

# 應用基於 QPESUMS 與 GraphCast 產品之生成式系集擴散模型於臺灣降水即時預報研究

## Application of Generative Ensemble Diffusion Model Based on QPESUMS and GraphCast Products for Precipitation Nowcasting in Taiwan

國立中興大學土木工程學系

研究生

徐振泰

Chen-Tai Hsu

教授

陳佳正

Chia-Jeng Chen

### 摘要

降水即時預報(nowcasting)指的是結合觀測數據與模型模擬進行的短期降水預報方法，其準確性與可靠性乃氣象水文研究中重要的一環。目前，基於 AI 之氣象預測模型，如 Google DeepMind 發展之 GraphCast 模型，其降雨預報已展現宏觀預報效能，但在臺灣地區之表現仍有待評估。本研究以臺灣為研究區域，運用生成式系集擴散模型(Generative Ensemble Diffusion, GED)方法，其方法透過集成多個生成式擴散模型，提升降水預報的準確性與穩定性，並能捕捉天氣場中的細微變化，產生更可信的預報結果，再以臺灣作業化定量降雨系統(Quantitative Precipitation Estimation and Segregation Using Multiple Sensors, QPESUMS)作為主要輸入，結合 GraphCast 的東西向與南北向風速( $u$ 、 $v$  風)、位勢高度等氣象特徵，旨在融合兩者優勢，產出新的降雨預測。接著，將預測的降雨結果與由美國國家海洋暨大氣總署(National Oceanic and Atmospheric Administration, NOAA)以全球預報系統(Global Forecast System, GFS)初始化的 GraphCast 預報降雨資料及 QPESUMS 的觀測數據進行校驗分析指標評估。本研究產出的新即時預報產品可提升臺灣短期降雨預報的準確度與穩定性，增強極端天氣的預警能力，並具備整合至作業化氣象系統的潛力，促進氣象預報技術的進步與應用。

關鍵字：降水臨近預報、生成式集合擴散模型、深度學習、GraphCast

### Abstract

Nowcasting refers to a short-term precipitation forecasting method that combines observational data with model simulations, and its accuracy and reliability are crucial components of meteorological and hydrological research. Currently, AI-based weather forecasting models, such as the GraphCast model developed by Google DeepMind, have demonstrated significant performance in macro forecasting for rainfall, but their effectiveness

in Taiwan still needs to be evaluated. This study focuses on Taiwan as the research area and employs the Generative Ensemble Diffusion (GED) method, which enhances the accuracy and stability of precipitation forecasts by integrating multiple generative diffusion models. This method can capture subtle changes in the weather field, producing more reliable forecast results. The Taiwan operational quantitative rainfall system (Quantitative Precipitation Estimation and Segregation Using Multiple Sensors) serves as the primary input, combined with meteorological features such as east-west and north-south wind speeds ( $u$ ,  $v$  wind) and geopotential height from GraphCast. The aim is to merge the advantages of both approaches to generate new rainfall predictions. Subsequently, the predicted rainfall results will be validated against the rainfall data from GraphCast initialized by NOAA using GFS and observational data from QPESUMS for evaluation of analysis indicators. The new real-time forecasting product developed in this study can enhance the accuracy and stability of short-term rainfall forecasts in Taiwan, strengthen the early warning capabilities for extreme weather, and has the potential to be integrated into operational meteorological systems, promoting advancements and applications in meteorological forecasting technology.

Keywords: Precipitation Nowcasting; Generative Ensemble Diffusion Model; Deep Learning; GraphCast.

## 一、前言

隨著人工智慧技術的進步，AI 氣象預測系統，已展現出卓越的降雨預報能力，像是 Google DeepMind 所開發的 GraphCast 模型等。近年來，生成式集成擴散模型(Generative Ensemble Diffusion, GED)方法的發展，使得影像生成與時間序列預測在氣象領域展現出顯著的潛力。

機率擴散模型(Probabilistic Diffusion Models, PDM)屬於數據生成模型，其核心原理是生成過程遵循馬爾可夫鏈(Markov chain)，從初始的雜訊分布中隨機取樣開始，接著透過多次迭代轉換與去噪(Denoising)，直到生成的樣本與真實數據分布相似。去噪操作依賴於與擴散時間相關的分數函數(score function)，這些函數通常以深度學習架構實現，並透過訓練數據學習其參數(Ludwig et al., 2024)。GED 方法則透過多個生成式擴散模型的集成，逐步重建降雨的時空分布，捕捉氣象預報中固有的不確定性，並生成時間連貫的模擬結果。此種預報集合生成策略能提供多種可能的氣候場景，降低單一模型預測的不確定性，對降水預報具有重要的參考價值(Meuer et al., 2024)。

本研究以臺灣地區為研究範圍，結合 GraphCast 模型氣象特徵預報資料(包括東西向與南北向風速、位勢高度等氣象特徵)與臺灣作業化定量降雨系統(Quantitative Precipitation Estimation and Segregation Using Multiple Sensors, QPESUMS)資料，建立基於 GED 方法的降水預測系統。本研究採單次生成與集成生成兩種策略，分別評估預報之準確度與穩定性，並比較其於不同月份與時段的表現；驗證方面，以 NOAA(用 GFS

初始化) 的 GraphCast 預報及 QPESUMS 觀測資料進行校驗與量化指標評估。本研究開發的即時降水預報產品，具備提升極端降雨事件早期警示能力的潛力，亦可與作業化氣象監測系統整合，為臺灣地區的災害防救、水資源管理及氣象研究提供嶄新的工具與方法，並為生成式 AI 技術在氣象領域的應用開啟更廣泛的探索方向。

## 二、研究區域與資料

### 2.1 研究區域

本研究區域涵蓋臺灣全島面積約 36,193 平方公里及周圍海域，地理位置坐落於北緯 21.5°至 25.5°、東經 119°至 122°之間，屬於西太平洋上的海島。臺灣的氣候為亞熱帶與熱帶季風氣候，深受梅雨及颱風以及東北季風的影響，地區降雨有顯著的季節特性。由於島內擁有複雜的地形，特別是中央山脈的南北走向，使得降雨的空間分布不平均。在夏季，受對流旺盛、西南氣流及颱風帶來的迎風面效應影響，中南部地區及山區的降雨量顯著高於其他區域；而在冬季，則因東北季風的影響，北部與東北部為迎風面，降雨相對頻繁。此種受海島性、地形、季風等多樣氣候因子影響的複雜降雨模式，對降水預測系統的建立至關重要。

### 2.2 降雨量資料

降雨資料來源於中央氣象署(Central Weather Administration, CWA)與美國國家海洋暨大氣總署(National Oceanic and Atmospheric Administration, NOAA)共同開發的定量降水估計與多感測器分離系統(QPESUMS)。該系統整合了多種混合波段氣象雷達、雨量計及數值天氣預報模式分析資料等多元觀測資料，且依據回波強度(Z)與降水率(R)之間的經驗關係式進行降雨估算，並結合現場雨量計資料進行校正，最終生成高解析度(0.0125°、10 分鐘)的降水及劇烈天氣監測預報產品(Cheng et al., 2021)。但為配合 GraphCast 預報資料的解析度，本研究將 QPESUMS 資料進行降尺度與累積雨量處理，轉換為 0.25°以及 12 小時累積降雨之形式。

### 2.3 氣象特徵資料

氣象特徵預報資料來源於 Google DeepMind 所開發的 GraphCast 模型。該模型採用基於圖神經網路(Graph Neural Network, GNN)的「編碼-處理-解碼」架構，並引入了多網格內部表示法，在全球範圍內保持空間解析度的均勻性。GraphCast 的開發是利用歐洲中期天氣預報中心(European Centre for Medium-Range Weather Forecasts, ECMWF)的第五代再分析資料第五代再分析資料(ECMWF Reanalysis 5th Generation, ERA5)進行訓練與評估，透過最小化均方誤差(Mean Squared Error, MSE)並採用自迴歸訓練機制進行學習，最後生成 0.25°解析度的 10 天預報(Lam et al., 2023)。本研究使用由 NOAA 以 GFS 初始化的 GraphCast 預報降雨資料，時空解析度為 0.25°解析度的十天預報，每 12 小時初始化一筆資料，每筆為資料 6 小時累積降雨。

### 三、研究方法

#### 3.1 生成式集成擴散模型(Generative Ensemble Diffusion, GED)

由義大利波隆那大學與 Cineca 高效能運算中心(Cineca Interuniversity Consortium for High Performance Computing, Cineca)共同開發的生成式集成擴散模型。該模型基於去噪擴散隱式模型(Denoising Diffusion Implicit Models, DDIM)，並採用 U 型網路(U-Net Convolutional Neural Network, U-Net)作為去噪網路，其開發方式是透過將雜訊變異量與額外的氣象特徵(如前兩小時降水、前兩小時風速分量、地表掩膜 Land-Sea Mask (LSM) 及位勢高度圖)拼接在輸入影像的通道軸上進行無分類器引導(Classifier-Free Guidance, CFG)的條件設定。GED 的核心創新在於其集成預報方法，它生成一系列可能的氣候情景，這些情景隨後可透過簡單平均或使用獨立的後處理 U-Net 網路進行融合，以產生更具機率性的預測(Asperti et al., 2023)。

本研究將 QPESUMS 降雨資料與 Graphcast 的氣象特徵資料放入 DDIM 模型，首先從機率生成模型(probabilistic generative models)的角度切入，目標是找到一個參數向量  $\theta$ ，使得由神經網路參數化的分佈  $p_\theta(x_0)$  能夠近似於生成數據的真實分佈  $q(x_0)$ ，表示模型旨在生成初始數據  $x_0$  的分佈，它是通過對整個反向生成路徑積分得到的，其方程式如 (3-1)。

$$p_\theta(x_0) = \int p_\theta(x_{0:T}) dx_{1:T} \quad (3-1)$$

DDIM 的非馬爾可夫前向擴散過程，描述了從原始數據  $x_0$  逐步添加噪聲直到變成完全隨機的  $x_T$  的過程，方程式(3-2)。

$$q_\sigma(x_{1:T} | x_0) = q_\sigma(x_T | x_0) \prod_{t=2}^T q_\sigma(x_{t-1} | x_t, x_0) \quad (3-2)$$

前向擴散過程的結果，表明任何時間步  $t$  的加噪數據  $x_t$  都可以表示為原始數據  $x_0$  和一個標準高斯噪聲  $\epsilon_t$  (Gaussian noise) 的加權線性組合，方程式(3-3)。

$$x_t = \sqrt{a_t}x_0 + \sqrt{1 - a_t}\epsilon_t \quad (3-3)$$

研究中訓練的神經網路  $\epsilon_\theta(x_t, a_t)$  的目標是估計添加到  $x_0$  中以生成  $x_t$  的噪聲  $\epsilon_t$ 。  $f_t$  則是利用這個預測噪聲來估計原始數據  $x_0$ ，方程式(3-4)。

$$f_t(x_t, a_t) = \frac{x_t - \sqrt{1 - a_t}\epsilon_\theta(x_t, a_t)}{\sqrt{a_t}} \quad (3-4)$$

這是反向生成過程中說明模型如何使用估計的  $x_0(f_t)$  和噪聲  $\epsilon_\theta$  來從  $x_t$  生成去噪後的  $x_{t-1}$ ，方程式(3-5)。

$$x_{t-1} = \sqrt{a_t - 1}f_t(x_t, a_t) + \sqrt{1 - a_{t-1} - \sigma_t^2}\epsilon_\theta(x_t, a_t) \quad (3-5)$$

最終用於訓練模型的神經網路  $\epsilon_\theta$  的損失函數。它被解釋為預測噪聲  $\epsilon_\theta(x_t, t)$  與實際噪聲  $\epsilon_t$  之間加權均方誤差的形式。其方程式如(3-6)。

$$L_t = \mathbb{E}_{t \sim (1,T), x_0, \epsilon_t} [\gamma_t \|\epsilon_t - \epsilon_\theta(x_t, t)\|^2] \quad (3-6)$$

引導模型生成特定條件(Graphcast 的氣象特徵)下的降雨預測，採用了無分類器引導(Classifier-Free Guidance)的方法。通過訓練一個條件模型 $\epsilon_{\theta}(x_t, t, y)$ 和一個非條件模型 $\epsilon_{\theta}(x_t, t, 0)$ ，並將它們的預測結果進行加權組合來估計最終的噪聲，方程式如(3-7)。

$$\hat{\epsilon}_{\theta}(x_t, t, y) = \epsilon_{\theta}(x_t, t, y) + S \cdot \epsilon_{\theta}(x_t, t) \quad (3-7)$$

### 3.2 研究評估

為評估模型的性能，研究使用了均方誤差(Mean Squared Error, MSE)作為主要指標，也計算準確率(Accuracy)、精確率(Precision)和召回率(Recall)三個指標，更全面了解模型表現，方程式如(3-8)至(3-11)所示。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3-8)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3-9)$$

$$Precision = \frac{TP}{TP+FP} \quad (3-10)$$

$$Recall = \frac{TP}{TP+FN} \quad (3-11)$$

式中 $y_i$ 代表真實值； $\hat{y}_i$ 代表模型預測值； $n$ 代表總數；TP代表真陽性；TN代表真陰性；FP代表假陽性；FN假陰性。

## 四、初步成果、小結

目前已成功整合 QPESUMS 降雨資料與 Graphcast 氣象特徵資料，並成功啟動模型進行預測。相關指標仍在確認其準確性，T+12 的均方誤差 MSE(單位為 $mm^2$ )約在 10 萬至 20 萬之間，T+24 及 T+36 的誤差逐漸增加，整體趨勢合理。目前 MSE 中有很大部分來自海上狀況，若將焦點放在陸地部分，MSE 誤差應能顯著降低。模型預測的影像與 QPESUMS 相比，看起來有些差距。解析度目前為 16x16，表現可能不及高解析度資料，未來將嘗試輸入高解析度資料，並增加更多氣象特徵，使模型能根據更豐富的特徵進行降雨預測。

表 4-1 模型降雨預測與 QPESUMS 真實值

Time/Method	Single Diffusion	Ensemble Diffusion
T+12h	151144.781	125969.384
T+24h	744433.625	645497.575
T+36h	1504397.750	1393514.597

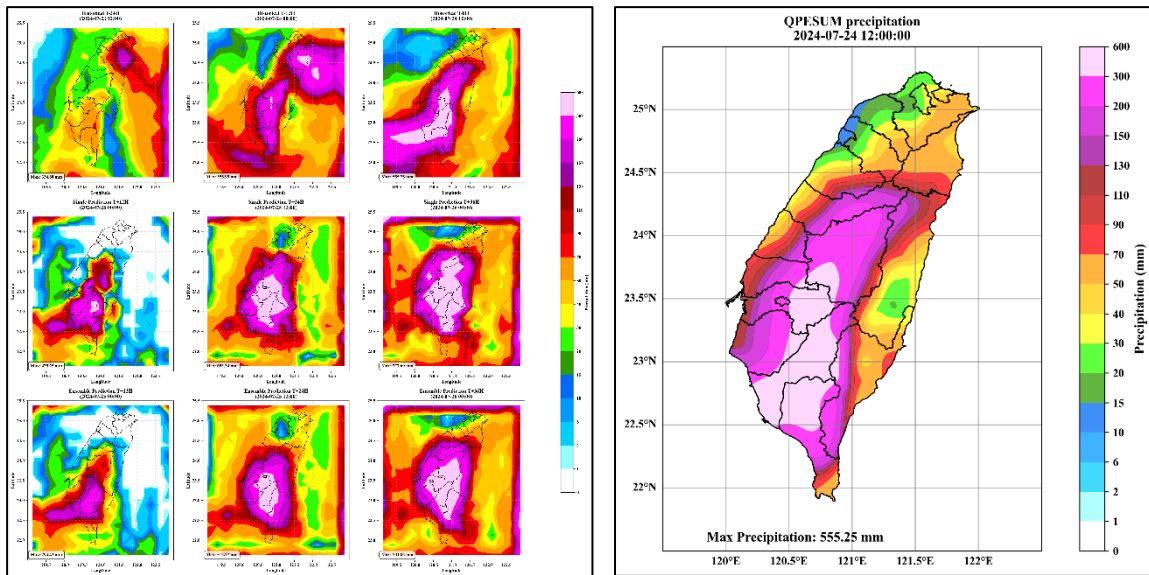


圖 4-1 (左)模型預測、(右)QPESUMS 真實降雨圖

圖 4-1 的左邊圖最上排依序從左到右是模型輸入 T-2、T-1、T+0 真實資料；中間排為單次擴散生成 T+1、T+2、T+3 降雨預測；底下排為集成擴散 T+1、T+2、T+3 降雨預測。右邊圖則是 QPESUMS 真實降雨圖。其中右圖應等於左圖左上方，用來對應輸入資料正確被模型使用。

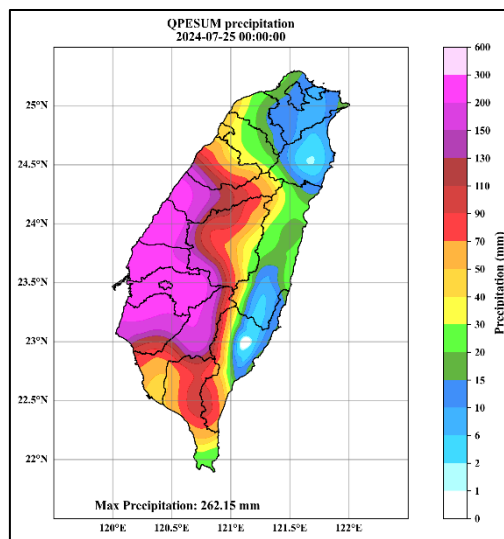


圖 4-2 QPESUMS 真實降雨圖

圖 4-2 應對應到單次與集成的 T+1 時間，用來對比模型預測降雨是否準確。但圖片看上去有些差異，需要找尋其原因然後進行優化。

## 五、參考文獻

1. Asperti, A., Merizzi, F., Paparella, A., Pedrazzi, G., Angelinelli, M., and Colamonaco, S., “Precipitation nowcasting with generative diffusion models”, *Applied Intelligence*, 55(3), 187, 2025.
2. Chang, P. L., Zhang, J., Tang, Y. S., Tang, L., Lin, P. F., Langston, C., ... and Howard, K., “An operational multi-radar multi-sensor QPE system in Taiwan”, *Bulletin of the American Meteorological Society*, 102(3), E555-E577, 2021.
3. Lam, R., Sanchez-Gonzalez, A., Willson, M., Wirnsberger, P., Fortunato, M., Alet, F., ... and Battaglia, P., “Learning skillful medium-range global weather forecasting”, *Science*, 382(6677), 1416-1421, 2023.
4. Li, L., Carver, R., Lopez-Gomez, I., Sha, F., and Anderson, J., “Generative emulation of weather forecast ensembles with diffusion models”, *Science Advances*, 10(13), eadk4489, 2024.
5. Meuer, J., Witte, M., Finn, T. S., Timmreck, C., Ludwig, T., and Kadow, C., “Latent Diffusion Model for Generating Ensembles of Climate Simulations”, arXiv preprint arXiv:2407.02070, 2024.
6. McGovern, A., Elmore, K. L., Gagne, D. J., Haupt, S. E., Karstens, C. D., Lagerquist, R., ... and Williams, J. K., “Using artificial intelligence to improve real-time decision-making for high-impact weather”, *Bulletin of the American Meteorological Society*, 98(10), 2073-2090, 2017.
7. Charlton-Perez, A. J., Dacre, H. F., Driscoll, S., Gray, S. L., Harvey, B., Harvey, N. J., ... and Volonté, A., “Do AI models produce better weather forecasts than physics-based models? A quantitative evaluation case study of Storm Ciarán”, *npj Climate and Atmospheric Science*, 7(1), 93, 2024.
8. Liu, C. C., Hsu, K., Peng, M. S., Chen, D. S., Chang, P. L., Hsiao, L. F., ... and Kuo, H. C., “Evaluation of five global AI models for predicting weather in Eastern Asia and Western Pacific”, *npj Climate and Atmospheric Science*, 7(1), 221, 2024.