

深度學習：環境資料數位化的應用

Deep Learning: Applications in the Digitization of Environmental Data

邱普運、王韻婷、林雋傑、劉佳儀、張佑文、張斐章

Pu-Yun Kow, Yun-Ting Wang, Jun-Jie Lin, Jia-Yi Liou, Yu-Wen Chang, Fi-John Chang

深度學習能精準捕捉資料中的非線性特徵和劇烈變化，實現高精度預測。本研究將其應用於多個環境議題，包括全臺灣的空氣污染、臺北市的下水道水位預測及溫室微氣候預測。空污預測使用了全臺灣環保署測站的歷史資料，涵蓋六個污染因子和兩個氣象因子，模型引入了注意力機制，成功解決傳統深度學習的梯度消失問題，顯著提升未來 72 小時的預測精度，誤差 (root-mean-square error, RMSE) 在 8.5 至 13.2 $\mu\text{g}/\text{m}^3$ 之間。在臺北市的下水道水位預測中，本研究採用了 DNN-AE 模型，能穩定預測未來 10 至 60 分鐘水位。在所有 DNN-AE 模型中，C-AE 模型在結構上更具優勢，卷積層能有效提取時間特徵，特別是在處理時間變化資料時，能捕捉更細緻的趨勢，顯著提高預測精度，誤差 (RMSE) 在 T+1 至 T+6 為 0.21 至 0.51 m，預測結果最佳且穩定。對於溫室微氣候預測，本研究使用 XGBoost 對彰化伸港各微氣候因子進行特徵篩選，分析了溫度、相對濕度和光照強度等關鍵影響因素。結果顯示影響溫度、相對濕度和光照強度的主要特徵分別為溫度、短波輻射 (日射量) 和 RH，反映了捲簾和遮蔽系統對溫室內部微氣候的影響。結果顯示，ANFIS 模型在溫度預測方面表現最佳， R^2 值超過 0.8，CNN 則在相對濕度與光照強度的預測上表現良好。綜合這些應用，臺灣的環境預測技術將能進一步推動智慧城市的發展，邁向更高階的數位化未來。

Deep learning accurately captures nonlinear features and sharp changes in data, enabling high-precision predictions. This study applies it to several environmental issues, including air pollution forecasting, sewer water level forecasting in Taipei, and greenhouse microclimate forecasting. For air pollution, historical data from the Environmental Protection Agency station from whole Taiwan, including six pollution and two meteorological factors, were used. The model's attention mechanism effectively solved the vanishing gradient problem, significantly improving 72-hour forecast accuracy, with RMSE errors ranging from 8.5 to 13.2 $\mu\text{g}/\text{m}^3$. In sewer water level forecasting for Taipei, a DNN-AE model was employed, providing stable forecasts for 10 to 60 minutes into the future. Among the models, the C-AE model demonstrated structural advantages, as its convolutional layers efficiently extracted temporal features, especially when handling time-varying data. It improved forecasting accuracy, with RMSE errors ranging from 0.21 to 0.51 meters from T+1 to T+6, yielding the most accurate and stable results. For greenhouse microclimate

forecasting in Shengang, Changhua, XGBoost was used to select features like TSF for temperature, SWI for shortwave radiation and RH for relative humidity, reflecting the effects of rolling curtains and shading systems. The ANFIS model performed best in temperature forecasting, with an R^2 value exceeding 0.8, while CNN excelled in forecasting humidity and light intensity. By integrating these applications, Taiwan's environmental forecasting technology will further drive the development of digital cities, moving towards a smarter and more advanced future.

一、深度學習與其在環境議題上之應用

隨著科技進步與大數據的崛起，人工智慧 (artificial intelligence, AI) 和深度學習 (deep learning, DL) 技術在各領域的應用日益廣泛，傳統的物理模型雖然具備一定的理論基礎，但其高昂的運算成本與複雜的參數調整，限制了即時預測的能力。與此同時，AI 技術憑藉其強大的數據處理能力與預測精度，展現出顯著的優勢，成為現代環境科學研究的重要工具。因此，本研究的應用主要的環境應用有三個議題，分別：空氣污染、地表水文及溫室微氣候預測。

1.1 空氣污染之應用

空氣污染模式主要分為大氣擴散模型以及資料驅動模型。大氣擴散模型是基於對 $PM_{2.5}$ 生成、傳輸和轉化的物理過程的深入理解，通過數學方程來描述這些過程，這種模型的優點在於具有較強的解釋性。然而，大氣擴散機制模型包含大量的參數，這些參數的校正需要大量的觀測資料和專業知識，且校正結果也難以驗證。此外，NCDR (2022) 曾指出 CMAQ 模型目前只能做到每六個小時提供一次預報，過去研究結果反映出大氣擴散機制模型的計算量巨大，需要高性能的計算器，限制了其在即時預測中的應用 (Grell et al., 2005)。大氣擴散機制模型對大氣過程的描述往往過於簡化，無法準確地捕捉大氣環境複雜的相互作用。大氣環境是一個極其複雜的系統，受到多種因素的影響，如氣象條件、排放源、地形地貌等 (Goliff et al., 2013; Zong et al., 2018)。

近年，隨著電腦硬體的突破以及監測系統的完善，更容易取得詳細的空氣污染觀測資料，為訓練深度學習模型提供了豐富的素材 (Taye, 2023)。深度學習的應用方向包括了結合不同神經網路架構的混合模型，例如卷積神經網路(convolutional neural network, CNN)、長短期記憶 (long short-term memory, LSTM) 和門控迴圈單元(gated recurrent unit, GRU)。這些模型在掌握 $PM_{2.5}$ 的時間和空間變化趨勢表現出更高的準確性 (Hu et al., 2023)。

1.2 地表水文之應用

地表水在水文循環中對人類生活至關重要，直接影響水資源管理、環境保護和城市安全，是水文學研究的核心議題之一。早期研究主要依賴物理模式，通過數學公式和物理機制模擬水從降水到地表逕流的過程，如 SWAT 模型常被用於大範圍流域的逕流和水質問題 (Arnold et al., 1998)。然而，Beven (2012) 指出，物理模式運算成本高，尤其在大規模流域模擬中，難以即時提供資料且準確度有限。研究顯示，機器學習 (machine learning, ML) 和深度學習技術在短期預測上的準確性優於傳統物理模式 (Mosavi et al., 2018)。過去，Kratzert et al. (2018) 曾用 LSTM 模型成功預測大範圍流域的河川流量。此外，AI 技術還可以與物理模式結合，進一步提升預測的準確性 (Zhang et al., 2008)。

隨著全球都市化加劇，都市防洪成為一大挑戰，因為不透水面積增加，降雨後逕流量上升，導致洪災風險上升 (Fletcher et al., 2013)。AI 技術能夠在洪水管理中結合即時數據進行準確的預測，提前發出預警，幫助決策者採取應對措施，從而減少洪災的影響。Chang et al. (2002) 指出應用混合式的機器學習及 PCA 模式對於區域淹水的議題有著顯著的效果。

1.3 溫室微氣候之應用

過往研究指出，溫室內的微氣候，如溫度、濕度和光照對作物的生長及產量有顯著影響 (Katsoulas and Kittas, 2008; Lin et al., 2024; Ma et al., 2019; Shi et al., 2024)。傳統溫室操作依賴農民經驗，難以應對微氣候短期波動，導致無法持續維持理想的生長條件。精準農業透過 IoT 設備和感測器來監測並控制環境，提升生產效率並減少環境影響 (Shafi et al., 2019; Wakchaure et al., 2023)，但高昂成本和技術接受度的問題，造成在小農經濟體中難以推廣 (Rajak et al., 2023)。因此，經濟上可行的短期預測對穩定溫室環境至關重要 (Gharghory, 2020; Kow et al., 2022; Li et al., 2024)。

目前，機器學習已在溫室微氣候預測方面取得進展。Li et al. (2024) 提出了基於注意力機制的 LSTM 方法來準確預測溫室內空氣和土壤溫度。Kow et al. (2024a) 提出混合深度學習模型，不須使用 IoT 資料即可用於多時間稽延和多因子預測。Sun and Chang (2023) 則開發了 DF-RF-ANN 混合模型，利用動態因子模型和倒傳遞類神經網路預測微氣候變化，幫助小農應對極端氣候，以達成永續發展目標 (SDGs)。

二、研究方法

2.1 深度學習與類神經網路

深度學習是機器學習的子領域，模仿人類大腦的結構和功能進行資料分析與決策，其基礎是類神經網路，由多層神經元組成，每層神經元接收前一層輸入，經過處理後傳遞至下一層，這種多層結構使深度學習具備強大的特徵學習能力。深度學習的優勢在於自動從大量資料中提取高層次特徵，於圖像識別、語音辨識、自然語言處理等領域表現出色。相比傳統機器學習，深度學習減少人工特徵萃取，能藉由大量資料自我優化，提升預測準確性和泛化能力。

2.2 注意力機制類神經網路

本研究提出了一種基於注意力機制 (attention) 的模型，注意力機制為 ChatGPT 的核心模型，已開始被應用在不同的環境議題 (Kow et al., 2024a; Sun et al., 2024)。注意力機制層的特點在於，每個變數都會生成對應的查詢向量 (query)、鍵向量 (key) 和數值向量 (value)。其中，query 的作用是匹配其他變數生成的 key，進而計算出一個初始的注意力分數，本文將其命名為矩陣「a」，a 矩陣會與 value 相乘，最終得出注意力機制的分數 (attention score)。注意力機制的主要功能是學習各個輸入變數之間的關聯性，以克服 LSTM 模型只能學習單一序列時間變化的問題。

2.3 卷積神經網路

卷積神經網路 (CNN) 屬於深度學習中一種常見的監督式前饋網路，網路架構主要包含卷積層 (convolutional layer)、池化層 (pooling layer) 與全連結層，CNN 透過卷積層萃取輸入

數據的局部特徵，再以池化層壓縮特徵以降低維度，可避免全連接層中參數過多、過度擬合的問題，經過反覆卷積與池化運算後，可建立 CNN 模式擷取特徵後的資訊與輸出值間的非線性關係，因此在圖像分類領域被廣泛應用 (Kow et al., 2022b)。本研究將使用 CNN 模式於時間序列資料，透過卷積層擷取資料的時間特性。

2.4 長短期記憶體類神經網路

長短期記憶體 (LSTM) 是一種著名的回饋式神經網路 (recurrent neural network, RNN)，其特點是能夠將過去的資訊回饋至模型的訓練過程中，以提升預測的精度 (Zhou et al., 2019; Kow et al., 2024b)。LSTM 包括三個關鍵的閥門：輸入閥門、遺忘閥門和輸出閥門，這三個閥門使 LSTM 能夠模擬具有記憶能力的神經網路，同時擁有長期和短期記憶的特性。

2.5 自編碼器

自編碼器 (autoencoder, AE) 是一種非監督式學習模型，可以分為編碼器 (encoder) 與解碼器 (decoder) 兩個部分，編碼器可以萃取資料的特徵，將資料轉換為低維度編碼，解碼器則負責將這些編碼重建還原為原始數據，AE 的目標是使還原後的數據與原始數據盡可能相似，常用於數據降維、特徵學習和數據去噪。過去研究曾應用 AE 模式對高維度的水文資料進行降維度之後，輸入到 LSTM 模式進行多時刻預測 (Kao et al., 2020; Kao et al., 2021)。

2.6 調適性網路模糊推論系統

調適性網路模糊推論系統 (adaptive network fuzzy inference system, ANFIS) 是基於模糊推論系統 (fuzzy inference systems, FIS) 的架構，結合類神經網路自我組織的特性來自動調整模糊規則參數 (Jang, 1993)。FIS 使用模糊化的 IF-THEN 規則來描述和分析人類推理過程，而 ANFIS 通過學習功能解決實際應用中規則設計和參數調整的問題。ANFIS 分為 5 層：第一層將輸入變數映射到模糊集合；第二層根據模糊集合進行運算；第三層正規化輸出；第四層進行推論；第五層綜合輸出結果 (Kow et al., 2023; 張斐章 and 張麗秋, 2015)。

2.7 eXtreme Gradient Boosting (XGBoost)

XGBoost 基於 Gradient Boosting，並增加了特徵隨機採樣、正則化以及並行處理等特點，進一步提升模型的性能和穩定性 (Chang et al., 2023)。透過增益 (gain)、覆蓋率 (cover) 和頻率 (frequency) 三種方式對輸入特徵進行評分和排序，能有效的篩選特徵，以解決研究中輸入特徵過多的問題，提升後續預測模型的演算效率 (Li et al., 2022; Osman et al., 2021)。

2.8 誤差指標

本研究使用決定係數 (R^2) 和均方根誤差 (RMSE) 作為模型性能指標，並引入平均絕對誤差 (MAE)，進一步評估模型的預測能力。其中，當 R^2 數值越接近 1，表示模型能夠更有效地捕捉目標資料的變化，說明模型具有較高的解釋力，反之靠近 0 為表現越糟糕。MAE 可衡量預測值與實際值之間的平均絕對差異，數值越接近於 0 表明預測值與真實值越接近。相較於 RMSE，MAE 不會放大極端誤差的影響，因此適合用於評估模型在整體上的預測穩定性；而 RMSE 由於有平方項，因此會把誤差較大的地方放大。綜合 R^2 、RMSE 和 MAE 這三個指標，可以更全面且客觀地評估模型的解釋力和預測準確性。

三、各問題的資料敘述以及對於深度學習的應用成果

3.1 空氣污染

(a) 資料統計與所應用到的模式架構圖

本研究的研究區域為全臺灣的空氣污染測站，共有 76 個測站。為了要更方便探討模式在各個區域的精確度，本研究將模式的表現分成四個區域比較討論。圖 1 顯示各區域空氣污染的資料統計結果，從統計結果可以觀察到，臺灣南部區域的 $PM_{2.5}$ 濃度最高且污染物變化很劇烈，其次為中部，這是因為中部與南部有大面積的重工業區以及火力發電廠，因此造成了嚴重的空氣污染；北部的 $PM_{2.5}$ 濃度排在中間，該區域主要為商業區， $PM_{2.5}$ 多來自於人為污染排放或是汽機車排放；東部則是以旅遊業為主且較少人類活動，因此空氣污染排放為全臺灣最低。




圖 1. 臺灣四個區域 $PM_{2.5}$ 統計值 (a) 平均值 (b) 標準差 (c) 下四分位數 (d) 上四分位數。

本研究所使用的模式架構如圖 2 所示，注意力機制模型的架構是由數層注意力層的模式所組成。模型的輸入為過去 72 小時的資料，包含空氣污染使用組成 AQI 指標的六個主要因子 (如： $PM_{2.5}$, PM_{10} , O_3 , NO_2 , SO_2 , CO)，以及兩個氣象因子 (溫度與相對濕度)，模型的輸出為未來 72 小時預測 $PM_{2.5}$ 的濃度。

(b) 空氣污染預測成果

圖 3 顯示了空氣污染的預測結果，本研究比較了注意力機制 (attention) 模型以及長短期記憶體 (LSTM) 模型的預報。Attention 模型的誤差比 LSTM 模型更小，證明了它可以有效地從不同時距的資料學習到非線性的關聯性，因此克服了深度學習所造成的梯度消失問題，提升了模式的預測精度。若比較訓練與測試的預測結果可以看出，整體而言測試的誤差比訓練更高，隨著預測時距越長 (從 $T+1$ 至 $T+72$)，誤差越大，這是因為模式的不確定性會提




圖 2. 模型架構流程圖。

升。比較不同區域的預測結果，顯示南部的誤差最大，其次為中部及北部，東部的誤差為全臺最小。誤差的表現與 3.1(a) 章節的統計結果有高度的相關性。其中，圖 3(c) 及 (d) 顯示，當 $PM_{2.5}$ 的平均值與標準差越高，模式的預測不確定性也越高，因此造成誤差越大，二者之間的相關性介於 $R^2 = 0.6$ 至 0.99 。




圖 3. 臺灣四個區域 $PM_{2.5}$ 空氣污染預測誤差 (RMSE) 的結果 (a) 訓練 (b) 測試 (c) 訓練表現 (d) 測試表現與觀測值之回歸關係。

3.2 雨水下水道水位

(a) 研究區域與資料收集

臺北市受到盆地地形的影響，在冬季周圍的山地與丘陵容易形成地形雨，而夏季則因為上升氣流旺盛，經常出現午後雷陣雨與颱風，近年來受到氣候變遷的影響，短延時強降雨越趨頻繁，雨量容易超過雨水下水道設計保護標準 (每小時 78.8 毫米)，導致低窪地區因排水不及而發生淹水災情。因此，針對雨水下水道水位之研究，選定臺北市的圓山、中山、新生與建國抽水站集水區為研究區域，總面積為 1981 公頃，涵蓋大同、中山、松山與大安等

行政區，四個抽水站集水區之排水系統皆排入基隆河。整體而言，研究區域地形平坦，僅新生、建國集水區上游地區與圓山集水區部分地區地勢較高。透過臺北市政府資料開放平台 (<https://data.taipei/index>) 網頁蒐集研究區域周邊雨量站共 11 站與雨水下水道水位站共 19 站，分布位置如圖 4 所示。




圖 4. 雨水下水道水位研究區域圖。

(b) 雨水下水道水位預報成果

本研究結合自編碼器 (AutoEncoder, AE) 與深度神經網路 (deep neural network, DNN) 提出新穎的深度學習模型 (DNN-AE)，AE 能有效降維高維度資料，而 DNN 能在降維後的特徵中進行更高精度的預測，這種結合能顯著減少計算資源並提高預測準確性，使用 DNN-AE 模式建立下水道水位多時刻預測模式，整體架構示意圖如圖 5 所示，首先以 AE 模式建置下水道水位降維還原模式，AE 模式之 encoder 部分可將 19 站的下水道水位資料降維成編碼 (code)，再使用 DNN 針對降維後的下水道水位特徵編碼建立預測模式，將以 CNN、BPNN 與 LSTM 分別建模，輸入資料皆使用研究區域周邊 11 個雨量站前時刻的雨量資料 (T-3-T)

與特徵編碼 (T-6-T)，以進行未來時刻各特徵編碼之預測，最後將所預測之特徵值套配至 AE 模式之 decoder 部分，即可進行未來 10 (T+1) 到 60 分鐘 (T+6) 的水位預測，並比較三種模式之預測結果。




圖 5. 雨水下水道水位預測模式架構圖。

特徵編碼預測模式 CNN、BPNN 與 LSTM 結合下水道水位降維還原 AE 模式，組合成三個 DNN-AE 模式，分別為 C-AE、B-AE 與 L-AE 模式。將 19 站下水道水位之未來 10 (T+1) 到 60 分鐘 (T+6) 預測，計算各模式平均下水道水位預測結果列於表 1，由 T+1 至 T+6 之 RMSE 結果可以發現，C-AE 與 B-AE 模式隨著預測時距越長 RMSE 有逐漸變大的勢，RMSE 介於 0.21 至 0.51 m 之間，有較穩定之預測結果，而 L-AE 模式之 RMSE 在 T+1 至 T+6 數值呈現大小不穩定變動之情形，RMSE 介於 0.24 至 0.54 m 之間，顯示 L-AE 預測結果較差且不穩定；比較訓練與測試結果可以發現，在訓練階段 B-AE 較 C-AE 模式之 RMSE 小約 0.02 m，在測試階段時則是 C-AE 比 B-AE 模式預測結果稍微好一些，且隨著預測時距

越長 C-AE 與 B-AE 模式之預測結果差異越明顯，由此可以得知 C-AE 模式，因為有卷積層擷取連續時間特徵，使長時間預測仍有較佳且穩定的表現；而 B-AE 模式由於全連結層的架構，在訓練時權重充分學習輸入與輸出間的關係，但在測試時有過度擬合的情況。圖 6 為測試階段 C-AE 模式於新生 10 下水道水位站 T+1 之預測結果，可以看出 C-AE 模式能夠掌握水位的變化趨勢，僅在峰值有些微提早延後的情況。

表 1. 平均下水道水位預測結果比較。

評估指標	預測時距	訓練			測試		
		C-AE	B-AE	L-AE	C-AE	B-AE	L-AE
RMSE (m)	T+1	0.47	0.45	0.47	0.22	0.21	0.30
	T+2	0.48	0.46	0.49	0.23	0.26	0.24
	T+3	0.49	0.46	0.54	0.25	0.24	0.45
	T+4	0.50	0.47	0.52	0.25	0.29	0.24
	T+5	0.50	0.47	0.49	0.26	0.31	0.28
	T+6	0.51	0.48	0.51	0.26	0.33	0.46




圖 6. 新生 10 下水道水位站 T+1 測試階段預測結果序列圖。

3.3 溫室微氣候預報

(a) 研究區域與資料

研究區域位於彰化伸港的一座強固型開頂溫室，設備包括內遮蔭、四面捲簾和屋頂。本研究使用了三個資料集，分別是中央氣象署 (Central Weather Administration, CWA) 提供的網格天氣預報資料 ($3 \times 3 \text{ m}^2$)、溫室操作資料和溫室內部 IoT 記錄，資料收集期間為 2020 年 4 月 1 日至 10 月 16 日，本研究將所有資料時間尺度統一為 1 小時。以 CWA 網格預報資料及溫室操作資料，預測未來 3 小時溫室內的氣象條件，包括溫度 ($^{\circ}\text{C}$)、相對濕度 (%)、光照強度 (W/m^2)。

本研究旨在找出最適合溫室微氣候預測的模型，由於模型輸入數據種類繁多，且搭配時間稽延數據，導致模型運算成本增加，因此先使用 XGBoost 進行初步特徵篩選，以提高模型效率。本研究選用了卷積神經網路 (CNN)、長短期記憶網路 (LSTM) 和自適應神經模糊推理系統 (ANFIS) 進行溫室內微氣候的預測。CNN 擅長提取空間特徵，LSTM 在時間序列數據處理上表現優異，而 ANFIS 則能有效處理數據中的不確定性。這些模型的性能通過對比分析，找出最適合溫室微氣候預測的最佳模型，以應對溫室內部環境調節的需求。

(b) 溫室微氣候預報成果

表 2 顯示 XGBoost 對各目標因子篩選出的前八個特徵，篩選方式是對各特徵進行時間稽延 (T~T-2) 評分，並加權排名得出結果。其中氣象因子包含表面溫度 (temperature surface, TSF)、蒸氣壓差 (vapor pressure deficit, VPD)、短波輻射 (short wave incoming radiation, SWI)、相對濕度 (relative humidity, RH) 及長波輻射 (longwave outgoing radiation, LWO)，TSF 是影響作物生長與產量的關鍵；而 VPD 及 RH 則與作物蒸散率相關，影響水及養分的傳輸；SWI 則直接反映了日照的強弱；LWO 則反應從溫室內部釋出的長波輻射能量。

此外，篩選結果顯示，預測主要受到相同物理意義的 CWA 資料影響，例如 TSF 是預測溫度的關鍵因子，而 SWI 對相對濕度的預測表現尤其重要；從操作層面來看，北部下捲簾對調節微氣候有較高的影響力，推測其遮蔽效果和氣流控制能力較強。篩選結果也顯示，捲簾比內遮蔭及天窗更重要，以上篩選結果皆符合物理意義和常理推斷。

表 2. 因子篩選結果。

溫度	相對濕度	光照強度
TSF 溫度	SWI 短波輻射	RH 相對濕度
VPD 蒸氣壓差	RH 相對濕度	VPD 蒸氣壓差
北下捲簾	北下捲簾	LWO 長波輻射
南下捲簾	南下捲簾	SWI 短波輻射
北上捲簾	南上捲簾	北下捲簾
南上捲簾	天窗	南上捲簾
內遮蔭	內遮蔭	內遮蔭

由表 3 所示，各模式在溫室微氣候皆有不錯之預測能力，其中又以光照強度 (photosynthetically active radiation, PAR) 較為優異，其原因為光照強度受到日照影響，使得資料特性較為規律，模式較能捕捉其特徵及關連性。以 R^2 為評鑑標準，ANFIS 表現皆於 0.8 以上，能夠說明其模糊規則庫功能優勢，其結構相對另外兩種模式來的簡單，能夠有較好之穩定性。以 MAE 為評鑑指標，CNN 除溫度資料外，其他兩項目標因子皆有較好之表現，說明卷積層擷取重要特徵之優點。

表 3. 各模式 T+1 預測結果。

氣象因子	模式	R2	MAE
溫度(°C)	CNN	0.75	2.50
	LSTM	0.83	2.37
	ANFIS	0.85	1.64
相對濕度(%)	CNN	0.75	6.87
	LSTM	0.70	7.49
	ANFIS	0.80	6.94
光照強度(W/m ²)	CNN	0.97	33.13
	LSTM	0.97	35.54
	ANFIS	0.96	49.06

四、結論

本研究應用深度學習技術於空氣污染、雨水下水道水位及微氣候預測，成功證明了AI模型在這些環境議題中的應用潛力，為數位化城市發展提供關鍵技術支持，加速智慧城市建設進程。透過注意力機制、自編碼器與卷積模型。本研究顯示，無論是空氣污染預測、下水道水位預測，還是微氣候預測，深度學習技術都能有效捕捉非線性關聯。特別是在多變的氣象和環境條件下，這些技術展現出在不同環境議題中的適應性和通用性。相較於傳統的物理模型，深度學習能更好地處理非線性數據關係，並具備更高的預測精度與實用性。

對於 $PM_{2.5}$ 的預測，本研究主要貢獻在於提出應用注意力機制模型。結果顯示，該模型在不同區域和季節的預測準確度均優於傳統基準模型。在雨水下水道水位預測中，應用了自編碼器成功降低數據維度，並利用 C-AE 模型進行高精度的水位預測，有助於減災防洪管理。針對溫室微氣候預測方面，XGBoost 篩選出的特徵符合物理意義，並能有效應用於溫室微氣候的預測。ANFIS 模型在穩定性上具有優勢，CNN 則擅長捕捉重要特徵，這些結果為未來溫室環控提供了參考。

未來研究可考慮在模型中引入更多氣象和環境變數，以提升預測準確度，並擴展至不同城市或區域進行驗證，評估模型的普適性與穩定性。針對極端天氣的即時預測技術和預警系統也需進一步優化，以應對更加複雜的氣候挑戰。同時，結合其他機器學習模型進一步提升預測的精度與穩定性。開發能適應不同環境變化的自適應模型，並將預測結果與自動控制系統結合，實現即時的環境調節。同時，研究氣候變遷對環境資料的長期影響，調整模型以應對未來更極端的氣候條件，是未來的重要發展方向。

參考文獻

1. Arnold, Jeffrey G, et al., *Journal of the American Water Resources Association*, **34** (1), 73 (1998).
2. Beven, Keith J. *Rainfall-Runoff Modelling: The Primer*. John Wiley & Sons, (2012).
3. Chang, Li-Chiu, Jia-Yi Liou, and Fi-John Chang, *Journal of Hydrology*, **612**, 128086 (2022).
4. Chang, Fi-John, Li-Chiu Chang, and Jui-Fa Chen, *Water*, **15** (10), 1846 (2023).
5. Fletcher, Tim D, Herve Andrieu, and Perrine Hamel, *Advances in water resources*, **51**, 261 (2013).
6. Gharghory, S. M., *International Journal of Computational Intelligence and Applications*, **19** (2), 18 (2020).
7. Goliff, Wendy S, William R Stockwell, and Charlene V Lawson., *Atmospheric Environment*, **68**, 174 (2013).
8. Grell, Georg A, et al., *Atmospheric environment*, **39** (37), 6957 (2005).
9. Hu, Juntao, et al., *Air Quality, Atmosphere & Health*, **16** (4), 857 (2023).
10. Jang, J-SR., *IEEE transactions on systems, man, and cybernetics*, **23** (3), 665 (1993).
11. Kao, I-Feng, et al., *Journal of Hydrology*, **583**, 124631 (2020).
12. Kao, I-Feng, et al., *Journal of Hydrology*, **598**, 126371 (2021).
13. Katsoulas, Nikolaos, and Constantinos Kittas, *The European Journal of Plant Science and Biotechnology*, **2** (1), 31 (2008).
14. Kow, Pu-Yun, et al., *Expert Systems with Applications*, **210**, 118481 (2022).
15. Kow, Pu-Yun, et al., *Environmental Pollution*, **306**, 119348 (2022).
16. Kow, Pu-Yun, et al., *Bioresource Technology*, **369**, 128412 (2023).
17. Kow, Pu-Yun, et al., *Science of The Total Environment*, **927**, 172246 (2024).
18. Kow, Pu-Yun, et al., *Journal of Environmental Management*, **351**, 119789 (2024).
19. Kratzert, Frederik, et al., *Hydrology and Earth System Sciences*, **22** (11), 6005 (2018).
20. Li, Hongfei, et al., *Methods*, **204**, 215 (2022).
21. Li, X. X., et al., *Computers and Electronics in Agriculture*, **217**, 13 (2024).
22. Lin, Y. S., et al., *Horticulturae*, **10** (3), 19 (2024).
23. Ma, D. D., et al., *Computers and Electronics in Agriculture*, **162**, 134 (2019).
24. Mosavi, Amir, Pinar Ozturk, and Kwok-wing Chau. *Water*, **10** (11), 1536 (2018).

25. NCDR. "National Report on Disaster Risk Reduction." Ed. National Science and Technology Center for Disaster Reduction, Taiwan (2022).
26. Osman, Ahmedbahaaldin Ibrahim Ahmed, et al., *Ain Shams Engineering Journal*, **12** (2), 1545 (2021).
27. Rajak, Prem, et al., *Journal of Agriculture and Food Research*, **14**, 100776 (2023).
28. Shafi, U., et al., *Sensors*, **19** (17), (2019).
29. Shi, Dongyuan, et al., *Agronomy*, **14** (2), 254 (2024).
30. Sun, Wei, and Fi-John Chang, *Water*, **15** (20), 3548 (2023).
31. Sun, Wei, Li-Chiu Chang, and Fi-John Chang, *Journal of Hydrology*, **636**, 131250 (2024).
32. Taye, Mohammad Mustafa, *Computers*, **12** (5), 91 (2023).
33. Wakchaure, Manas, B. K. Patle, and A. K. Mahindrakar, *Artificial Intelligence in the Life Sciences*, **3**, 100057 (2023).
34. Zhang, Xuesong, Raghavan Srinivasan, and Michael Van Liew, *Transactions of the ASABE*, **51** (6), 2039 (2008).
35. Zong, Ruihan, et al., *Atmospheric Environment*, **186**, 144 (2018).
36. Zhou, Yanlai, et al., *Journal of cleaner production*, **209**, 134 (2019).
37. 張斐章, 張麗秋, 類神經網路導論：原理及應用, 滄海圖書資訊股份有限公司, (2015).

作者簡介

邱普運先生為國立臺灣大學生物環境系統工程所博士，現為國立臺灣大學生物環境系統工程所博士後研究員。

Pu-Yun Kow received his Ph.D. in Bioenvironmental Systems Engineering from National Taiwan University. He is currently a Postdoctoral Researcher in the Department of Bioenvironmental Systems Engineering at National Taiwan University.

王韻婷小姐現為國立臺灣大學生物環境系統工程所博士生。

Yun-Ting Wang is currently a Ph.D. student in the Department of Bioenvironmental Systems Engineering at National Taiwan University

林雋傑先生現為國立臺灣大學生物環境系統工程所碩士生

Jun-Jie Lin is currently a M.S. student in the Department of Bioenvironmental Systems Engineering at National Taiwan University

劉佳儀小姐為國立臺灣大學生物環境系統工程所碩士，現為國立臺灣大學生物環境系統工程所研究助理。

Jia-Yi Liou received her M.S. in Bioenvironmental Systems Engineering from National Taiwan University. She is currently a Research Assistant in the Department of Bioenvironmental Systems Engineering at National Taiwan University.

張佑文先生為國立臺灣大學生物環境系統工程所碩士，現為國立臺灣大學生物環境系統工程所研究助理。

Yu-Wen Chang received his M.S. in Bioenvironmental Systems Engineering from National Taiwan University. He is currently a Research Assistant in the Department of Bioenvironmental Systems Engineering at National Taiwan University.

張斐章先生為美國普渡大學土木所博士，現為國立臺灣大學生物環境系統工程所特聘教授。

Fi-John Chang received his Ph.D. in Civil Engineering from Purdue University. He is currently a Distinguished Professor in the Department of Bioenvironmental Systems Engineering at National Taiwan University.