

AI 雷達定量降雨估計技術發展：XGBoost 模型建置與應用

廖信豪、黃紹欽、于宜強

國家災害防救科技中心 氣象組

摘要

近年來，短延時強降雨事件日益頻繁，提升雷達定量降雨估計 (Quantitative Precipitation Estimation, QPE) 的準確度已成為防災監測的重要課題。本研究採用 XGBoost 模型架構，整合 2017 至 2024 年之雷達與雨量觀測資料進行訓練，建立 AI-QPE 模型，並以 2025 年颱風和梅雨共 9 場降雨事件進行校驗。結果顯示，AI 模型在時雨量 20 毫米以下具有較佳的準確度，其偏差與均方根誤差均優於現行作業化雷達 QPE 方法。但隨降雨強度提升，現行雷達 QPE 則具備較穩定且準確的雨量估計表現。目前，AI-QPE 自動化作業模組已建置完成，並於天氣與氣候監測網(WATCH)提供即時服務，每 10 分鐘更新降雨估計產品，可作為降雨監測、防災決策及災害應變之重要參考。

一、前言

短延時強降雨的發生頻率在近年有越來越高的趨勢。這種又強又

急的極端降雨，影響範圍集中，短短幾小時內就可能降下破百毫米的雨量，導致都會區常因排水不及而引發積淹水災情發生。在山區，則易有崩塌或土石流等災害出現。因此，如何更快速、精確地掌握強降雨區的發展與移動趨勢，已成為防災預警的重要課題。

氣象雷達具備高時空解析度，能即時捕捉大氣中對流系統的最新位置與發展，若能利用雷達資料即時估算降雨範圍與強度，即可作為氣象監測、水文模擬及水資源管理的重要依據。其中，雙偏極化雷達不僅能偵測空中雨滴的形狀、大小與數量，亦可透過差異反射率 (Differential reflectivity, Z_{DR}) 與比差異相位差 (Specific differential propagation phase shift, K_{DP}) 等雙偏極化參數來提升降雨估計的精確度，強化降雨監測能力。然而，此種降雨估計方法仍需依賴經驗統計關係式，在複雜氣候與地形環境下易產生系統性誤差，也難以充分利用雷達提供的大量、多維度觀測資訊。

近年來，人工智慧 (Artificial Intelligence, AI) 的快速發展，為雷達 QPE 帶來新的突破。相較於傳統物理方法，AI 模型能從大量歷史觀測資料中，學習降雨與多種雷達參數之間的非線性關係，不僅能提升 QPE 的準確度 (Orellana-Alvear et al., 2019)，對於短延時強降雨及複雜地形造成的降雨誤差亦有最佳的改善能力，使其成為智慧氣象與防災

預警的未來發展方向，能為即時災害應變與水資源管理提供更可靠的決策資訊。

二、 極端梯度提升法(eXtreme Gradient Boosting, XGBoost)介紹

目前 AI 應用於降雨估計的方法相當多元，但不同演算法會因資料特性與應用需求而有各自的優勢，其中以隨機森林(Random Forest, RF)與卷積神經網路(Convolutional Neural Network, CNN)為較具代表性的 AI 模型。許多研究指出，RF 已被證實能有效處理高維度、多來源及複雜地形資料，具有良好的特徵學習與穩定的預測能力(Yang et al., 2017a; Wolfensberger et al., 2020; Hassan et al., 2022)。CNN 等深度學習方法，則擅長自動擷取時空特徵，適用於強對流系統與三維雷達資料的降雨估計(Zhang et al., 2021; Wen et al., 2024; Chen et al., 2023b)。

對氣象雷達資料而言，因具備高維度、多變量及巨量樣本等特性，AI 模型除了需有良好的非線性學習能力外，亦須兼顧預警準確度、運算效率及泛化能力。有鑒於此，本研究選擇與 RF 同屬樹狀集成學習架構、但更具平行運算效率與泛化能力的 XGBoost，作為 AI-QPE 之模型核心。由於 XGBoost 能有效整合多項雷達觀測參數，學習各項特徵與降雨量之間複雜的非線性關係，並透過正則化(Regularization)機制降低過度擬合風險，可在兼顧預測準確度、運算

效率及模型泛化能力皆有良好的表現，近年已廣泛應用於雷達 QPE 及強降雨預警研究(Gagne et al., 2019; Chen et al., 2024)。

XGBoost 的核心概念是透過梯度提升(Gradient Boosting)技術建構樹狀集成模型(Tree Ensemble Model，圖 1)。模型由多棵決策樹(Decision Trees)組成，並在訓練過程中採循序建樹的方式，以每一輪模型的預警誤差(殘差)作為下一棵決策樹的學習目標，逐步修正前一輪的結果，使模型持續逼近真實雨量。以圖 2 為例，模型首先以初始預測值(Base Score)作為起點，利用各雷達參數與其它氣象特徵建立第一棵決策樹，再根據模型預警與實際降雨量之間的殘差建立新的決策樹，經過反覆修正預警誤差，進而提升模型的精確度。




圖 1. XGBoost 樹狀集成模型概念圖(圖片摘自 Chen and Guestrin, 2016)。

在模型預警階段，輸入的特徵資料會依序通過所有已建立的決策樹，每棵樹根據分枝條件將樣本指派至對應的葉節點(LeafNode)，並

輸出一個預警分數。最後，XGBoost 會將所有決策樹的預警結果依據學習率(Learning Rate)作權重累加，形成最佳的降雨估計值。




圖 2. XGBoost 範例圖。

三、 XGBoost 訓練流程

圖 3 為本研究 AI-QPE 模組(基於 XGBoost 架構)之研發流程。在模型建置過程中，本研究以 2017 至 2024 年之雷達與雨量觀測資料建立訓練集，輸入特徵包含地面測站雨量資料、雷達觀測參數(雷達回波強度、垂直液態水含量(Vertically Integrated Liquid, VIL)、回波頂高(Echo Tops)，以及測站地理資訊(高程與經緯度)。此外，為反映降雨系統的時間演變，每筆樣本除使用當下觀測資訊外，另納入前 1 小時內每 10 分鐘更新一次的雷達觀測，共計 7 個時間序列特徵，使模型

能同時學習降雨系統的發展趨勢與時間連續性，進一步提升短延時降雨估計能力。



圖 3. XGBoost 雷達定量降雨估計模組訓練流程。

在模型訓練階段，本研究採用 5-fold 交叉驗證(5-fold Cross Validation)進行訓練、驗證與超參數最佳化。交叉驗證將訓練資料分為五個子資料集，每次只選取其中一組作為驗證資料，其餘四組作為訓練資料，重複進行五次訓練，以降低資料切分造成的隨機誤差與提升模型評估結果的可靠性。模型訓練皆以均方誤差(Mean Squared Error, MSE)作為主要損失函數與評估指標，透過最小化預測雨量與實際觀測雨量之間的誤差，建立最佳化的降雨估計模型。

為進一步提升模型效能及超參數搜尋效率，本研究導入 Optuna 超參數最佳化工具，針對 XGBoost 模型的重要參數進行搜尋，包括決策樹數量(Number of Trees)、決策樹最大深度(Max Depth)、學習率

(Learning Rate)、子樣本比例(Subsample)、特徵抽樣比例(Colsample)及正則化相關參數等。Optuna 主要透過貝葉斯最佳化(Bayesian Optimization)策略，根據前次搜尋結果動態調整搜尋方向，可在有限的運算時間內快速尋找最佳參數組合。本研究最終獲得最佳模型參數，包括 950 棵決策樹、0.065 的學習率及 10 層樹深度，交叉驗證最佳的均方誤差為 4.5502，顯示模型具有良好的收斂能力與訓練表現。

完成模型訓練與最佳化後，本研究利用 2025 年觀測資料作為獨立測試集進行驗證，並採用多元統計指標綜合評估方式，客觀評估模型面對未知的降雨系統時的預估能力與泛化表現。測試結果顯示，XGBoost 模型在預測趨勢與絕對誤差上皆有良好表現(表 1)，其相關係數(Correlation Coefficient, CC)為 0.8757，顯示模型能精準捕捉降雨系統之時空演變特性；均方誤差為 4.9280，且相對平均誤差(Relative Mean Error, rME)為 0.0543，代表模型具備良好的預測準確度。此外，Nash-Sutcliffe 效率係數(Nash-Sutcliffe Efficiency, NSE)為 0.7648，證實 AI-QPE 模型具備極高的預估效率與可信度。

表 1. XGBoost 模型各項評估指標。

縮寫	英文全名	中文名稱
MAE	Mean Absolute Error	平均絕對誤差
衡量預測值與觀測值之間絕對誤差的平均值，數值越小表示預測越準確		
MSE	Mean Squared Error	均方誤差
越小越好，對較大的誤差較為敏感，常作為模型訓練的損失函數		

CC	Correlation Coefficient	相關係數
越接近 1 越好，表示預測與觀測具有高度相關性		
NSE	Nash–Sutcliffe Efficiency	納許–蘇特克利夫效率係數
越接近 1 表示模型表現越佳，通常大於 0.75 即代表模型具有良好的預測能力		
rME	Relative Mean Error	相對平均誤差
越接近 0 越好，可判斷是否存在系統性高估或低估		
rRMSE	Relative Root Mean Square Error	相對均方根誤差
越小越好，可比較不同資料集的相對誤差		
Slope	Regression Slope	迴歸斜率
理想值為 1，小於 1 通常表示強降雨有低估傾向，大於 1 則表示高估傾向		
R ²	Coefficient of Determination	決定係數
越接近 1 越好，表示模型解釋能力越高		

四、 實際個案校驗分析與即時展示圖臺建置

為校驗 AI-QPE 模型於實際降雨事件中的表現，本研究篩選 2025 年時雨量大於 40 毫米的 9 場強降雨事件作為校驗個案(表 2)。此外，為評估模型於不同區域與降雨強度下的估計能力，將全臺分成北部(基隆、臺北、新北、桃園、新竹、苗栗)、中部(臺中、彰化、雲林、南投)、南部(嘉義、臺南、高雄、屏東)，以及東部(宜蘭、花蓮、臺東)，並依據觀測雨量將校驗區間分成小雨(0.5-10mm)、中雨(10-20mm、20-30mm)及大雨(30-40mm、40mm 以上)等雨量區間。同時，針對平地與山區進行系統性的精確度分析與評估。除評估 AI-QPE 模型的精確度表現外，本研究亦將校驗結果與現行作業化的雙偏極化 QPE 結果作比較，從不同降雨強度下的估計能力進行綜合評估，以探討 AI 和傳統物理方法在雷達定量降雨估計的優勢與災害預警的適用性。

表 2. 2025 年颱風和梅雨降雨事件校驗個案列表。

颱風個案 (5 場)	梅雨個案 (4 場)
6 月 11-13 日，熱帶性低氣壓	5 月 5-8 日
7 月 4-9 日，丹娜絲	5 月 9-12 日
7 月 17-20 日，薇帕	5 月 23-25 日
7 月 23-26 日，范斯高與竹節草	6 月 2-6 日
8 月 12-15 日，楊柳	

在颱風個案分析中，整體降雨(大於 0.5 毫米；圖 4a)結果顯示，AI 降雨估計於全臺各區域皆具有較佳的誤差表現，其偏差大多在 ± 1 毫米內，均方根誤差多優於雙偏極化方法。相較之下，雙偏極化降雨估計呈現高估、誤差略高於 AI 模型。不同降雨強度的分析則顯示，在小雨事件(圖 4b)中，AI 模型仍維持較佳表現，各區域的偏差多介於 0 至 1 毫米間，均方根誤差亦相對較低，代表 AI 模型能有效掌握弱降雨特性，而雙偏極化 QPE 則仍有高估情形。

當降雨強度提升至中雨(圖 4c)等級時，兩種方法開始呈現不同特性。在 10~20 毫米區間，兩者的誤差表現類似，偏差多維持於 ± 4 毫米內，均方根誤差低於 8 毫米。然而，在 20~30 毫米區間，AI 模型隨降雨強度增加有低估現象，偏差約介於-2 至-8 毫米，均方根誤差約為 10 毫米。相比之下，雙偏極化方法仍維持穩定的估計能力，其偏差控制在 ± 2 毫米內，均方根誤差低於 8 毫米，逐漸展現較佳的估計

表現。到了大雨階段(圖 4d)，雙偏極化 QPE 的優勢更加明顯，其中又以南部地區表現最佳。在 30~40 毫米區間，雙偏極化方法的偏差在 ± 5 毫米內，均方根誤差低於 15 毫米。當雨量超過 40 毫米時，其偏差仍可維持在-15 毫米以內，均方根誤差低於 20 毫米。整體誤差明顯小於 AI 模型，顯示雙偏極化 QPE 方法對於強降雨事件仍具有較佳的估計能力。




圖 4. 颱風個案-AI 和雙偏極化方法的校驗結果。(a)雨量大於 0.5 毫米、(b)小雨(0.5~10 毫米)、(c)中雨(10~30 毫米)及(d)大雨(大於 30 毫米)。橫座標為偏差(Bias)，縱座標為均方根誤差(RMSE)，圓形代表 AI 降雨估計結果，三角形代表雙偏極化降雨估計結果。藍色、綠色、紫色及紅色分別代表北部、中部、南部及東部地區。不同顏色的陰影及外框則為 AI-QPE 與雙偏極化 QPE 校驗結果的分布範圍。

在梅雨個案中(圖 5a-5d)，整體降雨(大於 0.5 毫米；圖 5a)及小雨事件(圖 5b)的結果顯示，AI-QPE 於各區域皆具有較佳的估計表現，其偏差維持在 ± 1 毫米以內，均方根誤差普遍低於雙偏極化方法。顯示 AI 模型對弱降雨具有較佳的估計能力。相較之下，雙偏極化降雨估計明顯呈現高估現象。在中雨等級(圖 5c)，兩種方法開始呈現不同特性。在 10~20 毫米雨量區間，AI 與雙偏極化方法皆具有不錯的估計能力，與整體表現相近。但當雨量提升至 20~30 毫米時，AI 模型逐漸出現低估現象，偏差約在-6 至-12 毫米，均方根誤差也隨之增加。雙偏極化降雨估計仍能維持較小的偏差與均方根誤差，呈現較佳的估計表現。大雨階段(圖 5d)，雙偏極化方法的優勢更加明顯。於 30~40 毫米雨量區間，偏差及均方根誤差皆小於 AI 模型，其中以中、南部地區的估計結果最佳，偏差在 ± 5 毫米以內，均方根誤差低於 10 毫米。當雨量超過 40 毫米時，AI 模型低估現象更為明顯，偏差普遍大於-15 毫米，均方根誤差亦多超過 20 毫米，而雙偏極化方法仍能維持較穩定的估計能力，顯示其對強降雨事件具有較佳的適用性。




圖 5. 同圖 4，但為梅雨個案-AI 和雙偏極化方法的校驗結果。

綜合前述分析結果，颱風與梅雨兩種降雨型態皆呈現一致的校驗趨勢，即 AI-QPE 模型能有效改善弱降雨之定量降雨估計能力。然而，AI-QPE 模型的雨量估計誤差會隨著降雨強度增加而提高。相比之下，雙偏極化雷達 QPE 在時雨量超過 20 毫米的降雨區間能維持較穩定且誤差較小的表現，尤其在 40 毫米以上強降雨事件中有更明顯的優勢。基於上述成果，本研究已完成 AI-QPE 自動化作業模組之建置，每 10 分鐘可自動更新並穩定產製 2 項雷達定量降雨估計產品，包括最新至過去 3 小時的逐時雨量動畫(圖 6)，以及 1、3、6、12 及 24 小時即時

累積雨量圖(圖 7)，即時呈現降雨系統的時空分布與演變過程。相關產品已於天氣與氣候監測網(WATCH)的短延時專區，對外提供即時防救災情資服務(https://watch.ncdr.nat.gov.tw/watch_page_nowcast_v2)，協助使用者掌握最新降雨動態、降雨發展趨勢及極端降雨發生區域，提供防災決策與災害應變的重要參考資訊。




圖 6.AI 雷達定量降雨估計(XGBoost) - 最新至過去 3 小時的逐時雨量動畫。




圖 7.AI 雷達定量降雨估計(XGBoost) - 1、3、6、12 及 24 小時即時累積雨量圖。

五、 結論

本研究利用 XGBoost 模型架構，蒐集 2017 至 2024 年雷達與雨量觀測資料作為訓練資料，整合雷達回波強度、垂直液態水含量、回波頂高、地理資訊及地面雨量站等多元特徵，並結合時間序列資訊，建立 AI 雷達定量降雨估計模型。另以 2025 年資料作為獨立測試集進行驗證，結果顯示 AI-QPE 模型在降雨趨勢預警及絕對誤差表現上均具有良好成果，證實建置的 AI 雷達定量降雨估計模型具有良好的預估效率與可信度。

在 2025 年颱風及梅雨共 9 場降雨事件的驗證結果中，於 20 毫米以下的降雨區間，AI-QPE 模型受惠於大數據訓練，可有效改善弱降雨之定量降雨估計能力。然而，隨著降雨強度增加，AI-QPE 模型有較嚴重的低估問題，而雙偏極化降雨估計方法因能反映雨滴形狀、大小及數量等物理特性，在時雨量 20 毫米以上的降雨區間具有較穩定的估計表現，尤其是時雨量 40 毫米以上強降雨事件。此分析結果顯示兩種方法在不同降雨強度各具優勢。

AI-QPE 自動化作業模組已順利完成，並於天氣與氣候監測網的短延時專區對外服務。每 10 分鐘自動更新雷達定量降雨估計產品，提供即時累積雨量圖和逐時雨量動畫等資訊，協助使用者掌握最新降

雨動態與極端降雨發生區域，可作為防災決策與災害應變之重要參考。

本研究目前僅以 2025 年的事件進行初步分析，分析結果顯示 AI-QPE 與傳統雙偏極化 QPE 技術在不同降雨強度各具優勢。未來除持續優化 AI-QPE 模型效能外，亦將嘗試整合 AI 與雙偏極化降雨估計技術，研發適用於不同降雨強度的雷達定量降雨估計技術，以提升降雨監測、災害預警及防災應變之應用效益。

致謝

本研究感謝中央氣象署提供氣象雷達與雨量觀測資料。

參考文獻

1. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). <https://doi.org/10.1145/2939672.2939785>
2. Chen, W., W. Hua, M. Ge, F. Su, N. Liu, Y. Liu, and A. Xiong (2023b). Severe precipitation recognition using attention-unet of multichannel doppler radar. *Remote Sensing* 15(4), 1111.
3. Chen, Y., Liu, Y., & Zhang, H. (2024). High-resolution rainfall estimation using ensemble learning techniques and multisensor data integration. *Remote Sensing*, 16(5), 812–829.
4. Gagne, D. J., Haupt, S. E., Nychka, D. W., & Thompson, G. (2019). Interpretable machine learning for high-impact weather prediction. *Bulletin of the American Meteorological Society*, 100(8), 1579–1596.

5. Hassan, D., G. A. Isaac, P. A. Taylor, and D. Michelson (2022). Optimizing radar-based rainfall estimation using machine learning models. *Remote Sensing* 14(20), 5188.
6. Orellana-Alvear, J., R. Céleri, R. Rollenbeck, and J. Bendix (2019). Optimization of x-band radar rainfall retrieval in the southern andes of ecuador using a random forest model. *Remote Sensing* 11(14), 1632.
7. Wen, Y., J. Zhang, D. Wang, X. Peng, and P. Wang (2024). A quantitative precipitation estimation method based on 3d radar reflectivity inputs. *Sym-metry* 16(5), 555.
8. Wolfensberger, D., M. Gabella, M. Boscacci, U. Germann, and A. Berne (2020). RainForest: a random forest algorithm for quantitative precipitation estimation over Switzerland. *Atmospheric Measurement Techniques Discussions* 2020, 1–35.
9. Yang, X., Q. Kuang, W. Zhang, and G. Zhang (2017a). A terrain-based weighted random forests method for radar quantitative precipitation estimation. *Meteorological Applications* 24(3), 404–414.
10. Zhang, Y., S. Chen, W. Tian, and S. Chen (2021). Radar Reflectivity and Meteorological Factors Merging-Based Precipitation Estimation Neural Network. *Earth and Space Science* 8(10), e2021EA001811.