

以類神經網路進行灌溉排水水量預報之研究

HOURLY STREAMFLOW FORECASTING FOR AGRICULTURE WATER SUPPLY USING ARTIFICIAL NEURAL NETWORK

桃園農田水利會
資訊室
主任

陳建國
Chien-Kuo Chen

國立臺灣大學
氣候變遷與永續發展研究中心
博後研究員

張明瑞*
Ming-Jui Chang

國立臺灣大學
氣候天氣災害研究中心
助理研究員

張向寬
Hsiang-Kuan Chang

國立臺灣大學
氣候變遷與永續發展研究中心
研究助理

廖皓宇
Hao-Yu Liao

國立臺灣大學
氣候天氣災害研究中心
研究助理

程于芬
Yu-Fen Cheng

摘要

隨著氣候變遷因素影響，極端降雨的現象愈趨明顯，且農業水資源常需因應臨時移用，貯水池調蓄能力更顯重要。桃園地區利用貯水池進行區域灌溉為特有農業灌溉方式，可因應桃園大圳、河水堰供水不足時輔助使用，如何永續發展和有效管理以強化農業水資源使用效率是重要課題。本研究在桃園大圳 10 支線與 12 支線以流域水文模式建構幹線水位預測模型，分別預測未來 1 至 3 小時水位，並轉換成水量，以期輔助決策管理系統。本研究結合物聯網雲端運算和 Microsoft Azure Machine Learning 平台中處理非線性問題，表現良好之方法「類神經網路」，降雨與水位之相互關係，以建置幹線水位預測模型，利用貯水池有效調配管理水資源，達到水資源永續利用之目的。結果顯示，水位預測之均方根誤差與平均絕對誤差均小於 0.22 公尺、相關係數均大於 0.90 且效率係數均大於 0.80，表示此模式可提供良好的水位預測結果。未來，可根據監測系統接收到的降雨和水位預報提前掌握可調配的水量，以增加貯水池的水資源。

關鍵詞：桃園大圳、水資源管理、物聯網雲端運算、類神經網路、Microsoft Azure Machine Learning。

* 通訊作者，國立臺灣大學氣候變遷與永續發展研中心博士後研究員，
台北市羅斯福路 4 段 1 號，f99521311@ntu.edu.tw

HOURLY STREAMFLOW FORECASTING FOR AGRICULTURE WATER SUPPLY USING ARTIFICIAL NEURAL NETWORK

Chien-Kuo Chen

Taoyuan Irrigation Association

Ming-Jui Chang*

National Taiwan University
Research Center of Climate
Change and Sustainable
Development

Hsiang-Kuan Chang

National Taiwan University
Center of Weather Climate and
Disaster Research

Hao-Yu Liao

National Taiwan University
Research Center of Climate Change and
Sustainable Development

Yu-Fen Cheng

National Taiwan University
Center of Weather Climate and
Disaster Research

ABSTRACT

The climate change leads to increase the frequency of the extreme rainfall. How to enhance effective water use by sustainable development and effective management is a crucial issue. Taoyuan main canal transportation channel (TMCTC) is important to the agriculture water supply in Taoyuan and HsinChu County. It is necessary to have accurate hourly forecasting streamflow for water use in irrigated agriculture. Therefore, unlike the traditional water resources management, a novel forecasting model based on neural network regression model (NNR) is proposed to forecast the water level for 1 to 3 h lead time. The forecasts of the water level are transformed into the streamflow to allocate water resources. The proposed model is constructed using NNR from Microsoft Azure Machine Learning (Azure ML). The Azure ML is a kind of cloud computing, and IoT techniques, and NNR is great flexibility in modeling nonlinear processes. The results show that root mean square errors, coefficient of correlation and coefficient of efficiency are less than 0.22 m, greater than 0.9, and greater than 0.8, respectively. On the basis of the aforementioned performance measures, the proposed model can produce accurate forecasts, and is expected to be useful to water resources management.

Keywords: Taoyuan main canal transportation channel, water resources management, cloud computing and IoT techniques, neural network regression Microsoft Azure Machine Learning.

Chen, C.K., Chang, M.J.*, Chang, H.K., Liao, H.Y., & Cheng, Y.F. (2019). "Application of Three-dimensional Water Quality Model to Predict Water Quality Conditions under Different Wind Stresses in the Subalpine Lake." *Journal of Taiwan Agricultural Engineering*, 65(3), 64-76.
[https://doi.org/10.29974/JTAE.201909_65\(3\).0006](https://doi.org/10.29974/JTAE.201909_65(3).0006)

一、前言

桃園地區內利用貯水池進行區域灌溉為特有農業灌溉方式，可因應桃園大圳、河水堰供水不足時輔助使用。隨著氣候變遷因素影響，極端降雨的現象愈趨明顯，且農業水資源常需因應臨時移用，因此貯水池調蓄能力更顯重要。桃園農田水利會自民國 75 年起開始規劃建置桃園大圳幹線灌溉管理自動化工程，並逐漸發展為網際網路架構，完成各類水文監測、閘門遙控系統、展示網頁等輔助管理之系統工具，有效協助管理人員操作。物聯網與水文監測系統的發展近年來愈趨成熟，無論是記錄器、感測器或通訊方式，已逐漸勾勒出水資源物聯網，桃園水利會也朝向服務導向建置維運，並將物聯網雲端運算與系統結合。基於水資源永續利用及發揮桃園水利會轄內貯水池效益，有效調配管理水資源，於農作時期能適時增加可供水量，維持農耕正常運作。擬於轄內貯水池及幹支線取入口以符合物聯網概念之設備建置監測系統，進行貯水量監測。本研究擬在桃園大圳 10 支線與 12 支線以流域水文模式建構幹線水位預測模型，分別預測未來 1 至 3 小時水位，以期建立水情預測與輔助決策管理系統。

本研究歸納過去國內外專家學者之文獻，目前用於流域水文模式，依據反應水流運動規律的科學性和複雜程度，可分為概念性水文模式(Conceptual model)、物理機制模式(Physically-based model)、以及資料驅動模式(Data-driven model)三大類。概念性水文模式是通過對逕流物理過程的概念化，利用一些簡單的物理概念和經驗關係來近似地描述水流在流域的運行狀態，由於這類模式對流域資料要求相對簡單，同時又具有一定的物理理論基礎和模擬精度，在目前應用較為廣泛。目前比較著名的集塊式概念性流域有：美國陸軍工程兵團的逕流綜合和水庫調節模式(SSARR)，美國國家天氣局的水文模式(NWSH)，美國國家天氣局河流預報中心的 Sacramento 河預報中心水文模式(Sacramento)，大陸的新安江模式，原蘇聯水文氣象中心降雨逕流模式(HMC)，日本國家防災研究中心的水筒模式(TANK)等。物理機制模式旨在重現水文過程的機制並將其反應在現實，基於物理機制的模式是完全分佈式模式(Calvo and Savi, 2009)，考慮水文參數和過程的空間異質性分類，VIC 分佈式模式、SWAT 分佈式模式和在歐洲應用相對較多的 MIKE-SHE 模式等。Seibert (2000) 使用 HBV model 進行了逕流演算並且結合了基因演算法進行參數律定，成功對水位進行了預測。Moore *et al.* (1996) 利用 TOPMODEL 進行了水位的預報；資料驅動模式也稱為黑盒模式(Black-box model)，不需要眾多簡

化假設和各種水文參數，僅由模式建立輸入和輸出資料之間的關係，具代表性的模式有：簡單線性模式(SLM)、約束線性系統模式(CLS)、線性可變增益因數模式(VGFLM)和機器學習模式(Machine learning)，而隨著電腦運算的能力增加，資料驅動模式的準確性及效率也隨著增加。

上述之概念性水文模式和物理機制模式需要大量的參數及複雜的率定過程，耗費大量人力和運算成本，使模式僅能計算小型的流域，而計算速度和資料缺乏也使得模式無法既時預報。這些問題在資料驅動模式得以有效解決，因此資料驅動模式逐漸廣泛使用。資料驅動模式中常使用機器學習法應用在水位和流量之預測上。Toth *et al.* (2000) 使用 ARMA (Auto-regressivemoving-averaged)、ANN (Artificial neural networks) 及 KNN (K-nearest neighbour) 等模式，比較在短期雨量預測之精度分析及該預測雨量對於即時洪水預報之精度分析，其中模式僅利用過去的降雨紀錄做為輸入項，研究結果顯示類神經網路的方法較能有效改善洪水預報之精確度。Sivapragasam (2002) 採用支援向量機(Support vector machine, SVM)進行洪水水位預報。Kuo *et al.* (2014) 以隨機森林法進行了前置 1~3 小時之水位預報，並發現於 3 小時起有明顯的洪峰誤差及時間延遲現象。Liong 和 Sivapragasam (2002) 使用 SVM 預報未來 1 至 7 日的水位。Hsu 等人(2002) 提出自組織映射輸出模式(Self-organizing linear output map, SOLO)預報河川流量。Chang and Chen (2003) 採輻狀基底函數(Radial basis function)神經網路，預報受潮汐及颱風影響之河川水位。江衍銘和張斐章(2006) 首先以氣象雷達之觀測資料與回饋式神經網路(RNN)，建立定量降水預報模式，再以模式預報之雨量訓練倒傳遞類神經網路，以架構五堵集水區多階段之流量預測模式，結果顯示網路在加入雨量預報值為額外之輸入時，不僅能改善流量預測之精確度，且在減少延遲現象的效應上亦可有效的提昇。Wu 等人(2008) 比較不同類神經網路技術的水位預報結果。Islam (2010) 利用類神經網路模式進行水位預報，其預報時間達 10 天，且有高度的準確性；陳昶憲等(2011) 以遺傳規劃法建立烏溪之洪水預報模式，利用自適應網路模糊推論系統對可能發生之誤差加以修正；張嘉玲等(2012) 以倒傳遞類神經網路分析集水區降雨-逕流的相關性，在輸入資料中加入前 1 時刻流量，能提升模式的精確度。前述各位學者其研究成果中顯示出人工智慧方法具有良好的預測效果，類神經網路所建立之模式具有良好之精度。Kuo *et al.* (2014) 以隨機森林法預報未來 1 至 3 小時水位，並發現於 3 小時起有明顯的洪峰誤差及時間延遲現象。Wu 和

Lin (2015)比較不同類神經網路的河川流量預報結果，提出經由強化學習方法結合 SOM 和 SVM 模式有最佳的表現。Chang *et al.* (2018) 建構基於 ANN 模型下之混合體 SOM-RNARX 模式進行二維洪水預報，結果發現與二維淹水模式(InfoWorks ICM)模擬的淹水分佈相近。Zhou *et al.* (2019)嘗試建構 ANFIS-SL (Adaptive neuro fuzzy inference system)、R-ANFIS-SL (Recurrent ANFIS)與 R-ANFIS-GL (Recurrent ANFIS embedded with genetic algorithm and least square estimator)進行洪水位預報，結果發現 R-ANFIS-GL (Recurrent ANFIS embedded with genetic algorithm and least square estimator)預報洪水位優於其它二者模型。

近年來機器學習即服務 (MLaaS) 開始蓬勃發展，機器學習即服務是自動化和半自動化雲平台的總括性定義，包含數據預處理、模型訓練和模型評估以及預測等基礎設施議題。預測結果可以通過 REST APIs 與內部 IT 基礎架構連接。目前市場是領先的雲端 MLaaS 服務有 Google Cloud AI、Microsoft Azure Machine Learning (Azure ML) (<https://studio.azureml.net/>) 和 Amazon Machine Learning，提供少量或沒有專業知識背景下進行快速模型訓練和應用。Azure ML studio 擁有最全面的技術服務，Google ML Engine 和 Amazon SageMakery 在深度神經網絡發展較佳。本研究之目標，在桃園大圳 10 支線與 12 支線幹線取入口，使用物聯網資通訊技術，收集水位資料後，傳送至水利署水資源物聯網，並使用水

資源物聯網與 Azure ML 的運算資源(部分為桃園水利會既有系統)，幹線水位預測模型，分別預測未來 1 至 3 小時水位，輔助產出調控貯水池策略，防災應變，貯水池管理建議等結果，並建置相關網頁，讓管理人員可以在行動裝置，桌上型電腦，以及本會、工作站之展示系統上，觀看相關產出之結果。

二、研究區域之概述

桃園地區位於台灣西北部，其地理位置如圖 1 所示。境內地形以台地為主，全年平均氣溫約 20 度，雨量於五至六月為最多，10 月至 12 月為最少，年平均雨量約 140 公釐，高度落差約 500 公尺。境內主要的河川有大漢溪、南崁溪、老街溪及社子溪等四條，但除了大漢溪外，其餘均為流路短水量少的小河，大多呈放射狀流路，流入台灣海峽，此外台地表面紅土極為緊密，地面雨水滲透不易，地下水較為貧乏，因此桃園地區時常缺乏灌溉用水。桃園大圳創設於民國五年，灌溉水路包含導水路段(隧道)長 18 公里下接桃園大圳幹線段長 25 公里，經過桃園市各重要城區，支分線穿越在各城區之城鄉社區。光復圳銜接桃園大圳尾水及自社水溪等河水取入、幹線長 15 公里，支線長 49 公里，給水段全長 148 公里。




圖 1 桃園大圳集水區

本研究選定桃園大圳 10 支線和 12 支線作為建置水位預報模式，兩支線分別屬於觀音工作站、新屋工作站轄區，沿線分別有貯水池 36 口和 27 口，貯水池灌溉總面積達 2,913 公頃和 2,292 公頃。歷史雨量和水位資料為建置水位預報模式之基本資料，本研究根據集水區內的八個氣象局屬雨量測站，徐昇多邊形法 (Thiessen's polygon method) 計算平均雨量，並蒐集 4 號退水門、8 支線、10 支線和 12 之線幹線取入口水位，做為預報模式的候選輸入因子，蒐集的雨量和水位的時間間隔為 10 分鐘，雨量站紀錄年份和徐昇權重如表 1 所示。本研究蒐集之降雨量、4 號退水門、8 支線、10 支線與 12 支線幹線時間尺度均為 10 分鐘，故以 10 分鐘時間間隔進行水位預報。

表 1 雨量站紀錄年份與徐昇權重

站號	站名	記錄年份	徐昇權重
C0C650	平鎮	2007/12/1	0.232
C0C490	八德	2011/12/1	0.277
C0C590	觀音	2007/10/1	0.059
C0C660	楊梅	2013/08/1	0.131
C0C630	大溪	2007/12/1	0.094
C0C480	桃園	2008/01/1	0.022
C0C670	龍潭	2014/04/1	0.185

三、研究方法與架構

3.1 Microsoft Azure Machine Learning

Azure ML 是由微軟開發的一項雲端服務，提供了一個可視化界面用來開發及部署機器學習服務模型。Azure ML 在建置、定型、部署及管理模型期間，均可進行追蹤以及管理，在 MLaaS 市場上擁有功能最多的工具集，涵蓋了大多數與機器學習相關的訓練，並且提供了一套可靠的 API 供人取用。此外，Azure ML 服務完全支援開放原始碼技術，如 R 語言、C++ 和 Python 等程式語言，因此可使用數以萬計的開放原始碼套件，與像是 TensorFlow 與 Scikit-learn 等機器學習服務元件，可輕鬆地以互動方式瀏覽資料及進行資料轉換、參數率定，然後再開發及測試模型，可協助輕鬆且具效率地正確建立模型。

3.2 系統架構

灌溉系統架構圖如圖 2 所示，現場水位監測資料，透過物聯網通訊 4G/NB-IoT 傳送至水利署水資源物聯網進行即時、歷史資料儲存，接著桃園水利會虛擬演算




圖 2 系統架構圖

伺服器透過 Web Service 自水利署水資源物聯網平台 (<https://iot.wra.gov.tw/>、<https://iotmanage.wra.gov.tw/#/login>) 取得即時、歷史監測資料，傳送至 Azure ML 進行運算，將 Azure ML 預測結果，傳回水利署水資源物聯網平台，最後桃園水利會虛擬網頁伺服器透過 Web Service 取得水文預測與演算結果，並產出展示網頁 (<https://ai.tia.org.tw/PondSystem/>) 和 APP，給後端管理人員使用，管理人員可透過水文動態監視 Web App，使用行動裝置監控現況或從水文監測與動態分析管理平台，取得調控貯水池策略、防災應變及貯水池管理建議等結果並可設定相關策略調整參數。

本研究透過 Azure ML 雲端運算平台服務的 Machine Learning Studio 建構預測水位模型，Azure ML 針對分類、回歸與聚類分析提供不同方法，針對回歸方法，如類神經網路(Neural network regression, NNR)、貝葉斯線性回歸(Bayesian linear regression)、決策森林(Decision forest)和線性回歸(Linear regression)等方法可使用，本次使用 NNR 建構水位預測模型。本研究建置幹線水位預測模型的流程圖，如圖 3 所示。建構模型的流程分為模型建置和模型預報，模型建置是以歷史觀測雨量和水位經過資料前處理、獨立降雨事件識別、因子篩選和參數率定，建置出一個準確且穩定的預報模型。建置完模型後，即可模型預報。模型預報中，接收到即時觀測雨量後，判斷是否達到啟動標準，達到啟動標準，即可與即時監測水位一起傳入以建置好的 Web 化 NNR 模型，預報未來 $t+6$ 至 $t+18$ 的水位。

NNR 以一層的輸入層(Input layer)、一層隱藏層(Hidden layer)以及一層的輸出層(Output layer)共三層的網路結構建置預測模型，其中 NNR 須設定的參數有神經元數(Number of hidden nodes)、學習速率(Learning rate)、疊代次數(Number of iterations)、初始權重(Initial learning weights)、慣性項(Momentum)與正規化(Normalizer)，本次 10 支線水位與 12 支線水位各參數

幹線水位預測模型




圖 3 幹線水位預測模型流程圖




圖 4 率定第 12 支線學習速率之 MAE 與 RMSE

表 2 NNR 參數設定表

參數	第 10 支線模型	第 12 支線模型
神經元數	5	4
隱藏層數	1	1
學習速率	0.000045	0.000066
疊代次數	467	800
初始權重	0.07	1.7
慣性項	0	0.25
正規化	離差標準化	高斯標準化

設定，是以網格搜尋法(Grid search method)搜尋最佳參數，搜尋的範圍分別為，神經元數從 1 至 10 顆、學習速率介於 0.1 至 0.000001、疊代次數介於 100 至 1000、初始權重介於 0.01 至 2、慣性項介於 0 至 1、正規化從離差標準化、高斯標準化和最大最小標準化中選擇，率定後的最佳化參數如下表 2 所示。在參數率定過程中，其 12 支線學習速率敏感度最大，即微調，如圖 4

所示，可看到隨著學習速率越小，則評鑑指標 RMSE 與 MAE 更好，在學習速率為 0.000066 有最好結果。10 支線參數訓練過程為使用自動化參數率定，結果 $t+6$ 至 $t+18$ 自動化率定結果參數相同，12 支線使用手動方式率定 $t+6$ 參數，並將 $t+12$ 與 $t+18$ 設定相同。

3.3 評鑑指標

將模型預測之結果與實際觀測值比對，利用均方根誤差 (Root mean square error, RMSE)、平均絕對誤差 (Mean absolute error, MAE)、相關係數 (Coefficient of correlation, CC)和效率係數 (Coefficient of efficiency, CE)作為評斷之標準。其分別定義如下：

1. RMSE 檢測模式對於極端值誤差之大小。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \dots\dots\dots (1)$$

2. MAE 檢測模式對於整體平均誤差之大小。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots\dots\dots (2)$$

3. CC 檢測模式預報值與觀測資料之相關性大小。

$$CC = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \dots\dots\dots (3)$$

4. CE 檢測模式預報值與觀測資料之平均值之相關性大小。

$$CE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \dots\dots\dots (4)$$

其中， n 為資料數； y_i 為 t 時刻之觀測值； $\bar{y}$ 為觀測值之平均值； $\hat{y}_i$ 為 t 時刻之預報值； $\bar{\hat{y}}$ 為預報值之平均值。RMSE 與 MAE 是計算誤差的指標，其值越小表示模型預報結果越準確；CC 和 CE 是評斷模式預報值與觀測的趨勢是否一致，數值越大，代表分類效果越佳。

四、模式應用與討論

4.1 模式建置與資料處理

本計劃選取觀測雨量大於 0，且觀測水位資料完整的場次資料當作模式訓練測試，爾後使用最小降雨間隔時間(Minimum inter-event time, MIET)篩選出獨立場次。MIET 為 24 小時，則一場獨立降雨事件之開始降雨與結束降雨之前後 24 小時均無任何降雨發生，則決定此一場獨立降雨事件發生。其最小降雨間隔時間根據柏松分布法決定，當降雨事件間隔時間之平均值與標準偏差的比值等於 1 時，即可決定最小降雨間隔時間，根據最小降雨間隔時間將平均雨量切割出獨立降雨事件，供給預報模型訓練與測試使用。

降雨資料在不同 MIET 的統計值如表 3 所示，在表中可看到隨著 MIET 數值越大，變異係數隨之增加，在 MIET 為 129 (即 21.5 小時)其變異係數為 1.000，即以 MIET 為 129 切割的獨立降雨事件最符合柏松分布。

圖 5 為 MIET 等於 21.5 小時，各切割降雨事件之降雨延時、累積雨量、最大降雨與前場間隔，總共切割 329 場雨場事件。各場降雨延時平均為 40 小時，其中 2016 年莫蘭蒂與馬勒卡颱風是延時最長的降雨事件，從 2016/9/8 06:20:00pm 至 2016/9/20 11:00:00pm 共有

表 3 降雨資料在不同 MIET 的統計值

MIET	場次數	平均值	標準偏差	變異係數
127	332	485.66	487.75	1.004
128	330	487.83	488.43	1.001
129	329	488.92	488.76	1.000
130	323	495.61	490.79	0.990
131	319	500.19	492.14	0.984

[註]MIET 單位為 10 分鐘；平均值與標準偏差單位為公釐




圖 5 各獨立降雨事件的(a) 延時(平均值為 40.0 小時)、(b) 累積雨量(平均值為 26.4mm)、(c) 最大降雨(平均值為 2.38mm)和(d) 與前場間隔(平均值為 81.5 小時)

292.5 小時。全部 329 場之平均累積雨量為 26.4mm，其中最大值累積雨量事件為 2017/6/14 10:30:00am 至 2017/6/18 06:30:00pm 的梅雨降雨事件，累積雨量最大值達 242.2mm。而所有場次之平均最大降雨為 2014 鳳凰颱風事件，該颱風南北縱走由台灣南部穿越中央山脈直達台灣北部出海口，造成強烈降雨，其平均最大降雨達到 2.38mm，而各場與前場時間差平均值為 81.5 小時，約 3.4 天。

4.2 因子篩選

本研究以皮爾森積差相關係數分析法篩選與幹線水位相關高的因子，分析結果如表 4 和 5 所示。表 4 顯示 10 支線未來 60 分鐘預測值($S10_{t+6}$)與平均雨量滯延時間 210 到 260 分鐘的相關性最高，表示此集水區的降雨經地表慢地流、地下水流和幹線明渠流等水文歷程，約 270 分鐘(210+60)流至第 10 支線取入口。而根據自相關係數第 10 支線的水位在 100 分鐘(40+60)內的相關性最大，可提供有效預測資訊。同理表 5 顯示 12 支線未來 60 分鐘預測值($S12_{t+6}$)相關性最大的平均雨量、第 10 支線水位和第 12 支線水位分別為 R_{t-26} 、 R_{t-25} 、 R_{t-24} 、 R_{t-23} 、 $S10_{t-3}$ 到 $S10_t$ 與 $S12_{t-4}$ 到 $S12_t$ ，10 支線與 12 支線相關因子輸入整理如表 6 所示。

4.3 模式分析結果

本研究採用即時降雨資料分別搭配幹線即時監測水位，以 NNR 建置幹線水位預報模型。研究中以利用嚴謹之評鑑指標以評估模型表現，並分析模型產出預

表 4 第 10 支線 t+6 水位與各因子相關係數

R_{t-i}	CC	$S10_{t-j}$	CC
$i = 18$	0.11	$j = 0$	0.87
$i = 19$	0.12	$j = 1$	0.85
$i = 20$	0.12	$j = 2$	0.82
$i = 21$	0.12	$j = 3$	0.80
$i = 22$	0.13	$j = 4$	0.77
$i = 23$	0.12	$j = 5$	0.75
$i = 24$	0.13	$j = 6$	0.72
$i = 25$	0.13	$j = 7$	0.69
$i = 26$	0.13	$j = 8$	0.67

[註] $t+6$ 表示未來 60 分鐘水位； R_{t-i} 表示 $i \times 10$ 分鐘前雨量。

表 5 第 12 支線 t+6 水位與各因子相關係數

R_{t-i}	CC	$S10_{t-j}$	CC	$S12_{t-k}$	CC
$i = 20$	0.08	$j = 0$	0.58	$k = 0$	0.74
$i = 21$	0.09	$j = 1$	0.56	$k = 1$	0.71
$i = 22$	0.10	$j = 2$	0.55	$k = 2$	0.69
$i = 23$	0.10	$j = 3$	0.54	$k = 3$	0.67
$i = 24$	0.09	$j = 4$	0.52	$k = 4$	0.65
$i = 25$	0.10	$j = 5$	0.51	$k = 5$	0.63
$i = 26$	0.10	$j = 6$	0.49	$k = 6$	0.61
$i = 27$	0.10	$j = 7$	0.47	$k = 7$	0.59
$i = 28$	0.10	$j = 8$	0.45	$k = 8$	0.56

表 6 各支線預測水位輸入項

預測時間 (10 分鐘)	輸入因子
第 10 支線	
$t+6$	$R(t-24)$, $R(t-23)$, $R(t-22)$, $R(t-21)$, $S10(t-4)$, $S10(t-3)$, $S10(t-2)$, $S10(t-1)$, $S10(t)$
$t+12$	$R(t-18)$, $R(t-17)$, $R(t-16)$, $R(t-15)$, $S10(t-4)$, $S10(t-3)$, $S10(t-2)$, $S10(t-1)$, $S10(t)$
$t+18$	$R(t-12)$, $R(t-11)$, $R(t-10)$, $R(t-9)$, $S10(t-4)$, $S10(t-3)$, $S10(t-2)$, $S10(t-1)$, $S10(t)$
第 12 支線	
$t+6$	$R(t-26)$, $R(t-25)$, $R(t-24)$, $R(t-23)$, $S10(t-3)$, $S10(t-2)$, $S10(t-1)$, $S10(t)$, $S12(t-4)$, $S12(t-3)$, $S12(t-2)$, $S12(t-1)$, $S12(t)$
$t+12$	$R(t-20)$, $R(t-19)$, $R(t-18)$, $R(t-17)$, $S10(t-3)$, $S10(t-2)$, $S10(t-1)$, $S10(t)$, $S12(t-4)$, $S12(t-3)$, $S12(t-2)$, $S12(t-1)$, $S12(t)$
$t+18$	$R(t-14)$, $R(t-13)$, $R(t-12)$, $R(t-11)$, $S10(t-3)$, $S10(t-2)$, $S10(t-1)$, $S10(t)$, $S12(t-4)$, $S12(t-3)$, $S12(t-2)$, $S12(t-1)$, $S12(t)$

表 7 第 10 支線與 12 支線 $t+6$ 、 $t+12$ 和 $t+18$ 模型建構之評鑑指標

模型	訓練				測試			
	RMSE (m)	MAE (m)	CE	CC	RMSE (m)	MAE (m)	CE	CC
第 10 支線								
$t+6$	0.07	0.03	0.96	0.98	0.08	0.03	0.96	0.98
$t+12$	0.11	0.05	0.92	0.96	0.11	0.06	0.92	0.96
$t+18$	0.13	0.07	0.86	0.93	0.14	0.08	0.88	0.94
第 12 支線								
$t+6$	0.14	0.07	0.89	0.93	0.14	0.08	0.90	0.95
$t+12$	0.18	0.10	0.84	0.89	0.18	0.11	0.86	0.93
$t+18$	0.22	0.14	0.75	0.84	0.21	0.14	0.80	0.90




圖 6 第 10 支線 $t+6$ 水位測試結果

報水位與相對應的實際觀測水位。

4.3.1 10 支線訓練與測試結果

本研究建構 10 支線水位預測評鑑指標計算如表 7 所示，在訓練階段 $t+6$ 模型其 RMSE、MAE、CE 與 CC 值分別為 0.069m、0.034m、0.963 與 0.982，CC 與 CE 均大於 0.9 以上，表示 NNR 預測水位模型訓練的結果很好，而測試階段 $t+6$ 預報時間預報結果的 CC 值也大於 0.9 以上，代表 NNR 預測水位模型有很好的預測水位能力，可實際應用於未來的場次中。而 $t+6$ 訓練與測試 RMSE 與 MAE 其值非常相近且各統計值計算結果小，模型預測與觀測值之間的誤差值非常小。 $t+6$ 與 $t+12$ 訓練與測試的 CE 值均大於 0.9、 $t+18$ 大於 0.8，且 CC 值 $t+6$ 到 $t+12$ 訓練與測試結果值均大於 0.9，顯示 NNR 模型能準確預測水位。整體而言 $t+6$ 、 $t+12$ 和 $t+18$ 模型之測試階段 RMSE 誤差範圍為 0.079 至 0.140m、MAE 為 0.034 至 0.077m、CE 為 0.962 至 0.877、

CC 為 0.981 至 0.936，證明 NNR 模型具有穩定且準確的預測表現。

圖 6 到圖 9 展示 $t+6$ 、 $t+12$ 和 $t+18$ 水位歷線，隨著預報時間增加，時間延遲(time-lag)越明顯，即預報與觀測水位的峰值之間的時間差距越明顯，且峰值低估逐漸增加，在水位較小和波動不明顯處，預報與觀測水位非常接近。為了凸顯單一事件預報能力，本研究以 2018/1/6 至 2018/1/10 間的水位歷線為例子(如圖 9)，探討時間延遲和峰值低估，其 $t+6$ 的預報與觀測水位間有 60 分鐘的時間延遲，隨著預測時間加長，其時間延遲增加。而 $t+6$ 預測與觀測峰值誤差約 0.07m，其誤差非常小，顯示模型具有良好的預測表現。

4.3.2 12 支線訓練與測試結果

12 支線模型 $t+6$ 、 $t+12$ 、 $t+18$ 水位預測評鑑指標表現如表 7 所示，訓練階段 $t+6$ 模型 RMSE、MAE、CE 與 CC 值分別為 0.141m、0.074m、0.894 與 0.934，其




圖 7 第 10 支線 $t+12$ 水位測試結果




圖 8 第 10 支線 $t+18$ 水位測試結果




圖 9 第 10 支線模型測試結果(2018/1/6 13:10 到 2018/1/10 9:50)

CC 值大於 0.9 以上，與 10 支線 $t+6$ 模型評鑑指標相當，代表 NNR 預測水位模型具有預測水位的能力，測試階段 $t+6$ 模型其 CC 值也大於 0.90 以上。對於 $t+6$ 訓

練與測試之評鑑指標 RMSE 與 MAE 其值計算結果小，模型預測與觀測值之間的誤差值小。CE 在 $t+6$ 訓練階段為 0.894，測試階段為 0.901； $t+12$ 訓練階段為 0.836，




圖 10 第 12 支線 $t+6$ 水位測試結果




圖 11 第 12 支線 $t+12$ 水位測試結果




圖 12 第 12 支線 $t+18$ 水位測試結果

測試階段為 0.857； $t+18$ 訓練階段為 0.750，測試階段為 0.800，隨著預測的時間越長，CE 值隨著下降，整體結果 NNR 預測水位模型能很好預測水位整體趨勢。總體觀察 $t+6$ 、 $t+12$ 、 $t+18$ 模型測試階段 RMSE 誤差範圍為 0.144m 到 0.206m、MAE 為 0.077m 到 0.143m、CE

為 0.90 到 0.80 和 CC 為 0.95 到 0.90。

圖 10 到圖 13 為 $t+6$ 、 $t+12$ 和 $t+18$ 訓練與測試結果。12 支線模型較於 10 支線模型訓練結果較差，主要原因為 12 支線的事件觀測水位震盪幅度大，常有突增或突減轉折處現象，造成模型預測不準確，觀察圖 13 在




圖 13 第 12 支線模型測試結果(2018/1/4 21:00 到 2018/1/10 9:50)

時間點 467 時，12 支線水位為 1.98m，當下預測輸入因子 R_{t-26} 為 0、 R_{t-25} 為 0.0283、 R_{t-24} 為 0、 R_{t-23} 為 0，此時輸入平均雨量幾乎為 0，無任何資訊，而輸入因子 $S10$ ，其 $S10_{t-3}$ 為 1.10m、 $S10_{t-2}$ 為 1.08m、 $S10_{t-1}$ 為 1.065m、 $S10_t$ 為 1.05m，且 $S12$ 輸入因子，其 $S12_{t-4}$ 為 1.22m、 $S12_{t-3}$ 為 1.27m、 $S12_{t-2}$ 為 1.19m、 $S12_{t-1}$ 為 1.18m 和 $S12_t$ 為 1.17m， $S10$ 與 $S12$ 前置項水位因子均為下降趨勢，但是當下預測 $S12_{t+6}$ 為 1.98m，為突增水位，由於前置項因子為下降趨勢，故預測水位結果較難反映突增或突減轉折處水位預測。若前置項因子可反映預測水位趨勢，則預測會更精準，如圖 13 在第 71 時間點其前置項水位表現上升趨勢，當下觀測峰值為 1.71m，預測峰值為 1.62m，峰值誤差為 0.08m，觀測與預測值非常接近。整體結果 12 支線水位預測模型能表現實際水位趨勢。

五、結論

本研究以 Azure ML 分別在桃園大圳 10 支線與 12 支線建構幹線水位預測模型，分別預測未來 1 至 3 小時水位，以期建立水情預測與輔助決策管理系統，得到以下結論與建議：

1. 以皮爾森積差相關係數進行因子篩選，結果顯示第 10 支線平均雨量 R_{t-21} 到 R_{t-26} 與觀測水位 $S10_{t+6}$ 相關係數最大，相關係數約 0.12 到 0.13，表示若有降雨發生，雨量經過 270 分鐘至 320 分鐘的時間，匯流至第 10 支線取入口；而 12 支線平均雨量 R_{t-23} 到 R_{t-26} 與觀測水位 $S12_{t+6}$ 相關係數最大，該結果顯示約需要 290 分鐘到 320 分鐘的時間，

雨量匯集到第 12 支線取入口，又 12 支線位於 10 支線下游段，故所需時間較於 10 支線時間長，故此因子篩選合理。

2. 以 NNR 建構 10 支線水位預測模型，在 $t+6$ 、 $t+12$ 和 $t+18$ 的預測中，RMSE 誤差不超過 0.14m、MAE 誤差均小於 0.077m、CE 均大於 0.88、CC 均大於 0.94，表示 NNR 預測水位模型能精準預測水位，對於模型預測水位趨勢 CC 與 CE 值非常高，表示模型之預測水位結果能精準符合與觀測水位之間的趨勢，且峰值誤差非常小。
3. 12 支線水位預測模型，其評鑑指標測試結果顯示 $t+6$ 到 $t+18$ ，RMSE 與 MAE 均低於 0.21m 與 0.14m，CC 與 CE 值均大於 0.80 與 0.90，表示預測水位模型能精準預測水位以及符合與觀測水位之間的趨勢，在測試階段的案例中，預測和觀測水位的峰值誤差非常接近，表示預測水位模型具有洪峰預測能力。
4. Azure ML 平台建構 10 支線與 12 支線 NNR 預測水位模型，經過評鑑指標以及預測水位與觀測水位歷線結果，顯示以 NNR 建構 $t+6$ 、 $t+12$ 、 $t+18$ 時刻之 10 支線與 12 支線水位預測模型，具有預測水位的能力。

參考文獻

1. 江衍銘、張斐章，「類神經網路建構定量降水及流量預報模式」，農業工程研討會論文集，pp. 191-204，2006。

2. 張嘉玲、李孟遠、王傳益，「應用倒傳遞類神經網路於集水區流量預測-以台北水源特定區為例」，臺灣水利，第 60 卷第 2 期，pp. 98–104，2012。
3. 陳昶憲、鍾佑達、方唯鈞、葉昭憲，「以遺傳規劃建構智慧型洪水預報機制」，中國土木水利工程學刊，第 23 卷第 3 期，pp. 317–327，2011。
4. Chang, F. J. and Y. C. Chen, “Estuary Water-Stage Forecasting by Using Radial Basis Function Neural Network,” *J. Hydrol.*, Vol. 270, pp. 158–166, 2003.
5. Chang, L. C., M. Z. M. Amin, S. N. Yang, and F. J. Chang, “Building ANN-Based Regional Multi-Step-Ahead Flood Inundation Forecast Models,” *Water*, 10(9), 1283, 2018.
6. Hsu, K.L., H.V. Gupta, X. Gao, Sorooshian, S. and Imam, B., “Self-organizing linear output map (SOLO): An artificial neural network suitable for hydrologic modeling and analysis,” *Water Resour. Res.*, Vol. 38, pp. 10–26, 2002.
7. Islam, A. S., “Improving flood forecasting in Bangladesh using an artificial neural network,” *J. Hydroinformatics*, Vol. 12(3), pp. 351–364, 2010.
8. Liong, S.Y. and C. Sivapragasam, “Flood stage forecasting with support vector machines,” *J. Am. Water Resour. Assoc.*, Vol. 38, pp. 173–186, 2002.
9. Sivapragasam, C. and S.Y. Liong, “Flow Region Specific Model for Flow Forecasting,” In: *Hydroinformatics 2002: Proceedings of the 5th International Conference on Hydroinformatics*, IWA Publishing, London, U.K., 653–658, 2002.
10. Toth, E., A. Brath, and A. Montanari, “Comparison of short-term rainfall prediction models for real-time flood forecasting,” *J. Hydrol.*, Vol. 239, pp. 132–147, 2000.
11. Wu M. C. and G.F. Lin, “An hourly streamflow forecasting model coupled with an enforced learning strategy,” *Water*, Vol. 7, pp. 5876–5895, 2015.
12. Wu, C.L., K.W. Chau, and Y.S. Li, “River stage prediction based on a distributed support vector regression,” *J. Hydrol.*, Vol. 358, pp. 96–111, 2008.
13. Zhou, Y., S. Gui, and F. J., Chang, “Explore an evolutionary recurrent ANFIS for modelling multi-step-ahead flood forecasts,” *J. Hydrol.*, Vol. 570, pp. 343–355, 2019.

收稿日期：民國 107 年 10 月 21 日
修正日期：民國 107 年 12 月 13 日
接受日期：民國 107 年 12 月 21 日