

逢甲大學
營建及防災研究中心
實務工作研究論文

臺中市災害應變中心颱洪豪雨決策輔助
資訊之人工智慧監視影像水位辨識模式
建置研究

A study on establishment of real-time water level recognition model with artificial intelligence technology for decision support of disaster prevention and protection in Taichung city during typhoon and torrential rain period

申請人：陳柏蒼 研究副教授

歐鎰元 助理研究員

李彥德 助理研究員

中華民國一〇八年八月三十日

摘要

在地理位置上臺灣處於西北太平洋邊緣，且位於西北太平洋熱帶氣旋移動範圍內，依據中央氣象局統計，自 1958 年至今，於西北太平洋颱風場數計有 1,545 場，颱風為臺灣本島帶來豐沛的雨量，侵臺期間挾帶豪大雨暴雨及西南氣流影響，使各地大量降雨造成局部低窪地區發生積水或淹水情況，由於颱風所降下的雨水，易造成都市排洪系統排水不及導致淹水災害，對此相關單位決策者非常關切颱風豪雨可能帶來的淹水地區，但目前受限於科技限制，難以完整精準掌控及預警。近年氣候極端的異常，分析近 50 年降雨日數呈現明顯減少、降雨強度集中，而豪雨及大雨次數則有增加趨勢，過去被視為不尋常的極端氣候到未來恐成為常態現象，而都市淹水主要原因大致為河川、排水通水斷面不足，外水溢淹至都市內，或者外水水位高漲，內水不易排除所導致，為能防範重大災情，各重大排水渠道及橋梁河川陸續架設 CCTV 水位監視設備以進行監控，然監視錄影影像需經監測者確認，在眾多的即時影像呈現中，洪水漫淹至堤防的進程卻不易於多鏡頭肉眼監控過程中被發現，且目前大部分水位資訊需由現場人員進行資訊回傳，若無人回傳則無水位紀錄，僅有少部分地區架設河川水位感測器進行回傳，此外現場儀器壽命易受限於環境、水流流況、機具特性及維護經費等條件影響，對此為能輔助臺中市災害應變中心在災害應變中心開設期間，就可能發生或加劇的淹水災害地區進行預警，本研究透過人工智慧方法建置水位辨識模型於颱風豪雨時期提供可信賴的輔助決策資訊，供決策者災中應變與相關決策制定參考之用。

關鍵詞：卷積神經網路，水位監控，影像辨識

目錄

摘 要.....	I
目 錄.....	II
表目錄.....	III
第一章 研究緣起.....	1
第二章 研究目的.....	4
第三章 文獻探討.....	6
第四章 研究架構與研究方法.....	9
4.1 研究架構.....	9
4.2 研究方法.....	10
4.2.1 資料蒐集.....	10
4.2.2 影像預處理.....	11
4.2.3 模式建置.....	12
4.2.4 評鑑指標.....	16
第五章 結果與討論.....	17
第六章 結論與建議.....	21
參考文獻.....	24

表目錄

表 1 模式樣本數量	17
------------------	----

圖目錄


圖 1	2018 年 0823 事件河川水位監控	2
圖 2	監控者同時監控多台即時影像(現況).....	2
圖 3	各地區災情通報	3
圖 4	防災應變單位決策示意圖	4
圖 5	南屯知高圳 2018/10/09 16:00 現況照片及水位	5
圖 6	LeNet-5 神經網路架構	7
圖 7	本研究架構	9
圖 8	觀測站位置圖	10
圖 9	訓練、驗證及測試資料分類示意圖	11
圖 10	影像分割示意圖	12
圖 11	本研究影像辨識模型架構圖	13
圖 12	卷積操作過程範例(二維運算).....	14
圖 13	卷積操作過程範例(三維運算).....	14
圖 14	特徵映射最大值池化示意圖	15
圖 15	全連接層輸出架構	16
圖 16	監測影像示意圖	17
圖 17	各監視器模式訓練過程之正確辨識率變化圖	18
圖 18	各監視器影像水位辨識模式之測試結果	20
圖 19	橋墩水尺之水位辨識示意圖	22
圖 20	API 操作流程示意圖	23

第一章 研究緣起



在地理位置上臺灣處於西北太平洋邊緣，且位於西北太平洋熱帶氣旋移動範圍內，依據中央氣象局統計，自 1958 年至今，於西北太平洋颱風場數計有 1,545 場，颱風為臺灣本島帶來豐沛的雨量，侵臺期間挾帶豪大雨暴雨及西南氣流影響，使各地大量降雨造成局部低窪地區發生積水或淹水情況，由於颱風所降下的雨水，易造成都市排洪系統排水不及導致淹水災害，對此相關單位決策者非常關切颱風豪雨可能帶來的淹水地區，但目前受限於科技限制，難以完整精準掌控及預警。近年氣候極端的異常，分析近 50 年降雨日數呈現明顯減少、降雨強度集中，而豪雨及大雨次數則有增加趨勢，2018 年 8 月 23 日受到低壓帶及西南氣流影響，南臺灣壟罩在滂沱大雨之中，連日豪雨重創南臺灣的民生經濟，過去被視為不尋常的極端氣候到未來恐成為常態現象，而都市淹水主要原因大致為河川、排水通水斷面不足，外水溢淹至都市內，或者外水水位高漲，內水不易排除所導致，因此面對氣候致災的不確定性除採工程對策外，政府為了防範洪水侵襲，早已經陸續建置多個閉路電視監控(Closed-Circuit Television, CCTV)，藉由監視錄影影像即時監控洪水水位或者觀察洪水水位計回傳資訊，已達到控制洪水水位，以防水患之發生(0823 河川排水水位監控如圖 1 所示)，然目前淹水災情通報仍大多由民眾或水情巡守網絡通報水情監控中心或區公所再傳達至市府防災中心，僅有少部分監視設施同時具有感測電傳水尺能夠即時回報，需要監控者隨時監控(如圖 2 所示)，因此而 0823 豪雨事件中發生仍有多處地區尚未即時撤離應變(如圖 3 所示)，在防災應變上仍有所不足。

本研究團隊長期擔任臺中市政府的災害情資研判幕僚，颱風豪雨期間透過即時氣象資訊配合長年的應變經驗、歷史紀錄與既有的科技，研析其關聯性後，提供適切的防洪應變參考，而後續可啟動本研究未來發展的防汛網路預警系統，及早研判可能致災區域，以供決策者研擬適當的災害應變決策。

八掌溪八掌溪橋



曾文溪新中水位站



八掌溪橋左岸



曾文溪渡頭堤防



資料來源：國家災害防救科技中心

圖 1 2018 年 0823 事件河川水位監控



資料來源：三立新聞網

圖 2 監控者同時監控多台即時影像(現況)



圖片來源：台南市消防局提供

台南市中華醫事科大幼兒園學童受困



圖片來源：中央社/警方提供

高雄市新興區民生路淹水



圖片來源：中央社/警方提供

高雄市新興區民生路淹水

圖 3 各地區災情通報

第二章 研究目的

根據 2017 年 7 月經濟部提出前瞻基礎建設計畫-水環境建設之「推廣水資源智慧管理系統及節水技術」，其計畫內容智慧防汛網推廣建置計畫一都市(區域)設置智慧監控設備暨研發管理軟體中，預期目標將「導入物聯網架構下之智慧感測元件、通訊模組，針對現有水情監控進行逐步升級」，而未來將會是資料爆炸時代，如何應用演算法及運算分析大數據，儼然成為重要的議題。

目前人工智慧系統關鍵技術為深度學習(deep learning)，其深度學習為機器學習(machine learning)之一種方式，都必須仰賴訓練資料建構模型，同時 AI 也可說是資料科學最重要的應用之一。藉由深度學習技術從監視錄影影像龐大資料庫中，找尋影像特徵，進行目標辨識甚至行為(behavior)萃取。深度學習主要模型具多種深度神經網路(Deep Neural Network, DNN)，其中卷積神經網路(Convolutional Neural Network, CNN)最為成功的 DNN 特例之一，廣泛運用於圖像辨識應用，如深度學習最先廣為人知的 Google 大腦專案或 Facebook 人臉辨識等多項研究，證明影像辨識的可行性。為此，藉由影像辨識技術運用於監視錄影器之影像，助於即時自動化 AI 監測水位，以掌握大規模河流的洪水動態，進而達到城市整體基礎設施智慧方向發展(如圖 4 所示)。




圖 4 防災應變單位決策示意圖

臺中市災害應變中心於颱風豪雨期間，透過中央氣象局及各方相關單位所提供的資訊，就可能發生或加劇的淹水災害地區進行預警，其中現況水位監控部分，概分為兩個面向，茲將之分述如下：

一、為能防範重大災情，各重大排水渠道及橋梁河川陸續架設 CCTV 水位監視

設備以進行監控，然監視錄影影像需經監測者確認，在眾多的即時影像呈現中，洪水漫淹至堤防的進程卻不易於多鏡頭肉眼監控過程中被發現，因此，若不具備影像辨識技術，往往容易忽略鏡頭所傳遞的洪水漲升及漫淹行為，除未能有效使用國家預算所佈建的監控設備之即時傳遞的寶貴訊息外，更白白錯失原先可把握的防洪應變的時間，故本研究水位辨識模型能有效減少人力成本，及早研判淹水風險。

二、目前大部分水位資訊需由現場人員進行資訊回傳，若無人回傳則無水位紀錄，僅有少部分地區架設河川水位感測器進行回傳，此外現場儀器壽命易受限於環境、水流流況、機具特性及維護經費等條件影響，如南屯知高圳2018年10月9日當日水位正常，現場量測儀器顯示不明訊號，如圖5所示，且儀器設置有諸多限制以至於其不見得能完全被包含於既有的防洪操作系統中，故本研究水位辨識模型能輔助測量儀器失效時之空窗時期，亦可加強未架設感測儀器之排水區段，建立完善的防汛網路。



資料來源：台中市水情監測系統(<http://twr.jianhua.com.tw/Detail.aspx?stationId=W01GB11>)。節取日期 2018.12.20

圖 5 南屯知高圳 2018/10/09 16:00 現況照片及水位


臺中市災害應變中心在災害應變中心開設期間，可能會遇到水位資訊回傳不及或現場水位感測儀器損壞等問題，為能輔助災害應變中心獲得即時水位資訊，本研究將透過透過人工智慧方法建立水位辨識模型，透過 CCTV 影像即時影像辨識水位回傳，於颱風豪雨時期提供可信賴的輔助決策資訊，供決策者災中應變與相關決策制定參考之用

第三章 文獻探討

目前臺灣於水位辨識模型仍採用水位之邊緣偵測(Edge Detection)方式進行，如郭等人(2015)提出「監視影像辨識技術應用」內容針對河川水位進行影像辨識，辨識流程由後端平台傳送的彩色的 RGB(Red、Green、Blue，紅綠藍三色)數位影像檔，對整張 RGB 的數位彩色影像進行灰階影像轉換後進行影像強化及校正處理，劃設感興趣區域選取(ROI)，透過中位數濾波器(Median Filter)演算法針對 ROI 影像進行雜訊處理後，以邊緣偵測找尋水位影像輪廓。此做法前提需正對影像進行校正及標示影像中水位高度所對應之位置始能辨識，建模過程繁瑣困難，而人工智慧的技術爆發，新一代的影像辨識技術為卷積神經網路(Convolutional Neural Network, CNN)，已廣泛運用到各大行業，其辨識精準度也明顯提升。

卷積神經網路最初是為解決圖像辨識問題設計的，過去全連結層(fully-connected layer)的神經網路，以黑白圖像、尺寸為 500 pixel×500 pixel 的影像辨識而言，一張圖片就有 25 萬個 pixel，如以各 pixel 為模式輸入資料，即輸入維度為 25 萬，其後如再連接一層隱藏層神經元數與輸入個數等量的隱藏層(即 25 萬個隱藏層神經元)，僅在輸入與隱藏層間，即存在 625 萬的連結，第一層隱藏層後至輸出層輸出單元，如再以全連結方式進行訓練，其運算量將遠超出一般電腦計算能力，因此必須減少模式參數數量。而另外存在問題是影像為三維形狀(RGB 色彩)包含重要空間資訊，各色版間具有緊密關聯性，距離較遠的像素彼此沒有關係，潛藏著必須瞭解的本質類型，但全連結層忽略形狀的重要，把輸入資料當成相同維度處理，無法發揮與形狀有關的資料。1980 年由日本科學家 Kunihiko Fukushima 提出神經感知機(neocognitron)的概念，也可以是為最初的實作模型，包含兩類神經元，分別為抽取特徵的 S-cells 及抗形變的 C-cells，1990 年時 LeCun 等人發表 CNN 架構，並在 1998 年加以改良，並且命名為 LeNet-5 的多層神經網絡(如圖 6 所示)，也是奠定現在 CNN 基石之作，圖中包含輸入層、卷積層(convolutional layer)、降採樣(subsample)的池化層(pooling layer)、全連結層及輸出層共計 8 層，其輸入圖像為 32×32 的灰階圖像，有 6 個卷積核(kernels)有部分文獻把這名稱為濾鏡(尺寸為 5×5)，此核以 2 格的步幅針對輸入圖像進行濾鏡移動，將各個位置乘上濾鏡的元素與對應輸入的元素，以積和得到卷積運算的輸出結果作為非線性轉換函數映射，轉換函數採用雙彎曲函數(sigmoid function)，再以 2×2 的平均池化層用來進行降採樣，

最後連結全連結層使用反向傳播算法訓練，最後輸出分類結果，理論上對縮放、平移、旋轉等劇烈改變具有不變性，有著很強的泛化性，最大特點在於卷積的權重共用結構，可以提取資料中最有效的特徵，且降低模型複雜度，使原始像素直接識別視覺模式成為可能，在當時手寫辨識中有很好的效果。



資料來源：Lecun, Y., et al., Gradient-based learning applied to document recognition. Proceedings of the IEEE, 1998. 86(11): p. 2278-2324.

圖 6 LeNet-5 神經網路架構

2006 年起，Hinton(2006)教授和學生 Salakhutdinov 提出深度學習概念，其主要傳達兩個主要資訊，其很多隱層的類神經網路具有優異的特徵學習能力，學習獲得的特徵對資料有更本質的刻畫，進一步有利於視覺化或分類；2012 年由 Geoffrey Hinton 教授的學生 Alex Karpathy 等人提出能顯著改善以前方法在圖像分類任務，將 CNN 整體架構命名為 AlexNet，類似於更深層的 LeNet-5 架構，Top-5 錯誤率為 16.4%，相較於傳統淺層模型方法提升許多，模型除了將神經網路架構加深之外，成功使用線性整流函數(Rectified Linear Unit, ReLU)作為轉換函數，成功解決 Sigmoid 在網路較深時使深度消失問題，並且使用資料增強(水平翻轉影像、隨機平移、增加光源等)訓練樣本及 Dropout 機制，主要是避免過度擬合(over fitting)，進而能提升演算法準確率，同時採用 GPU 加速等新技術，隨著 AlexNet 成功，啟發後續更多技術創新。

現今 CNN 已廣為各領域之運用，如 Minnema(2018)於醫療積層製造業中，將頭顱掃描之 CT(Computed Tomography, CT)影像透過 CNN 技術全自動化精準分割頭顱形狀，使得頭顱模型更易製造；馬德芸(2018)應用深度神經網路建立臉部影像酒駕偵測系統，於酒駕臉部特徵辨識獲得了 92.2%的準確率，而 PPGI 信號獲得了 60%的準確率優於過去的接觸式 PPG 信號。

本研究目的為提供即時水位資訊，輔助臺中市災害應變中心多元的災害應變決策輔助支援資訊，參考上述文獻，本研究擬採卷積神經網路概念建構水位

影像辨識模型，並初步採用 AlexNet 網路作為本研究所建置之網路架構，採用臺中市水情監測系統提供之歷史監測影像及水位紀錄作為分析資料，在進行影像訓練時，考量各監視影像品質不一及各階段水位資訊數量不足等情形，本研究後續於模式訓練前將進行影像預處理階段，減少訓練影像畫面之干擾及解決樣本不平衡所導致的模式失效等問題，建置高精度之水位辨識模型，介接監控河川排水之 CCTV 影像獲得即時水位資訊，減少人力資源。

未來本研究將其技術原理轉換為水尺水位辨識模型，於未架設感測儀器之河川排水或道路，配合各地區所架設之 CCTV 監視器，即時辨識水尺推估水位資訊，建立防汛網路預警系統做為另一決策輔助系統，必要時，提供決策者更進一步的決策輔助參考資訊。

第四章 研究架構與研究方法

4.1 研究架構

本研究水位影像辨識模式之研究架構主要參考 Kuo(2016)流程架構改良，分階段方式進行，為資料蒐集階段、影像預處理階段及模式建置階段，研究架構如圖 7 所示。





圖 7 本研究架構

模式建置分三階段流程，第一階段為資料蒐集階段將蒐集現況水位影像及水位資訊，並將各區間範圍水位進行分類，將各區間水位抽取訓練、驗證及測試資料，作為後續模式訓練之用；第二階段為影像預處理階段，透過前期預處理減少畫面干擾及處理訓練樣本不平衡，提高模式訓練成效；第三階段模式建置，訓練影像預處理後輸入至模式反覆訓練測試直到模型之辨識水位達到合理準確度，即可建立水位辨識模型，續以輸入測試資料，測試模式之準確度。各階段作法將於後續章節研究方法中詳述。

4.2 研究方法

4.2.1 資料蒐集

本研究以臺中市為研究標的，採用臺中市水情監測系統提供之歷史監測影像及水位紀錄作為分析資料，共計 72 個測站影像及其對應水位資料，觀測站位置分別如圖 8 所示，將蒐集之測站歷史影像紀錄及水位分為訓練及測試資料，其作法係以 10cm 為區間進行區隔，隨機挑選各類別總數之 8 成作為訓練資料，其餘則平分為驗證資料及測試資料，如圖 9 所示。



資料來源：本研究繪製。

圖 8 觀測站位置圖




圖 9 訓練、驗證及測試資料分類示意圖

4.2.2 影像預處理

本研究蒐集影像及水位資訊後，於進入模式前透過將影像資料預處理方式，盡可能不被關鍵因素影響，進而提升模型效能，如 Kuo(2016)等人利用 CNN 神經網路建立影像檢索，影像辨識架構分三階段，預處理階段(data pre-processing stage)、訓練階段(testing stage)及測試階段，於影像預處理方面利用影像灰化、水平翻轉及直方圖均化增加訓練資料，處理後影像檢索結果與未處理結果相比精度略有上升；Phong(2017)等人透過辨識 CT 影像診斷腦出血病例，其影像辨識前預先將影像中多餘資訊處理，利用增強技術調整影像亮度及旋轉影像，增加後續訓練影像豐富度，其訓練模型精度皆達 99%以上；Rzanny(2017)等人於自動化影像辨識葉子種類上，針對影像預先處理結果進行試驗，發現輸入當影像特徵越明確有助於後續訓練階段，使影像辨識發揮最大功效。

將蒐集河川排水影像資料與監測水位紀錄數值透過，其影像預處理階段分為影像分割及影像資料平衡處理，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，各處理說明如下：

一、影像分割

為加速模式訓練時間及減少多餘參數，先行將訓練影像進行分割將影像著重於辨識區域，如圖 10 所示：




圖 10 影像分割示意圖

二、影像資料平衡

2015 年 Paulina Hensman 及 David Masko 等人針對訓練樣本不平衡情形進行研究測試，當訓練影像樣本數越不平衡，模式辨識效果越差導致訓練失效，而作者透過過採樣(oversampling)技術，複製樣本數較少類別平衡各樣本數，訓練效果極佳與原始數據平衡情況相比其結果相距不大。因河川排水常時水位影像資訊佔樣本大多數，重複性質較高，因此本研究除過採樣技術外，同時採用欠採樣(undersampling)技術減少常水位採樣次數，以達到平衡樣本之目的。

4.2.3 模式建置

自 AlexNet 於 2012 年提出後，深度學習領域的研究發展極其迅速，本研究以其網路架構為基礎建立影像辨識模型，包含 8 個卷積層、4 個池化層及 1 個全連接層，如圖 11 所示。本研究將影像資料預處理後，輸入至本研究建置模型輸出辨識水位與實際水位資訊進行比對，其差值利用最陡坡降法(gradient steepest descent method)的觀念，將誤差函數予以最小化，配合學習速率倒推回去計算權重與閾值修正量，修正整體神經網路權重值，每經一段訓練次數，則以未參與模式訓練的影像，亦即測試資料(testing data)驗證其模型精確度，重複操作直到模型達到合理精確度完成影像辨識模型，即建立完成的模型。本研究影像辨識模型神經網路架構詳述如下：




圖 11 本研究影像辨識模型架構圖


一、卷積層：

主要目的就是在保留圖像的空間排列並取得局部圖像作為輸入特徵，原理是透過一個指定尺寸的過濾器(kernel，也稱 filter)，由依序滑動取得影像中各局部特徵，將卷積核所輸出區域以點積(dot product)方式累加，如圖 12 所示，圖中為灰階處理，通常是以二維進行運算，因本研究採集影像資料是以彩色為主，除了必須處理垂直、水平方向外，依照各個色版方向(即深度方向)進行輸入資料與濾鏡的三維卷積運算，如圖 13 所示，經過輸出結果再由非線性轉換函數處理，即為所謂的特徵映射(feature map)，每一點可視為原圖形中該區域的特徵。在進行卷積處理之前，會將輸入資料進行周圍填上固定的資料(例如 0)，這個動作稱為填補(zero padding)，目的是為了調整輸出大小，以避免每次進行卷積運算時，空間就會縮小的問題。卷積層在數學上，若以輸入圖像位置定為(i,j)，而有 k 個 kernel 計算如下：

$$z_{i,j,k}^l = W_k^{lT} X_{i,j}^l + b_k^l \quad \text{式(1)}$$

$$a_{i,j,k}^l = a(z_{i,j,k}^l) \quad \text{式(2)}$$


其中 $z_{i,j,k}^l$ 為特徵映射，由過濾器上 W_k^l 權重向量與輸入圖像值相乘產生，加上 b_k^l 偏差值，指數 l 為輸入圖像的維度，再透過轉換函數 $a(\cdot)$ 即為卷積層輸出資料 $a_{i,j,k}^l$ 。



圖片來源：改作自 Apple Inc.技術文件

(<https://developer.apple.com/library/content/documentation/Performance/Conceptual/vImage/ConvolutionOperations/ConvolutionOperations.html>)

圖 12 卷積操作過程範例(二維運算)



資料來源：Convolutional Neural Networks (CNNs): An Illustrated Explanation, 2016, Abhinav Saxena。
 (<http://xrds.acm.org/blog/2016/06/convolutional-neural-networks-cnns-illustrated-explanation/>)


圖 13 卷積操作過程範例(三維運算)

二、池化層

功能是將輸入的影像尺寸縮小，以減少每張特徵映射維度並保留重要的特徵，其優點可加快系統運作的效率、具有抗干擾的作用及減少過度擬合的情況，使用卷積層所輸出特徵映射值運算，選取一固定尺寸區域，並於區域範圍中選擇一個最大池化(max pooling)或平均池化(average pooling)，而本研究主要在影像辨識領域中，使用的是最大池化，以減少了圖素的參數數量，保留了重要的特徵資訊，增進 CNN 的運作效率，最大值池化如圖 14 所示。數學表示如下：

$$y_{i,j,k}^l = \text{pool}(a_{m,n,k}^l), \forall (m,n) \in R_{ij} \quad \text{式(3)}$$

其中 R_{ij} 係指卷積層輸出範圍 (i,j) 內選取 (m,n) 尺寸範圍進行池化。



圖片來源：<http://cs231n.github.io/convolutional-networks/>

圖 14 特徵映射最大值池化示意圖

三、全連接層

全連接層係指傳統神經網路，在卷積神經網路架構中，有整合輸出作用，本研究在此階段將特徵值排序為全連接層之輸入值，透過與隨機亂數產生權重值相乘加總，並以線性轉換函數輸出至下一層至輸出層推論水位值，後續計算與實際水位間的誤差值，反覆修正輸出流程如圖 15 所示。




圖 15 全連接層輸出架構

4.2.4 評鑑指標

為評估模式辨識結果之準確度，將模式所辨識之水位值與實際水位值相互比較，計算正確辨識數量與辨識總數量之百分比，即正確辨識率(Correct Identification Rates ,CIR)，公式如下所示：

$$CIR = \frac{N_c}{N} \times 100\% \quad \text{式(4)}$$

其中 N_c 係指正確辨識數量， N 為辨識總數量。

本研究實際水位值係由臺中市水情監測系統現場架設之感測水尺，所回傳之數據屬單點量測，而水體流動時水表面會因風或渠底障礙物等因素而產生擾動，導致水表面有不同水位卻屬同一量測水位值，因此本研究考量前述之緣由故將辨識之水位值與實際水位值之差值小於等於 10 cm 內結果視為準確範圍。

第五章 結果與討論

本研究以人工智慧卷積神經網路建置水位辨識模型，其網路架構係以 8 層卷積層、4 層池化層與 1 層全連結層組合，本研究以台中市水情監視系統為輸入影像訓練來源，採其中三處排水監視影像(1)龍井大排支流下游；(2)霧峰後溪底排水下游；(3)大里樹王埤排水上游(如圖 16)為例，各監視影像數量如表 1 所示。



圖 16 監測影像示意圖


表 1 模式樣本數量

監視影像位置	訓練數量	驗證數量	測試數量
龍井大排支流下游	5362	668	654
霧峰後溪底排水下游	1288	157	149
大里樹王埤排水上游	2114	283	272


將訓練影像樣本預處理後輸入至本研究建置網路模式進行反覆訓練驗證，每批次(batch-size)輸入 64 張影像，為求各訓練影像樣本經模式訓練 300 次以上，故設定總疊代(iteration)訓練次數為 29500 次，以每 100 次訓練進行一次正確辨識率驗證，各監視影像訓練過程結果如圖 17 所示，由圖得知，訓練過程後段部分已到達穩定情形，其正確辨識率不再上升，本研究所訓練次數範圍內，模型之水位辨識能力達到合理準確度。

後續模型建置採訓練範圍內最高正確辨識率驗證值之權重進行建置，即完成水位辨識模型，將測試影像輸入至訓練完成之模型輸出其辨識水位，並與實際水位值以散佈圖方式呈現，計算準確範圍內(± 10 cm)之水位，結果顯示皆有高達 96%以上正確辨識率，如圖 18，由結果得知其模型有高準確度之辨識能力。


(a)龍井大排支流下游



(b)霧峰後溪底排水下游




(c)大里樹王埤排水上游




註：虛線為訓練過程中最高正確辨識率

圖 17 各監視器模式訓練過程之正確辨識率變化圖

(a)龍井大排支流下游



(b)霧峰後溪底排水下游



(c)大里樹王埤排水上游




圖 18 各監視器影像水位辨識模式之測試結果

第六章 結論與建議

現況資訊越充足越能於災害時期做出適切的決策，除氣象局的專業報導及資訊之外，另行發展一套輔助支援模型，根據既有能得到的資訊，可有效的及早研判可能致災區域，預防可能發生或加劇的災害，提供適切的輔助資訊。

本研究團隊長期擔任臺中市政府的災害情資研判幕僚，藉由長年的應變經驗、歷史紀錄與既有的科技，輔助臺中市災害應變中心決策者於災害應變中心開設期間，研擬適當的災害應變決策。本研究透過臺中市水情監測系統提供之歷史監測影像及水位紀錄作為訓練及測試資料，輸入至本研究所建置之網路架構，其架構係以 8 層卷積層、4 層池化層與 1 層全連結層組合，將訓練影像預處理後輸入至模式訓練測試直到模型之辨識水位達到合理準確度，以示範地區監視影像為例，模式辨識準確率皆達 96% 以上，透過模型建置即時回報水位變化，可減少人為判斷及感測儀器損壞時所導致的資訊不完全，有助於即時災前整備與災中應變淹水情資的掌握。

本研究係全國水利淹水影像辨識領域第一個成功案例，未來將用之以輔助臺中市災害應變中心根據新技術可提供的資訊進一步研擬災害應變計畫。而在未來操作上，本研究提出以下建議，做為未來應變中心防災之參考。

一、水尺辨識模型

本研究以卷積神經網路以透過 CCTV 歷史影像建立水位辨識模型，而新架設之 CCTV 無歷史影像及無水位資訊地區，未來亦可用於發展水尺辨識模型，於未架設感測儀器之河川排水，架設水尺透過水尺辨識模型讀取水尺水位資訊(如圖 19 所示)，其模型除用於河川排水外，亦可以轉作道路上使用，即時掌握民眾回傳或監視設備擷取之各地水尺顯示之路面淹水情況。



圖片來源：經濟部水利署

圖 19 橋墩水尺之水位辨識示意圖

二、資料生成

本研究分析臺中市水情監測系統歷史監測影像進行模式建立，當缺乏歷史資訊則無法分析建置，故後續可透過生成對抗網路(Generative Adversarial Network, GAN)資料生成，填補訓練所需資訊。

三、平行運算

本研究將建置多組 CNN 模型，採用圖形處理器(Graphics Processing Unit, GPU)運算，但仍考量未來資訊量龐大電腦運算能力有限，後續將利用多張 GPU，開發平行運算方式同時運算訓練及啟用多組影像辨識模型，提升整體運算辨識能力，以建構完整且即時更新之防汛網路預警系統。

四、標準介接介面建置

針對都市防洪策略為強化「監控」、「預警」、「通報」及「應變」功能，未來將本研究模式及後續發展之水尺辨識模型，運用物聯網及雲端資料創造整合提供應用程式介面(Application Programming Interface, API)，有關單位可透過介接功能(如圖 20 所示)，獲取所需資訊，提高有關單位救災能力。

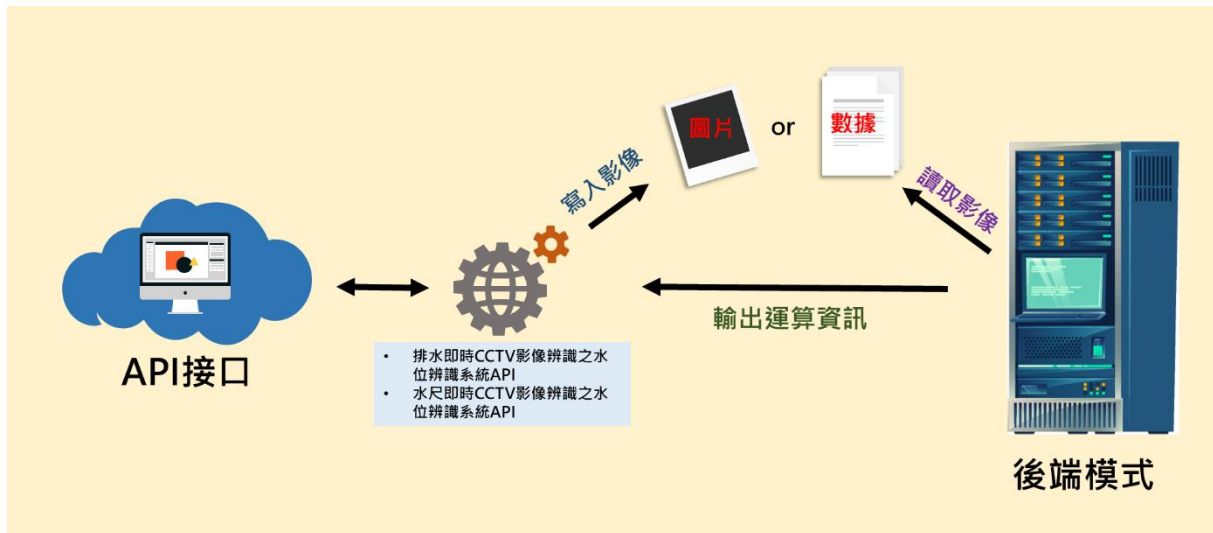


圖 20 API 操作流程示意圖

五、防汛網路預警系統

災害預警係於天然災害發生或加劇前，就事件風險資訊對可能受到影應變單位發出警報，以適時、適切地協助民眾採行應變作為，進而降低民眾生命財產的損失，未來可整合「氣象預警報」、「河川排水警戒資訊」及「各地區監視影像系統」，結合本研究水位辨識模型及未來發展之水尺辨識模型建立防汛網路預警系統，即時通知警戒地區，給予防救業務單位參考。

參考文獻

馬德芸，應用深度神經網路之臉部影像酒駕偵測系統，中興大學電機工程學系所學位論文，2018。

集智俱樂部，「人腦電腦黃金交叉：人工智慧將統一世界」，佳魁資訊，2016。

郭晉安、簡仲和、陳泰賓，「監視影像辨識技術應用」，經濟部水利署，2015。

謝劍斌、興軍亮等人，「改變未來 20 年最重要的 20 個視覺機器學習理論深讀」，佳魁資訊，2016。

Asha Gowda, Karegowda, A.S. Manjunath, M.A. Jayaram. Application of Genetic Algorithm optimized Neural Network connection weights for Medical Diagnosis of PIMA Indians Diabetes. International Journal on Soft Computing (IJSC), Vol.2(2011), No.2, p. 15-23.

Alex Krizhevsky, Ilya Sutskever, and Geoff Hinton, "ImageNet classification with deep convolutional neural networks", In Advances in Neural Information Processing Systems 25, pages 1106–1114, 2012.

Council, N.S.a.T., N.a.I. Technology, and R.a.D. Subcommittee, The National Artificial Intelligence Research and Development Strategic Plan. 2016.

D.C. Ciresan et al., "Deep Big Simple Neural Nets for Handwritten Digit Recognition," Neural Computation, Vol. 22, 2010, 3207-3220.

Fukushima, K., Neocognitron, "A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", Biological Cybernetics, 36(4), 193-202, 1980.

Faqlang Wang, Wangmeng Zuo, Liang Lin, David Zhang, Lei Zhang, Joint Learning of Single-Image and Cross-Image Representations for Person Re-Identification, The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 1288-1296.

Guan Qingji, Huang Yaping, Zhong Zhun, Zheng Zhedong, Zheng Liang, Yang Yi, Diagnose like a Radiologist: Attention Guided Convolutional Neural Network,

Published 2018 in ArXiv., 2018.

Hecht-Nielsen, R., “Theory of the backpropagation neural network”, in International 1989 Joint Conference on Neural Networks, 1989.

Hinton, G.E. and R.R. Salakhutdinov, “Reducing the Dimensionality of Data with Neural Networks”, Science, 313(5786), 504-507, 2006.

He, K., et al, “Deep Residual Learning for Image Recognition”, in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.

J. Dai, Y. Li, K. He, and J. Sun. R-fcn: Object detection via region-based fully convolutional networks. arXiv:1605.06409, 2016.

Kuo, C.-H., Y.-H. Chou, and P.-C. Chang, “Using Deep Convolutional Neural Networks for Image Retrieval”, Electronic Imaging, 2016(2) ,1-6, 2016.

LeCun, Y., et al., “Handwritten Digit Recognition with a Back-Propagation Network”, Advances in neural information processing systems 2 Pages 396-404, 1990.

Lecun, Y., et al., “Gradient-based learning applied to document recognition”, Proceedings of the IEEE, 86(11) , 2278-2324, 1998.

Lin, M., Q. Chen, and S. Yan, “Network In Network”, In Proc. ICLR, 2014.

Michael, R., “Acquiring and preprocessing leaf images for automated plant identification: understanding the tradeoff between effort and information gain”, Plant Methods (2017) ,13-97, 2017.

Mason R. Swofford “Image Completion on CIFAR-10”, arXiv:1810.03213v1 [cs.CV] 7 Oct 2018.

Paulina, Hensman and David, Masko “The Impact of Imbalanced Training Data for Convolutional Neural Networks”, KTH, School of Computer Science and Communication, 2015.

Phong, T.D., et al., “Brain Hemorrhage Diagnosis by Using Deep Learning”, in

Proceedings of the 2017 International Conference on Machine Learning and Soft Computing., ACM: Ho Chi Minh City, Vietnam, 34-39, 2017.

Simonyan, K. and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition”, Published as a conference paper at ICLR 2015, 2014.

Szegedy, C., et al., “Going deeper with convolutions”, in 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2015. Boston, MA, USA: IEEE, 2015.

ZHU, Cheng; CHENG, Tao. Research on geological hazard identification based on deep learning. In: AIP Conference Proceedings. AIP Publishing, 2018. p. 040027.

Zhang, C., Zhu, Y., Huang, M., Li, C, Development of Automatic Water Level Monitor for Reservoir Based on Image Recognition. In Journal of Physics: Conference Series (Vol. 1176, No. 5, p. 052032). IOP Publishing, 2019, March.