

以倒傳遞類神經網路進行地下水位與抽水量推估

USING BACK-PROPAGATION NEURAL NETWORK TO ESTIMATE GROUNDWATER LEVEL AND PUMPING QUANTITY

國立中央大學
通訊工程學系
大專生

邱正鈞
Cheng-Chun Chiu

國立中央大學
通訊工程學系
大專生

萬昱廷
Yu-Ting Wan

國立中央大學
應用地質研究所
助理教授

王士榮*
Shih-Jung Wang

摘要

由於台灣地狹人稠且降雨不均，因此水資源的控管相當重要，尤其是地下水的過度抽取可能導致地層下陷等問題發生。傳統的水文分析方法可能存在許多難以符合實際狀況的假設，而類神經網路模式能夠建構出有別於傳統的關係模型。因此，本研究蒐集水文觀測資料，並自行發展監督式倒傳遞類神經網路模式，藉由預測地下水位並推估抽水量，冀望有助於相關單位對未來地下水資源的有效管理。本研究可分為三項內容：資料補遺、地下水位推估以及地下水抽水量推估。首先，本研究利用類神經網路模型進行資料補遺，選取人為影響較小的臺中地區中山地下水位觀測井為例，以氣象資料與觀測地下水位資料建模，將連續觀測資料中的某段移除後進行補遺並與觀測資料做比較。補遺結果顯示，本研究類神經網路補遺較傳統反距離插值法獲得更好的補遺結果。之後以同樣的方法進行地下水位推估。結果顯示，本研究建立的類神經網路模式推估水位與觀測水位有相似的趨勢，但量值有所差異，主要原因在於推估地下水位變化量之累積誤差以及人為因素影響所致。在瞭解氣候水文與地下水位之關聯性後，本研究蒐集台灣南部某抽水井群觀測抽水量資料，配合鄰近地下水位與降雨量觀測資料，建立類神經網路模型進行抽水量的推估。其中輸入資料採用是否加入降雨量分別進行建模與分析，以比較兩者的優缺點。結果顯示，本研究以類神經網路模式推估之抽水量與觀測抽水量有相似的趨勢，但峰值與谷值有所差異，可能因觀測井位於抽水井群之洩降錐內，無法建立穩定的降雨量、地下水位和抽水總量關聯模型。本研究完成地下水位資料補遺、地下水位推估與抽水量推估，並取得可接受成果。研究成果可提供研究區未來地下水位資料的補遺與預測，以及地下水抽水量的推估，並做為未來地下水資源規劃與管理之參考。

關鍵詞：類神經網路、預測、地下水位、資料補遺、抽水量推估。

* 通訊作者，國立中央大學應用地質研究所助理教授

32001 桃園市中壢區中大路 300 號，sjwang@ncu.edu.tw

USING BACK-PROPAGATION NEURAL NETWORK TO ESTIMATE GROUNDWATER LEVEL AND PUMPING QUANTITY

Cheng-Chun Chiu

National Central University
Department of Communication
Engineering

Yu-Ting Wan

National Central University
Department of Communication
Engineering

Shih-Jung Wang*

National Central University
Graduate Institute of Applied
Geology

ABSTRACT

Due to the densely population and uneven rainfall in Taiwan, the management of water resources is an important issue, especially the excessive extraction of groundwater situation which may cause land subsidence problem. Traditional hydrological analysis methods commonly include some assumptions that are difficult to conform to the actual situation, and the neural network model can construct a relational model that is different from the traditional one. Therefore, this study collects the hydrological observation data and develops a supervised back propagation neural network model. By predicting the groundwater level and estimating the pumping quantity, the results can provide government to effectively manage future groundwater resources. This study includes three parts: data supplements, groundwater level predictions, and groundwater pumping estimations. First, this study uses the neural network model to supply the loss data, and selects the Zhongshan groundwater monitoring well in Taichung area with small human influence as an example. The meteorological data and the observed groundwater level data are adopted, and a certain section of the continuous observation data is removed to do supplement and compare with the observations. The result shows that the supplement data using neural network interpolation obtains better results than using the inverse distance interpolation method. The same concept is adopted to estimate the groundwater level. The result shows that the neural network model well predicts the groundwater level, though still includes some discrepancies. The estimated groundwater level variations have accumulative errors, but the result looks reasonably. After realizing the correlation between climatic hydrological data and groundwater level data, this study continued to build a neural network model based on the observed pumping data of a well group and the groundwater level monitoring data from a nearest well in southern Taiwan. The pumping quantity is estimated by using the groundwater level data, and considering if the rainfall be the input data or not to compare the advantages and disadvantages of these two situations. The results show that the pumping quantity estimated by the neural network model can capture the pattern but have a discrepancy with the observed pumping quantity, which may because the monitoring well is located in the cone of depression of the pumping well group. Therefore, it is difficult to establish a stable pumping quantity estimation model with climate conditions. The study results provide the tool for groundwater level supplements and predictions and groundwater pumping assessments in the study area, which can be the reference in future planning and management of groundwater resources.

Keywords: Artificial neural network, Prediction, Groundwater level, Data supplement, Pumping quantity estimation.

Chiu, C.C., Wan, Y.T., & Wang, S.J.* (2020). "Using Back-Propagation Neural Network to Estimate Groundwater Level and Pumping Quantity." *Journal of Taiwan Agricultural Engineering*, 66(4), 46-58.
[https://doi.org/10.29974/JTAE.202012_66\(4\).0005](https://doi.org/10.29974/JTAE.202012_66(4).0005)

一、前言

在台灣，水資源的管控是一件相當重要的事。台灣為副熱帶季風氣候，在夏秋季雨量豐厚，但因地狹人稠，水流湍急，導致相當多可用的水資源經由河流流入大海當中，因此冬季與春季常有缺水情況發生。在一些可能面臨水資源缺乏的地區，興建水庫儲存水資源以防乾季缺水是一個常用的手段，但是興建水庫耗時、勞民、傷財更破壞了生態環境，且在短期內難以建成取得成果。因此在補注量比較豐厚的地區開發地下水資源，為一個開源的方法。然而，在永續地下水資源利用的概念中，補注量與抽水量之間的平衡難以拿捏，尤其在農漁牧發達地區，常有超抽地下水導致地層下陷，而產生潛在的公安問題。因此，有效的利用並管理地下水資源是我國重要的一大課題。

人工智慧技術(Artificial Intelligence, AI)，從 Hinten *et al.* (1986)發明了倒傳遞演算法(Back Propagation)後，成為了類神經網路(Artificial Neural Network, ANN)的濫觴。近期在各行各業有著非常廣泛的應用，尤其 Silver *et al.* (2016)以 Deep Q Learning 技術發展的 AlphaGo，先後擊敗人類棋手李世乭與柯潔，引爆了人工智慧技術的狂潮。Apple 運用人工智慧進行物體偵測(Zhou, 2017)，證明了資料驅動的深度學習技術(Deep Learning, DL)有無窮無盡的潛能。林楷為(2008)運用 HEP (Habitat Evaluation Procedure)來搭配資料進行建模，以進行生態環境變因分析。若搭配數據中心(Data Center)所擁有的 PB (Peta Byte)級、甚至 EB (Exa Byte)級大數據(Big Data)，可以統計金融市場、對股市的漲跌幅做出預測。如黃華山與邱一薰(2005)利用倒傳類神經網路進行台灣 50 股價指數研究。趙士儀(1999)在資料探勘(Data Mining)中利用主成分分析法(Principle Component Analysis, PCA)，找出資料間的主要成分以處理資料補遺。

不僅在金融科技領域上能應用神經網路方法，在地球科學領域上的應用也有所斬獲，如 Yesilnacar *et al.* (2008)利用類神經網路來預測地下水硝酸鹽含量、卓惠玲(2008)利用類神經網路應用於資料補遺、甚至王啟明(2004)將其應用在颱風暴潮的預測。Chang *et al.* (2005)與 Hsu *et al.* (2009)利用類神經網路預測地下水位，兩研究與本研究相同，認為類神經網路較一般之遞迴式神經網路(Recurrent Neural Network, RNN)適合用於地下水位預測。然而，Hsu *et al.* (2009)僅以單月而非長時間來預測，無法呈現整個水文年豐枯水期地下水位變化之狀態。因此，本研究採用連續且大於一個水文年的每日觀測資料進行建模與分析，且採用地下水位之變

化量而非高程進行研究。以水平衡的觀點來看，地下水位的變化量才能反映出氣候水文變化與人為抽水的影響，即水位變化量導因於地下水之補注量與抽取量之變化。

有效利用水資源的前提是有效的管理，但是台灣因地下水管理機制與法規未落實，各地區地下水抽水量一直是未知數，雖有不同方法進行推估，但推估結果存在非常大的差異(經濟部水利署，2014, 2015)，也造成地方政府無法有效的進行地下水權的分配與管理。地下水位變化直接反映補注量與抽水量的變化，補注量主要來自天然因素，因此可採用氣候水文觀測資料進行有效推估；但抽水來自人為因素，除了不同產業有不同抽水需求與型態(王仁甫，2011)，受到含水層實際為異質異向性之影響，不易採用單一物理模式進行完整的描述與模擬。因此，人工智慧的類神經網路系統，採用觀測資料進行建模，捨棄物理模式中相關假設之限制，為拆分地下水位資訊為天然與人為因素之可行的方式。然而，現今採用類神經網路進行地下水抽水量推估的研究相當缺乏。因此，本研究利用人工智慧的類神經網路系統，從氣候與水文時序列資料中，來進行地下水位推估與預測，並用此技術進行抽水量之推估。相關技術發展成熟後，可以推展到其他站井與研究區，以協助各管理單位釐清地下水資源整體情況，提供未來水資源管理之依據與參考。

二、研究背景與資料

本研究共進行三項工作，分別為資料補遺、水位推估與抽水量推估。本研究蒐集水利署氣候與水文日觀測資料進行建模與分析，但觀測資料常有缺漏問題，短則一日，多則數月，造成後續進行時間序列分析時無法有效使用。因此本研究首先進行資料補遺工作，由觀測氣象資料與地下水位資料建立類神經網路模式，以填補缺漏之地下水位資料。之後以同樣的概念進行地下水位推估，建立觀測氣候水文對地下水位變化之相關性模式。然而，以地下水位進行抽水量推估時，需有抽水量資料進行模式驗證，因水位推估採用之觀測水井未有抽水量資料，因此另外選取台灣南部某抽水井群之觀測水位與抽水量進行分析。

本研究分別依照適合的資料狀態來選取採用的資料。地下水位推估研究中，採用臺中中山地下水位觀測井為案例，藉由相對單純的氣候水文與地下水文連結進行模式訓練，確認方法之可行性。圖 1a 為水位推估中採用觀測站井之分布，中山 1 地下水位觀測井與臺




圖 1 本研究採用水文觀測站井分布。(a)地下水位推估採用之中山 1 地下水位觀測井與氣象站分布、(b)抽水量推估採用抽水井群中心與氣象站分布。

中氣象站相距 857 公尺，為距離中山 1 測站最近之氣象站，所以本研究使用此氣象站之資料進行分析，再以類神經網路採用梯度下降法(Gradient Descent)訓練模型，以藉由輸入因子預測結果來推估地下水位。而抽水量推估研究中，採用台灣南部某抽水井群為案例，大寮氣象站距抽水井群中心最近約 5.1 公里(圖 1b)，因此採用此氣象站之資料，進行該抽水井群抽水量推估之氣候輸入因子。

2.1 資料補遺

本研究蒐集臺中氣象站 2014/01/01 至 2016/12/31 的氣象資料，包含氣壓、氣溫、相對濕度、風速、雨量、日射量等日觀測資料，作為類神經網路輸入因子。其中除了雨量及日射量為當日總量外，其餘數值皆為當日平均。類神經網路的輸出為對應之地下水井當日至隔日的地下水位變化量。中山 1 原始每日地下水位觀測時間序列資料如圖 2 所示。資料顯示，中山 1 地下水位有顯著的乾濕季振盪變化，與降雨量的多寡有非常高的相關性。為確認資料補遺的效果，本研究將觀測地下水位日資料分為訓練集與測試集兩部分：訓練集時間為 2014/01/01 至 2016/12/31，但不包含 2015/05/16 至 2015/08/23，共 995 筆；測試集時間為 2015/05/16 至 2015/08/23，資料總共 100 筆。本研究以訓練集資料進行模式訓練，模式訓練完成後用來推估測試集期間的地下水位，並與測試集的觀測地下水位做比較，以瞭解模式在地下水位補遺的準確度。




圖 2 中山 1 地下水位時間序列與台中降雨量比較圖

2.2 地下水位推估

本研究採用與資料補遺相同的觀測站井進行地下水位預測，但使用較長時間的日觀測資料，時間為 2007/01/01 至 2016/12/31。氣象資料同樣採用臺中氣象

站，資料類型包含氣壓、氣溫、相對濕度、風速、雨量、日射量，作為神經網路輸入因子。類神經網路的輸出為對應之中山 1 地下水井當日至隔日的地下水位變化量。地下水位時間序列同樣如圖 2。本研究於地下水位推估中，同樣將資料分為訓練集與測試集：訓練集時間為 2007/01/01 至 2015/03/19，總共 3,000 筆；測試集時間為 2015/03/20 至 2016/12/31，總共 653 筆。採用與資料補遺相同的方式，以訓練集之氣候觀測資料連結地下水位資料進行模式訓練，之後以訓練完成之模式進行地下水位推估，並與測試集之觀測地下水位資料進行比較，以確認本研究地下水位推估之準確性。

2.3 地下水抽水量推估

為了確認抽水量推估之正確性，本研究蒐集台灣南部某地區之地下水抽水井群之抽水量與鄰近觀測井之地下水位資料，作為類神經網路之訓練集以及測試集。抽水量與地下水位之原始觀測資料為每十分鐘一筆，本研究先計算各抽水井每小時累積抽水量與觀測井每小時平均地下水位後，統計該區數個井之合計抽水量作為總抽水量。本研究使用兩種模式推估抽水總量，模式一：採用降雨量與地下水位作為類神經網路輸入，輸出抽水總量；模式二：僅採用地下水位作為類神經網路輸入，輸出抽水總量。第二種模式沒有輸入降雨量，看是否能僅由地下水位資料進行抽水量推估，之後進行兩種方法比較與討論。

觀測抽水量與地下水位時間序列如圖 3 所示。由資料可知，地下水位與抽水量時間序列有著一小時的偏移，抽水的結果會影響後一小時的地下水位變化量，類似的偏移也會出現在氣壓對水位影響的觀測中(陳清田等, 2013)。主要原因在於抽水井與觀測井並非共構，




圖 3 台灣南部某地區之總抽水量與觀測地下水位之時間序列圖。資料點時間間隔為 1 小時，其中抽水量與地下水位存在一小時的時間差，抽水量變化快於地下水位變化。

而是有一段距離，因此抽水的反應需一段時間後才能由觀測井中觀測到。為了方便進行相關性之模式建置，本研究在進行模式訓練前先將資料平移至相同的時間點，以建立抽水對地下水位之影響模式。但須注意，模擬結果與實際觀測會有一個小時的時間延遲作用。採用訓練集時間為 2017/8/22 15:00 至 2018/6/10 8:00，總共 7,000 筆；測試集時間為 2018/6/10 9:00 至 2018/11/6 14:00，總共 2,998 筆。

三、研究方法

3.1 類神經網路模型

本研究採用之類神經網路結構及其原理如圖 4 所示。類神經網路的結構包含輸入層(Input layer)、隱藏層(Hidden Layer)及輸出層(Output Layer)。在每層中(除了輸入層)均做線性層、激勵函數層與代價函數(Loss function)計算，分別如下：

$$Z^{(k)} = W^{(k)} A^{(k-1)} + B^{(k)} \quad (1.1)$$

$$A^{(k)} = \sigma(Z^{(k)}) \quad (1.2)$$

$$Cost = \frac{1}{m} \sum (A^{(L)} - y)^2 \quad (1.3)$$

其中 Z 為任意層的線性計算值， A 為任意層的值， B 為每一線性層的置偏， W 為兩層間的全連接， σ 為激勵函數(Activation Function)，又總層數為 L ，因此 $A^{(L)}$ 為輸出層輸出值，此外整個系統的輸入為 $X = [X^{(1)} \dots X^{(n)}]$ ， n 為第 n 個輸入樣本。其中在輸入層可視為第 0 層的輸出，因此 $A^{(0)} = X$ ， y 為實際資料，




圖 4 類神經網路基本結構

m 為總樣本數。代價函數能夠計算模型的輸出與實際資料之間的差。功能是提供一個可評估模型性能的函式，而且必須是可微分函數。在線性層，可以得知每個神經元受到上一層的神經激勵關係。在激勵函數層，可以強化模型的非線性能力。此過程稱之為前饋式(Feed Forward)運算。 W 及 B 的更新如下：

$$dA^{(k)} = W^{(k+1)'} dZ^{(k+1)} \quad (2.1)$$

$$dZ^{(k)} = dA^{(i)} * d\sigma(A^{(k+1)}) \quad (2.2)$$

$$W^{(k)} = W^{(k)} - \alpha \frac{1}{m} dZ^{(k)} A^{(k+1)} \quad (2.3)$$

$$B^{(k)} = B^{(k)} - \alpha \frac{1}{m} \sum dZ^{(k)} \quad (2.4)$$

其中 α 為學習速率， $\sum dZ^{(k)}$ 為矩陣列之和。此過程稱為倒傳遞算法。

3.2 類神經網路程式開發

本研究採用 Python 程式語言搭配 Tensorflow 框架，自行開發所有的相關程式碼，如此才能夠掌握運算的所有細節。Python 程式語言是個直譯式、動態的程式語言，具有可重用性高且快速開發的特性，因此在本研究中，Python 語言是個不二選擇。

本研究的網路爬蟲技術是使用 BeautifulSoup4 框架分析，從中央氣象局觀測資料查詢系統伺服器中獲得回傳之 HTML 原始碼，再利用 Regular Expression 對字串進行過濾，並自動抓取觀測資料查詢系統中每日的表格資訊，將資料依照日期進行合併，再轉換成可供後續研究快速利用的格式。取得之資料為每小時記錄一次的時資料。

在類神經網路開發方面，使用 Tensorflow 框架來編寫類神經網路的細節，使用 CUDA 後端使其可以調用繪圖運算單元(GPU)的資源，快速的對模型進行迭代，速度將可達到使用中央處理器(CPU)的數倍。再將使用網路爬蟲得到的時間序列資料輸入類神經網路當中進行訓練，來藉此運行本研究的所有核心內容。

3.3 誤差計算

本研究採用之誤差計算式為平均絕對誤差(Mean Absolute Error, MAE)：

$$MAE = \frac{1}{n} \sum_{i=1}^n |u_{predict} - u_{observed}| \quad (3)$$

其中 $u_{predict}$ 代表類神經網路輸出之結果， $u_{observed}$ 代表實際觀測之結果，將兩者進行比較計算其差值，並以 MAE 作為類神經網路輸出之評估標準。

以 MAE 而言，加入絕對值能更反應出預測的合理性，不會受到正負抵銷的影響，也因為不是平方，所以掌握趨勢便可合理判斷優劣，並不會因為偏離太大或太小而影響太劇烈或太些微。

四、研究結果

本研究內容分為三部分，分別為資料補遺、地下水位推估以及地下水抽水量推估。以下分別說明研究成果。

4.1 資料補遺

本研究在資料補遺的部分，再將問題分為兩個面向，分別為：(1)單一觀測井在時間上的資料補遺，(2)觀測井在水平空間中的資料插值。第二項指在未有觀測井之地點，進行地下水位高程的推估，以獲得更有代表性的空間分布流場。

4.1.1 單一觀測井在時間上的資料補遺

本研究以深度神經網路模型，建立地下水位變化量與各項可能影響水位變化量之因子間的關聯性，建構出可以模擬複雜數學關係的模型。本研究採用類神經網路插值進行資料補遺並與傳統反距離插值法之結果做比較。圖 4 為本研究進行氣候觀測因子輸入與地下水位變化量輸出之類神經網路架構示意圖。輸入各項氣候因子進入類神經網路，並以地下水位變化量作為輸出，藉此推算出可能的地下水位值。

圖 5 為資料補遺結果比較，綠線為原始觀測地下水位，紅色虛線為使用類神經網路模式，輸入氣候水文觀測資料進行地下水位推估結果，該區間假設觀測資料遺失 100 筆(綠線)。從類神經網路補遺之結果可以看到，類神經網路模式能針對實際觀測氣候狀況進行地下水位推估，快速上升的水位與水位變化趨勢皆能掌握，惟局部振盪量值尚無法完全掌握，MAE 誤差為 0.254 m/day。誤差除了氣候水文資料與地下水文資料的連結可能存在不確定性外，人為抽水與補注為主要影響因子，因人為因素與氣候水文觀測資料相關性較低，不易與氣候水文觀測資料進行連結。

本研究將 Shepard (1968)所提出的反距離插值法應用於相同的資料，並與類神經網路模式結果做比較，藉




圖 5 中山 1 觀測與補遺之地下水位歷線比較

此瞭解其與類神經網路模式的差異與優劣。首先建立反距離插值法之計算方程式。假設有 m 筆已知資料，欲找出某遺失點的資料，可藉由遺失點與已知點之距離 D ，透過下列公式計算已知各點至遺失點位置之權重：

$$Weight_{ij} = \frac{D_{ij}^{-2}}{\sum_{j=1}^m D_{ij}^{-2}} \quad \dots\dots\dots (4)$$

其中 i 為遺失點位置， j 為周圍已知點的位置， D_{ij} 為點 i 到點 j 之間的距離， $Weight_{ij}$ 是指點 j 對點 i 的資訊貢獻度。再透過已知點資料 X_j 與其距離權重相乘後加總，即為遺失點之資料 X_i 。

$$X_i = \sum_{j=1}^m (Weight_{ij} \times X_j) \quad \dots\dots\dots (5)$$

反距離差值法中，距離越近則影響係數越大，通常用在空間資料分析。本研究將距離之概念導入時間序列中，假設在時間越靠近遺失點之水位，會與遺失水位有越大的相關性。

反距離插值法資料補遺結果如圖 5 藍線所示。結果顯示，反距離插值法未能針對水位變化做出適當的插值推估，只能單純的進行時間上的非線性補遺。因反距離差值算法中強調距離越近的觀測點對於測點的影響力較大，因此在周圍已知點越多的情況下差值會越準確，適合拿來進行空間差值；以時間差值的概念，最近的點只有前後兩個觀測點(若在 t 秒時資料遺失，則最近的兩個點是 $t-1$ 及 $t+1$)，可能無法反應局部的水位振盪情況。其 MAE 誤差為 0.435 m/day，誤差較類神經網路法大許多。

4.1.2 觀測井在水平空間中的資料插值

傳統地下水流場主要以地下水流物理模式配合 Modflow 軟體進行計算(如洪耀明，2013)，本研究嘗試以插值概念，使用 Python 語言建立類神經網路模式來




圖 6 地下水位空間插值法於研究區之(a)地表高程圖，(b)地下水位 Y 軸投影分布圖，與(c)類神經網路地下水位空間插值結果

估算研究區中整體之地下水流場。但目前採用因子相對簡單，仍屬初步嘗試階段。本研究將反距離插值法的空間概念延伸至類神經網路，計算欲推估的地下水位地點與其他觀測井之間的距離，以這些距離計算每個觀測井對於樣本點的比重作為神經網路的輸入，並以此訓練類神經網路的權重。本研究將「各觀測井與目標地的距離平方」、「各觀測井之地下水位」以及關鍵「目標地的地表高程」作為類神經網路的輸入，輸出為「目標地的地下水位高程」，對類神經網路進行訓練。

圖 6 為本研究利用類神經網路方法進行空間插值的結果。圖 6a 為利用 Python 繪製的去掉極端負值後的研究區 DEM 地形圖。圖 6b 為觀測地下水位於 Y 軸的投影分布。圖 6c 為本研究透過類神經網路插值之 3D 地下水位高程圖，顯示出大致與地形相似之分布，將於後面章節針對空間分布插值結果進行進一步討論。

4.2 地下水位推估

使用之類神經網路結構如圖 4，將觀測資料分為訓練集與測試集，以驗證模式之準確性。圖 7 為本研究




圖 7 以類神經網路進行地下水位推估結果比較圖。2015 年 3 月 20 日前之序列為訓練結果比較，2015 年 3 月 20 日後之序列為測試結果比較

類神經網路地下水位推估之訓練與測試結果。圖中，2015 年 3 月 20 日前之序列為訓練結果比較，結果顯示，雖然類神經網路模式掌握了大部分的地下水位變化趨勢，但因類神經網路的輸出為變化量，導致誤差累加而產生較大偏移，本研究將於後續章節討論此問題與未來修正的想法。圖中 2015 年 3 月 20 日後之序列

為測試結果比較，與訓練集的結果相似，地下水位推估結果產生了偏移，部分測試結果甚至有相反的趨勢，可能受到該期間降雨型態與人為因素所影響，其 MAE 誤差為 0.040 m/day。

4.3 地下水抽水量推估

本研究利用 Python 程式語言撰寫網路爬蟲程式，由氣象局網頁中提供的氣象資料，蒐集距離抽水井群最近之氣象站資料，並將抽水量與地下水位的觀測資料計算為每小時資料，以利比較。此外，抽水量推估的工作分為兩個部份，分別為傅立葉分析與抽水量推估，以下分別說明。

4.3.1 傅立葉分析

本研究蒐集台灣南部某抽水井群抽水量與地下水位觀測資料，並計算為每小時一筆之觀測總抽水量資料，以與氣象資料取樣頻率一致。抽水總量時間序列如圖 8a 所示。由圖中可知，抽水量序列似有顯著的週期性，因此本研究先以傅立葉轉換找出抽水的週期，以確認抽水量與地下水位的相關性，結果如圖 8b 所示。圖中顯示，抽水量的顯著頻率約為每小時 0.04 與 0.08 次，將頻率倒數後可得週期，換算總抽水量的時間序列中，顯著週期約 24 與 12 小時，與該地區產業用水型態有關。該地區之地下水位傅立葉轉換分析結果如圖 8c 所示。結果顯示，地下水位的顯著頻率與抽水量之頻率相同，可以推斷兩者具有高度的相關性，也確認本研究將地下水位作為類神經網路輸入推估抽水量的合理性。

4.3.2 抽水量推估

為釐清研究區降雨量和抽水量對地下水位之影響，本研究先針對乾濕季地下水位、抽水量與降雨量進行比較，如圖 9 所示。其中乾季的時間選取 2018/03/14 17:00 ~ 2018/03/18 21:00，濕季的時間選取 2018/07/01 01:00 ~ 2018/07/05 04:00。由圖 9a 中可知，乾季期間降雨量不顯著，相對大的一次降雨事件(約 8.5 mm 降雨)對地下水位無顯著影響，而其他未有降雨期間，地下水位仍有相當大的振盪現象。對比抽水量資料可以明顯得知，地下水位的振盪變化主要導因於抽水，抽水量開始增加而地下水位逐漸降低，停止抽水後水位迅速回升。濕季期間降雨量相對較大(圖 9b)，但比較降雨、抽水與水位的相關性，地下水位受到降雨量的影響不如抽水的影響。因此，該區域就算有顯著降雨，地下水位之變化仍主要導因於人為抽水作用。此現象主要受到觀測井與抽水井群相當靠近之緣故(觀測井距抽水井群




圖 8 台灣南部某抽水井群之(a)總抽水量時間序列圖與(b)抽水量之傅立葉分析結果(c)地下水位傅立葉分析結果

中心約 250 公尺)，觀測井位於抽水井的主要洩降錐內，當開始抽水時地下水位迅速下降，其下降量遠大於降雨補注之上升量，故相對而言，降雨量之影響小而不顯著。而從地下水位快速上升與下降之行為，亦可推測觀測井開篩位置之含水層導水係數相當高，觀測井水位可迅速反應含水層因抽水引起的水位下降與上升行為。比較乾濕季的抽水量資料可發現，乾濕季的抽水頻




圖 9 地下水位、抽水量與降雨量於(a)乾季與(b)濕季之比較
圖。乾季期間為 2018/03/14 17:00 ~ 2018/03/18 21:00 ;
濕季期間為 2018/07/01 01:00 ~ 2018/07/05 04:00

率有些微差異，乾季抽水頻率相對較高。除了可能與該產業淡旺季之生產型態不同引致用水量不同有關外，亦可能顯示該產業有搭配地面水之使用，在乾季地面水相對較少情況下，抽水頻率增加。但實際情形尚需蒐集更長時間的抽水量與地下水位觀測資料，並與該產業的生產量時間序列或生產型態作比對方能確認。

本研究接著將降雨量以及地下水位變化量作為類神經網路輸入，進行抽水量之推估(模式一)，結果如圖 10 藍色虛線所示，其 MAE 誤差為 $789.90 \text{ m}^3/\text{hour}$ 。圖中可以發現，模式一約在 30 小時左右的推估抽水量有顯著上升的結果，但觀測資料未有抽水事件。該現象主要反映出該時間發生降雨事件，但地下水位卻沒有顯著上升，導致類神經網路判斷地下水位未上升為抽水量增加之緣故，造成推估抽水量大而實際未有抽水行為。若於類神經網路中忽略降雨量之輸入(模式二)，類神經網路的推估結果可正確反映抽水量的行為(圖 10




圖 10 採用不同模式推估抽水量結果比較圖。橘色實線為觀測抽水量；藍色虛線為以降雨量和地下水位推估抽水量結果；紅色點線為僅以地下水位推估抽水量結果

紅色點線)，其 MAE 誤差約 $639.98 \text{ m}^3/\text{hour}$ 。而圖中亦顯示，類神經網路的抽水量估算，在抽水量大時皆低估實際抽水量，但抽水量小時則有高估情形，尤其在尖峰抽水量部分低估較為嚴重。推測可能的原因在於，地下水位的變化不能完全呈現抽水總量的改變，地下水位的變化存在更多的影響因素，例如地質與水力特性，所以需要考慮其他的因子，才能更完善地建立地下水位與抽水量的關係，進而準確的推估抽水量值。

五、討論

5.1 資料補遺

本研究針對類神經網路補遺及反距離插值法進行比較，類神經網路在對資料進行補遺時是對資料進行統計並計算變化量，理論上較為合理；相對的反距離插值法在遺失資料區塊補遺結果，以時間序列來說並不理想，僅在短時間內有較合理的結果。若針對長時間與短時間上的補遺作討論，在短時間內類神經網路補遺仍較能夠針對水位高程的變化來調整，有劇烈變化時能做出相應的處理；而反距離插值法雖能在未有劇烈變化時有不錯的表現，但若資料缺失段有劇烈變化時，則無法反應出來。在長時間的情況下，類神經網路補遺較能夠針對水位高程變化調整，有劇烈變化時能做出相應的調整，但可能有較大的累計誤差，也可能變得不穩定，需要更精細的配置、調整與較多訓練數據。反距離插值法在長時間幾乎無法反應劇烈變化，只能用平順的插值補遺，相對的在非常穩定與規律的水位變化能有不錯的表現。

表 1 資料補遺方法優缺點比較

	優點	缺點
反距離插值法	所需要的資料量較少,而且計算量較少。可以適用於多種場合。	基於對距離的相關性而進行假設建模,適合的情況若非以距離作為考量的話可能有異。
類神經網路法	資料足夠就能夠合理的對各項因子建模。	需要大量資料進行訓練,需要有該輸出點的輸入資料才能進行。

綜合來說,反距離插值法依其性質(公式(4)(5)),適合用在空間連續資料之上,如地表高程的資料補遺,因與遺失點數量相較之下,存在的資料點數量較多,且依據公式,其非常仰賴與遺失點距離較近之觀測點。因此,若用其計算地下水位高程,會因為距離相近的點過少而導致產生較為不可靠的補遺結果。若是以類神經網路方法進行補遺,類神經網路會嘗試計算每個輸入因子以推估輸出結果而建立模式,且即使有除了輸入因子之外的變因會導致輸出產生變化,類神經網路方法內的置偏(bias)也能夠適應變化,據此可以對該資料站進行適切的建模。類神經網路法與反距離插值法的優缺點列於表 1 供參考。

5.2 地下水位推估

在地下水位推估中,本研究以各項氣候因子來預測地下水位變化量,因此,當時間線拉長便會導致偏差逐日累積,產生較大的偏移。也因為有這樣的累積偏差性質,所以本研究也嘗試在每次類神經網路訓練時,進行地下水位推估(非變化量),並且將結果作為下次訓練的輸入,反覆循環訓練迭代,獲得較變化量更為穩定的推估結果。未來也會考慮使用支撐向量分類來做前處理,在倒傳遞演算之前先將資料做分類或批量常規化等前處理(陳清田等, 2013),以降低可能的累積誤差問題。

另外,本研究採用氣候水文因子進行地下水位之推估,其概念為忽略人為影響,因此在觀測站井之選擇相對重要,需盡量避開人為影響之區域,例如農漁牧業與產業之抽水區域。因此,本研究以氣候水文資料進行地下水位推估結果產生之誤差,亦可能來自人為影響之不確定性所引起。

5.3 地下水抽水量推估

5.3.1 傅立葉分析

本研究無法在時間序列中找到乾季時雨量與地下水位變化量的密切關係,且濕季的資料亦不足以提供

兩者的相關性資訊;但抽水量之週期與地下水位變化則有強烈相關性。本研究將抽水量視為有週期的人為干擾並以傅立葉分析計算其週期,其在頻率為每小時 0.04 及 0.08 時有較為明顯的振幅,意味著抽水有約 24 及 12 小時的週期,該週期雖然與潮汐相當,但該地區屬於內陸無海潮影響且水位變化超過地潮振盪,因此為非天然週期,應與產業的上下班抽水行為有關。

5.3.2 抽水量推估

本研究採用兩模式推估抽水總量,模式一於類神經網路中輸入降雨量,模式二則沒有考慮降雨量。比較兩模式可以發現,降雨量對於地下水位的影響無法忽略,因此在模式一的抽水量推估中產生較大的影響(觀測無抽水但推估有抽水)。考量到雨量資料的空間不穩定性,以及未考慮較多的氣候因子,本研究嘗試單獨輸入兩個觀測井的地下水位資料來推估抽水總量,結果確實較為穩定,也降低 MAE 的誤差值。此結果亦反映出研究區中的地下水位變化,主要受到抽水影響但對降雨量相對不敏感,導因於觀測井與抽水井群距離相近。未來若欲採用氣候水文資料配合地下水文資料進行抽水量推估,地下水位觀測井之位置需與抽水井(群)有一定距離,避免位於抽水區的主要洩降錐中,造成抽水影響過大而無法加入氣候水文的觀測因子進行抽水量推估。而此觀測井與抽水井(群)之位置概念,亦可提供未來設置監測井以觀測抽水井(群)抽水量之位置參考。

六、結論

類神經網路是從資料中萃取資訊,其注重的是對於目標的預測。當資料足夠時,能夠以資料中各輸入因子建模,而且只要類神經網路的層數與資料夠多,在類神經網路內部的偏置能夠適應各項非輸入之因子。在本研究之資料補遺研究中,當用作輸入的資料有足夠的代表性時,資料補遺的結果比反距離法可靠;將之用來推估地下水位時,也可掌握推估地下水位變化之趨勢。但由於使用變化量的方式來推估地下水位,因此若進行長時間的推估會產生較大累計誤差。於抽水量推估結果,因觀測地下水位井位於抽水井群之洩降錐內,抽水量對地下水位之影響巨大而可忽略降雨與其他氣候水文因子之影響,故僅考慮地下水位與抽水量可獲得最好之推估結果。本研究於抽水量較大部份產生低估狀況,抽水量較小部分產生高估情形,未來可檢討採用因子,並選取距離抽水井群適當距離之觀測井進行

建模與分析，以改善本研究結果。本研究結果顯示，在資料量足夠多的情形下，使用類神經網路方法進行地下水位補遺與預測，以及抽水量推估是一個可行的方法。研究成果可提供研究區未來地下水位資料的補遺與預測，以及未來地下水抽水量的推估。

本研究對於水位預測的累積誤差，若使用遞迴式神經網路相關系統，由於其會在內部進行狀態的傳遞，因此能夠發現時間序列之先後關係，不失為一種可改進的方案。未來也可考慮直接對神經網路輸入地下水位的方式進行地下水位推估，也許能夠進行更長時間且穩定的推估結果。而類神經網路方法所產生的模型受限於資料的所在地，因此只要資料不全、過少，或者是模式應用到另外一個研究區，將沒有辦法適用已建立的模型而需要重新訓練，每次均需要對於該研究區中之觀測站並進行類神經網路的調整與訓練，將會十分費時。未來的研究，可著重在如何分析已訓練的類神經網路模型，將各項因子的相互關係分離，以期待未來能夠減少類神經網路方法對於資料量的依賴性。

誌謝

本文作者感謝經濟部水利署與交通部中央氣象局提供氣候水文與地下水觀測資料；感謝國立中央大學環境研究中心李奕賢博士提供 AI 技術諮詢，使本研究能順利完成。本研究並承蒙行政院科技部研究計畫經費補助(計畫編號 MOST 106-2116-M-008-023-MY3 與大專學生計畫編號 MOST 107-2813-C-008-041-M)。

符號表

符號	說明
A_k	第 k 層的激勵函數層
B_k	第 k 層的線性層置偏
D_{ji}	目標地點 j 到測量站 i 的距離平方
H_i	測量站 i 的地下水位高程
H_j	目標地 j 之推估水位高程
i	目標地點
j	各測量站(以 1、2...n 表示)
j height	目標地點 j 的地表高程
m	神經網路輸入總樣本數
W_k	第 k 至 k+1 層的全連結層
$Weight_{ij}$	從點 j 到點 i 的距離權重
X	輸入資料
X_j	已知的資料
X_i	遺失的資料
Z_k	第 k 層的線性層
α	學習速率

參考文獻

1. Chang, L., Xie, J.-C., "Prediction of Groundwater Level by Optimized Neural Network Algorithm," Transactions of the Hydro-Science and Engineering, No.4, Dec. 2005.
2. Hinton, G. E., Rumelhart, D. E., & Williams, R. J., "Learning Representations by Back-propagating Errors," Transactions of the Nature, 323(9), 533-536, 1986.
3. Hsu, N.-S., Lin, W.-T., & Chen, C.-W., "Study on Groundwater Level Forecasting in Choushui Creek Alluvial Fan Using Artificial Neural Network Approaches," Transactions of the Journal of the Chinese Institute of Civil and Hydraulic Engineering, Vol. 21, No. 3, pp. 285-293, 2009.
4. Shepard, D., "A Two-dimensional Interpolation Function for Irregularly-spaced Data," ACM, 517-524, 1968.
5. Silver, D., Huang, A., "Mastering the Game of Go with Deep Neural Networks and Tree Search," Nature, 529(27), 484-489, 2016.
6. Yesilnacar, M. I., Sahinkaya, E., Naz, M., & Ozkaya, B., "Neural Network Prediction of Nitrate in Groundwater of Harran Plain, Turkey," Transactions of the Environment Geology, 56, 19-25, 2008.
7. Zhou, Y., O. Tuzel., "VoxelNet: End-to-End Learning for Point Cloud Based 3D Object Detection," Apple Inc, Nov. 2017.
8. 王仁甫，地下水系統場置性抽水型態之辨識及其抽水量的估算，臺灣大學土木工程學研究所碩士論文，2011。
9. 王啟明，類神經網路應用於颱風暴潮之預測，國立成功大學水利及海洋工程學系碩博士班，2004。
10. 余貴坤、黃瑞德，地震前兆觀測-地下水水位分析，萬能技術學院土木系，331-333。
11. 卓惠玲，迴歸模型及類神經網路應用於地下水位資料補遺之研究，逢甲大學土地管理所，2008。
12. 林楷為，Data oriented analysis techniques for the habitat evaluations in two National Parks，國立中山大學海洋環境及工程學系研究所碩士論文，2008。
13. 洪耀明，應用三維地下水模式於颱風期間土石壩地下水位預測，明道大學綠環境設計學系，2-5, 2013。
14. 陳清田、陳儒賢、劉采蓉，支撐向量分類結合神經網路於地下水位預測之研究，國立嘉義大學與水資源工程學系，台灣首府大學休閒管理學系，國立嘉義大學土木與水資源工程學研究所，1-4，2013。

15. 黃華山、邱一薰，類神經網路預測台灣 50 股價指數之研究，國立彰化師範大學資訊管理研究所，2005。
16. 趙士儀，以主成分分析法處理定量資料缺失值問題，元智大學資訊管理研究所碩士論文，1999。
17. 經濟部水利署，氣候變遷下臺灣九大地下水資源區地下水潛能變化之研究(1/2)，財團法人成大研究發展基金會，2014。
18. 經濟部水利署，氣候變遷下臺灣九大地下水資源區地

下水潛能變化之研究(2/2)，財團法人成大研究發展基金會，2015。

收稿日期：民國 108 年 08 月 23 日

修正日期：民國 109 年 03 月 30 日

接受日期：民國 109 年 04 月 28 日