

# 人工智慧於水庫下游即時水位預報之研究

## Water level forecasting of Reservoir downstream by machine learning

莊浥岫<sup>1,\*</sup>

林國峰<sup>2</sup>

張明瑞<sup>3</sup>

曾元福<sup>4</sup>

1. 國立臺灣大學土木工程系水利組碩士生

2. 國立臺灣大學土木工程學系特聘教授

3. 國立臺灣大學土木工程學系博後研究員

4. 國立臺灣大學土木工程學系水利組博士生

\* 通訊作者，Email: [r10521327@ntu.edu.tw](mailto:r10521327@ntu.edu.tw)

### 摘要

台灣地處於副熱帶季風區，每年熱帶氣旋形成的颱風以及強盛西南氣流產生的對流，引發各種複合型災害，且近年來短延時降雨頻率和強度增加，導致水庫及下游河岸預警系統應變時間縮短，歷年研究指出現行的水位預報沒有考慮水庫放水量，因此本研究提出一考慮水庫放水量之水庫下游水位預報模式，提供下游水位預報給防災單位參考。

本研究以台北橋水位作為預報目標，蒐集 2014 年至 2021 年之颱風和暴雨事件資料，如台北橋上游集水區降雨量、石門水庫放水量、石門水庫入流量和翡翠水庫放水量和淡水河口潮位作為模式之備選因子。以多種人工智慧方法如多層感知器、支援向量機、長短期記憶網路，建立水位預報模式，應用時介接氣象局定量降水預報，產出未來 6 小時台北橋水位預報。結果顯示本研究所提出之水位預報模式，可準確預報未來 6 小時水位，後續搭配定量降水預報和警戒水位，可提供未來 6 小時水位預警，以利大台北地區能夠警戒水位前提早疏散，並更有效低操作橫移門和疏散門，以降低損失生命財產的風險。

**關鍵字：**水位預報、定量降水預報、人工智慧、台北橋

## Abstract

Taiwan is located in the subtropical monsoon region, both typhoons and vigorous convection caused by strong southwesterly flow develop seasonal compound disasters. In addition, the response time for early warning systems of the reservoirs and downstream riverbanks has been shortened due to higher frequency and greater intensity of short-duration rainfall events in recent years. Past studies pointed out that the current water level forecast does not consider the outflow discharge of the reservoir. Therefore, this study proposes a downstream water level forecasting model that considers the outflow discharge of the reservoir, and the model is provided to relevant hazard mitigation centers.

This research has selected the water level of the Taipei bridge as target status and collected data of typhoon and storm events from 2014-2021. These data included the precipitation in the watershed of upstream of Taipei bridge, outflow discharge of Shimen reservoir, inflow discharge of Shimen reservoir, outflow discharge of Feitsui reservoir, and tidal of Tamsui river estuary as the alternative factors. Subsequently, building several models based on multiple machine learning, such as RNN, SVM, and LSTM to interface with the constant-quantity rainfall forecast of the Central Weather Bureau, then produce the forecast in the future 6 hours about the water level of Taipei bridge. The proposed water level forecast is proved to improve the accuracy of the forecast in the future 6 hours about the water level of Taipei bridge. Moreover, by coordinating the Quantitative Precipitation Forecast(QPF) and warning water level, the model provides early warning of the future six-hour water level, which is not only beneficial to evacuation and operating traversing dock-gate and evacuation gates efficiently, but also conducive to reducing the risk of losses in life and property.

**Keywords:** water level, reservoir, Quantitative Precipitation Forecast, machine learning, MSF, Taipei bridge

## 一、前言

近年來，全球暖化日益嚴重，溫室效應也隨之加劇，使大眾更加關注氣候變遷的議題，且由於台灣地處於副熱帶季風區，每年熱帶氣旋形成的颱風以及強盛西南氣流產生的對流，經常引發各種複合型災害，氣候變遷也讓災害的影響更加嚴重，在短延時降雨頻率和強度的增加下，往往造成水庫操作上的不確定性，進而使水庫及下游河岸預警系統應變時間縮短，因此準確的下游水位預報，將以利後續搭配定量降水預報和警戒水位，可提供未來水位預警，以利大台北地區能夠警戒水位前提早疏散，並更有效低操作橫移門和疏散門，以降低損失生命財產的風險。

在雨量觀測資料的選擇上，以往多選擇氣象局和水利署雨量站的歷史資料來當作雨量觀測資料，然而考慮到缺乏空間性，無法呈現實際的空間降雨情形，本研究選擇採用劇烈天氣監測系統(Quantitative Precipitation Estimation and Segregation Using Multiple Sensors，簡稱 QPESUMS)，此系統整合雷達、衛星、雨量與閃電等觀測資料，並結合地理資訊，提供劇烈天氣即時監測資訊、定量降水估計以及短時定量降水預報等產品之平台(Zhang et al., 2011)。其中，雷達定量估計降雨是利用回波與降雨率關係進行估計得到水平網格解析度為  $0.0125^\circ$  的網格降雨分布，為更接近地面觀測資料的降雨，使用雨量站即時觀測資料進行降雨量修正，得到經雨量站修正後雷達降雨估計產品。透過此系統的修正後降雨估計資料將能解決雨量資料在空間性不足的因素。

歷年研究指出現行在水庫下游的河川水位預報，皆無考慮水庫放水量，因此在輸入項選擇上，本研究除了考慮台北橋上游集水區降雨量和淡水河口潮位作為模式之備選因子，也加入石門水庫放水量、石門水庫入流量和翡翠水庫放水量，提出一考慮水庫放水量之水庫下游水位預報模式，以提升預報的準確性。水位預測模型除了基於物理機制所建置之物理模式之外，機器學習方法也不斷被提出，在科技進步的支持下，機器學習已在許多領域都有不錯的成果，其中以類神經網路、支持向量機、決策規則演算法為常見的技術，相較於物理機制模式需要大量的參數及複雜的率定過程，且其中複查運算的過程需要使用大量電腦運算資源，使模式會被侷限於小範圍的局部地區，應用於大範圍分析則會因為尺度調整而導致分析成果表現不佳，而資料不易取得也造成模式無法及時更新；而機器學習涉及機率論、統計學、逼近論等多門學科，從中延伸出使電腦可以學習的演算法，由資料分析獲得規律，其概念主要為推斷統計學，並利用訓練後最佳規律對未知資料進行預測或判斷，隨著機器學習方法的成熟其準確性及效率也大幅提升。本研究基於類神經網路理論選擇較適合時間序列

資料的遞迴神經網路(Recursive neural networks, RNN)、長短期記憶網路(LSTM)與支援向量機(Support vector machine, SVM)建置模式及水位預測。

## 二、 研究區域與資料

本研究選用台北橋集水區作為研究區域(如圖 1 所示)，台北橋是位於台灣北部淡水河之上的橋樑，其上游集水區涵蓋整個大台北區域，其中上游可延伸至石門水庫及翡翠水庫。為建立台北橋水位預報模式，需要搜集颱風和暴雨期間台北橋集水區之雨量資料和石門水庫入流量及出流量資料做為模式之輸入項。本研究搜集 2014 年至 2021 年共 8 年之暴雨事件，由於要探討水庫出流量對台北橋水位的影響，考量主要應用目的為在台北橋到達水位警戒值提前防災，且主要影響的是石門水庫，因此搜集的規則有兩個，(1)石門水庫具有放水紀錄的事件，(2)台北橋水位高於 2.0 公尺(三級警戒值為 2.2 公尺)，搜集的場次如表 1 所示。

### (一)、 雨量資料

本研究台北橋集水區內氣象局和水利署雨量站眾多(如圖 1 所示)，然而本研究採用劇烈天氣監測系統(Quantitative Precipitation Estimation and Segregation Using Multiple Sensors, 簡稱 QPESUMS)，此系統由中央氣象局、經濟部水利署、農委會水土保持局及美國劇烈風暴實驗室(National Severe Storm Laboratory)所共同開發建置，整合雷達、衛星、雨量與閃電等觀測資料，並結合地理資訊，提供劇烈天氣即時監測資訊、定量降水估計以及短時定量降水預報等產品之平台(Zhang et al., 2011)。雷達定量估計降雨的方式是利用資料品管處理後之最低仰角回波，透過回波與降雨率關係進行估計得到水平網格解析度為  $0.0125^\circ$  的網格降雨分布，如圖 2 所示，為得到更接近地面觀測資料的降雨，使用雨量站即時觀測資料進行降雨量修正。方法是利用雨量站與其上雷達估計降雨網格點上差值，經過客觀分析，將各網格點上的估計差值加上原本的雷達降雨估計量，得到經雨量站修正後雷達降雨估計產品。由於石門水庫與翡翠水庫之雨量並不直接影響台北橋水位，因此本研究將兩水庫內之雨量分別提出為兩項輸入項，而其他區域之雨量取平均雨量作為一輸入項。

### (二)、 潮位資料

台北橋為感潮河段水位起伏主要受到潮汐影響，因此本研究搜集 2014 年至 2021 年淡水潮位站(1140H029)潮位資料作為模式的輸入項，以精進模式表現。

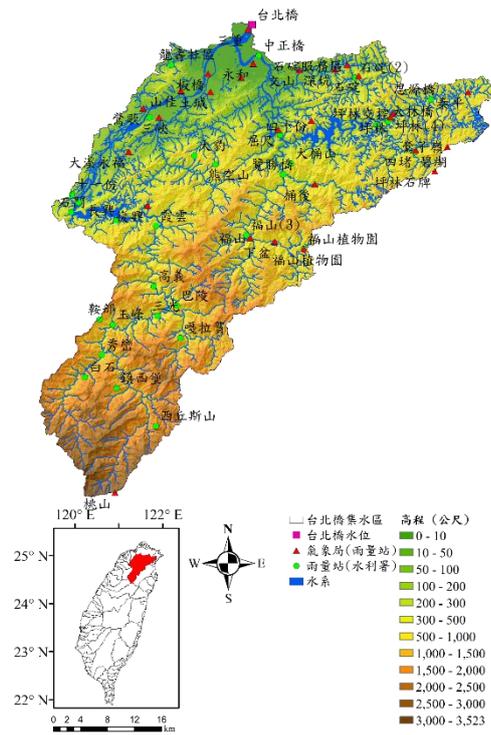


圖 1 石門水庫集水區雨量站、氣象站和水位站

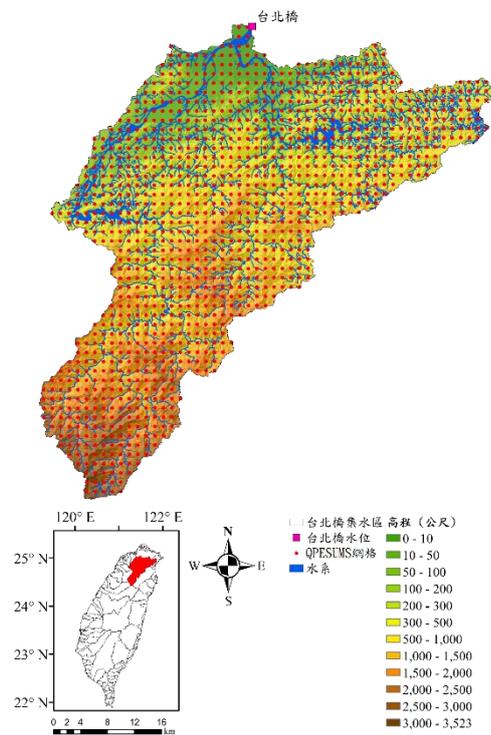


圖 2 石門水庫集水區 QPESUMS 網格

表 1 搜集之颱風暴雨場次資訊

場次	日期	集水區最大平均降雨(mm/h)	石門最大出流量(cms)	翡翠最大出流量(cms)	最大潮位(cm)	台北橋最大水位(m)	資料比數	備註
1	2014/7/22	22.0	882.3	80.2	168.1	1.8	138	麥德姆颱風
2	2014/8/1	0.1	246.2	75.7	163.5	1.69	50	
3	2014/8/9	0.0	0.0	77.0	211.4	2.11	30	
4	2014/8/12	6.0	0.0	77.5	213.5	2.14	30	
5	2014/9/21	0.2	32.0	82.1	170.5	1.71	30	鳳凰颱風
6	2014/10/8	0.0	0.0	79.8	215.5	2.11	30	
7	2014/10/11	1.8	0.0	78.0	229.7	2.31	30	
8	2015/7/10	0.0	32.0	78.2	168.2	2.1	28	昌鴻颱風
9	2015/7/12	1.0	35.5	77.6	143.9	1.66	31	
10	2015/7/19	0.8	247.7	76.6	154.3	1.81	35	
11	2015/8/6	20.8	5012.9	316.0	159	5.17	157	蘇迪勒颱風
12	2015/8/19	10.5	376.7	104.1	139.7	1.56	40	天鵝颱風
13	2015/8/27	20.9	308.1	122.6	183.4	2.04	49	
14	2015/9/2	1.1	274.0	76.1	163.3	1.93	43	
15	2015/9/6	22.4	309.1	78.3	132.9	1.46	56	
16	2015/9/27	12.2	3027.4	556.3	197.1	3.78	109	杜鵑颱風
17	2015/10/5	0.5	306.6	74.4	112.3	1.21	30	
18	2015/10/8	16.7	377.9	74.6	122.1	1.35	42	
19	2016/3/1	0.0	48.6	78.0	75.6	0.86	33	
20	2016/7/6	56.3	302.8	123.1	168.9	1.84	54	尼伯特颱風
21	2016/9/13	22.6	48.6	78.1	144.2	1.58	32	莫蘭蒂颱風
22	2016/9/14	8.6	273.8	78.0	192.3	2.13	93	莫蘭蒂颱風
23	2016/9/17	20.8	991.8	79.3	217.8	2.63	63	馬勒卡颱風
24	2016/9/19	0.2	0.0	78.1	192.4	2.18	30	馬勒卡颱風
25	2016/9/25	16.1	3985.4	794.2	182.7	3.35	114	梅姬颱風
26	2016/10/11	1.7	215.9	556.3	134.3	1.5	29	
27	2016/10/14	4.8	250.5	310.9	171.5	2.04	44	
28	2016/11/14	0.0	0.0	76.5	198.2	2.14	30	
29	2017/6/2	2.3	1410.8	79.7	141.5	1.58	75	
30	2017/6/11	1.9	337.4	125.4	162.3	1.82	226	
31	2017/7/19	0.0	0.0	78.2	136.4	3.62	30	
32	2017/7/28	15.2	575.6	79.6	157.8	1.71	83	尼莎颱風
33	2017/9/13	0.4	51.1	81.4	156.2	1.74	32	泰利颱風

表 1 搜集之颱風暴雨場次資訊(續)

場次	日期	集水區最大平均降雨(mm/h)	石門最大出流量(cms)	翡翠最大出流量(cms)	最大潮位(cm)	台北橋最大水位(m)	資料比數	備註
34	2017/10/13	30.7	269.9	316.1	149.4	1.63	58	
35	2017/10/21	0.1	0.0	77.4	183.8	2.11	30	
36	2018/1/8	0.4	278.1	77.0	149.7	1.62	42	
37	2018/8/12	2.2	0.0	81.3	214	2.15	30	
38	2018/9/7	2.0	259.0	82.9	185.5	1.96	29	
39	2018/9/28	2.0	287.4	81.7	183.9	2.02	54	
40	2019/5/19	21.6	374.9	77.7	178.2	2.02	41	
41	2019/6/10	13.8	376.2	78.0	157.3	1.88	117	
42	2019/7/17	32.2	61.2	79.5	170.7	1.82	45	丹娜絲颱風
43	2019/8/7	2.8	983.3	81.0	165.3	1.81	111	利奇馬颱風
44	2019/8/23	22.1	58.1	78.2	115.2	1.16	42	白鹿颱風
45	2019/9/29	9.3	1039.3	315.7	204.1	2.6	108	米塔颱風
46	2020/8/3	5.7	51.1	81.4	153.8	1.62	31	哈格比颱風
47	2020/8/10	8.4	51.1	81.8	102.1	1.02	33	米克拉颱風
48	2020/8/22	1.8	51.1	84.2	160.3	1.52	28	巴威颱風
49	2021/5/30	0.3	56.3	81.4	144.6	1.75	78	

### 三、 研究方法

#### (一) 支援向量機(SVM)

在機器學習(machine learning)演算法中，支援向量機(Support vector machine, SVM)是在分類與迴歸分析中分析資料的監督式學習模型。在 1990 年代早期 Vapnik 發展出 SVM，用來解決統計分類的問題(Vapnik, 1995; Cristianini and Shaw-Taylor, 2000)，並且在 1995 年將其應用範圍擴展到迴歸分析的問題上。

SVM 主要有兩個特點：(1) 傳統類神經使用經驗風險最小化(Empirical risk minimization)，而 SVM 使用結構化風險最小誤差法(Structural risk minimization)，能夠有效降低目標誤差函數，並且將網路結構複雜度列入考慮，使模式能達到一定的準確度，也不會造成架構太大而增加運算時間的問題；(2) 為了避免傳統方

法求解時產生區域最佳解的缺失，模式的結構和權重被轉換成一個二次規劃問題(Quadratic programming)，採用標準演算法快速求解，得到全域唯一最佳解。SVM 中的輸入向量透過核函數映射至高維度的特徵空間，適合的核函數分別為：線性(Linear, LN)、多項式(Polynomial, PL)、輻狀基底函數(Radial basis function, RBF)及邏輯函數(Sigmoid, SIG)。SVM 需要率定的參數有四種核函數、Gamma、多項式度數(Degree)、誤差容許(Epsilon)及懲罰係數(Cost)。

## (二) 遞迴神經網路(RNN)

遞迴神經網路(Recursive neural networks, RNN)為機器學習的一個分支，具有多層隱藏層的神經網路，其隱藏層層數基本上超過三層，主要將資料透過多層的線性與非線性轉換自動抽取其代表資料特性的特徵。其早在 1960 及 1970 年，就有資訊科學家提出多層類神經網路，受限於當時電腦的計算能力，無進一步的成效，近幾年因科技進步，深度學習則再次回歸幕前。

RNN 最初雛形為 Jeffrey L. Elman 在 1990 年提出的，為 ANN 加入了遞迴項，將隱藏層或輸出層神經元的輸出值回饋，做為下一筆輸入項的訊息，將過去的訊息透過遞迴項記憶在網路中，以對具有前後時間訊息能被學習。因此 RNN 架構適合用在輸入資料間是有相關性或時間序列性質的。深度神經網路內的網路層，主要為輸入、隱藏和輸出層，其層與層間相互連接，為每一層的任一網路神經元皆與下一層的任一神經元互相連結。在深度學習訓練中，通常使用隨機梯度下降法(Stochastic gradient descent, SGD)，找出網路架構中最好的權重組合，讓學習目標指標越小越好的最佳化過程。目前常見的深度學習架構為應用在影像辨識上的 CNN 和與時間序列有關的 RNN。而本文使用的為 RNN。

## (三) 長短期記憶網路架構(LSTM)

長短期記憶網路(Long short term memory network, LSTM)是在 1997 年 Hochreiter 等人發表，其為解決傳統 RNN 的問題，適合處理時間序列資料，即使為中間時序間隔較長，也能在辨識上有良好的效果。

LSTM 與傳統 RNN 的不同在於隱藏層的鏈結構內構造，LSTM 將隱藏層中的神經元改成由一組遞迴連接的子網路組成記憶區塊，每一個區塊包含一或多個自我連接的神經元及 3 閘門(Gate)，分別為輸入、輸出和遺忘閘門，其輸入閘門為對這一節點的輸入值進行選擇性記憶；輸出閘門則為決定訊息是否會被當成這一節點的輸出；遺忘閘門則是對上一節點的輸入值進行選擇性忘記。利用閘門函數控制閘門開關，來判斷是否記憶或非記憶資料；將輸入閘門保持關閉，神經元的值則不會被新的輸入資料覆蓋，而透過打開輸出閘門則可以將保存的記憶資料輸出到時間步驟較久之後。

$$\text{Input node } g^{(t)} = \tanh(W_{gx}x^{(t)} + W_{gh}h^{(t-1)} + b_g)$$

$$\text{Input gate } i^{(t)} = \sigma(W_{ix}x^{(t)} + W_{ih}h^{(t-1)} + b_i)$$

$$\text{Forget gate } f^{(t)} = \sigma(W_{fx}x^{(t)} + W_{fh}h^{(t-1)} + b_f)$$

$$\text{Output gate } o^{(t)} = \sigma(W_{ox}x^{(t)} + W_{oh}h^{(t-1)} + b_o)$$

$$\text{Cell state } s^{(t)} = g^{(t)} \odot i^{(t)} + s^{(t-1)} \odot o^{(t)}$$

$$\text{Hidden gate } h^{(t)} = \tanh(s^{(t)}) \odot o^{(t)}$$

$$\text{Output layer } y^{(t)} = (W_{hy}h^{(t)} + b_y)$$

其中， $w_{ij}$ 為單元  $i$  連接到單元  $j$  的權重， $x^{(t)}$ 為在時間  $t$  狀態下的輸入值， $h^{(t-1)}$ 為接收到的上一時間  $t-1$  狀態的輸入值， $h^{(t)}$ 為在時間  $t$  狀態下傳遞到下一節點的輸出值， $g^{(t)}$ 為當前的輸入數據， $i^{(t)}$ 、 $f^{(t)}$ 、 $o^{(t)}$ 為輸入、忘記和輸出閘門的控制訊號，下標  $i$ 、 $f$ 和  $o$ 表示記憶區塊的輸出、遺忘和輸出閘門， $s^{(t)}$ 、 $s^{(t-1)}$ 為在時間  $t$  狀態下和在時間  $t-1$  狀態下的記憶輸出層， $y^{(t)}$ 為在時間  $t$  時節點的輸出， $\sigma$ 為sigmoid函數，可將數據轉換成(0, 1)範圍內的數值。

#### 四、 模式建置與結果

本研究目的為建置最佳之台北橋水位預報模式，提供台北市府預警之參考。模式的建置首先進行研究區域資料之搜集，而後利用網格搜尋法(Grid research method)(Brad 1983)對 3 種人工智慧模式進行因子篩選和參數率定，透過訓練和測試，模式表現經過評鑑指標評估。

##### (一) 因子篩選和參數率定

本研究利用網格搜尋法(Grid research method)(Brad, 1983)來尋找最佳的輸入因子和模式參數，網格搜尋法的基本概念是在空間中評估所有網格點之指標，比較後決定最佳因子和參數組合，方法簡單卻相當耗費計算資源，適用於運跑效率高的模式。網格搜尋法需決定連續變數的上下限，和類別變數的種類，再進行交叉配對決定最終必須運跑的組數。

本研究先透過歷程分析得知 49 場的雨量峰值和水位峰值的稽延時間(Lag time)，即石門水庫放水最大量至台北橋水位峰值之時間，約為 3 小時，此外本研究相關係數分析的成果如表 2 所示，相關係數最高的為前三小時的北橋水位和石門水庫出流量。因此，雨量  $R$ 、潮位  $S$ 、水庫放水量  $Q$  和台北橋水位  $H$  的輸入項組合為  $R(t)$ 至  $R(t-6)$ 、 $Q(t)$ 至  $Q(t-6)$ 、 $H(t)$ 至  $H(t-6)$ 的交叉配對。此外，3 種人工智慧模式率定的參數眾多，本研究挑選幾個常見的參數進行網格搜尋，如表 3 所

示，與因子備選組合交叉配對後，運跑出所有結果，再用評鑑指標多目標的探討並挑選最佳之模式。

表 2 各因子與台北橋水位相關係數分析

過去時間	集水區 平均降雨(t)	石門水庫 入流量(t)	石門水庫 出流量(t)	翡翠水庫 出流量(t)	潮位(t)	台北橋水位(t)
t	-0.048*	0.347	0.352	0.154	0.873	1.000
t-1	-0.036	0.365	0.359	0.149	0.838	0.888
t-2	-0.019	0.373	0.355	0.146	0.601	0.594
t-3	-0.005	0.372	0.340	0.144	0.240	0.218
t-4	0.007	0.361	0.317	0.143	-0.150	-0.150
t-5	0.015	0.340	0.288	0.140	-0.465	-0.421
t-6	0.017	0.314	0.259	0.137	-0.636	-0.539

[\*]-0.048 表示台北橋水位 t 時刻水位與集水區平均降雨(t)相關係數為-0.048

表 3 模式參數率定之備選參數

Model	Parameter					
SVM	Kernal function	Gamma	Cost	Epsilon	Degree	
	RBF, LN, PL, SIG	(2 <sup>-7</sup> , 2 <sup>7</sup> , 2)	(2 <sup>-7</sup> , 2 <sup>7</sup> , 2)	(2 <sup>-7</sup> , 2 <sup>7</sup> , 2)	(2, 3, 1)	
	Hidden layer	Activation	Optimizer	Batch	Dropou t	Epoch Loss
DNN	{[32]}, {[64]}, {[128]},		Nadam,	16,	0%,	
LSTM	{[256]}, {[512]}	Tanh, Relu	Adam,	32,	30%,	50, MAE,
	{[32], [64]}, {[64], [128]},		Rmsprop	64,	60%	100 MSLE
	{[128], [256]}					

[註] hyperbolic tangent : Tanh、Rectified Linear Unit : Relu

## (二) 評鑑指標

誤差(E)是指實際值( $Q_t$ )估計值( $\hat{Q}_t$ )的差額，利用誤差的探討來比較不同模式的結果，此研究中以均方根誤差、均值絕對誤差、相關係數以及效率係數來評估模式間的優劣。誤差計算方法如下：

$$\text{誤差}(E) = \text{實際值}(Q_t) - \text{估計值}(\hat{Q}_t)$$

均方根誤差(Root mean square error, RMSE)，將誤差平方後加總，再取平均，最後開根號。將誤差平方可以放大檢視極端事件，因此 RMSE 值越小，估計值就越接近實際值。RMSE 值計算方法如下：

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Q_t - \hat{Q}_t)^2} \quad (\text{式 1})$$

均值絕對誤差(Mean absolute error, MAE)，將所有誤差取絕對值計算其總和後，再取平均。MAE 值越小，估計值就越接近實際值。MAE 值計算方法如下：

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |Q_t - \hat{Q}_t| \quad (\text{式 2})$$

相關係數(Correlation coefficient, CC)，計算實際值與估計值的關係數，若相關係數越接近一，表示實際值與估計值的相關程度越高。CC 值計算方法如下：

$$\text{CC} = \frac{\sum_{t=1}^n (Q_t - \bar{Q})(\hat{Q}_t - \bar{\hat{Q}})}{\sqrt{\sum_{t=1}^n (Q_t - \bar{Q})^2 \sum_{t=1}^n (\hat{Q}_t - \bar{\hat{Q}})^2}} \quad (\text{式 3})$$

效率係數(Coefficient of efficiency, CE)，效率係數的範圍介於負無窮到一之間，若 CE 值等於一，表示模式的推估與實計值吻合；若 CE 值趨近於一時，表示模式的準確度越高；若 CE 值大於零時表示結果優於平均值；若 CE 值小於零，表示結果劣於平均值。CE 值計算方法如下：

$$\text{CE} = 1 - \frac{\sum_{t=1}^n (Q_t - \hat{Q}_t)^2}{\sum_{t=1}^n (Q_t - \bar{Q})^2} \quad (\text{式 4})$$

### (三) 預報結果與比較

為了探討水庫出流量對台北橋水位的影響，本研究使用 SVM、RNN 和 LSTM 技術，建立台北橋未來 1 至 6 小時水位預報模式，其評鑑指標統計於表 4。未來預報未來 1 至 6 小時，三個模式的表現皆相似，隨著預報時間增加，預報表現降低，即 RMSE 和 MAE 誤差增加，趨勢指標 CC 和 CE 值變小，LSTM、RNN 模式在預報未來 6 小時相關係數(CC)均大於 0.8，誤差(MAE)小於 0.4，顯示此兩種模式具有穩定表現，在 6 個預報時間中，RNN 的指標表現均略優於 LSTM 和 SVM 模式。

此外，本研究以測試資料中前三大場次之一的梅姬颱風作為範例，繪製歷線圖如圖 3 至圖 5 所示。由於台北橋為感潮河段，水位起伏可明顯看出受潮位影響，預報未來 1 至 6 小時，預報的潮汐震盪均符合觀測值。分別在  $t+1$ 、 $t+3$ 、 $t+6$  時刻中，SVM 都較符合到峰值，因為 SVM 的主要優勢為解決小樣本下機器學習的問題，因此對本研究而言較為合適，另外 RNN 在結果上也相較於變體 LSTM 為優，其原因可能為 LSTM 擅長於長時間的序列做訓練，而本研究之訓練資料對於 LSTM 無法發揮該優勢，在峰值常有高估，在預報  $t+6$  時刻 SVM 及 RNN 能

較符合峰值，但存在明顯的遲滯效應。此一現象也驗證石門水庫放水流至台北橋的時間約為 3 小時，當時刻的放水量將嚴重影響未來 3 小時的水位，因此預報 6 小時以上的水位變化，將有遲滯現象出現，且升水段將略為低估，因此本研究的建模成果以 3 小時內預報內可靠度較高。

綜合以上分析，三個模式於水位預報皆有穩定表現，雖然 RNN 於指標表現較佳，但 SVM 峰值的預報較兩模式準確，因此建議以 SVM 建立的台北橋水位預報模式，預報的未來 1 至 6 小時水位作為台北市政府防災參考依據。

表 4 各模式之評鑑指標

Lead time (h)	Model		
	SVM	RNN	LSTM
RMSE(m)			
$t+1$	0.30	0.28	0.28
$t+3$	0.44	0.41	0.43
$t+6$	0.65	0.56	0.57
MAE(m)			
$t+1$	0.21	0.20	0.20
$t+3$	0.28	0.29	0.29
$t+6$	0.44	0.39	0.39
CE			
$t+1$	0.90	0.91	0.91
$t+3$	0.78	0.81	0.80
$t+6$	0.52	0.65	0.64
CC			
$t+1$	0.96	0.96	0.96
$t+3$	0.89	0.90	0.91
$t+6$	0.78	0.81	0.81

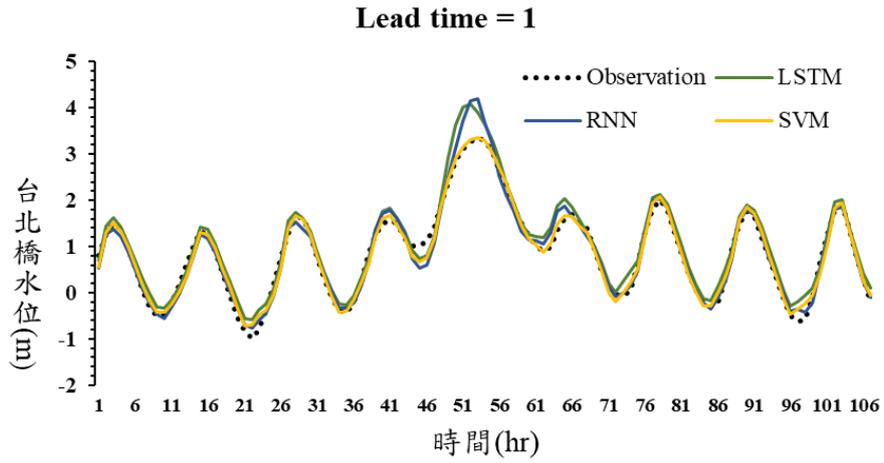


圖 3 梅姬颱風台北橋未來 1 小時水位預報

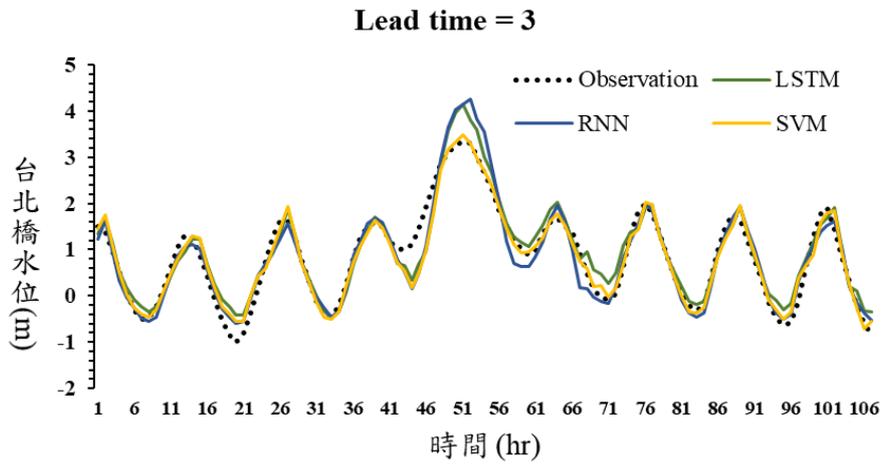


圖 4 梅姬颱風台北橋未來 1 小時水位預報

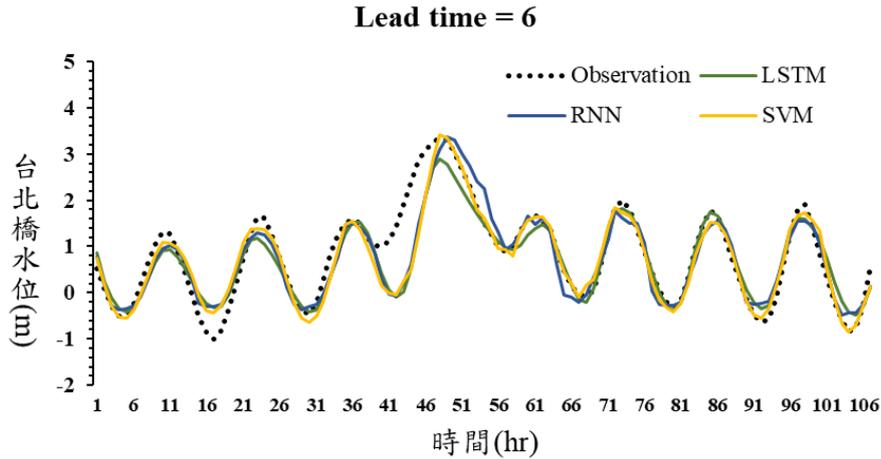


圖 5 梅姬颱風台北橋未來 1 小時水位預報

## 五、 結論

本研究主要以 3 種人工智慧模式預報台北橋未來 1 至 6 小時之水位，研究過程分為三個步驟：(1) 篩選模式輸入項和模式參數；(2) 探討支援向量機、遞迴神經網路和長短期記憶網路模式預報成果，挑選出最佳之水庫入庫流量預報模式。依據本研究結果可以歸納成以下的結論：

1. 台北橋水位受到淡水河口潮位、石門和翡翠水庫出流量、集水區降雨量影響，其中常水位時受到淡水河口潮位影響，暴雨時水庫放水遇到漲潮會嚴重產生迴水，是造成台北橋水位壅高的主要原因。
2. 使用網格搜尋法優選模式輸入項和模式參數，可迅速優選出最適合的模式參數，建置最佳的水位預報模式。
3. 三個模式於水位預報皆有穩定表現，RNN、LSTM 於指標表現較佳，SVM 峰值的預報較準確，因此建議以 SVM 建立的台北橋水位預報模式，預報的未來 3 小時水位作為相關單位防災參考依據。

## 參考文獻

1. Brad J.F., 1983. An Efficient Point Algorithm for a Linear Two-Stage Optimization Problem. *Oper. Res.*, Vol.31, pp.670–684.
2. Vapnik V., 1995 *The nature of statistical learning theory*. Springer, New York
3. Hochreiter S., Schmidhuber J., 1997. Long Short-Term Memory. *Neural Comput.* 9:1735–1780.
4. Zhang, J., K. Howard, C. Langston, S. Vasiloff, B. Kaney, A. Arthur, S. V. Cooten, K. Kelleher, D. Kitzmiller, F. Ding, D.-J. Seo, E. Wells and C. Dempsey, 2011: National mosaic and multi-sensor