

人工智慧排水水位影像辨識之速成建模研究

AI-Based Rapid Model Development for Drainage Water Level Image Recognition

逢甲大學
水利工程與資源保育學系

碩士班研究生
王健明

Jian-Ming Wang

逢甲大學
水利工程與資源保育學系

學士班專題生
蔡杰儒

Chien-Ju Tsai

逢甲大學
水利工程與資源保育學系暨
營建及防災研究中心

助理教授
陳柏蒼

Boris P.-T.Chen

摘要

本研究旨在探討利用人工智慧技術進行排水水位影像辨識的速成建模方法。一般而言，人工智慧模型的訓練需要大量的歷史紀錄數據，特別是針對特定地點的水位高度紀錄。而本研究評估了在缺乏過去水位影像紀錄的情況下，利用現有的 CCTV 設備進行水位辨識的可行性。本研究使用低水位影像(乾季或無水位)人工生成各種水位高度影像來進行 AI 模型訓練，並在訓練後使用真實的高水位影像進行模型驗證。根據驗證結果，建立了一套標準作業程序。透過將現有的 CCTV 設備轉化為智慧水尺，不僅能夠降低集水區或灌區整體感測水尺的布設成本，還可以在減災階段提供更完整的集水區逕流資訊，以及在災害應變階段更好地掌握轄區災情。研究利用於灌區，則可用於確認控制點控制放流量與各灌區實際流量進行稽核。速成建模方法顯示了在資源有限的情況下，快速部署和應用 AI 技術於水位辨識的潛力。

關鍵詞：人工智慧，智慧水尺，影像辨識，影像生成

Abstract

This study aims to explore rapid modeling methods for drainage water level image recognition using artificial intelligence (AI) technology. Typically, training AI models requires extensive historical data, especially water level records for specific locations. This study evaluates the feasibility of using existing CCTV equipment for water level recognition in the absence of past water level image records. The study employs artificially generated images of various water levels using low water level images (dry season or no water level) for AI model training. After training, real high water level images are used for model validation. Based on the validation results, a standard operating procedure was established. By converting existing CCTV equipment into intelligent water gauges, the overall cost of deploying water gauges in catchment or irrigation areas can be reduced. Additionally, this approach can provide more comprehensive runoff information during disaster mitigation phases and better monitor disaster situations within the

jurisdiction during disaster response phases. When applied to irrigation areas, it can be used to verify control point discharge and audit actual flow rates in different irrigation areas. The rapid modeling method demonstrates the potential for quickly deploying and applying AI technology for water level recognition in resource-limited situations.

Keywords: Artificial Intelligence, Intelligent Water Level Meter, Image Recognition, Image Generation

一、前言

近年來，氣候變遷導致極端氣候現象日益頻繁，河川流量的豐枯期變化也越發明顯。過去五十年中，降雨日數顯著減少，降雨強度卻逐漸集中，並且豪雨及大雨次數有增加的趨勢。這使得各地區經常面臨洪水的威脅，其原因大多與河川排水通道不足有關，導致外水溢入都市，或外水水位高漲使內水難以排除。例如，2017年6月1日的0601豪雨事件，在鋒面與西南氣流的共同影響下，新北市三芝和雲連線草嶺地區的最大三小時累積雨量突破210毫米，而高雄南天池地區的總雨量更高達1,446毫米，造成嚴重淹水災情。為應對這種情況，政府致力於建設與自然共生的「韌性城市」，在災害衝擊下，力求減少災害損失並迅速恢復。掌握災害地區的現況以有效運用有限資源，是決策者的重要關切點。為了防範重大災情，許多地方在主要排水渠道和橋樑河川上安裝了CCTV水位監視設備。然而，這些監視錄影影像若無水位感測器搭配，仍需監測人員肉眼確認。在眾多即時影像中，洪水漫溢堤防的進程不易被同步多鏡頭監控所發現並發出警訊。缺乏影像辨識技術，往往容易忽略鏡頭傳遞的洪水漲升或漫溢行為，不僅未能有效利用國家預算建設的監控設備所提供的即時資訊，更錯失了寶貴的防洪應變時間。

本研究基於此背景，利用現有CCTV監視影像資料，採用人工智慧(Artificial Intelligence, AI)中的卷積神經網路(Convolutional Neural Network, CNN)技術，解析歷史水位影像，使機器自我學習影像特徵，建立水位影像辨識模型，發展自動水位辨識技術。結合相關水情資訊，促進城市基礎設施的智慧化發展。

二、文獻回顧

本研究對國內外有關人工智慧深度學習應用於水情影像辨識的相關文獻進行了綜合分析。通過閱讀和整理學術論文、期刊文章、政府出版物、報紙雜誌和網絡資料等，對現有的深度學習應用於影像辨識和水情預測的方法和限制進行了描述、分類、總結和分析。並將文獻回顧分為五個部分，以系統化和有條理地呈現相關研究。首先，介紹卷積神經網路(CNN)的發展歷程，展示從最初的神經感知機到現代CNN的技術進步；接著，探討深度殘差網路(Residual Neural Network, ResNet)的突破，該技術解決了CNN隨著網絡層數增加而出現的退化問題，提高了網絡深度和準確性，是CNN發展中的重要里程碑；之後，展示CNN在各領域的應用，如醫療、安防和自動駕駛，強調其廣泛的實際價值和應用前景。隨後，介紹洪水監測技術的進展，強調現有技術的挑戰和需求，為基於CNN的水位識別和洪水監測方法提供背景資料。最後，聚焦於深度學習技術在水位識別和洪水監測中的應用，展示最新研究成果和技術創新，通過具體案例強調其效

果和挑戰，為未來研究提供參考。

2.1 卷積神經網路的發展歷程

卷積神經網路(Convolutional Neural Network, CNN)最初是為解決圖像辨識問題設計的。在早期的全連結層(fully-connected layer)神經網路中，黑白圖像的像素數量巨大。例如，尺寸為 500 pixel × 500 pixel 的影像包含 25 萬個像素，如果以各 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，這種龐大的計算量遠超出一般電腦的計算能力，因此必須減少模式參數數量。此外，影像是三維形狀（RGB 色彩），包含重要的空間資訊，各色版間具有緊密關聯性，但全連結層忽略了形狀的重要性，把輸入資料當成相同維度處理，無法充分利用形狀相關的資料。

1980 年，日本科學家 Kunihiko Fukushima 提出了神經感知機(neocognitron)的概念，這可以看作是最初的實作模型，包含兩類神經元：抽取特徵的 S-cells 及抗形變的 C-cells。1990 年，LeCun 等人發表了 CNN 架構，並在 1998 年改良後命名為 LeNet-5，這一多層神經網絡成為現代 CNN 的基石。LeNet-5 包含輸入層、卷積層(convolutional layer)、池化層(pooling layer)、全連結層及輸出層共計 8 層，其輸入圖像為 32x32 的灰階圖像，使用 6 個卷積核(kernels)，卷積核尺寸為 5x5，以 2 格步幅針對輸入圖像進行濾鏡移動，通過卷積運算得到非線性轉換函數映射的輸出結果，使用 sigmoid 函數進行轉換，然後以 2x2 的平均池化層進行降採樣，最後連結全連結層使用反向傳播算法訓練，理論上對縮放、平移、旋轉等變化具有不變性，且具有很強的泛化性。

2006 年，Hinton 和 Salakhutdinov 提出了深度學習的概念，指出多隱層的神經網路具有優異的特徵學習能力，學習獲得的特徵能更本質地刻畫資料，有利於視覺化或分類。2012 年，Hinton 的學生 Alex Krizhevsky 等人提出了 AlexNet，這種新方法顯著改善了圖像分類任務。AlexNet 類似於更深層的 LeNet-5 架構，成功使用線性整流函數(Rectified Linear Unit, ReLU)作為轉換函數，解決了 Sigmoid 在網路較深時深度消失的問題，並使用資料增強（例如水平翻轉影像、隨機平移、增加光源等）和 Dropout 機制來避免過度擬合，進而提升算法準確率。同時，AlexNet 採用了 GPU 加速等新技術，使得深度學習成為一個強大工具。

2.2 卷積神經網路的突破—深度殘差網路

深度學習模型自 2012 年起快速發展，LeNet (Yann LeCun 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)等網路結構相繼出現。這些網路隨著層數的增加，使用的參數量和所需的運算資源和成本也相應提升。然而，網路層數的增加並不一定能夠提高準確度，這是因為原始的 CNN 架構在逐步加深網路層級時會產生退化問題(degradation problem)。

2015 年，Kaiming He 等人提出了深度殘差網路(deep residual network)，有效解決了網路深度導致的退化問題，提出了 ResNet 架構，網路深度可以達到 34、50、101 及 152 層。隨後，Ke Zhang(2017)提出了 RoR(Residual Networks of Residual Networks)多

層級殘差網路；Saining Xie(2017)將 ResNet 結合了 GoogleNet 的 Inception 結構，提出 ResNeXt，在不增加參數的前提下提高了電腦視覺的辨識準確度。

2.3 CNN 在各領域的應用

卷積神經網路(CNN)技術在各個領域的應用範圍廣泛且深入，具有強大的特徵提取和模式識別能力，解決了許多複雜的圖像和視頻分析問題。在醫療領域，CNN 被用於醫學影像分析，例如胸腔 X 光片的疾病分類、肝臟腫瘤檢測、腦腫瘤檢測、乳腺癌篩查和眼底圖像診斷，顯示出高度的準確性和可靠性。在安防領域，CNN 技術被應用於面部識別、行為分析和監控視頻的自動分析，提升公共安全防範能力。例如，馬德芸(2018)利用深度神經網絡建立臉部影像酒駕偵測系統，準確率達到 92.2%。

在自動駕駛領域，CNN 被用於環境感知和路徑規劃，能夠識別道路、行人和其他車輛，從而提高行駛安全性和乘客舒適度。特斯拉和 Waymo 等公司利用 CNN 技術實現了自動泊車、自動導航和交通標誌識別等功能。農業領域同樣受益於 CNN 技術，特別是在作物健康監測和害蟲檢測方面，通過分析農田的航拍圖像，CNN 能夠識別作物的健康狀況和病蟲害情況，幫助農民提高農業生產效率。

金融和商業領域也應用了 CNN 技術，如銀行和金融機構利用 CNN 進行支票圖像識別、ATM 監控和信用卡欺詐檢測，提升了金融服務的自動化和安全性。電子商務平台利用 CNN 技術進行圖像搜索和推薦系統，通過分析用戶購物行為，提供個性化的產品推薦。總之，CNN 技術憑藉其強大的特徵提取和模式識別能力，已經在醫療、安防、自動駕駛、農業和金融等各個領域廣泛應用，並帶來了革命性的變革和創新。隨著技術的不斷進步，CNN 在未來將繼續發揮重要作用。

2.4 洪水監測技術的進展

近年來，隨著極端氣候現象的頻繁和城市化進程的加速，全球各地的城市越來越容易遭受洪水的侵襲。這一現象促使研究人員和決策者加強城市的抗洪能力。建立抗洪城市的一個關鍵組成部分是實時決策支持，這需要從洪水監測和傳感器網絡中收集實時信息(Manzoor et al., 2014; Perez et al., 2015; Loftis et al., 2018)。儘管用於實時決策的城市洪水監測網絡正在增長，但仍缺乏在洪水事件中做出精細決策所需的監測站覆蓋範圍(Helmrich et al., 2021; Rosenzweig et al., 2021)。因此，研究推進細尺度、實時城市洪水監測的傳感方法具有重要意義(Moy de Vitry et al., 2019; Muhadi et al., 2020)。

目前，最先進的洪水監測通常使用現場水位傳感器(Loftis et al., 2018; Carlson et al., 2019)，儘管也有使用衛星(Li et al., 2019)、無人機(UAV)(Gebrehiwot et al., 2019)或固定點監控攝像機(Moy de Vitry et al., 2019)的遠程感測方法。這些感測方式各有優勢和不足。現場水位傳感器可以在關鍵點收集高精度的水位數據，但由於它們只觀察單一點，缺乏表示洪水空間分佈的能力(Lo et al., 2015)。通過遠程感測捕獲的空間分佈洪水觀測數據對於輔助決策者以及構建和校準城市排水系統的水文和水力模型以進行預測具有重要價值(Chao et al., 2019; Shen et al., 2019; Liu et al., 2020; Moy de Vitry et al., 2020)。

2.5 基於深度學習的水位識別和洪水監測

許多研究探討了使用圖像處理和卷積神經網絡(CNN)技術進行水位識別和洪水監測的方法。Bai 等人(2019)則通過深入實驗分析和模型設計，證明了基於卷積神經網絡的多尺度深度特徵學習方法在序列建模中的有效性，並為未來的研究提供了新的方向。P. C haudhary(2020)使用在 ImageNet 上預訓練的 VGG16 作為 Reg + Rank、回歸和 Regression++的網絡主幹，對非侵入性河流水位進行測量，具體來說，該研究使用深度學習技術，通過分析監控攝像頭拍攝的圖像來自動測量河流水位，且準確率達到 90%以上。Gang Dou(2022)提出了一種基於數字圖像處理技術和 CNN 的水位識別方法對水尺進行水位辨識，精度達到 94.6%，該方法在提取水位特徵方面具有高效性，並能應對不同光照條件下的影像處理。Yidi Wang(2024)應用了 Deeplabv3+和 LinkNet 兩種基於深度卷積神經網絡(DCNN)的語義分割模型，對城市洪水影像中的洪水範圍進行精確分割，這些模型能夠有效區分水體和非水體區域，提供精確的洪水影像分析。

據上，目前的 AI 技術在水位識別和洪水監測中主要依賴於水尺的辨識或讀數。然而，在光源不足或水尺損壞的情況下，這些技術仍存在一定的限制。影像質量的下降和水尺部分遮擋等問題可能影響水位的準確讀取。因此，本研究的目標是提出一種直接辨識水位的方法，而無需依賴傳統的水尺。我們旨在實現高效、準確的水位識別，即使在沒有水尺或遇到挑戰性環境（如光照不足）時，仍能保持穩定的性能。這種方法將為洪水監測和水位管理提供更靈活且可靠的解決方案。

2.6 小結

隨著技術的進步，基於 CNN 和深度學習的水位識別和洪水監測方法在準確性和自動化程度上有顯著提升。這些方法為城市洪水監測和水資源管理提供了有效的技術手段，促進了相關領域的進一步發展。然而，這些方法的準確性和穩定性可能受周圍環境影響，因此在實際應用中，需結合多種技術手段，以提高整體系統的可靠性和精確性。未來的研究方向應集中於改進算法的穩定性、擴展數據集的多樣性和增強模型的泛化能力，從而提升基於深度學習的水位識別和洪水監測系統的實用性和應用範圍。

一般的 CNN 影像辨識應用通常依賴大量歷史影像數據進行訓練。然而，獲取這些歷史資料可能因為資源、時間或其他限制而變得非常困難。因此，本研究旨在探索和開發一種不依賴歷史資料進行訓練的 CNN 影像辨識方法。這將不僅解決歷史資料難以取得的問題，還可能創造出更加靈活和適應性強的影像辨識系統。這種方法將依賴於即時獲取的數據或合成數據，從而提高模型的可用性和適應性。

三、研究方法

本研究擬提出一種不依賴歷史數據的水位辨識方法，以克服目前技術在特定情境下的局限性。以水位辨識為例，若要對某河道或排水系統進行高低水位辨識，傳統方法通常需要擁有該斷面的高低水位影像。在此過程中，需先蒐集特定河道或排水斷面的各高程水位紀錄，這通常要求經歷至少一個豐水時期的長期影像監測記錄。接著，需篩選出高低水位影像進行模型訓練。

這些過程通常包括影像蒐集、篩選及模型訓練等步驟。短則需要等待一次明顯的降

兩紀錄加上一定的工作時間，長則須經數年的資料蒐集，才能獲得足夠的歷史數據來進行有效的模式訓練。這不僅耗時且對於水位監測的及時性和靈活性造成限制。因此，本研究旨在突破這些限制，開發一種無需歷史數據的水位辨識系統。希望在乾水季節或無任何任何水位影像紀錄下，也能有效建置並實施這一系統，從而實現對水位的即時監控和管理，提供更高效且靈活的解決方案。

3.1 研究方法

本研究探索不依賴歷史數據的 CNN 影像辨識方法，旨在解決數據獲取困難，提升模型靈活性和適應性，本研究首先包含資料蒐集階段。在這一階段，透過寫爬蟲程式從監測站、政府機構或研究機構的數據庫中獲取水位影像和對應的水位數據。確保數據的品質和完整性是關鍵，需特別注意在特殊條件下拍攝的影像，如水滴干擾或渠道內雜草等情況，並排除無水位資料或重複時間的影像。接著進入影像預處理階段，選擇低水位且影像清晰的圖片，通過人工方式生成多種水位的水位影像資料，以平衡影像數據。此步驟確保訓練數據的多樣性和全面性，為模型訓練提供充足的資料支持。隨後進行模型建立與訓練階段，包括訓練資料準備、建立影像辨識模型及模型參數調整，確保模型具備足夠準確度。最後是驗證數據預處理階段，收集並處理驗證數據，包括高、中、低水位的水位影像及其對應數據，進行模型定案和模型效能討論，評估模型的準確性和可靠性。下文將詳細描述此研究的完整流程，從數據收集到模型訓練及驗證階段的每個步驟：

一、資料蒐集(Data Collection)

在研究初始階段，首先進行數據蒐集。此步驟的目標是獲取與水位相關的各種影像資料，這些資料將成為後續影像預處理和模型訓練的基礎。

本研究水位影像和水位資料蒐集過程主要透過撰寫爬蟲程式自動從公開的監測站、政府機構或研究機構的數據庫中獲取資料。蒐集的資料包含空渠床影像及高、中、低水位之影像。其中渠道的空渠床影像，用於人工生成各水位影像，並將人工生成後之各水位影像用於 CNN 模型的訓練資料。

在模式驗證部分，則利用蒐集欲辨識之渠道的各水位真實影像，用於 CNN 模型建模後模式對真實影像辨識能力的評估基礎，藉以半段本研究所建置之模型是否可行。在蒐集過程中可能受到天氣條件、儀器校準和數據記錄等多種因素的影響，存在缺失或不準確的情況。因此，在資料蒐集過程中，需特別注意在特殊條件下拍攝的影像，例如有水滴干擾、渠道內雜草干擾等情況下的影像。這些影像在數據集中的存在可能會影響模型的準確性，因此需要特別標註並處理。此外，確保所有影像都有對應的水位資料，排除那些缺少水位數據或重複時間的影像，以確保數據集的準確性和一致性。這種系統性的數據處理方法將有助於提升模型的訓練效果和最終的準確性。

(二)影像之畫質選定：

本研究所開發的程式能夠處理不同畫質的影像，不論是高畫質還是低畫質的影像，都能夠利用此程式進行人工生成各水位影像及進行水位辨識。不論影像的初始品質如何，只要符合基本要求，皆可用於生成訓練數據，並達到預期的效果

二、影像預處理階段(Image Preprocessing Stage)

(一)選擇低水位且影像清晰的圖片：

首先，從蒐集到的數據中篩選出低水位且影像清晰的圖片。這些圖片將作為基礎數據，用於生成不同水位的影像資料。篩選的過程中，確保所選圖片在光照條件良好、視角適中且無遮擋物的情況下拍攝，以保證影像的質量和細節清晰度。這些高質量的低水位圖片將有助於後續影像資料的準確生成和水位變化的模擬，提高模型訓練的效果和準確性。

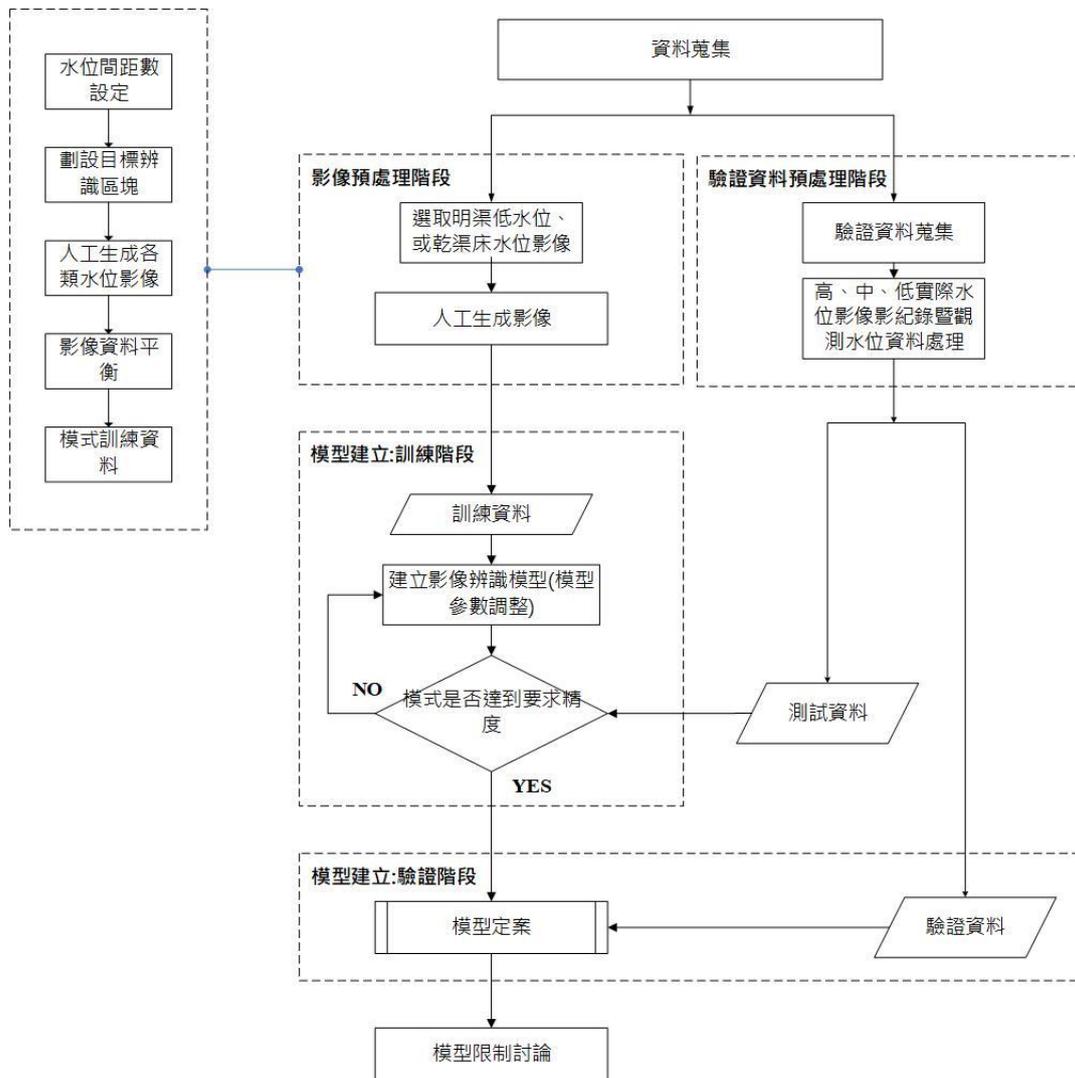


圖 1 研究架構圖

(二)人工生成不同水位的影像資料：

利用選擇的低水位圖片，通過人工方式生成多種水位的影像，以此平衡影像數據。此步驟確保訓練數據的多樣性和全面性，為模型訓練提供充足的資料支持。

1.水位間隔設定(Setting of Water Level Intervals)

此步驟的目的是確定不同水位的間隔，這將為後續的影像生成和模型訓練提供基礎數據。

根據現有的水位數據和實際需求，確定不同水位之間的間隔大小。這一過

程需要考慮到實際的水位變化範圍和頻率，以便生成的影像能夠充分反映實際水位變化情況。例如，可以根據歷史數據確定每 10 公分為一個水位間隔，從而涵蓋從低水位到高水位的所有範圍。

2. 目標識別區塊的指定(Designation of Target Recognition Block)

在確定水位間隔之後，需要指定目標識別區塊。這一步驟的主要目的是劃定影像中的關鍵區域，以便進行準確的水位辨識。

根據影像中的特徵，選擇適合進行水位辨識的區域。這些區域應能夠清晰地顯示水位的變化情況。目標區域的選擇應該考慮到影像中的光照條件、遮擋物和水面反光等因素，以確保識別結果的準確性，如圖 2 所示。

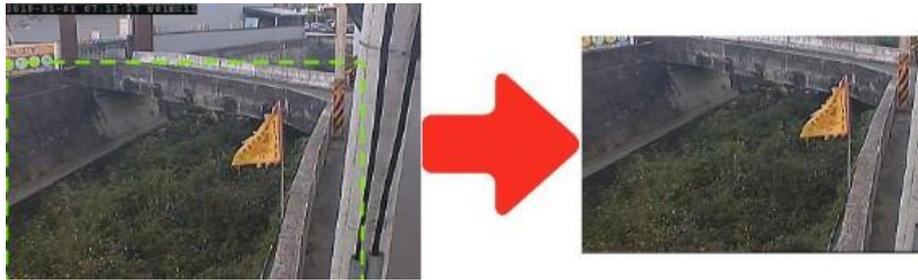


圖 2 目標區域選擇

3. 各水位影像的人工生成(Artificial Generation of Various Water Level Images)

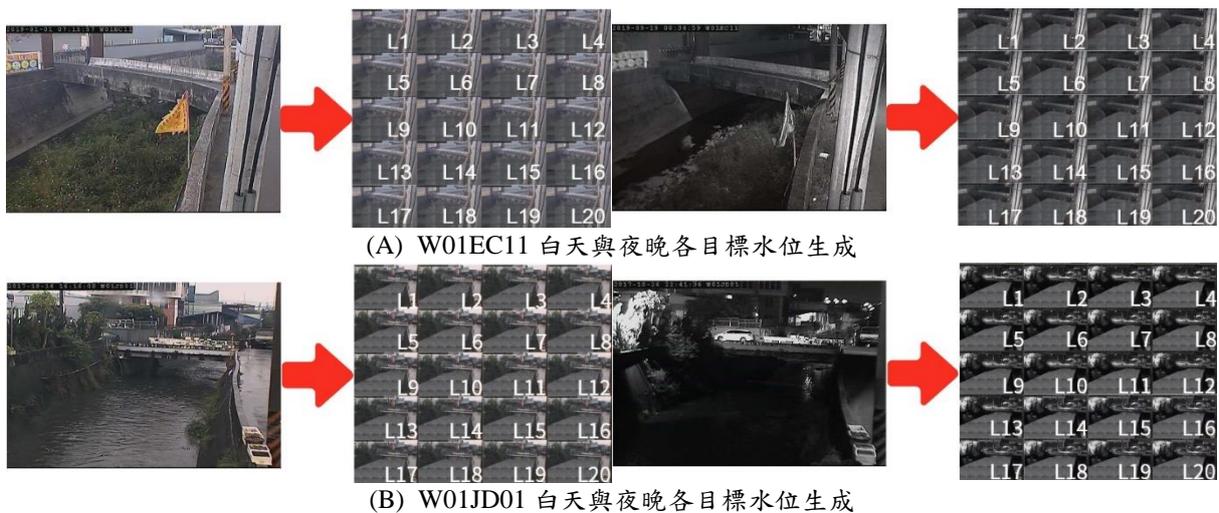
在指定目標識別區塊之後，需要生成不同水位的影像。這一步驟的主要目的是為模型訓練提供足夠的數據支持。具體過程如下：

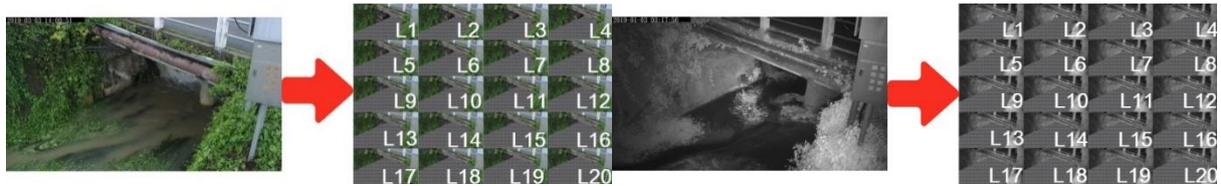
(1) 低水位影像的選擇

從現有影像中選擇低水位且清晰的影像作為基礎數據。這些影像應具備良好的光照條件和較少的遮擋物，確保後續生成的影像質量。

(2) 人工生成高水位和中水位影像

在低水位影像的基礎上，通過人工方式生成不同水位的影像，包括高水位和中水位。確保生成的影像能夠真實反映各種水位情況，如圖 3。





(C) W01CB11 白天與夜晚各目標水位生成

圖 3 人工生成不同水位之影像

4. 影像數據的平衡(Balancing of Image Data)

在生成不同水位影像之後，需進行影像數據的平衡。這一步驟的主要目的是確保訓練數據的多樣性和均衡性，以提高模型的準確性。

將生成的各種水位影像進行分類和整理，確保每種類型的影像數據量大致相等。通過平衡數據，避免模型在訓練過程中因數據不均而產生偏差。例如，可以針對每個水位間隔生成相同數量的影像，以確保模型能夠均衡學習各種水位情況。

5. 訓練數據準備(Training Data for the Model)

經過上述步驟處理後的影像數據，將作為模型訓練的基礎數據。這一步驟的主要目的是為模型訓練提供高質量的數據支持。

將經過平衡處理的影像數據整理成模型可接受的格式。以及確保訓練數據的質量和多樣性，以提高模型訓練的效果。

三、驗證數據預處理階段(Validation Data Preprocessing Stage)

(一) 蒐集驗證數據：

獲取用於模型驗證的數據，這些數據將在模型訓練完成後，用於評估模型的準確性和可靠性。在這一階段，我們需要確保蒐集到的驗證數據具有代表性和多樣性，以能夠全面檢驗模型在不同場景下的表現。例如，可以從實際的監測場景中收集到不同時間段的水位影像，以及相應的真實水位數據。

(二) 處理高、中、低水位影像及其對應數據

對驗證數據進行分類和處理，確保包含高、中、低水位的影像及其對應數據，以全面評估模型的表現。

四、模型建立：訓練及驗證階段(Model Development: Training & Validation Stage)

訓練及測試階段的目的是建立和驗證卷積神經網絡(CNN)模型，以進行準確的影像辨識。首先，根據影像預處理階段生成的平衡影像數據，準備包含低、中、高水位的訓練資料集。訓練資料集的多樣性和全面性是模型有效訓練的關鍵。

在建立影像辨識模型時，使用多層卷積層、池化層和全連接層設計初始模型，並通過調整學習率、批次大小等參數來優化模型性能。訓練過程中，不斷監控準確率和損失函數等指標，以確保模型達到最佳效果。

測試資料集的準備同樣重要，需確保其多樣性和代表性，未參與訓練的資料用來評估模型性能。將測試資料輸入已訓練模型，計算並記錄預測結果，使用準確率、召回率進行綜合評估。根據測試結果，分析模型的優缺點，調整模型結構或重新訓練，以提升性能。

最終，確定最佳模型架構和參數設置，並將其部署於實際應用場景中進行實時

水位監測。通過持續監控和分析實際應用中的預測結果，不斷對模型進行微調，確保其長期穩定運行，達到準確辨識水位並提供可靠預警的目標。訓練及測試階段是確保模型在實際應用中能夠發揮最大效能的重要環節。

3.2 模式的建置與應用

3.2.1 研究區域

本研究以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及驗證資料共計 72 個測站(測站分布如圖 4 所示)影像挑出 3 個測站影像(就颱風期間本研究就記錄較完整資訊者選出 3 個為本文研究標的)及其對應水位紀錄資料(模式驗證用)。



資料來源：臺中市水情監測系統(<http://wrbalert.taichung.gov.tw/index.html>)

圖 4 台中市水位監測站位置

3.2.2 模式建置

本研究將各站以生成影像輸入至本研究所建置之網路架構輸出辨識水位值，將其辨識結果與設定水位值相互間的誤差，利用最陡坡降法(The 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修正量與閾值修正量，反覆修正至誤差量收斂，即完成影像辨識模型訓練；模型建置完成後，針對未參與模式訓練的影像(實測影像)，亦即測試資料(testing data)，輸入至建置完成之模式驗證其準確度。

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 5 所示。本研究將影像資料預處理後(包含各水位圖像資料生成)，輸入至本研究建置模型輸出辨識水位與設定水位資訊進行比對，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：

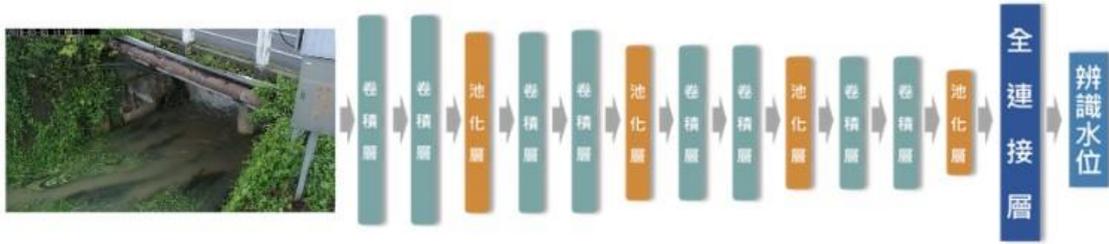
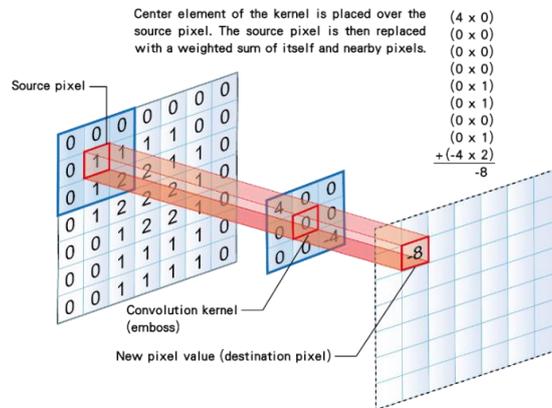


圖 5 本研究影像辨識模型架構圖

(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 6 所示，圖中為灰階處理，通常是以一維進行運算，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)進行輸入資料與過濾器的三維卷積運算，如圖 7 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：



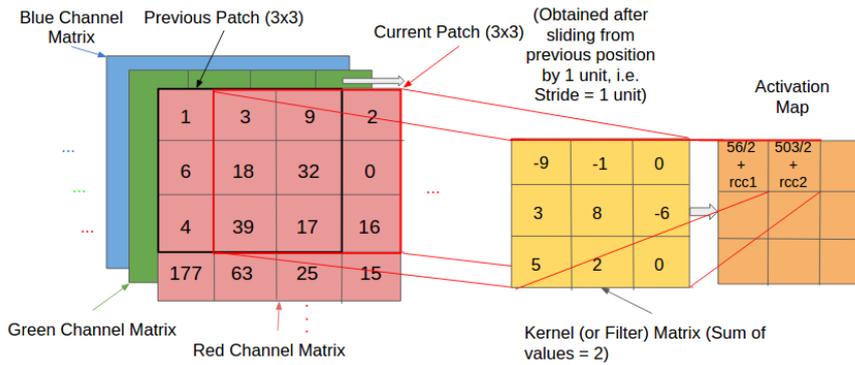
圖片來源：改作自 Apple Inc.技術文件(<https://developer.apple.com/library/content/documentation/Performance/Conceptual/vImage/ConvolutionOperations/ConvolutionOperations.html>)

圖 6 卷積操作過程範例(一維運算)

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

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

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 $a_{i,j,k}^l$ 。



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

圖 7 卷積操作過程範例(三維運算)

(二) 池化層：

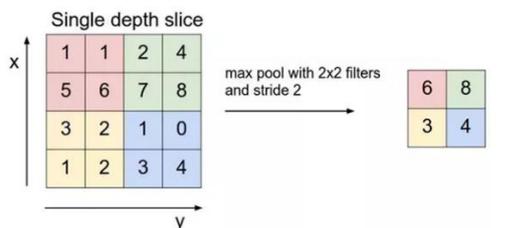
功能是将輸入的影像尺寸縮小，以減少每張特徵映射維度並保留重要的特徵，其優點可加快系統運作的效率、具有抗干擾的作用及減少過度擬合的情況，使用卷積層所輸出特徵映射值運算，選取一固定尺寸區域，並於區域範圍中選擇一個最大池化(max pooling)或平均池化(average pooling)，而本研究主要在影像辨識領域中，使用的是最大池化，以減少了圖素的參數數量，保留了重要的特徵資訊，增進 CNN 的運作效率，最大值池化如圖 8 所示。數學表示如下：

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

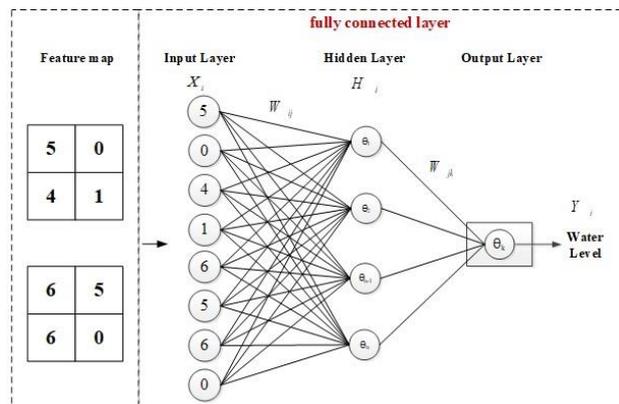
其中 R_{ij} 係指卷積層輸出範圍(i,j)內選取(m,n)尺寸範圍進行池化。

(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 9 所示。



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



X_i ：輸入值； W_{ij} 、 W_{jk} ：權重值； θ_n ：閾值向量； H_i ：隱藏層輸出值； Y_i ：輸出值

圖 8 特徵映射最大值池化示意圖

圖 9 全連接層輸出架構

四、結果與討論

本研究以人工智慧卷積神經網路建置影像辨識模型，網路架構由 8 層卷積層、4 層池化層與 1 層全連結層組成。研究首先對訓練影像進行預處理，將其輸入至模型進行反覆訓練測試，並測試不同參數組合（如學習次數、學習速率等），直到模型在辨識水位方面達到合理的準確度。考量到水體流動時，水表面可能因風或渠底障礙物等因素產生擾動，研究將辨識值與實際值差距小於等於 10 公分的結果視為準確範圍。當訓練準確度穩定且不再上升時，即完成影像辨識模型的訓練。雖然目前僅針對單一渠道生成了訓練資料，尚未能完全解決所有挑戰，但研究結果已顯示出模型在水位辨識方面的潛力。未來的研究可考慮進一步優化訓練資料生成過程，特別是針對更廣泛的水位範圍進行數據增強和模擬。通過這些改進，有望進一步提升模型的辨識精度，為智慧水尺的應用奠定更堅實的基礎。

本研究透過空明渠的影像資料作為訓練資料，並輸入至所建置的網路架構中，進行反覆訓練，直到模型的辨識水位達到合理的精確度，從而完成影像辨識模型的建置。接著，將未參與訓練的影像輸入模型，以驗證其準確度。根據圖 10 的結果顯示，誤差均在 20% 以下，證明模型具備可行性。未來，若能增加人工生成影像中的水位間距數量，將有助於再提高水位辨識的準確性，以支援基於影像辨識技術的水尺辨識系統開發。這將有效降低傳統水尺的建設成本，並能即時掌握路面淹水情況，建立智慧防汛網絡，從而達到減少洪氾災害的目標。



圖 10 水位預測

五、結論與建議

本研究的意義和價值在於開發了一種不依賴歷史資料的快速生成水位辨識影像的方法，為水位監測和洪水預警提供了一種創新且高效的解決方案。傳統的 CNN 影像辨識應用通常需要大量的歷史影像數據進行訓練，而這些數據的獲取往往因資源、時間或其他限制而變得困難。本研究方法突破了這一瓶頸，僅利用低水位影像即可生成多種不同水位的訓練資料。具體而言，研究通過選取低水位且影像清晰的圖片，利用人工方式生成中水位和高水位的影像，並將這些生成影像用於平衡數據集，確保訓練資料的多樣性和全面性。這種方法不僅降低了數據獲取的門檻，還大大縮短了模型訓練的時間，提升了水位監測系統的部署效率。模式驗證結果顯示，模型在不同水位條件下的誤差範圍仍堪為防災水位預警參考之用，亦即在影像辨識建模過程，即使在缺乏歷史數據的情況下，以生成影像進行模式訓練，模式對真實影像仍具辨識能力，驗證了生成影像方法的可靠性。

在模型調整過程中，訓練資料的多寡與對真實世界的詮釋能力對最終輸出結果有顯

著影響。本研究透過三支不同位置的 CCTV 影像紀錄，實證人工生成水位影像作為人工智慧模式訓練資料的可行性，並以真實影像資料的推論能力，評估此一過程模式的可能誤差範圍。本研究人工生成影像刻意使用單一水面紋理照片填充各水位所在平面空間，並分成日夜間進行各水位照片的人工生成，雖能賦予人工智慧一定推論能力，然實際 CCTV 在影像記錄過程可能的機身抖動、鏡頭水珠、空間霧氣、現場反光、水面波動、異物漂流等現場狀況未來建議納入考量，因此模式在水面物理情況迥異與人工生成水位照片時，會出現較大誤差。隨生成式 AI 熱潮引爆全球，2024 年更被視為從雲端落地的應用元年，預估至 2024 年底 AI 的圖像生成亦將有跳躍性的成長，因此本研究的虛擬水位生成，將有更有效率的操作空間，預期 AI 的圖像生成能提升訓練資料的多樣性，並進一步降低輸出結果的誤差。整體而言，本研究呈現了不依賴歷史資料的 CNN 影像辨識建模可能，為水位監測與洪水預警提供了新的解決方案，可為日後以善用各單位既有 CCTV 影像的賦能操作，節省另建水位監視設備所需初建與維護成本的參考。

致謝

本研究感謝國家科學及技術委員會提供經費支持，計畫編號：NSTC112-2625-M-035-002。

參考文獻

1. 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。
2. Arratia, A., and Sepúlveda, E. "Convolutional Neural Networks, Image Recognition and Financial Time Series Forecasting." In *Mining Data for Financial Applications*, pp. 60–69, Springer, Cham, 2020.
3. Babiker, M. A. A., Elawad, M. A. O., and Ahmed, A. H. M. "Convolutional Neural Network for a Self-Driving Car in a Virtual Environment." In *2019 International Conference on Computer, Control, Electrical, and Electronics Engineering (ICCCEE)*, pp. 1–6, 2019. <https://doi.org/10.1109/ICCCEE46830.2019.9070826>.
4. Dou, G., Chen, R., Han, C., Liu, Z., and Liu, J. "Research on Water-Level Recognition Method Based on Image Processing and Convolutional Neural Networks." *Water*, 14(12), 1890, 2022.
5. Fischer, T., and Krauss, C. "Deep Learning with Long Short-Term Memory Networks for Financial Market Predictions." *European Journal of Operational Research*, 270(2018), pp. 654–669.
6. Fukushima, K. "Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position." *Biological Cybernetics*, 36(4), pp. 193–202, 1980.
7. Gonzalez, J., and Yu, W. "Non-linear System Modeling Using LSTM Neural Networks." *IFAC-PapersOnLine*, 51(13): 485–489, 2018.

8. He, K., Zhang, X., Ren, S., and Sun, J. "Deep Residual Learning for Image Recognition." *arXiv*, 2015. <https://arxiv.org/abs/1512.03385>.
9. Krizhevsky, A., Sutskever, I., and Hinton, G. E. "ImageNet Classification with Deep Convolutional Neural Networks." In F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, eds., *Advances in Neural Information Processing Systems 25*, Curran Associates, Inc., pp. 1097–1105, 2012.
10. Kuo, C. H., Chou, Y. H., and Chang, P. C. "Using Deep Convolutional Neural Networks for Image Retrieval." *Electronic Imaging*, 2016(2): 1–6.
11. Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P. "Gradient-based Learning Applied to Document Recognition." *Proceedings of the IEEE*, 86(11): 2278–2324, 1998. <https://doi.org/10.1109/5.726791>.
12. Ma, X., Tao, Z., Wang, Y., Yu, H., and Wang, Y. "Long Short-Term Memory Neural Network for Traffic Speed Prediction Using Remote Microwave Sensor Data." *Transportation Research Part C: Emerging Technologies*, 54, pp. 187–197, 2015.
13. Qing, X., and Niu, Y. "Hourly Day-Ahead Solar Irradiance Prediction Using Weather Forecasts by LSIM." *Energy*, 148, pp. 461–468, 2018.
14. Simonyan, K., and Zisserman, A. "Very Deep Convolutional Networks for Large-Scale Image Recognition." In *The 3rd International Conference on Learning Representations*, San Diego, United States, 2015: 1–14.
15. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. "Going Deeper with Convolutions." *Computer Vision and Pattern Recognition*, arXiv:1409.4842, 2014. <https://doi.org/10.48550/arXiv.1409.4842>.
16. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. "Going Deeper with Convolutions." In *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1–9, 2015. <https://doi.org/10.1109/CVPR.2015.7298594>.
17. Wang, J., Mall, S., and Perez, L. "The Effectiveness of Data Augmentation in Image Classification Using Deep Learning," 2015.
18. Yulita, I. N., Rambe, M. F. R., Sholahuddin, A., and Prabuwno, A. S. "A Convolutional Neural Network Algorithm for Pest Detection Using GoogleNet." *AgriEngineering*, 5(4): 2366–2380, 2023. <https://doi.org/10.3390/agriengineering5040145>.
19. Zhang, J., Zhu, Y., Zhang, X., Ye, M., and Yang, J. "Developing a Long Short-Term Memory (LSTM) Based Model for Predicting Water Table Depth in Agricultural Areas." *Journal of Hydrology*, 561(2018), pp. 918–929.
20. Zhang, K., Sun, M., Han, T. X., Yuan, X., Guo, L., and Liu, T. "Residual Networks of Residual Networks: Multilevel Residual Networks." *arXiv*, 2016. <https://doi.org/10.1109/TCSVT.2017.2654543>.