

應用深度學習方法於農業灌溉水質預測模式發展研究：以新店溪為例

Development of Agricultural Irrigation Water Quality Prediction Models Using Deep Learning Methods: A Case Study of Xindian River

國立臺灣科技大學

營建工程系

碩士生

王禧隆

Xi-Long Wang

國立中山大學

海洋環境及工程學系

助理教授

鍾秉宸

Bing-Chen Jhong

國立臺灣科技大學

營建工程系

副教授

何嘉浚

Chia-Chun Ho

摘 要

農業在國家發展中扮演著重要角色，其中農業用水水質不僅對於農作物生長與產量造成影響，亦會直接影響國民健康，因此農業用水水質的有效預測成為了具有重要意義的研究課題。而且，近年來隨著人工智慧的快速發展，全球各國針對應用人工智慧在農業相關研究上投入了大量資源。本研究針對農業灌溉水質提出了一個整合深度學習方法之水質預測模式，首先探討不同的人工智慧深度學習方法應用於水質預測模式的準確程度，並嘗試分析影響水質預測之關鍵輸入項因子。本研究以新店溪及其上游水域為實際案例，通過各觀測點的水質因子來訓練水質預測模式，並對該模式的預測能力進行評估。我們將利用多種人工智慧方法建模以評估模式準確性，並進行多次交替驗證以確保模式的穩定性及適用性。由於水質數據是區域性的特徵，本研究所提出之模式主要乃針對新店溪及其上游水域之水質進行預測，結果初步顯示人工智慧深度學習方法可有效地預測區域性水質。本研究期望提出之模式能在農業水質預測評估和未來永續發展上有所貢獻，進一步保障國民的健康和環境的可持續性。

關鍵詞：人工智慧，深度學習，農業灌溉，水質預測，新店溪

Abstract

Agriculture plays a crucial role in national development, where the quality of agricultural water not only affects crop growth and yield but also has a direct impact on public health. Therefore, effective prediction of agricultural water quality has become a significant research

topic. In recent years, with the rapid advancement of artificial intelligence (AI), countries worldwide have invested substantial resources in applying AI to agricultural research. This study proposes a water quality prediction model for agricultural irrigation water, integrating deep learning methods. First, we investigate the accuracy of different AI deep learning methods applied to the water quality prediction model and analyze the key input factors influencing water quality prediction. Using the Xindian River and its upstream waters as a case study, we train the water quality prediction model with water quality factors from various observation points and evaluate the model's predictive capabilities. We employ multiple AI methods to model and assess the accuracy, conducting cross-validation to ensure the model's stability and applicability. Given the regional characteristics of water quality data, the proposed model primarily focuses on predicting the water quality of the Xindian River and its upstream areas. Preliminary results indicate that AI deep learning methods can effectively predict regional water quality. This study aims to contribute to agricultural water quality prediction and sustainable development, further safeguarding public health and environmental sustainability.

Keywords: Artificial Intelligence, Deep Learning, Agricultural Irrigation, Water Quality Prediction, Xindian River

一、前言

農業用水的水質狀態是影響農作物生長的關鍵因素之一，其中氮氮的含量與農作物的生長息息相關。近年來，隨著人工智慧技術的迅速發展，許多研究機構開始重視其在各領域的應用。因此，本研究旨在利用人工智慧方法對氮氮含量進行預測，並期望所提出的模型能為未來水質預測與評估的發展做出貢獻。

二、研究區域

本研究區域位於台灣北部的新店溪，該河川全長約八十一公里，流域面積約為九百二十一平方公里，上游銜接北勢溪，下游則匯入淡水河。本研究針對新店溪的八個測站點資料進行分析，這些測站點分別為碧潭吊橋、中正橋、華中大橋、華江大橋、廣興橋、青潭堰以及秀朗橋，詳見表一。研究使用的資料為月尺度資料，根據測站點的不同，每個測站點包含 13 至 14 個因子，詳見表二，資料來源為台灣行政院環境部全國水質監測網¹。

表一、測站資訊

測站名稱	經度	緯度	距離源頭 (km)
廣興橋	121, 32, 50. 9	24, 54, 44. 3	56. 21

¹ 網址：<https://wq.moenv.gov.tw/EWQP/zh/Default.aspx>

直潭堰取水口	121, 31, 59.2	24, 55, 31.4	60.07
青潭堰	121, 32, 42.7	24, 56, 29.1	65.76
碧潭吊橋	121, 32, 08.9	24, 57, 39.3	68.44
秀朗橋	121, 31, 42.8	24, 59, 19.3	72.64
中正橋	121, 30, 51.2	25, 01, 16.7	77.56
華中大橋	121, 29, 46.5	25, 00, 36.7	80.16
華江大橋	121, 29, 00.6	25, 02, 05.6	83.64

三、研究方法

為了有效預測氨氮濃度，本研究在模式訓練前，首先使用相關係數（correlation coefficient, CC）進行因子篩選，詳見表二，以尋找最適合用於預測氨氮的因子。資料被分為七成訓練集與三成測試集，進行模式訓練和測試。選定的因子將作為輸入參數，並透過支持向量機（Support Vector Machine, SVM）、長短期記憶網路（Long short-term memory, LSTM）以及門控循環單元（Gated Recurrent Unit, GRU）等機器學習模型進行訓練，預測一個月後的氨氮濃度。


四、結果討論

以中正橋為例，我們從該測站的其他因子中，選取與氨氮相關係數最高的前三個因子作為輸入參數，分別為氯鹽、生化需氧量與導電度，如表二所示。圖一為選擇之參數與氨氮之趨勢變化圖。接著，將這三個因子與氨氮濃度一同作為輸入參數，利用支持向量機（SVM）模型進行建模，預測一個月後的氨氮濃度。預測結果如圖二與圖三所示。

表二、各因子與氨氮之相關係數比較


參數	CC
導電度	0.875
氯鹽	0.864
生化需氧量	0.834
化學需氧量	0.679
總磷	0.421
大腸桿菌群	0.332
總有機碳	0.293
水溫	0.070
氣溫	-0.112
懸浮固體	-0.217
酸鹼值	-0.458

溶氧(電極法)	-0.848
溶氧飽和度	-0.877




(圖一)經正規化之(a)氨氮與氯鹽(b)氨氮與導電度(c)氨氮與生化需氧量之趨勢圖


從結果中可以發現，儘管模型在訓練階段能夠部分捕捉到氨氮濃度變化的趨勢，但對於某些高點和低點的數值變化卻較難精確掌握（見圖二）。具體來說，模式在低點時傾向於高估，而在高點時則容易低估。在 45 度散佈圖中也能觀察到這一現象：當觀察值較低時，預測值往往高於 45 度線；當觀察值較高時，預測值則低於 45 度線（見圖三）。這種低值高估及高值低估的趨勢在測試階段中也表現出相似的情況（見圖四和圖五）。我們推測，這可能是因為僅依賴該測站本身的因子來預測一個月後的氨氮濃度，其效果較為有限。因此，未來的研究將聚焦於上下游各測站間因子的關聯性，以期找到更有效的預測模式。




(圖二)訓練階段之氨氮觀察值與預測值



(圖三) 訓練階段之氨氮 45 度散佈圖



(圖四)測試階段之氨氮觀察值與預測值



(圖五) 測試階段之氨氮 45 度散佈圖