

計畫編號：111 保發-8.1-保-01-06-001(20)

---

區域性中長期智慧降雨預報輔助土石災害  
預警系統之建構

Medium to long term regional  
precipitation forecast for debris flow  
disaster prevention using deep learning  
models

---

執行單位：國立臺灣大學

執行期間：111 年 01 月 18 日至 111 年 12 月 31 日

計畫主持人：胡明哲 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

(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)



# 區域性中長期智慧降雨預報輔助土石災害預警系統之 建構

## 摘要

本研究將利用 Windy 天氣預報（歐洲 ECMWF 模式、美國 GFS 模式）之相關影像資料，結合臺灣本島之降雨氣象雷達觀測資訊、既有雨量站歷史降雨資料（可應用於土石流潛勢溪流影響範圍與大規模崩塌潛勢區影響範圍），利用深度學習模式 CNN、RNN 以及 LSTM，建立中期數值天氣預報、雷達觀測、與降雨預測之人工智慧深度學習模式，針對易發生土石災害的重點地區，提供短至中長期的降雨預報資訊，以期達到爭取防災操作時間、未來十日土石災害預警、以及中長期水土資源保育與規劃改善之用。

**關鍵詞：**深度學習模式、降雨預測、雷達回波、中長期天氣預報。



# **Medium to long term regional precipitation forecast for debris flow disaster prevention using deep learning models**

## **Abstract**

This research aims to establish an artificial intelligence deep learning model for precipitation prediction to supplement the debris flow disaster warning system. The regional weather forecast of Windy websites (the ECMWF and the NOAA's GFS model data), the local weather radar observation information in Taiwan, the historical precipitation data (in the influence area map of the debris flow disasters and large-scale landslides) will be collected and applied to achieve this goal. The deep learning precipitation prediction model will utilize neural network algorithms, such as CNN, RNN, and LSTM, to generate precipitation prediction/forecast for hours to days. This research has three objectives. The first is to provide more operation time for debris flow disaster prevention actions other than just 2 to 3 hours at present time. The second is to have an early warning for debris hazards forecast in the next ten days. And the third is to make suggestions for medium to long term water and soil resources conservation and planning for authorities.

**Keywords: Deep learning models, Precipitation prediction, Radar return, Medium to long term weather forecast.**



# 目次

摘要.....	I
Abstract.....	III
目次.....	V
表次.....	VII
圖次.....	IX
第一章 緒論 .....	1-1
第一節 計畫緣起 .....	1-1
第二節 計畫目標 .....	1-5
第二章 工作執行方法與步驟 .....	2-1
第一節 工作項目與執行方法 .....	2-1
第二節 工作預定進度與流程 .....	2-1
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 .....	3-2
第四章 工作項目及計畫成果 .....	4-1
第一節 資料蒐集及處理 .....	4-1
第二節 深度學習模型建立與訓練與網路爬取資 料程式 .....	4-3
第三節 資料資料與程式碼連結 .....	4-11
第五章 結論及建議 .....	5-1
第一節 結論 .....	5-1
第二節 建議 .....	5-2
參考文獻.....	參-1
附錄.....	附錄-1

附錄一、期初審查會議紀錄暨回覆辦理情形 .....	附錄-1
附錄二、期中審查會議紀錄暨回覆辦理情形 .....	附錄-4
附錄三、期末審查會議紀錄暨回覆辦理情形 .....	附錄-7



## 表次

表 3-1 重要工作項目與已執行進度.....	3-1
-------------------------	-----

(以下略)



## 圖次

圖 1-1 ECMWF 與 GFS 的預測準確率比較 .....	1-3
圖 2-1 石門水庫集水區雨量站分佈圖 .....	2-3
圖 3-1 計畫流程圖 .....	3-2
(以下略)	



## 第一章 緒論

### 第一節 計畫緣起

臺灣擁有多元的地貌，有高達三、四千公尺的高山群、間有丘陵、台地、盆地、平原、以及沿岸沙洲群，交錯密佈在這個長 394 公里、寬 140 公里的島嶼上，加之位處（亞）熱帶及深受季風與颱風影響所形成的高溫多雨氣候，要時刻維持人為開發活動與自然水土環境之間的平衡共存實屬不易。

對高溫多雨且地勢陡峭的臺灣而言，降雨是一切水土災害的起始驅動力。針對最易在短時間內造成嚴重災害的土石流與大規模崩塌，行政院農委會水保局架設的土石流防災資訊網 (<https://246.swcb.gov.tw/>)，提供一般民眾查詢各地區的土石流警戒基準值與大規模崩塌警戒基準值，以達提前預警與疏散人員之功效。目前以上兩種警戒皆以降雨量為評判指標，由此可知，若能掌握各地區的長期、即時、甚且未來近期內的降雨型態與趨勢，對於區域及整體的水土保持規劃與災害預防都有相當程度的助益。

110 年度氣象防災資訊應用研討會中，水保局曾針對提問說明，目前土石流警戒的發佈是依據雨量站的累積雨量來區分紅黃色警戒，但是因為架設雨量站的位置，其降雨量不一定能代表其所控制集水區的所有降雨量，可能造成與現實狀況不符。當（氣象局）預測雨量達到紅色警戒而需疏散民眾避難時，可能會面臨困擾與不易執行的情況發生。除了適時調整紅黃警戒值之外，水保局也認為未來發布土石流警戒時，一併將氣象局提供之降雨雷達資料納入參考，將可更貼近現地狀況。氣象局亦補充說明：氣象局的雨量預測準確與否，確實

會直接影響到土石流紅黃警戒的判斷。氣象局近年已可提供更精確的防災降雨雷達資料，在一般情況下，雷達的降雨估計可較數值天氣預報(Numerical Weather Prediction)模式準確，但時間最多只能到發生前 2 小時，可供防災操作的時間稍嫌不足，因此仍需要數值天氣預報來輔助決策。

數值天氣（氣候）預報模式可提供前置期未來 12~24 小時、甚且是中長期天氣與氣候的資訊，在空間上則可達到即使廣設雨量站亦無法達成的精細且分散均勻的解析度。雷達觀測降雨估計則可提供現時與未來 2 小時的即時資訊，卻有著設置地點有限及易受高山與地形屏阻的缺點。如何結合兩者之優勢，以獲取更多、更準確的降雨預報資訊，在短時間期距內（如 2~12 小時）可爭取防災操作時間，在未來十日內可評估土石流發生風險之高低，而在中長期則可進行水土資源的保育與規劃，此即本研究預計探討並解決之問題。

1954 年農業試驗所啟動「農林邊際地可利用限度分類調查」，此為臺灣水土保育工作之開端。時至今日，裨益於日新月異的科技進展，我們已從僅能被動的事（災）後調查，拓展至主動的事前規劃、即時監測、以及提前預警。然而，儘管累積了大量且長期的現況與調查結果、運用了已知的各式學術理論機制、參酌了極端事件的風險因子，並據以設立了詳盡的水土保持規範與施行細則，不可否認地，面對這關係複雜、涉及地表上、地表、與地表下三層空間內的水與土的問題，其中仍存在吾人未盡詳知的奧秘，殊難單純名之以因果。

數值理論天氣預報模式應用於降雨預測已行之有年，預測結果於時間空間上的精細度與準確度，常有賴於大量電腦運算力、完備的理論基礎、模式相關係數與參數的繁複調校、以及由充足的實際觀測資

料分析所得的模式初始運算狀態。歐洲中期天氣預報中心(European Center for Medium-Range Weather Forecasts, ECMWF)及美國國家海洋暨大氣總署(National Oceanic and Atmospheric Administration, NOAA)環球預報系統(Global Forecast System, GFS)是目前最具公信力且最複雜的兩大氣象預報系統，兩者之發展過程與任務取向不盡相同。一般而言，ECMWF 的預報準確率略高於 GFS（見圖 1-1），但在某些局部地區的氣象事件中，GFS 仍能取得優於 ECMWF 的預報結果，NOAA 亦長期持續地投入 GFS 的研發與提升(Bassill 2014; Sillin 2019; Douglas 2021)。




圖 1-1 ECMWF 與 GFS 的預測準確率比較

資料來源：<https://blog.weather.us/>

數值氣象預報系統有其立基於真實世界因果關係的理論優勢，卻也不免受制於已知理論的侷限以及繁瑣的運算過程而缺乏彈性。應用類神經網路(Neural Network)的機器學習(Machine Learning)演算法則為降雨預測提供了另一條蹊徑。近年來，電腦運算能力的顯著提升大大降低了計算成本，某種程度上解除了以往阻礙大型類神經網路演算

發展的問題，加上演算法的持續精進，以人工神經網路(Artificial Neural Network, ANN)為架構，且基於數學與閾值(threshold)邏輯的演算法，遂由機器學習更進一步發展為時下所趨的深度學習(Deep Learning)，並衍生出各式深度學習框架，如深度神經網路(Deep Neural Network, DNN)、卷積神經網路(Convolutional Neural Network, CNN)、深度置信網路(Deep Belief Network, DBN)、與循環神經網路(Recurrent Neural Network, RNN) 等。在電腦視覺、語音辨識、圖形辨識、與生物資訊學等領域的應用，都有相當不錯的成效。2015 年人工智慧圍棋軟體 AlphaGo 擊敗職業棋士，是當年最廣為世人所知的應用實例之一。該研發團隊 DeepMind (<https://deepmind.com/>)後續與英國氣象局合作，於 2021 年開發了應用機器學習的降水即時預報(Precipitation Nowcasting)，利用高解析雷達資料，預測未來 2 小時的雷達資料並生成系集預報(Ensemble Predictions)，可進一步推估降雨機率，其預報結果獲得大多數氣象預報專家的認可與支持採用(Ravuri et al., 2021)。

ECMWF 與 GFS 模式皆為基於全球大氣環流尺度的天氣預報數值模式，對於中長期與大範圍的氣象發展趨勢都有極佳的掌握。本計畫研擬借助於上述模式之科研成果與發佈之天氣預報相關影像資料，配合臺灣的區域雷達觀測網、以及既有雨量站歷史降雨量記錄，應用人工智慧深度學習模式專長於圖形辨識之優勢，建立中長期數值天氣預報、雷達觀測、與降雨預測之人工智慧深度學習模式。將天氣預報的空間尺度由全球與區域(ECMWF、GFS)、局部地區(雷達)、單一點(雨量站)，由上而下串連起來；時間尺度則由過往中長期(ECMWF 及 GFS)連結至短延時(雷達與雨量站)，再應用於預測



未來短至中長期的雷達回波與降雨量。後續再輔以水保局公布之土石流潛勢溪流影響範圍圖與大規模崩塌潛勢區影響範圍圖，針對易發生土石災害的重點地區，提供短至中長期的降雨預報資訊，以期達到爭取防災的事前操作時間、未來十日土石災害潛勢之預警、以及中長期水土資源保育與規劃改善之用。

## 第二節 計畫目標

本研究分析資料將利用Windy天氣預報網站之天氣預報相關影像資料（包含ECMWF模式與GFS模式等資料），可再結合臺灣區域之降雨觀測資訊、既有雨量站歷史降雨資料，研究土石流潛勢溪流影響範圍圖與大規模崩塌潛勢區影響範圍等區域，建構深度學習模式CNN結合LSTM（Long Short-Term Memory，長短期記憶）之模型，作為中期數值天氣預報、雷達觀測、與降雨預測之人工智慧深度學習模式，可提供易發生土石災害的重點地區之短至中長期的降雨預報資訊，以期達到爭取防災的事前操作時間、未來十日土石災害潛勢之預警、以及中長期水土資源保育與規劃改善之用。具體計畫目標包括：

### 一、資料蒐集、整理與分析

蒐集並整理數值天氣預報模式產出之預報資料、臺灣降雨氣象雷達觀測資訊、雨量站歷史降雨資料、以及土石流潛勢溪流影響範圍圖與大規模崩塌潛勢區影響範圍圖，整合建構一套符合土石流災害預警系統所需之上中下游系統資料庫。

### 二、人工智慧深度學習降雨預測模式之建構、訓練及驗證

了解既有的機器學習演算法之演進與其長處，擇定適合本計劃之

深度學習模式，整合上述之系統資料庫，建立中期數值天氣預報、雷達觀測、與降雨預測之人工智慧深度學習模式，針對易發生土石災害的重點地區，提供短至中長期的降雨預報資訊。

### **三、提供土石災害預警與水土資源保育規劃之建議**

利用建置並完成訓練的人工智慧機器學習降雨預報模式，針對土石災害重點地區，提供相關預報資訊以輔助土石災害預警系統之決策操作，期望透過數據科學的靈活運用，增加區域降雨預報的可信度，進一步強化掌控災害風險的能力。

## 第二章 工作執行方法與步驟

### 第一節 工作項目與執行方法

本研究將利用 Windy 天氣預報網站（歐洲 ECMWF 模式、美國 GFS 模式）之相關影像資料，結合臺灣本島之降雨氣象雷達觀測資訊、既有雨量站歷史降雨資料、應用於土石流潛勢溪流影響範圍圖與大規模崩塌潛勢區影響範圍，建立深度學習模式 CNN、RNN 以及 LSTM，作為中期數值天氣預報與降雨預測之人工智慧深度學習模式，可應用易發生土石災害的重點地區，提供短至中長期的降雨預報資訊，以期達到爭取防災操作時間、未來十日土石災害預警、以及中長期水土資源保育與規劃改善之用，以下為本計畫之執行方法與步驟。

### 第二節 工作預定進度與流程

#### 一、資料蒐集、整理與分析

本計畫預計應用且需取得的資料相當多元且大量，包含氣象預報影像資料、氣象雷達觀測資料、雨量站降雨資料、以及土石災害空間分佈及特性資料，囊括了不同時間以及空間尺度，須詳加檢視各類資料所對應之時空尺度，取得符合本計畫目標所需之資材，整合建構一套上中下游系統資料庫，以利後續資料之整合與應用。上游意指氣象預報與雷達回波，中間為雨量站歷史紀錄，下游端則為土石災害空間分佈資料，並視個別之資料特性予以適時更新。

本研究利用 Windy 天氣預報網站上之以歐洲氣象模式 ECMWF 資料，再結合研究區域之雨量觀測（如中央氣象局、水利署、水保局、

水庫管理局等相關資料)，利用全臺各地所分設的雨量站之逐時、逐日以及逐月的降水量觀測等資料，作為深度學習模式之訓練與驗證資料。

本研究應用區域於石門水庫集水區內，根據研究調查指出，石門水庫集水區內岩石劈理節理與裂縫發達，再經地殼變動之強力擠壓破壞，加之地形陡峻、雨水充沛，遂成為崩塌地高潛能地帶與土石流之料源區。區內之崩塌與溪流沖刷、人為道路開闢及聚落開發活動皆有關係，近年因全球氣候變遷所造成的極端降雨也可能是形成崩塌的原因之一（黃宏斌、徐肇斌、謝孟荃，2006）。石門水庫管理局於水庫集水區設置有石門、霞雲、高義、巴陵、嘎拉賀、池端、玉峰、白石、鎮西堡、西丘斯山共 10 個雨量觀測站（見圖 2-1），其行政區位分屬桃園市復興區、新竹縣尖石鄉與宜蘭縣大同鄉；中央氣象局則於桃園市復興區設立復興氣象站，觀測項目包括雨量、氣溫、風速/風向、氣壓、日照時數與濕度，資料起始自 2007 年 10 月 1 日。

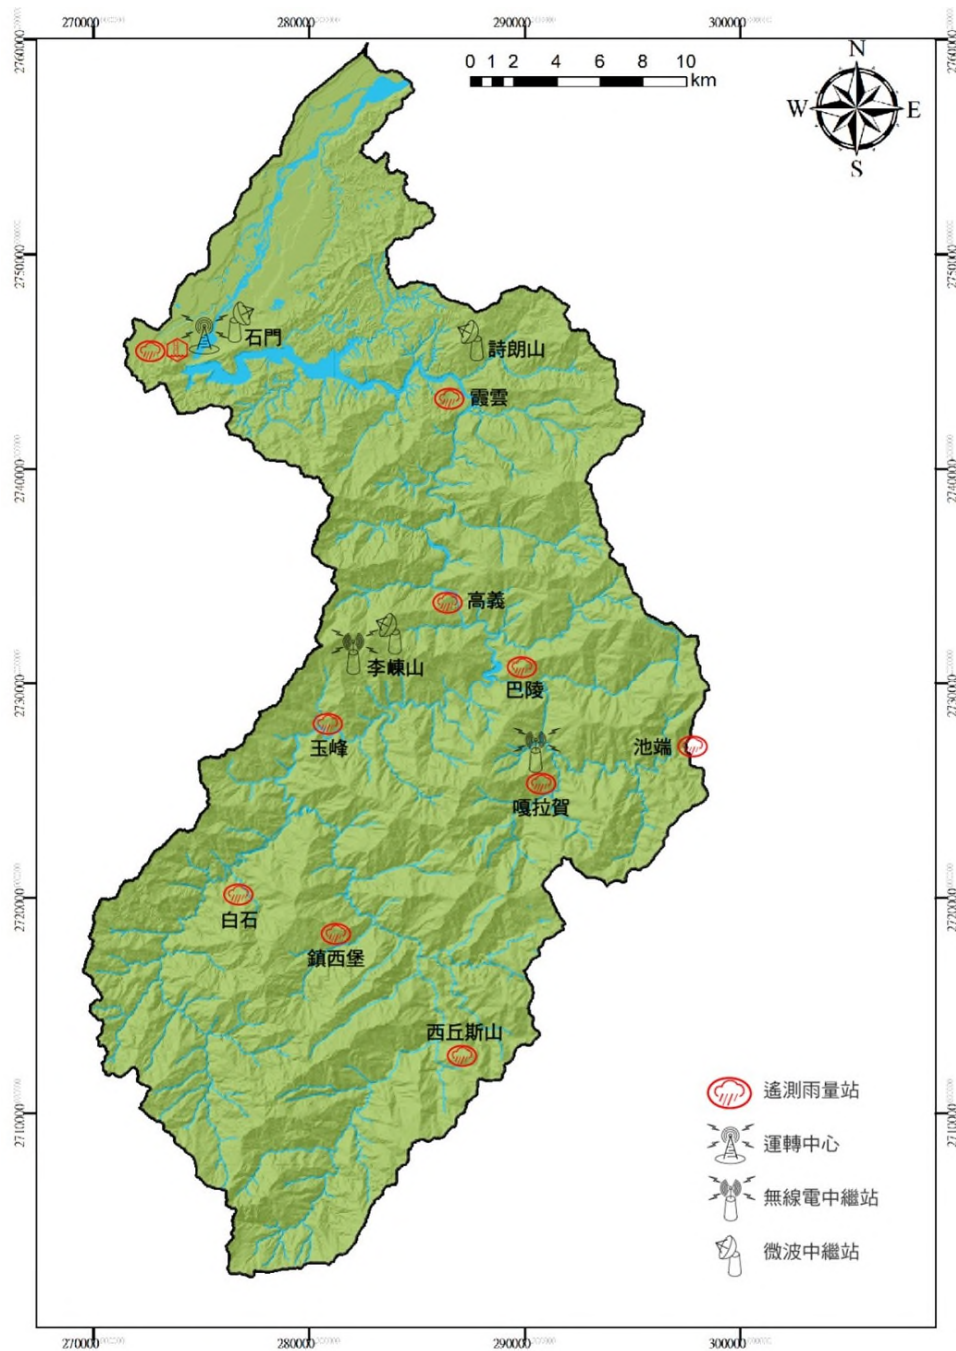


圖 2-1 石門水庫集水區雨量站分佈圖

資料來源：北區水資源局網頁

水保局於此區亦設立了義興、蘇樂、高坡國小、雪霧鬧聚落、光華農路等雨量站，觀測當地降雨量以作為發布土石流警戒之依據。土石流防災資訊網則整合了上述各單位之資料，提供當日不同長短延時的即時累積雨量的查詢展示，以達防災監測預警之效。

其中，蘇樂站乃因當地於民國 96 年 6 月 4 日發生洪水災害、導致蘇樂橋中斷與兩端道路毀損約 50 公尺之後而設立。事後檢討，災害發生時鄰近的高義雨量站有效累積雨量為 133mm。水保局遂於民國 97 年間完成桃園縣復興區高義村蘇樂觀測站之建置，於現場設置攝影機與雨量計，用以觀測溪流現場動態情況，掌握現場即時影像資訊，以及量測觀測站當地降雨量，作為發布土石流警戒之重要依據。嗣後民國 104 年杜鵑颱風，蘇樂累積雨量達警戒值，未發生土石流；民國 110 年烟花颱風暨 0130 光華崩塌，蘇樂累積雨量達警戒值 369.8mm，未發生土石流。

綜上所述，本計畫預計以石門水庫集水區為目標研究區域，進行分類、蒐集、檢視與彙整各項所需及可得資料，包含氣象預報影像資料、雷達觀測資料、雨量站降雨資料、以及土石災害空間分佈及特性資料，整合建構一套上中下游系統資料庫，以提供後續人工智慧深度學習模式之建構與應用，並視個別之資料特性予以適時更新。

## **二、人工智慧深度學習模式之建構、訓練及驗證**

機器學習是利用人工智慧在經驗學習中改善具體演算法的效能，著重於人工智慧從資料中學習，並根據經驗不斷改進。在機器學習中，會藉由資料集去訓練模型並建立資料之間的關聯性，並根據該分析做出最佳決策或是進行預測。當存取的資料越多，機器學習會不斷修正、改善，可使預測準確度越高。

深度學習是機器學習的分支，不同於一般的機器學習，深度學習是模仿人類大腦神經運作方式，以人工神經網路為架構，對資料進行分析、學習，從中生產出一個演算法，而新的資料加入時可進行演算法的修正，也就是讓機器模仿人類思考、學習。隨著現代科技的發展，

至今已有各式各樣的深度學習演算法，本計畫即預計使用 CNN、RNN 與 LSTM 建立模型，並利用雷達回波觀測資料進行降雨量預測。各演算法之基本原理簡略說明詳見第三章。

### 三、模式成果應用評估

建構完成之模式，應用上可結合歷史氣象、降雨及土石災害事件，進行模式的應用評估，亦即所謂的 data reanalysis，回顧分析探討過去事件，並從中檢討與經驗學習。

### 四、土石災害預警與水土資源保育規劃之建議

利用建置並完成訓練的人工智慧機器學習降雨預報模式，針對土石災害重點地區，提供相關預報資訊以輔助土石災害預警系統之決策操作，期望透過數據科學的靈活運用，提升區域短中長期降雨預報的可信度，進一步強化掌控災害風險的能力。後續更可以結合全島地形特徵、地表特性資料，例如坡度、植被狀態、地質特性、開發程度等，搭配中長期降雨預測資訊，提供未來水土資源的保育與開發規劃之建議。由於中長期預報資料不準確性高於短期預報，本計畫研究模型之雨量預測與趨勢，並非直接應用於土石流預警，仍需以短期預報為預警之主要依據，若實際狀況及短期預報之發展趨勢與本模式之預報趨勢一致時，則所產出的短至中長期預測即具有相當之參考價值，可藉此增加防災預警的事前可操作時間、提示未來十日土石災害之潛勢預警、以及中長期水土資源保育與規劃改善之用。





### 第三章 工作進度與交付項目

#### 第一節 計畫甘特圖

工作項目與執行進度之時程如表 3-1 所示，計畫流程則如圖 3-1 所示。本研究已經依規劃完成工作項目進度：(1)資料蒐集、整理與分析、(2)深度學習模式之文獻蒐集與比較、(3)人工智慧深度學習模式之建構、(4)深度學習降雨預報模式之訓練、測試與驗證、(5)模式成果應用評估、期末報告、研討會成果報告、(6)土石災害預警與水土資源保育規劃規劃之建議。

表 3-1 重要工作項目與已執行進度

重要工作項目	比重 %	預定 進度	111 年			
			1-3 月	4-6 月	7-9 月	10-12 月
資料蒐集、整理與分析	15	工作量	<u>50</u>	<u>50</u>	<u>0</u>	<u>0</u>
		累計百分比	<u>50</u>	<u>100</u>	<u>100</u>	<u>100</u>
深度學習模式之文獻蒐集與比較	5	工作量	<u>100</u>	<u>0</u>	<u>0</u>	<u>0</u>
		累計百分比	<u>100</u>	<u>100</u>	<u>100</u>	<u>100</u>
人工智慧深度學習模式之建構	15	工作量	<u>10</u>	<u>80</u>	<u>10</u>	<u>0</u>
		累計百分比	<u>10</u>	<u>90</u>	<u>100</u>	<u>100</u>
深度學習降雨預報模式之訓練、測試與驗證	25	工作量	<u>0</u>	<u>40</u>	<u>50</u>	<u>10</u>
		累計百分比	<u>0</u>	<u>40</u>	<u>90</u>	<u>100</u>
模式成果應用評估、期末報告、研討會成果報告	20	工作量	<u>0</u>	<u>0</u>	<u>40</u>	<u>60</u>
		累計百分比	<u>0</u>	<u>0</u>	<u>40</u>	<u>100</u>
土石災害預警與水土資源保育規劃之建議	20	工作量	<u>0</u>	<u>0</u>	<u>10</u>	<u>90</u>
		累計百分比	<u>0</u>	<u>0</u>	<u>10</u>	<u>100</u>
累計總進度	百分比		<u>14</u>	<u>44</u>	<u>68</u>	<u>100</u>

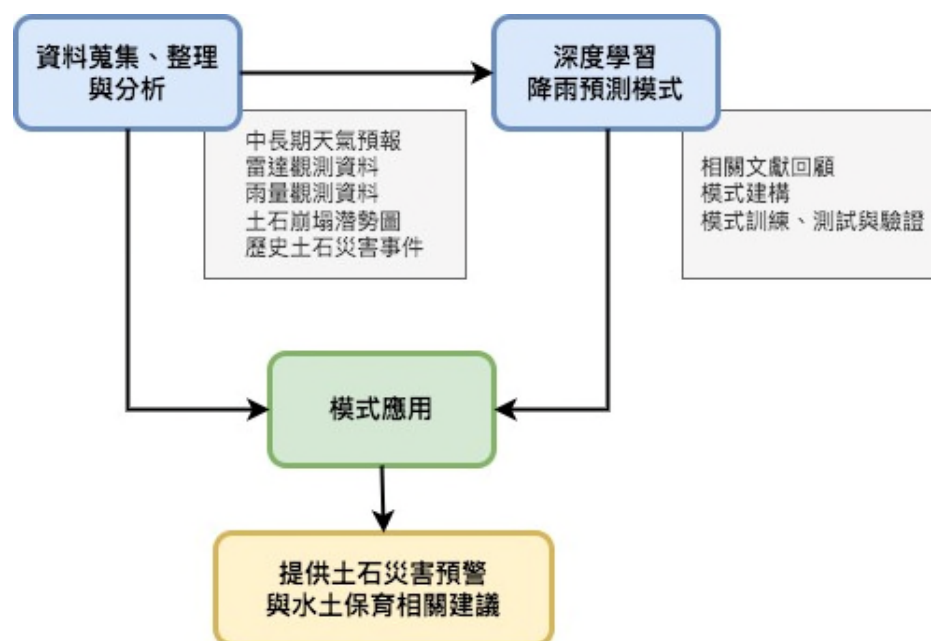


圖 3-1 計畫流程圖

## 第二節 計畫交付項目

本計畫由 Windy 天氣預報擷取雷達回波資料，雷達回波資料是由大氣中的降水粒子所反射回來的訊號，其建構的雷達回波圖可以判斷天氣系統的降水強度與分布狀況(交通部中央氣象局, 2022a)。回波的強度越高，所反射的訊號強度也越強，其強度單位為 dBZ，可以用來描述雷達反射率之比例。當 dBZ 值小於零時表示雖有凝結形成降雨粒子，但是幾乎不降雨；20 以下為起霧狀態，超過二十就是感受得到的小雨，如毛毛雨，30 以下都是小雨，45 以上為豪雨或雷雨等級，若是降冰雹，則其值會在 55dBZ 以上(駱銘樂, 2009)。

Shi et al. (2015)提出 conv-LSTM，將 2 維的圖像矩陣轉換成 3 維

的張量，並利用卷積層獲取空間關係，改進原本 LSTM 模型只能捕捉時間關係的缺點。

Wang, Long, Wang, Gao, and Yu (2017)將 conv-LSTM 進行堆疊，提出 Pred-RNN。將時空間的關係記憶在平行的 LSTM 或 GRU-cell，改善 conv-LSTM 底層會忽略頂層在上一時間中儲存的內容，將記憶單元與各個層之間獨立開來。Wang et al. (2018)提出 EIDETIC 3D LSTM，結合 3DConv 與 LSTM，利用 3DConv 捕捉短期的局部特徵，與利用 RNN 捕捉長期的時間特徵。

Xu, Du, Wang, Jiang, and Ren (2019)提出將 GAN 與 LSTM 結合，先利用過去觀測到的衛星雲圖訓練 GAN，再利用 LSTM 訓練得到的預測衛星雲圖訓練 GAN。Tian, Li, Ye, Xie, and Li (2019) 利用雷達回波圖來預測降水利用雷達回波圖來預測降雨，使用的模型為 GAN-ConvGRU 模型，改進應用 ConvGRU 模型會產生較為模糊的雷達回波圖像的問題。Ravuri et al. (2021)提出 DGMR 模型，將 GAN 中的判別器分成空間與時間兩部分並組合而成，可以同時捕捉空間相關性與時間相關性，以此生成未來的預測圖片。

上述文獻大多使用經轉換後的雷達回波資料，而本研究嘗試在模型中加入可以獲取原始資料與雨量隱含關係的模型。研究資料來源於交通部中央氣象局提供至政府資料開放平臺之 QPESUMS 產出之

雷達整合回波資料，主要欄位有 dataTime(觀測時間)、updateTime(資料更新時間)、url(下載網址)。

目前臺灣的雷達分布，由五分山、花蓮、墾丁和七股等完全涵蓋，而本資料中的雷達觀測站亦(張智昌, 2006)為五分山、花蓮、七股、樹林、南屯、林園雷達觀測站、解析度為 0.0125、單位為 dBZ。經向及緯向解析度均為 0.0125 度，每 10 分鐘更新 1 筆資料(交通部中央氣象局, 2022b)，此部分資料亦可整合至本研究之深度學習模型。

本研究透過 Python 串接平台提供之 AP 下載 xml 檔，並將其轉換成資料更加容易處理的 json 檔。下載的時間為 2022-06-14 至 2022-06-23。然本 API 僅提供下載過去歷史一週的資料，需要每週更新檔案。

json 資料中，有一 content 欄位。此 content 之欄位內的格點資料以逗號分隔之浮點數值，每一個數值以科學記號格式記錄，代表不同經緯度上之雷達回波值，單位為 dBZ；其中資料無效值為-99，雷達觀測範圍外或經資料品管流程移除之資料則以-999 表示。Content 中的為一維的陣列，左下角第一點之座標為東經 115.0、北緯 18.0，依序先由西向東、再由南往北遞增。使用之座標系統為 TWD67。

本研究將使用 06-14 的雷達回波資料作為 mock data，資料量有 117 筆，並且將會使用每五幀的資料對於後 1 幀的資料進行預測。


雷達回波資料數值轉換方法在雷達回波圖上，進行降水預測，需要將 dBZ 進行轉換以得到較為適合深度學習的數值。本研究因設備因素暫時僅使用 6 月 14 的資料進行訓練。

馬歇爾-帕爾默公式 (Marshall-Palmer formula) 中 dBZ 是雷達的基本反射率 (雷達掃出來的結果) 透過以下公式將 dBZ 換算為時雨量 (DesktopDoppler, 2002)

$$\frac{mm}{hr} = \left( \frac{10^{(dBZ/10)}}{200} \right)^{\frac{5}{8}}$$


並裁剪到 [0,255] 之間轉換成 png 圖片。線性轉換對於最後的訓練和測試沒有多大的影響，也是在深度學習更常見的值域範圍。除此之外，亦須將資料進行標準化。

圖像前處理之 png 圖片使用 RGB 三通道，並且以 5 幀為單位進行滑窗處理，增加序列資料量。即將其從 2D 的矩陣轉換為 3D 的張量，資料視覺化如下所示。




本研究之 convLSTM 深度學習模型可進行時空序列之訓練與模擬分析，也是最有效且常見的模型(Shi et al., 2015)，應用時空預測的循環神經網絡，在輸入到狀態和狀態到狀態的轉換中都具有捲積結構。通過其鄰域的輸入和過去狀態來確定網格中某個單元格的未來狀態。通過卷積 state-to-state 和 input-to-state 進行轉換。此方法改善傳統的 FC-LSTM 僅能獲取時間序列訊息，無法提取空間訊息的缺點。FC-LSTM 所預測的是一維的數據，然雷達回波資料屬於不平衡資料集，其中還有大量冗余的資料，因此 FC-LSTM 的預測結果會有

偏誤。而 conv-LSTM 將 FC-LSTM 的矩陣相乘換成捲積，以此獲取空間訊息。因此此模型可以同時獲取時空間的相關性，以此提高預測準確度。



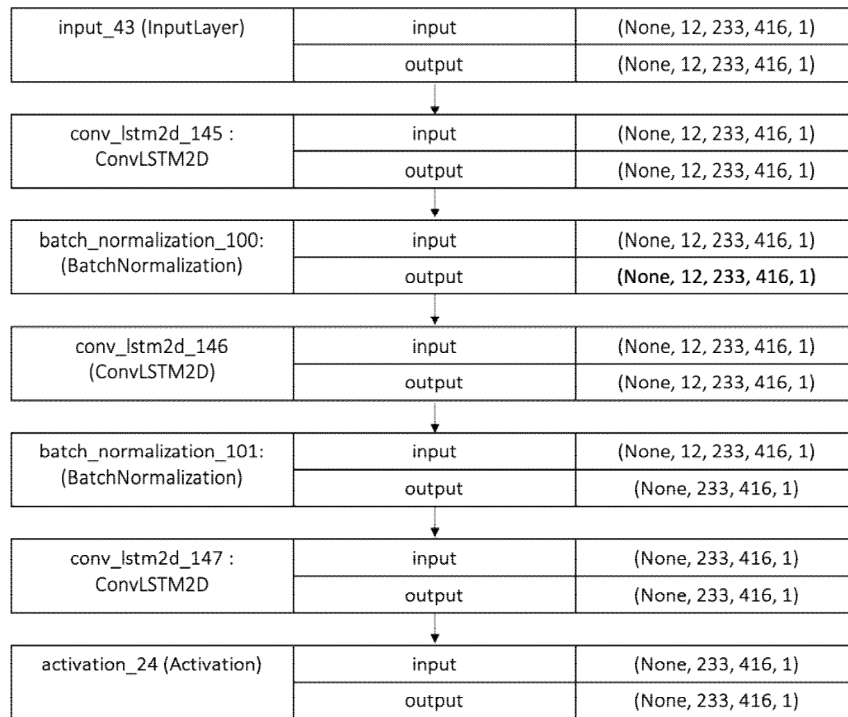
輸入  $X$  和  $C$  (cell output) 還有  $H$  (hidden state) 都是三維的張量。利用卷積運算通過過去一個時刻的輸入和  $C$  還有  $H$  得到新的或者說目標時刻的  $C$  和  $H$  值。



主要的方程式如下，方程式中把 input-to-state，state-to-state 的正常乘積運算，改為卷積運算(hadamard 乘積)。

$$\begin{aligned}
 i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \odot C_{t-1} + b_i) \\
 f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \odot C_{t-1} + b_f) \\
 C_t &= f_t \odot C_{t-1} + i_t \odot \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \\
 o_t &= \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \odot C_t + b_o) \\
 H_t &= o_t \odot \tanh(C_t)
 \end{aligned}$$

本研究嘗試利用 convLSTM 具有 CNN 網路可以捕捉空間相關性的特性建立氣象雷達影像以及累積雨量圖的相關性，以及 LSTM 網路可以捕捉時間相關性的特性進行預測。過去常使用 dBZ 與雨量的轉換公式，例如馬歇爾-帕爾默公式（Marshall-Palmer formula）或是 Z-R 轉換，然而使用上述的轉換公式可能仍無法比擬 CNN 網路所訓練出的高精度的相關性，因此本研究建構 convLSTM 模型應可建立更加良好的相關性公式與氣象雷達及累積雨量圖的連結。



convLSTM 網路架構圖。



## 第四章 工作項目及計畫成果

本章列出工作項目及計畫各項成果。

### 第一節 資料蒐集及處理

本研究之深度學習模型擷取自 Windy 天氣預報網站之氣象資料，其天氣預報資料來自歐洲 ECMWF 模式、美國 GFS 模式所發佈之天氣預報相關影像資料，Windy(Lukačovič, 2022)提供美國國家海洋和大氣管理局全球預報系統（Global Forecast System）、歐洲中期天氣預報中心及瑞士 NEMS 模型的天氣預報結果。此網站提供更多氣象數據，如溫度、大氣壓力、相對濕度、雲層等，而風速動畫是基於 Cameron Beccario Earth 的開源項目。該網站現具有 12 小時至當時的雷達與衛星影像、風速預測影像、降雨與雷暴預測影像、溫度與溼度預測影像、雲層預測影像、波浪預測影像、空氣質素預測影像。本研究將會透過螢幕擷取的方式，截取經緯度約在東經 119.00 度至 123.00 度，北緯 21.5 度至 25.5 度的氣象雷達圖、累積雨量作為訓練之輸入資料。

深度學習所使用之降雨量資料來源於交通部中央氣象局提供至政府資料開放平臺之自動雨量站-雨量觀測資料(交通部中央氣象局, 2022) 每十分鐘更新一筆資料。主要欄位有 lat(緯度)、lon(經度)，座標系統採 TWD67 ；locationName(地點名稱)是測站名稱、stationId 是測站編號；obsTime(觀測時間)；elementName 是參數因子，跟雨量有關的資料有 RAIN，是 60 分鐘累積雨量、MIN\_10，是 10 分鐘累積雨量、HOUR\_3，是 3 小時累積雨量、HOUR\_6，是 6 小時累積雨量、HOUR\_12，是 12 小時累積雨量、HOUR\_24，是 24 小時累積雨量、

NOW，本日累積雨量、latest\_2days，前 1 日 0 時到現在之累積雨量、latest\_3days，前 2 日 0 時到現在之累積雨量；單位皆為毫米。若雨量值小於 0.00 表示無資料，為 -998.00 表示表示 RAIN=MIN\_10=HOUR\_3= HOUR\_6= 0.00。

本研究透過 Python 串接平台提供之 API 下載 xml 檔，因需要與來自 Windy 的氣象雷達圖結合，該網站提供的氣象雷達圖亦是約莫 10 分鐘可獲取一次，因此採用 elementName 欄位中的 MIN\_10(10 分鐘累積雨量)，每一份檔案中有 1125 筆資料，可用於繪製成雨量累積地圖。

本研究將使用 Windy 的氣象雷達影像圖結合來自政府資料開放平臺之自動雨量站-雨量觀測資料的 10 分鐘累積雨量作為模擬資料，並且將會使用每 5 幀的氣象雷達影像對於後 1 幀的累積雨量影像進行訓練，並預測未來的降雨狀況。

網路資料蒐集透過 Python request 套件進行爬蟲，每十分鐘從交通部中央氣象局提供至政府資料開放平臺之自動雨量站-雨量觀測資料獲取 xml 資料。再透過 xmltodict 套件處理 xml 資料，選取其中的經緯度 lon、lat 以及 10 分鐘累積雨量 MIN\_10。每一份 xml 檔案中可以取出 1125 筆來自不同測站的 MIN\_10。

本研究也會使用克利金推估模式將不同測站的雨量資料進行插值處理，繪製成雨量的等值線地圖，彌補在雨量站稀少的區域無法準確描述出區域的降雨，以此更加符合現實物理以及習慣使用圖像，以此增加訓練所產出結果的有效性。克利金法 (Kriging) 又稱為空間局部估計或空間局部插值(Inc., 2017)，是地理統計學兩大主要內容之一。該方法(陳怡玢 et al.)估計地面雨量場是假設空間隨機變數具有定

常性，平均值為未知常數，在有限區域內對區域化變量的取值，最大限度地利利用空間取樣，進行無偏最佳化估計。在地理統計中常用的克利金估計方法有三種，分別為：普通克利金 (Ordinary Kriging)、指標克利金 (Indicator Kriging)、聯合克利金 (Co-Kriging)。Windy 網站提供使用者瀏覽 12 小時至當時的氣象雷達資料，本研究使用螢幕擷取的方式獲取資料。




圖 4-1:利用 Windy 所截取的氣象雷達影像，資料來源:Lukačovič (2022)。

## 第二節 深度學習模型建立與訓練與網路爬取資料程式

網路爬取資料程式十分鐘降雨量資料透過 python request 套件，每半小時從網站爬取資料。再利用 xmltodict 套件分析 xml 檔案中的欄位，選取出 lon, lat, MON\_10。將所選出的欄位儲存為 dataframe，並儲存為 csv 檔，再將檔案上傳至 google colab，使用該網站所提供之 GPU 進行訓練。

```
import glob
import xmltodict
import json
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
data_list = glob.glob('datasets/tw-rainfall/*.xml')
# filename = data_list[0]
for filename in data_list:
    lat = []
    lon = []
    MIN_10 = []
    # for filename in data_list:
    with open(filename, 'r') as f:
        data_dict = xmltodict.parse(f.read())['cwbopendata']['location']
        for d in data_dict:
            # extract value in xml
            lat.append(d['lat'])
            lon.append(d['lon'])
            value_MIN_10 = float(d['weatherElement'][2]['elementValue']['value'])
            # since MIN_10 < 0 means NaN or no rainfall
            if value_MIN_10 < 0 :
                value_MIN_10 = 0
            MIN_10.append(value_MIN_10)
```

```

# make a dataframe to storage the data
# to plot on geo maps and convert to RGB image
df_rainfall = pd.DataFrame(
    {'lat' : lat,
     'lon' : lon,
     'MIN_10' : MIN_10}
)

df_rainfall.to_csv('datasets/tw-rainfall/csv/'+filename[21:-4].replace(".", "_")+'.csv',
                  index=False)
# df_rainfall.to_csv('test.csv',
#                    index=False)

```

參考台灣常用之累積雨量圖的雨量區間(單位：毫米)，設定五個雨量區間，(0,3), (3.1, 15), (15.1, 40), (40.1, 80), (80.1, 200), (200.1, 3000)，因繪圖需要，因此將各個區間的數值乘以十，以此讓雨量資料於地圖上的散點可以有更明顯的呈現效果。

將台灣所在的經緯度地點匡選出來，並將雨量資料使用散點圖的方式繪製於地圖上。未來將會使用克利金插值等方法繪製更加適合呈現與模型訓練的雨量等值線圖。

```

import plotly.graph_objects as go

import pandas as pd

df = pd.read_csv(csv_list[72])
limits = [(0, 30), (31, 150), (151, 400), (401, 800), (801, 2000), (2001, 30000)]

```

```
colors = ["royalblue", "crimson", "lightseagreen", "orange",
"lightgrey", "black"]
fig = go.Figure()
for i in range(len(limits)):
    fig.add_trace(go.Scattergeo(
        lon=df['lon'],
        lat=df['lat'],
        marker=dict(
            size=df['MIN_10']*10,
            color=colors[i],
            line_color='rgb(40, 40, 40)',
            line_width=0.5,
            sizemode='area'
        ),
    ))
fig.update_layout(
    showlegend=False,
    geo=go.layout.Geo(
        resolution=50,
        scope='asia',
        showframe=False,
        coastlinewidth=2,
        landcolor="rgb(229, 229, 229)",
        countrycolor="black",
        coastlinecolor="black",
        projection_type='mercator',
        lonaxis_range=[119.2, 122.8],
        lataxis_range=[21.8, 25.4],
    ), height=500, width = 500,
    margin={"r":0, "t":0, "l":0, "b":0}
)

fig.show()
```

本研究建立之深度學習模型程式與註解解釋如下，以供檢視，第一部分為 python 所 import 相關常用程式集。

```
# basic
import json
import os
import numpy as np
import scipy as sp
import pandas as pd
import glob
import csv

# plot
import matplotlib.pyplot as plt
%matplotlib inline
import imageio

#
from sklearn.model_selection import train_test_split
# tensorflow
from keras import layers
from keras.layers.core import Activation
from tensorflow.keras.models import Model
from tensorflow.keras.callbacks import EarlyStopping

from PIL import Image

import cv2
```

以下深度學習模型建立 x, y 訓練資料，令氣象雷達影像為 x，雨量影像資料為 y，以此訓練深度學習模型，取代常使用的物理方程式將氣象雷達數值(dBZ)轉換至時雨量的研究，使用深度學習網路 CNN 捕捉兩者的相關性，此部分程式讀入訓練資料之輸入與輸出資料。

```
x_img_list      =      glob.glob('/content/drive/MyDrive/Colab
Notebooks/Windy/datasets/train/*.png' )
x_img = Image.open(x_img_list[0])

#Image size after reduction
height = int(x_img.height)
width = int(x_img.width)

#Array to put the loaded image
x_imgs=np.empty((0, height, width, 3))

for i in x_img_list:
    name = i
    with open(name) as file:
        x_img = Image.open(name)
        x_img = x_img.convert(' RGB' )
        x_img = x_img.resize((width, height))
        x_img_np = np.array(x_img).reshape(1, height, width, 3)
        x_imgs = np.append(x_imgs, x_img_np, axis=0)
y_img_list      =      glob.glob('/content/drive/MyDrive/Colab
Notebooks/Windy/datasets/test/*.png' )
y_img = Image.open(y_img_list[0])

#Image size after reduction
height = int(x_img.height)
width = int(x_img.width)

#Array to put the loaded image
y_imgs=np.empty((0, height, width, 3))

for i in y_img_list:
    name = i
    with open(name) as file:
        y_img = Image.open(name)
        y_img = y_img.convert(' RGB' )
        y_img = y_img.resize((width, height))
```



```
y_img_np = np.array(y_img).reshape(1, height, width, 3)
y_imgs = np.append(y_imgs, y_img_np, axis=0)
```

以下為所建立之深度學習模型，將每五筆的氣象雷達資料對一筆的雨量資料進行訓練，透過 convLSTM 中包含 CNN 與 LSTM 二部份，CNN 處理空間資料，捕捉兩者之間空間相關性的特性，例如可處理氣象雷達影像與累積時雨量影像的關聯，另外 LSTM 可以進行時序預測的特性進行雨量的預測，並繪製成圖，呈現時間序列模擬預測結果。以下所建立之 convLSTM 模型可處理具時間序列的空間影像資料，深度學習模型之各層網路架構分別訂定如下。以下也讀入訓練資料，以訓練深度學習模型，模型訓練後即可進行預測。

```
# Arrange in a format that can be learned in chronological order
n_seq = 5
n_sample = x_imgs.shape[0] - n_seq

x = np.zeros((n_sample, n_seq, height, width, 3))
y = np.zeros((n_sample, height, width, 3))
for i in range(n_sample):
    x[i] = x_imgs[i:i+n_seq]
    y[i] = y_imgs[i+n_seq]
x, y = (x-128)/128, (y-128)/128

x_train, x_test, y_train, y_test = train_test_split(x, y,
test_size = 0.1, shuffle = False)
```

convLSTM 模型，使用 tensorflow 框架。

```
inputs = layers.Input(shape=(5, height, width, 3))
x0 = layers.ConvLSTM2D(filters=16, kernel_size=(3,3),
padding="same", return_sequences=True,
data_format="channels_last")(inputs)
x0 = layers.BatchNormalization(momentum=0.6)(x0)
x0 = layers.ConvLSTM2D(filters=16, kernel_size=(3,3),
padding="same", return_sequences=True,
data_format="channels_last")(x0)
```

```
x0 = layers.BatchNormalization(momentum=0.8)(x0)

x0 = layers.ConvLSTM2D(filters=3, kernel_size=(3,3),
padding="same", return_sequences=False,
data_format="channels_last")(x0)
out = Activation('tanh')(x0)
model = Model(inputs=inputs, outputs=out)
model.summary()
model.compile(optimizer='rmsprop',
              loss='mae', metrics=['mse'])
call_backs=[EarlyStopping(monitor="val_loss", patience=10)]
model.fit(x_train, y_train, batch_size=4, epochs=100,
verbose=2, validation_split=0.2, shuffle=True,
callbacks=call_backs)

loss = model.history.history['loss']
val_loss = model.history.history['val_loss']
mse = model.history.history['mse']
val_mse = model.history.history['val_mse']
train = plt.plot(loss, label='train')
val = plt.plot(val_loss, label='val')
plt.legend(loc='upper right')
plt.title("mae")
train = plt.plot(mse, label='train')
val = plt.plot(val_mse, label='val')
plt.legend(loc='upper right')
plt.title("mse")
```

```
for i in range(7):
    nx = ny = 881
    lon = np.linspace(119+0.0125*40, 110+0.0125*40+nx*0.0125,
nx)
    lan = np.linspace(21, 13+ny*0.0125, ny)

    fig, axes = plt.subplots(1, 2, figsize=(12,6))
    axes[0].set_xlabel('Easting')
```

```

axes[0].set_ylabel('Northing')
axes[0].set_title('i='+str(i+1))
axes[0].imshow((y_test[i]+1)/2,
                extent=[lon[0], lon[-1], lan[0], lan[-1]])

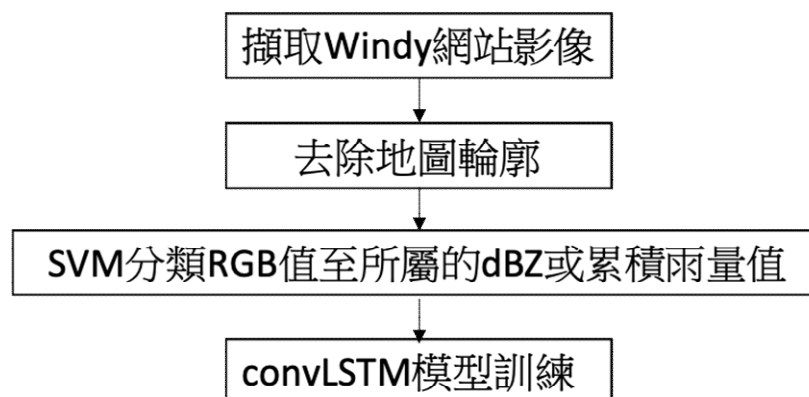
axes[1].set_xlabel('Easting')
axes[1].set_ylabel('Northing')
axes[1].set_title('i='+str(i+1))

axes[1].imshow((model.predict(x_test[[i]]).reshape(height, width, 3)+1)/2,
                extent=[lon[0], lon[-1], lan[0], lan[-1]])

```

### 第三節 資料資料與程式碼連結

本研究成果包含 Windy 氣象預報資料之前處理，所蒐集之雨量與雷達回波影像資料需進行影像資料前處理（雜訊、背景線條、多餘背景之去除等），本研究也建構支持向量機模型（Supporting Vector Machine, SVM）比對雨量及雷達回波資料，再進一步建構 convLSTM 深度學習模型，已進行模型之之訓練與驗證，架構如下所示。



支持向量機是用於分類和回歸問題的線性模型。它可以解決線性和非線性問題，並且可以很好地解決許多實際問題，支持向量機利用創建一條線或一個超平面，將數據分成幾類。SVM 算法從兩個類別中找到最接近直線的點，這些點稱為支持向量，並計算直線和支持向量之間的距離，稱為邊距。SVM 算法的目標為最大化邊距，而邊距最大的超平面是最優超平面，超平面可以表示為：

$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p = 0$$

如果 X 滿足上述方程，則該點位於平面上。否則，它必須位於平面的一側。因此可以藉由該方法來將多個 X 進行分類。

本計畫研究成果之 convLSTM 深度學習模型程式碼與雨量模擬模擬結果資料因資料篇幅較大，程式與資料提供於網路，其網路連結如下，供參考。

[https://drive.google.com/drive/folders/14Tq\\_1stBq1478q4Rn7481n7EyiZ\\_Zet4s?usp=sharing](https://drive.google.com/drive/folders/14Tq_1stBq1478q4Rn7481n7EyiZ_Zet4s?usp=sharing)

[https://drive.google.com/drive/folders/170IM1LCmVI5wifloDB3JXALQ\\_XUm0K7IE?usp=sharing](https://drive.google.com/drive/folders/170IM1LCmVI5wifloDB3JXALQ_XUm0K7IE?usp=sharing)

模型輸出資料：政府資料開放平臺爬取之自動雨量站十分鐘累積雨量數值資料



表 4-1：2022-08-23 08:00 經緯度以及十分鐘累積雨量部分資料


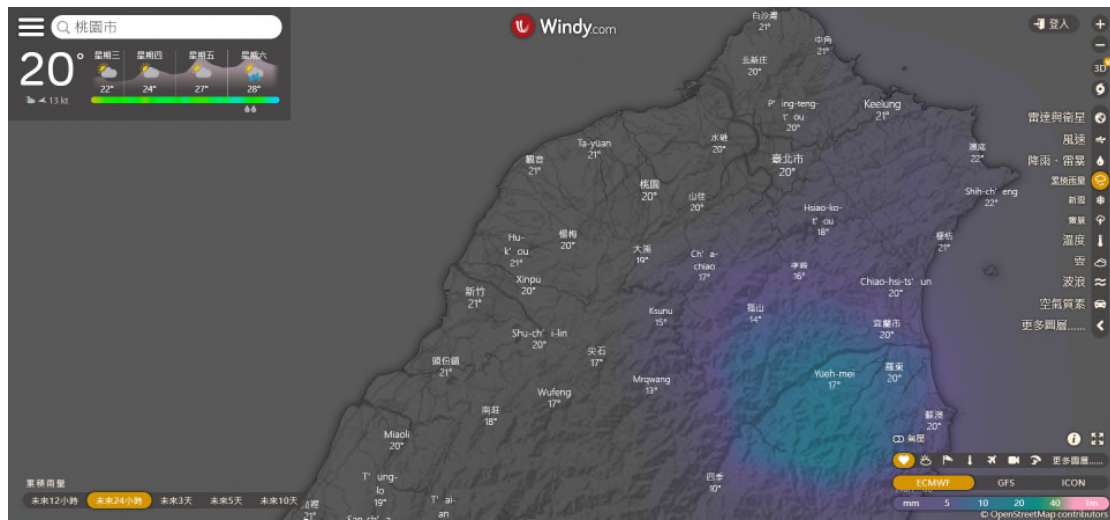
lat	lon	MIN_10	lat	lon	MIN_10
23.6914	120.8428	0	23.7427	121.418	0
22.6767	120.2769	0	22.7268	121.0298	0
23.9132	120.6792	0	23.5921	120.7367	0
23.596	120.9362	0	23.7556	120.6309	0
23.7633	120.8248	0	24.3578	120.7211	0
23.8603	120.9867	0	25.1776	121.6812	0

23.5871	120.1724	0	25.1285	121.3823	0
23.5161	120.2216	0	25.0177	121.7962	0
23.3008	120.6567	0	24.9417	121.4628	0
23.3909	120.7085	0	24.8401	121.5179	0
23.4558	120.7414	0	24.8607	121.3518	0
23.3878	120.4692	0	24.9275	121.4384	0
23.6882	120.5953	0	24.8554	121.4293	0
23.6413	120.7783	0	24.8268	121.2804	0
24.0871	121.1654	0	24.7698	121.3434	0
23.93	121.0833	0	24.7305	121.2183	0
23.0413	121.1669	0	24.6822	121.2386	0
25.073	121.7726	0	24.7072	121.175	0
23.149	120.0782	0	24.6479	121.1429	0
24.6271	121.1399	0	24.4634	120.8557	0
24.721	121.2755	0	24.4493	120.7821	0
23.9747	121.5978	0	24.2382	120.8718	0
21.9027	120.8472	0.5	24.1584	120.7485	0
24.4345	121.2956	0	24.037	120.7163	0
24.3906	121.2633	0	24.3354	120.9121	0
24.3904	121.2282	0	23.8563	120.8614	0
23.3398	120.6752	0	23.9945	120.7544	0
25.9669	119.9724	0	23.8505	120.9272	0
23.5643	119.4603	0	23.8074	120.8295	0
23.4018	119.3147	0	23.7807	120.8886	0
25.1309	121.5689	0	24.0133	120.8143	0
24.3	120.8977	0	24.0584	120.9032	0
23.9517	120.8462	0	23.7866	120.8556	0
23.53	120.8486	0	23.7954	120.7027	0
23.7272	120.8685	0	23.6301	120.8624	0
23.7416	120.862	0	23.5373	120.7008	0
23.6698	120.8688	0	23.3832	120.5225	0
25.0931	121.8307	0	23.2422	120.6886	0

模型輸入資料：Windy 全台與北部雷達回波資料（如下所示）

## 區域性中長期智慧降雨預報輔助土石災害預警系統之建構





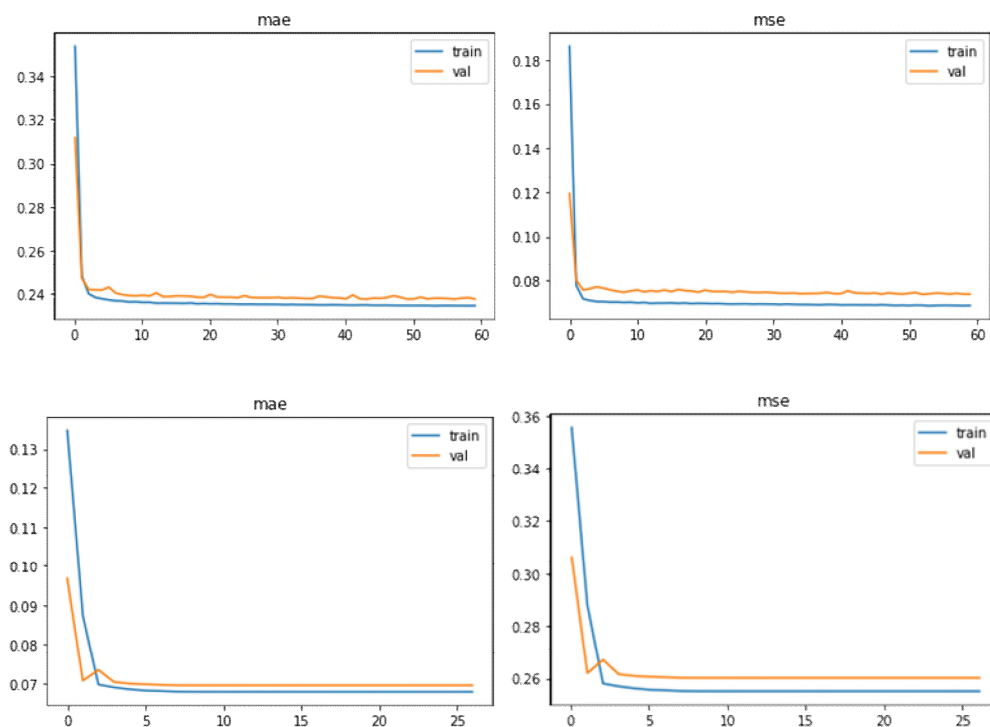




## 第五章 結論及建議


### 第一節 結論

本研究也測試不同深度學習模型之損失函數(Loss Functions)來評估 ML 模型之改善，測試包含 Mean Average Error (MAE)或 MSE (Mean Square Error) 等損失函數，結果顯示均有趨向收斂的結果，模擬結果顯示良好的模擬。



訓練與預測資料之結果顯示，模型捕捉空間、時間上資訊，未來結合更長期資料，可以提升預測效果。未來可以透過改進損失函數來增進模型的效能與準確度，以及除了使用 MSE 與 MAE 之外，可以使用在氣象領域中較常見的 CSI、FAR、POD、Correlation 指標進行

模型的評估。透過克利金插值繪製雨量等值線圖，應是可以讓模型捕捉更多空間上的相關性。在模型中將每五筆的氣象雷達資料對一筆的雨量資料進行訓練，未來該部分仍可以進行更加深度的修改，例如先行對每筆資料相互使用 CNN 網路訓練，捕捉數值間的相關性，將氣象雷達資料轉換成時雨量後，再利用 convLSTM 模型進行訓練與預測。



## 第二節 建議

本計畫之模式輸出之短至中長期預測降雨，可計算特定期距內的有效累積降雨量，但由於中長期預報資料不準確性高於短期預報，本計畫提供短至之中長期的雨量預測與趨勢，可作為未來十日土石災害之潛勢預警之參考，也可增加事前可操作時間，並作中長期水土資源保育與規劃改善之用。

雷達回波資料是氣象雷達的最終產品，亦是在進行短時間的雨量評估時相當重要的工具。過去在轉換雷達回波資料與時雨量時，常使用 Z-R 轉換或馬歇爾-帕默爾公式，然當資料進行轉換時或多或少會損失一些資訊，本研究之深度學習人工智慧模型利用雷達回波資料對未來降水進行預測，可減少其中的資訊損失。

本研究開發測試相當具有模擬與預測潛力之深度學習方法，此方法之優點包含可以透過訓練神經網路獲取資料底層中相當複雜的隱含關係，也應對本研究希望直接透過原始資料而非經過轉換後的物理量進行預測的想法，因此本研究建構時空序列預測的深度學習方法來分析雷達回波資料。本研究透過深度學習模型來建構雷達回波原始資料之強度(dBZ)與時雨量的關係式，並透過該模型進行雨量的時空序列預測，將接續過去台灣已經深入研究之雷達回波圖與未來降水的預測方法，本研究建構深度學習模式來提供雨量預測，可提供土石流警戒預報之用。

本研究以建構深度學習人工智慧之降雨預報模式與架構，可應用於不同研究區域，結合不同研究區域之訓練與驗證資料，即可針對土石災害重點地區，進行區域中長期之降雨預報模擬，亦可提供相關預報資訊，以供輔助土石災害預警系統之決策操作，本研究之目的期望測試機器學習、人工智慧、數據科學等新興工具，協助雨量預測模擬、

水土保持災害預警等工作，希望提升降雨預報的可信度，提供更多元的區域短中長期降雨模擬，更期待進一步強化模擬、掌控災害的風險與不確定性。後續研究更可以應用於不同研究區域，進行中長期降雨預測模型建構與模擬，並搭配不同地形特徵、地表特性資料（例如坡度、植被狀態、地質特性、開發程度等），評估災害之可能風險，供未來水土資源的保育與開發規劃之決策參考。中長期預報資料不準確性高於短期預報，本計畫研究模型期望提供雨量與趨勢之模擬，並非直接應用於土石流預警，土石流預警仍需以短期預報為預警之主要依據，若實際狀況及短期預報之發展趨勢與本模式之預報趨勢一致時，則所產出的短至中長期預測即可提供災害風險評估之參考，可增加防災預警的事前可操作時間、提示未來十日土石災害之潛勢預警、以及中長期水土資源保育與規劃改善之用。

## 參考文獻

1. 黃宏斌、徐肇斌、謝孟荃，“石門水庫集水區崩塌地之調查研究”，農業工程學報，第 52(3)期，32-45 頁，2006。
2. 曾吉暉，天空的眼淚知多少“，科學發展，第 538 期，12-16 頁，2017。
3. 交通部中央氣象局.(2022a). 雷達回波. Retrieved from [https://www.cwb.gov.tw/V8/C/W/OBS\\_Radar.html](https://www.cwb.gov.tw/V8/C/W/OBS_Radar.html)
4. 交通部中央氣象局.(2022b). QPESUMS 產出之雷達整合回波資料. Retrieved from: <https://data.gov.tw/dataset/76629>.
5. 交通部中央氣象局.(2022). 自動雨量站-雨量觀測資料. Retrieved from <https://data.gov.tw/dataset/9177>
6. 陳怡矧, 顧欣怡, 黃于盈, 李天浩, 鄭安孺, & 于芃. 應用普通克利金內插雨量差值法修正雷達定量降雨估計推估計地面雨量分析場之研究. Retrieved from [https://conf.cwb.gov.tw/media/cwb\\_past\\_conferences/105/1.大氣監測與分析/1-26.pdf](https://conf.cwb.gov.tw/media/cwb_past_conferences/105/1.大氣監測與分析/1-26.pdf)
7. 國家實驗研究院.(2022). 國家實驗研究院台灣颱風洪水研究中心.
8. 張智昌.(2006). 整合氣象雷達與即時降雨資料於颱風降雨推估

之研究.

9. 駱銘樂. (2009). 守護台灣北部機場的桃園都卜勒氣象雷達. 2009 海峽兩岸航空氣象與飛行安全研討會: 中華航空氣象協會
10. N. P. Bassill, Accuracy of early GFS and ECMWF Sandy (2012) track forecasts: Evidence for a dependence on cumulus parameterization. *Geophysical Research Letters*, 41(9), pp.3274-3281, 2014.
11. P. Douglas, "Will a New GFS Weather Model Upgrade Close the Gap with The European Model?" *AerisWeather* , 18 April 2021, retrieved 8 November 2021.
12. R. C. Gonzalez and R. E. Woods, "Image Pattern Classification," *Digital Image Processing*, 4th edition, Pearson, 1168 pages, 2018.
13. S. Ravuri, K. Lenc, et al., "Skillful Precipitation Nowcasting using Deep Generative Models of Radar," *Nature*, 597(7878), pp. 672 – 677, 2021. <https://doi.org/10.1038/s41586-021-03854-z>
14. J. Sillin, "Model Mania: What Are the ECMWF and GFS Models, and Why Are They Different?" [blog.weather.us](https://blog.weather.us). 18 December 2019, retrieved 8 November 2021.
15. DesktopDoppler. (2002). NWS NEXRAD. Retrieved from <https://web.archive.org/web/20160314102041/http://www.desktopdoppler.com/help/nws-nexrad.htm#rainfall%20rates>
16. Ravuri, S., Lenc, K., Willson, M., Kangin, D., Lam, R., Mirowski,

- P., Madge, S. (2021). Skilful precipitation nowcasting using deep generative models of radar. *Nature*, 597(7878), 672-677.
17. Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., & Woo, W.-c. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28.
  18. Tian, L., Li, X., Ye, Y., Xie, P., & Li, Y. (2019). A generative adversarial gated recurrent unit model for precipitation nowcasting. *IEEE Geoscience and Remote Sensing Letters*, 17(4), 601-605.
  19. Wang, Y., Jiang, L., Yang, M.-H., Li, L.-J., Long, M., & Fei-Fei, L. (2018). Eidetic 3D LSTM: A model for video prediction and beyond. Paper presented at the International conference on learning representations.
  20. Wang, Y., Long, M., Wang, J., Gao, Z., & Yu, P. S. (2017). Predrnn: Recurrent neural networks for predictive learning using spatiotemporal lstms. *Advances in neural information processing systems*, 30.
  21. Xu, Z., Du, J., Wang, J., Jiang, C., & Ren, Y. (2019). Satellite image prediction relying on GAN and LSTM neural networks. Paper presented at the ICC 2019-2019 IEEE International Conference on Communications (ICC).





## 附錄

## 附錄一、期初審查會議紀錄暨回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一	研究目標甚具理想性，惟土石流預警係短期間可即時掌握雨量為目標，對中、長期降雨預報之需求性雖不予排除，但在行政管理面之操作可能較不易顧及。	臺灣現行的雷達觀測降雨估計可提供現時與未來 2 小時的即時與預測資訊，以作為土石流預警之用。數值天氣（氣候）預報模式則可提供未來 12~24 小時、甚且是中長期天氣與氣候的資訊，在空間上可達到即使廣設雨量站亦無法達成的精細且分散均勻的解析度。本計劃旨在結合兩者之優勢，以獲取更多、更準確的降雨預報資訊，在短時間期距內（如 2~12 小時）爭取防災的事前操作時間，在未來十日內可評估土石流災害發生風險之高低，而在中長期則可進行水土資源的保育與規劃。
二	防災預警係屬短期雨量預測為依據，而山區雨量受地形地貌、坡向、風向、風力等因素影響甚大，單從雨量之歷史資料，亦難以掌握，此乃歷年研究未能克服之問題，如何建構包括多元氣象要素之學習模式，以所採之 ECMWF 與 GFS 模式可否滿足？	山區雨量受地形地貌、坡向、風向、風力等因素影響甚大，本研究即欲應用雷達觀測資料彌補單點雨量測站所無法呈現之空間分佈，並以 ECMWF 與 GFS 中長期天氣預測與雷達觀測歷史資料，進行短（6 小時）至中長期（15 天以上）的雨量預測，以期增加

項次	審查意見	回覆辦理情形
		防災預警的事前可操作時間。補充說明詳見計畫說明書第4頁。
三	以中期天氣預報模式及雷達觀測降雨來預測10日內之降雨為本研究重點。但用於好發土石流之山區，除地形效應外及雷達之適用性均需校正，才能確定其可行性。	人工智慧深度學習模式具有專長於圖形辨識之優勢，若能輔以足量圖資與數據以供模式訓練學習，例如雷達觀測資料、觀測雨量、過往崩塌分佈圖、地形圖、土石流潛勢溪流影響範圍圖、與大規模崩塌潛勢區影響範圍圖等，將可提升其可行性與預測準確度。
四	本模式之應用區域未敘明。	已依審查意見補充說明。本研究預計以石門水庫集水區為模式建置與應用區域。相關說明詳見計畫說明書第2-2頁。
五	如何將本模式之輸出預測與土石流降雨預警模式（既有或申請者之模式）應用以結合以提升防救災之效益。	可將本模式輸出之短至中長期預測降雨，計算特定期距內的有效累積降雨量，若達到警示雨量值，則可提供土石流降雨預警模式參考，提示為需提高警戒之區域。
六	中長期預報資料不準確性高於短期預報，應用於土石流預警易誤報，建議區分各項預報資料之應用面。	已依審查意見補充說明於計畫說明書第7頁。由於中長期預報資料不準確性高於短期預報，本計畫預計產出短（6小時）至中長期（15天以上）的雨量預測與趨勢，並不建議直接應用於土石流預警之用，仍需以短期預報為預警之主要依據。若實際狀況及短期預報之發展趨勢與本模式之

項次	審查意見	回覆辦理情形
		預報趨勢一致時，則所產出的短至中長期預測即具有相當之參考價值，可藉此增加防災預警的事前可操作時間、提示未來十日土石災害之潛勢預警、以及中長期水土資源保育與規劃改善之用。
七	未說明模式建置是全台亦或選擇區域。	已依審查意見補充說明。本研究預計以石門水庫集水區為模式建置與應用區域。相關說明詳見計畫說明書第 2-2 頁。
八	本計畫為一年期計畫，建立中期數值天氣預報、雷達觀測、與降雨預測之人工智慧深度學習模式，建議加強說明模式之驗證方式。	本計劃將視可取得之各項資料的時間長度，劃分資料以進行人工智慧深度學習模式的訓練、驗證與測試之用，並選取適當之指標參數，用以檢視訓練與驗證結果之優劣。

## 附錄二、期中審查會議紀錄暨回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一	<p>本計畫所訂定的三大目標，內容具體，預期對提高區域降雨預報可信度也有幫助。但從期中報告書看不出來確實完成工作的證明，特別是沒有提供交付的成果，難以評估是否如文字所述都已完成。例如ECMWF和GFS資料是從何網址下載的？是否需特別註冊帳號？本研究下載了哪些檔案？請挑選一些有代表性的範例檔案，放在雲端硬碟，提供連結，讓使用者和審查者下載檢視，並附上說明文件。</p>	<p>本計畫建立 ConvLSTM 深度學習模型，模型之輸入輸出是設定影像作為輸入資料，雨量作為輸出資料。輸入資料由Windy 擷取影像作為輸入資料，並擷取氣象局雨量資料作為輸出資料，再一齊作為為訓練資料。</p> <p>影像資料與雨量資料蒐集與爬取，請見新增之第四章第一節，另外請見新增之第四章第三節中的網路連結，提供程式碼與示範資料。</p>
二	<p>將數值模式reanalysis的結果以影像的方式呈現，然後建立深度學習的架構，從相應的雨量觀測資料去學習要如何產出這些影像，之後就可以達到從雨量觀測建立如數值模式預報的成果，這樣的構想很好。只是從這份期中報告書看不到任何影像。整份報告只有三幅無關研究成果的圖，完全沒有任何研究成果的圖。尤其是數值模式的產出是3D格網的資料，要如何適當選取資料，將3D格網資料轉成2D影像，一定有很多需要考量之</p>	<p>本計畫架構是將影像作為輸入資料，雨量作為輸出資料，再蒐集氣象局雨量資料與Windy 擷取之影像作為訓練資料，進行 convLSTM 深度學習模型之訓練，訓練後之模型再用來預測雨量。修訂期中報告書新增之第四章第二節，提供 convLSTM 深度學習模型及註解，另外也請見新增之第四章第三節中的網路連結，提供程式碼與示範資料。</p>

項次	審查意見	回覆辦理情形
	處，但報告書中都沒有詳細說明。	
三	一般深度學習模型之研究成果會詳細交代使用了幾組訓練資料？這些資料是從何而來？訓練過程中校調參數的過程和最後理想的參數組合。各種訓練成效評估的指標。本研究宣稱要用CNN、RNN、LSTM等方法來建立模型，但只有在P3-7和P3-8提供了部份程式的螢幕截圖，而且顯示的幾行都不是程式的關鍵內容。建議列表說明目前發展之模型，精度評估之量化數據，並提供輔助說明資料以供佐證。	本修正期中報告書新增第四章之「已完成工作項目及目前計畫成果」，第四章第二節之「深度學習模型建立與訓練與網路爬取資料程式」，提供見convLSTM深度學習模型之相關架構與參數。 修訂期中報告書新增之第四章第一節，提供影像資料與雨量資料蒐集與爬取。第四章第二節，提供convLSTM深度學習模型及註解，另外新增之第四章第三節中提供網路連結，提供程式碼與示範資料。
四	本計畫已完成工作包括1.資料蒐集、整理與分析、2.深度學習模式之文獻蒐集與比較。3.人工智慧學習模式之建構，但文中未見相關比較分析之說明，請補充。	本修正期中報告書新增第四章之「已完成工作項目及目前計畫成果」，第四章內容陳列資料蒐集及處理、深度學習模型建立與訓練、及網路爬取資料程式等已完成事項。
五	建議依據P3-2計畫流程之工作流程項目，分別敘述工作步驟，並於後面章節敘述目前之初步成果供檢視。	本報告新增第四章之「已完成工作項目及目前計畫成果」，第五章為結論及建議。新增第四章內容用以回覆期中審查意見，並供檢視目前成果。
六	本計畫重點為輔助土石流災害預警系統之建構，其構想如何？	本計畫之模式輸出之短至中長期預測降雨，可計算特定期距內的有效累積降雨量，但由於中長期預報資料不準確性

項次	審查意見	回覆辦理情形
		高於短期預報，本計畫提供短至之中長期的雨量預測與趨勢，可作為未來十日土石災害之潛勢預警之參考，也可增加事前可操作時間，並作中長期水土資源保育與規劃改善之用。

## 附錄三、期末審查會議紀錄暨回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一	這麼長時間的降雨預報準確性已經相當有疑慮，不清楚用不確定性這麼高的降雨預報拿來做這麼長時間的土石流災害預報的目的性為何？後續的行政作為建議為何？	土石流預警，仍需以短期預報為預警之主要依據，然而本計畫研究模型產出之雨量預測與趨勢，仍可提供短至中長期的土石流可能機率之參考，可增加防災預警的事前可操作時間、提示未來十日土石災害之潛勢、以及中長期水土資源保育與規劃改善之用。
二	目標明確，預警準確性能提升。	謝謝寶貴意見，本計畫模型產出之雨量預測與趨勢，可提供短至中長期的土石流可能機率參考，及中長期水土資源保育規劃之用。