數量對坡地災害影像而言仍是個不容易達到的目標。此外，深度學習模式已逐漸由單一影像內容物辨識提升至串流影像的行為辨識，也就是由空間尺度提升至時間與空間尺度，可透過一連串的影像內容識別人類行為 (Shiranthika et al., 2020) 或火災災害的偵測 (Nguyen et al., 2021)，而災害的發生也具備時間與空間上的行為變異特性，綜上敘述，本研究採用串流影像辨識技術發展電腦視覺坡地災害辨識模式。

在網路的演化上 LeNet (Yann LeChun et al, 1998)、AlexNet (Alex Krizhevsky et al., 2012)、VGGNet (Karen Simonyan et al., 2014)、GoogleNet (Christian Szegedy et al., 2014)、ResNet (Kaiming He et al., 2015)，網路越深層越複雜，其使用之參數量高與所需之運算資源、成本也相對提升，但網路越深並不表示能取得更高之準確度，主要係因為原始的 CNN 架構在逐步加深網路層級時會產生退化問題

(Degradation problem)，Kaiming He 等人於 2015 年所發表的深度殘差網路 (Deep Residual Network) 有效解決網路深度所導致退化問題並提出 ResNet 架構，其使網路深度可達到 34、50、101 及 152 層之深，在殘差網路概念提出後有各式變形模式被提出，Ke Zhang(2017) 以殘差網路建立 RoR (Residual Networks of Residual Networks) 多層級殘差網路；Saining Xie(2017) 將 ResNet 結合了 GoogleNet 的核心 Inception 結構 (Christian Szegedy et al., 2014) 提出 ResNeXt，在不增加參數的前題下提高了電腦視覺的辨識準確度。ResNet 的應用相當廣泛，Adelisa Sirco 等人 (2022) 比較 ResNet-18、ResNet34、ResNet-50 及 ResNet-101 在電腦斷層掃描影像肝臟腫瘤；在災害辨識上所使用之影像更為多元，Danu Kim 等人 (2022) 透過前、後期衛星影像進行洪水災害後建物損害之辨識。

第二節 坡地災害影像庫樣本精煉

本研究首先根據前期研究所蒐集之網路災害影像資料 (摘錄部分影像如表 2-1 所示) 進行災害聚焦作業，將影像內容盡量聚焦於坡地災害本身，藉此降低環境雜訊對模式學習之干擾，並完成坡地災害影像庫樣本的精煉作業。本研究以 Python 程式進行開發，以 OpenCV 所提供之單物件追蹤元件進行功能開發，初始得以人工方式進行區域標註後，便可由演算法進行自動追蹤與範圍框選，再擷錄框選範圍內之災害影像並另存為新的訓練影像，整體程序與成果產出意如圖 2-1 所示，OpenCV 提供 BOOSTING、MIL、GOTURN、TLD、MEDIANFLOW、KCF、MOSSE 及 CSRT 等八大追蹤演算法，各類演算法之比較如表 2-2 所示，本研究以速度快且精準度最高之 CSRT 作為追蹤方法。

表 2-1 網路媒體影像資訊

類型	來源	影像內容			
土石流	TikTok				
落石	Youtube				
滑坡	Youtube				
					



圖 2-1 影像精煉程序與成果示意圖

表 2-2 OpenCV 物件追蹤演算法

演算法	速度	精準度	說明
BOOSTING	慢	差	元老級追蹤器，速度較慢，並且不是很準確。
MIL	慢	差	比 BOOSTING 更精確，但仍然不是很準確。
GOTURN	中	中	需要搭配深度運算模型才能運作的追蹤器。
TLD	中	中	速度普通，精準度普通的追蹤器。
MEDIANFLOW	中	中	對於會跳動或快速移動的物件，判斷不是很準確。
KCF	快	高	不錯的追蹤器，但在物件被遮蔽的狀態下不是很準確。
MOSSE	最快	高	速度最快，但精準度比 KCF 和 CSRT 稍差。
CSRT	快	最高	精準度比 KCF 好，但速度比 KCF 慢。

資料來源：<https://steam.oxxostudio.tw/category/python/ai/ai-tracker.html>

第三節 電腦視覺坡地災害辨識模式與精進

根據文獻回顧結果，本研究新增 ResNet 網路架構進行坡地災害辨識，並以精煉後之影像進行先期計畫所建置之 LRCN 模式 (LSTM+CNN, LSTM+VGG16 and LSTM+VGG19) 及今年度新增之 LSTM+ResNet50 模式進行辨識能力比較及透過調整超參數來取得最佳之參數組合，參數部分以影像大小、影像序列長度、訓練 epoch 數、學習速率四個面向進行測試。ResNet 架構依然係以卷積概念為基礎進行網路設計，其設計名為「bottleneck」結構，降低了 3x3 卷積寬度且大幅減少運算量，開啟深度學習網路的可行性，ResNet 架構有 18、34、50、101 及 152 層不同深度的設計，各種深度的網路架構如表 2-3 所示，深度愈深其所需的參數量也愈高，因此對於運算的硬體設備需求也愈高，在實踐上本研究以 Tensorflow 所提供之 ResNet-50 模型結合 LSTM 進行建模。

表 2-3 ResNet 不同深度架構

Layer name	Output size	18-layer	34-layer	50-layer	101-layer	152-layer
Conv1	112 × 112	7 × 7, 64, stride 2				
		3 × 3 max pool, stride 2				
Conv2_x	56 × 56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
Conv3_x	28 × 28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
Conv4_x	14 × 14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
Conv5_x	7 × 7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1 × 1	Average pool 1000-d fc softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

資料來源：修改自 Kaiming He (2015)。

第四節 影像資料蒐集自動化

本研究基於前期研究所蒐集之農村水保署觀測站資料展示平台及交通部公路總局智慧化省道即時資訊服務網所公開的 CCTV 進行影像蒐錄作業自動化，今年度以農村水保署觀測站資料展示平台 CCTV 影像為主要蒐錄對象，交通部公路總局之 CCTV 根據情形進行蒐錄作業。其中農村水保署觀測站資料展示平臺中計有 24 處(其中明霸克露橋工區僅提供雨量計資訊)，原計有 60 支 CCTV，於今年度更新後支數為 59 支(其中缺少的攝影機為豐丘下游 CCTV)，影像之解析度為 704*480，其主要以圖片輪播方式，以約 30 秒為單位擷取 1 張影像，並播放 5 分鐘內之畫面，土石流潛勢溪流監測站資訊如表 2-4 所示；交通部公路土石流總局智慧化省道即時資訊服務網 CCTV 部分，主要係以臺中市轄內台 8 線與台 7 甲線延線之 CCTV 影像作為監測對象，其提供之 CCTV 為串流影像，以每秒播放現場影像，本研究擇山區路段之 CCTV 作為坡地災害監測影像來源，共計有 13 支，影像資訊如表 2-5 所示。今年度本計畫以觀測站資料展示平台所提供之 CCTV 為主要影像蒐集對象，故以觀測站資料展示平台所提供之 CCTV 網頁內容所取得本文中之 Java Script 程式片段(示意如圖 2-2 所示)，並解析取得影像資源變數 (PKList) 與時間變數 (CDateList)，再讀取影像資源後儲存於系統本機端，以供坡地災害辨識模式使用。

表 2-4 農村水保署土石流潛勢溪流監測站資訊

監測站	土石流潛勢溪流編號	SID	CID	X	Y
白布帆-全景式攝影機	苗縣 DF058	1	2	120.9056	24.29807
九份二山-中游攝影機	投縣 DF101	2	1	120.8552	23.95073
九份二山-上游攝影機	投縣 DF101	2	3	120.8561	23.95028
九份二山-下游攝影機	投縣 DF101	2	6	120.8569	23.95199

監測站	土石流潛勢溪流編號	SID	CID	X	Y
神木-霍蔭攝影機	投縣 DF199	3	1	120.8564	23.52833
神木-愛玉子溪下游攝影機	投縣 DF199	3	3	120.8564	23.52833
神木-出水溪下游攝影機	投縣 DF199	3	4	120.8602	23.5267
神木-出水溪上游攝影機-1	投縣 DF199	3	6	120.8603	23.52659
神木-出水溪上游攝影機-2	投縣 DF199	3	7	120.8603	23.52655
神木-愛玉子溪上游攝影機	投縣 DF199	3	9	120.8533	23.52415
上安-全景式攝影機	投縣 DF165	4	2	120.8756	23.72506
郡坑-上游攝影機	投縣 DF167	5	1	120.8711	23.74022
郡坑-下游攝影機	投縣 DF167	5	2	120.8701	23.73952
豐丘-上游全景式攝影機	投縣 DF190	6	4	120.877	23.66839
大粗坑-下游攝影機 1	新北 DF174	7	2	121.837	25.09053
大粗坑-上游攝影機	新北 DF174	7	3	121.84	25.09101
大粗坑-下游攝影機 2	新北 DF174	7	4	121.837	25.09069
鳳義坑-下游攝影機	花縣 DF125	8	2	121.4269	23.74241
鳳義坑-上游全景式攝影機	花縣 DF125	8	3	121.4262	23.74186
射馬干-上游攝影機	東縣 DF058	9	1	121.037	22.7255
華山-中游攝影機	雲縣 DF002	10	1	120.6091	23.59321
華山-上游攝影機	雲縣 DF002	10	3	120.6115	23.59254
華山-全景式攝影機	雲縣 DF002	10	4	120.6068	23.59314
華山-華山橋下游攝影機	雲縣 DF002	10	6	120.5989	23.59361
華山-華山橋上游攝影機	雲縣 DF002	10	7	120.5989	23.59357
大興-下游攝影機	花縣 DF118	11	2	121.3802	23.64091
大興-上游全景式攝影機	花縣 DF118	11	3	121.3777	23.64216
豐山-乾坑溪下游攝影機	嘉縣 DF039	12	1	120.7456	23.59057
豐山-野溪攝影機	嘉縣 DF039	12	2	120.7446	23.59101
豐山-乾坑溪上游攝影機	嘉縣 DF039	12	3	120.7454	23.59054
松鶴-下游攝影機	中市 DF028	13	1	120.9857	24.17664
松鶴-上游全景式攝影機	中市 DF028	13	3	120.9858	24.17662
坪頂-停車場攝影機	-	14	1	120.6379	23.75286
坪頂-邊坡攝影機(菜園)	-	14	2	120.637	23.75257
坪頂-入口處攝影機	-	14	4	120.6383	23.75386
蘇樂-上游攝影機	桃縣 DF035	15	2	121.3597	24.70069
羌黃坑-上游攝影機	南市 DF048	18	1	120.538	23.06977
羌黃坑-中游攝影機	南市 DF048	18	2	120.537	23.07185
羌黃坑-下游攝影機	南市 DF048	18	3	120.5357	23.074
集來-上游攝影機-1	高市 DF072	19	1	120.596	23.02931
集來-中游攝影機	高市 DF072	19	2	120.5941	23.02886
集來-下游攝影機	高市 DF072	19	3	120.594	23.0288
集來-上游攝影機-2	高市 DF072	19	4	120.5962	23.02929
來義-匯流口攝影機	屏縣 DF025	20	1	120.6842	22.52715
來義-主流攝影機	屏縣 DF025	20	2	120.6763	22.52607

監測站	土石流潛勢溪流編號	SID	CID	X	Y
來義-潛勢溪流攝影機	屏東 DF025	20	3	120.676	22.5244
大鳥-崩塌地攝影機	東縣 DF097	21	1	120.91	22.38982
大鳥-中游攝影機	東縣 DF097	21	2	120.9092	22.39012
大鳥-下游攝影機	東縣 DF097	21	4	120.9101	22.38924
大鳥-沉砂池攝影機	東縣 DF097	21	5	120.9099	22.3888
南豐-中游前段攝影機	投縣 DF012	24	1	121.0872	24.01981
南豐-中游後段攝影機	投縣 DF012	24	2	121.0884	24.01739
南豐-下游攝影機	投縣 DF012	24	3	121.0892	24.01331
和中-上游攝影機	花縣 DF166	25	1	121.742	24.27402
和中-中游攝影機	花縣 DF166	25	2	121.7422	24.27382
和中-下游攝影機	花縣 DF166	25	3	121.743	24.27352
火炎山-攝影機	苗縣 DF036	26	1	120.7287	24.35587
寒溪-下游攝影機	宜縣 DF086	27	1	121.6859	24.60891
寒溪-上游全景式攝影機	宜縣 DF086	27	2	121.6846	24.59753

備註：*表崩塌災害監測。

表 2-5 公路總局道路監視影像資訊

監測站	影像資訊	適用監測
台 8 線 30K+600		滑 落 坡 石
台 8 線 63K+500		滑 落 坡 石
台 8 線 78K+500		滑 落 坡 石
台 8 線臨 37 1k+300		滑 落 坡 石
台 8 線臨 37 便道 4k+050		滑 落 坡 石

監測站	影像資訊			適用 監測
台 8 線臨 37 便道 7K+000				滑 落 坡 石
台 8 線臨 37 便道 12k+000				滑 坡
台 8 線臨 37 便道 12k+510				滑 落 坡 石
台 8 線臨 37 便道 14K+100				滑 落 坡 石
台 8 線臨 37 便道 17K+300				滑 落 坡 石
台 8 線臨 37 便道 18K+900				滑 落 坡 石
台 8 線臨 37 便道 20K+300				滑 落 坡 石
台 7 甲線 47K+070				滑 落 坡 石

```

<script>
var _StationID = "1";
var _SensorName = " ";
var _SensorStatus = "0";
jQuery(document).ready(function ($) {
    if (_SensorName == "") {
        $('#imgHeader').hide();
        $('#img1').attr("src", '/mydfm/images/noCCD_2.jpg');
    } else {
        if (_SensorStatus == "1") { //無夜間顯示
            $('#img1').attr("src", '/mydfm/images/noCCD_1.jpg');
        } else if (_SensorStatus == "2") { //暫停顯示或查無資料
            $('#img1').attr("src", '/mydfm/images/noCCD_2.jpg');
        } else if (PKList.length == 0) { //查無資料
            $('#img1').attr("src", '/mydfm/images/noCCD_2.jpg');
        } else if (PKList.length == 1) { //單張不輪播
            $('#img1').attr("src", '/mydfm/CCD/ShowOne/' + PKList[0]);
            $('#imgTitle').text(_SensorName + " " + CDateList[0]);
        } else {
            timer = window.setTimeout(showImg, 0);
        }
    }
}

function showImg() {
    var url = '/mydfm/CCD/ShowOne/' + PKList[PKIndex];
    $('#img1').attr("src", url);
    $('#imgTitle').text(_SensorName + " " + CDateList[PKIndex]);
    PKIndex++;
    if (PKIndex >= PKList.length) PKIndex = 0;
    timer = window.setTimeout(showImg, 1000);
}

});

var timer = null;
var PKIndex = 0;
var PKList =
[179216902,179216952,179217006,179217055,179217112,179217161,179217213,179217267,179217314,179217365];
var CDateList = ['2023/6/7 下午 02:43:32','2023/6/7 下午 02:44:02','2023/6/7 下午
02:44:32','2023/6/7 下午 02:45:02','2023/6/7 下午 02:45:32','2023/6/7 下午 02:46:02','2023/6/7 下午
02:46:32','2023/6/7 下午 02:47:03','2023/6/7 下午 02:47:32','2023/6/7 下午 02:48:02']; == $0
</script>

```

圖 2-2 Javascript 程式碼片段範例

第五節 線上即時坡地災害影像觀測系統功能與雛型建構

本研究設計一網頁服務，用以提供本研究成果進行實用性測試，其中以地圖平臺為基礎，將所蒐集之 CCTV 影像置入地圖平臺中，提供點選播放及進行坡地災害辨識模式測試，平臺初步規劃如圖 2-3 所示，元素包含地圖平臺、資訊窗格，其中地圖平臺可進行 CCTV 點位的置放並於點選後彈跳出資訊窗格；資訊窗格主要進行 CCTV 影像內容的顯示與模式辨識結果的呈現。由於深度學習模式係以 Python 為基礎進行設計，故本研究以能夠整合 Python 及網頁服務之 Django 架構進行網站服務建置，Django 係以 Python 為基礎進行 Web 應用程式開發環境，Django 透過 cookies 中所記錄之密鑰進行後端資料庫的存取作業，可大幅提升網頁服務的安全性。




圖 2-3 電腦視覺災害決策平臺架構初稿

第三章 工作進度與交付項目

第一節 計畫甘特圖

本研究期程自民國 112 年 02 月 18 日起至民國 112 年 12 月 31 日止，各項預期工作期程安排如表 3-1 所示，本研究以 2 個月完成坡地災害影像資料庫之影像精煉化作業；以 4 至 5 個月完成模式的程序建構及測試；最後以 3 個月左右的時間進行模式的最後校正與應用測試範例平台建置及測試，本研究已完成坡地災害影像蒐集作業、模式調參測試及網頁架構建置，CCTV 影像蒐集已達 6.6TB，計有 4,932,420 張影像檔。



表 3-1 預定執行工作進度表

工作項目	開始	完成	民國 112 年											
			1 月	2 月	3 月	4 月	5 月	6 月	7 月	8 月	9 月	10 月	11 月	12 月
文獻探討	112/02/08	112/03/30												
坡地災害影像庫樣本精煉成果	112/02/08	112/08/30												
精進坡地災害電腦視覺辨識模式與發展	112/02/08	112/09/30												
建構基於網頁架構之線上即時坡地災害影像觀測系統	112/06/15	112/11/30												
期中報告	112/07/01	112/07/13												
期末報告	112/11/01	112/11/13												
成果報告	112/11/01	112/12/25												
當月預定進度(%)			6%	11%	11%	7%	7%	8%	18%	12%	6%	5%	4%	3%
累積預計進度(%)			6%	17%	28%	35%	42%	50%	68%	82%	88%	93%	97%	100%
實際累計進度(%)			8%	23%	29%	39%	45%	63%	74%	85%	94%	98%	100%	100%

第二節 計畫交付項目

本研究成果產出項目有精煉影像資料庫乙式、各模式訓練最佳成果 (.h5) 檔案及模式應用網頁乙式，預計於成果報告中提供整體成果數位檔案，各成果分述於下：

一、精煉影像資料庫

本研究將影像資料庫區分為原始影像及精煉影像兩類，其中分為訓練與測試兩種，各樣本影像檔案皆置於其對應之資料夾內，資料夾結構如所示。

表 3-2 精煉影像資料庫結構

第一層資料夾	第二層資料夾	第三層資料夾	檔案數
原始影像 (org)	訓練 (train)	None	16
		Collapse	13
		DebrisFlow	10
		Rockfall	10
	測試 (test)	None	34
		Collapse	8
		DebrisFlow	10
		Rockfall	1
精煉影像 (cut)	訓練 (train)	None	16
		Collapse	13
		DebrisFlow	10
		Rockfall	10
	測試 (test)	None	34
		Collapse	8
		DebrisFlow	10
		Rockfall	1

二、各模式訓練最佳成果

本研究根據各模式在參數調整數組中擇最佳之訓練成果作為模式應用測試，各模式最佳成果對照的檔案名稱如表 3-3 所示，共計有 4 個 (.h5) 檔案。

表 3-3 各模式最佳成果檔案對照

模式	檔案名稱	最佳辨識精度
LSTM+CNN	LSTMCNN_128_50.h5	88.68%
LSTM+VGG16	LSTMVGG16_128_25.h5	86.79%
LSTM+VGG19	LSTMVGG19_224_25.h5	81.13%
LSTM+ResNet50	LSTMResNet50_224_15.h5	90.57%

三、模式應用網頁

本研究以 Django 框架建置應用測試網頁平台，透過平台可直接進行模式的測試，其中資料包含了網頁資料夾架構及原始碼。



第四章 期末成果

根據本研究之目標與執行成果，本研究完成坡地災害影像資料庫之建置與電腦視覺坡地災害辨識模式，茲將就各項目成果分述於下：

第一節 坡地災害影像庫樣本精煉成果









本研究於先期計畫中已透過 Youtube、Twitter 等影音社群網站取得坡地災害（滑坡、落石及土石流）相關影片，並將辨識類別分為非坡地災害(None)、滑坡(Collapse)、土石流(DebrisFlow)及落石(Rockfall)，其中非坡地災害係本研究就所蒐整之 CCTV 所拍攝之道路、河道等非坡地災害影像進行整合而成的影片，各類別編號如表 4-1 所示，經前期研究證實透過樣本調整手段確實能夠提升模式 (LSTM+CNN、LSTM+VGG16 及 LSTM+VGG19) 辨識能力。今年度本於精進之精神，探討將樣本內容聚焦於災害本體降低背景資訊後對於模式辨識能力之影響，故提出影像內容精煉方法，影像精煉方式經本研究測試評估後採用 OpenCV 所提供之頻道和空間可靠性追蹤方法 (Channel and Spatial Reliability Tracking, CSRT) 與 MedianFlow 追蹤方法進行坡地災害範圍框定與自動追蹤範圍切割影像，影像精煉成果最終以 300*300 像素大小進行儲存，經精煉後之影像共計有 52 個，精煉成果如表 4-2 所示，經過精煉後之影像已完全聚焦於災害發生之區域，後續將依照前期研究中訓練樣本最後調整組合（如表 4-3 所示）進行進行各模式的測試，以瞭解精煉前、後之影像對於模式辨識的能力影響。









表 4-1 類別編號

代號	對應行為	
N	非坡地災害	None
C	滑坡	Collapse
D	土石流	DebrisFlow
R	落石	Rockfall

表 4-2 訓練影像精煉成果

類別	序號	影像內容	選擇範圍	精煉成果
Collapse	C01			
	C02			




類別	序號	影像內容	選擇範圍	精煉成果
	C03			
	C04			
	C05			
	C06			
	C07			
	* C08			
	C09			
	C10			

類別	序號	影像內容	選擇範圍	精煉成果
	C11			
	C12			
	C13			
	C14			
	C15			
	* C16			
	* C17			
	C18			
	C19			
	* C20			

類別	序號	影像內容	選擇範圍	精煉成果
	C21			
DebrisFlow	D01			
	D02			
	D03			

類別	序號	影像內容	選擇範圍	精煉成果
	D04			
	D05			
	D06			

類別	序號	影像內容	選擇範圍	精煉成果
	D07			
	D08			
	D09			
	D10			
	D11			
	D12			
	D13			
	D14			

類別	序號	影像內容	選擇範圍	精煉成果
	D15			
	D16			
	D17			
	D18			
	D19			
	D20			
Rockfall	R01			
	R02			
	R03			
	R04			



類別	序號	影像內容	選擇範圍	精煉成果
	R05			
	R06			
	R07			
	R08			
	R09			
	R10			
	R11			

表 4-3 訓練樣本組合

類別	樣本組合
N	N01、N03、N05、N06、N13、N17、N22、N26、N31、N34、N35、N36、N41、N43、N46、N48
C	C01、C05、C07、C08、C10、C11、C12、C14、C16、C17、C18、C19、C20
D	D01、D02、D03、D04、D07、D09、D10、D14、D15、D16
R	R01、R02、R03、R04、R06、R10、R07、R08、R09、R11



第二節 電腦視覺坡地災害辨識模式與精進成果

今年度以前期研究成果為基礎再加入 LSTM 結合 ResNet50 架構，在模式實踐上以 Python 語言進行開發，本項目目標有比較影像精煉前後差異及 LSTM+ResNet50 網路與前期成果網路之差異。茲將就各成果分述於下：

一、影像精煉化成果

本項目以前期研究所建立的模式 LSTM+CNN、LSTM+VGG-16 及 LSTM+VGG-19 進行精煉影像的測試，根據精煉影像的測試結果 (如表 4-4 所示)，各模式在不同的樣本組合下最深層的 LSTM+VGG19 模式提升最多，由 66.04% 提升至 84.91%，整體提升了 18.87%，各模式的整體均衡度也有所提升，因此透過樣本調整手段，將影像特徵聚焦於災害本身係可穩定模式的學習情形，亦可提高模式的辨識能力。

表 4-4 各模式使用精煉前、後樣本比較

調樣 次數	模 式	最佳值					
		原始樣本			精煉樣本		
		測試	訓練	序列長度	測試	訓練	序列長度
1	LSTM+ CNN	59.76%	95.00%	20	82.89%↑	100.00%	15
	LSTM+ VGG-16	52.44%	60.00%	15	81.58%↑	92.31%	30
	LSTM+ VGG-19	52.44%	65.00%	50	75.00%↑	88.46%	40
2	LSTM+ CNN	72.86%	93.75%	30	81.43%↑	96.88%	15

調樣 次數	模 式	最佳值					
		原始樣本			精煉樣本		
		測試	訓練	序列長度	測試	訓練	序列長度
	LSTM+ VGG-16	54.29%	65.63%	20	77.14%↑	96.88%	40
	LSTM+ VGG-19	54.29%	37.50%	15	82.86%↑	84.38%	30
3	LSTM+ CNN	68.57%	100.00%	25	64.29%↓	90.63%	25
	LSTM+ VGG-16	62.86%	100.00%	40	68.57%↑	100.00%	50
	LSTM+ VGG-19	55.71%	34.38%	15	68.57%↑	100.00%	40
4	LSTM+ CNN	72.58%	100.00%	30	80.65%↑	90.00%	15
	LSTM+ VGG-16	58.06%	100.00%	15	74.19%↑	100.00%	15
	LSTM+ VGG-19	62.90%	27.50%	30	74.19%↑	95.00%	50
5	LSTM+ CNN	82.14%	100.00%	15	82.14%	91.30%	15
	LSTM+ VGG-16	76.79%	95.65%	50	75.00%↓	100.00%	30
	LSTM+ VGG-19	62.50%	32.61%	15	80.36%↑	95.65%	30

調樣 次數	模 式	最佳值					
		原始樣本			精煉樣本		
		測試	訓練	序列長度	測試	訓練	序列長度
6	LSTM+ CNN	84.91%	100.00%	20	86.79%↑	97.96%	30
	LSTM+ VGG-16	75.47%	97.96%	50	79.25%↑	91.84%	20
	LSTM+ VGG-19	66.04%	48.98%	40	84.91%↑	91.84%	50

備註：底色表使用精煉影像後精確度提升；粗體字為最大精確值。

二、參數調整成果

本研究以最後調樣之樣本組合進行影像大小、影像序列長度、Epoch 數及學習速率參數測試，共計有 240 種組合，本研究執行調整之各參數如表 4-5 所示，成果如表 4-6 所示，其中於測試影像辨識率成果中 LSTM+CNN(86.79%提升至 88.68%) 與 LSTM+VGG16(81.58%提升至 86.79%) 辨識率皆有所提升，唯 LSTM+VGG19 辨識率由些許下降，由 84.91 降至 81.13%，整體而言皆有 8 成以上的辨識能力。

表 4-5 模式調校參數組合

項次	參數名稱	規劃執行參數
1	影像大小	128、224
2	影像序列長度	15、20、25、30、40、50
3	學習速度	0.1、0.01、0.001
4	Epoch 數	100、200、500、1000、2000

表 4-6 參數調校成果

影像 大小	序列 長度	學習率 超參數	epoch	模式								
				LSTM+CNN			LSTM+VGG16			LSTM+VGG19		
				訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間
128	15	0.1	100	32.65%	64.15%	25.50	32.65%	64.15%	29.88	20.41%	1.89%	25.01

影像大小	序列長度	學習率 超參數	epoch	模式								
				LSTM+CNN			LSTM+VGG16			LSTM+VGG19		
				訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間
			200	26.53%	15.09%	28.56	32.65%	64.15%	38.49	20.41%	18.87%	37.66
			300	32.65%	64.15%	69.56	32.65%	64.15%	93.79	32.65%	64.15%	94.72
			500	30.61%	58.49%	132.49	32.65%	64.15%	189.33	20.41%	18.87%	190.78
			1000	26.53%	15.09%	292.78	26.53%	15.09%	386.04	20.41%	1.89%	400.19
		0.01	100	91.84%	60.38%	15.05	32.65%	64.15%	19.28	32.65%	64.15%	19.71
			200	32.65%	64.15%	46.16	32.65%	64.15%	38.21	32.65%	64.15%	37.93
			300	32.65%	64.15%	69.59	32.65%	64.15%	93.21	32.65%	64.15%	95.25
			500	32.65%	64.15%	139.12	32.65%	64.15%	190.02	32.65%	64.15%	191.65
			1000	32.65%	64.15%	301.68	32.65%	64.15%	404.06	32.65%	64.15%	395.72
		0.001	100	93.88%	77.36%	14.84	53.06%	58.49%	19.29	71.43%	77.36%	19.70
			200	100.00%	77.36%	45.36	89.80%	69.81%	38.23	67.35%	62.26%	38.18
			300	100.00%	77.36%	65.83	32.65%	64.15%	95.11	77.55%	64.15%	96.77
			500	100.00%	79.25%	146.61	20.41%	18.87%	191.14	32.65%	64.15%	191.95
			1000	100.00%	66.04%	293.70	32.65%	64.15%	434.89	32.65%	64.15%	447.02
	20	0.1	100	32.65%	64.15%	21.51	32.65%	64.15%	35.88	32.65%	64.15%	32.44
			200	32.65%	64.15%	38.01	32.65%	64.15%	56.08	32.65%	64.15%	40.21
			300	32.65%	64.15%	87.79	32.65%	64.15%	120.42	26.53%	15.09%	97.45
			500	26.53%	15.09%	164.24	32.65%	64.15%	218.42	20.41%	18.87%	217.90
			1000	32.65%	64.15%	374.74	32.65%	64.15%	435.35	32.65%	64.15%	456.25
		0.01	100	69.39%	71.70%	20.48	32.65%	64.15%	33.34	32.65%	64.15%	21.53
			200	32.65%	64.15%	40.07	32.65%	64.15%	55.50	32.65%	64.15%	40.44
			300	32.65%	64.15%	91.95	32.65%	64.15%	109.29	32.65%	64.15%	98.77
			500	32.65%	64.15%	187.41	32.65%	64.15%	218.25	32.65%	64.15%	222.41
			1000	34.69%	64.15%	378.57	32.65%	64.15%	446.00	0.00%	0.00%	0.00
		0.001	100	95.92%	73.58%	20.57	61.22%	71.70%	30.40	63.27%	67.92%	21.17
			200	100.00%	75.47%	39.27	53.06%	58.49%	56.65	28.57%	28.30%	40.30
			300	100.00%	73.58%	91.37	100.00%	69.81%	115.10	32.65%	64.15%	101.87
			500	100.00%	83.02%	192.30	100.00%	64.15%	219.68	32.65%	64.15%	242.21
			1000	100.00%	75.47%	390.77	100.00%	73.58%	426.21	32.65%	64.15%	402.12
	25	0.1	100	32.65%	64.15%	31.32	32.65%	64.15%	38.56	32.65%	64.15%	29.58

影像大小	序列長度	學習率 超參數	epoch	模式								
				LSTM+CNN			LSTM+VGG16			LSTM+VGG19		
				訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間
	30		200	32.65%	64.15%	52.71	32.65%	64.15%	52.27	32.65%	64.15%	47.10
			300	32.65%	64.15%	122.12	32.65%	64.15%	124.26	32.65%	64.15%	114.43
			500	32.65%	64.15%	232.98	32.65%	64.15%	244.46	32.65%	64.15%	232.55
			1000	32.65%	64.15%	433.88	26.53%	15.09%	496.51	32.65%	64.15%	510.50
		0.01	100	89.80%	77.36%	21.49	32.65%	64.15%	26.63	32.65%	64.15%	24.58
			200	77.55%	62.26%	55.71	32.65%	64.15%	51.97	32.65%	64.15%	47.19
			300	97.96%	79.25%	124.31	32.65%	64.15%	123.50	32.65%	64.15%	114.92
			500	100.00%	69.81%	239.16	32.65%	64.15%	247.25	32.65%	64.15%	269.95
			1000	32.65%	64.15%	419.64	32.65%	64.15%	492.93	32.65%	64.15%	531.67
		0.001	100	91.84%	71.70%	30.51	81.63%	71.70%	27.22	63.27%	75.47%	46.42
			200	77.55%	75.47%	55.31	69.39%	45.28%	50.35	61.22%	60.38%	47.36
			300	100.00%	77.36%	125.42	97.96%	66.04%	124.96	26.53%	15.09%	116.58
			500	100.00%	73.58%	199.67	100.00%	86.79%	250.24	32.65%	64.15%	256.00
			1000	100.00%	75.47%	398.09	26.53%	15.09%	510.57	32.65%	64.15%	496.20
	40	0.1	100	32.65%	64.15%	27.48	32.65%	64.15%	38.05	26.53%	15.09%	38.00
			200	32.65%	64.15%	52.63	32.65%	64.15%	57.18	26.53%	15.09%	59.44
			300	32.65%	64.15%	124.02	32.65%	64.15%	139.33	32.65%	64.15%	142.08
			500	32.65%	64.15%	229.42	32.65%	64.15%	279.78	20.41%	18.87%	294.77
			1000	32.65%	64.15%	470.95	32.65%	64.15%	562.53	26.53%	15.09%	562.59
		0.01	100	42.86%	35.85%	28.14	32.65%	64.15%	28.75	32.65%	64.15%	29.72
			200	87.76%	73.58%	53.14	32.65%	64.15%	56.55	32.65%	64.15%	59.16
			300	97.96%	60.38%	120.38	32.65%	64.15%	140.58	32.65%	64.15%	146.70
			500	91.84%	50.94%	231.78	32.65%	64.15%	280.00	32.65%	64.15%	293.38
			1000	32.65%	64.15%	465.51	32.65%	64.15%	566.89	32.65%	64.15%	587.80
		0.001	100	85.71%	75.47%	34.83	65.31%	69.81%	29.52	55.10%	62.26%	31.86
			200	100.00%	83.02%	53.47	32.65%	64.15%	56.30	55.10%	60.38%	57.42
			300	100.00%	77.36%	121.45	91.84%	67.92%	143.25	30.61%	24.53%	146.61
			500	100.00%	75.47%	233.33	32.65%	64.15%	278.25	32.65%	60.38%	289.94
			1000	100.00%	81.13%	464.83	100.00%	62.26%	583.15	32.65%	64.15%	601.98
	40	0.1	100	32.65%	64.15%	38.42	26.53%	15.09%	44.19	20.41%	18.87%	47.10

影像大小	序列長度	學習率 超參數	epoch	模式								
				LSTM+CNN			LSTM+VGG16			LSTM+VGG19		
				訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間
			200	32.65%	64.15%	76.98	32.65%	64.15%	91.27	32.65%	64.15%	76.02
			300	32.65%	64.15%	166.02	32.65%	64.15%	180.86	32.65%	64.15%	190.13
			500	20.41%	1.89%	308.03	32.65%	64.15%	364.44	26.53%	15.09%	374.64
			1000	32.65%	64.15%	615.50	32.65%	64.15%	728.86	32.65%	64.15%	763.91
		0.01	100	32.65%	64.15%	37.95	32.65%	64.15%	37.61	32.65%	64.15%	38.49
			200	100.00%	71.70%	75.53	32.65%	64.15%	74.09	32.65%	64.15%	77.33
			300	32.65%	64.15%	169.29	32.65%	64.15%	182.98	32.65%	64.15%	189.20
			500	36.73%	49.06%	321.58	32.65%	64.15%	363.39	32.65%	64.15%	381.00
			1000	36.73%	33.96%	608.55	32.65%	64.15%	706.11	32.65%	64.15%	759.23
		0.001	100	67.35%	81.13%	37.91	32.65%	64.15%	38.09	57.14%	60.38%	40.56
			200	100.00%	81.13%	78.69	57.14%	75.47%	73.81	71.43%	58.49%	76.33
			300	97.96%	71.70%	169.55	75.51%	75.47%	182.66	26.53%	15.09%	191.45
			500	75.51%	71.70%	311.36	32.65%	64.15%	367.45	32.65%	64.15%	402.19
			1000	46.94%	71.70%	614.78	55.10%	67.92%	697.70	28.57%	26.42%	775.05
	50	0.1	100	32.65%	64.15%	39.82	32.65%	64.15%	51.02	26.53%	15.09%	54.61
			200	32.65%	64.15%	70.22	32.65%	64.15%	88.89	32.65%	64.15%	91.40
			300	26.53%	15.09%	172.18	32.65%	64.15%	220.34	32.65%	64.15%	223.20
			500	32.65%	64.15%	373.33	32.65%	64.15%	427.97	32.65%	64.15%	481.54
			1000	32.65%	64.15%	737.39	32.65%	64.15%	886.62	32.65%	64.15%	869.92
		0.01	100	77.55%	71.70%	35.90	32.65%	64.15%	45.08	32.65%	64.15%	47.11
			200	100.00%	52.83%	70.22	32.65%	64.15%	89.23	32.65%	64.15%	91.29
			300	100.00%	84.91%	171.74	32.65%	64.15%	218.64	32.65%	64.15%	221.54
			500	32.65%	64.15%	371.17	32.65%	64.15%	451.93	32.65%	64.15%	444.50
			1000	100.00%	81.13%	729.55	32.65%	64.15%	889.35	32.65%	64.15%	877.43
		0.001	100	81.63%	73.58%	36.01	79.59%	77.36%	44.88	59.18%	64.15%	47.38
			200	100.00%	88.68%	69.98	57.14%	56.60%	89.43	75.51%	77.36%	91.45
			300	81.63%	69.81%	171.79	93.88%	66.04%	219.48	83.67%	64.15%	223.45
			500	100.00%	75.47%	373.13	100.00%	79.25%	433.18	36.73%	39.62%	445.85
			1000	100.00%	79.25%	739.06	100.00%	67.92%	875.29	100.00%	64.15%	885.77
224	15	0.1	100	32.65%	62.26%	35.00	32.65%	64.15%	50.74	20.41%	1.89%	52.58

影像 大小	序列 長度	學習率 超參數	epoch	模式								
				LSTM+CNN			LSTM+VGG16			LSTM+VGG19		
				訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間
			200	32.65%	64.15%	61.81	32.65%	64.15%	88.07	32.65%	64.15%	86.53
			300	26.53%	15.09%	154.02	26.53%	15.09%	214.78	32.65%	64.15%	220.59
			500	26.53%	15.09%	313.50	32.65%	64.15%	430.54	32.65%	64.15%	432.36
			1000	26.53%	15.09%	657.86	20.41%	1.89%	892.30	32.65%	64.15%	877.66
		0.01	100	32.65%	64.15%	30.63	32.65%	64.15%	43.83	32.65%	64.15%	43.42
			200	32.65%	64.15%	61.99	32.65%	64.15%	87.28	32.65%	64.15%	86.20
			300	32.65%	64.15%	154.64	32.65%	64.15%	213.32	32.65%	64.15%	216.50
			500	32.65%	64.15%	314.07	32.65%	64.15%	434.83	32.65%	64.15%	428.11
			1000	32.65%	64.15%	661.28	26.53%	15.09%	862.64	26.53%	15.09%	853.87
		0.001	100	91.84%	79.25%	30.88	20.41%	1.89%	44.71	34.69%	26.42%	43.25
			200	100.00%	69.81%	61.78	85.71%	62.26%	86.53	32.65%	64.15%	86.64
			300	100.00%	75.47%	185.19	59.18%	67.92%	220.73	32.65%	64.15%	216.88
			500	100.00%	79.25%	320.14	100.00%	77.36%	445.11	32.65%	64.15%	445.92
			1000	100.00%	64.15%	668.51	32.65%	64.15%	870.35	32.65%	64.15%	862.32
	20	0.1	100	32.65%	64.15%	47.47	32.65%	64.15%	52.23	32.65%	64.15%	68.06
			200	30.61%	9.43%	84.49	32.65%	64.15%	104.55	32.65%	64.15%	125.58
			300	26.53%	15.09%	206.15	32.65%	64.15%	294.82	32.65%	64.15%	274.97
			500	32.65%	64.15%	409.67	32.65%	64.15%	564.23	32.65%	64.15%	535.65
			1000	32.65%	64.15%	849.81	20.41%	18.87%	1061.83	26.53%	15.09%	1055.55
		0.01	100	32.65%	64.15%	41.80	32.65%	64.15%	56.63	32.65%	64.15%	56.60
			200	32.65%	64.15%	84.18	32.65%	64.15%	114.25	32.65%	64.15%	111.91
			300	32.65%	64.15%	203.79	32.65%	64.15%	291.68	32.65%	64.15%	271.98
			500	32.65%	64.15%	416.90	32.65%	64.15%	566.15	32.65%	64.15%	521.50
			1000	32.65%	64.15%	818.96	32.65%	64.15%	1051.38	32.65%	64.15%	1058.86
		0.001	100	91.84%	79.25%	42.86	59.18%	60.38%	53.05	48.98%	45.28%	56.52
			200	100.00%	75.47%	84.26	87.76%	71.70%	114.25	32.65%	64.15%	112.08
			300	100.00%	77.36%	204.84	100.00%	79.25%	280.87	32.65%	64.15%	279.53
			500	100.00%	84.91%	412.68	100.00%	75.47%	569.33	32.65%	64.15%	540.28
			1000	100.00%	75.47%	840.64	100.00%	66.04%	1037.71	32.65%	64.15%	1086.77
	25	0.1	100	32.65%	64.15%	56.48	20.41%	1.89%	71.14	26.53%	15.09%	74.06

影像大小	序列長度	學習率 超參數	epoch	模式								
				LSTM+CNN			LSTM+VGG16			LSTM+VGG19		
				訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間
			200	32.65%	64.15%	99.93	32.65%	64.15%	126.91	26.53%	15.09%	124.02
			300	32.65%	64.15%	240.72	32.65%	64.15%	311.13	26.53%	15.09%	325.05
			500	32.65%	64.15%	499.06	32.65%	64.15%	639.61	32.65%	64.15%	625.91
			1000	32.65%	64.15%	1019.52	26.53%	15.09%	1267.08	26.53%	15.09%	1300.02
			100	42.86%	50.94%	49.27	32.65%	64.15%	64.20	32.65%	64.15%	64.77
		0.01	200	100.00%	66.04%	98.82	32.65%	64.15%	126.30	32.65%	64.15%	131.70
			300	32.65%	64.15%	246.94	32.65%	64.15%	312.05	32.65%	64.15%	325.06
			500	32.65%	64.15%	500.99	32.65%	64.15%	627.80	32.65%	64.15%	638.82
			1000	32.65%	64.15%	1005.22	32.65%	64.15%	1268.70	32.65%	64.15%	1285.25
			100	79.59%	83.02%	51.63	79.59%	60.38%	64.03	61.22%	67.92%	68.31
		0.001	200	100.00%	67.92%	99.85	57.14%	60.38%	125.67	57.14%	64.15%	124.81
			300	100.00%	69.81%	242.03	100.00%	66.04%	316.08	85.71%	81.13%	318.42
			500	100.00%	79.25%	505.01	100.00%	75.47%	633.30	77.55%	75.47%	637.24
			1000	100.00%	64.15%	1002.14	100.00%	75.47%	1282.05	100.00%	69.81%	1333.75
	30		100	32.65%	64.15%	68.80	32.65%	64.15%	103.63	32.65%	64.15%	96.59
			200	32.65%	64.15%	120.73	32.65%	64.15%	157.67	32.65%	64.15%	179.64
			300	32.65%	64.15%	306.33	32.65%	64.15%	384.82	32.65%	56.60%	392.08
			500	32.65%	64.15%	586.85	32.65%	64.15%	762.94	32.65%	64.15%	799.33
			1000	26.53%	16.98%	1198.29	32.65%	64.15%	1571.99	26.53%	15.09%	1574.77
		0.01	100	32.65%	64.15%	62.59	32.65%	64.15%	81.00	32.65%	64.15%	78.86
			200	32.65%	64.15%	121.67	32.65%	64.15%	158.70	32.65%	64.15%	157.54
			300	32.65%	64.15%	306.51	32.65%	64.15%	394.83	32.65%	64.15%	391.58
			500	97.96%	75.47%	598.09	32.65%	64.15%	777.19	32.65%	64.15%	783.13
			1000	26.53%	43.40%	1215.18	32.65%	64.15%	1579.40	32.65%	64.15%	1543.31
		0.001	100	81.63%	71.70%	61.58	57.14%	58.49%	78.92	55.10%	69.81%	103.67
			200	100.00%	67.92%	124.39	87.76%	67.92%	155.82	77.55%	64.15%	162.91
			300	100.00%	73.58%	306.01	100.00%	75.47%	400.06	91.84%	60.38%	397.53
			500	100.00%	81.13%	608.65	32.65%	64.15%	769.97	26.53%	15.09%	791.17
			1000	100.00%	67.92%	1183.68	100.00%	54.72%	1594.26	100.00%	54.72%	1539.19
	40	0.1	100	32.65%	64.15%	81.76	26.53%	15.09%	113.30	26.53%	15.09%	114.86

影像大小	序列長度	學習率 超參數	epoch	模式								
				LSTM+CNN			LSTM+VGG16			LSTM+VGG19		
				訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間	訓練 精度	測試 精度	時間
			200	32.65%	64.15%	160.73	32.65%	64.15%	205.24	32.65%	64.15%	242.63
			300	26.53%	15.09%	411.31	26.53%	15.09%	509.71	32.65%	64.15%	520.58
			500	24.49%	9.43%	790.50	30.61%	20.75%	1015.28	32.65%	64.15%	1013.91
			1000	32.65%	64.15%	1573.21	32.65%	64.15%	2072.95	32.65%	64.15%	2062.58
		0.01	100	32.65%	64.15%	82.48	32.65%	64.15%	103.11	32.65%	64.15%	103.11
			200	85.71%	67.92%	159.03	32.65%	64.15%	203.43	32.65%	64.15%	212.78
			300	32.65%	64.15%	407.28	32.65%	64.15%	536.67	32.65%	64.15%	524.17
			500	32.65%	62.26%	786.03	32.65%	64.15%	1013.65	32.65%	64.15%	1016.30
			1000	32.65%	64.15%	1556.24	32.65%	64.15%	2016.25	32.65%	64.15%	2038.42
		0.001	100	79.59%	73.58%	81.67	42.86%	39.62%	103.55	53.06%	60.38%	108.91
			200	100.00%	69.81%	160.79	73.47%	66.04%	203.77	26.53%	15.09%	210.64
			300	100.00%	81.13%	406.72	100.00%	67.92%	501.36	57.14%	64.15%	512.39
			500	100.00%	73.58%	801.42	32.65%	64.15%	1008.13	100.00%	75.47%	1026.53
			1000	100.00%	83.02%	1599.24	100.00%	77.36%	2054.69	59.18%	67.92%	2042.33
	50	0.1	100	32.65%	64.15%	102.32	20.41%	1.89%	142.28	32.65%	64.15%	162.36
			200	32.65%	64.15%	192.10	32.65%	64.15%	257.19	32.65%	64.15%	261.34
			300	32.65%	64.15%	482.37	26.53%	15.09%	640.25	32.65%	64.15%	639.88
			500	32.65%	64.15%	938.08	32.65%	64.15%	1289.96	32.65%	64.15%	1287.37
			1000	32.65%	64.15%	1983.98	32.65%	64.15%	2564.90	26.53%	15.09%	2539.08
		0.01	100	48.98%	67.92%	98.77	32.65%	64.15%	131.50	32.65%	64.15%	134.05
			200	51.02%	64.15%	215.85	32.65%	64.15%	259.37	32.65%	64.15%	262.92
			300	89.80%	62.26%	484.32	32.65%	64.15%	631.73	32.65%	64.15%	646.67
			500	32.65%	64.15%	929.15	32.65%	64.15%	1261.61	32.65%	64.15%	1261.92
			1000	81.63%	60.38%	1867.52	32.65%	64.15%	2527.91	32.65%	64.15%	2547.19
		0.001	100	85.71%	67.92%	99.85	55.10%	67.92%	128.81	53.06%	49.06%	133.13
			200	91.84%	73.58%	197.22	89.80%	71.70%	284.21	57.14%	64.15%	255.75
			300	100.00%	77.36%	497.04	93.88%	71.70%	639.83	100.00%	67.92%	651.16
			500	100.00%	75.47%	935.97	100.00%	67.92%	1279.11	57.14%	58.49%	1283.10
			1000	100.00%	69.81%	1971.49	100.00%	75.47%	2583.11	32.65%	64.15%	2589.41

三、LSTM+ResNet50辨識成果

為提供多樣化的模式選擇，本研究加入 LSTM+ResNet50 模式，架構如圖 4-1 所示，經本研究以訓練樣本進行 LSTM+ResNet50 架構訓練後再進行測試影像測試成果如表 4-7 所示，在影像大小設定上，本研究採用 ResNet50 模式原始之影像大小 (224*224) 進行輸入大小設定，影像長度、Epoch、訓練速率等皆與調校參數一致，進行模式的設定及訓練。在根據上述之參數設定進行模式訓練過程中發現模式的訓練因受限於硬體設備 (GPU 可用記憶體空間大小)，當影像序列長度大於 15 時，就會出現超出 GPU 記憶體空間之錯誤訊息，經本研究測試後將影像序列長度調整為 5、10、15，在學習速率上增加 0.0001，其餘參數皆與其他模式一致，經訓練與測試結果 LSTM+ResNet50 在影像序列長度為 15、迭代次數 1000、訓練速度於 0.0001 時最佳之辨識成果達到 90.57%，優於其他模式之辨識能力，透過驗證影像辨識上本研究截取滑坡發生期間第 45 至 60 之影格進行說明，由表 4-8 中發現 LSTM+ResNet50 在第 14 影格模式就辨識出落石狀況，到了第 20 影格開始，影像中山坡土石開始崩滑後，由於土石流與崩滑在影像上呈現的滑動特性有部分特徵相似，模式易將滑地坡災害辨識為土石流災害，故於本研究中係認定其有達到坡地災害辨識之能力，直到第 63 至第 66 影格時，影像模式短暫判斷為無災害外，其餘皆能辨識出坡地災害。再根據其觀注熱區顯示，其主要觀注於影像之左上方及左下方處，在第 53 影像開始辨識為非災害影像時，其觀注熱區轉向非災害發生處之天空方向移動，故無法正確辨識出影像情境內容。




圖 4-1 LSTM+ResNet 架構

表 4-7 LSTM+ResNet 訓練成果

影像長度	15									
訓練時間	3127.62 秒									
成果	訓練資料誤差矩陣					測試資料誤差矩陣				
		A	B	C	D		A	B	C	D
	A	16	0	0	0	A	34	0	0	0
	B	0	13	0	0	B	0	5	2	1
	C	0	0	10	0	C	0	2	8	0
	D	0	0	0	10	D	0	0	0	1
	精準度： 100%					精準度： 90.57%				

表 4-8 LSTM+ResNet50 辨識成果

影格 編號	原始影像	觀注熱區	辨識類別
14			
15			
16			
17			
18			
19			
20			
30			

影格 編號	原始影像	觀注熱區	辨識類別
40			
45			
50			
60			
61			
62			
63			
64			
65			

影格 編號	原始影像	觀注熱區	辨識類別
66			
67			
68			
69			
70			



第三節 影像資料蒐集自動化成果

爬蟲架構整合於本研究所發展之坡地災害監視系統中，使用 BeautifulSoup、urllib、re 等元件建構 CCTV 擷錄程序，以每五分鐘進行網頁內容解析與影像擷錄乙次，擷錄成果將儲存於對應 CCTV 之 SID 與 ID 所組合之資料夾，影像命名方式上以「{SID}_{ID}_{資源編號}_{時間}.jpg」進行儲存 (如圖 4-2 所示)，本研究透過作業系統中之工作排程器以每五分鐘執行爬蟲程式 (如圖 4-3 所示)，為避免重覆擷錄影像，本研究以儲存之影像名稱為依據判斷影像是否重覆，如具有相同影像名稱則不加以擷錄，此能減少儲存空間的浪費與避免過度存取影像伺服器增其負載，截至 10 月 30 日止已爬取超過 493 萬張以上的潛勢溪流影像，使用儲存空間計有近 6.6TB。




圖 4-2 擷錄影像儲存資料夾結構與內容




圖 4-3 系統工作排程器固定執行影像爬蟲作業



第四節 線上即時坡地災害影像觀測系統建構成果

於期中部分本研究已透過 Django 框架完成網頁服務執行環境之建置並初步建構地圖平臺及介接農村水保署 CCTV 開放資料 (<https://data.coa.gov.tw/Service/OpenData/DataFileService.aspx?UnitId=111>)，格式如圖 4-4 所示，在 Python 語言環境下，資料接取技術上可先使用 urlopen 元件針對 url 本文的讀取，再透過 json 元件進行文件內容解析，在農村水保署所提供的 CCTV 影像資訊有攝影機名稱、縣市、行政區、架設或拍攝地點、影像連結網址及經緯度，本研究將解析成果以 Sqlite 資料庫進行儲存 (如圖 4-5 所示) 並可提供 CCTV 的新增、刪除等作業 (如圖 4-6 所示)；在地圖設定部分，本研究介接了地理資訊圖資雲服務平臺 (Taiwan geospatial one stop, TGOS)、開放街圖 (OpenStreetMap) 所發布之各式電子地圖樣式 (如表 4-9 所示)，共計 9 種，可提供使用者就需求選取適合的電子地圖樣式，整體呈現如圖 4-7 所示，點選 CCTV 點位呈現之跳出視窗如圖 4-8 所示，其中包含了即時影像也包含了各模式的辨識成果。

本研究以現有模式進行 CCTV 影像辨識結果顯示 (如表 4-10 所示) 係存在誤判之情形，經本研究觀察誤判區間主要分布於夜間無雨情境下之紅外線影像中樹木遇大風而搖晃過度時會導致模式誤判為坡地災害發生，在本研究中較為淺層的網路 (LSTM+CNN 及 LSTM+VGG16) 將其辨識為滑坡，較深層網路 (LSTM+VGG19 及 LSTM+ResNet50) 則辨識為土石流，對此部分本研究判斷係因訓練樣本主要多為日間拍攝之影像，故模式對於夜間影像之辨識能力較為薄弱，後續可設計一人機互動介面針對誤判部分影像進行模式的強化訓練。

```
[
{
  "攝影機名稱": "大粗坑下游攝影機",
  "縣市": "新北市",
  "行政區": "瑞芳鎮",
  "架設或拍攝地點": "新北市瑞芳鎮弓橋里大粗坑",
  "影像連結網址": "http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg-
  LG.asp?StationID=7&CCDId=2",
  "經度": "121.836959",
  "緯度": "25.090534"
},
{...}
]
```

圖 4-4 農村水保署 CCTV 開放資料 json 格式示意

id	cctv_name	cctv_county	cctv_section	cctv_position	cctv_W84	cctv_W84	cctv_SIC	cctv_OI	cctv_url
1	大粗坑下游攝影機	新北市	瑞芳鎮	新北市瑞芳鎮弓橋里大粗坑	121.83...	25.090...	7	2	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
2	大粗坑上游全景式攝影機	新北市	瑞芳鎮	新北市瑞芳鎮弓橋里大粗坑	121.83...	25.091...	7	3	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
3	大粗坑下游攝影機-2	新北市	瑞芳鎮	新北市瑞芳鎮弓橋里大粗坑	121.83...	25.090...	7	4	https://dfm.swcb.gov.tw/debrisFinal/...
4	新南上游攝影機	桃園市	楊梅鎮	桃園市楊梅鎮新南村新南	121.15...	24.700...	15	2	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
5	台中市全景式攝影機	苗栗縣	卓蘭鎮	苗栗縣卓蘭鎮內埔里白布坑	120.90...	24.298...	1	2	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
6	松鶴下游攝影機	台中市	和平區	台中市和平區松鶴里松鶴村	120.98...	24.176...	13	1	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
7	松鶴上游全景式攝影機	台中市	和平區	台中市和平區松鶴里松鶴村	120.98...	24.176...	13	3	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
8	上安全網式攝影機	南投縣	水里鄉	南投縣水里鄉上安村	120.87...	23.725...	4	2	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
9	新坑上游攝影機	南投縣	水里鄉	南投縣水里鄉新坑村	120.87...	23.740...	5	1	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
10	新坑下游攝影機	南投縣	水里鄉	南投縣水里鄉新坑村	120.87...	23.738...	5	2	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
11	新南上游攝影機	南投縣	信義鄉	南投縣信義鄉新南村	120.85...	23.528...	3	1	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...
12	新南上游攝影機	南投縣	信義鄉	南投縣信義鄉新南村	120.85...	23.528...	3	3	http://dfm.swcb.gov.tw/debrisFinal/ShowCCDImg...

圖 4-5 Sqlite 資料庫儲存示意

CCTV列表-(共59支攝影機)

大粗坑下游攝影機(121.836959, 25.090534)

2023/11/01 15:27:41

添加CCTV

站名:

縣市:

行政區:

架設或拍攝地點:

影像連結網址:

WGS84 X座標:






WGS84 Y座標:



(a)CCTV 列表與刪除

(b)新增 CCTV

圖 4-6 CCTV 列表與操作介面

表 4-9 地圖平臺介接電子地圖樣式

	
TGOS	OSM
	
OSM.DE	OSM.CH
	
OSM.France	OSM.HOT






圖 4-7 網頁服務平臺介面













圖 4-8 跳出視窗呈現成果

表 4-10 模式實際應用於 CCTV 辨識成果

原始影像	LSTM+ CNN	LSTM+ VGG16	LSTM+ VGG19	LSTM+ ResNet50
				
				
				
				
				
				
				
				
				
				

原始影像	LSTM+ CNN	LSTM+ VGG16	LSTM+ VGG19	LSTM+ ResNet50
				
				
				
				
				
				
				
				
				
				
				



第五章 結論與建議

第一節 結論

本節將就期末成果進行後續執行方向說明，茲將分述於下：

一、精進成果

精進部分可分為樣本面及模式面，在樣本面精進成果部分，根據本研究精煉後的影像進行各模式測試之成果顯示（如表 5-1），證明透過樣本調整手段將影像內容聚焦於災害本身之特徵係有助於提升模式辨識率，後續將根據此方法進行新增災害影像特徵選取與訓練樣本的擴充作業；模式面部分，可以調整超參數方式進行精進作業，本研究項計針對影像大小、影像序列長度、Epoch 數及學習速率進行模式的測試（如表 5-2 所示），預計有 240 種組合，各模式經參數調整測試後，精度確實有所提升，唯 LSTM+VGG19 略有下降，本研究成果顯示，在人工智慧模式之應用上以調樣或調參兩種手段皆可提升模式之辨識能力。

表 5-1 精煉影像訓練成果比較

模式	精煉前		精煉後	
	序列長度	最佳值	序列長度	最佳值
LSTM+CNN	20	84.91%	50	86.79%
LSTM+VGG16	50	76.79%	30	81.58%
LSTM+VGG19	40	66.04%	50	84.91%

表 5-2 模式調校參數組合成果比較

模式	調參前		調參後	
	序列長度	最佳值	序列長度	最佳值
LSTM+CNN	50	86.79%	50	88.68%
LSTM+VGG16	30	81.58%	25	86.79%
LSTM+VGG19	50	84.91%	25	81.13%

二、模式精煉成果

本研究為探討具有更深層且複雜的深度學習架構模式於坡地災害的辨識能力，選擇在影像辨識中最被廣泛應用之 ResNet-50 作為研究對象，經過本研究的建置與測試結果，LSTM+ResNet50 架構在有限的資源與影像長度下，經過參數調整後辨識度可達 90%，優於其他 3 種架構，因此證明愈深層的學習網路在影像細節特徵的萃取上優於於淺層網路。

三、應用面成果

本研究以 Django 框架作為開發環境，透過 Django 框架可快速建構影像辨識服務，其對於 python 的支援及後續模式擴充上皆相當充足，在網頁介面設計上提供多種樣式的電子地圖切換功能及介接農村水保署 CCTV 影像並直接進行線上更新作業，可於網頁平臺介面中進行點選 CCTV 點位圖示並顯示目前 CCTV 最新影像及各模式辨識成果。經本研究觀察應用於實際 CCTV 影像測試結果中發現，模式如預期有誤判之情形發生，主要為影像內有強烈變動情況，例如風吹草樹晃動範圍太大時，模式即有可能誤判為坡地災害，本研究透過實際應證實模式的可用性與其限制及可能產生誤判的癥結所在，可作為後續模式與架構的調整參考。

第二節 建議

本節就後續執行建議方向與項目進行說明：

一、樣本與模式精進方向

樣本部分建議可依本研究所建置之程序持續蒐整、擴充影像資料庫；模式面建議可於樣本蒐整至一定數量後重新訓練或就現有之訓練成果再行訓練，透過滾動式訓練提升模式辨識能力，後續在模式使用上目前可以本研究所提出之影像辨識架構進行，後續可加入現行之影像辨識模式或建立模式評估方式進行汰除更新，對於坡地災害發生示警部分可整合各模式的辨識結果以多數決或是權重評估方式來計算坡地災害發生與否，減少誤報之情形。

二、網站架構部分

在網站架構部分，由於訓練的模式係根據即有的影像資訊進行訓練無法包含各種現況，故模式需進行滾動式訓練增加其辨識能力，故於後續可就現有網頁服務平臺架構增加人機互動學習功能，當模式發生誤判情形時，可由人為的介入讓模式基於現有的學習成果下加入新的影像資訊再進行訓練，藉以持續提升模式的辨識能力。



參考文獻

1. 吳志泓、曾建濤、林孟緯、葉庭瑄、蕭一豪、羅世瑋、林芳邦、林信宏、常若愚，” 針對特定已知比例尺之標的物影像辨識進行淹水深度估算之方法” ，中華民國發明專利，專利字號：發明第 I720644 號，專利權期間自 2021 年 3 月 1 日至 2039 年 10 月 7 日止。
2. 胡舒閔、陳明源、羅佳明，2014，” 影像感測技術於邊坡運動監測之適用性初探” ，中華水土保持學報，第四十五卷，第一期，27-35 頁。
3. 陳柏蒼、李彥德，” 利用圖形辨識量測水位之方法及其系統” ，中華民國發明專利，專利字號：發明第 I690859 號，專利權期間自 2020 年 4 月 11 日至 2038 年 9 月 9 日止。
4. 黃國豪、黃效禹、林建良，2020，” 智慧型水位辨識結合物聯網應用於土石流防災監測” ，土木水利，第四十七卷，第三期。
5. 顏呈仰，2010，” TDR 監測系統與傳統監測方式應用於邊坡坡體滑動之比較” ，三聯技術雜誌，第 2-6 頁。
6. 蘇元風、張志新、陳宏宇，” 山區洪水偵測方法” ，專利證號：I650529，2019 年 2 月 11 日取得。

7. A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, in F. Pereira; C. J. C. Burges; L. Bottou & K. Q. Weinberger, ed., 'Advances in Neural Information Processing Systems 25' , Curran Associates, Inc., , pp. 1097—1105, 2012.
8. C. Shiranthika, N. Premakumara, H. -L. Chiu, H. Samani, C. Shyalika and C. -Y. Yang, "Human Activity Recognition Using CNN & LSTM," 2020 5th International Conference on Information Technology Research (ICITR), 2020, pp. 1-6, doi: 10.1109/ICITR51448.2020.9310792.
9. D.J. Varnes, “Slope movement types and processes”. In: Schuster RL, Krizek RJ (eds) Landslides, analysis and control, special report 176: Transportation research board, National Academy of Sciences, Washington, DC., pp. 11–33, 1978.
10. I. Salian, NVIDIA Research Achieves AI Training Breakthrough Using Limited Datasets , <https://blogs.nvidia.com/blog/2020/12/07/neurips-research-limited-data-gan/>, 2020.
11. J. Donahue et al., "Long-term recurrent convolutional networks for visual recognition and description," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 2625-2634, doi: 10.1109/CVPR.2015.7298878.
12. C.H. Kuo, Y.H. Chou, and P.C. Chang, “Using Deep Convolutional Neural Networks for Image Retrieval,” Electronic Imaging, 2016. 2016(2): p. 1-6.
13. M. D. Nguyen, H. N. Vu, D. C. Pham, B. Choi and S. Ro,

- “Multistage Real-Time Fire Detection Using Convolutional Neural Networks and Long Short-Term Memory Networks,” in IEEE Access, vol. 9, pp. 146667-146679, 2021, doi: 10.1109/ACCESS.2021.3122346.
14. R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh and D. Batra, Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization, 2017 IEEE International Conference on Computer Vision (ICCV), 2017, pp. 618-626, doi: 10.1109/ICCV.2017.74.
 15. KaimingHe, XiangyuZhang, ShaoqingRen and JianSun., DeepResidualLearningforImageRecognition, <https://arxiv.org/abs/1512.03385>.
 16. SIMONYAN K and ZISSERMAN A., Very deep convolutional networks for large-scale image recognition[C]. The 3rd International Conference on Learning Representations, San Diego, United States, 2015: 1–14.
 17. Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich., Going Deeper with Convolutions, Computer Vision and Pattern Recognition, 2014, arXiv:1409.4842, <https://doi.org/10.48550/arXiv.1409.4842>.
 18. Kim D, Won J, Lee E, Park KR, Kim J, Park S, Yang H and Cha M (2022) Disaster assessment using computer vision and satellite imagery: Applications in detecting water-related building damages. Front. Environ. Sci. 10:969758. doi: 10.3389/fenvs.2022.969758 .



附錄

附錄一、期初審查會議紀錄回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一	不同類型之坡地災害(如崩塌、落石、土石流、地滑…)等均有其他地形條件等，是否依地形條件事件分類屬於哪種災害類型後，再去針對不同類別分別學習及預測。	感謝委員建議，電腦視覺判斷模式的訓練需有判釋「標的」的紀錄，以本研究而言，標的為坡地「災害」，確實如委員所提，如能有各類地形條件下的災害分類，則模式的建置將更為完整妥適；然受限於災害紀錄影片取得的數量，目前以辨識各類坡災的行為特徵為主，且根據前期計畫所規劃之模式考量後續實務應用之便利性，故模式應用設計係以較具有通用性的坡地災害行為特徵為主要辨識條件，直接辨識影像場景中坡地災害之類型，如未來能取得更多的災害影像紀錄，續以地形條件為分類前提、再細分災害類別，模式亦將更為穩健。

項次	審查意見	回覆辦理情形
報告內容審查意見：		
二	前期計畫已完成 CCTV 影像辨識，今年度所提內容仍是使用各單位之 CCTV 影像，而其他單位拍攝重點不是坡地，且影像品質也不會變好，宜先解決根本問題。	感謝委員建議，本計畫研究課題主軸確如委員所言，如能有拍攝重點為坡的高品質影像，將有助於本計畫案的研究推行；但已建置的 CCTV 拍攝到災害發生且具高畫質的影像紀錄，在大局的協助取得下，數量猶稀，因此本計畫在此限制下，嘗試先不局限於 CCTV 的影像紀錄進行廣泛的災害影像蒐集，並以能判釋僅有的 CCTV 災害影像紀錄 (CCTV 災害影像紀錄稀缺，用於模式判釋能力檢核而不用於模式建置) 為研究主軸方向，而為能最大程度的彌補此一先天不足，本計畫同步啟動既有設備下最大可能的 CCTV 影像資料蒐整作業(包含大局 CCTV 系統以外的外單位監控影像蒐集)，目的在於盡可能地取得 CCTV 所拍

項次	審查意見	回覆辦理情形
報告內容審查意見：		
		攝之坡地災害影像，本計畫在進行 CCTV 影像蒐整時會先就所拍攝之範圍中是否有包含具備坡地災害發生之條件才予以納入蒐整清單之中，而今年度會根據所蒐整之 CCTV 影像介接於本計畫所規劃建置之「線上即時坡地災害影像觀測系統」中，進行即時監視測試，在實際應用上會以農村水保署現有之 CCTV 為主，外單位之 CCTV 影像為輔進行測試。而取得的 CCTV 影像品質，限制於影像提供單位，非本計畫所能介入，但大局中若可提供高解析度或高速串流之 CCTV 影像，本計畫亦可將之納入模式應用之壓力測試。

附錄二、期中審查會議紀錄回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一	本研究已有初步成果，效果尚佳，後續也預定對參數調校再予以加強，應可達成計畫目標。	感謝委員肯定，根據本研究新增之 LSTM+ResNet50 架構於測試影像上可達 90% 之辨識率，也優於原先使用之 CNN(88%)、VGG16(86.79%) 及 VGG19(81.13%) 架構，確實達成模式精進及預計之辨識率目標。
二	請評估模式的效能，包括 Recall, Precision 及運算時間等。	根據測試結果各模式最佳辨識率下之 Recall、Precision 及所需之訓練時間如下： LSTM+CNN(100%、88.68%、69.98 秒) LSTM+VGG16(100%、86.79%、250.24 秒) LSTM+VGG19(85.71%、81.13%、318.42 秒) LSTM+ResNet50(100%、90.57%、3127.62 秒)
三	請針對特殊狀況做測試，包括光線不足、下雨或部分遮蔽等	感謝委員建議，關於特殊狀況測試上主要透過本研究所架

項次	審查意見	回覆辦理情形
報告內容審查意見：		
	狀況之因應方式。	構之線上展示平臺進行呈現，透過即時的 CCTV 影像辨識即可進行各類情況的測試，在應用測試過程中本研究發現夜晚的紅外線影像係較容易造成模式誤判的時間段，於後續模式精進部分，可針對誤判區域再進行模式的強化訓練，以滾動式強化學習方式逐步精進模式的辨識能力。
四	P4-12 ResNet 模式的「關注熱區」是模式自行判定，或需先由人工指定？	關於模式的關注熱區部分，本研究採用 Selvaraju 等(2017)所提出之 Gradient-weighted Class Activation Mapping (Grad-CAM)演算法取得模式的觀注熱區，其主要使用梯度的全局平均來計算權重，以該權重對最後一層特徵圖進行線性組合的加權運算，最後以 ReLu 激活函數得到推算的辨識觀注熱區。
五	P4-16 每五鐘進行網頁內容	感謝委員建議，關於影像擷錄

項次	審查意見	回覆辦理情形
報告內容審查意見：		
	解析與影像擷錄乙次，如災害持續時間很短時，此五分鐘的間隔是否會漏判事件？	的時間長度主要受限於農村水保署公開之 CCTV 影像頻率，5 分鐘係本研究根據各 CCTV 影像播放特性所歸納出之平均值，對於發生時間急短的落石事件在現有的 CCTV 影像上確實有可能會有無法判辨的情形，但對於長時間發生的滑坡、土石流等災害係具備一定的辨識能力，在爬蟲設定上係可隨農村水保署所提供之影像更新率進行調整，未來若能提供每秒影像，對於模式的辨識將可更為精確。
六	本案延續前期研究成果，精進現有 CCTV 材料，結合影像判釋技術，運用有限影像源進行處理。建議調整資料庫與目前對災害的定義、條件、調整目的補充於影像庫精煉章節，比如 P4-1 期中成果，類別欄位偵測 Collapse 崩塌，針對	感謝委員建議，已於本文補充說明前期研究之成果及相關之樣本類別與樣本組合等資訊，以利於委員瞭解前期研究之成果，在地坡地災害類別中本研究區分為滑坡 (Collapse)、土石流 (DebrisFlow) 及落石 (Rockfall) 3 類，再加上

項次	審查意見	回覆辦理情形
報告內容審查意見：		
	崩塌設定的辨識條件，前期遇到的辨識情境，與本計畫目前的演算法調整方向，建議列出比較表或架構表，將有助於技術成熟度評估與後續應用參考。	非坡地災害 (None) 類別，共 4 類，於前期研究中證實可透過樣本調整手段提升模式的辨識能力，故於本年度提出更進一步針對影像內容進行操作，以瞭解影像內容對於模式辨識學習的提升效果，就本研究而言，透過聚焦動作對於模式的辨識係有所幫助的，也提供未來在進行影像識別模式訓練時可嘗試之方法之一。在演算法調整上主要係以超參數調整進行測試，在不同的時間序列長度、訓練次數、收斂速度、Epochs 數量共 240 種組合下之辨識能力評估，整體測成果於表 4-6 中有完整呈現，經測試發現各模式最佳辨識能力的參數組合不盡相同，但學習速度都分布於 0.001，故於後續模式超參數調整上學習速率可以 0.001 作為初始

項次	審查意見	回覆辦理情形
報告內容審查意見：		
		設定，其餘參數建議就模式特性及樣本特性再行測試。
七	階段成果中，建置 Demo 網站，有助於效果呈現與驗證討論系統可行性。創研計畫之系統雛型常具有發展潛力，惟大原則上，最終皆希望能模組化納入本署既有系統或技術架構，建議可評估系統架構模組化可能性。	感謝委員建議與肯定，就現皆段本研究所提出的雛型架構確實能夠直接進行實際應用，關於模式模組化部分，本研究團隊正評估及研討再精進應用的方案，例如以 API 方式提供模式辨識服務，抑或以軟硬整合方式開發低廉可廣布之實體監測儀器等皆係可發展之方向，就綜合探討結果本研究提供多種深度之模式可進行多面向辨識結果，但在各模式中之訓練影像資料庫中欠缺夜間坡地災害影像，故對於夜間的坡地災害辨識能力較為薄弱，後續可針對高坡地災害發生之區域建立高幀度的 CCTV 系統進行持續性的坡地監測任務，並將監錄之影像資訊作為擴充坡地災害資

項次	審查意見	回覆辦理情形
報告內容審查意見：		
		料庫之用，以此完善各模式全天候非接觸式坡地災害監測目標。
八	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管理中心下載(https://elibrary.ardswc.gov.tw/)。	感謝委員指正，已照範本進行修正，並修正內文用語。



附錄三、期末成效評核及審查意見回覆辦理情形


一、計畫編號：112 保發-5.1-保-01-06-001(43)

二、計畫名稱：坡地災害辨識電腦視覺模式精進與應用評估

三、計畫執行機關：逢甲大學

四、計畫主持人：陳昶憲特聘教授

五、期末聯合審查評核問卷統計



六、審查意見：

- (一)坡地災害類型眾多，CCTV 影像受天候影響，依日前研究成果後續如何精進才能提升正確性或應用性。
- (二)影像庫樣本是否有納入天候或影像不佳者進行訓練？所採用 CCTV 影像品質是否適用？
- (三)影像辨識方法與應用發展已久，實務面上的經濟可行性如何？
- (四)辨識的成功率如何？若是在現地環境極不穩定或氣候不佳的情形下，是否能夠穩定的運行？
- (五)訓練樣本數太少，使用深度學習模型來訓練，卷積層數太多，並不可能會有準確的效果，所以 VGG16, VGG19 的準確率比 CNN 低，應更好效率的設計研究流程所須測試的模型。
- (六)樣本數太多及動態影像的問題，可以使用 Data argumentation 來試著解決（例 平移像窗口，對稱 folding）。
- (七)是否考慮過使用 transfer learning 的分析技術？
- (八)計畫以災害影片訓練電腦模式，有助益未來土石流等災害的辨識，實為可行性高的研究。但是訓練影片少且參數數量多，容易有 overfitting 之情形。建議本研究說明各模式或參數篩選的基準並說明如何避免 overfitting 的情形。

七、計畫主辦單位期末評核結果

請勾選	☒ 通過，相關建議如上項說明
	☐ 修正後通過，修正事項如上項建議 說明：_____
	☐ 不予通過，辦理 ☐ 複審或 ☐ 計畫終止 說明：_____

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一	坡地災害類型眾多，CCTV 影像受天候影響，依日前研究成果後續如何精進才能提升正確性或應用性。	感謝委員，對於後續精進部分，本研究建議可搭配平臺系統進行滾動式修正，透過平臺之人機介面，在模式發生誤判情形下，以人為方式選取誤判影像區段，將其所選之影像產製為新的訓練樣本並重新訓練模式，以此方式逐步擴充訓練樣本集及提升各模式的辨識能力。
二	影像庫樣本是否有納入天候或影像不佳者進行訓練？所採用 CCTV 影像品質是否適用？	1.在樣本庫中坡地災害部分主要使用一般民眾所拍攝之影像，故以白天可見之影像為主，在一般非坡地災害部分係以 CCTV 所組織而成的影像，一般影像包含了日間、夜晚、風吹、降雨、雲霧等氣候條件，在非坡地災害訓練影像中係較具有全天候的情境。 2.在 CCTV 影像品質部分，農村水保署所提供之 CCTV

項次	審查意見	回覆辦理情形
報告內容審查意見：		
		影像解析度基本上係能夠滿足本研究於坡地災害辨識使用，未來如農村水保署能建置高幀數之 CCTV 系統，可直接介接並進行模式測試。
三	影像辨識方法與應用發展已久，實務面上的經濟可行性如何？	在本研究中透過平臺建置測試結果顯示各模式實際應用於 CCTV 上皆可正常運行且能夠進行影像內容辨識，但礙於訓練影像缺乏夜間坡地災害之影像，故在各模式之夜間辨識能力上較易產生誤判情形，整體而言，透過後端（模式建置）與前端（展示平臺）的架構係具有一定可行性，本研究所提之架構，以現有 CCTV 即可達到監測之目的，後續 CCTV 之提升亦不影響後端之模式，因此整體建構成本是具有經濟效益。
四	辨識的成功率如何？若是在	1.在測試資料各模式的辨識

項次	審查意見	回覆辦理情形
報告內容審查意見：		
	現地環境極不穩定或氣候不佳的情形下，是否能夠穩定的運行？	率上皆有 80%以上，其中 ResNet50+LSTM 可達到 90%，實際應用於 CCTV 監測上，發現在夜間遠紅外線影像部分較易產生誤判，另陰天降雨情境下也有誤判之情形，但非所有模式都會產生一致性的誤判。 2.本模式主要係擷取 CCTV 影像進行辨識，故在 CCTV 影像能持續提供且網路連線無礙情形下，本研究模式皆可持續運作。
五	訓練樣本數太少，使用深度學習模型來訓練，卷積層數太多，並不可能會有準確的效果，所以 VGG16,VGG19 的準確率比 CNN 低，應更好效率的設計研究流程所須測試的模型。	1.謝謝委員建議，在本研究中所使用之模式(CNN、VGG16、VGG19 及 ResNet50)有深有淺，有簡有繁，主要目的係想瞭解不同網路結構在辨識上的差異，其中 VGG16、VGG19 在測試樣本下的辨識度確實低於 CNN，但更為複雜且深層的 ResNet50 表

項次	審查意見	回覆辦理情形
報告內容審查意見：		
		現上係優於 CNN，在未來係可再測試更多模式或以 ResNet 為基礎發展坡地災害辨識網路架構。
六	樣本數太多及動態影像的問題，可以使用 Data argumentation 來試著解決(例 平移像窗口，對稱 folding)。	感謝委員建議，透過 Data argumentation 方式在靜態影像辨識上確實可作為增加影像樣本多樣性之方法，但本研究主要係針對 CCTV 所拍攝之影像，其在角度或環境上具有侷限性，故在本研究上僅進行直方圖的均化作業及影像大小的縮放，在後續的研究上建議可加入各種情境濾鏡模擬不同氣候條件，例如不同降雨強度、雲霧、光照等濾鏡以增加影像多樣性。
七	是否考慮過使用 transfer learning 的分析技術？	是的，感謝委員建議，本研究目前主要以現有模試進行測試並瞭解坡地災害辨識模式可發展之方向，根據測試結果可朝，委員所提之 transf

項次	審查意見	回覆辦理情形
報告內容審查意見：		
		er learning 係可於下一階段中進行更深入的討論不同的遷移學習方式對於坡地災害辨識之效果並以遷移學習之經驗建構可通用於坡地災害辨識之模式。
八	計畫以災害影片訓練電腦模式，有助益未來土石流等災害的辨識，實為可行性高的研究。但是訓練影片少且參數數量多，容易有 overfitting 之情形，建議本研究說明各模式或參數篩選的基準並說明如何避免 overfitting 的情形。	感謝委員肯定與建議，本研究所使用的影像相較現有深度學習所使用之影像數量確實是少，但本研究主要係以影片為主，故可就每一影片擷取不同影格長度再組合成訓練影像集，因此每一影像的訓練資料係足夠的，在模式結構的設計上，本研究採用 Dropout 方式來避免模式 overfitting，在各模式參數設定上係設定影像大小、影像序列長度、學習速度及 Epoch 數後，所有模式皆以同樣的訓練樣本及測試樣本進行測試及以測試樣本辨識能力進行評估。